



UNIVERSIDAD DE VALLADOLID

FACULTAD DE MEDICINA

ESCUELA DE INGENIERÍAS INDUSTRIALES

TRABAJO DE FIN DE GRADO

GRADO EN INGENIERÍA BIOMÉDICA

**DETERMINACIÓN DE LA PEEP ÓPTIMA EN
PACIENTES CON VENTILACIÓN MECÁNICA
UTILIZANDO INTELIGENCIA ARTIFICIAL**

Autor:

D.^a Susana Martín Maroto

Tutores:

Dr. D. Juan Pablo Casaseca de la Higuera

Dr. D.^a Elena Bustamante Munguira

Valladolid, septiembre de 2025

TÍTULO:	Determinación de PEEP Óptima en Pacientes con Ventilación Mecánica Invasiva Utilizando Inteligencia Artificial
AUTOR:	Susana Martín Maroto
TUTOR:	Dr. D. Juan Pablo Casaseca de la Higuera Dr. D. ^a Elena Bustamante Munguira
DEPARTAMENTO:	Departamento de Teoría de la Señal y Comunicaciones e Ingeniería Telemática Departamento de Medicina, Dermatología y Toxicología

TRIBUNAL

PRESIDENTE:	Dr. D. Juan Pablo Casaseca de la Higuera
SECRETARIA:	Dr. D. ^a Elena Bustamante Munguira
VOCAL:	Dr. D. Rodrigo de Luís García
SUPLENTE 1:	Dr. D. Miguel Ángel Martín Fernández
SUPLENTE 2:	Dr. D. Santiago Aja Fernández

Agradecimientos

Quiero comenzar agradeciendo a mis tutores, Pablo Casaseca de la Higuera y Elena Bustamante Munguira, por su orientación y apoyo constante durante la realización de este Trabajo de Fin de Grado. Gracias por su paciencia, su dedicación y por guiarme en todo momento para que pudiera dar lo mejor de mí en este proyecto.

También quiero dar las gracias a mis amigos, compañeros de carrera y de vida. Por convertir una etapa a la que llegué sin grandes expectativas en una llena de recuerdos valiosos que guardaré siempre.

A mi padre, por celebrar mis éxitos como si fueran suyos y saber restarle peso a lo que yo sentía como fracasos, recordándome que no eran más que parte del camino. También a mi hermana y a mi perro, por su compañía y cariño incondicional.

Y, por último, a mi madre, por transmitirme la fuerza que me ha sostenido todo este tiempo. Su huella ha estado en cada paso que me ha traído hasta aquí.

Resumen

La ventilación mecánica es esencial en pacientes críticos. El ajuste óptimo de la presión positiva al final de la espiración (PEEP) es clave para mejorar la oxigenación y reducir el daño pulmonar. Actualmente no existe un método estandarizado para su determinación. Esto impulsa el desarrollo de herramientas objetivas basadas en datos.

El objetivo de este trabajo fue desarrollar y evaluar modelos de inteligencia artificial para predecir parámetros fundamentales de la función respiratoria. Estos fueron la presión parcial de oxígeno (PaO_2), la presión parcial de dióxido de carbono (PaCO_2) y la distensibilidad pulmonar (Crs). Además, se buscó estimar el impacto de los ajustes de PEEP sobre dichos parámetros.

Se realizó un estudio con 23315 estancias en UCI procedentes de la base de datos MIMIC-III. Se incluyeron pacientes mayores de 16 años con ventilación mecánica y al menos una medición de PaO_2 , PaCO_2 o Crs. Tras un preprocesado con imputación, codificación y normalización de variables, se entrenaron tres modelos predictivos: red neuronal individual, red neuronal multitarea y Random Forest. Se evaluó el rendimiento con el error absoluto medio (MAE) y el error porcentual absoluto medio (MAPE). También se aplicaron métodos de interpretabilidad (Permutation Importance y valores de Shapley). Por último, se implementó una simulación para estimar los efectos de cambios hipotéticos en PEEP.

Random Forest logró los menores errores relativos en todas las predicciones. En gran parte de los modelos, la medición más reciente de la variable objetivo fue la que mostró mayor influencia en la predicción. Las simulaciones de cambios en PEEP generaron escenarios coherentes con respuestas fisiológicas plausibles.

Los modelos desarrollados permiten estimar con precisión parámetros respiratorios relevantes y simular el impacto de ajustes de PEEP usando solo datos clínicos rutinarios. Este enfoque podría servir como apoyo a la decisión clínica en UCI y favorecer una determinación de PEEP más personalizada y segura.

Palabras clave: Ventilación mecánica, PEEP, inteligencia artificial, redes neuronales, Random Forest, MIMIC-III, PaO_2 , PaCO_2 , Crs, Permutation Importance, valores de Shapley, simulación clínica.

Abstract

Mechanical ventilation is essential in critically ill patients. Optimal setting of positive end-expiratory pressure (PEEP) is key to improve oxygenation and reduce lung damage. Currently there is no standardized method for its determination. This drives the development of objective data-driven tools.

The aim of this study was to develop and evaluate artificial intelligence models to predict fundamental parameters of respiratory function. These were partial pressure of oxygen (PaO_2), partial pressure of carbon dioxide (PaCO_2) and respiratory system compliance (Crs). In addition, it was sought to estimate the impact of PEEP adjustments on these parameters.

A study was performed with 23315 ICU stays from the MIMIC-III database. Patients older than 16 years with mechanical ventilation and at least one measurement of PaO_2 , PaCO_2 or Crs were included. After preprocessing with imputation, coding and normalization of variables, three predictive models were trained: single neural network, multitask neural network and Random Forest. Performance was evaluated using the mean absolute error (MAE) and the mean absolute percentage error (MAPE). Interpretability methods (Permutation Importance and Shapley values) were also applied. Finally, a simulation was implemented to estimate the effects of hypothetical changes in PEEP.

Random Forest achieved the lowest relative errors in all predictions. In most of the models, the most recent measurement of the target variable showed the greatest influence on the prediction. Simulations of changes in PEEP generated scenarios with plausible physiological responses.

The developed models allow to accurately estimate relevant respiratory parameters and simulate the impact of PEEP adjustments using only routine clinical data. This approach could serve as clinical decision support in ICU and favor a more personalized and safer PEEP determination.

Key words: Mechanical ventilation, PEEP, artificial intelligence, neural networks, Random Forest, MIMIC-III, PaO_2 , PaCO_2 , Crs, Permutation Importance, Shapley values, clinical simulation.

Índice de contenidos

Capítulo 1. Introducción.....	21
1.1. Planteamiento del problema.....	21
1.2. Motivación.....	21
1.4. Hipótesis y objetivos	22
1.5. Fases del proyecto.....	23
1.6. Descripción del documento.....	23
Capítulo 2. Antecedentes y estado del arte.....	26
2.1. Fisiología básica de la respiración.....	26
2.1.1. Mecánica del ciclo respiratorio.....	26
2.1.2. Alteraciones que comprometen la función ventilatoria	27
2.1.2.1. Alteraciones obstructivas.....	27
2.1.2.2. Alteraciones restrictivas	28
2.1.2.3. Alteraciones del control ventilatorio central	28
2.1.2.4. Otras alteraciones.....	29
2.2. Ventilación mecánica	29
2.2.1. Modalidades según la vía de administración.....	31
2.2.1.1. Ventilación mecánica invasiva (VMI).....	31
2.2.1.2. Ventilación mecánica no invasiva (VMNI)	33
2.2.2. Modos ventilatorios registrados en la base de datos.....	35
2.2.3. Presión positiva al final de la expiración (PEEP).....	38
2.3. Estado del arte.....	39
Capítulo 3. Fundamentos de Machine Learning.....	44
3.1. Bases conceptuales	44
3.1.1. Fases de desarrollo y evaluación de un modelo de ML	44
3.1.2. Tipos de ML	46
3.1.3. <i>Overfitting</i> y sus soluciones	47
3.2. Modelos de ML empleados en el estudio.....	48
3.2.1. Redes neuronales individuales.....	49
3.2.2. Redes neuronales multitarea.....	54
3.2.3. Random Forest.....	54
3.3. Técnicas de interpretabilidad	59
3.3.1. Método Permutation Importance (PI)	59
3.3.2. Método SHAP (Shapley Additive Explanations).....	61

Capítulo 4. Materiales y métodos.	64
4.1. Materiales	64
4.1.1. Población de estudio	65
4.1.2. Variables incluidas en el estudio	66
4.1.2.1. Variables respiratorias	66
4.1.2.2. Variables circulatorias	68
4.1.2.3. Variables de laboratorio	68
4.1.2.4. Variables demográficas	69
4.1.3. Notación de las variables	70
4.1.4. División en entrenamiento y test	70
4.2. Metodología	70
4.2.1. Preprocesado de los datos	70
4.2.2. Configuraciones de entrada de los datos	72
4.2.3. Modelos predictivos	74
4.2.3.1. FNN aplicada en el estudio	74
4.2.3.2. FNN multitarea aplicada en el estudio	80
4.2.3.3. RF aplicado en el estudio	87
4.2.4. Interpretabilidad	88
4.2.4.1. Método PI aplicado en el estudio	88
4.2.4.2. Método SHAP aplicado en el estudio	88
4.2.5. Simulación de ajustes en la PEEP	89
Capítulo 5. Resultados.	92
5.1. Desempeño de los modelos predictivos	92
5.2. Análisis de la importancia de variables	98
5.2.1. Análisis mediante PI	98
5.2.1.1. Agrupado por modelos	98
5.2.1.2. Agrupado por variables objetivo	103
5.2.2. Análisis mediante valores de Shapley	107
5.2.2.1. Agrupado por modelos	107
5.2.2.2. Agrupado por variables objetivo	112
5.3. Evaluación de la simulación de los ajustes de la PEEP	131
Capítulo 6. Discusión.	136
6.1. Interpretación de la precisión de los modelos predictivos	136
6.2. Relevancia de las variables de entrada en la explicación de los resultados	138
6.2.1. Interpretación mediante PI	138

6.2.2. Interpretación mediante valores de Shapley.....	143
6.2.3. Comparación entre PI y valores de Shapley: análisis conjunto de patrones 149	
6.2.4. Perspectiva fisiológica de los resultados.....	155
6.3. Análisis crítico de la simulación de los ajustes de la PEEP	158
6.4. Comparación con otros estudios.....	159
6.5. Limitaciones.	161
Capítulo 7. Conclusiones y líneas futuras.	165
7.1. Contribuciones.....	165
7.2. Conclusiones.	165
7.3. Líneas futuras.	166
Anexo.	169
Bibliografía	185

Índice de tablas

Capítulo 2

Tabla 2.1. Modalidades de VM determinadas por quién controla el desarrollo de la fase inspiratoria del ciclo respiratorio.....	31
Tabla 2.2. Tipos de interfaces de VMNI (Gómez Mendoza et al., 2024).	34

Capítulo 4

Tabla 4.1. Capas de la FNN con la configuración “All Data”: tipo, salida y número de parámetros.	76
Tabla 4.2. Capas de la FNN con la configuración “30 Minutes Blinded”: tipo, salida y número de parámetros.	78
Tabla 4.3. Capas de la FNN con la configuración “60 Minutes Blinded”: tipo, salida y número de parámetros.	80
Tabla 4.4. Capas de la FNN múltiple con la configuración “All Data”: tipo, salida y número de parámetros.	82
Tabla 4.5. Capas de la FNN múltiple con la configuración “30 Minutes Blinded”: tipo, salida y número de parámetros.	85
Tabla 4.6. Capas de la FNN múltiple con la configuración “60 Minutes Blinded”: tipo, salida y número de parámetros.	86

Capítulo 5

Tabla 5.1. Rendimiento de los modelos para todas las configuraciones de entrada.....	93
Tabla 5.2. Ranking de importancia de características según PI — FNN, configuración “All Data”	98
Tabla 5.3. Ranking de importancia de características según PI — FNN multitarea, configuración “All Data”	99
Tabla 5.4. Ranking de importancia de características según PI — RF, configuración “All Data”	99
Tabla 5.5. Ranking de importancia de características según PI — FNN, configuración “30 Minutes Blinded”	100
Tabla 5.6. Ranking de importancia de características según PI — FNN multitarea, configuración “30 Minutes Blinded”	100
Tabla 5.7. Ranking de importancia de características según PI — RF, configuración “30 Minutes Blinded”	101
Tabla 5.8. Ranking de importancia de características según PI — FNN, configuración “60 Minutes Blinded”	101
Tabla 5.9. Ranking de importancia de características según PI — FNN multitarea, configuración “60 Minutes Blinded”	102
Tabla 5.10. Ranking de importancia de características según PI — RF, configuración “60 Minutes Blinded”	102
Tabla 5.11. Ranking de importancia de características según PI — PaO ₂ , configuración “All Data”	103
Tabla 5.12. Ranking de importancia de características según PI — PaCO ₂ , configuración “All Data”	104
Tabla 5.13. Ranking de importancia de características según PI — Crs, configuración “All Data”	104
Tabla 5.14. Ranking de importancia de características según PI — PaO ₂ , configuración “30 Minutes Blinded”	105
Tabla 5.15. Ranking de importancia de características según PI — PaCO ₂ , configuración “30 Minutes Blinded”	105
Tabla 5.16. Ranking de importancia de características según PI — Crs, configuración “30 Minutes Blinded”	106

Tabla 5.17. Ranking de importancia de características según PI — PaO ₂ , configuración "60 Minutes Blinded"	106
Tabla 5.18. Ranking de importancia de características según PI — PaCO ₂ , configuración "60 Minutes Blinded"	107
Tabla 5.19. Ranking de importancia de características según PI — Crs, configuración "60 Minutes Blinded"	107
Tabla 5.20. Ranking de importancia de características según los valores Shapley— FNN, configuración "All Data"	108
Tabla 5.21. Ranking de importancia de características según los valores de Shapley — FNN multitarea, configuración "All Data"	108
Tabla 5.22. Ranking de importancia de características según los valores de Shapley — RF, configuración "All Data"	109
Tabla 5.23. Ranking de importancia de características según los valores de Shapley — FNN, configuración "30 Minutes Blinded"	110
Tabla 5.24. Ranking de importancia de características según los valores de Shapley — FNN multitarea, configuración "30 Minutes Blinded"	110
Tabla 5.25. Ranking de importancia de características según los valores de Shapley — RF, configuración "30 Minutes Blinded"	111
Tabla 5.26. Ranking de importancia de características según los valores de Shapley — FNN, configuración "60 Minutes Blinded"	111
Tabla 5.27. Ranking de importancia de características según los valores de Shapley — FNN multitarea, configuración "60 Minutes Blinded"	112
Tabla 5.28. Ranking de importancia de características según los valores de Shapley — RF, configuración "60 Minutes Blinded"	112
Tabla 5.29. Ranking de importancia de características según los valores de Shapley — PaO ₂ , configuración "All Data"	113
Tabla 5.30. Ranking de importancia de características según los valores de Shapley — PaCO ₂ , configuración "All Data"	113
Tabla 5.31. Ranking de importancia de características según los valores de Shapley — Crs, configuración "All Data"	114
Tabla 5.32. Ranking de importancia de características según los valores de Shapley — PaO ₂ , configuración "30 Minutes Blinded"	114
Tabla 5.33. Ranking de importancia de características según los valores de Shapley — PaCO ₂ , configuración "30 Minutes Blinded"	115
Tabla 5.34. Ranking de importancia de características según los valores de Shapley — Crs, configuración "30 Minutes Blinded"	116
Tabla 5.35. Ranking de importancia de características según los valores de Shapley — PaO ₂ , configuración "60 Minutes Blinded"	116
Tabla 5.36. Ranking de importancia de características según los valores de Shapley — PaCO ₂ , configuración "60 Minutes Blinded"	117
Tabla 5.37. Ranking de importancia de características según los valores de Shapley — Crs, configuración "60 Minutes Blinded"	117
Tabla 5.38. PI de las variables predictoras para cada variable objetivo en la configuración "All Data". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.	120
Tabla 5.39. PI de las variables predictoras para cada variable objetivo en la configuración "30 Minutes Blinded". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.	122
Tabla 5.40. PI de las variables predictoras para cada variable objetivo en la configuración "60 Minutes Blinded". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.	123
Tabla 5.41. Valores de Shapley de las variables predictoras para cada variable objetivo en la configuración "All Data". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.	126

Tabla 5.42. Valores de Shapley de las variables predictoras para cada variable objetivo en la configuración "30 Minutes Blinded". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF. 128

Tabla 5.43. Valores de Shapley de las variables predictoras para cada variable objetivo en la configuración "60 Minutes Blinded". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF. 130

Capítulo 6

Tabla 6.1. Comparación de MAE y MAPE entre Händel et al. y este trabajo para FNN, FNN multitarea y RF en las configuraciones "All Data", "30 Minutes Blinded" y "60 Minutes Blinded". 160

Índice de figuras

Capítulo 3

Figura 3.1. Proceso de construcción de un modelo de ML (Rojas, 2020).....	45
Figura 3.2. Comparación entre una neurona biológica y una neurona artificial (Lao-León et al., 2017). ..	49
Figura 3.3. Estructura básica de la FNN (Chen et al., 2019).	52
Figura 3.4. Esquema básico de un árbol de decisión con su terminología (Sitio Big Data, 2019).	55

Capítulo 4

Figura 4.1. Visión general del flujo de trabajo en este estudio (Händel et al., 2024).	64
Figura 4.2. Representación del preprocesamiento aplicado a una observación ejemplo de la variable objetivo PaO ₂ (Händel et al., 2024).	73
Figura 4.3. Representación esquemática de la arquitectura de la FNN para la configuración “All Data” creada con PlotNeuralNet.	77
Figura 4.4. Representación esquemática de la arquitectura de FNN para la configuración “30 Minutes Blinded” creada con PlotNeuralNet.	79
Figura 4.5. Representación esquemática de la arquitectura de FNN para la configuración “60 Minutes Blinded” creada con PlotNeuralNet.	80
Figura 4.6. Representación esquemática de la arquitectura de FNN múltiple para la configuración “All Data” creada con PlotNeuralNet.	83
Figura 4.7. Representación esquemática de la arquitectura de FNN múltiple para la configuración “30 Minutes Blinded” creada con PlotNeuralNet.	85
Figura 4.8. Representación esquemática de la arquitectura de FNN múltiple para la configuración “60 Minutes Blinded” creada con PlotNeuralNet.	87

Capítulo 5

Figura 5.1. Comparación entre los valores reales y las predicciones del modelo FNN para la variable PaO ₂ , en la configuración “All Data”.	93
Figura 5.2. Comparación entre los valores reales y las predicciones del modelo FNN para la variable PaCO ₂ , en la configuración “All Data”.	93
Figura 5.3. Comparación entre los valores reales y las predicciones del modelo FNN para la variable Crs, en la configuración “All Data”.	93
Figura 5.4. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaO ₂ , en la configuración “All Data”.	94
Figura 5.5. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaCO ₂ , en la configuración “All Data”.	94
Figura 5.6. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable Crs, en la configuración “All Data”.	94
Figura 5.7. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaO ₂ , en la configuración “All Data”.	94
Figura 5.8. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaCO ₂ , en la configuración “All Data”.	94
Figura 5.9. Comparación entre los valores reales y las predicciones del modelo RF para la variable Crs, en la configuración “All Data”.	94
Figura 5.10. Comparación entre los valores reales y las predicciones del modelo FNN para la variable PaO ₂ , en la configuración “30 Minutes Blinded”.	95
Figura 5.11. Comparación entre los valores reales y las predicciones del modelo FNN para la variable PaCO ₂ , en la configuración “30 Minutes Blinded”.	95

Figura 5.12. Comparación entre los valores reales y las predicciones del modelo FNN para la variable Crs, en la configuración “30 Minutes Blinded”.....	95
Figura 5.13. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaO ₂ , en la configuración “30 Minutes Blinded”.	95
Figura 5.14. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaCO ₂ , en la configuración “30 Minutes Blinded”.	95
Figura 5.15. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable Crs, en la configuración “30 Minutes Blinded”.	95
Figura 5.16. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaO ₂ , en la configuración “30 Minutes Blinded”.	96
Figura 5.17. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaCO ₂ , en la configuración “30 Minutes Blinded”.....	96
Figura 5.18. Comparación entre los valores reales y las predicciones del modelo RF para la variable Crs, en la configuración “30 Minutes Blinded”.....	96
Figura 5.19. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaO ₂ , en la configuración “60 Minutes Blinded”.	96
Figura 5.20. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaCO ₂ , en la configuración “60 Minutes Blinded”.	96
Figura 5.21. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable Crs, en la configuración “60 Minutes Blinded”.	96
Figura 5.22. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaO ₂ , en la configuración “60 Minutes Blinded”.	97
Figura 5.23. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaCO ₂ , en la configuración “60 Minutes Blinded”.	97
Figura 5.24. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable Crs, en la configuración “60 Minutes Blinded”.	97
Figura 5.25. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaO ₂ , en la configuración “60 Minutes Blinded”.....	97
Figura 5.26. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaCO ₂ , en la configuración “60 Minutes Blinded”.....	97
Figura 5.27. Comparación entre los valores reales y las predicciones del modelo RF para la variable Crs, en la configuración “60 Minutes Blinded”.....	97
Figura 5.28. Simulación de ajustes de PEEP para el paciente con identificador de estancia en la UCI 200229.....	131
Figura 5.29. Simulación de ajustes de PEEP para el paciente con identificador de estancia en la UCI 211202.....	132
Figura 5.30. Simulación de ajustes de PEEP para el paciente con identificador de estancia en la UCI 251077.....	132

Anexo

Figura A.1. Importancia de variables basada en valores de Shapley para el modelo FNN en la predicción de PaO ₂ — configuración “All Data”.	169
Figura A.2. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaCO ₂ — configuración “All Data”.	170
Figura A.3. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de Crs — configuración “All Data”.	170
Figura A.4. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaO ₂ — configuración “All Data”.	171
Figura A.5. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaCO ₂ — configuración “All Data”.	171

Figura A.6. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de Crs — configuración “All Data”.	172
Figura A.7. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaO ₂ — configuración “All Data”.	172
Figura A.8. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaCO ₂ — configuración “All Data”.	173
Figura A.9. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de Crs — configuración “All Data”.	173
Figura A.10. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaO ₂ — configuración “30 Minutes Blinded”.	174
Figura A.11. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaCO ₂ — configuración “30 Minutes Blinded”.	174
Figura A.12. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de Crs — configuración “30 Minutes Blinded”.	175
Figura A.13. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaO ₂ — configuración “30 Minutes Blinded”.	175
Figura A.14. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaCO ₂ — configuración “30 Minutes Blinded”.	176
Figura A.15. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de Crs — configuración “30 Minutes Blinded”.	176
Figura A.16. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaO ₂ — configuración “30 Minutes Blinded”.	177
Figura A.17. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaCO ₂ — configuración “30 Minutes Blinded”.	177
Figura A.18. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de Crs — configuración “30 Minutes Blinded”.	178
Figura A.19. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaO ₂ — configuración “60 Minutes Blinded”.	179
Figura A.20. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaCO ₂ — configuración “60 Minutes Blinded”.	179
Figura A.21. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de Crs — configuración “60 Minutes Blinded”.	180
Figura A.22. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaO ₂ — configuración “60 Minutes Blinded”.	180
Figura A.23. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaCO ₂ — configuración “60 Minutes Blinded”.	181
Figura A.24. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de Crs — configuración “60 Minutes Blinded”.	181
Figura A.25. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaO ₂ — configuración “60 Minutes Blinded”.	182
Figura A.26. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaCO ₂ — configuración “60 Minutes Blinded”.	182
Figura A.27. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de Crs — configuración “60 Minutes Blinded”.	183

Acrónimos

Acrónimo	Significado
VM	Ventilación mecánica
UCI	Unidad de Cuidados Intensivos
PEEP	Presión positiva al final de la expiración
IA	Inteligencia Artificial
ML	Machine Learning
TFG	Trabajo de Fin de Grado
O₂	Oxígeno
CO₂	Dióxido de carbono
VMI	Ventilación mecánica invasiva
TET	Tubo endotraqueal
VMNI	Ventilación mecánica no invasiva
APRV	Ventilación con liberación de presión
A/C CMV	Ventilación Asistida-Controlada
CPAP	Presión positiva continua en la vía aérea
MMV	Ventilación mandatoria minuto
PCV	Ventilación controlada por presión
PRVC	Ventilación controlada a volumen y regulada a presión
PSV	Ventilación con presión de soporte
SIMV	Ventilación mandatoria intermitente sincronizada
SDRA	Síndrome de dificultad respiratoria aguda
PaO₂	Presión parcial de oxígeno en sangre arterial
PaCO₂	Presión parcial de dióxido de carbono en sangre arterial
Crs	Distensibilidad pulmonar
RR	Frecuencia respiratoria
VT	Volumen corriente
FiO₂	Fracción de oxígeno inspirado
SpO₂	Saturación periférica de oxígeno
HR	Frecuencia cardíaca
MAP	Presión arterial media
NE	Tasa de norepinefrina
INR	Índice Internacional Normalizado
NN	Red neuronal artificial
RF	Random Forest
RMSE	Raíz del Error Cuadrático Medio
MAE	Error Absoluto Medio
MAPE	Error Porcentual Absoluto Medio
FNN	Red neuronal <i>feedforward</i>
MTL	Aprendizaje multitarea

Capítulo 1. Introducción.

1.1. Planteamiento del problema

La ventilación mecánica (VM) representa un recurso esencial en el tratamiento de alteraciones respiratorias. En la unidad de cuidados intensivos (UCI) su uso se ha vuelto cada vez más frecuente. El propósito principal de su implementación es aliviar o reemplazar el trabajo respiratorio del paciente hasta que pueda recuperarlo y mantenerlo de manera autónoma (Castillo M & Andrés E, 2017).

A pesar de su utilidad, su aplicación implica una gran responsabilidad. Un ajuste inadecuado de los parámetros ventilatorios puede generar complicaciones y empeorar la evolución del paciente. Dentro de estos parámetros, la presión positiva al final de la espiración (PEEP) tiene un papel clave. Su influencia en la oxigenación arterial y en la mecánica pulmonar es directa y determinante.

El ajuste de la PEEP sigue siendo uno de los principales retos en la VM. A día de hoy no existe un criterio único ni un procedimiento estandarizado para definir su valor óptimo. Esto provoca una práctica clínica heterogénea, con diferencias entre profesionales y entre centros (Spatenkova et al., 2024).

Ante esta situación, es necesario contar con herramientas de apoyo que aprovechen los datos clínicos disponibles y ayuden a seleccionar una PEEP más segura y adaptada a cada paciente.

1.2. Motivación

Aunque en los últimos años ha aumentado el interés por el uso de inteligencia artificial (IA) en medicina, su aplicación en el ámbito de la VM sigue siendo escasa. Optimizar esta técnica es una tarea compleja y conlleva riesgos para los pacientes. Además, requiere un conocimiento profundo de la fisiopatología respiratoria. Por ello, el apoyo de la IA y el *Machine Learning* (ML) puede resultar de gran utilidad (Misseri et al., 2024).

El ajuste de la PEEP es especialmente complejo porque no existe un valor único que sea válido para todos los pacientes. Esta variabilidad hace que los métodos tradicionales

no siempre sean suficientes para guiar la decisión, lo que refuerza la necesidad de explorar enfoques alternativos.

En este contexto, el presente trabajo propone un nuevo enfoque basado en ML para ajustar la PEEP a partir de datos clínicos que ya se registran de forma habitual en la práctica asistencial. El propósito del modelo es proporcionar al profesional sanitario una estimación sobre cómo podría afectar una modificación de la PEEP a parámetros clave del éxito ventilatorio. Este enfoque busca contribuir a una toma de decisiones más objetiva, individualizada y basada en el análisis de grandes volúmenes de información.

1.4. Hipótesis y objetivos

Para realizar este trabajo de fin de grado (TFG), se plantea la hipótesis de que los métodos de IA, concretamente el aprendizaje profundo, permiten estimar de forma automática la PEEP en pacientes sometidos a VM, utilizando únicamente datos recogidos de manera rutinaria en la UCI. En consonancia con esta hipótesis, el objetivo general del presente trabajo consiste en desarrollar y evaluar modelos de ML para predecir la PEEP óptima, a partir de variables clínicas y ventilatorias extraídas del entorno de cuidados intensivos. Para alcanzar este objetivo, se ha realizado un análisis retrospectivo de los registros clínicos de pacientes ventilados incluidos en la base de datos pública Medical Information Mart for Intensive Care III (MIMIC-III), disponible en (A. Johnson et al., 2016).

Una vez definido el objetivo general, se detallan los objetivos específicos de este trabajo, que son necesarios para alcanzarlo:

1. Identificar el modelo de ML más adecuado para la predicción de las variables respiratorias seleccionadas.
2. Analizar qué variables presentan mayor relevancia en la predicción mediante el uso de técnicas de explicabilidad (XAI).
3. Evaluar la capacidad de los modelos para anticipar la evolución de las variables de salida ante distintos valores de PEEP, determinando así su capacidad para estimar la PEEP óptima.

1.5. Fases del proyecto

Con el fin de alcanzar los objetivos planteados, el desarrollo del proyecto se llevó a cabo a través de distintas fases consecutivas.

1. Realizar una revisión bibliográfica sobre el uso de IA en el ajuste automático de parámetros ventilatorios, especialmente de la PEEP.
2. Preprocesar los datos clínicos y ventilatorios de la base de datos MIMIC-III (A. Johnson et al., 2016), seleccionando las variables más relevantes para el entrenamiento del modelo.
3. Diseñar, entrenar y comparar modelos de regresión.
4. Evaluar el rendimiento de los modelos en distintas configuraciones de entrada.
5. Analizar la interpretabilidad de cada modelo mediante diversas técnicas.
6. Simular escenarios clínicos para observar el comportamiento de los modelos ante posibles ajustes de la PEEP, y valorar su utilidad como herramienta de apoyo clínico.
7. Extraer conclusiones sobre la viabilidad del modelo propuesto y proponer futuras líneas de investigación o mejoras.

1.6. Descripción del documento

El TFG se divide en 7 capítulos: introducción, antecedentes y estado del arte, fundamentos de ML, materiales y métodos, resultados, discusión y conclusiones y líneas futuras.

El Capítulo 1: ‘Introducción’ plantea el problema en el que se basa el presente estudio y la motivación para llevarlo a cabo. Además, se presentan la hipótesis y los objetivos y se describe brevemente la estructura del trabajo.

El Capítulo 2: ‘Antecedentes y estado del arte’ ofrece una visión general de los fundamentos fisiológicos de la respiración y de los aspectos clínicos relacionados con su alteración. Sobre esta base, se introduce el concepto de VM como herramienta de soporte en pacientes críticos y se contextualiza el papel de la PEEP dentro de este entorno. Además, se plantea el estado del arte.

El Capítulo 3: ‘Fundamentos de Machine Learning’ introduce las bases conceptuales de la disciplina. Expone los principios de las redes neuronales individuales (Izaurieta & Saavedra, 2000), de su enfoque multitarea (Caruana et al., 1997) y del modelo Random Forest (Breiman, 2001). Además, presenta los fundamentos de las técnicas de interpretabilidad empleadas.

El Capítulo 4: ‘Materiales y métodos’ presenta la base de datos y los criterios utilizados para seleccionar a los pacientes incluidos en el estudio. Se detallan las variables recogidas, agrupadas según su naturaleza fisiológica. También se describe el proceso de preprocesado, incluyendo imputación, codificación y normalización de datos. A continuación, se explican las distintas configuraciones de entrada diseñadas para simular escenarios clínicos reales. Se desarrollan los tres tipos de modelos predictivos aplicados en el estudio. Por último, se exponen las técnicas de interpretabilidad aplicadas y la estrategia seguida para simular ajustes en la PEEP.

El Capítulo 5: ‘Resultados’ muestra el rendimiento de los modelos predictivos en las distintas configuraciones de entrada. Se incluyen las métricas obtenidas para cada variable objetivo y la comparación entre modelos. También se presenta el análisis de importancia de variables. Por último, se exponen los resultados de la simulación de ajustes en la PEEP y su efecto estimado sobre las variables estudiadas.

El Capítulo 6: ‘Discusión’ interpreta los resultados y analiza las diferencias de rendimiento entre modelos y configuraciones. Se comentan los patrones observados en el análisis de importancia de las variables y su relación con la fisiología respiratoria. Además, se compara la coherencia de los hallazgos con estudios previos y se examina la utilidad y las limitaciones de la simulación de ajustes en la PEEP.

El Capítulo 7: ‘Conclusiones y líneas futuras’ resume las aportaciones principales del trabajo y presenta las conclusiones obtenidas. También propone mejoras metodológicas y nuevas líneas de investigación para aumentar la robustez y la aplicabilidad práctica del estudio.

Además, al final del documento se incorpora el Anexo: ‘Gráficas y valores de Shapley’ en el que se incluyen las gráficas de SHAP correspondientes a los distintos modelos y configuraciones analizados.

Capítulo 2. Antecedentes y estado del arte.

2.1. Fisiología básica de la respiración

La respiración es un proceso vital y continuo cuyo objetivo principal es el intercambio de oxígeno (O_2) y dióxido de carbono (CO_2). Dicha actividad requiere la interacción precisa y coordinada entre los distintos componentes del sistema respiratorio.

Resulta fundamental comprender los mecanismos que regulan la actividad respiratoria y su relación con otros sistemas. De esta forma, podremos reconocer de forma precoz las disfunciones que pueden aparecer cuando se pierde el equilibrio que mantiene su correcto funcionamiento (Puppo et al., 2021).

2.1.1. Mecánica del ciclo respiratorio

El diafragma es el principal músculo encargado de la inspiración en personas sanas. Cuando recibe señales enviadas del centro respiratorio a través de la placa motora, este se contrae. Provoca un desplazamiento hacia abajo que incrementa el diámetro vertical de la caja torácica y comprime la cavidad abdominal (Ramos Gómez, 2012).

Por tanto, la presión intrapleuraleal (P_{pl}) se reduce y la presión abdominal (P_{ab}) se incrementa, generándose así un gradiente de presión denominado presión transdiafragmática (P_{di}).

$$P_{di} (cmH_2O) = P_{ab} (cmH_2O) - P_{pl} (cmH_2O) \quad [1]$$

A su vez, la disminución de presión intrapleuraleal da lugar a otro gradiente de presión que actúa directamente sobre los pulmones. Este se denomina presión transpulmonar (P_L), y se obtiene restandole a la presión intrapleuraleal la presión de entrada a las vías respiratorias (P_{ao}).

$$P_L (cmH_2O) = P_{ao} (cmH_2O) - P_{pl} (cmH_2O) \quad [2]$$

Los cambios rítmicos en esta presión transpulmonar son los que, en última instancia, permiten que se produzca la ventilación alveolar (de Vries et al., 2018).

Durante situaciones de mayor demanda ventilatoria, como el ejercicio o ciertas enfermedades, se activan los músculos inspiratorios accesorios. Entre ellos se encuentran el esternocleidomastoideo, el escaleno, los intercostales externos y los músculos paraesternales. Su contracción contribuye a expandir la cavidad torácica. Esto genera una

disminución de presión intrapleuraleal y de las vías respiratorias en relación con la presión atmosférica. Esta diferencia de presiones favorece la entrada de aire hacia los pulmones, facilitando su expansión (Van Oosten et al., 2025).

Por otro lado, la espiración ocurre de forma pasiva en condiciones normales y en reposo. Esto es gracias al retroceso elástico de los pulmones y la caja torácica tras la relajación de los músculos inspiratorios.

No obstante, cuando aumenta la exigencia respiratoria, es necesario activar los músculos espiratorios. Los más relevantes son los músculos de la pared abdominal, y como auxiliares participan el intercostal interóseo interno y el triangular del esternón. Su acción provoca un aumento de presión en el abdomen y, si el diafragma no está contraído, esta presión se transmite al tórax, facilitando la salida de aire (de Vries et al., 2018).

2.1.2. Alteraciones que comprometen la función ventilatoria

Una vez explicada la mecánica respiratoria, es fundamental considerar aquellas situaciones en las que el proceso se ve alterado. Diversos factores pueden interferir en el intercambio gaseoso, ya sea dificultando la entrada y salida de aire, o afectando a la capacidad de generar los gradientes de presión necesarios para que ocurra la ventilación alveolar.

Estas alteraciones pueden comprometer el volumen y la eficacia del aire movilizado y, en consecuencia, poner en riesgo el equilibrio respiratorio del organismo. A nivel clínico, pueden clasificarse según el mecanismo predominante que las origina.

2.1.2.1. Alteraciones obstructivas

Las alteraciones obstructivas se caracterizan por una limitación al flujo aéreo durante la espiración, lo que provoca una salida más lenta del aire en comparación con sujetos sanos. Esto ocurre principalmente debido a procesos inflamatorios y estructurales que estrechan las vías respiratorias. Se genera así un incremento del volumen de aire que permanece atrapado en los pulmones tras la espiración.

Estas enfermedades representan una carga significativa para los sistemas de salud a nivel global, tanto por su elevada prevalencia como por los costes asociados a su tratamiento. En fases avanzadas, especialmente en pacientes con antecedentes de tabaquismo, suelen requerir soporte ventilatorio. La dificultad para lograr su retirada eficaz es bastante frecuente.

Entre las entidades más representativas del grupo obstructivo se encuentran la enfermedad pulmonar obstructiva crónica (EPOC), la bronquitis crónica, el enfisema pulmonar, el asma, las bronquiectasias, la bronquiolitis y la fibrosis quística (Correa et al., 2014).

2.1.2.2.Alteraciones restrictivas

Las alteraciones restrictivas comprenden un conjunto diverso de patologías que comparten como característica principal una limitación en la expansión pulmonar. Esta se traduce en una reducción significativa de los volúmenes pulmonares, especialmente de la capacidad pulmonar total (CPT).

Desde el punto de vista etiológico, estas enfermedades pueden clasificarse en dos grandes grupos. Por un lado, se encuentran las causas intrínsecas, en las que el tejido pulmonar está directamente afectado por inflamación, fibrosis o infiltración. Esto sucede en las enfermedades pulmonares intersticiales. Estas condiciones pueden comprometer tanto el intersticio alveolar como las zonas periféricas de los bronquios.

Por otro lado, están las causas extrínsecas, en las que el problema se origina fuera del pulmón. Estas consisten en limitaciones en la función neuromuscular y los movimientos de la caja torácica. Pueden ser originadas por enfermedades neuromusculares, trastornos pleurales, obesidad y otras condiciones que generan una limitación mecánica al proceso inspiratorio (Pedro Martínez-Pitre et al., 2023).

Independientemente de si el origen del trastorno es intrínseco o extrínseco, estas enfermedades llevan a trastornos del sueño, como el síndrome de apnea/hipopnea y/o hipoventilación, y en última instancia a hipoventilación mantenida en la vigilia. Esto incrementa el riesgo de insuficiencia respiratoria. Por ello, en etapas avanzadas, suele ser necesario recurrir al soporte ventilatorio como parte del tratamiento (Carlucci & Fusar Poli, 2023).

2.1.2.3.Alteraciones del control ventilatorio central

Las alteraciones del control ventilatorio central son un conjunto de patologías en las que el compromiso de la función ventilatoria se produce como consecuencia de una disfunción a nivel del sistema nervioso central. Se ven afectados los mecanismos automáticos que regulan la respiración.

A diferencia de las enfermedades de origen mecánico, ya sean obstructivas o restrictivas, en este caso la estructura anatómica del aparato respiratorio puede encontrarse conservada. Sin embargo, existe un déficit en la generación o transmisión del impulso ventilatorio necesario para mantener una respiración adecuada.

Algunas de estas afecciones son el síndrome de hipoventilación central congénita; la obesidad de inicio rápido con disfunción hipotalámica, hipoventilación y desregulación autonómica; la disautonomía familiar y la malformación de Chiari.

En estos trastornos, el soporte ventilatorio constituye una parte fundamental del tratamiento. Es especialmente importante durante el sueño, donde la hipoventilación suele ser más marcada. El objetivo principal es asegurar una ventilación y oxigenación adecuadas permitiendo mantener una buena calidad de vida y un desarrollo funcional lo más normalizado posible (Cielo & Marcus, 2014).

2.1.2.4. Otras alteraciones

Además de las alteraciones obstructivas, restrictivas y las disfunciones del control ventilatorio central, existen otros trastornos respiratorios que no encajan de forma estricta en estas categorías. Sin embargo, también pueden comprometer la función ventilatoria.

Dentro de la evaluación funcional respiratoria, pueden encontrarse casos en los que coexisten alteraciones tanto obstructivas como restrictivas, lo que se conoce como presentaciones mixtas. Esto ocurre, por ejemplo, en pacientes con fibrosis pulmonar y enfisema simultáneos (Cottin & Cordier, 2009). Otro caso significativo es el de pacientes con bronquiectasias extensas concurrentes con enfisema (Martínez et al., 2021). Estos cuadros pueden presentar dificultades diagnósticas y requieren una evaluación funcional e imagenológica cuidadosa.

También existen alteraciones ventilatorias que no responden a un patrón clásico. Estas en ocasiones están influidas por factores emocionales como la ansiedad. Otras causas posibles incluyen secuelas de intervenciones quirúrgicas torácicas, tratamientos como la radioterapia, o procesos inflamatorios previos, entre otros.

2.2. Ventilación mecánica

Se entiende por VM el conjunto de técnicas que utilizan un dispositivo mecánico con el fin de asistir o reemplazar la función ventilatoria. Su objetivo es provocar un

intercambio gaseoso más adecuado, facilitando la oxigenación y regulando la mecánica pulmonar cuando esta se ve comprometida.

La VM no constituye una terapia en sí misma. Es un soporte temporal destinado a mantener al paciente en condiciones fisiológicas estables mientras se trata la causa subyacente que motivó su indicación (Castillo et al., 2014).

Para entender los diferentes tipos y modos de VM, primero es necesario conocer cómo se clasifican las respiraciones mecánicas que puede recibir un paciente conectado a un ventilador. Cada inspiración puede dividirse en tres momentos: cuándo comienza, qué la limita y cuándo termina.

El inicio de la ventilación o *trigger* puede comenzar por una señal automática del ventilador, programada según una frecuencia establecida. También puede ser desencadenada por el propio esfuerzo respiratorio del paciente al superar un umbral de sensibilidad determinado. A continuación, durante la fase inspiratoria, se introduce aire en los pulmones hasta alcanzar un valor límite predefinido de presión, volumen o flujo, que regula el proceso sin interrumpirlo de forma inmediata. La inspiración termina cuando el ventilador detecta que se ha cumplido el criterio establecido para finalizar la inspiración activa. Esto se denomina ciclado. Por último, la espiración corresponde al vaciamiento pasivo del aire, completando así el ciclo respiratorio (Hickey et al., 2024).

Dependiendo de quién controle los distintos momentos del ciclo, ya sea el paciente o el ventilador, se distinguen cuatro formas de VM: controlada, asistida, soportada y espontánea.

- Controlada. En este modo, el ventilador se encarga por completo del ciclo respiratorio. Decide cuándo comienza la inspiración, cómo se administra y cuándo termina. Todos los parámetros están configurados previamente por el profesional de salud, sin intervención del paciente.
- Asistida. Es el paciente quien da inicio a la inspiración al alcanzar un nivel de esfuerzo definido por el sistema. Sin embargo, una vez que comienza, el ventilador determina cómo se lleva a cabo y cuándo finaliza. Esto es según los valores programados por el médico.

- Soportada. En este caso, la inspiración se inicia también por el paciente, quien controla su frecuencia respiratoria. El ventilador, por su parte, ofrece un nivel de ayuda fijado y concluye la inspiración una vez se alcanza ese límite.
- Espontánea. En esta modalidad, el paciente tiene el control total sobre su respiración. Decide cuándo empezar, cómo mantenerla y cuándo terminarla. Aunque está conectado al ventilador, este no impone el ritmo. Solo puede ofrecer un flujo continuo o soporte mínimo, según la configuración (Aguilar et al., 2024).

En la Tabla 2.1 se recogen las modalidades de VM según el control ejercido por el paciente o el ventilador en las distintas fases del ciclo respiratorio.

Formas de VM			
Tipo de respiración	<i>Trigger</i>	Límite	Ciclado
Controlada	Ventilador	Ventilador	Ventilador
Asistida	Paciente	Ventilador	Ventilador
Soportada	Paciente	Ventilador	Paciente
Espontánea	Paciente	Paciente	Paciente

Tabla 2.1. Modalidades de VM determinadas por quién controla el desarrollo de la fase inspiratoria del ciclo respiratorio.

2.2.1. Modalidades según la vía de administración

Tras comprender los principios básicos y los distintos modos de VM, resulta fundamental distinguir entre las dos grandes modalidades según la vía de administración del soporte ventilatorio: la ventilación mecánica invasiva (VMI) y la no invasiva (VMNI).

2.2.1.1. Ventilación mecánica invasiva (VMI)

La VMI es una forma de asistencia respiratoria que emplea presión positiva para impulsar aire a los pulmones a través de un acceso artificial a la vía aérea. Se aplica cuando el paciente no puede mantener una ventilación efectiva por sí mismo. Suele constituir una de las causas más frecuentes de ingreso en UCI. Habitualmente, la VMI se da mediante un tubo endotraqueal (TET) o traqueostomía.

El TET se emplea con frecuencia para administrar VM, tanto en intervenciones breves como en pacientes críticos en UCI. Este dispositivo incluye un balón distal que sella la vía aérea, evitando la aspiración de secreciones y permitiendo la ventilación con presión positiva. Sin embargo, una presión excesiva del balón sobre la tráquea puede comprometer la circulación sanguínea local y dañar la mucosa. Para reducir el riesgo de lesiones isquémicas, se recomienda mantener la presión del balón entre 20 y 30 cmH₂O. Aun así, el uso prolongado de tubos grandes o la insuflación con alta presión pueden generar complicaciones como estenosis traqueal, laringitis, úlceras, edema glótico o incluso fístulas (José Tincani et al., 2011).

Por otro lado, la traqueotomía es un procedimiento quirúrgico que puede realizarse en situaciones de urgencia o de forma programada. Se utiliza especialmente cuando es necesario facilitar la eliminación de secreciones abundantes o mantener la VM durante períodos prolongados. Aunque ofrece ventajas clínicas importantes en pacientes críticos, su uso exige una gestión cuidadosa. Esto es porque pueden surgir complicaciones como infecciones locales, obstrucción del tubo por secreciones o coágulos, fugas de aire y desplazamiento accidental del dispositivo. Dado su papel clave en la ventilación prolongada, el cuidado especializado del tubo de traqueostomía es esencial. Esto incluye el control de signos inflamatorios, el aseguramiento del sellado adecuado de la vía aérea y la prevención de complicaciones postoperatorias (Cardoso et al., 2025).

La decisión de iniciar VMI debe basarse en una valoración clínica precisa, considerando tanto el estado del paciente como el pronóstico. En situaciones complejas, también es recomendable abordar previamente con el paciente y su entorno familiar los objetivos del tratamiento. Una vez tomada la decisión, el paso de la respiración espontánea a una ventilación controlada supone un cambio crítico, especialmente en pacientes con inestabilidad hemodinámica o deterioro orgánico (Popat & Jones, 2012).

A continuación, se detallan las indicaciones más frecuentes para iniciar VMI:

1. Compromiso de las vías respiratorias. Se requiere ventilación cuando hay riesgo de obstrucción o pérdida del control de la vía aérea. Esto puede deberse a una disminución del nivel de conciencia o a bloqueos en las vías respiratorias, como en casos de angioedema, broncoespasmo o EPOC agudizada.

2. **Hipoventilación e hipercapnia.** Ocurre cuando no se ventila suficiente y se acumula CO₂. Puede deberse a fallo del impulso respiratorio, debilidad muscular o daño neurológico. También por problemas en la caja torácica o en los pulmones.
3. **Insuficiencia respiratoria hipoxémica.** Ocurre cuando los pulmones no oxigenan bien la sangre. Puede deberse a neumonía, edema, embolias o enfermedades que dificultan el paso del oxígeno como la fibrosis pulmonar.
4. **Aumento de la demanda ventilatoria.** En situaciones críticas como sepsis, shock o acidosis, la demanda de oxígeno supera la capacidad del paciente, por lo que se requiere soporte ventilatorio (Hickey et al., 2024).

2.2.1.2. Ventilación mecánica no invasiva (VMNI)

La VMNI consiste en proporcionar soporte respiratorio sin recurrir a métodos invasivos. Numerosos estudios respaldan su eficacia, ya que permite evitar la VMI, reduce el tiempo en la UCI y minimiza las complicaciones. Además, acorta la estancia hospitalaria, mejora la supervivencia y calidad de vida del paciente, y proporciona un alivio rápido de la disnea cuando se aplica tempranamente.

Dado su impacto positivo, es fundamental que la VMNI sea administrada por personal capacitado. Se deben seguir los protocolos establecidos y llevar una monitorización clínica adecuada, sin importar si se realiza en UCI, urgencias, unidades intermedias, planta hospitalaria o servicios prehospitalarios (Castuera Gil et al., 2023).

Uno de los factores clave para lograr una correcta adaptación y buena tolerancia a la VMNI es la selección adecuada de la interfase. Esta es entendida como el dispositivo que permite administrar el soporte ventilatorio al paciente sin necesidad de procedimientos invasivos.

Para que la VMNI sea efectiva, la interfase debe garantizar un sellado eficiente que evite fugas de aire, al tiempo que debe resultar cómoda y aceptable para el paciente. Existen diversas opciones de interfases que pueden clasificarse, de forma general, en seis tipos descritos en la Tabla 2.2 (Gómez Mendoza et al., 2024).

Tipos de interfaces	Descripción	Ilustración
Máscara oronasal	Cubre la boca y la nariz. Con o sin espaciador de frente.	
Máscara nasal	Cubre toda la nariz, pero no la boca. Con o sin espaciador de frente.	
Máscara oral	Colocado entre los labios del paciente. Las boquillas pueden tener varios grados de flexión.	
Máscara facial total	Cubre boca, nariz, ojos, y sella alrededor del perímetro de la cara.	
Almohadillas nasales	Subtipo de máscara nasal. Aplicado externamente sobre las narinas.	
Casco cefálico	Cubre toda la cabeza y todo o parte del cuello, sin contacto con la cabeza. Tiene al menos dos puertos.	

Tabla 2.2. Tipos de interfaces de VMNI (Gómez Mendoza et al., 2024).

La VMNI se utiliza principalmente en pacientes con insuficiencia respiratoria, ya sea de aparición aguda, crónica o en fase de descompensación. Su indicación se basa tanto en la evaluación clínica como en parámetros gasométricos. Entre los signos que justifican su inicio se incluyen:

1. Disnea de moderada o severa.
2. Frecuencia respiratoria elevada (más de 25 respiraciones por minuto).
3. Utilización de músculos accesorios o abdominales durante la respiración.

4. Relación $\text{PaO}_2/\text{FiO}_2$ inferior a 300.
5. Alteraciones en el equilibrio ácido-base, como hipercapnia ($\text{PCO}_2 > 45 \text{ mmHg}$) o acidosis (pH menor a 7,35).

No debe utilizarse en casos de parada cardíaca, necesidad urgente de intubación, inestabilidad hemodinámica, obstrucción grave de la vía aérea, hemorragia pulmonar abundante, exceso de secreciones difícil de controlar, o cuando el paciente está agitado, no coopera o rechaza el tratamiento.

Se recomienda precaución si hay neumotórax sin drenar, sangrados digestivos o nasales persistentes, embarazo, cirugía reciente en vía aérea o tracto digestivo, o si el personal no domina la técnica (Castuera Gil et al., 2023).

2.2.2. Modos ventilatorios registrados en la base de datos

A continuación, se describen específicamente aquellos modos de VM que se encuentran registrados en la base de datos utilizada (A. Johnson et al., 2016). Estos representan las configuraciones clínicas empleadas en los pacientes analizados.

- Ventilación con liberación de presión (APRV). Es una modalidad controlada por presión en la que se mantiene una presión positiva sostenida durante la mayor parte del ciclo respiratorio. Esta es interrumpida por descensos breves y periódicos a un nivel de presión inferior, sincronizados de forma temporal (Swindin et al., 2020). En algunos pacientes registrados en la base de datos utilizada, este modo se aplicó con configuraciones que permitían alternar dos niveles de presión y activaban automáticamente una ventilación de respaldo si no se detectaban respiraciones espontáneas.
- Ventilación Asistida-Controlada (A/C CMV). Es una de las formas más básicas de soporte ventilatorio. Está indicada principalmente en pacientes con insuficiencia respiratoria severa que requieren sustitución completa de la ventilación espontánea. En este modo, el ventilador puede iniciar los ciclos respiratorios automáticamente según una frecuencia mínima preestablecida. También permite que el paciente dispare la inspiración si realiza un esfuerzo por debajo del umbral de sensibilidad configurado. Puede funcionar controlando el

volumen o la presión, dependiendo de la variable que se haya programado en el dispositivo (Arnaldo et al., 2002).

En los pacientes analizados en este trabajo, se registraron diferentes combinaciones de este modo. Estas incluyeron versiones con asistencia inspiratoria y ajustes automáticos de la presión para alcanzar el volumen objetivo.

- Presión positiva continua en la vía aérea (CPAP). Se trata de un modo de respiración espontánea que incorpora presión positiva al final de la espiración (PEEP). Mantiene una presión superior a la atmosférica durante todo el ciclo respiratorio. Para asegurar un suministro adecuado de gas, el flujo tiene que ser elevado, superando las demandas del paciente. Además, las variaciones de presión deben mantenerse por debajo de 5 cmH₂O para evitar un aumento del trabajo respiratorio (Arnaldo et al., 2002).

En los pacientes incluidos en la base de datos utilizada, se registraron varias configuraciones basadas en este modo. Algunas de ellas combinaron el uso de CPAP con ventilación con presión de soporte ventilatorio (PSV). Otras incluyeron presión de soporte proporcional (PPS). También se observaron variantes que incorporaron sistemas de respaldo por volumen en caso de apnea.

- Ventilación mandatoria minuto (MMV). Es una estrategia de soporte respiratorio que garantiza al paciente un volumen minuto mínimo previamente definido. Este modo permite al paciente respirar por sí mismo. Si consigue alcanzar el volumen requerido de forma espontánea, el ventilador no actúa. Sin embargo, si la respiración espontánea no es suficiente, el equipo añade automáticamente respiraciones mecánicas para alcanzar el volumen total necesario. Tanto el volumen minuto objetivo como el volumen corriente administrado están configurados de antemano (Laaban et al., 2020).

En los pacientes incluidos en la base de datos utilizada, se utilizó tanto de forma aislada como en combinación con presión de soporte ventilatorio (PSV) y con ajustes automáticos de flujo.

- Ventilación controlada por presión (PCV). Es un modo de asistencia respiratoria en el que el ventilador se encarga completamente del trabajo respiratorio. Durante la inspiración, se administra aire hasta alcanzar una presión previamente definida. El objetivo es mantener abiertas las vías respiratorias y los alvéolos. Una vez alcanzada la presión establecida, la velocidad de flujo de aire se

mantiene constante durante toda la inspiración. Al finalizar este periodo, se inicia la espiración, durante la cual el sistema mantiene una presión positiva. Regula el flujo de salida según el tiempo espiratorio programado (Laaban et al., 2023).

En los pacientes incluidos en la base de datos también se identifican variantes de este modo de ventilación. Algunas incluían una versión avanzada de este modo, conocida como ventilación controlada por presión mejorada. Otras eran combinaciones con presión de soporte ventilatorio (PSV). También se dieron adaptaciones que permitían asistencia adicional al esfuerzo respiratorio del paciente.

- Ventilación controlada a volumen y regulada a presión (PRVC). Es un modo de VM que ajusta automáticamente la presión inspiratoria según los cambios en la mecánica respiratoria del paciente. El objetivo es garantizar un volumen corriente establecido, modificando la presión en cada respiración si las condiciones del paciente varían.

Permite reducir las presiones en la vía aérea. Es útil para aplicar ventilación protectora en pacientes con daño pulmonar, aunque requiere precaución si el esfuerzo respiratorio del paciente es elevado (Singer & Corbridge, 2011).

En los registros de los pacientes incluidos en la base de datos, se observa el uso del modo de ventilación PRVC en combinación con la estrategia asistida-controlada. Esta configuración permite adaptar la asistencia respiratoria tanto a las necesidades del paciente como a su capacidad de iniciar respiraciones espontáneas.

- Ventilación con presión de soporte (PSV). El sistema regula la presión aplicada durante la inspiración. El volumen corriente obtenido dependerá de la mecánica pulmonar del paciente, incluyendo su distensibilidad pulmonar y resistencia. Este modo se utiliza frecuentemente para disminuir el riesgo de barotrauma y reducir el esfuerzo respiratorio. Sin embargo, en algunos casos el volumen entregado puede ser excesivo. Para pacientes que mantienen respiración espontánea, el modo PSV es una opción habitual. Esto es porque permite proporcionar soporte inspiratorio sincronizado con los intentos respiratorios del paciente (Singer & Corbridge, 2011).

En algunos pacientes de la base de datos se empleó combinada con pruebas de respiración espontánea.

- Ventilación mandatoria intermitente sincronizada (SIMV). Es un modo de control por volumen. El ventilador proporciona un número fijo de respiraciones mecánicas, pero permite también que el paciente realice respiraciones espontáneas entre ellas. Estas respiraciones espontáneas se activan cuando la presión en la vía aérea desciende por debajo de un umbral determinado. SIMV se emplea comúnmente en pacientes con distintos grados de insuficiencia respiratoria y durante el proceso de retirada del soporte ventilatorio. Presenta desventajas como la posible asincronía entre paciente y ventilador o una asistencia excesiva (Abdelbaky et al., 2025).

En los pacientes de la base de datos analizada este modo se utilizó de forma combinada, principalmente con PSV y ajustes automáticos de flujo inspiratorio.

- Standby. En algunos registros, se observó que el ventilador se encontraba en modo de espera, lo que indica que no estaba suministrando ventilación activa al paciente. Este estado puede corresponder a momentos de desconexión temporal o fases posteriores a la extubación.

2.2.3. Presión positiva al final de la espiración (PEEP)

Los modos de VM descritos anteriormente representan configuraciones frecuentemente empleadas en el manejo clínico de pacientes bajo soporte respiratorio. La elección del modo ventilatorio debe adaptarse a cada paciente. Es fundamental garantizar seguridad clínica y una buena relación entre ventilación y perfusión. También hay que tener en consideración la mecánica presión-volumen del pulmón. Además, es importante lograr una buena sincronización entre el paciente y el ventilador. El confort respiratorio es otro aspecto clave al seleccionar el modo de soporte (Hickey et al., 2024).

En este contexto, adquiere especial relevancia el ajuste de ciertos parámetros clave, como la PEEP. Dado que es un elemento central en este estudio, a continuación, se explica con más profundidad.

La PEEP es un parámetro esencial en VM que mantiene una presión superior a la atmosférica en los alvéolos al final de la fase espiratoria. Aunque gran parte de la evidencia sobre su uso proviene de estudios en pacientes con síndrome de dificultad respiratoria aguda (SDRA), sus beneficios se aplican también a otras patologías pulmonares.

La PEEP puede clasificarse en dos formas: extrínseca, cuando es aplicada por el ventilador, e intrínseca o auto-PEEP, cuando se genera de manera no intencionada debido a una espiración incompleta. Esta última suele aparecer cuando el tiempo asignado para la espiración es insuficiente o cuando existe un colapso de las vías aéreas más pequeñas. También puede producirse por un aumento de la resistencia al flujo de aire, lo cual puede estar relacionado con factores como el uso de un TET demasiado estrecho, la presencia de broncoespasmo o la acumulación de secreciones en las vías respiratorias (Zersen, 2023).

La PEEP extrínseca óptima contribuye a mantener los alvéolos abiertos y evita su colapso al final de la espiración. Esto favorece una adecuada oxigenación arterial y mejora el aporte de O₂ al sistema nervioso central. Además, disminuye el shunt intrapulmonar y favorece la distensibilidad pulmonar, al disminuir las zonas mal ventiladas, ya sea por atelectasias o por sobredistensión.

La VM se usa en pacientes críticos para mantener una oxigenación adecuada y prevenir complicaciones. Sin embargo, aún no existe un método consensuado para ajustar de forma óptima la PEEP. Esta falta de acuerdo se debe a que hay múltiples variables implicadas y los efectos de la PEEP pueden variar según el perfil del paciente. En algunos casos, como pacientes con daño cerebral, un mal ajuste puede alterar la presión intracraneal o el flujo sanguíneo cerebral.

Actualmente se utilizan diversos métodos para determinar la PEEP: mediciones de distensibilidad pulmonar, curvas presión-volumen, índices de oxigenación, fracción de espacio muerto o herramientas como la tomografía de impedancia eléctrica. Muchos de estos enfoques buscan el punto de mejor equilibrio entre colapso alveolar y sobredistensión, para minimizar el daño pulmonar. A pesar de estas opciones, no hay un estándar universalmente aceptado. La selección de la PEEP sigue siendo individualizada y depende del contexto clínico (Spatenkova et al., 2024).

En este contexto, la inteligencia artificial (IA) surge como una herramienta prometedora para asistir en la estimación de la PEEP óptima.

2.3. Estado del arte

En la última década, el desarrollo del aprendizaje automático, especialmente en lo relativo a redes neuronales, ha experimentado un notable impulso. Paralelamente, el

entorno de cuidados intensivos ha intensificado la recogida y almacenamiento de datos clínicos. Esta confluencia ha favorecido la implementación progresiva de sistemas inteligentes de apoyo a la decisión clínica en la práctica diaria de las UCI (Händel et al., 2024).

Revisiones recientes muestran que el número de trabajos de ML en UCI se duplicó desde 2015. Sin embargo, la mayoría emplea métodos clásicos y se basan en cohortes pequeñas. Esto limita su fiabilidad. Solo un 6 % validan sus modelos en datos independientes, y la calidad predictiva mejora significativamente en grandes bases (> 100.000 pacientes). Este hallazgo enfatiza la necesidad de estudios robustos, con validación externa y métodos estandarizados (Shillan et al., 2019).

Hasta la fecha, existen reseñas que recogen más de 25 estudios sobre sistemas de soporte inteligente para VM. Muchos implementan modelos por *ensemble* (*boosting*), que han alcanzado precisiones de hasta el 94 % en predicción de parámetros como volumen tidal o éxito del destete o retirada de la VM. Sin embargo, estos trabajos presentan gran heterogeneidad en objetivos, tamaños de muestra y variables analizadas; además, carecen en general de validación externa. Estas limitaciones dificultan la transferencia de dichos sistemas a la práctica clínica (Ossai & Wickramasinghe, 2021).

Los algoritmos clásicos de ML han demostrado ser especialmente eficaces en tareas de regresión con datos tabulares. Entre ellos, los métodos basados en árboles de decisión han sido, y siguen siendo, una de las opciones más destacadas. Su simplicidad interpretativa y buen rendimiento los han mantenido como referentes en este tipo de problemas (Grinsztajn et al., 2022).

En el ámbito concreto de las UCI, varios trabajos han abordado problemas de regresión utilizando este tipo de enfoques. Algunos de ellos resultan especialmente relevantes por sus aportaciones metodológicas o por el tipo de variables que analizan.

1. Los autores del artículo (Ghazal et al., 2019) desarrollaron un modelo para predecir la saturación de oxígeno (SpO_2) en pacientes pediátricos. El objetivo era anticipar la SpO_2 cinco minutos después de modificar los ajustes del ventilador. Clasificaron los valores en tres rangos y aplicaron modelos supervisados, incluyendo redes neuronales y árboles agregados. El rendimiento del modelo fue limitado. La precisión no alcanzó niveles clínicamente aceptables, especialmente

en los rangos más bajos de saturación. Los autores atribuyen este resultado a la falta de datos suficientes en los casos más críticos.

2. En el artículo (Y. Luo et al., 2016) se refleja el uso de técnicas clásicas de aprendizaje automático para predecir valores de laboratorio a partir de otros análisis previos. Se aplicaron distintos modelos supervisados, como regresión logística, máquinas de vectores soporte y árboles de decisión. El objetivo era estimar si determinados parámetros, como la ferritina, se encontraban dentro o fuera del rango normal. Se obtuvieron resultados precisos, con áreas bajo la curva superiores al 0,9 en varios casos. No obstante, su enfoque se basó únicamente en datos analíticos, sin integrar información fisiológica ni otras mediciones clínicas.
3. En el trabajo (Peine et al., 2021) desarrollaron VentAI, un sistema basado en aprendizaje por refuerzo con el objetivo de recomendar configuraciones óptimas del ventilador. El modelo fue entrenado para ajustar parámetros como la PEEP, el volumen tidal y la fracción inspirada de oxígeno (FiO_2), utilizando datos clínicos procedentes de las bases MIMIC-III (A. Johnson et al., 2016) y eICU (Pollard et al., 2019). A diferencia de los enfoques supervisados, este método permitió considerar el efecto acumulado de las decisiones a lo largo del tiempo. VentAI mostró un rendimiento reproducible entre las dos cohortes analizadas.
4. En la investigación presentada en (Komorowski et al., 2018) propusieron el *AI Clinician*, un modelo de aprendizaje por refuerzo diseñado para optimizar el tratamiento hemodinámico en pacientes con sepsis. El agente fue entrenado con datos de MIMIC-III (A. Johnson et al., 2016) y validado en la base eICU (Pollard et al., 2019). Tomaba decisiones sobre el uso combinado de líquidos intravenosos y vasopresores. El modelo fue capaz de superar, en rendimiento teórico, las estrategias clínicas reales, sugiriendo tratamientos más conservadores y personalizados. Además, los pacientes cuya terapia coincidió con las recomendaciones del modelo presentaron menores tasas de mortalidad, lo que sugiere una posible utilidad futura en entornos reales.

En conjunto, estos trabajos evidencian el potencial de la IA en la toma de decisiones clínicas complejas.

El trabajo de (Händel et al., 2024) representa un punto de referencia clave. En él se propone un modelo de ML para predecir los efectos de distintos niveles de PEEP. Utilizan

bases de datos públicas, MIMIC-III (A. Johnson et al., 2016) y eICU (Pollard et al., 2019). Además, emplean variables clínicas habituales y un enfoque supervisado. Los resultados muestran un rendimiento sólido y una posible aplicación práctica en la UCI. Su planteamiento metodológico ha servido de base para el desarrollo de este trabajo.

Capítulo 3. Fundamentos de Machine Learning.

3.1. Bases conceptuales

El ML constituye una de las ramas principales de la IA que se caracteriza por no limitarse a ejecutar instrucciones predefinidas. En su lugar, desarrolla una forma de aprendizaje basada en la experiencia, similar en cierto sentido a la inteligencia humana. Para ello, emplea algoritmos capaces de analizar grandes cantidades de datos y establecer relaciones entre las variables disponibles. Gracias a este proceso, la máquina adquiere la capacidad de generar recomendaciones o incluso de tomar decisiones de manera autónoma.

El funcionamiento se basa en la repetición continua y en la actualización de los algoritmos. El sistema aprende a asociar entradas concretas con salidas esperadas, lo que le permite mejorar progresivamente su rendimiento (Helm et al., 2020).

Una vez obtenidas las predicciones, estas se contrastan con resultados ya conocidos. A partir de esa comparación, el sistema se ajusta de forma iterativa, refinando su precisión y aumentando su capacidad de anticipar escenarios futuros. Al recibir las mismas variables de entrada, el sistema no responde siempre de forma idéntica, sino que adapta sus salidas en función del contexto cultural, social y regional del usuario (Salas Flores et al., 2024).

3.1.1. Fases de desarrollo y evaluación de un modelo de ML

En ML, un modelo es la representación matemática que un algoritmo construye a partir de los datos. Puede adoptar formas muy diversas. En los casos más simples, se trata de una ecuación lineal que relaciona de manera directa las variables de entrada con las de salida. En cambio, en enfoques más avanzados, como las redes neuronales, el modelo es capaz de detectar características ocultas o patrones latentes que concentran la información más relevante de los datos (Bobadilla, 2021).

En la Figura 3.1 podemos ver los distintos pasos que llevan a la creación de un modelo de ML.



Figura 3.1. Proceso de construcción de un modelo de ML (Rojas, 2020).

El proceso comienza con la obtención de los datos, que pueden provenir de fuentes muy variadas. Esta fase es especialmente exigente, ya que recopilar información adecuada requiere tiempo y planificación cuidadosa.

Una vez reunidos los datos, se procede a su preparación, con el fin de asegurar que se encuentren en un formato útil para los algoritmos. En este punto se aplican técnicas de limpieza que corrigen inconsistencias y garantizan la calidad mínima necesaria para el análisis posterior (López, 2015). En esta etapa, se diferencia entre variables continuas y variables categóricas. Las primeras suelen normalizarse para que todas se encuentren en escalas comparables. Las segundas, al no tener un valor numérico intrínseco, requieren técnicas específicas de codificación. Entre las técnicas disponibles encontramos los *embeddings*. Estos permiten representar variables categóricas como vectores densos de números reales. De esta manera, categorías similares están más próximas en el espacio vectorial. Así, se permite que el modelo capture relaciones y similitudes entre categorías de manera más eficiente, mejorando su capacidad predictiva (Guo & Berkhahn, 2016).

Posteriormente, se lleva a cabo un análisis exploratorio, en el que se examinan las variables disponibles para detectar valores atípicos, patrones iniciales o registros incompletos.

Con los datos ya listos, se realiza el entrenamiento del modelo. Esto es la etapa en la que el algoritmo aprende a partir de la información disponible. Durante este proceso, se ajustan los parámetros internos para que el sistema sea capaz de generar representaciones útiles y emitir predicciones coherentes. Normalmente, para este fin se reserva una parte de los datos llamada conjunto de entrenamiento.

Finalmente, se pasa a la evaluación del modelo, donde se mide su capacidad predictiva y su utilidad en condiciones prácticas. En este punto, se utiliza un conjunto de test, formado por datos distintos a los del entrenamiento. De este modo, se puede comprobar si el sistema es capaz de generalizar y mantener un buen rendimiento al enfrentarse a información nueva. Si los resultados no son satisfactorios, el ciclo se reinicia, aplicando modificaciones en los parámetros o en el preprocesamiento de datos, con el fin de mejorar la precisión y robustez del sistema (López, 2015).

3.1.2. Tipos de ML

Los problemas de ML se pueden clasificar en alguno de los siguientes tipos.

1) Aprendizaje supervisado.

El aprendizaje supervisado es un enfoque de ML en el que cada dato de entrada está vinculado a una etiqueta o valor de referencia. El objetivo consiste en entrenar un modelo a partir de estas asociaciones, de modo que, una vez finalizado el proceso, pueda predecir la etiqueta o el valor correspondiente para nuevas entradas (Bobadilla, 2021). Según el tipo de salida esperada, puede emplearse:

- En tareas de clasificación, cuando se asignan categorías. El propósito es predecir el valor de una característica específica de los datos, denominada variable de clase o variable objetivo (Orenes et al., 2021).
- En problemas de regresión. Consisten en predecir un valor numérico continuo tomando en cuenta la información proporcionada por una o varias variables explicativas (Ondiviela, 2024).

2) Aprendizaje no supervisado.

El aprendizaje no supervisado se entiende como un enfoque en el que el modelo se entrena sin necesidad de disponer de datos previamente clasificados o etiquetados. A diferencia del aprendizaje supervisado, este método busca identificar estructuras internas en la información, agrupando ejemplos con características semejantes y revelando patrones ocultos dentro de los conjuntos de datos (Bishop, 2006). Puede utilizarse para:

- Modelos de clustering o agrupamiento. Permiten dividir un conjunto de información en varios grupos o clústeres. La idea principal es que los elementos

dentro de un mismo grupo presenten características similares entre sí, mientras que las diferencias con respecto a otros grupos sean mayores (Ezugwu et al., 2022).

- Reducción de dimensionalidad. Es una técnica de preprocesamiento que transforma datos con muchas variables en una representación más compacta y manejable. Su objetivo es condensar la información de manera que se conserven los patrones más relevantes, eliminando redundancias o valores poco informativos (Bobadilla, 2021).

3) Aprendizaje semi-supervisado.

Se trabaja con una combinación de datos etiquetados y no etiquetados. Este enfoque resulta especialmente útil en situaciones donde asignar etiquetas manualmente requiere mucho tiempo o esfuerzo humano. A partir de los datos etiquetados, el modelo aprende una primera versión que luego se emplea para estimar etiquetas en el conjunto no etiquetado. Estas nuevas etiquetas se reutilizan para mejorar el modelo mediante un reentrenamiento progresivo (Isasi Viñuela & Galván León, 2004).

4) Aprendizaje por refuerzo.

Este tipo de aprendizaje se sitúa entre los anteriores. La red recibe un conjunto de entradas y, tras producir una salida, se le indica si su respuesta fue adecuada o no. No se le proporciona la respuesta correcta, sino una señal de refuerzo que le permite aprender a partir de la experiencia. Es especialmente útil en entornos donde no se conoce con certeza cuál es la solución correcta en cada caso, pero sí se puede evaluar la calidad de la respuesta generada (Isasi Viñuela & Galván León, 2004).

3.1.3. *Overfitting* y sus soluciones

En el aprendizaje supervisado, uno de los desafíos más comunes es que el modelo no logre generalizar adecuadamente. Es decir, aunque funcione muy bien con los datos con los que fue entrenado, su rendimiento cae al enfrentarse a datos nuevos. Este problema se conoce como *overfitting*.

En esta situación, el modelo aprende de memoria los datos del conjunto de entrenamiento, incluidos los posibles errores o variaciones irrelevantes, en lugar de captar patrones generales útiles para la predicción. En consecuencia, su precisión disminuye notablemente cuando se evalúa con datos diferentes a los que usó para aprender.

Como estrategias para evitar el *overfitting*, encontramos las siguientes:

1. Detención temprana (*Early Stopping*).

Consiste en parar el entrenamiento cuando el rendimiento en validación deja de mejorar, evitando que el modelo aprenda ruido.

2. Reducción del modelo (*Model Reduction*).

Se simplifica el modelo eliminando partes irrelevantes. Puede hacerse durante el entrenamiento (*pre-pruning*) o después (*post-pruning*).

3. Ampliación de datos (*Data Expansion*).

Aumentar la cantidad o diversidad de ejemplos mejora la capacidad de generalización. Puede hacerse con nuevos datos, añadiendo ruido, o generando variantes de los existentes.

4. Regularización.

Consiste en aplicar ajustes durante el entrenamiento que limitan la influencia de características poco útiles, evitando que el modelo dependa demasiado de información irrelevante. Se divide en:

- a. L1: elimina directamente características que aportan poca información, favoreciendo que el modelo se quede solo con las más importantes.
- b. L2 (*Weight Decay*): limita la influencia de cada característica para que ninguna domine en exceso, lo que ayuda a que el modelo sea más equilibrado.
- c. *Dropout*: excluye temporalmente parte de la información o de las unidades del modelo para evitar dependencias excesivas. (Ying, 2019).

5. Normalización por lotes (*Batch Normalization*)

Aunque su objetivo principal es acelerar y estabilizar el entrenamiento, también ayuda a reducir el *overfitting*. Al normalizar la entrada de los datos en cada lote, introduce un ligero efecto regularizador similar al de *dropout* (P. Luo et al., 2019).

3.2. Modelos de ML empleados en el estudio

Aunque la literatura recoge una gran diversidad de algoritmos de ML, en el presente estudio se han seleccionado tres que destacan por su utilidad práctica y su aplicabilidad a

los datos analizados. A continuación, se describen los fundamentos de las redes neuronales, las redes neuronales multitarea y el Random Forest.

3.2.1. Redes neuronales individuales

Desde mediados del siglo XX, han surgido intentos de construir modelos informáticos que imiten cómo funciona el cerebro humano. Entre estos enfoques destacan las redes neuronales artificiales (NN). En ellas, cada nodo, llamado neurona artificial, actúa como una pequeña unidad de procesamiento que recibe información de otras y genera una salida (Gestal, 2014).

Conceptos básicos

Una forma clara de entender cómo funciona una neurona artificial es comparándola con una neurona biológica. Tal como se muestra en la Figura 3.2, ambas comparten una estructura funcional análoga. Las dendritas equivalen a las entradas del modelo artificial, las sinapsis a los pesos asignados a cada entrada, y el axón, por donde se transmite la señal nerviosa, representa la salida computada por la neurona. Esta salida se obtiene tras aplicar una función de activación sobre la combinación ponderada de todas las entradas recibidas (Lao-León et al., 2017).




Figura 3.2. Comparación entre una neurona biológica y una neurona artificial (Lao-León et al., 2017).

- Entradas de la neurona: x_i .

Corresponden a los estímulos que recibe la neurona en un instante de tiempo. Estas señales pueden provenir tanto del entorno externo como de otras neuronas del sistema.

- Pesos sinápticos: w_i .

Cada entrada está asociada a un peso que regula la influencia de dicha señal sobre la neurona receptora. Matemáticamente, este parámetro representa la intensidad de la conexión entre la neurona presináptica y la postsináptica. Los pesos pueden amplificar o reducir la señal según su signo y magnitud.

- Agregación de señales.

Todas las entradas ponderadas se combinan mediante una suma:

$$a = \sum_{i=1}^n w_i x_i \quad [3]$$

Este valor acumulado representa el estado interno de la neurona antes de decidir si se activa o no.

- Función de activación: f .

A la suma anterior se le aplica una función no lineal que determina la salida de la neurona.

- Salida: y .

Finalmente, la salida de la neurona se expresa como:

$$y = f\left(\sum_{i=1}^n w_i x_i\right) = f(a) \quad [4]$$

Esta salida puede pasar a otras neuronas o ser parte del resultado final de la red (Bertona, 2005).

Una NN puede entenderse como un conjunto de estas neuronas conectadas entre sí, organizadas por capas. Su estructura, las reglas con las que aprende, y la forma en que se entrena determinan su capacidad para resolver problemas. De hecho, uno de los aspectos más valorados de estas redes es su capacidad de adaptación, organización autónoma y tolerancia al fallo (Gestal, 2014).

Las funciones de activación, mencionadas anteriormente, desempeñan un papel fundamental en el funcionamiento de las NN. Permiten capturar características complejas a través de transformaciones no lineales. Estas funciones son clave para que la red pueda representar relaciones no lineales en los datos.

Para ser eficaces, las funciones de activación deben cumplir con dos propiedades deseables:

- a) Deben introducir suficiente no linealidad como para favorecer una convergencia más eficiente del entrenamiento.

- b) No deben implicar un coste computacional excesivo que ralentice el modelo (Dubey et al., 2022).

Dinámica de aprendizaje y ejecución

Cuando una NN se pone en marcha, su actividad puede dividirse en dos etapas principales: la fase de aprendizaje y la fase de ejecución.

En la fase de aprendizaje, el modelo ajusta sus parámetros internos para adquirir la capacidad de realizar una tarea específica. Este proceso implica la exposición a múltiples ejemplos que le permiten mejorar progresivamente su rendimiento. Las NN se entrenan fundamentalmente mediante aprendizaje supervisado, y en algunos casos mediante enfoques semi-supervisados. Una vez completado este proceso y alcanzado un nivel de precisión aceptable, se pasa a la fase de operación, en la cual la red ya entrenada se emplea para resolver el problema real para el que fue diseñada (Bertona, 2005).

En esta etapa, se pone en práctica lo aprendido. Una ventaja clave de este tipo de sistemas es que no solo memorizan ejemplos, sino que son capaces de captar patrones dentro de los datos. Esto les permite aplicar ese conocimiento a situaciones nuevas (Isasi Viñuela & Galván León, 2004).

NN de tipo feedforward (FNN)

En este estudio se utilizaron FNN totalmente conectadas (*fully connected*) con arquitectura personalizada de múltiples entradas.

Las FNN se caracterizan por un flujo unidireccional de información, avanzando exclusivamente desde la entrada hacia la salida sin bucles ni retroalimentaciones.

En la Figura 3.3 podemos observar la estructura básica de una FNN. Se compone de una capa de entrada, una o varias capas ocultas y una capa de salida, donde cada nodo está conectado con los de la capa siguiente.




Figura 3.3. Estructura básica de la FNN (Chen et al., 2019).

Este tipo de redes se entrena comúnmente mediante el algoritmo de *backpropagation* del error, que ajusta iterativamente los pesos y sesgos del modelo con el objetivo de reducir el error entre las salidas previstas y las reales. Para ello, se aplica un método de optimización basado en el descenso del gradiente (Jiang et al., 2017).

A continuación, se explica en mayor profundidad este enfoque.

El entrenamiento de la FNN se basa en minimizar una función de pérdidas. En concreto, se emplea el error cuadrático medio (MSE) como criterio de ajuste de los parámetros del modelo. Si se tienen N muestras de entrenamiento, la pérdida global puede definirse como el promedio del error individual sobre todas ellas:

$$\mathcal{L}(W, b) = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad [5]$$

Donde:

- W son los pesos.
- b son los sesgos.
- $\hat{y}_i$ es la salida predicha por la red para la muestra i .
- y_i es el valor real correspondiente a esa muestra.

Para encontrar los valores de W y b que minimicen la función de pérdidas se utiliza el algoritmo de descenso por gradiente. Este actualiza los parámetros en cada paso en función del gradiente de la pérdida:

$$W_{nuevo} = W_{anterior} - \eta \cdot \nabla_W \mathcal{L}(W, b) \quad [6]$$

$$b_{nuevo} = b_{anterior} - \eta \cdot \nabla_b \mathcal{L}(W, b) \quad [7]$$

Aquí, η es la tasa de aprendizaje, que determina el tamaño del paso en cada actualización.

El proceso de entrenamiento se organiza en épocas, que son pasadas completas por el conjunto de entrenamiento. En lugar de procesar todos los datos a la vez, se dividen en mini-batches por motivos de eficiencia y estabilidad numérica.

Una época recorre todas las muestras una vez. Un mini-batch es un grupo pequeño de ejemplos que se usa para calcular el gradiente. Cada mini-batch genera un step de actualización de parámetros.

Por tanto, el flujo completo de entrenamiento consiste en los siguientes pasos:

1. Se mezclan los datos de entrenamiento.
2. Se dividen en mini-batches.
3. Para cada mini-batch:
 - 3.1. Se calcula el error (MSE).
 - 3.2. Se actualizan los parámetros.
4. Se repite este proceso para todos los mini-batches.
5. Se reitera el ciclo durante un número total de épocas.

Este procedimiento permite que la red mejore gradualmente su capacidad de predicción, reduciendo el error en cada iteración (Zarzuela, 2023).

Una de las principales fortalezas de las FNN es su capacidad para aproximar funciones no lineales con alta precisión. Sin embargo, también presentan limitaciones: por ejemplo, pueden quedar atrapadas en óptimos locales durante el entrenamiento y suelen requerir tiempos de convergencia prolongados debido a la naturaleza del algoritmo de optimización empleado.

3.2.2. Redes neuronales multitarea

El aprendizaje multitarea (MTL, por sus siglas en inglés) es un paradigma del aprendizaje automático en el que un modelo es entrenado para resolver varias tareas a la vez, en lugar de aprender cada una de forma independiente. Este enfoque parte de la idea de que tareas relacionadas pueden beneficiarse mutuamente durante el entrenamiento al compartir representaciones intermedias. El MTL mejora la generalización, reduce el *overfitting* y aumenta la eficiencia (Caruana et al., 1997).

En el contexto de NN, esto se implementa mediante una arquitectura compartida. En ella, las capas iniciales aprenden representaciones comunes a todas las tareas y las capas finales se dividen en ramas específicas para cada salida. Esta estructura permite que el modelo capture patrones comunes y específicos, promoviendo una transferencia de conocimiento entre tareas.

En conclusión, la principal diferencia respecto a las NN individuales es que, en lugar de entrenar un modelo separado para cada tarea, la red multitarea permite resolver varias de ellas de manera conjunta dentro de una misma arquitectura.

Al tratarse de un modelo basado igualmente en NN, también del tipo *feedforward*, los fundamentos que rigen su funcionamiento son esencialmente los mismos que los explicados previamente.

3.2.3. Random Forest

Para comprender el funcionamiento del algoritmo Random Forest (RF), es necesario partir de los conceptos clave de los árboles de decisión.

Conceptos básicos de los árboles de decisión

Los algoritmos basados en árboles de decisión constituyen una herramienta fundamental dentro del ML. Son ampliamente utilizados en tareas de clasificación, regresión y selección de características.

Su funcionamiento se basa en dividir progresivamente el conjunto de datos en subconjuntos más homogéneos, guiándose por los valores de las distintas variables de entrada. Este proceso da lugar a una estructura en forma de árbol, donde cada nodo representa una condición sobre una variable. Cada rama conduce a una nueva división o a un resultado final. El criterio para realizar estas divisiones suele depender de medidas

que permiten seleccionar en cada paso la variable más informativa (Domor Mienye & Jere, 2016).

Antes de profundizar, conviene familiarizarse con algunos términos clave que definen la estructura de un árbol de decisión. En la Figura 3.4 se representan algunos de ellos.




Figura 3.4. Esquema básico de un árbol de decisión con su terminología (Sitio Big Data, 2019).

- El nodo raíz o nodo de decisión superior es el punto de partida del árbol y representa el conjunto completo de datos. A partir de este nodo se generan las primeras divisiones hacia subconjuntos más homogéneos.
- La división es el procedimiento mediante el cual un nodo se separa en dos o más subnodos, según ciertas condiciones.
- Nodo de decisión se refiere a cualquier nodo que, al ser dividido, da lugar a nuevos subnodos. Es un punto intermedio donde aún se toman decisiones.
- Nodos hoja o terminales son aquellos nodos finales del árbol que no se dividen más. Representan una decisión o una predicción concreta.
- La poda consiste en eliminar nodos del árbol para reducir su complejidad y mejorar su capacidad de generalización, es decir, el proceso inverso a dividir.
- Rama o subárbol corresponde a una porción del árbol que incluye un nodo y todos sus descendientes. Puede considerarse un árbol en sí mismo dentro del árbol mayor.
- Cuando un nodo se divide, se le denomina nodo padre, y los subnodos generados a partir de él se llaman nodos hijos.

Entre las principales ventajas de los árboles de decisión destaca su facilidad de interpretación, ya que su estructura permite visualizar el proceso de toma de decisiones de forma clara y comprensible. Además, requieren muy poco procesamiento previo de los datos, sin necesidad de normalización ni codificación especial para variables numéricas o categóricas. Otro aspecto favorable es su bajo coste computacional en la fase de predicción, incluso cuando se entrenan con conjuntos de datos de gran tamaño. Por último, al tratarse de modelos de tipo “caja blanca”, permiten justificar cada salida mediante reglas lógicas simples, lo que mejora su transparencia y explicabilidad.

Entre sus principales desventajas, los árboles de decisión presentan una marcada tendencia al sobreajuste si no se regulan adecuadamente ciertos parámetros, como la profundidad máxima del árbol o el número mínimo de muestras por nodo. Además, son modelos sensibles a pequeñas variaciones en los datos, lo que puede dar lugar a estructuras significativamente diferentes entre ejecuciones. Otro aspecto limitante es su dificultad para capturar patrones complejos que no se ajustan bien a divisiones jerárquicas simples, como los casos del problema XOR. Por último, cuando el conjunto de datos está desbalanceado, existe el riesgo de que el modelo genere predicciones sesgadas hacia las clases mayoritarias (Pedregosa et al., 2024).

Medidas de selección de atributos

Las medidas de selección de atributos son técnicas empleadas para determinar qué variable utilizar al dividir un nodo dentro de un árbol de decisión. Estas métricas, también conocidas como funciones de partición, permiten identificar el punto más adecuado para separar los datos y crear ramas más homogéneas.

Cada característica del conjunto de datos recibe una puntuación basada en su capacidad para organizar la información de forma eficiente. La variable con el valor más alto se selecciona como criterio de división en ese nodo. En el caso de variables continuas, también es necesario definir el valor umbral que determina la separación entre ramas.

Las medidas más utilizadas se describen a continuación.

1) Entropía.

La entropía es una medida de la impureza o aleatoriedad presente en un conjunto de datos. Se utiliza principalmente en árboles de decisión como criterio para evaluar qué tan homogénea es una partición. Si todas las instancias de un subconjunto pertenecen a la

misma clase, la entropía es 0. En cambio, si las clases están equilibradamente distribuidas, la entropía es máxima.

Sea $\mathcal{L}$ un conjunto de datos con j clases posibles, y p_i la proporción de elementos pertenecientes a la clase i , entonces la entropía se define como:

$$Entropía(\mathcal{L}) = - \sum_{i=1}^j p_i \log_2(p_i) \quad [8]$$

Esta fórmula calcula la suma ponderada de las probabilidades de cada clase multiplicadas por el logaritmo binario de dichas probabilidades. El resultado representa el grado de incertidumbre del sistema. Cuanto menor es la entropía tras una división, más efectiva es la variable utilizada para dividir el nodo (Tangirala, 2020).

2) Ganancia de información.

La ganancia de información es una métrica derivada de la entropía y se emplea para determinar qué atributo proporciona la mejor partición de un conjunto de datos. Mide la reducción de la incertidumbre al dividir el conjunto original según los valores de una variable específica.

Al evaluar un atributo, se calcula primero la entropía del conjunto completo y luego la entropía ponderada de los subconjuntos resultantes tras aplicar la división. La diferencia entre ambas representa la ganancia de información:

$$IG(\mathcal{L}, f) = Entropía(\mathcal{L}) - \sum_{v=1}^V \frac{|\mathcal{L}^v|}{|\mathcal{L}|} Entropía(\mathcal{L}^v) \quad [9]$$

Donde:

- $\mathcal{L}$ es el conjunto original de datos,
- f es la característica evaluada,
- $\mathcal{L}^v$ representa los subconjuntos generados por los distintos valores de f ,
- $\frac{|\mathcal{L}^v|}{|\mathcal{L}|}$ es el peso relativo de cada subconjunto.

Cuanto mayor sea la ganancia de información, más eficaz es el atributo f para clasificar correctamente los datos. Por tanto, los algoritmos de construcción de árboles de decisión suelen escoger el atributo con mayor ganancia como criterio de partición en cada nodo (Tangirala, 2020).

3) Índice Gini.

El índice Gini es una medida de impureza que evalúa la calidad de una partición en un conjunto de datos. A diferencia de la entropía, que utiliza logaritmos, el índice Gini se basa en la probabilidad de clasificación incorrecta si se asignara una clase al azar según la distribución de clases en los datos. Se calcula como:

$$GINI(\mathcal{L}) = 1 - \sum_{i=1}^j p_i^2 \quad [10]$$

Donde:

- $\mathcal{L}$ es el conjunto de datos analizado,
- j es el número de clases posibles,
- p_i representa la proporción de instancias de la clase i en $\mathcal{L}$.

El valor del índice Gini es mínimo (cero) cuando todos los elementos del conjunto pertenecen a una sola clase, lo que indica una partición completamente pura. A medida que aumenta la mezcla de clases, el índice Gini se aproxima a su valor máximo.

Cuando se aplica una división en el conjunto de datos, se calcula el índice Gini ponderado de los subconjuntos resultantes. El atributo que produzca la menor impureza total será seleccionado como el mejor para dividir el nodo (Tangirala, 2020).

Fundamentos de RF

La estrategia del algoritmo RF consiste en generar múltiples árboles de decisión contruidos de forma aleatoria. Sus predicciones se combinan habitualmente mediante promedios para obtener un resultado más robusto. Este método ha mostrado un desempeño notable, especialmente en contextos donde la cantidad de variables supera con creces al número de muestras disponibles. Asimismo, destaca por su capacidad para adaptarse a problemas de gran escala, ajustarse a tareas de aprendizaje específicas y ofrecer estimaciones del grado de relevancia de cada variable en el modelo (Biau & Scornet, 2016).

El algoritmo de RF mantiene muchas de las ventajas propias de los árboles de decisión. Mejora su rendimiento mediante técnicas como el *bagging*, la selección aleatoria de variables y un sistema de votación por mayoría.

Este enfoque permite manejar eficazmente tanto datos faltantes como variables de distintos tipos (continuas, binarias o categóricas), lo que lo hace especialmente adecuado para trabajar con conjuntos de datos de alta dimensión.

A diferencia de los árboles de decisión tradicionales, los árboles que conforman un bosque aleatorio no requieren ser podados, ya que la estrategia de ensamblado y el muestreo con reemplazo (*bootstrap*) mitigan los riesgos de sobreajuste (Zhang & Ma, 2012).

3.3. Técnicas de interpretabilidad

Para entender mejor cómo los modelos realizan sus predicciones, se aplican técnicas de interpretabilidad. Estas herramientas permiten analizar la influencia que tiene cada variable de entrada sobre el resultado del modelo. Así, es posible identificar cuáles son más relevantes.

3.3.1. Método Permutation Importance (PI)

La importancia de una característica mediante permutación se define como el incremento en el error del modelo al desordenar aleatoriamente los valores de dicha característica. Se interrumpe así su relación con la variable objetivo. Esta técnica evalúa cuánto depende el modelo de esa característica para realizar sus predicciones.

Una característica se considera relevante si, al modificar sus valores, el rendimiento del modelo disminuye notablemente. En cambio, si el modelo mantiene un rendimiento similar tras alterar esa variable, se deduce que su contribución a la predicción era mínima o inexistente.

El uso de la permutación para evaluar la relevancia de las características fue introducido originalmente por Leo Breiman en 2001 en el contexto de los RF. A partir de este enfoque, Fisher, Rudin y Dominici propusieron una generalización del método, aplicable a cualquier tipo de modelo predictivo. Este enfoque permite medir la dependencia del modelo con respecto a cada entrada, sin necesidad de conocer su estructura interna (Fisher et al., 2019).

Algoritmo de PI

Para aplicar este método, se parte de un modelo ya entrenado, al que llamamos $\hat{f}$, junto con un conjunto de datos de test compuesto por una matriz de características X y el

vector de salidas verdaderas y . Además, se define una métrica de evaluación L , que puede ser cualquier función de error adecuada como MSE, MAE o MAPE, entre otras.

El primer paso consiste en calcular el error del modelo sobre el conjunto de test sin modificar. A este valor se le llama error base u original. Se calcula como el promedio de la métrica de error aplicada a cada predicción:

$$e_{orig} = \frac{1}{n_{test}} \sum_{i=1}^{n_{test}} L(y^{(i)}, \hat{f}(x^{(i)})) \quad [11]$$

Aquí, n_{test} representa el número total de muestras en el conjunto de test, e i es el índice que recorre esas muestras (desde 1 hasta n_{test}). El término $x^{(i)}$ corresponde al vector de características de la muestra i , mientras que $y^{(i)}$ es el valor verdadero de la salida asociada a esa muestra.

Una vez se ha calculado este error base, se procede a analizar el impacto de cada variable de forma individual. Para ello, se toma una columna de la matriz de entrada (es decir, una característica concreta j) y se permutan aleatoriamente sus valores entre las distintas muestras. Esto rompe cualquier estructura o correlación que esa variable pudiera tener con la variable objetivo. Se genera así una nueva versión de la matriz de entrada, en la que todo se mantiene igual excepto los valores de esa característica concreta, que han sido desordenados.

Con esta matriz modificada, se vuelve a evaluar el modelo y se calcula el nuevo error de predicción:

$$e_{perm,j} = \frac{1}{n_{test}} \sum_{i=1}^{n_{test}} L(y^{(i)}, \hat{f}(x_{perm,j}^{(i)})) \quad [12]$$

Finalmente, se cuantifica la importancia de la característica como la diferencia o el cociente entre el nuevo error y el error original. Las dos formas más comunes de expresarlo son:

$$FI_j = e_{perm,j} - e_{orig} \quad [13]$$

$$FI_j = \frac{e_{perm,j}}{e_{orig}} \quad [14]$$

Tras repetir este proceso para cada variable, se obtienen sus valores de importancia relativa. Estos pueden ordenarse para identificar cuáles son las características que más influyen en el comportamiento del modelo (Molnar, 2025).

3.3.2. Método SHAP (Shapley Additive Explanations)

Este método permite la identificación y jerarquización de las variables más influyentes en la predicción realizada, independientemente del modelo de ML utilizado. Asigna a cada característica un valor que representa su contribución específica a una predicción concreta.

Este enfoque se basa en principios de teoría de juegos cooperativos, donde cada característica se considera un “jugador” que colabora en el resultado del modelo. Para distribuir de manera justa la importancia entre todas las variables, SHAP recurre al valor de Shapley. Consiste en una solución matemática que evalúa todas las combinaciones posibles de características y determina cuánto aporta cada una de ellas, en promedio, al resultado final. De esta forma, se consigue una explicación precisa, coherente y teóricamente fundamentada sobre cómo influye cada variable en la salida del modelo (Rozemberczki et al., 2022).

Algoritmo para sacar los valores de Shapley

Matemáticamente, si se denota por $f(x)$ la predicción del modelo para una instancia x , y por $E|f(x)|$ el valor esperado de las predicciones en todo el conjunto de datos, la predicción puede descomponerse como:

$$f(x) = E|f(x)| + \sum_{j=1}^p \phi_j \quad [15]$$

Donde:

- ϕ_j representa el valor de Shapley asociado a la variable j ,
- p es el número de variables de entrada.

El valor ϕ_j se interpreta como la contribución media marginal de la variable j a lo largo de todas las posibles combinaciones de variables presentes y ausentes. Para calcularlo de forma general, se utiliza la siguiente expresión:

$$\phi_j = \sum_{S \subseteq N \setminus \{j\}} \frac{|S|! (p - |S| - 1)!}{p!} [f_{S \cup \{j\}}(x) - f_S(x)] \quad [16]$$

Donde:

- $N = \{1, 2, \dots, p\}$ es el conjunto total de variables,
- S es un subconjunto de variables que no incluye a la variable j ,
- $f_S(x)$ es la predicción del modelo considerando únicamente las variables en S ,
- $f_{S \cup \{j\}}(x)$ es la predicción al añadir la variable j a ese subconjunto.

El término $\frac{|S|!(p-|S|-1)!}{p!}$ actúa como un peso que garantiza una distribución equitativa sobre todas las posibles permutaciones de las variables.

Esta definición general es válida para cualquier modelo predictivo, ya sea lineal, basado en RF, NN, o modelos de caja negra. Sin embargo, el cálculo exacto de ϕ_j es computacionalmente costoso, ya que requiere evaluar el modelo en un número exponencial de combinaciones de entrada (es decir, 2^p subconjuntos posibles). Por ello, en la práctica se utilizan aproximaciones o algoritmos específicos optimizados para ciertas familias de modelos (Lundberg et al., 2017).

Capítulo 4. Materiales y métodos.

En la Figura 4.1 se presenta el esquema general del flujo de trabajo desarrollado en el estudio. Sirve como punto de partida para la comprensión global del enfoque adoptado.




Figura 4.1. Visión general del flujo de trabajo en este estudio (Händel et al., 2024).

A partir de la base de datos MIMIC-III (A. Johnson et al., 2016), se realiza la selección de pacientes junto con la extracción de sus variables clínicas. A continuación, los datos se dividen en conjuntos de entrenamiento y prueba, que sirven respectivamente para ajustar los modelos de aprendizaje automático y para valorar su precisión. Una vez entrenados, los modelos se aplican a escenarios con distintos niveles de PEEP, lo que permite obtener predicciones y analizar el comportamiento de las variables respiratorias. Por último, se evalúa tanto el rendimiento alcanzado como la validez de las simulaciones generadas.

4.1. Materiales

Como se ha mencionado con anterioridad, la base de datos utilizada en este TFG es MIMIC-III (A. Johnson et al., 2016). Constituye un recurso público muy utilizado en investigación biomédica. Aunque es de libre acceso para la comunidad científica, su descarga está restringida a usuarios acreditados de Physionet (PhysioNet, 2025) que cumplan ciertos requisitos. Esta base contiene datos clínicos anonimizados de pacientes ingresados en UCI del Beth Israel Deaconess Medical Center de Boston, recogidos entre los años 2001 y 2012. Incluye información detallada sobre constantes vitales, resultados de laboratorio, administración de medicamentos, procedimientos médicos, notas clínicas, informes radiológicos y datos de mortalidad. Para este proyecto, se obtuvo acceso tras completar la formación CITI “Data or Specimens Only Research” y firmar el acuerdo de

uso de datos correspondiente. El uso de la base se realizó respetando todas las condiciones éticas y de confidencialidad exigidas (A. E. W. Johnson et al., 2016).

4.1.1. Población de estudio

La base MIMIC-III (A. Johnson et al., 2016) contiene registros clínicos correspondientes a 53.423 ingresos hospitalarios de pacientes mayores de 16 años atendidos en UCI entre los años 2001 y 2012. En total, incluye datos de 38.597 pacientes adultos únicos. Además, incorpora información de 7.870 neonatos ingresados entre 2001 y 2008. La edad mediana de los pacientes adultos es de 65,8 años, con un rango intercuartílico de 52,8 a 77,8 años. Alrededor del 56 % de los casos corresponden a varones. La mortalidad hospitalaria alcanza un 11,5 %.

La estancia media en UCI tiene una duración mediana de 2,1 días (rango intercuartílico: 1,2 - 4,6), mientras que el tiempo total de hospitalización asciende a 6,9 días de media (Q1 - Q3: 4,1 - 11,9). Para cada episodio hospitalario, se recogen miles de observaciones clínicas registradas manualmente (una media de 4.579 por ingreso), así como resultados de laboratorio y otras mediciones (A. E. W. Johnson et al., 2016).

En este trabajo, al igual que en (Händel et al., 2024), se seleccionaron únicamente las estancias en UCI que cumplían tres criterios:

1. El paciente tenía 16 años o más en el momento del ingreso. Se excluyeron los casos pediátricos por presentar características fisiológicas y necesidades ventilatorias distintas a la población adulta.
2. Había recibido VM durante su estancia en UCI. El estudio se centra en la predicción y ajuste de parámetros ventilatorios, por lo que solo tienen relevancia los pacientes que recibieron soporte ventilatorio.
3. Existían registros disponibles de al menos uno de los siguientes parámetros respiratorios: presión parcial de oxígeno en sangre arterial (PaO_2), presión parcial de dióxido de carbono en sangre arterial (PaCO_2) o distensibilidad pulmonar (Crs). Estos son esenciales como objetivos de predicción y como referencia clínica en el análisis de la PEEP. Sin al menos uno de estos registros, no sería posible aplicar ni validar los modelos desarrollados.

Tras aplicar estos filtros, se obtuvo una cohorte final de 23.315 estancias en UCI, correspondientes a 20.328 pacientes únicos. Esto es puesto que algunos de estos pacientes

fueron ingresados en UCI en más de una ocasión a lo largo del periodo registrado. Esta muestra fue la utilizada para llevar a cabo los análisis del estudio.

4.1.2. Variables incluidas en el estudio

Las variables seleccionadas para el estudio presentan diferente naturaleza y comportamientos, lo cual se tuvo en cuenta a la hora de estructurar los datos.

Algunas variables son configuradas, mientras que otras son medidas. Algunas presentan un comportamiento temporal, cambiando con frecuencia, mientras que otras se mantienen constantes durante toda la estancia en UCI. También se diferencian según su tipo de dato: algunas son continuas y otras categóricas.

En función de la variable y de su relación fisiológica con la medición objetivo (es decir, el momento en el que se registró la variable a predecir), se aplicaron distintos criterios para seleccionar las mediciones. En algunos casos se incluyó la medición más reciente disponible antes del momento de análisis. En otros se excluyeron los datos registrados en los últimos minutos previos (por ejemplo, 30, 60 o hasta 480 minutos). El fin fue evitar el posible impacto directo de intervenciones clínicas recientes sobre la predicción. Así, se garantizaba una representación más realista del estado previo del paciente.

A continuación, se describen las variables consideradas en el estudio, agrupadas según su naturaleza fisiológica y clínica.

4.1.2.1. Variables respiratorias

- Presión parcial de oxígeno en sangre arterial (PaO_2)

Variable medida. Se incluyeron registros tomados a 0, 30, 60, 120, 240 y 480 minutos antes del evento.

- Presión parcial de dióxido de carbono en sangre arterial (PaCO_2)

Variable medida. Se consideraron registros tomados 0, 30, 60, 120, 240 y 480 minutos antes del evento.

- Distensibilidad pulmonar (Crs)

Variable medida y registrada clínicamente. Se emplearon valores recogidos a 0, 30, 60, 120, 240 y 480 minutos antes del evento.

- Frecuencia respiratoria (RR)

Se incluyeron tanto valores configurados (RRset) como valores medidos directamente (RRmeas).

- RRset se tomó a 0, 30, 60 y 120 minutos.
- RRmeas se incluyó a 30, 60 y 120 minutos.

- Volumen corriente (VT)

Se consideraron valores configurados (VTset) y medidos (VTmeas).

- VTset se registró a 0, 30, 60 y 120 minutos del evento.
- VTmeas se incluyó a 30, 60 y 120 minutos del evento.

- Modo de ventilación (VentMode)

Variable configurada, categórica y registrada por el sistema de ventilación. Se utilizó el valor disponible en el minuto 0.

- PEEP

Variable configurada (PEEPset). Se seleccionaron registros correspondientes a 30, 60, 120, 240 y 480 minutos antes del evento.

- Presión inspiratoria pico (Ppeakinsp)

Variable medida directamente. Se incluyeron valores 30, 60 y 120 minutos antes del evento.

- Fracción de oxígeno inspirado (FiO₂)

Variable configurada por el clínico. Se utilizaron mediciones a 0, 30, 60, 120, 240 y 480 minutos del evento.

- Saturación periférica de oxígeno (SpO₂)

Variable medida de forma continua. Se tomaron registros 30, 60 y 120 minutos antes del evento.

4.1.2.2. Variables circulatorias

- Frecuencia cardiaca (HR)

Variable medida mediante monitorización continua. Se consideraron valores registrados a 30, 120 y 480 minutos antes del evento.

- Presión arterial media (MAP)

Variable medida mediante manguito oscilométrico. Se incluyeron registros tomados a 30, 120 y 480 minutos del evento.

- Tasa de norepinefrina (NE)

Variable configurada por el profesional clínico, correspondiente a la dosis administrada de este vasopresor. Se utilizó el valor registrado en el minuto 0, representando la tasa activa de infusión en ese momento.

4.1.2.3. Variables de laboratorio

- Albumina (Albumin)

Variable medida mediante análisis bioquímico en sangre. Se consideró el valor registrado 30 minutos antes del evento.

- Bilirrubina (Bilirubin)

Variable medida en sangre. Se incluyeron los valores correspondientes a la bilirrubina directa (Direct Bilirubin) y bilirrubina indirecta (Indirect Bilirubin), ambas recogidas a 30 minutos del evento.

- Creatinina (Creatinine)

Variable medida en laboratorio clínico. Se utilizó el valor correspondiente a 30 minutos antes del evento.

- Lactato (Lactate)

Variable medida en sangre venosa o arterial. Se consideró el valor registrado a 30 minutos antes del evento.

- Temperatura corporal (Temperature)

Variable medida clínicamente. Se incluyó la medición correspondiente a 30 minutos antes del evento.

- Plaquetas (Platelets)

Variable medida en análisis hematológico. Se consideró el valor a 30 minutos antes del evento.

- Leucocitos (Leukocytes)

Variable medida, obtenida de análisis de sangre. Se utilizó el valor registrado a 30 minutos antes del evento.

- Hemoglobina (Hb)

Variable medida en análisis de gases arteriales. Se seleccionó el valor correspondiente a 30 minutos antes del evento.

- pH sanguíneo (pH)

Variable medida mediante gasometría. Se incluyó el valor a 30 minutos antes del evento.

- Índice internacional normalizado (INR)

Variable medida, utilizada para evaluar la coagulación. Se empleó el valor correspondiente a 30 minutos antes del evento.

4.1.2.4. Variables demográficas

- Edad (Age)

Variable constante, calculada a partir de la diferencia entre la fecha de ingreso hospitalario y la fecha de nacimiento. Se expresa en años completos al momento del ingreso en UCI.

- Género (Gender)

Variable categórica, registrada y codificada como masculino o femenino.

- Estatura (Height)

Variable medida, expresada en centímetros. Se utilizó el valor más reciente disponible por paciente.

- Peso (Weight)

Variable medida, expresada en kilogramos. Se empleó el último valor registrado por paciente.

4.1.3. Notación de las variables

Para reflejar el instante temporal asociado a cada medición, se utilizó una notación basada en corchetes. El número dentro del corchete indica cuántos minutos antes del evento se seleccionó el valor. No siempre se disponía de una medición exacta en ese minuto. Por eso, se tomaba el dato más reciente disponible antes del instante indicado.

Por ejemplo, la variable PaO_2 [30] representa el valor de PaO_2 registrado al menos 30 minutos antes del evento. Si no había una medición exacta en ese momento, se usaba la última disponible anterior a los 30 minutos.

Esta notación fue útil para mantener la coherencia temporal entre variables. Hace posible organizar los datos de una forma más clara y controlar con precisión el intervalo temporal considerado en cada análisis.

4.1.4. División en entrenamiento y test

La base de datos se dividió en dos subconjuntos independientes para el entrenamiento y la evaluación del modelo. Esta partición se realizó a nivel de paciente, de modo que todos los datos correspondientes a un mismo individuo se incluyeran únicamente en uno de los conjuntos. El 90 % de los pacientes se asignó al conjunto de entrenamiento, mientras que el 10 % restante se destinó al conjunto de test. Esta estrategia permitió evaluar el rendimiento del modelo sobre pacientes no vistos previamente. Así, se redujo el riesgo de sobreajuste y se proporcionó una estimación más realista de su capacidad de generalización.

4.2. Metodología

A continuación, se describen los métodos adoptados para el desarrollo de este proyecto.

4.2.1. Preprocesado de los datos

El preprocesado de los datos comenzó con la gestión de los valores faltantes, tanto en variables numéricas como categóricas. La presencia de datos ausentes es habitual en

registros clínicos reales. Para tratarlos, se aplicaron estrategias diferentes según el tipo de variable. El objetivo era evitar perder información y no introducir sesgos en los análisis posteriores.

En el caso de las variables numéricas, se optó por una imputación basada en la mediana. Se identificaron todas las columnas de tipo numérico y, para cada una de ellas, se calculó la mediana tomando únicamente los valores disponibles. Esto es, ignorando los registros con datos faltantes. A continuación, se reemplazaron todos los valores perdidos en esa columna por su mediana correspondiente. Así, se mantuvo una representación coherente de cada variable.

En cuanto a las variables categóricas, se llevó a cabo una imputación mediante la asignación de una categoría adicional. Para ello, se introdujo una nueva etiqueta denominada “MISSING” que agrupa todos los valores ausentes detectados en cada variable categórica. Esta estrategia evitaba tener que recurrir a imputaciones arbitrarias, al tiempo que permitía conservar información sobre la ausencia del dato original.

Tras la imputación de valores faltantes, se continuó con la codificación de las variables categóricas. Cada una de ellas fue transformada en valores numéricos enteros, asignando un código distinto a cada categoría. Antes de aplicar esta codificación, se reorganizaron las categorías para que la etiqueta “MISSING” apareciera siempre en primer lugar. Esta decisión se tomó para facilitar el análisis posterior y permitir una identificación directa de los datos ausentes.

Una vez reordenadas, se asignaron los códigos numéricos empezando desde 0, de modo que cada categoría quedó representada por un único valor. Esto permitió adaptar las variables categóricas al formato requerido por los modelos de aprendizaje automático.

Antes de ingresar los datos en los modelos utilizados, se normalizaron las variables numéricas para evitar que diferencias de escala influyeran en el rendimiento de los algoritmos. Para ello, se calcularon la media y la desviación estándar de cada variable utilizando únicamente los datos del conjunto de entrenamiento. A partir de estos valores, se transformaron tanto los datos de entrenamiento como los de test. Se restó la media y se dividió por la desviación correspondiente. Con esto se consiguió que todas las variables numéricas tuvieran una media cercana a cero y una varianza unitaria.

Las variables categóricas no se normalizaron, ya que representan clases discretas y no magnitudes continuas.

4.2.2. Configuraciones de entrada de los datos

Una vez finalizado el preprocesado, se organizaron los datos en tres configuraciones distintas para su posterior uso en los modelos de predicción. Estas configuraciones se definieron con el objetivo de simular distintos escenarios clínicos, en función del grado de información disponible en momentos cercanos al evento de interés.

1. Configuración “All Data”

Esta configuración incluye todas las variables disponibles hasta el instante en el que se realiza la predicción. No se aplicó ninguna exclusión temporal sobre los datos, por lo que cada variable aportó su valor más reciente según los criterios definidos previamente. Esta configuración representa un escenario clínico óptimo, en el que se dispone de acceso completo a la información del paciente en tiempo real.

Su propósito principal fue evaluar el rendimiento máximo del modelo, aprovechando toda la información posible antes del evento.

2. Configuración “30 Minutes Blinded”

Esta configuración se construyó eliminando, de entre las variables medidas, aquellas correspondientes al instante del evento. Es decir, se prescindió de las versiones anotadas con el sufijo [0]. Esta exclusión no se aplicó a las variables configuradas, que permanecieron sin cambios. Esto es porque no reflejan una medición puntual, sino un parámetro de ajuste clínico. El objetivo de esta configuración fue simular un escenario en el que no se dispone de los resultados más recientes de ciertas pruebas o monitorizaciones. Esto puede ocurrir en entornos donde existe un desfase entre la recogida del dato y su disponibilidad para la toma de decisiones.

Este enfoque se adapta mejor a situaciones reales, donde a veces los datos no están disponibles al instante. El resto del preprocesado y la división en conjuntos de entrenamiento y test se mantuvo igual que en la configuración sin restricciones.

3. Configuración “60 Minutes Blinded”

Esta configuración se definió eliminando, al igual que en la anterior, las variables medidas en el instante exacto del evento. Además, en este caso también se excluyeron

aquellas registradas 30 minutos antes. De este modo, solo se conservaron las mediciones tomadas al menos 60 minutos antes del evento. Representa un escenario aún más limitado, en el que se pretende predecir el estado del paciente con información más alejada en el tiempo.

El objetivo fue comprobar si el modelo mantenía un rendimiento aceptable incluso con datos más desactualizados. Esta situación se puede dar habitualmente en entornos donde la frecuencia de monitorización es baja o hay retrasos en la disponibilidad de resultados.

El resto del preprocesado se mantuvo sin cambios respecto a las otras configuraciones.

En la Figura 4.2 se muestra un ejemplo de cómo se organiza la información temporal para predecir PaO_2 a partir de FiO_2 en las tres configuraciones de entrada explicadas anteriormente.




Figura 4.2. Representación del preprocesamiento aplicado a una observación ejemplo de la variable objetivo PaO_2 (Händel et al., 2024).

Cada fila representa la misma variable considerada con distintos desfases temporales: el valor más reciente (FiO_2 [0]), el valor disponible hasta 30 minutos antes (FiO_2 [30]) y hasta 60 minutos antes (FiO_2 [60]). Los intervalos sombreados en verde indican los periodos de tiempo descartados antes de seleccionar las mediciones. Por otro lado, los círculos verdes señalan los valores finalmente escogidos para cada configuración. De este modo, se ilustran las tres configuraciones de entrada utilizadas en el modelo.

4.2.3. Modelos predictivos

El ajuste adecuado de la PEEP es un proceso clínico complejo que depende de múltiples factores fisiológicos y ventilatorios. En este contexto, la estimación precisa de parámetros respiratorios como la PaO_2 , la $PaCO_2$ y la Crs puede proporcionar información clave para apoyar dicho ajuste.

Con este fin, se desarrollaron modelos de regresión entrenados a partir de las variables incluidas en el estudio.

A continuación, se describen los modelos implementados. Se detallan las estructuras utilizadas, el proceso de entrenamiento y las métricas empleadas para la evaluación del rendimiento.

4.2.3.1. FNN aplicada en el estudio

Para la predicción de cada una de las variables objetivo, se entrenaron FNN individuales. Cada red recibió como entrada tanto variables numéricas como categóricas.

Las variables categóricas se transformaron mediante capas de *embedding*. Cada categoría se representó como un vector de dimensiones reducidas, cuyos pesos se ajustaron durante el entrenamiento. Las cuatro variables categóricas de la base de datos se codificaron con tamaños de *embedding* entre 3 y 7, según el número de clases de cada variable. Tras cada capa de *embedding* se aplicó una capa de *dropout* con tasa de 0,04 como técnica de regularización.

Las variables numéricas pasaron por una capa de *Batch Normalization* antes de ser concatenadas con los vectores *embedding*, formando así un único vector por paciente. Este vector se procesó mediante una capa oculta de 256 neuronas con función de activación ReLU (*Rectified Linear Unit*). Es una función no lineal ampliamente utilizada por su eficiencia computacional. Se define como:

$$f(x) = \max(0, x) \quad [17]$$

Permite que la red aprenda relaciones complejas evitando el problema del desvanecimiento del gradiente en capas profundas (Agarap, 2019). Seguidamente encontramos una capa de *dropout* con tasa 0,5. Se incorporó además un término de regularización L2 (*weight decay*), con un valor de 0,1.

El entrenamiento se realizó durante 20 épocas utilizando el optimizador Adam, con una tasa de aprendizaje de 0,002 y un tamaño de minibatch de 64. No se utilizó el conjunto de test para el ajuste de hiperparámetros, con el fin de evitar fugas de información.

Durante el entrenamiento se monitorizaron tres métricas de error: la Raíz del Error Cuadrático Medio (RMSE), el Error Absoluto Medio (MAE) y el Error Porcentual Absoluto Medio (MAPE).

$$RMSE = \sqrt{\left(\frac{1}{N}\right) * \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad [18]$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad [19]$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad [20]$$

Estas se utilizaron para evaluar el rendimiento final del modelo en el conjunto de test.

A continuación, en la Tabla 4.1, Tabla 4.2 y Tabla 4.3 se muestran todas las capas empleadas en esta arquitectura para las distintas configuraciones de entrada. Estas incluyen el tipo funcional de cada capa, la forma de salida (cuando está disponible) y el número de parámetros entrenables asociados. También, se acompañan de la Figura 4.3, Figura 4.4 y Figura 4.5 que muestran una representación esquemática de la arquitectura de capas con el objetivo de facilitar la comprensión del diseño del modelo.

Capa (Tipo)	Forma de salida	Número de parámetros
numerical_input (Entrada de características)	Desconocida	0
numerical_normalization (Batch Normalization)	Desconocida	0
categorical_input_1 (Entrada de características)	Desconocida	0
embedding_1 (Fully Connected)	(None, 3)	6

embedding_dropout_1 (Dropout)	Desconocida	0
categorical_input_2 (Entrada de características)	Desconocida	0
embedding_2 (Fully Connected)	(None, 7)	14
embedding_dropout_2 (Dropout)	Desconocida	0
categorical_input_3 (Entrada de características)	Desconocida	0
embedding_3 (Fully Connected)	(None, 3)	6
embedding_dropout_3 (Dropout)	Desconocida	0
categorical_input_4 (Entrada de características)	Desconocida	0
embedding_4 (Fully Connected)	(None, 4)	8
embedding_dropout_4 (Dropout)	Desconocida	0
feature_concatenation (Concatenación)	Desconocida	0
hidden_fc (Fully Connected)	(None, 256)	21760
activation_relu (ReLU)	Desconocida	0
dropout (Dropout)	Desconocida	0
output (Fully Connected)	(None, 1)	257

Tabla 4.1. Capas de la FNN con la configuración “All Data”: tipo, salida y número de parámetros.




Figura 4.3. Representación esquemática de la arquitectura de la FNN para la configuración "All Data" creada con PlotNeuralNet.

Capa (Tipo)	Forma de salida	Número de parámetros
numerical_input (Entrada de características)	Desconocida	0
numerical_normalization (Batch Normalization)	Desconocida	0
categorical_input_1 (Entrada de características)	Desconocida	0
embedding_1 (Fully Connected)	(None, 3)	6
embedding_dropout_1 (Dropout)	Desconocida	0
categorical_input_2 (Entrada de características)	Desconocida	0
embedding_2 (Fully Connected)	(None, 7)	14

embedding_dropout_2 (Dropout)	Desconocida	0
categorical_input_3 (Entrada de características)	Desconocida	0
embedding_3 (Fully Connected)	(None, 3)	6
embedding_dropout_3 (Dropout)	Desconocida	0
categorical_input_4 (Entrada de características)	Desconocida	0
embedding_4 (Fully Connected)	(None, 4)	8
embedding_dropout_4 (Dropout)	Desconocida	0
feature_concatenation (Concatenación)	Desconocida	0
hidden_fc (Fully Connected)	(None, 256)	21248
activation_relu (ReLU)	Desconocida	0
dropout (Dropout)	Desconocida	0
output (Fully Connected)	(None, 1)	257

Tabla 4.2. Capas de la FNN con la configuración “30 Minutes Blinded”: tipo, salida y número de parámetros.




Figura 4.4. Representación esquemática de la arquitectura de FNN para la configuración "30 Minutes Blinded" creada con PlotNeuralNet.

Capa (Tipo)	Forma de salida	Número de parámetros
numerical_input (Entrada de características)	Desconocida	0
numerical_normalization (Batch Normalization)	Desconocida	0
categorical_input_1 (Entrada de características)	Desconocida	0
embedding_1 (Fully Connected)	(None, 3)	6
embedding_dropout_1 (Dropout)	Desconocida	0
categorical_input_2 (Entrada de características)	Desconocida	0
embedding_2 (Fully Connected)	(None, 7)	14

embedding_dropout_2 (Dropout)	Desconocida	0
feature_concatenation (Concatenación)	Desconocida	0
hidden_fc (Fully Connected)	(None, 256)	14848
activation_relu (ReLU)	Desconocida	0
dropout (Dropout)	Desconocida	0
output (Fully Connected)	(None, 1)	257

Tabla 4.3. Capas de la FNN con la configuración “60 Minutes Blinded”: tipo, salida y número de parámetros.




Figura 4.5. Representación esquemática de la arquitectura de FNN para la configuración “60 Minutes Blinded” creada con PlotNeuralNet.

4.2.3.2. FNN multitarea aplicada en el estudio

Este modelo multitarea compartía la estructura base descrita para el modelo individual: entrada conjunta de variables numéricas y categóricas, normalización por

lotes para las variables numéricas y concatenación de todas las entradas en un único vector representativo por paciente.

Al igual que en la red individual, incluía una única capa compartida de 256 neuronas con función de activación ReLU, regularizada con una capa de *dropout*. A partir de esta, la arquitectura se bifurcaba en tres ramas independientes. Cada una de estas ramas estaba dedicada a una de las variables objetivo. Consta de una capa intermedia con 64 neuronas y activación ReLU, seguida de una capa final con una única neurona de salida.

El entrenamiento se realizó con los mismos parámetros que en las redes individuales. Las métricas de error se calcularon por separado para cada salida, permitiendo evaluar el rendimiento de la red de forma específica para cada variable predicha. Fueron las mismas que en la FNN individual.

La Tabla 4.4, Tabla 4.5 y Tabla 4.6 junto con la Figura 4.6, Figura 4.7 y Figura 4.8 que se muestran a continuación recogen la arquitectura del modelo multitarea, estructurada según las distintas configuraciones de entrada.

Capa (Tipo)	Forma de salida	Número de parámetros
numerical_input (Entrada de características)	Desconocida	0
numerical_normalization (Batch Normalization)	Desconocida	0
categorical_input_1 (Entrada de características)	Desconocida	0
embedding_1 (Fully Connected)	(None, 3)	6
embedding_dropout_1 (Dropout)	Desconocida	0
categorical_input_2 (Entrada de características)	Desconocida	0
embedding_2 (Fully Connected)	(None, 7)	14
embedding_dropout_2 (Dropout)	Desconocida	0
categorical_input_3 (Entrada de características)	Desconocida	0

embedding_3 (Fully Connected)	(None, 3)	6
embedding_dropout_3 (Dropout)	Desconocida	0
categorical_input_4 (Entrada de características)	Desconocida	0
embedding_4 (Fully Connected)	(None, 4)	8
embedding_dropout_4 (Dropout)	Desconocida	0
feature_concatenation (Concatenación)	Desconocida	0
shared_fc (Fully Connected)	(None, 256)	21248
shared_relu (ReLU)	Desconocida	0
shared_dropout (Dropout)	Desconocida	0
pao2_fc (Fully Connected)	(None, 64)	16448
pao2_relu (ReLU)	Desconocida	0
pao2_output (Fully Connected)	(None, 1)	65
paco2_fc (Fully Connected)	(None, 64)	16448
paco2_relu (ReLU)	Desconocida	0
paco2_output (Fully Connected)	(None, 1)	65
crs_fc (Fully Connected)	(None, 64)	16448
crs_relu (ReLU)	Desconocida	0
crs_output (Fully Connected)	(None, 1)	65

Tabla 4.4. Capas de la FNN múltiple con la configuración “All Data”: tipo, salida y número de parámetros.




Figura 4.6. Representación esquemática de la arquitectura de FNN múltiple para la configuración "All Data" creada con PlotNeuralNet.

Capa (Tipo)	Forma de salida	Número de parámetros
numerical_input (Entrada de características)	Desconocida	0
numerical_normalization (Batch Normalization)	Desconocida	0
categorical_input_1 (Entrada de características)	Desconocida	0
embedding_1 (Fully Connected)	(None, 3)	6
embedding_dropout_1 (Dropout)	Desconocida	0
categorical_input_2 (Entrada de características)	Desconocida	0
embedding_2 (Fully Connected)	(None, 7)	14

embedding_dropout_2 (Dropout)	Desconocida	0
categorical_input_3 (Entrada de características)	Desconocida	0
embedding_3 (Fully Connected)	(None, 3)	6
embedding_dropout_3 (Dropout)	Desconocida	0
categorical_input_4 (Entrada de características)	Desconocida	0
embedding_4 (Fully Connected)	(None, 4)	8
embedding_dropout_4 (Dropout)	Desconocida	0
feature_concatenation (Concatenación)	Desconocida	0
shared_fc (Fully Connected)	(None, 256)	21248
shared_relu (ReLU)	Desconocida	0
shared_dropout (Dropout)	Desconocida	0
pao2_fc (Fully Connected)	(None, 64)	16448
pao2_relu (ReLU)	Desconocida	0
pao2_output (Fully Connected)	(None, 1)	65
paco2_fc (Fully Connected)	(None, 64)	16448
paco2_relu (ReLU)	Desconocida	0
paco2_output (Fully Connected)	(None, 1)	65
crs_fc (Fully Connected)	(None, 64)	16448
crs_relu (ReLU)	Desconocida	0

crs_output (Fully Connected)	(None, 1)	65
---------------------------------	-----------	----

Tabla 4.5. Capas de la FNN múltiple con la configuración “30 Minutes Blinded”: tipo, salida y número de parámetros.




Figura 4.7. Representación esquemática de la arquitectura de FNN múltiple para la configuración “30 Minutes Blinded” creada con PlotNeuralNet.

Capa (Tipo)	Forma de salida	Número de parámetros
numerical_input (Entrada de características)	Desconocida	0
numerical_normalization (Batch Normalization)	Desconocida	0
categorical_input_1 (Entrada de características)	Desconocida	0
embedding_1 (Fully Connected)	(None, 3)	6
embedding_dropout_1 (Dropout)	Desconocida	0

categorical_input_2 (Entrada de características)	Desconocida	0
embedding_2 (Fully Connected)	(None, 7)	14
embedding_dropout_2 (Dropout)	Desconocida	0
feature_concatenation (Concatenación)	Desconocida	0
shared_fc (Fully Connected)	(None, 256)	14848
shared_relu (ReLU)	Desconocida	0
shared_dropout (Dropout)	Desconocida	0
pao2_fc (Fully Connected)	(None, 64)	16448
pao2_relu (ReLU)	Desconocida	0
pao2_output (Fully Connected)	(None, 1)	65
paco2_fc (Fully Connected)	(None, 64)	16448
paco2_relu (ReLU)	Desconocida	0
paco2_output (Fully Connected)	(None, 1)	65
crs_fc (Fully Connected)	(None, 64)	16448
crs_relu (ReLU)	Desconocida	0
crs_output (Fully Connected)	(None, 1)	65

Tabla 4.6. Capas de la FNN múltiple con la configuración “60 Minutes Blinded”: tipo, salida y número de parámetros.




Figura 4.8. Representación esquemática de la arquitectura de FNN múltiple para la configuración “60 Minutes Blinded” creada con PlotNeuralNet.

4.2.3.3. RF aplicado en el estudio

Se entrenó un modelo de RF con los mismos datos utilizados en las NN. Se construyó con 50 árboles de decisión empleando la técnica de *bagging* (*bootstrap aggregation*) para combinar sus predicciones. No se estableció un límite explícito de profundidad en los árboles base. La predicción final se calculó como el promedio de todas sus salidas.

Durante la construcción de los árboles, las divisiones internas se guiaron por la reducción del error logarítmico cuadrático medio (MSLE). Sea $\mathcal{L}$ el conjunto de datos con $n = |\mathcal{L}|$ muestras, y_i el valor real de la muestra i y $\hat{y}_i$ su predicción correspondiente, el MSLE se calcula como:

$$MSLE(\mathcal{L}) = \frac{1}{|\mathcal{L}|} \sum_{i=1}^{|\mathcal{L}|} (\log(1 + y_i) - \log(1 + \hat{y}_i))^2 \quad [21]$$

Permitió seleccionar en cada nodo la variable y el umbral que mejor disminuían la variabilidad de la variable objetivo. Esta estrategia resulta especialmente adecuada para tareas de regresión, como en este caso.

La evaluación del modelo se realizó mediante MSLE, además de MAE y MAPE para facilitar la comparación.

Como en el resto de modelos, el conjunto de test no se empleó en ninguna fase de ajuste. Se reservó exclusivamente para la evaluación final.

4.2.4. Interpretabilidad

En este estudio se emplearon dos técnicas complementarias de interpretabilidad: PI y SHAP. El primero evalúa cómo cambia el rendimiento del modelo al modificar una variable concreta. El segundo descompone cada predicción en contribuciones individuales asociadas a las variables.

A continuación, se describe en detalle la aplicación de ambos enfoques.

4.2.4.1. Método PI aplicado en el estudio

Este método se aplicó sobre todos los modelos desarrollados para estimar la relevancia relativa de cada variable de entrada.

Primero, se calculó el error base del modelo utilizando el conjunto de test. Como métrica de referencia se empleó el MAPE.

Posteriormente, se realizó una permutación aleatoria de los valores de cada variable, manteniendo el resto sin alterar. Este procedimiento se repitió cinco veces por variable, y se midió el incremento medio en el MAPE tras cada permutación.

Finalmente, los resultados obtenidos se ordenaron en un ranking descendente. También se calcularon los porcentajes relativos de impacto para facilitar la comparación entre variables.

Este análisis se repitió para cada combinación de modelo, variable objetivo y configuración de entrada.

4.2.4.2. Método SHAP aplicado en el estudio

El método SHAP se aplicó de forma sistemática a los diferentes modelos desarrollados en este estudio.

Para ello, se utilizó una estrategia de muestreo que permite estimar la contribución individual de cada variable a las predicciones del modelo sin necesidad de reentrenarlo. En cada caso, se seleccionó un subconjunto de datos de test sobre el cual se calcularon los valores de Shapley mediante la comparación de predicciones con y sin la presencia de

cada variable. Esta comparación se llevó a cabo en múltiples escenarios generados aleatoriamente. Se sustituyeron las variables ausentes por valores tomados aleatoriamente del conjunto de entrenamiento.

El resultado fue un valor medio que refleja el impacto de cada característica sobre la salida del modelo, permitiendo interpretar su comportamiento de forma transparente y consistente.

Esta metodología se aplicó de forma uniforme en todos los modelos del estudio para garantizar la comparabilidad de los resultados interpretativos.

4.2.5. Simulación de ajustes en la PEEP

La simulación de modificaciones en la PEEP constituye una parte fundamental de este trabajo. Su objetivo fue predecir cómo distintos niveles de PEEP podrían afectar a variables clínicas importantes, sin necesidad de aplicar realmente esos cambios al paciente. Esta herramienta permite anticipar los posibles efectos de una intervención ventilatoria y servir como apoyo en la toma de decisiones clínicas.

Enfoque y procedimiento de la simulación

Para estimar los efectos hipotéticos de distintos niveles de PEEP, se aplicó una estrategia de simulación basada en el modelo de FNN multitarea descrito previamente. Este enfoque refleja mejor la práctica clínica, ya que un cambio en la PEEP afecta al mismo tiempo a la mecánica respiratoria y al intercambio de gases. Además, al entrenar las variables de forma conjunta, el modelo aprovecha sus relaciones fisiológicas. Esto permite generar predicciones más consistentes incluso cuando no se dispone de resultados directos con los que contrastarlas. Con el fin de evitar que el modelo estuviera influenciado por cambios recientes en el estado del paciente, se utilizó el enfoque “30 Minutes Blinded”.

Primero se seleccionaron observaciones clínicas completas de pacientes de la base de datos. Cada observación representaba un momento concreto en el que se habían medido las variables de interés y se conocía el valor de PEEP aplicado.

A partir de cada una de estas observaciones, se crearon varias copias modificadas. En cada copia, se cambió únicamente el valor de la PEEP, simulando distintos niveles posibles. El resto de variables se mantuvo igual. Generalmente, se probaron valores entre -5 y +5 cmH₂O respecto al valor original. Este rango se seleccionó porque representa

un intervalo de ajuste habitual en la práctica clínica. Cambios dentro de este margen permiten modificar la PEEP de forma progresiva sin generar un riesgo elevado de efectos adversos como barotrauma o compromiso hemodinámico. Además, es suficientemente amplio como para observar posibles respuestas fisiológicas relevantes en los parámetros respiratorios del paciente.

Las entradas modificadas se introdujeron en el modelo de FNN multitarea entrenado previamente. Para cada entrada, el modelo devolvía una predicción de las tres variables objetivo: PaO_2 , PaCO_2 y Crs. Estas predicciones representaban el valor esperado de esas variables entre 30 y 60 minutos después de aplicar el nivel de PEEP simulado.

Repetir este proceso con distintos valores de PEEP permitía ver cómo cambiarían las condiciones del paciente en función del ajuste, sin necesidad de hacer la prueba en la práctica. Esto permite explorar de forma segura qué ajustes podrían ser más beneficiosos para un paciente concreto, apoyando una ventilación más personalizada y basada en datos.

Capítulo 5. Resultados.

5.1. Desempeño de los modelos predictivos

La Tabla 5.1 muestra el rendimiento de los modelos FNN, FNN multitarea y RF en la predicción de PaO₂, PaCO₂ y Crs bajo las tres configuraciones de entrada: “All Data”, “30 Minutes Blinded” y “60 Minutes Blinded”. Se presentan los valores de RMSE, MAE y MAPE obtenidos en el conjunto de test para cada caso.

		FNN	FNN multitarea	RF
“All Data”				
PaO ₂ (mmHg)	RMSE	39,58	47,79	40,45
	MAE	32,05	28,35	21,04
	MAPE	23,53 %	22,44 %	16,70 %
PaCO ₂ (mmHg)	RMSE	4,56	6,62	5,05
	MAE	4,36	4,52	2,78
	MAPE	10,84 %	11,23 %	6,76 %
Crs (mL/cmH ₂ O)	RMSE	4,80	6,97	5,19
	MAE	3,43	3,71	1,86
	MAPE	13,51 %	15,47 %	6,71 %
“30 Minutes Blinded”				
PaO ₂ (mmHg)	RMSE	39,65	47,79	44,21
	MAE	32,59	28,35	26,57
	MAPE	24,19 %	22,44 %	21,24 %
PaCO ₂ (mmHg)	RMSE	4,52	6,62	5,93
	MAE	4,32	4,52	3,95
	MAPE	10,62 %	11,23 %	9,69 %
Crs (mL/cmH ₂ O)	RMSE	4,87	6,97	6,54
	MAE	3,57	3,71	3,22
	MAPE	14,62 %	15,47 %	13,27 %
“60 Minutes Blinded”				
PaO ₂ (mmHg)	RMSE	41,27	49,29	45,51
	MAE	33,36	29,60	27,33
	MAPE	24,70 %	24,04 %	22,01 %

PaCO ₂ (mmHg)	RMSE	4,56	6,56	6,02
	MAE	4,32	4,35	4,01
	MAPE	10,50 %	10,60 %	9,83 %
Crs (mL/cmH ₂ O)	RMSE	4,88	6,96	6,60
	MAE	3,56	3,72	3,28
	MAPE	14,81 %	15,39 %	13,51 %

Tabla 5.1. Rendimiento de los modelos para todas las configuraciones de entrada.

De manera general, las tres métricas de rendimiento muestran un patrón similar: los errores se incrementan cuando se pasa de la configuración “All Data” a las configuraciones “30 Minutes Blinded” y “60 Minutes Blinded”.

En relación con los modelos empleados, ninguno destaca de forma uniforme en todas las combinaciones de variable y métrica. A pesar de esto, se observan tendencias consistentes. El RF tiende a alcanzar los valores más bajos de MAE y MAPE. Sin embargo, al considerar el RMSE, la FNN y la FNN multitarea presentan en varios casos resultados más favorables.

A continuación, se presentan las gráficas de comparación entre los valores reales y las predicciones generadas por los modelos para cada una de las variables objetivo. Estas representaciones permiten visualizar el grado de ajuste alcanzado por los modelos en las distintas configuraciones de entrada.

La Figura 5.1, la Figura 5.2 y la Figura 5.3 muestran las gráficas para el modelo FNN con “All Data” como configuración de entrada.




Figura 5.1. Comparación entre los valores reales y las predicciones del modelo FNN para la variable PaO₂, en la configuración “All Data”.

Figura 5.2. Comparación entre los valores reales y las predicciones del modelo FNN para la variable PaCO₂, en la configuración “All Data”.

Figura 5.3. Comparación entre los valores reales y las predicciones del modelo FNN para la variable Crs, en la configuración “All Data”.

La Figura 5.4, la Figura 5.5 y la Figura 5.6 muestran las gráficas para el modelo FNN multitarea con “All Data” como configuración de entrada




Figura 5.4. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaO₂, en la configuración “All Data”.




Figura 5.5. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaCO₂, en la configuración “All Data”.




Figura 5.6. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable Crs, en la configuración “All Data”.

La Figura 5.7, la Figura 5.8 y la Figura 5.9 muestran las gráficas para el modelo RF con “All Data” como configuración de entrada.




Figura 5.7. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaO₂, en la configuración “All Data”.




Figura 5.8. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaCO₂, en la configuración “All Data”.




Figura 5.9. Comparación entre los valores reales y las predicciones del modelo RF para la variable Crs, en la configuración “All Data”.

La Figura 5.10, la Figura 5.11 y la Figura 5.12 muestran las gráficas para el modelo FNN con “30 Minutes Blinded” como configuración de entrada.




Figura 5.10. Comparación entre los valores reales y las predicciones del modelo FNN para la variable PaO₂, en la configuración “30 Minutes Blinded”.




Figura 5.11. Comparación entre los valores reales y las predicciones del modelo FNN para la variable PaCO₂, en la configuración “30 Minutes Blinded”.




Figura 5.12. Comparación entre los valores reales y las predicciones del modelo FNN para la variable Crs, en la configuración “30 Minutes Blinded”.

La Figura 5.13, la Figura 5.14 y la Figura 5.15 muestran las gráficas para el modelo FNN multitarea con “30 Minutes Blinded” como configuración de entrada.




Figura 5.13. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaO₂, en la configuración “30 Minutes Blinded”.




Figura 5.14. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaCO₂, en la configuración “30 Minutes Blinded”.




Figura 5.15. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable Crs, en la configuración “30 Minutes Blinded”.

La Figura 5.16, la Figura 5.17 y la Figura 5.18 muestran las gráficas para el modelo RF con “30 Minutes Blinded” como configuración de entrada.




Figura 5.16. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaO₂, en la configuración “30 Minutes Blinded”.




Figura 5.17. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaCO₂, en la configuración “30 Minutes Blinded”.




Figura 5.18. Comparación entre los valores reales y las predicciones del modelo RF para la variable Crs, en la configuración “30 Minutes Blinded”.

La Figura 5.19, la Figura 5.20 y la Figura 5.21 muestran las gráficas para el modelo FNN con “60 Minutes Blinded” como configuración de entrada.




Figura 5.19. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaO₂, en la configuración “60 Minutes Blinded”.




Figura 5.20. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaCO₂, en la configuración “60 Minutes Blinded”.




Figura 5.21. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable Crs, en la configuración “60 Minutes Blinded”.

La Figura 5.22, la Figura 5.23 y la Figura 5.24 muestran las gráficas para el modelo FNN multitarea con “60 Minutes Blinded” como configuración de entrada.




Figura 5.22. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaO_2 , en la configuración “60 Minutes Blinded”.




Figura 5.23. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable PaCO_2 , en la configuración “60 Minutes Blinded”.




Figura 5.24. Comparación entre los valores reales y las predicciones del modelo FNN multitarea para la variable Crs , en la configuración “60 Minutes Blinded”.

La Figura 5.25, la Figura 5.26 y la Figura 5.27 muestran las gráficas para el modelo RF con “60 Minutes Blinded” como configuración de entrada.




Figura 5.25. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaO_2 , en la configuración “60 Minutes Blinded”.




Figura 5.26. Comparación entre los valores reales y las predicciones del modelo RF para la variable PaCO_2 , en la configuración “60 Minutes Blinded”.




Figura 5.27. Comparación entre los valores reales y las predicciones del modelo RF para la variable Crs , en la configuración “60 Minutes Blinded”.

En general, puede observarse que los valores predichos tienden a concentrarse en torno a un rango más estrecho que los valores reales. Se refleja en una nube de puntos más compacta y alineada. Este patrón se repite en todas las configuraciones de entrada y tipos de modelo.

5.2. Análisis de la importancia de variables

Este apartado presenta el análisis de la relevancia que han tenido las distintas variables de entrada en la predicción, desglosado por modelo y por variable objetivo, para cada configuración de entrada.

5.2.1. Análisis mediante PI

5.2.1.1. Agrupado por modelos

La Tabla 5.2 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN con “All Data” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	PaCO ₂ [30]	VTset [0]
2	FiO ₂ [0]	Crs [0]	Ppeakinsp [60]
3	SpO ₂ [30]	FiO ₂ [0]	PaCO ₂ [0]
4	RRset [120]	PaCO ₂ [60]	PEEPset [60]
5	FiO ₂ [120]	PaO ₂ [0]	FiO ₂ [120]
6	PaO ₂ [240]	PaCO ₂ [480]	Crs [30]
7	FiO ₂ [480]	RRmeas [30]	PaCO ₂ [30]
8	Albumin [30]	pH [30]	PaO ₂ [0]
9	PaCO ₂ [0]	Crs [120]	HR [480]
10	FiO ₂ [240]	PEEPset [120]	PaO ₂ [240]
...	...	...	...
71	PEEPset [480]	PaCO ₂ [240]	PEEPset [480]

Tabla 5.2. Ranking de importancia de características según PI — FNN, configuración “All Data”

La Tabla 5.3 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN multitarea con “All Data” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	RRset [0]	Crs [120]
2	FiO ₂ [30]	RRset [30]	VTset [0]
3	FiO ₂ [0]	RRmeas [120]	FiO ₂ [30]
4	SpO ₂ [30]	FiO ₂ [30]	RRset [120]
5	RRset [120]	PaCO ₂ [480]	RRmeas [60]

6	VTset [120]	FiO ₂ [0]	SpO ₂ [30]
7	Ppeakinsp [120]	PaO ₂ [30]	FiO ₂ [480]
8	FiO ₂ [480]	PaCO ₂ [30]	PaCO ₂ [30]
9	FiO ₂ [120]	PaCO ₂ [60]	PaO ₂ [30]
10	VTset [60]	SpO ₂ [30]	VTset [60]
...	...	...	...
69	PEEPset [120]	VTset [0]	RRset [30]

Tabla 5.3. Ranking de importancia de características según PI — FNN multitarea, configuración “All Data”

La Tabla 5.4 recoge el ranking de importancia de las variables de entrada obtenido mediante RF con “All Data” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	FiO ₂ [480]	PEEPset [240]	Crs [480]
2	FiO ₂ [30]	FiO ₂ [480]	Crs [60]
3	Albumin [30]	FiO ₂ [120]	Crs [30]
4	Ppeakinsp [120]	PaO ₂ [0]	VTset [0]
5	Crs [60]	RRmeas [30]	VTset [60]
6	VTset [0]	FiO ₂ [60]	Gender
7	RRmeas [30]	FiO ₂ [30]	VTset [120]
8	Crs [30]	FiO ₂ [0]	RRset [60]
9	RRset [0]	MAP [120]	PEEPset [120]
10	Crs [120]	PaCO ₂ [30]	RRset [120]
...	...	...	...
71	FiO ₂ [0]	VentMode [0]	Crs [240]

Tabla 5.4. Ranking de importancia de características según PI — RF, configuración “All Data”

La Tabla 5.5 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN con “30 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	PaCO ₂ [30]	Ppeakinsp [30]
2	FiO ₂ [0]	PaCO ₂ [60]	VTset [0]
3	SpO ₂ [30]	FiO ₂ [0]	PEEPset [30]

4	FiO ₂ [120]	PaCO ₂ [480]	FiO ₂ [120]
5	PaO ₂ [240]	Weight	VTset [30]
6	RRset [120]	pH [30]	PaCO ₂ [30]
7	Albumin [30]	PaCO ₂ [240]	Indirect bilirubin [30]
8	VTset [120]	SpO ₂ [30]	MAP [120]
9	Ppeakinsp [60]	RRset [0]	Crs [30]
10	FiO ₂ [480]	RRmeas [30]	Direct bilirubin [30]
...	...	...	...
69	PEEPset [240]	Direct bilirubin [30]	PaCO ₂ [480]

Tabla 5.5. Ranking de importancia de características según PI — FNN, configuración “30 Minutes Blinded”

La Tabla 5.6 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN multitarea con “30 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	RRset [0]	Crs [120]
2	FiO ₂ [30]	RRset [30]	VTset [0]
3	FiO ₂ [0]	RRmeas [120]	FiO ₂ [30]
4	SpO ₂ [30]	FiO ₂ [30]	RRset [120]
5	RRset [120]	PaCO ₂ [480]	RRmeas [60]
6	VTset [120]	FiO ₂ [0]	SpO ₂ [30]
7	Ppeakinsp [120]	PaO ₂ [30]	FiO ₂ [480]
8	FiO ₂ [480]	PaCO ₂ [30]	PaCO ₂ [30]
9	FiO ₂ [120]	PaCO ₂ [60]	PaO ₂ [30]
10	VTset [60]	SpO ₂ [30]	VTset [60]
...	...	...	...
69	PEEPset [120]	VTset [0]	RRset [30]

Tabla 5.6. Ranking de importancia de características según PI — FNN multitarea, configuración “30 Minutes Blinded”

La Tabla 5.7 recoge el ranking de importancia de las variables de entrada obtenido mediante RF con “30 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	VentMode [0]	FiO ₂ [0]	RRset [60]
2	FiO ₂ [0]	FiO ₂ [30]	Crs [480]
3	NE [0]	FiO ₂ [60]	Ppeakinsp [30]
4	FiO ₂ [120]	Leukocytes [30]	VTset [120]
5	FiO ₂ [240]	RRmeas [30]	Ppeakinsp [60]
6	Creatinine [30]	MAP [30]	RRset [0]
7	RRset [0]	RRset [60]	PEEPset [60]
8	Crs [60]	Ppeakinsp [30]	VTset [0]
9	MAP [120]	Creatinine [30]	Crs [60]
10	Indirect bilirubin [30]	SpO ₂ [30]	Lactate [30]
...	...	...	...
69	FiO ₂ [60]	FiO ₂ [240]	Crs [30]

Tabla 5.7. Ranking de importancia de características según PI — RF, configuración “30 Minutes Blinded”

La Tabla 5.8 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN con “60 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [60]	PaCO ₂ [60]	VTset [0]
2	FiO ₂ [0]	FiO ₂ [0]	Ppeakinsp [60]
3	FiO ₂ [120]	PaCO ₂ [480]	Crs [60]
4	RRset [120]	Weight	FiO ₂ [30]
5	RRset [30]	RRmeas [60]	PEEPset [30]
6	SpO ₂ [60]	VTset [0]	Crs [480]
7	FiO ₂ [480]	SpO ₂ [60]	VTset [30]
8	FiO ₂ [240]	PEEPset [60]	Gender
9	PaO ₂ [240]	HR [480]	MAP [480]
10	VTset [120]	Crs [60]	RRset [60]
...	...	...	...
49	PEEPset [240]	HR [120]	FiO ₂ [480]

Tabla 5.8. Ranking de importancia de características según PI — FNN, configuración “60 Minutes Blinded”

La Tabla 5.9 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN multitarea con “60 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [60]	VTset [30]	VTset [0]
2	FiO ₂ [30]	FiO ₂ [30]	VTset [120]
3	FiO ₂ [0]	FiO ₂ [0]	Crs [120]
4	VTset [120]	VTset [60]	FiO ₂ [30]
5	Ppeakinsp [120]	PaCO ₂ [60]	RRmeas [60]
6	RRset [120]	RRset [30]	FiO ₂ [480]
7	FiO ₂ [60]	PaCO ₂ [240]	RRset [120]
8	FiO ₂ [480]	RRmeas [120]	FiO ₂ [120]
9	Crs [120]	SpO ₂ [60]	PaO ₂ [480]
10	FiO ₂ [120]	VentMode [0]	PaO ₂ [60]
...	...	...	...
49	RRmeas [60]	RRset [120]	VTset [30]

Tabla 5.9. Ranking de importancia de características según PI — FNN multitarea, configuración “60 Minutes Blinded”

La Tabla 5.10 recoge el ranking de importancia de las variables de entrada obtenido mediante RF con “60 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	FiO ₂ [120]	FiO ₂ [120]	Crs [60]
2	NE [0]	FiO ₂ [240]	VTset [120]
3	VTset [30]	FiO ₂ [60]	RRset [60]
4	Crs [120]	RRset [30]	Crs [240]
5	Crs [240]	RRset [120]	Crs [120]
6	RRset [60]	NE [0]	VTset [0]
7	Gender	FiO ₂ [0]	RRset [30]
8	RRset [120]	Ppeakinsp [60]	Ppeakinsp [60]
9	RRmeas [120]	Crs [120]	RRmeas [120]
10	VTset [0]	Crs [480]	PEEPset [120]
...	...	...	...
49	FiO ₂ [480]	VentMode [0]	Crs [480]

Tabla 5.10. Ranking de importancia de características según PI — RF, configuración “60 Minutes Blinded”

5.2.1.2. Agrupado por variables objetivo

La Tabla 5.11 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaO₂ con “All Data” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaO ₂ [30]	PaO ₂ [30]	FiO ₂ [480]
2	FiO ₂ [0]	FiO ₂ [30]	FiO ₂ [30]
3	SpO ₂ [30]	FiO ₂ [0]	Albumin [30]
4	RRset [120]	SpO ₂ [30]	Ppeakinsp [120]
5	FiO ₂ [120]	RRset [120]	Crs [60]
6	PaO ₂ [240]	VTset [120]	VTset [0]
7	FiO ₂ [480]	Ppeakinsp [120]	RRmeas [30]
8	Albumin [30]	FiO ₂ [480]	Crs [30]
9	PaCO ₂ [0]	FiO ₂ [120]	RRset [0]
10	FiO ₂ [240]	VTset [60]	Crs [120]
...	...	...	...
71	PEEPset [480]	PEEPset [120]	FiO ₂ [0]

Tabla 5.11. Ranking de importancia de características según PI — PaO₂, configuración “All Data”

La Tabla 5.12 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaCO₂ con “All Data” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaCO ₂ [30]	RRset [0]	PEEPset [240]
2	Crs [0]	RRset [30]	FiO ₂ [480]
3	FiO ₂ [0]	RRmeas [120]	FiO ₂ [120]
4	PaCO ₂ [60]	FiO ₂ [30]	PaO ₂ [0]
5	PaO ₂ [0]	PaCO ₂ [480]	RRmeas [30]
6	PaCO ₂ [480]	FiO ₂ [0]	FiO ₂ [60]
7	RRmeas [30]	PaO ₂ [30]	FiO ₂ [30]
8	pH [30]	PaCO ₂ [30]	FiO ₂ [0]
9	Crs [120]	PaCO ₂ [60]	MAP [120]
10	PEEPset [120]	SpO ₂ [30]	PaCO ₂ [30]
...	...	...	...

71	PaCO ₂ [240]	VTset [0]	VentMode [0]
----	-------------------------	-----------	--------------

Tabla 5.12. Ranking de importancia de características según PI — PaCO₂, configuración “All Data”

La Tabla 5.13 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de Crs con “All Data” como configuración de entrada.

Top	NN	NN multitarea	RF
1	VTset [0]	Crs [120]	Crs [480]
2	Ppeakinsp [60]	VTset [0]	Crs [60]
3	PaCO ₂ [0]	FiO ₂ [30]	Crs [30]
4	PEEPset [60]	RRset [120]	VTset [0]
5	FiO ₂ [120]	RRmeas [60]	VTset [60]
6	Crs [30]	SpO ₂ [30]	Gender
7	PaCO ₂ [30]	FiO ₂ [480]	VTset [120]
8	PaO ₂ [0]	PaCO ₂ [30]	RRset [60]
9	HR [480]	PaO ₂ [30]	PEEPset [120]
10	PaO ₂ [240]	VTset [60]	RRset [120]
...	...	...	...
71	PEEPset [480]	RRset [30]	Crs [240]

Tabla 5.13. Ranking de importancia de características según PI —Crs, configuración “All Data”

La Tabla 5.14 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaO₂ con “30 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaO ₂ [30]	PaO ₂ [30]	VentMode [0]
2	FiO ₂ [0]	FiO ₂ [30]	FiO ₂ [0]
3	SpO ₂ [30]	FiO ₂ [0]	NE [0]
4	FiO ₂ [120]	SpO ₂ [30]	FiO ₂ [120]
5	PaO ₂ [240]	RRset [120]	FiO ₂ [240]
6	RRset [120]	VTset [120]	Creatinine [30]
7	Albumin [30]	Ppeakinsp [120]	RRset [0]
8	VTset [120]	FiO ₂ [480]	Crs [60]
9	Ppeakinsp [60]	FiO ₂ [120]	MAP [120]
10	FiO ₂ [480]	VTset [60]	Indirect bilirubin [30]

...	...	...	...
69	PEEPset [240]	PEEPset [120]	FiO ₂ [60]

Tabla 5.14. Ranking de importancia de características según PI — PaO₂, configuración “30 Minutes Blinded”

La Tabla 5.15 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaCO₂ con “30 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaCO ₂ [30]	RRset [0]	FiO ₂ [0]
2	PaCO ₂ [60]	RRset [30]	FiO ₂ [30]
3	FiO ₂ [0]	RRmeas [120]	FiO ₂ [60]
4	PaCO ₂ [480]	FiO ₂ [30]	Leukocytes [30]
5	Weight	PaCO ₂ [480]	RRmeas [30]
6	pH [30]	FiO ₂ [0]	MAP [30]
7	PaCO ₂ [240]	PaO ₂ [30]	RRset [60]
8	SpO ₂ [30]	PaCO ₂ [30]	Ppeakinsp [30]
9	RRset [0]	PaCO ₂ [60]	Creatinine [30]
10	RRmeas [30]	SpO ₂ [30]	SpO ₂ [30]
...	...	...	...
69	Direct bilirubin [30]	VTset [0]	FiO ₂ [240]

Tabla 5.15. Ranking de importancia de características según PI — PaCO₂, configuración “30 Minutes Blinded”

La Tabla 5.16 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de Crs con “30 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	Ppeakinsp [30]	Crs [120]	RRset [60]
2	VTset [0]	VTset [0]	Crs [480]
3	PEEPset [30]	FiO ₂ [30]	Ppeakinsp [30]
4	FiO ₂ [120]	RRset [120]	VTset [120]
5	VTset [30]	RRmeas [60]	Ppeakinsp [60]
6	PaCO ₂ [30]	SpO ₂ [30]	RRset [0]

7	Indirect bilirubin [30]	FiO ₂ [480]	PEEPset [60]
8	MAP [120]	PaCO ₂ [30]	VTset [0]
9	Crs [30]	PaO ₂ [30]	Crs [60]
10	Direct bilirubin [30]	VTset [60]	Lactate [30]
...	...	...	...
69	PaCO ₂ [480]	RRset [30]	Crs [30]

Tabla 5.16. Ranking de importancia de características según PI —Crs, configuración “30 Minutes Blinded”

La Tabla 5.17 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaO₂ con “60 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaO ₂ [60]	PaO ₂ [60]	FiO ₂ [120]
2	FiO ₂ [0]	FiO ₂ [30]	NE [0]
3	FiO ₂ [120]	FiO ₂ [0]	VTset [30]
4	RRset [120]	VTset [120]	Crs [120]
5	RRset [30]	Ppeakinsp [120]	Crs [240]
6	SpO ₂ [60]	RRset [120]	RRset [60]
7	FiO ₂ [480]	FiO ₂ [60]	Gender
8	FiO ₂ [240]	FiO ₂ [480]	RRset [120]
9	PaO ₂ [240]	Crs [120]	RRmeas [120]
10	VTset [120]	FiO ₂ [120]	VTset [0]
...	...	...	...
49	PEEPset [240]	RRmeas [60]	FiO ₂ [480]

Tabla 5.17. Ranking de importancia de características según PI — PaO₂, configuración “60 Minutes Blinded”

La Tabla 5.18 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaCO₂ con “60 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaCO ₂ [60]	VTset [30]	FiO ₂ [120]
2	FiO ₂ [0]	FiO ₂ [30]	FiO ₂ [240]
3	PaCO ₂ [480]	FiO ₂ [0]	FiO ₂ [60]
4	Weight	VTset [60]	RRset [30]

5	RRmeas [60]	PaCO ₂ [60]	RRset [120]
6	VTset [0]	RRset [30]	NE [0]
7	SpO ₂ [60]	PaCO ₂ [240]	FiO ₂ [0]
8	PEEPset [60]	RRmeas [120]	Ppeakinsp [60]
9	HR [480]	SpO ₂ [60]	Crs [120]
10	Crs [60]	VentMode [0]	Crs [480]
...	...	...	...
49	HR [120]	RRset [120]	VentMode [0]

Tabla 5.18. Ranking de importancia de características según PI — PaCO₂, configuración “60 Minutes Blinded”

La Tabla 5.19 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de Crs con “60 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	VTset [0]	VTset [0]	Crs [60]
2	Ppeakinsp [60]	VTset [120]	VTset [120]
3	Crs [60]	Crs [120]	RRset [60]
4	FiO ₂ [30]	FiO ₂ [30]	Crs [240]
5	PEEPset [30]	RRmeas [60]	Crs [120]
6	Crs [480]	FiO ₂ [480]	VTset [0]
7	VTset [30]	RRset [120]	RRset [30]
8	Gender	FiO ₂ [120]	Ppeakinsp [60]
9	MAP [480]	PaO ₂ [480]	RRmeas [120]
10	RRset [60]	PaO ₂ [60]	PEEPset [120]
...	...	...	...
49	FiO ₂ [480]	VTset [30]	Crs [480]

Tabla 5.19. Ranking de importancia de características según PI —Crs, configuración “60 Minutes Blinded”

5.2.2. Análisis mediante valores de Shapley

5.2.2.1. Agrupado por modelos

La Tabla 5.20 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN con “All Data” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	PaCO ₂ [30]	VTset [0]
2	FiO ₂ [0]	PaCO ₂ [60]	Ppeakinsp [60]
3	Albumin [30]	PaCO ₂ [480]	Crs [30]
4	SpO ₂ [30]	FiO ₂ [0]	PaCO ₂ [0]
5	RRset [30]	pH [30]	PEEPset [60]
6	RRset [120]	Crs [0]	FiO ₂ [120]
7	FiO ₂ [120]	PaCO ₂ [240]	Crs [480]
8	FiO ₂ [480]	PaO ₂ [0]	PaO ₂ [0]
9	FiO ₂ [240]	RRmeas [30]	Crs [240]
10	PaO ₂ [480]	VTmeas [30]	PaCO ₂ [30]
...	...	...	...
71	Platelets [30]	Albumin [30]	FiO ₂ [240]

Tabla 5.20. Ranking de importancia de características según los valores Shapley— FNN, configuración “All Data”

La Tabla 5.21 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN multitarea con “All Data” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	PaCO ₂ [30]	Crs [120]
2	RRset [0]	RRset [0]	RRset [0]
3	RRset [30]	RRset [30]	VTset [0]
4	RRset [120]	PaCO ₂ [480]	RRset [30]
5	SpO ₂ [30]	RRset [120]	Ppeakinsp [120]
6	FiO ₂ [30]	VTset [0]	VTset [30]
7	VTset [0]	PaCO ₂ [240]	RRset [120]
8	FiO ₂ [0]	SpO ₂ [30]	Crs [480]
9	Ppeakinsp [120]	VTset [30]	PEEPset [30]
10	VTset [30]	FiO ₂ [30]	FiO ₂ [30]
...	...	...	...
69	MAP [120]	PaO ₂ [240]	RRmeas [30]

Tabla 5.21. Ranking de importancia de características según los valores de Shapley — FNN multitarea, configuración “All Data”

La Tabla 5.22 recoge el ranking de importancia de las variables de entrada obtenido mediante RF con “All Data” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	PaCO ₂ [30]	PaO ₂ [0]
2	Crs [0]	PaO ₂ [0]	PaCO ₂ [0]
3	SpO ₂ [30]	PaCO ₂ [60]	Crs [30]
4	PaCO ₂ [0]	Crs [0]	Crs [60]
5	PaO ₂ [60]	PaCO ₂ [480]	Crs [480]
6	FiO ₂ [0]	PaCO ₂ [240]	Crs [120]
7	PaO ₂ [120]	PaCO ₂ [120]	VTset [0]
8	PaO ₂ [240]	pH [30]	Crs [240]
9	FiO ₂ [30]	Weight	RRset [0]
10	SpO ₂ [60]	VTmeas [30]	FiO ₂ [0]
...	...	...	...
71	Platelets [30]	Platelets [30]	NE [0]

Tabla 5.22. Ranking de importancia de características según los valores de Shapley — RF, configuración “All Data”

La Tabla 5.23 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN con “30 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	PaCO ₂ [30]	Ppeakinsp [30]
2	FiO ₂ [0]	PaCO ₂ [60]	Crs [30]
3	SpO ₂ [30]	PaCO ₂ [480]	VTset [0]
4	FiO ₂ [120]	Weight	PEEPset [30]
5	Albumin [30]	FiO ₂ [0]	Crs [120]
6	RRset [120]	pH [30]	Crs [480]
7	PaO ₂ [240]	RRset [0]	FiO ₂ [120]
8	FiO ₂ [480]	PaCO ₂ [240]	Crs [240]
9	PEEPset [480]	SpO ₂ [30]	VTset [30]
10	FiO ₂ [240]	VTmeas [30]	RRmeas [30]
...	...	...	...
69	FiO ₂ [30]	VTset [120]	PaCO ₂ [30]

Tabla 5.23. Ranking de importancia de características según los valores de Shapley — FNN, configuración “30 Minutes Blinded”

La Tabla 5.24 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN multitarea con “30 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	PaCO ₂ [30]	Crs [120]
2	RRset [0]	RRset [0]	RRset [0]
3	RRset [30]	RRset [30]	VTset [0]
4	RRset [120]	PaCO ₂ [480]	RRset [30]
5	SpO ₂ [30]	RRset [120]	Ppeakinsp [120]
6	FiO ₂ [30]	VTset [0]	VTset [30]
7	VTset [0]	PaCO ₂ [240]	RRset [120]
8	FiO ₂ [0]	SpO ₂ [30]	Crs [480]
9	Ppeakinsp [120]	VTset [30]	PEEPset [30]
10	VTset [30]	FiO ₂ [30]	FiO ₂ [30]
...	...	...	...
69	MAP [120]	PaO ₂ [240]	RRmeas [30]

Tabla 5.24. Ranking de importancia de características según los valores de Shapley — FNN multitarea, configuración “30 Minutes Blinded”

La Tabla 5.25 recoge el ranking de importancia de las variables de entrada obtenido mediante RF con “30 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [30]	PaCO ₂ [30]	Crs [30]
2	PaO ₂ [60]	PaCO ₂ [60]	Crs [60]
3	SpO ₂ [30]	PaCO ₂ [480]	Crs [120]
4	FiO ₂ [0]	PaCO ₂ [240]	Crs [480]
5	RRset [0]	PaCO ₂ [120]	Crs [240]
6	FiO ₂ [30]	pH [30]	VTset [0]
7	PaO ₂ [120]	Weight	RRset [0]
8	SpO ₂ [60]	RRmeas [30]	FiO ₂ [0]

9	PaO ₂ [240]	VTmeas [30]	Ppeakinsp [30]
10	PaO ₂ [480]	RRset [0]	Ppeakinsp [60]
...	...	...	...
69	Platelets [30]	Platelets [30]	NE [0]

Tabla 5.25. Ranking de importancia de características según los valores de Shapley — RF, configuración “30 Minutes Blinded”

La Tabla 5.26 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN con “60 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [60]	PaCO ₂ [60]	VTset [0]
2	FiO ₂ [0]	PaCO ₂ [480]	Ppeakinsp [60]
3	RRset [120]	PaCO ₂ [240]	Crs [60]
4	RRset [30]	FiO ₂ [0]	FiO ₂ [30]
5	FiO ₂ [120]	Weight	PEEPset [30]
6	SpO ₂ [60]	RRmeas [60]	VTset [30]
7	VTset [120]	RRset [30]	Crs [480]
8	FiO ₂ [480]	SpO ₂ [60]	Crs [120]
9	PEEPset [480]	VTset [0]	Crs [240]
10	FiO ₂ [240]	VTset [60]	RRmeas [60]
...	...	...	...
49	Weight	RRset [0]	RRset [120]

Tabla 5.26. Ranking de importancia de características según los valores de Shapley — FNN, configuración “60 Minutes Blinded”

La Tabla 5.27 recoge el ranking de importancia de las variables de entrada obtenido mediante FNN multitarea con “60 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [60]	PaCO ₂ [60]	VTset [0]
2	RRset [0]	PaCO ₂ [480]	Crs [120]
3	RRset [30]	PaCO ₂ [240]	Ppeakinsp [120]
4	FiO ₂ [30]	RRset [0]	VTset [30]
5	SpO ₂ [60]	RRset [30]	RRset [0]

6	VTset [0]	RRset [120]	RRset [30]
7	RRset [120]	VTset [0]	RRset [120]
8	RRmeas [60]	VTset [30]	PEEPset [30]
9	VTset [120]	PaO ₂ [60]	Crs [240]
10	Ppeakinsp [120]	SpO ₂ [60]	RRmeas [60]
...	...	...	...
49	RRset [60]	Crs [480]	FiO ₂ [60]

Tabla 5.27. Ranking de importancia de características según los valores de Shapley — FNN multitarea, configuración “60 Minutes Blinded”

La Tabla 5.28 recoge el ranking de importancia de las variables de entrada obtenido mediante RF con “60 Minutes Blinded” como configuración de entrada.

Top	PaO ₂	PaCO ₂	Crs
1	PaO ₂ [60]	PaCO ₂ [60]	Crs [60]
2	SpO ₂ [60]	PaCO ₂ [120]	Crs [120]
3	FiO ₂ [0]	PaCO ₂ [480]	Crs [480]
4	FiO ₂ [30]	PaCO ₂ [240]	Crs [240]
5	PaO ₂ [120]	Weight	VTset [0]
6	RRset [0]	RRmeas [60]	RRset [0]
7	PaO ₂ [240]	VTmeas [60]	Ppeakinsp [60]
8	PaO ₂ [480]	Age	FiO ₂ [0]
9	VTset [0]	FiO ₂ [0]	Ppeakinsp [120]
10	FiO ₂ [60]	RRmeas [120]	VTset [30]
...	...	...	...
49	NE [0]	NE [0]	NE [0]

Tabla 5.28. Ranking de importancia de características según los valores de Shapley — RF, configuración “60 Minutes Blinded”

5.2.2.2. Agrupado por variables objetivo

La Tabla 5.29 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaO₂ con “All Data” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaO ₂ [30]	PaO ₂ [30]	PaO ₂ [30]

2	FiO ₂ [0]	RRset [0]	Crs [0]
3	Albumin [30]	RRset [30]	SpO ₂ [30]
4	SpO ₂ [30]	RRset [120]	PaCO ₂ [0]
5	RRset [30]	SpO ₂ [30]	PaO ₂ [60]
6	RRset [120]	FiO ₂ [30]	FiO ₂ [0]
7	FiO ₂ [120]	VTset [0]	PaO ₂ [120]
8	FiO ₂ [480]	FiO ₂ [0]	PaO ₂ [240]
9	FiO ₂ [240]	Ppeakinsp [120]	FiO ₂ [30]
10	PaO ₂ [480]	VTset [30]	SpO ₂ [60]
...	...	...	...
71	Platelets [30]	MAP [120]	Platelets [30]

Tabla 5.29. Ranking de importancia de características según los valores de Shapley — PaO₂, configuración “All Data”

La Tabla 5.30 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaCO₂ con “All Data” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaCO ₂ [30]	PaCO ₂ [30]	PaCO ₂ [30]
2	PaCO ₂ [60]	RRset [0]	PaO ₂ [0]
3	PaCO ₂ [480]	RRset [30]	PaCO ₂ [60]
4	FiO ₂ [0]	PaCO ₂ [480]	Crs [0]
5	pH [30]	RRset [120]	PaCO ₂ [480]
6	Crs [0]	VTset [0]	PaCO ₂ [240]
7	PaCO ₂ [240]	PaCO ₂ [240]	PaCO ₂ [120]
8	PaO ₂ [0]	SpO ₂ [30]	pH [30]
9	RRmeas [30]	VTset [30]	Weight
10	VTmeas [30]	FiO ₂ [30]	VTmeas [30]
...	...	...	...
71	Albumin [30]	PaO ₂ [240]	Platelets [30]

Tabla 5.30. Ranking de importancia de características según los valores de Shapley — PaCO₂, configuración “All Data”

La Tabla 5.31 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de Crs con “All Data” como configuración de entrada.

Top	NN	NN multitarea	RF
1	VTset [0]	Crs [120]	PaO ₂ [0]
2	Ppeakinsp [60]	RRset [0]	PaCO ₂ [0]
3	Crs [30]	VTset [0]	Crs [30]
4	PaCO ₂ [0]	RRset [30]	Crs [60]
5	PEEPset [60]	Ppeakinsp [120]	Crs [480]
6	FiO ₂ [120]	VTset [30]	Crs [120]
7	Crs [480]	RRset [120]	VTset [0]
8	PaO ₂ [0]	Crs [480]	Crs [240]
9	Crs [240]	PEEPset [30]	RRset [0]
10	PaCO ₂ [30]	FiO ₂ [30]	FiO ₂ [0]
...	...	...	...
71	FiO ₂ [240]	RRmeas [30]	NE [0]

Tabla 5.31. Ranking de importancia de características según los valores de Shapley — Crs, configuración “All Data”

La Tabla 5.32 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaO₂ con “30 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaO ₂ [30]	PaO ₂ [30]	PaO ₂ [30]
2	FiO ₂ [0]	RRset [0]	PaO ₂ [60]
3	SpO ₂ [30]	RRset [30]	SpO ₂ [30]
4	FiO ₂ [120]	RRset [120]	FiO ₂ [0]
5	Albumin [30]	SpO ₂ [30]	RRset [0]
6	RRset [120]	FiO ₂ [30]	FiO ₂ [30]
7	PaO ₂ [240]	VTset [0]	PaO ₂ [120]
8	FiO ₂ [480]	FiO ₂ [0]	SpO ₂ [60]
9	PEEPset [480]	Ppeakinsp [120]	PaO ₂ [240]
10	FiO ₂ [240]	VTset [30]	PaO ₂ [480]
...	...	...	...
69	FiO ₂ [30]	MAP [120]	Platelets [30]

Tabla 5.32. Ranking de importancia de características según los valores de Shapley — PaO₂, configuración “30 Minutes Blinded”

La Tabla 5.33 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaCO₂ con “30 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaCO ₂ [30]	PaCO ₂ [30]	PaCO ₂ [30]
2	PaCO ₂ [60]	RRset [0]	PaCO ₂ [60]
3	PaCO ₂ [480]	RRset [30]	PaCO ₂ [480]
4	Weight	PaCO ₂ [480]	PaCO ₂ [240]
5	FiO ₂ [0]	RRset [120]	PaCO ₂ [120]
6	pH [30]	VTset [0]	pH [30]
7	RRset [0]	PaCO ₂ [240]	Weight
8	PaCO ₂ [240]	SpO ₂ [30]	RRmeas [30]
9	SpO ₂ [30]	VTset [30]	VTmeas [30]
10	VTmeas [30]	FiO ₂ [30]	RRset [0]
...	...	...	...
69	VTset [120]	PaO ₂ [240]	Platelets [30]

Tabla 5.33. Ranking de importancia de características según los valores de Shapley — PaCO₂, configuración “30 Minutes Blinded”

La Tabla 5.34 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de Crs con “30 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	Ppeakinsp [30]	Crs [120]	Crs [30]
2	Crs [30]	RRset [0]	Crs [60]
3	VTset [0]	VTset [0]	Crs [120]
4	PEEPset [30]	RRset [30]	Crs [480]
5	Crs [120]	Ppeakinsp [120]	Crs [240]
6	Crs [480]	VTset [30]	VTset [0]
7	FiO ₂ [120]	RRset [120]	RRset [0]
8	Crs [240]	Crs [480]	FiO ₂ [0]
9	VTset [30]	PEEPset [30]	Ppeakinsp [30]
10	RRmeas [30]	FiO ₂ [30]	Ppeakinsp [60]
...	...	...	...
69	PaCO ₂ [30]	RRmeas [30]	NE [0]

Tabla 5.34. Ranking de importancia de características según los valores de Shapley — Crs, configuración “30 Minutes Blinded”

La Tabla 5.35 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaO₂ con “60 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaO ₂ [60]	PaO ₂ [60]	PaO ₂ [60]
2	FiO ₂ [0]	RRset [0]	SpO ₂ [60]
3	RRset [120]	RRset [30]	FiO ₂ [0]
4	RRset [30]	FiO ₂ [30]	FiO ₂ [30]
5	FiO ₂ [120]	SpO ₂ [60]	PaO ₂ [120]
6	SpO ₂ [60]	VTset [0]	RRset [0]
7	VTset [120]	RRset [120]	PaO ₂ [240]
8	FiO ₂ [480]	RRmeas [60]	PaO ₂ [480]
9	PEEPset [480]	VTset [120]	VTset [0]
10	FiO ₂ [240]	Ppeakinsp [120]	FiO ₂ [60]
...	...	...	...
49	Weight	RRset [60]	NE [0]

Tabla 5.35. Ranking de importancia de características según los valores de Shapley — PaO₂, configuración “60 Minutes Blinded”

La Tabla 5.36 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de PaCO₂ con “60 Minutes Blinded” como configuración de entrada.

Top	NN	NN multitarea	RF
1	PaCO ₂ [60]	PaCO ₂ [60]	PaCO ₂ [60]
2	PaCO ₂ [480]	PaCO ₂ [480]	PaCO ₂ [120]
3	PaCO ₂ [240]	PaCO ₂ [240]	PaCO ₂ [480]
4	FiO ₂ [0]	RRset [0]	PaCO ₂ [240]
5	Weight	RRset [30]	Weight
6	RRmeas [60]	RRset [120]	RRmeas [60]
7	RRset [30]	VTset [0]	VTmeas [60]
8	SpO ₂ [60]	VTset [30]	Age
9	VTset [0]	PaO ₂ [60]	FiO ₂ [0]
10	VTset [60]	SpO ₂ [60]	RRmeas [120]

...	...	...	...
49	RRset [0]	Crs [480]	NE [0]

Tabla 5.36. Ranking de importancia de características según los valores de Shapley — PaCO₂, configuración “60 Minutes Blinded”

La Tabla 5.37 recoge el ranking de importancia de las variables de entrada obtenido en la predicción de Crs con “60 Minutes Blinded” como configuración de entrada

Top	NN	NN multitarea	RF
1	VTset [0]	VTset [0]	Crs [60]
2	Ppeakinsp [60]	Crs [120]	Crs [120]
3	Crs [60]	Ppeakinsp [120]	Crs [480]
4	FiO ₂ [30]	VTset [30]	Crs [240]
5	PEEPset [30]	RRset [0]	VTset [0]
6	VTset [30]	RRset [30]	RRset [0]
7	Crs [480]	RRset [120]	Ppeakinsp [60]
8	Crs [120]	PEEPset [30]	FiO ₂ [0]
9	Crs [240]	Crs [240]	Ppeakinsp [120]
10	RRmeas [60]	RRmeas [60]	VTset [30]
...	...	...	...
49	RRset [120]	FiO ₂ [60]	NE [0]

Tabla 5.37. Ranking de importancia de características según los valores de Shapley — Crs, configuración “60 Minutes Blinded”

Para completar la información presentada en este apartado de manera visual, a continuación, se incluyen la Tabla 5.38, la Tabla 5.39 y la Tabla 5.40 para el método PI y la Tabla 5.41, la Tabla 5.42 y la Tabla 5.43 para el método SHAP. En ellas se muestran todas las variables de entrada, junto con su porcentaje relativo de contribución a la predicción de cada una de las variables objetivo, organizadas por configuración de entrada y modelo.

Se ha aplicado un código de colores para facilitar la identificación visual de las variables más relevantes en cada caso. Los tonos verdes corresponden a las contribuciones

más altas, los amarillos a valores intermedios y los blancos a aportaciones bajas o nulas.

Además, dentro de cada color, una mayor intensidad refleja un porcentaje más elevado.

PI con configuración "All Data"																	
FNN						FNN multitarea						RF					
PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs	
Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje
Age	0	Age	0,02	Age	0	Age	0	Age	0,31	Age	0	Age	0	Age	0	Age	0
Gender	0	Gender	0	Gender	0,03	Gender	0	Gender	0	Gender	0	Gender	0,16	Gender	0	Gender	2,52
Height	0	Height	0,12	Height	0,95	Height	0	Height	0,47	Height	0	Height	0	Height	0	Height	0
Weight	0	Weight	0,29	Weight	1,16	Weight	0	Weight	0	Weight	0	Weight	0	Weight	0	Weight	0
PaO ₂ [0]	0	PaO ₂ [0]	2,44	PaO ₂ [0]	2,76	PaO ₂ [0]	0	PaO ₂ [0]	0	PaO ₂ [0]	0	PaO ₂ [0]	0	PaO ₂ [0]	9,55	PaO ₂ [0]	0,01
PaO ₂ [30]	55,72	PaO ₂ [30]	0	PaO ₂ [30]	0,83	PaO ₂ [30]	35,72	PaO ₂ [30]	5,08	PaO ₂ [30]	4,64	PaO ₂ [30]	0	PaO ₂ [30]	0	PaO ₂ [30]	0
PaO ₂ [60]	0	PaO ₂ [60]	0,06	PaO ₂ [60]	1,19	PaO ₂ [60]	0	PaO ₂ [60]	0,6	PaO ₂ [60]	0,01	PaO ₂ [60]	0	PaO ₂ [60]	0,01	PaO ₂ [60]	0
PaO ₂ [120]	0	PaO ₂ [120]	0	PaO ₂ [120]	0	PaO ₂ [120]	0,16	PaO ₂ [120]	0	PaO ₂ [120]	0	PaO ₂ [120]	0	PaO ₂ [120]	0	PaO ₂ [120]	0
PaO ₂ [240]	2,44	PaO ₂ [240]	0,21	PaO ₂ [240]	2,4	PaO ₂ [240]	0,89	PaO ₂ [240]	0	PaO ₂ [240]	0	PaO ₂ [240]	0,01	PaO ₂ [240]	0,09	PaO ₂ [240]	0
PaO ₂ [480]	0,60	PaO ₂ [480]	0,01	PaO ₂ [480]	0,49	PaO ₂ [480]	0	PaO ₂ [480]	0	PaO ₂ [480]	0,95	PaO ₂ [480]	0	PaO ₂ [480]	0	PaO ₂ [480]	0
PaCO ₂ [0]	1,59	PaCO ₂ [0]	0	PaCO ₂ [0]	13,78	PaCO ₂ [0]	0	PaCO ₂ [0]	0	PaCO ₂ [0]	0	PaCO ₂ [0]	0	PaCO ₂ [0]	0	PaCO ₂ [0]	0
PaCO ₂ [30]	0	PaCO ₂ [30]	72,22	PaCO ₂ [30]	2,81	PaCO ₂ [30]	0,63	PaCO ₂ [30]	4,9	PaCO ₂ [30]	4,96	PaCO ₂ [30]	0	PaCO ₂ [30]	0,57	PaCO ₂ [30]	0
PaCO ₂ [60]	0	PaCO ₂ [60]	2,53	PaCO ₂ [60]	0	PaCO ₂ [60]	0,17	PaCO ₂ [60]	3,84	PaCO ₂ [60]	0,8	PaCO ₂ [60]	0	PaCO ₂ [60]	0	PaCO ₂ [60]	0
PaCO ₂ [120]	0	PaCO ₂ [120]	0,33	PaCO ₂ [120]	0,74	PaCO ₂ [120]	0	PaCO ₂ [120]	0,08	PaCO ₂ [120]	0,1	PaCO ₂ [120]	0	PaCO ₂ [120]	0	PaCO ₂ [120]	0
PaCO ₂ [240]	0	PaCO ₂ [240]	0	PaCO ₂ [240]	0	PaCO ₂ [240]	0	PaCO ₂ [240]	0,86	PaCO ₂ [240]	3,08	PaCO ₂ [240]	0	PaCO ₂ [240]	0	PaCO ₂ [240]	0
PaCO ₂ [480]	0	PaCO ₂ [480]	1,33	PaCO ₂ [480]	0,09	PaCO ₂ [480]	0	PaCO ₂ [480]	5,71	PaCO ₂ [480]	2,76	PaCO ₂ [480]	0	PaCO ₂ [480]	0	PaCO ₂ [480]	0
Crs [0]	0	Crs [0]	8,26	Crs [0]	0	Crs [0]	0	Crs [0]	0	Crs [0]	0	Crs [0]	0	Crs [0]	0	Crs [0]	0
Crs [30]	0	Crs [30]	0,01	Crs [30]	4,28	Crs [30]	0	Crs [30]	0,45	Crs [30]	0,93	Crs [30]	0,24	Crs [30]	0	Crs [30]	8,15
Crs [60]	0	Crs [60]	0,21	Crs [60]	0,01	Crs [60]	0,1	Crs [60]	0,05	Crs [60]	0	Crs [60]	0,51	Crs [60]	0	Crs [60]	23,57
Crs [120]	0	Crs [120]	0,59	Crs [120]	0	Crs [120]	0,69	Crs [120]	0	Crs [120]	19,21	Crs [120]	0,17	Crs [120]	0	Crs [120]	0
Crs [240]	0	Crs [240]	0,44	Crs [240]	0,02	Crs [240]	0	Crs [240]	0	Crs [240]	0	Crs [240]	0,04	Crs [240]	0	Crs [240]	0
Crs [480]	0	Crs [480]	0	Crs [480]	0,22	Crs [480]	0	Crs [480]	0	Crs [480]	1,81	Crs [480]	0	Crs [480]	0	Crs [480]	48,95
RRset [0]	0	RRset [0]	0	RRset [0]	0	RRset [0]	0	RRset [0]	20,03	RRset [0]	0	RRset [0]	0,23	RRset [0]	0	RRset [0]	0,12
RRset [30]	0,53	RRset [30]	0,21	RRset [30]	0	RRset [30]	0	RRset [30]	15,69	RRset [30]	0	RRset [30]	0	RRset [30]	0,08	RRset [30]	0,45
RRset [60]	0	RRset [60]	0	RRset [60]	0	RRset [60]	0	RRset [60]	0,25	RRset [60]	0,47	RRset [60]	0	RRset [60]	0	RRset [60]	1,22
RRset [120]	4,18	RRset [120]	0,34	RRset [120]	0	RRset [120]	6,73	RRset [120]	0	RRset [120]	5,61	RRset [120]	0	RRset [120]	0	RRset [120]	0,74
RRmeas [30]	0	RRmeas [30]	1	RRmeas [30]	0	RRmeas [30]	0,15	RRmeas [30]	0,8	RRmeas [30]	0	RRmeas [30]	0,27	RRmeas [30]	9,25	RRmeas [30]	0,01
RRmeas [60]	0	RRmeas [60]	0,06	RRmeas [60]	0,05	RRmeas [60]	0	RRmeas [60]	2,7	RRmeas [60]	5,57	RRmeas [60]	0,01	RRmeas [60]	0	RRmeas [60]	0
RRmeas [120]	0	RRmeas [120]	0,01	RRmeas [120]	0	RRmeas [120]	0	RRmeas [120]	7,82	RRmeas [120]	2,83	RRmeas [120]	0	RRmeas [120]	0	RRmeas [120]	0
VTset [0]	0	VTset [0]	0	VTset [0]	21,14	VTset [0]	0	VTset [0]	0	VTset [0]	9,96	VTset [0]	0,48	VTset [0]	0	VTset [0]	5,86
VTset [30]	0	VTset [30]	0	VTset [30]	0,82	VTset [30]	0	VTset [30]	0	VTset [30]	0	VTset [30]	0	VTset [30]	0	VTset [30]	0
VTset [60]	0	VTset [60]	0	VTset [60]	0	VTset [60]	1,59	VTset [60]	1,68	VTset [60]	3,19	VTset [60]	0	VTset [60]	0	VTset [60]	3,22

VTset [120]	0,68	VTset [120]	0	VTset [120]	0	VTset [120]	5,07	VTset [120]	0	VTset [120]	2,15	VTset [120]	0	VTset [120]	0	VTset [120]	2,23
VTmeas [30]	0	VTmeas [30]	0	VTmeas [30]	0	VTmeas [30]	0	VTmeas [30]	1,19	VTmeas [30]	0,99	VTmeas [30]	0,12	VTmeas [30]	0	VTmeas [30]	0
VTmeas [60]	0	VTmeas [60]	0,05	VTmeas [60]	0	VTmeas [60]	0	VTmeas [60]	0,15	VTmeas [60]	0,08	VTmeas [60]	0	VTmeas [60]	0	VTmeas [60]	0,09
VTmeas [120]	0	VTmeas [120]	0,21	VTmeas [120]	0	VTmeas [120]	0,12	VTmeas [120]	0	VTmeas [120]	0	VTmeas [120]	0	VTmeas [120]	0	VTmeas [120]	0
VentMode [0]	0	VentMode [0]	0,11	VentMode [0]	0,5	VentMode [0]	1,49	VentMode [0]	2,05	VentMode [0]	1,05	VentMode [0]	0	VentMode [0]	0	VentMode [0]	0
PEEPset [30]	0	PEEPset [30]	0	PEEPset [30]	0,63	PEEPset [30]	1	PEEPset [30]	0	PEEPset [30]	0	PEEPset [30]	0,05	PEEPset [30]	0	PEEPset [30]	0,66
PEEPset [60]	0	PEEPset [60]	0	PEEPset [60]	5,49	PEEPset [60]	0	PEEPset [60]	0,09	PEEPset [60]	0,02	PEEPset [60]	0	PEEPset [60]	0	PEEPset [60]	0,19
PEEPset [120]	0	PEEPset [120]	0,48	PEEPset [120]	0,44	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	1,06
PEEPset [240]	0	PEEPset [240]	0	PEEPset [240]	0,09	PEEPset [240]	0	PEEPset [240]	0,37	PEEPset [240]	0,11	PEEPset [240]	0	PEEPset [240]	36	PEEPset [240]	0
PEEPset [480]	0	PEEPset [480]	0,34	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0,47
Ppeakinsp [30]	0,49	Ppeakinsp [30]	0,06	Ppeakinsp [30]	0	Ppeakinsp [30]	0	Ppeakinsp [30]	0,1	Ppeakinsp [30]	0	Ppeakinsp [30]	0,01	Ppeakinsp [30]	0	Ppeakinsp [30]	0
Ppeakinsp [60]	0	Ppeakinsp [60]	0,2	Ppeakinsp [60]	19,78	Ppeakinsp [60]	0,09	Ppeakinsp [60]	0	Ppeakinsp [60]	0	Ppeakinsp [60]	0	Ppeakinsp [60]	0	Ppeakinsp [60]	0
Ppeakinsp [120]	0	Ppeakinsp [120]	0	Ppeakinsp [120]	0,88	Ppeakinsp [120]	3,94	Ppeakinsp [120]	0	Ppeakinsp [120]	0	Ppeakinsp [120]	0,54	Ppeakinsp [120]	0	Ppeakinsp [120]	0
FiO ₂ [0]	17,24	FiO ₂ [0]	4,88	FiO ₂ [0]	0	FiO ₂ [0]	11,27	FiO ₂ [0]	5,62	FiO ₂ [0]	2,78	FiO ₂ [0]		FiO ₂ [0]	1,36	FiO ₂ [0]	0
FiO ₂ [30]	0	FiO ₂ [30]	0,05	FiO ₂ [30]	1	FiO ₂ [30]	14,01	FiO ₂ [30]	7,71	FiO ₂ [30]	7,4	FiO ₂ [30]	42,71	FiO ₂ [30]	1,49	FiO ₂ [30]	0
FiO ₂ [60]	0	FiO ₂ [60]	0,13	FiO ₂ [60]	0	FiO ₂ [60]	0	FiO ₂ [60]	0,12	FiO ₂ [60]	0,94	FiO ₂ [60]	0	FiO ₂ [60]	1,55	FiO ₂ [60]	0
FiO ₂ [120]	3,9	FiO ₂ [120]	0,01	FiO ₂ [120]	5,25	FiO ₂ [120]	1,72	FiO ₂ [120]	0,84	FiO ₂ [120]	2,95	FiO ₂ [120]	0	FiO ₂ [120]	13,93	FiO ₂ [120]	0
FiO ₂ [240]	1,01	FiO ₂ [240]	0,13	FiO ₂ [240]	0	FiO ₂ [240]	0,65	FiO ₂ [240]	0,82	FiO ₂ [240]	1,78	FiO ₂ [240]	0	FiO ₂ [240]	0	FiO ₂ [240]	0
FiO ₂ [480]	1,85	FiO ₂ [480]	0	FiO ₂ [480]	0	FiO ₂ [480]	2,55	FiO ₂ [480]	1,79	FiO ₂ [480]	5,01	FiO ₂ [480]	50,4	FiO ₂ [480]	24	FiO ₂ [480]	0
SpO ₂ [30]	8,02	SpO ₂ [30]	0	SpO ₂ [30]	0,26	SpO ₂ [30]	10,67	SpO ₂ [30]	3,28	SpO ₂ [30]	5,08	SpO ₂ [30]	0,01	SpO ₂ [30]	0	SpO ₂ [30]	0
SpO ₂ [60]	0	SpO ₂ [60]	0,06	SpO ₂ [60]	0,29	SpO ₂ [60]	0	SpO ₂ [60]	0	SpO ₂ [60]	1,28	SpO ₂ [60]	0,06	SpO ₂ [60]	0	SpO ₂ [60]	0,01
SpO ₂ [120]	0	SpO ₂ [120]	0,17	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0,06	SpO ₂ [120]	0,02
HR [30]	0	HR [30]	0	HR [30]	1,16	HR [30]	0	HR [30]	0	HR [30]	0	HR [30]	0	HR [30]	0	HR [30]	0,04
HR [120]	0	HR [120]	0,03	HR [120]	0,62	HR [120]	0	HR [120]	0,02	HR [120]	0	HR [120]	0	HR [120]	0	HR [120]	0
HR [480]	0	HR [480]	0,25	HR [480]	2,45	HR [480]	0	HR [480]	0,19	HR [480]	0	HR [480]	0	HR [480]	0	HR [480]	0
MAP [30]	0	MAP [30]	0	MAP [30]	1,42	MAP [30]	0	MAP [30]	0	MAP [30]	0	MAP [30]	0	MAP [30]	0,57	MAP [30]	0
MAP [120]	0	MAP [120]	0,03	MAP [120]	1,51	MAP [120]	0	MAP [120]	0,53	MAP [120]	0	MAP [120]	0	MAP [120]	0,71	MAP [120]	0,11
MAP [480]	0	MAP [480]	0,36	MAP [480]	0,82	MAP [480]	0	MAP [480]	0	MAP [480]	0,23	MAP [480]	0,03	MAP [480]	0,1	MAP [480]	0,02
NE [0]	0	NE [0]	0	NE [0]	0,08	NE [0]	0	NE [0]	0	NE [0]	0,08	NE [0]	0	NE [0]	0,14	NE [0]	0
Albumin [30]	1,75	Albumin [30]	0,08	Albumin [30]	0	Albumin [30]	0	Albumin [30]	1,31	Albumin [30]	0	Albumin [30]	3,86	Albumin [30]	0,27	Albumin [30]	0,07
Bilirubin_d [30]	0	Bilirubin_d [30]	0,11	Bilirubin_d [30]	0,35	Bilirubin_d [30]	0	Bilirubin_d [30]	0,11	Bilirubin_d [30]	0	Bilirubin_d [30]	0	Bilirubin_d [30]	0	Bilirubin_d [30]	0,03
Bilirubin_i [30]	0	Bilirubin_i [30]	0,13	Bilirubin_i [30]	0,52	Bilirubin_i [30]	0	Bilirubin_i [30]	0,27	Bilirubin_i [30]	0,5	Bilirubin_i [30]	0	Bilirubin_i [30]	0	Bilirubin_i [30]	0,16
Creatinine [30]	0	Creatinine [30]	0,06	Creatinine [30]	0	Creatinine [30]	0	Creatinine [30]	0,14	Creatinine [30]	0	Creatinine [30]	0,07	Creatinine [30]	0	Creatinine [30]	0
Lactate [30]	0	Lactate [30]	0,47	Lactate [30]	0,65	Lactate [30]	0	Lactate [30]	0	Lactate [30]	0	Lactate [30]	0	Lactate [30]	0	Lactate [30]	0
Temperatur e [30]	0	Temperatur e [30]	0	Temperatur e [30]	0,3	Temperatur e [30]	0	Temperatur e [30]	0,15	Temperatur e [30]	0,54	Temperatur e [30]	0	Temperatur e [30]	0	Temperatur e [30]	0
Platelets [30]	0	Platelets [30]	0	Platelets [30]	0,72	Platelets [30]	0	Platelets [30]	0,55	Platelets [30]	0	Platelets [30]	0	Platelets [30]	0	Platelets [30]	0
Leukocytes [30]	0	Leukocytes [30]	0,18	Leukocytes [30]	0,9	Leukocytes [30]	0	Leukocytes [30]	0,3	Leukocytes [30]	0	Leukocytes [30]	0	Leukocytes [30]	0,13	Leukocytes [30]	0
HB gasometry [30]	0	HB gasometry [30]	0	HB gasometry [30]	0	HB gasometry [30]	0,13	HB gasometry [30]	0	HB gasometry [30]	0	HB gasometry [30]	0	HB gasometry [30]	0	HB gasometry [30]	0
pH [30]	0	pH [30]	0,63	pH [30]	0,12	pH [30]	0,46	pH [30]	0,99	pH [30]	0,14	pH [30]	0	pH [30]	0	pH [30]	0

INR [30]	0	INR [30]	0,11	INR [30]	0	INR [30]	0	INR [30]	0	INR [30]	0	INR [30]	0	INR [30]	0,14	INR [30]	0
----------	---	----------	------	----------	---	----------	---	----------	---	----------	---	----------	---	----------	------	----------	---

Tabla 5.38. PI de las variables predictoras para cada variable objetivo en la configuración "All Data". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.

Al observar la Tabla 5.38, se aprecia que los porcentajes más elevados se concentran en la mayoría de los casos en las variables directamente asociadas a las mediciones recientes de PaO₂, PaCO₂ y Crs. Cuentan con valores numéricos que superan con claridad al resto. En paralelo, FiO₂ y algunos parámetros ventilatorios también presentan contribuciones destacables en distintos modelos. Por otro lado, la mayoría de variables demográficas y bioquímicas aparecen con porcentajes próximos a cero.

PI con configuración "30 Minutes Blinded"																	
FNN						FNN multitarea						RF					
PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs	
Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje
Age	0	Age	0,29	Age	0	Age	0	Age	0,31	Age	0	Age	0	Age	0	Age	0
Gender	0	Gender	0,31	Gender	0	Gender	0	Gender	0	Gender	0	Gender	0	Gender	0	Gender	0
Height	0	Height	0,26	Height	0	Height	0	Height	0,47	Height	0	Height	0	Height	0	Height	0
Weight	0	Weight	1,83	Weight	0	Weight	0	Weight	0	Weight	0	Weight	0,01	Weight	0	Weight	0
PaO ₂ [0]	0	PaO ₂ [30]	0,51	PaO ₂ [30]	0,86	PaO ₂ [0]	0	PaO ₂ [30]	5,08	PaO ₂ [30]	4,64	PaO ₂ [0]	0	PaO ₂ [30]	0	PaO ₂ [30]	0
PaO ₂ [30]	57,42	PaO ₂ [60]	0,41	PaO ₂ [60]	0	PaO ₂ [30]	35,72	PaO ₂ [60]	0,6	PaO ₂ [60]	0,01	PaO ₂ [30]	0	PaO ₂ [60]	0	PaO ₂ [60]	0
PaO ₂ [60]	0	PaO ₂ [120]	0,42	PaO ₂ [120]	0	PaO ₂ [60]	0	PaO ₂ [120]	0	PaO ₂ [120]	0	PaO ₂ [60]	0	PaO ₂ [120]	0	PaO ₂ [120]	0
PaO ₂ [120]	0	PaO ₂ [240]	0,45	PaO ₂ [240]	0	PaO ₂ [120]	0,16	PaO ₂ [240]	0,86	PaO ₂ [240]	0	PaO ₂ [120]	0	PaO ₂ [240]	0	PaO ₂ [240]	0
PaO ₂ [240]	3,96	PaO ₂ [480]	0,32	PaO ₂ [480]	0	PaO ₂ [240]	0,89	PaO ₂ [480]	0	PaO ₂ [480]	0,95	PaO ₂ [240]	0	PaO ₂ [480]	0,01	PaO ₂ [480]	0
PaO ₂ [480]	0,39	PaCO ₂ [0]	0	PaCO ₂ [30]	3,3	PaO ₂ [480]	0	PaCO ₂ [0]	0	PaCO ₂ [30]	4,96	PaO ₂ [480]	0	PaCO ₂ [0]	0	PaCO ₂ [30]	0
PaCO ₂ [30]	0,02	PaCO ₂ [30]	57,59	PaCO ₂ [60]	0	PaCO ₂ [30]	0,63	PaCO ₂ [30]	4,9	PaCO ₂ [60]	0,8	PaCO ₂ [30]	0	PaCO ₂ [30]	0	PaCO ₂ [60]	0
PaCO ₂ [60]	0	PaCO ₂ [60]	7,45	PaCO ₂ [120]	0	PaCO ₂ [60]	0,17	PaCO ₂ [60]	3,84	PaCO ₂ [120]	0,1	PaCO ₂ [60]	0	PaCO ₂ [60]	0	PaCO ₂ [120]	0
PaCO ₂ [120]	0,18	PaCO ₂ [120]	0,22	PaCO ₂ [240]	0	PaCO ₂ [120]	0	PaCO ₂ [120]	0,08	PaCO ₂ [240]	3,08	PaCO ₂ [120]	0	PaCO ₂ [120]	0	PaCO ₂ [240]	0
PaCO ₂ [240]	0	PaCO ₂ [240]	1,15	PaCO ₂ [480]	0	PaCO ₂ [240]	0	PaCO ₂ [240]	0	PaCO ₂ [480]	2,76	PaCO ₂ [240]	0	PaCO ₂ [240]	0	PaCO ₂ [480]	0
PaCO ₂ [480]	0	PaCO ₂ [480]	3,52	Crs [0]	0	PaCO ₂ [480]	0	PaCO ₂ [480]	5,71	Crs [0]	0	PaCO ₂ [480]	0,01	PaCO ₂ [480]	0	Crs [0]	0
Crs [30]	0	Crs [30]	0,39	Crs [30]	2,51	Crs [30]	0	Crs [30]	0,45	Crs [30]	0,93	Crs [30]	0,18	Crs [30]	0	Crs [30]	0
Crs [60]	0,13	Crs [60]	0,38	Crs [60]	0	Crs [60]	0,1	Crs [60]	0,05	Crs [60]	0	Crs [60]	0,71	Crs [60]	0	Crs [60]	1,26
Crs [120]	0	Crs [120]	0,3	Crs [120]	0	Crs [120]	0,69	Crs [120]	0	Crs [120]	19,21	Crs [120]	0	Crs [120]	0	Crs [120]	0
Crs [240]	0	Crs [240]	0,55	Crs [240]	0,89	Crs [240]	0	Crs [240]	0	Crs [240]	0	Crs [240]	0	Crs [240]	0	Crs [240]	0
Crs [480]	0	Crs [480]	0,4	Crs [480]	1,14	Crs [480]	0	Crs [480]	0	Crs [480]	1,81	Crs [480]	0,21	Crs [480]	0	Crs [480]	19,71
RRset [0]	0	RRset [0]	0,76	RRset [0]	0	RRset [0]	0	RRset [0]	20,03	RRset [0]	0	RRset [0]	0,9	RRset [0]	0	RRset [0]	8,12

RRset [30]	0,02	RRset [30]	0,1	RRset [30]	0	RRset [30]	0	RRset [30]	15,69	RRset [30]	0	RRset [30]	0,32	RRset [30]	0	RRset [30]	0
RRset [60]	0	RRset [60]	0,2	RRset [60]	0	RRset [60]	0	RRset [60]	0,25	RRset [60]	0,47	RRset [60]	0	RRset [60]	0,12	RRset [60]	23,11
RRset [120]	2,11	RRset [120]	0,28	RRset [120]	0	RRset [120]	6,73	RRset [120]	0	RRset [120]	5,61	RRset [120]	0	RRset [120]	0	RRset [120]	0
RRmeas [30]	0	RRmeas [30]	0,7	RRmeas [30]	0	RRmeas [30]	0,15	RRmeas [30]	0,8	RRmeas [30]	0	RRmeas [30]	0,09	RRmeas [30]	0,34	RRmeas [30]	0,13
RRmeas [60]	0	RRmeas [60]	0,44	RRmeas [60]	0	RRmeas [60]	0	RRmeas [60]	2,7	RRmeas [60]	5,57	RRmeas [60]	0,12	RRmeas [60]	0	RRmeas [60]	0,11
RRmeas [120]	0	RRmeas [120]	0,18	RRmeas [120]	0	RRmeas [120]	0	RRmeas [120]	7,82	RRmeas [120]	2,83	RRmeas [120]	0	RRmeas [120]	0	RRmeas [120]	0,01
VTset [0]	0	VTset [0]	0,39	VTset [0]	26,53	VTset [0]	0	VTset [0]	0	VTset [0]	9,96	VTset [0]	0	VTset [0]	0	VTset [0]	1,76
VTset [30]	0	VTset [30]	0,23	VTset [30]	5,03	VTset [30]	0	VTset [30]	0	VTset [30]	0	VTset [30]	0,29	VTset [30]	0	VTset [30]	0
VTset [60]	0	VTset [60]	0,36	VTset [60]	0	VTset [60]	1,59	VTset [60]	1,68	VTset [60]	3,19	VTset [60]	0	VTset [60]	0	VTset [60]	0
VTset [120]	1,2	VTset [120]	0,2	VTset [120]	0	VTset [120]	5,07	VTset [120]	0	VTset [120]	2,15	VTset [120]	0	VTset [120]	0	VTset [120]	13,36
VTmeas [30]	0	VTmeas [30]	0,69	VTmeas [30]	0	VTmeas [30]	0	VTmeas [30]	1,19	VTmeas [30]	0,99	VTmeas [30]	0	VTmeas [30]	0	VTmeas [30]	0
VTmeas [60]	0	VTmeas [60]	0,36	VTmeas [60]	0,96	VTmeas [60]	0	VTmeas [60]	0,15	VTmeas [60]	0,08	VTmeas [60]	0	VTmeas [60]	0	VTmeas [60]	0,78
VTmeas [120]	0	VTmeas [120]	0,22	VTmeas [120]	0	VTmeas [120]	0,12	VTmeas [120]	0	VTmeas [120]	0	VTmeas [120]	0,26	VTmeas [120]	0	VTmeas [120]	0,43
VentMode [0]	0	VentMode [0]	0,35	VentMode [0]	0	VentMode [0]	1,49	VentMode [0]	2,05	VentMode [0]	1,05	VentMode [0]	50,21	VentMode [0]	0	VentMode [0]	0
PEEPset [30]	0	PEEPset [30]	0,21	PEEPset [30]	12,08	PEEPset [30]	1	PEEPset [30]	0	PEEPset [30]	0	PEEPset [30]	0	PEEPset [30]	0	PEEPset [30]	0
PEEPset [60]	0,01	PEEPset [60]	0,56	PEEPset [60]	0	PEEPset [60]	0	PEEPset [60]	0,09	PEEPset [60]	0,02	PEEPset [60]	0,05	PEEPset [60]	0	PEEPset [60]	1,76
PEEPset [120]	0	PEEPset [120]	0,22	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	0
PEEPset [240]	0	PEEPset [240]	0,37	PEEPset [240]	0	PEEPset [240]	0	PEEPset [240]	0,37	PEEPset [240]	0,11	PEEPset [240]	0	PEEPset [240]	0	PEEPset [240]	0
PEEPset [480]	0	PEEPset [480]	0,22	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0	PEEPset [480]	0
Ppeakinsp [30]	0	Ppeakinsp [30]	0,27	Ppeakinsp [30]	29,04	Ppeakinsp [30]	0	Ppeakinsp [30]	0,1	Ppeakinsp [30]	0	Ppeakinsp [30]	0,24	Ppeakinsp [30]	0,05	Ppeakinsp [30]	16,22
Ppeakinsp [60]	0,58	Ppeakinsp [60]	0,19	Ppeakinsp [60]	0,08	Ppeakinsp [60]	0,09	Ppeakinsp [60]	0	Ppeakinsp [60]	0	Ppeakinsp [60]	0	Ppeakinsp [60]	0	Ppeakinsp [60]	10,96
Ppeakinsp [120]	0	Ppeakinsp [120]	0,36	Ppeakinsp [120]	0	Ppeakinsp [120]	3,94	Ppeakinsp [120]	0	Ppeakinsp [120]	0	Ppeakinsp [120]	0	Ppeakinsp [120]	0	Ppeakinsp [120]	0,66
FiO ₂ [0]	15,05	FiO ₂ [0]	5,68	FiO ₂ [0]	0	FiO ₂ [0]	11,27	FiO ₂ [0]	5,62	FiO ₂ [0]	2,78	FiO ₂ [0]	19,75	FiO ₂ [0]	64,3	FiO ₂ [0]	0
FiO ₂ [30]	0	FiO ₂ [30]	0,25	FiO ₂ [30]	0	FiO ₂ [30]	14,01	FiO ₂ [30]	7,71	FiO ₂ [30]	7,4	FiO ₂ [30]	0	FiO ₂ [30]	27,4	FiO ₂ [30]	0
FiO ₂ [60]	0	FiO ₂ [60]	0,14	FiO ₂ [60]	0,8	FiO ₂ [60]	0	FiO ₂ [60]	0,12	FiO ₂ [60]	0,94	FiO ₂ [60]	0	FiO ₂ [60]	4,02	FiO ₂ [60]	0
FiO ₂ [120]	4,99	FiO ₂ [120]	0,47	FiO ₂ [120]	8,56	FiO ₂ [120]	1,72	FiO ₂ [120]	0,84	FiO ₂ [120]	2,95	FiO ₂ [120]	10,38	FiO ₂ [120]	0	FiO ₂ [120]	0
FiO ₂ [240]	0	FiO ₂ [240]	0,18	FiO ₂ [240]	0	FiO ₂ [240]	0,65	FiO ₂ [240]	0,82	FiO ₂ [240]	1,78	FiO ₂ [240]	2,7	FiO ₂ [240]	0	FiO ₂ [240]	0
FiO ₂ [480]	0,57	FiO ₂ [480]	0,4	FiO ₂ [480]	0	FiO ₂ [480]	2,55	FiO ₂ [480]	1,79	FiO ₂ [480]	5,01	FiO ₂ [480]	0	FiO ₂ [480]	0	FiO ₂ [480]	0
SpO ₂ [30]	11,03	SpO ₂ [30]	0,9	SpO ₂ [30]	0	SpO ₂ [30]	10,67	SpO ₂ [30]	3,28	SpO ₂ [30]	5,08	SpO ₂ [30]	0	SpO ₂ [30]	0,02	SpO ₂ [30]	0
SpO ₂ [60]	0	SpO ₂ [60]	0,37	SpO ₂ [60]	0	SpO ₂ [60]	0	SpO ₂ [60]	0	SpO ₂ [60]	1,28	SpO ₂ [60]	0	SpO ₂ [60]	0	SpO ₂ [60]	0
SpO ₂ [120]	0	SpO ₂ [120]	0,29	SpO ₂ [120]	0,84	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0
HR [30]	0	HR [30]	0,37	HR [30]	0	HR [30]	0	HR [30]	0	HR [30]	0	HR [30]	0,01	HR [30]	0,01	HR [30]	0
HR [120]	0	HR [120]	0,52	HR [120]	0	HR [120]	0	HR [120]	0,02	HR [120]	0	HR [120]	0	HR [120]	0	HR [120]	0,02
HR [480]	0,12	HR [480]	0,2	HR [480]	0	HR [480]	0	HR [480]	0,19	HR [480]	0	HR [480]	0	HR [480]	0	HR [480]	0
MAP [30]	0	MAP [30]	0,31	MAP [30]	0	MAP [30]	0	MAP [30]	0	MAP [30]	0	MAP [30]	0	MAP [30]	0,14	MAP [30]	0,04
MAP [120]	0	MAP [120]	0,22	MAP [120]	2,54	MAP [120]	0	MAP [120]	0,53	MAP [120]	0	MAP [120]	0,33	MAP [120]	0	MAP [120]	0,08
MAP [480]	0	MAP [480]	0,49	MAP [480]	0	MAP [480]	0	MAP [480]	0	MAP [480]	0,23	MAP [480]	0	MAP [480]	0	MAP [480]	0

NE [0]	0	NE [0]	0,36	NE [0]	0	NE [0]	0	NE [0]	0	NE [0]	0,08	NE [0]	10,87	NE [0]	0	NE [0]	0
Albumin [30]	1,73	Albumin [30]	0,29	Albumin [30]	0	Albumin [30]	0	Albumin [30]	1,31	Albumin [30]	0	Albumin [30]	0	Albumin [30]	0	Albumin [30]	0,26
Bilirubin_d [30]	0,17	Bilirubin_d [30]	0,09	Bilirubin_d [30]	1,46	Bilirubin_d [30]	0	Bilirubin_d [30]	0,11	Bilirubin_d [30]	0	Bilirubin_d [30]	0	Bilirubin_d [30]	0	Bilirubin_d [30]	0
Bilirubin_i [30]	0,04	Bilirubin_i [30]	0,15	Bilirubin_i [30]	2,63	Bilirubin_i [30]	0	Bilirubin_i [30]	0,27	Bilirubin_i [30]	0,5	Bilirubin_i [30]	0,32	Bilirubin_i [30]	0,01	Bilirubin_i [30]	0,05
Creatinine [30]	0	Creatinine [30]	0,58	Creatinine [30]	0	Creatinine [30]	0	Creatinine [30]	0,14	Creatinine [30]	0	Creatinine [30]	2,04	Creatinine [30]	0,03	Creatinine [30]	0
Lactate [30]	0	Lactate [30]	0,45	Lactate [30]	0	Lactate [30]	0	Lactate [30]	0	Lactate [30]	0	Lactate [30]	0	Lactate [30]	0,02	Lactate [30]	0,92
Temperatur e [30]	0	Temperatur e [30]	0,29	Temperatur e [30]	0,77	Temperatur e [30]	0	Temperatur e [30]	0,15	Temperatur e [30]	0,54	Temperatur e [30]	0	Temperatur e [30]	0	Temperatur e [30]	0
Platelets [30]	0	Platelets [30]	0,25	Platelets [30]	0	Platelets [30]	0	Platelets [30]	0,55	Platelets [30]	0	Platelets [30]	0	Platelets [30]	0	Platelets [30]	0
Leukocytes [30]	0,13	Leukocytes [30]	0,42	Leukocytes [30]	0	Leukocytes [30]	0	Leukocytes [30]	0,3	Leukocytes [30]	0	Leukocytes [30]	0	Leukocytes [30]	3,54	Leukocytes [30]	0,24
HB gasometry [30]	0	HB gasometry [30]	0,19	HB gasometry [30]	0	HB gasometry [30]	0,13	HB gasometry [30]	0	HB gasometry [30]	0	HB gasometry [30]	0	HB gasometry [30]	0	HB gasometry [30]	0
pH [30]	0	pH [30]	1,26	pH [30]	0	pH [30]	0,46	pH [30]	0,99	pH [30]	0,14	pH [30]	0	pH [30]	0	pH [30]	0
INR [30]	0,14	INR [30]	0,31	INR [30]	0	INR [30]	0	INR [30]	0	INR [30]	0	INR [30]	0	INR [30]	0	INR [30]	0

Tabla 5.39. PI de las variables predictoras para cada variable objetivo en la configuración "30 Minutes Blinded". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.

En la configuración “30 Minutes Blinded” (Tabla 5.39), el reparto de valores mantiene la misma estructura general, aunque los porcentajes se desplazan hacia mediciones de desfases temporales más amplios. Visualmente, se aprecia un incremento de la presencia de variables ventilatorias (como PEEP, VT o Ppeakinsp) en varios de los modelos, con porcentajes notables en ciertas columnas.

PI con configuración "60 Minutes Blinded"																	
FNN						FNN multitarea						RF					
PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs	
Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje
Age	0	Age	0,09	Age	0,62	Age	0	Age	0	Age	1,24	Age	0	Age	0	Age	0
Gender	0	Gender	0,13	Gender	2,39	Gender	0	Gender	0	Gender	0,99	Gender	4,24	Gender	0,24	Gender	0
Height	0	Height	0,21	Height	1,51	Height	0	Height	0,33	Height	1,59	Height	0	Height	0	Height	0
Weight	0	Weight	0,81	Weight	1,95	Weight	0	Weight	2,14	Weight	1,84	Weight	0	Weight	0	Weight	0
PaO ₂ [0]	0	PaO ₂ [60]	0,29	PaO ₂ [60]	0,5	PaO ₂ [0]	0	PaO ₂ [60]	2,81	PaO ₂ [60]	3,16	PaO ₂ [0]	0	PaO ₂ [60]	0	PaO ₂ [60]	0
PaO ₂ [60]	55,19	PaO ₂ [120]	0,1	PaO ₂ [120]	1,41	PaO ₂ [60]	37,84	PaO ₂ [120]	0	PaO ₂ [120]	1,2	PaO ₂ [60]	0,28	PaO ₂ [120]	0	PaO ₂ [120]	0
PaO ₂ [120]	0	PaO ₂ [240]	0,27	PaO ₂ [240]	1,44	PaO ₂ [120]	0	PaO ₂ [240]	3,32	PaO ₂ [240]	1,3	PaO ₂ [120]	0,11	PaO ₂ [240]	0	PaO ₂ [240]	0
PaO ₂ [240]	0,42	PaO ₂ [480]	0,13	PaO ₂ [480]	1,14	PaO ₂ [240]	1,09	PaO ₂ [480]	0	PaO ₂ [480]	3,5	PaO ₂ [240]	0,17	PaO ₂ [480]	0	PaO ₂ [480]	0
PaO ₂ [480]	0	PaCO ₂ [0]	0	PaCO ₂ [60]	0,69	PaO ₂ [480]	0	PaCO ₂ [0]	0	PaCO ₂ [60]	2,86	PaO ₂ [480]	0,02	PaCO ₂ [0]	0	PaCO ₂ [60]	0
PaCO ₂ [60]	0	PaCO ₂ [60]	82,86	PaCO ₂ [120]	1,24	PaCO ₂ [60]	0,75	PaCO ₂ [60]	5,9	PaCO ₂ [120]	0,98	PaCO ₂ [60]	0	PaCO ₂ [60]	0	PaCO ₂ [120]	0
PaCO ₂ [120]	0	PaCO ₂ [120]	0,13	PaCO ₂ [240]	0,76	PaCO ₂ [120]	0	PaCO ₂ [120]	0	PaCO ₂ [240]	1,22	PaCO ₂ [120]	0	PaCO ₂ [120]	0	PaCO ₂ [240]	0
PaCO ₂ [240]	0	PaCO ₂ [240]	0,01	PaCO ₂ [480]	1,85	PaCO ₂ [240]	0	PaCO ₂ [240]	5,24	PaCO ₂ [480]	1,31	PaCO ₂ [240]	0	PaCO ₂ [240]	0	PaCO ₂ [480]	0,01
PaCO ₂ [480]	0,11	PaCO ₂ [480]	2,76	Crs [0]	0	PaCO ₂ [480]	0	PaCO ₂ [480]	0	Crs [0]	0	PaCO ₂ [480]	0	PaCO ₂ [480]	0	Crs [0]	0

Crs [60]	0	Crs [60]	0,34	Crs [60]	6,78	Crs [60]	0,56	Crs [60]	0	Crs [60]	0	Crs [60]	0,35	Crs [60]	0	Crs [60]	36,48
Crs [120]	0	Crs [120]	0,09	Crs [120]	2,01	Crs [120]	2,45	Crs [120]	0	Crs [120]	5,68	Crs [120]	6,87	Crs [120]	0,58	Crs [120]	8,64
Crs [240]	0	Crs [240]	0,3	Crs [240]	1,04	Crs [240]	0,12	Crs [240]	0	Crs [240]	0	Crs [240]	6,87	Crs [240]	0	Crs [240]	9,1
Crs [480]	0	Crs [480]	0,21	Crs [480]	2,93	Crs [480]	0	Crs [480]	0	Crs [480]	1,26	Crs [480]	0,14	Crs [480]	0,43	Crs [480]	0
RRset [0]	0	RRset [0]	0,12	RRset [0]	1,57	RRset [0]	0	RRset [0]	0	RRset [0]	2,12	RRset [0]	0	RRset [0]	0	RRset [0]	0
RRset [30]	4,5	RRset [30]	0,34	RRset [30]	0,29	RRset [30]	0	RRset [30]	5,35	RRset [30]	0	RRset [30]	0	RRset [30]	8,34	RRset [30]	7,47
RRset [60]	0	RRset [60]	0,09	RRset [60]	2,04	RRset [60]	0	RRset [60]	0	RRset [60]	0,86	RRset [60]	4,64	RRset [60]	0	RRset [60]	9,26
RRset [120]	6,87	RRset [120]	0,21	RRset [120]	0,93	RRset [120]	4,63	RRset [120]	0	RRset [120]	3,7	RRset [120]	2,94	RRset [120]	8,16	RRset [120]	0
RRmeas [60]	0,37	RRmeas [60]	0,45	RRmeas [60]	1,68	RRmeas [60]	0	RRmeas [60]	3,47	RRmeas [60]	3,95	RRmeas [60]	0,02	RRmeas [60]	0	RRmeas [60]	0,5
RRmeas [120]	0	RRmeas [120]	0,25	RRmeas [120]	1,4	RRmeas [120]	0	RRmeas [120]	5,19	RRmeas [120]	1,4	RRmeas [120]	0,9	RRmeas [120]	0	RRmeas [120]	1,57
VTset [0]	0	VTset [0]	0,43	VTset [0]	12,95	VTset [0]	0	VTset [0]	0	VTset [0]	19,15	VTset [0]	0,78	VTset [0]	0	VTset [0]	7,56
VTset [30]	0	VTset [30]	0,22	VTset [30]	2,87	VTset [30]	0	VTset [30]	17,96	VTset [30]	0	VTset [30]	10,11	VTset [30]	0	VTset [30]	0
VTset [60]	0	VTset [60]	0,19	VTset [60]	0,94	VTset [60]	0,51	VTset [60]	8,44	VTset [60]	2,75	VTset [60]	0	VTset [60]	0	VTset [60]	0
VTset [120]	0,37	VTset [120]	0,1	VTset [120]	1,63	VTset [120]	7,31	VTset [120]	0	VTset [120]	5,73	VTset [120]	0	VTset [120]	0	VTset [120]	11,27
VTmeas [60]	0	VTmeas [60]	0,17	VTmeas [60]	1,48	VTmeas [60]	0	VTmeas [60]	0	VTmeas [60]	0,78	VTmeas [60]	0	VTmeas [60]	0	VTmeas [60]	0,07
VTmeas [120]	0	VTmeas [120]	0,05	VTmeas [120]	1,46	VTmeas [120]	0	VTmeas [120]	0	VTmeas [120]	0,89	VTmeas [120]	0,72	VTmeas [120]	0,21	VTmeas [120]	0
VentMode [0]	0	VentMode [0]	0,06	VentMode [0]	1,08	VentMode [0]	0,7	VentMode [0]	4,73	VentMode [0]	1,43	VentMode [0]	0	VentMode [0]	0	VentMode [0]	0
PEEPset [30]	0	PEEPset [30]	0,09	PEEPset [30]	4,12	PEEPset [30]	1,58	PEEPset [30]	0	PEEPset [30]	0	PEEPset [30]	0	PEEPset [30]	0,06	PEEPset [30]	0
PEEPset [60]	0	PEEPset [60]	0,35	PEEPset [60]	1,36	PEEPset [60]	0	PEEPset [60]	0	PEEPset [60]	1,12	PEEPset [60]	0	PEEPset [60]	0	PEEPset [60]	0
PEEPset [120]	0	PEEPset [120]	0,16	PEEPset [120]	0,8	PEEPset [120]	0	PEEPset [120]	0,1	PEEPset [120]	0,84	PEEPset [120]	0	PEEPset [120]	0	PEEPset [120]	0,63
PEEPset [240]	0	PEEPset [240]	0,11	PEEPset [240]	0,6	PEEPset [240]	0	PEEPset [240]	0	PEEPset [240]	0,14	PEEPset [240]	0	PEEPset [240]	0	PEEPset [240]	0
PEEPset [480]	0	PEEPset [480]	0,18	PEEPset [480]	1,75	PEEPset [480]	0	PEEPset [480]	1,02	PEEPset [480]	2,62	PEEPset [480]	0,77	PEEPset [480]	0	PEEPset [480]	0
Ppeakinsp [60]	0,37	Ppeakinsp [60]	0,24	Ppeakinsp [60]	9,93	Ppeakinsp [60]	0	Ppeakinsp [60]	0	Ppeakinsp [60]	0,84	Ppeakinsp [60]	0	Ppeakinsp [60]	0,86	Ppeakinsp [60]	6,79
Ppeakinsp [120]	0	Ppeakinsp [120]	0,16	Ppeakinsp [120]	0,8	Ppeakinsp [120]	6,51	Ppeakinsp [120]	0	Ppeakinsp [120]	0	Ppeakinsp [120]	0,09	Ppeakinsp [120]	0	Ppeakinsp [120]	0,51
FiO ₂ [0]	16,52	FiO ₂ [0]	5,41	FiO ₂ [0]	1,72	FiO ₂ [0]	8,91	FiO ₂ [0]	11,82	FiO ₂ [0]	2,34	FiO ₂ [0]	0	FiO ₂ [0]	1,26	FiO ₂ [0]	0
FiO ₂ [30]	0	FiO ₂ [30]	0,06	FiO ₂ [30]	4,64	FiO ₂ [30]	17,69	FiO ₂ [30]	13,44	FiO ₂ [30]	4,9	FiO ₂ [30]	0	FiO ₂ [30]	0	FiO ₂ [30]	0
FiO ₂ [60]	0	FiO ₂ [60]	0,33	FiO ₂ [60]	0,85	FiO ₂ [60]	0	FiO ₂ [60]	0	FiO ₂ [60]	1,64	FiO ₂ [60]	0	FiO ₂ [60]	17,97	FiO ₂ [60]	0
FiO ₂ [120]	8,64	FiO ₂ [120]	0	FiO ₂ [120]	1,99	FiO ₂ [120]	1,72	FiO ₂ [120]	0	FiO ₂ [120]	3,56	FiO ₂ [120]	46,16	FiO ₂ [120]	36,37	FiO ₂ [120]	0
FiO ₂ [240]	1,23	FiO ₂ [240]	0,26	FiO ₂ [240]	1,33	FiO ₂ [240]	1,05	FiO ₂ [240]	0	FiO ₂ [240]	2,04	FiO ₂ [240]	0	FiO ₂ [240]	21,61	FiO ₂ [240]	0
FiO ₂ [480]	2,32	FiO ₂ [480]	0,1	FiO ₂ [480]	0,07	FiO ₂ [480]	2,73	FiO ₂ [480]	3,13	FiO ₂ [480]	3,95	FiO ₂ [480]	0	FiO ₂ [480]	0	FiO ₂ [480]	0
SpO ₂ [60]	3,08	SpO ₂ [60]	0,4	SpO ₂ [60]	1,77	SpO ₂ [60]	3,83	SpO ₂ [60]	5,05	SpO ₂ [60]	0	SpO ₂ [60]	0	SpO ₂ [60]	0,01	SpO ₂ [60]	0,01
SpO ₂ [120]	0	SpO ₂ [120]	0,14	SpO ₂ [120]	1,65	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0	SpO ₂ [120]	0
HR [120]	0	HR [120]	0	HR [120]	1,4	HR [120]	0	HR [120]	0	HR [120]	1,15	HR [120]	0	HR [120]	0	HR [120]	0,01
HR [480]	0	HR [480]	0,35	HR [480]	1,19	HR [480]	0	HR [480]	0	HR [480]	1,07	HR [480]	0	HR [480]	0	HR [480]	0
MAP [120]	0	MAP [120]	0,08	MAP [120]	1,59	MAP [120]	0	MAP [120]	0,09	MAP [120]	0,78	MAP [120]	0,26	MAP [120]	0	MAP [120]	0,04
MAP [480]	0	MAP [480]	0,1	MAP [480]	2,07	MAP [480]	0	MAP [480]	0,47	MAP [480]	1,16	MAP [480]	0	MAP [480]	0,17	MAP [480]	0,08
NE [0]	0	NE [0]	0,08	NE [0]	1,75	NE [0]	0	NE [0]	0	NE [0]	0,93	NE [0]	13,54	NE [0]	3,73	NE [0]	0

Tabla 5.40. PI de las variables predictoras para cada variable objetivo en la configuración "60 Minutes Blinded". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.

En la configuración “60 Minutes Blinded” (Tabla 5.40), se observa que las celdas con valores más altos recaen sobre mediciones a 60 minutos o más. Al igual que en las

configuraciones anteriores, las variables demográficas mantienen porcentajes residuales, mientras que FiO₂ y parámetros de ventilación vuelven a destacar en varios modelos.

Valores de Shapley con configuración "All Data"																	
FNN						FNN multitarea						RF					
PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs	
Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje
Age	1,32	Age	1,3	Age	1,3	Age	1,29	Age	1,42	Age	1,4	Age	1,21	Age	1,29	Age	0,88
Gender	1,32	Gender	1,3	Gender	1,3	Gender	1,28	Gender	1,42	Gender	1,4	Gender	0,25	Gender	0,47	Gender	1,28
Height	1,32	Height	1,3	Height	1,33	Height	1,28	Height	1,42	Height	1,4	Height	0,35	Height	0,36	Height	0,09
Weight	1,32	Weight	1,31	Weight	1,32	Weight	1,33	Weight	1,43	Weight	1,4	Weight	1,27	Weight	1,75	Weight	0,98
PaO ₂ [30]	4,08	PaO ₂ [0]	1,49	PaO ₂ [0]	1,62	PaO ₂ [30]	3,1	PaO ₂ [0]	0	PaO ₂ [0]	0	PaO ₂ [30]	12,27	PaO ₂ [0]	11,65	PaO ₂ [0]	13,75
PaO ₂ [60]	1,32	PaO ₂ [30]	1,3	PaO ₂ [30]	1,3	PaO ₂ [60]	1,28	PaO ₂ [30]	1,46	PaO ₂ [30]	1,44	PaO ₂ [60]	5,63	PaO ₂ [30]	1,19	PaO ₂ [30]	0,79
PaO ₂ [120]	1,32	PaO ₂ [60]	1,29	PaO ₂ [60]	1,28	PaO ₂ [120]	1,28	PaO ₂ [60]	1,42	PaO ₂ [60]	1,4	PaO ₂ [120]	3,51	PaO ₂ [60]	1,18	PaO ₂ [60]	0,7
PaO ₂ [240]	1,41	PaO ₂ [120]	1,31	PaO ₂ [120]	1,29	PaO ₂ [240]	1,34	PaO ₂ [120]	1,41	PaO ₂ [120]	1,4	PaO ₂ [240]	3,29	PaO ₂ [120]	0,94	PaO ₂ [120]	0,79
PaO ₂ [480]	1,42	PaO ₂ [240]	1,3	PaO ₂ [240]	1,31	PaO ₂ [480]	1,58	PaO ₂ [240]	1,41	PaO ₂ [240]	1,39	PaO ₂ [480]	2,07	PaO ₂ [240]	0,84	PaO ₂ [240]	0,67
PaCO ₂ [0]	1,39	PaO ₂ [480]	1,3	PaO ₂ [480]	1,27	PaCO ₂ [0]	0	PaO ₂ [480]	1,44	PaO ₂ [480]	1,43	PaCO ₂ [0]	6,48	PaO ₂ [480]	0,74	PaO ₂ [480]	0,67
PaCO ₂ [30]	1,32	PaCO ₂ [30]	5,6	PaCO ₂ [0]	2,35	PaCO ₂ [30]	1,37	PaCO ₂ [30]	1,91	PaCO ₂ [0]	0	PaCO ₂ [30]	1,09	PaCO ₂ [30]	16,05	PaCO ₂ [0]	8,52
PaCO ₂ [60]	1,32	PaCO ₂ [60]	2,32	PaCO ₂ [30]	1,48	PaCO ₂ [60]	1,29	PaCO ₂ [60]	1,46	PaCO ₂ [30]	1,41	PaCO ₂ [60]	0,91	PaCO ₂ [60]	7,56	PaCO ₂ [30]	0,81
PaCO ₂ [120]	1,32	PaCO ₂ [120]	1,31	PaCO ₂ [60]	1,3	PaCO ₂ [120]	1,28	PaCO ₂ [120]	1,42	PaCO ₂ [60]	1,4	PaCO ₂ [120]	0,7	PaCO ₂ [120]	2,8	PaCO ₂ [60]	0,8
PaCO ₂ [240]	1,32	PaCO ₂ [240]	1,53	PaCO ₂ [120]	1,29	PaCO ₂ [240]	1,34	PaCO ₂ [240]	1,49	PaCO ₂ [120]	1,4	PaCO ₂ [240]	0,67	PaCO ₂ [240]	3,03	PaCO ₂ [120]	0,64
PaCO ₂ [480]	1,32	PaCO ₂ [480]	2,07	PaCO ₂ [240]	1,31	PaCO ₂ [480]	1,51	PaCO ₂ [480]	1,67	PaCO ₂ [240]	1,4	PaCO ₂ [480]	0,59	PaCO ₂ [480]	4,61	PaCO ₂ [240]	0,66
Crs [0]	1,36	Crs [0]	1,55	PaCO ₂ [480]	1,28	Crs [0]	0	Crs [0]	0	PaCO ₂ [480]	1,41	Crs [0]	7,16	Crs [0]	7,2	PaCO ₂ [480]	0,65
Crs [30]	1,33	Crs [30]	1,31	Crs [30]	2,54	Crs [30]	1,28	Crs [30]	1,42	Crs [30]	1,4	Crs [30]	0,68	Crs [30]	0,82	Crs [30]	8,29
Crs [60]	1,32	Crs [60]	1,3	Crs [60]	1,27	Crs [60]	1,28	Crs [60]	1,42	Crs [60]	1,4	Crs [60]	0,74	Crs [60]	0,89	Crs [60]	7,67
Crs [120]	1,32	Crs [120]	1,32	Crs [120]	1,47	Crs [120]	1,57	Crs [120]	1,43	Crs [120]	2,5	Crs [120]	0,56	Crs [120]	0,69	Crs [120]	4,29
Crs [240]	1,32	Crs [240]	1,31	Crs [240]	1,54	Crs [240]	1,28	Crs [240]	1,41	Crs [240]	1,4	Crs [240]	0,49	Crs [240]	0,6	Crs [240]	3,6
Crs [480]	1,32	Crs [480]	1,31	Crs [480]	1,73	Crs [480]	1,36	Crs [480]	1,43	Crs [480]	1,47	Crs [480]	0,42	Crs [480]	0,52	Crs [480]	6,22
RRset [0]	1,32	RRset [0]	1,31	RRset [0]	1,26	RRset [0]	2,39	RRset [0]	1,8	RRset [0]	1,88	RRset [0]	1,37	RRset [0]	0,81	RRset [0]	2,94
RRset [30]	1,66	RRset [30]	1,3	RRset [30]	1,25	RRset [30]	2,07	RRset [30]	1,68	RRset [30]	1,79	RRset [30]	0,6	RRset [30]	0,81	RRset [30]	1,03
RRset [60]	1,32	RRset [60]	1,3	RRset [60]	1,26	RRset [60]	1,28	RRset [60]	1,42	RRset [60]	1,4	RRset [60]	0,91	RRset [60]	0,64	RRset [60]	0,71
RRset [120]	1,61	RRset [120]	1,3	RRset [120]	1,31	RRset [120]	2,03	RRset [120]	1,51	RRset [120]	1,48	RRset [120]	0,84	RRset [120]	0,43	RRset [120]	0,68
RRmeas [30]	1,41	RRmeas [30]	1,38	RRmeas [30]	1,28	RRmeas [30]	1,31	RRmeas [30]	1,42	RRmeas [30]	1,39	RRmeas [30]	1,38	RRmeas [30]	1,27	RRmeas [30]	0,76

RRmeas [60]	1,32	RRmeas [60]	1,3	RRmeas [60]	1,36	RRmeas [60]	1,56	RRmeas [60]	1,47	RRmeas [60]	1,43	RRmeas [60]	0,89	RRmeas [60]	1,19	RRmeas [60]	0,67
RRmeas [120]	1,32	RRmeas [120]	1,3	RRmeas [120]	1,29	RRmeas [120]	1,51	RRmeas [120]	1,44	RRmeas [120]	1,42	RRmeas [120]	0,85	RRmeas [120]	0,95	RRmeas [120]	0,7
VTset [0]	1,32	VTset [0]	1,33	VTset [0]	3,01	VTset [0]	1,89	VTset [0]	1,51	VTset [0]	1,8	VTset [0]	0,61	VTset [0]	0,95	VTset [0]	4,08
VTset [30]	1,32	VTset [30]	1,31	VTset [30]	1,41	VTset [30]	1,62	VTset [30]	1,48	VTset [30]	1,55	VTset [30]	0,33	VTset [30]	0,63	VTset [30]	1,12
VTset [60]	1,32	VTset [60]	1,3	VTset [60]	1,28	VTset [60]	1,49	VTset [60]	1,42	VTset [60]	1,4	VTset [60]	0,55	VTset [60]	0,9	VTset [60]	0,76
VTset [120]	1,37	VTset [120]	1,3	VTset [120]	1,31	VTset [120]	1,58	VTset [120]	1,44	VTset [120]	1,41	VTset [120]	0,47	VTset [120]	0,47	VTset [120]	0,48
VTmeas [30]	1,32	VTmeas [30]	1,36	VTmeas [30]	1,29	VTmeas [30]	1,33	VTmeas [30]	1,42	VTmeas [30]	1,42	VTmeas [30]	0,88	VTmeas [30]	1,44	VTmeas [30]	0,91
VTmeas [60]	1,32	VTmeas [60]	1,3	VTmeas [60]	1,27	VTmeas [60]	1,28	VTmeas [60]	1,41	VTmeas [60]	1,4	VTmeas [60]	1,22	VTmeas [60]	1,09	VTmeas [60]	0,9
VTmeas [120]	1,31	VTmeas [120]	1,3	VTmeas [120]	1,29	VTmeas [120]	1,28	VTmeas [120]	1,41	VTmeas [120]	1,4	VTmeas [120]	1,09	VTmeas [120]	0,89	VTmeas [120]	0,94
VentMode [0]	1,32	VentMode [0]	1,32	VentMode [0]	1,3	VentMode [0]	1,31	VentMode [0]	1,42	VentMode [0]	1,4	VentMode [0]	0,64	VentMode [0]	0,48	VentMode [0]	0,46
PEEPset [30]	1,32	PEEPset [30]	1,31	PEEPset [30]	1,3	PEEPset [30]	1,55	PEEPset [30]	1,44	PEEPset [30]	1,46	PEEPset [30]	0,25	PEEPset [30]	0,23	PEEPset [30]	0,41
PEEPset [60]	1,32	PEEPset [60]	1,3	PEEPset [60]	2,16	PEEPset [60]	1,28	PEEPset [60]	1,42	PEEPset [60]	1,4	PEEPset [60]	0,21	PEEPset [60]	0,2	PEEPset [60]	0,35
PEEPset [120]	1,32	PEEPset [120]	1,32	PEEPset [120]	1,31	PEEPset [120]	1,38	PEEPset [120]	1,43	PEEPset [120]	1,43	PEEPset [120]	0,21	PEEPset [120]	0,19	PEEPset [120]	0,3
PEEPset [240]	1,37	PEEPset [240]	1,3	PEEPset [240]	1,27	PEEPset [240]	1,28	PEEPset [240]	1,41	PEEPset [240]	1,4	PEEPset [240]	0,21	PEEPset [240]	0,21	PEEPset [240]	0,24
PEEPset [480]	1,38	PEEPset [480]	1,29	PEEPset [480]	1,28	PEEPset [480]	1,45	PEEPset [480]	1,42	PEEPset [480]	1,42	PEEPset [480]	0,21	PEEPset [480]	0,23	PEEPset [480]	0,27
Ppeakinsp [30]	1,36	Ppeakinsp [30]	1,3	Ppeakinsp [30]	1,29	Ppeakinsp [30]	1,28	Ppeakinsp [30]	1,42	Ppeakinsp [30]	1,4	Ppeakinsp [30]	0,6	Ppeakinsp [30]	0,69	Ppeakinsp [30]	1,12
Ppeakinsp [60]	1,32	Ppeakinsp [60]	1,3	Ppeakinsp [60]	2,86	Ppeakinsp [60]	1,28	Ppeakinsp [60]	1,42	Ppeakinsp [60]	1,4	Ppeakinsp [60]	0,73	Ppeakinsp [60]	0,64	Ppeakinsp [60]	1,38
Ppeakinsp [120]	1,32	Ppeakinsp [120]	1,31	Ppeakinsp [120]	1,3	Ppeakinsp [120]	1,68	Ppeakinsp [120]	1,44	Ppeakinsp [120]	1,75	Ppeakinsp [120]	0,76	Ppeakinsp [120]	0,64	Ppeakinsp [120]	0,96
FiO ₂ [0]	2,21	FiO ₂ [0]	1,63	FiO ₂ [0]	1,29	FiO ₂ [0]	1,69	FiO ₂ [0]	1,45	FiO ₂ [0]	1,41	FiO ₂ [0]	3,73	FiO ₂ [0]	1,03	FiO ₂ [0]	1,99
FiO ₂ [30]	1,32	FiO ₂ [30]	1,31	FiO ₂ [30]	1,29	FiO ₂ [30]	1,95	FiO ₂ [30]	1,47	FiO ₂ [30]	1,45	FiO ₂ [30]	3,11	FiO ₂ [30]	0,81	FiO ₂ [30]	0,96
FiO ₂ [60]	1,32	FiO ₂ [60]	1,3	FiO ₂ [60]	1,27	FiO ₂ [60]	1,29	FiO ₂ [60]	1,42	FiO ₂ [60]	1,4	FiO ₂ [60]	1,84	FiO ₂ [60]	0,63	FiO ₂ [60]	0,64
FiO ₂ [120]	1,56	FiO ₂ [120]	1,29	FiO ₂ [120]	1,85	FiO ₂ [120]	1,37	FiO ₂ [120]	1,42	FiO ₂ [120]	1,4	FiO ₂ [120]	1,1	FiO ₂ [120]	0,56	FiO ₂ [120]	0,71
FiO ₂ [240]	1,44	FiO ₂ [240]	1,3	FiO ₂ [240]	1,23	FiO ₂ [240]	1,31	FiO ₂ [240]	1,42	FiO ₂ [240]	1,4	FiO ₂ [240]	0,84	FiO ₂ [240]	0,74	FiO ₂ [240]	0,51
FiO ₂ [480]	1,49	FiO ₂ [480]	1,29	FiO ₂ [480]	1,26	FiO ₂ [480]	1,41	FiO ₂ [480]	1,42	FiO ₂ [480]	1,4	FiO ₂ [480]	0,71	FiO ₂ [480]	0,7	FiO ₂ [480]	0,55
SpO ₂ [30]	1,7	SpO ₂ [30]	1,32	SpO ₂ [30]	1,28	SpO ₂ [30]	1,96	SpO ₂ [30]	1,49	SpO ₂ [30]	1,44	SpO ₂ [30]	7,04	SpO ₂ [30]	0,99	SpO ₂ [30]	0,46
SpO ₂ [60]	1,32	SpO ₂ [60]	1,31	SpO ₂ [60]	1,32	SpO ₂ [60]	1,39	SpO ₂ [60]	1,43	SpO ₂ [60]	1,42	SpO ₂ [60]	2,52	SpO ₂ [60]	0,81	SpO ₂ [60]	0,44
SpO ₂ [120]	1,32	SpO ₂ [120]	1,29	SpO ₂ [120]	1,29	SpO ₂ [120]	1,49	SpO ₂ [120]	1,44	SpO ₂ [120]	1,42	SpO ₂ [120]	1,61	SpO ₂ [120]	0,64	SpO ₂ [120]	0,45
HR [30]	1,32	HR [30]	1,3	HR [30]	1,27	HR [30]	1,39	HR [30]	1,42	HR [30]	1,4	HR [30]	1,54	HR [30]	0,95	HR [30]	0,74
HR [120]	1,32	HR [120]	1,29	HR [120]	1,31	HR [120]	1,28	HR [120]	1,41	HR [120]	1,4	HR [120]	0,97	HR [120]	0,74	HR [120]	0,63
HR [480]	1,32	HR [480]	1,31	HR [480]	1,29	HR [480]	1,31	HR [480]	1,42	HR [480]	1,41	HR [480]	0,76	HR [480]	0,71	HR [480]	0,63
MAP [30]	1,32	MAP [30]	1,31	MAP [30]	1,31	MAP [30]	1,3	MAP [30]	1,42	MAP [30]	1,4	MAP [30]	0,82	MAP [30]	0,85	MAP [30]	0,65
MAP [120]	1,32	MAP [120]	1,3	MAP [120]	1,3	MAP [120]	1,28	MAP [120]	1,41	MAP [120]	1,4	MAP [120]	0,68	MAP [120]	0,74	MAP [120]	0,59
MAP [480]	1,33	MAP [480]	1,31	MAP [480]	1,28	MAP [480]	1,3	MAP [480]	1,42	MAP [480]	1,4	MAP [480]	0,6	MAP [480]	0,6	MAP [480]	0,56
NE [0]	1,32	NE [0]	1,29	NE [0]	1,28	NE [0]	1,28	NE [0]	1,42	NE [0]	1,4	NE [0]	0,12	NE [0]	0,12	NE [0]	0

Albumin [30]	1,77	Albumin [30]	1,29	Albumin [30]	1,24	Albumin [30]	1,38	Albumin [30]	1,42	Albumin [30]	1,4	Albumin [30]	0,89	Albumin [30]	0,63	Albumin [30]	0,57
Bilirubin_d [30]	1,32	Bilirubin_d [30]	1,3	Bilirubin_d [30]	1,28	Bilirubin_d [30]	1,28	Bilirubin_d [30]	1,42	Bilirubin_d [30]	1,4	Bilirubin_d [30]	0,1	Bilirubin_d [30]	0,11	Bilirubin_d [30]	0,15
Bilirubin_i [30]	1,32	Bilirubin_i [30]	1,3	Bilirubin_i [30]	1,31	Bilirubin_i [30]	1,28	Bilirubin_i [30]	1,41	Bilirubin_i [30]	1,4	Bilirubin_i [30]	0,11	Bilirubin_i [30]	0,08	Bilirubin_i [30]	0,14
Creatinine [30]	1,32	Creatinine [30]	1,35	Creatinine [30]	1,31	Creatinine [30]	1,28	Creatinine [30]	1,41	Creatinine [30]	1,4	Creatinine [30]	0,72	Creatinine [30]	0,87	Creatinine [30]	0,61
Lactate [30]	1,33	Lactate [30]	1,32	Lactate [30]	1,25	Lactate [30]	1,31	Lactate [30]	1,42	Lactate [30]	1,4	Lactate [30]	0,78	Lactate [30]	1,03	Lactate [30]	0,61
Temperatura [30]	1,32	Temperatura [30]	1,3	Temperatura [30]	1,27	Temperatura [30]	1,43	Temperatura [30]	1,42	Temperatura [30]	1,41	Temperatura [30]	0,54	Temperatura [30]	0,4	Temperatura [30]	0,44
Platelets [30]	1,31	Platelets [30]	1,3	Platelets [30]	1,28	Platelets [30]	1,29	Platelets [30]	1,42	Platelets [30]	1,4	Platelets [30]	0,03	Platelets [30]	0,03	Platelets [30]	0,04
Leukocytes [30]	1,32	Leukocytes [30]	1,29	Leukocytes [30]	1,24	Leukocytes [30]	1,28	Leukocytes [30]	1,42	Leukocytes [30]	1,39	Leukocytes [30]	0,33	Leukocytes [30]	0,4	Leukocytes [30]	0,28
HB gasometry [30]	1,32	HB gasometry [30]	1,3	HB gasometry [30]	1,3	HB gasometry [30]	1,28	HB gasometry [30]	1,42	HB gasometry [30]	1,39	HB gasometry [30]	0,73	HB gasometry [30]	0,6	HB gasometry [30]	0,54
pH [30]	1,32	pH [30]	1,56	pH [30]	1,29	pH [30]	1,38	pH [30]	1,44	pH [30]	1,4	pH [30]	0,95	pH [30]	2,51	pH [30]	0,62
INR [30]	1,36	INR [30]	1,3	INR [30]	1,31	INR [30]	1,34	INR [30]	1,42	INR [30]	1,4	INR [30]	0,67	INR [30]	0,63	INR [30]	0,57

Tabla 5.41. Valores de Shapley de las variables predictoras para cada variable objetivo en la configuración "All Data". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.

En la Tabla 5.41 se presentan los porcentajes de contribución relativa en la configuración “All Data”. Visualmente, destacan valores muy elevados en las filas correspondientes a las mediciones recientes de PaO₂ y PaCO₂, especialmente en los modelos FNN y FNN multitarea. También se observan porcentajes notables en FiO₂ en distintos desfases y en parámetros ventilatorios como VTset o Ppeakinsp. Por otro lado, variables demográficas como edad, sexo o talla mantienen valores próximos a cero.

Valores de Shapley con configuración "30 Minutes Blinded"																	
FNN						FNN multitarea						RF					
PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs	
Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje
Age	1,38	Age	1,37	Age	1,33	Age	1,29	Age	1,42	Age	1,4	Age	1,35	Age	1,48	Age	1,25
Gender	1,37	Gender	1,36	Gender	1,31	Gender	1,28	Gender	1,42	Gender	1,4	Gender	0,26	Gender	0,49	Gender	0,81
Height	1,37	Height	1,36	Height	1,34	Height	1,28	Height	1,42	Height	1,4	Height	0,48	Height	0,42	Height	0,1
Weight	1,37	Weight	1,59	Weight	1,32	Weight	1,33	Weight	1,43	Weight	1,4	Weight	1,56	Weight	2,09	Weight	1,38
PaO ₂ [30]	4,04	PaO ₂ [30]	1,36	PaO ₂ [30]	1,32	PaO ₂ [30]	3,1	PaO ₂ [30]	1,46	PaO ₂ [30]	1,44	PaO ₂ [30]	10,69	PaO ₂ [30]	1,23	PaO ₂ [30]	0,97
PaO ₂ [60]	1,37	PaO ₂ [60]	1,37	PaO ₂ [60]	1,33	PaO ₂ [60]	1,28	PaO ₂ [60]	1,42	PaO ₂ [60]	1,4	PaO ₂ [60]	6,54	PaO ₂ [60]	1,24	PaO ₂ [60]	0,88
PaO ₂ [120]	1,37	PaO ₂ [120]	1,37	PaO ₂ [120]	1,33	PaO ₂ [120]	1,28	PaO ₂ [120]	1,41	PaO ₂ [120]	1,4	PaO ₂ [120]	3,38	PaO ₂ [120]	1,06	PaO ₂ [120]	0,86
PaO ₂ [240]	1,48	PaO ₂ [240]	1,37	PaO ₂ [240]	1,32	PaO ₂ [240]	1,34	PaO ₂ [240]	1,41	PaO ₂ [240]	1,39	PaO ₂ [240]	2,86	PaO ₂ [240]	0,99	PaO ₂ [240]	0,83

PaO2 [480]	1,43	PaO2 [480]	1,37	PaO2 [480]	1,32	PaO2 [480]	1,58	PaO2 [480]	1,44	PaO2 [480]	1,43	PaO2 [480]	2,45	PaO2 [480]	0,93	PaO2 [480]	0,94
PaCO ₂ [30]	1,37	PaCO ₂ [30]	4,99	PaCO ₂ [30]	1,3	PaCO ₂ [30]	1,37	PaCO ₂ [30]	1,91	PaCO ₂ [30]	1,41	PaCO ₂ [30]	0,91	PaCO ₂ [30]	15,2	PaCO ₂ [30]	0,8
PaCO ₂ [60]	1,37	PaCO ₂ [60]	2,13	PaCO ₂ [60]	1,32	PaCO ₂ [60]	1,29	PaCO ₂ [60]	1,46	PaCO ₂ [60]	1,4	PaCO ₂ [60]	0,82	PaCO ₂ [60]	6,7	PaCO ₂ [60]	0,78
PaCO ₂ [120]	1,37	PaCO ₂ [120]	1,37	PaCO ₂ [120]	1,32	PaCO ₂ [120]	1,28	PaCO ₂ [120]	1,42	PaCO ₂ [120]	1,4	PaCO ₂ [120]	0,69	PaCO ₂ [120]	3,11	PaCO ₂ [120]	0,71
PaCO ₂ [240]	1,41	PaCO ₂ [240]	1,49	PaCO ₂ [240]	1,33	PaCO ₂ [240]	1,34	PaCO ₂ [240]	1,49	PaCO ₂ [240]	1,4	PaCO ₂ [240]	0,69	PaCO ₂ [240]	3,12	PaCO ₂ [240]	0,83
PaCO ₂ [480]	1,41	PaCO ₂ [480]	1,76	PaCO ₂ [480]	1,34	PaCO ₂ [480]	1,51	PaCO ₂ [480]	1,67	PaCO ₂ [480]	1,41	PaCO ₂ [480]	0,74	PaCO ₂ [480]	3,87	PaCO ₂ [480]	0,76
Crs [30]	1,37	Crs [30]	1,37	Crs [30]	2,63	Crs [30]	1,28	Crs [30]	1,42	Crs [30]	1,4	Crs [30]	0,9	Crs [30]	1,35	Crs [30]	10,49
Crs [60]	1,37	Crs [60]	1,36	Crs [60]	1,34	Crs [60]	1,28	Crs [60]	1,42	Crs [60]	1,4	Crs [60]	0,88	Crs [60]	1,17	Crs [60]	7,85
Crs [120]	1,37	Crs [120]	1,38	Crs [120]	2,21	Crs [120]	1,57	Crs [120]	1,43	Crs [120]	2,5	Crs [120]	0,67	Crs [120]	1,11	Crs [120]	7,24
Crs [240]	1,37	Crs [240]	1,38	Crs [240]	1,75	Crs [240]	1,28	Crs [240]	1,41	Crs [240]	1,4	Crs [240]	0,61	Crs [240]	0,9	Crs [240]	4,81
Crs [480]	1,37	Crs [480]	1,37	Crs [480]	2,09	Crs [480]	1,36	Crs [480]	1,43	Crs [480]	1,47	Crs [480]	0,57	Crs [480]	0,88	Crs [480]	6,52
RRset [0]	1,42	RRset [0]	1,5	RRset [0]	1,32	RRset [0]	2,39	RRset [0]	1,8	RRset [0]	1,88	RRset [0]	4,15	RRset [0]	1,79	RRset [0]	3,76
RRset [30]	1,37	RRset [30]	1,36	RRset [30]	1,31	RRset [30]	2,07	RRset [30]	1,68	RRset [30]	1,79	RRset [30]	0,91	RRset [30]	1,25	RRset [30]	1,53
RRset [60]	1,37	RRset [60]	1,37	RRset [60]	1,32	RRset [60]	1,28	RRset [60]	1,42	RRset [60]	1,4	RRset [60]	0,94	RRset [60]	1,05	RRset [60]	0,96
RRset [120]	1,5	RRset [120]	1,37	RRset [120]	1,34	RRset [120]	2,03	RRset [120]	1,51	RRset [120]	1,48	RRset [120]	1,02	RRset [120]	0,86	RRset [120]	0,85
RRmeas [30]	1,43	RRmeas [30]	1,37	RRmeas [30]	1,46	RRmeas [30]	1,31	RRmeas [30]	1,42	RRmeas [30]	1,39	RRmeas [30]	1,59	RRmeas [30]	1,99	RRmeas [30]	1,41
RRmeas [60]	1,37	RRmeas [60]	1,36	RRmeas [60]	1,32	RRmeas [60]	1,56	RRmeas [60]	1,47	RRmeas [60]	1,43	RRmeas [60]	0,93	RRmeas [60]	1,67	RRmeas [60]	1,11
RRmeas [120]	1,37	RRmeas [120]	1,36	RRmeas [120]	1,31	RRmeas [120]	1,51	RRmeas [120]	1,44	RRmeas [120]	1,42	RRmeas [120]	0,85	RRmeas [120]	1,28	RRmeas [120]	0,99
VTset [0]	1,37	VTset [0]	1,36	VTset [0]	2,5	VTset [0]	1,89	VTset [0]	1,51	VTset [0]	1,8	VTset [0]	2,25	VTset [0]	1,72	VTset [0]	4,61
VTset [30]	1,37	VTset [30]	1,37	VTset [30]	1,65	VTset [30]	1,62	VTset [30]	1,48	VTset [30]	1,55	VTset [30]	0,4	VTset [30]	0,77	VTset [30]	1,76
VTset [60]	1,37	VTset [60]	1,36	VTset [60]	1,32	VTset [60]	1,49	VTset [60]	1,42	VTset [60]	1,4	VTset [60]	0,41	VTset [60]	0,81	VTset [60]	0,92
VTset [120]	1,4	VTset [120]	1,35	VTset [120]	1,31	VTset [120]	1,58	VTset [120]	1,44	VTset [120]	1,41	VTset [120]	0,6	VTset [120]	0,68	VTset [120]	0,67
VTmeas [30]	1,37	VTmeas [30]	1,41	VTmeas [30]	1,32	VTmeas [30]	1,33	VTmeas [30]	1,42	VTmeas [30]	1,42	VTmeas [30]	1,09	VTmeas [30]	1,98	VTmeas [30]	1,12
VTmeas [60]	1,37	VTmeas [60]	1,37	VTmeas [60]	1,32	VTmeas [60]	1,28	VTmeas [60]	1,41	VTmeas [60]	1,4	VTmeas [60]	1,29	VTmeas [60]	1,46	VTmeas [60]	1,01
VTmeas [120]	1,37	VTmeas [120]	1,36	VTmeas [120]	1,31	VTmeas [120]	1,28	VTmeas [120]	1,41	VTmeas [120]	1,4	VTmeas [120]	1,6	VTmeas [120]	1,44	VTmeas [120]	1,14
VentMode [0]	1,37	VentMode [0]	1,37	VentMode [0]	1,32	VentMode [0]	1,31	VentMode [0]	1,42	VentMode [0]	1,4	VentMode [0]	0,83	VentMode [0]	0,75	VentMode [0]	0,52
PEEPset [30]	1,37	PEEPset [30]	1,35	PEEPset [30]	2,22	PEEPset [30]	1,55	PEEPset [30]	1,44	PEEPset [30]	1,46	PEEPset [30]	0,46	PEEPset [30]	0,52	PEEPset [30]	1,01
PEEPset [60]	1,37	PEEPset [60]	1,37	PEEPset [60]	1,33	PEEPset [60]	1,28	PEEPset [60]	1,42	PEEPset [60]	1,4	PEEPset [60]	0,34	PEEPset [60]	0,4	PEEPset [60]	0,71
PEEPset [120]	1,38	PEEPset [120]	1,36	PEEPset [120]	1,32	PEEPset [120]	1,38	PEEPset [120]	1,43	PEEPset [120]	1,43	PEEPset [120]	0,26	PEEPset [120]	0,35	PEEPset [120]	0,55
PEEPset [240]	1,42	PEEPset [240]	1,36	PEEPset [240]	1,33	PEEPset [240]	1,28	PEEPset [240]	1,41	PEEPset [240]	1,4	PEEPset [240]	0,22	PEEPset [240]	0,34	PEEPset [240]	0,4
PEEPset [480]	1,45	PEEPset [480]	1,36	PEEPset [480]	1,32	PEEPset [480]	1,45	PEEPset [480]	1,42	PEEPset [480]	1,42	PEEPset [480]	0,58	PEEPset [480]	0,32	PEEPset [480]	0,36
Ppeakinsp [30]	1,37	Ppeakinsp [30]	1,37	Ppeakinsp [30]	3,46	Ppeakinsp [30]	1,28	Ppeakinsp [30]	1,42	Ppeakinsp [30]	1,4	Ppeakinsp [30]	0,89	Ppeakinsp [30]	1,31	Ppeakinsp [30]	1,97
Ppeakinsp [60]	1,39	Ppeakinsp [60]	1,37	Ppeakinsp [60]	1,32	Ppeakinsp [60]	1,28	Ppeakinsp [60]	1,42	Ppeakinsp [60]	1,4	Ppeakinsp [60]	0,93	Ppeakinsp [60]	1,12	Ppeakinsp [60]	1,9

Ppeakinsp [120]	1,37	Ppeakinsp [120]	1,37	Ppeakinsp [120]	1,32	Ppeakinsp [120]	1,68	Ppeakinsp [120]	1,44	Ppeakinsp [120]	1,75	Ppeakinsp [120]	0,92	Ppeakinsp [120]	1,22	Ppeakinsp [120]	1,51
FiO ₂ [0]	2,05	FiO ₂ [0]	1,54	FiO ₂ [0]	1,32	FiO ₂ [0]	1,69	FiO ₂ [0]	1,45	FiO ₂ [0]	1,41	FiO ₂ [0]	5,6	FiO ₂ [0]	1,64	FiO ₂ [0]	2,62
FiO ₂ [30]	1,36	FiO ₂ [30]	1,36	FiO ₂ [30]	1,33	FiO ₂ [30]	1,95	FiO ₂ [30]	1,47	FiO ₂ [30]	1,45	FiO ₂ [30]	3,99	FiO ₂ [30]	1,35	FiO ₂ [30]	1,22
FiO ₂ [60]	1,37	FiO ₂ [60]	1,37	FiO ₂ [60]	1,32	FiO ₂ [60]	1,29	FiO ₂ [60]	1,42	FiO ₂ [60]	1,4	FiO ₂ [60]	2,11	FiO ₂ [60]	1,1	FiO ₂ [60]	0,74
FiO ₂ [120]	1,75	FiO ₂ [120]	1,37	FiO ₂ [120]	1,99	FiO ₂ [120]	1,37	FiO ₂ [120]	1,42	FiO ₂ [120]	1,4	FiO ₂ [120]	1,56	FiO ₂ [120]	1,01	FiO ₂ [120]	0,74
FiO ₂ [240]	1,44	FiO ₂ [240]	1,37	FiO ₂ [240]	1,33	FiO ₂ [240]	1,31	FiO ₂ [240]	1,42	FiO ₂ [240]	1,4	FiO ₂ [240]	1,27	FiO ₂ [240]	1,16	FiO ₂ [240]	0,54
FiO ₂ [480]	1,47	FiO ₂ [480]	1,37	FiO ₂ [480]	1,34	FiO ₂ [480]	1,41	FiO ₂ [480]	1,42	FiO ₂ [480]	1,4	FiO ₂ [480]	0,83	FiO ₂ [480]	1,2	FiO ₂ [480]	0,49
SpO ₂ [30]	1,94	SpO ₂ [30]	1,48	SpO ₂ [30]	1,33	SpO ₂ [30]	1,96	SpO ₂ [30]	1,49	SpO ₂ [30]	1,44	SpO ₂ [30]	6,19	SpO ₂ [30]	1,75	SpO ₂ [30]	0,69
SpO ₂ [60]	1,37	SpO ₂ [60]	1,36	SpO ₂ [60]	1,3	SpO ₂ [60]	1,39	SpO ₂ [60]	1,43	SpO ₂ [60]	1,42	SpO ₂ [60]	3,05	SpO ₂ [60]	1,42	SpO ₂ [60]	0,67
SpO ₂ [120]	1,37	SpO ₂ [120]	1,37	SpO ₂ [120]	1,33	SpO ₂ [120]	1,49	SpO ₂ [120]	1,44	SpO ₂ [120]	1,42	SpO ₂ [120]	1,6	SpO ₂ [120]	0,84	SpO ₂ [120]	0,53
HR [30]	1,37	HR [30]	1,36	HR [30]	1,31	HR [30]	1,39	HR [30]	1,42	HR [30]	1,4	HR [30]	1,61	HR [30]	1,11	HR [30]	0,94
HR [120]	1,38	HR [120]	1,38	HR [120]	1,32	HR [120]	1,28	HR [120]	1,41	HR [120]	1,4	HR [120]	0,92	HR [120]	0,96	HR [120]	0,9
HR [480]	1,37	HR [480]	1,37	HR [480]	1,31	HR [480]	1,31	HR [480]	1,42	HR [480]	1,41	HR [480]	0,76	HR [480]	0,91	HR [480]	0,8
MAP [30]	1,37	MAP [30]	1,38	MAP [30]	1,31	MAP [30]	1,3	MAP [30]	1,42	MAP [30]	1,4	MAP [30]	1,04	MAP [30]	1,51	MAP [30]	1,19
MAP [120]	1,37	MAP [120]	1,37	MAP [120]	1,33	MAP [120]	1,28	MAP [120]	1,41	MAP [120]	1,4	MAP [120]	0,85	MAP [120]	1,25	MAP [120]	1
MAP [480]	1,37	MAP [480]	1,36	MAP [480]	1,31	MAP [480]	1,3	MAP [480]	1,42	MAP [480]	1,4	MAP [480]	0,74	MAP [480]	1,12	MAP [480]	0,94
NE [0]	1,37	NE [0]	1,35	NE [0]	1,34	NE [0]	1,28	NE [0]	1,42	NE [0]	1,4	NE [0]	0,1	NE [0]	0,13	NE [0]	0,01
Albumin [30]	1,58	Albumin [30]	1,36	Albumin [30]	1,32	Albumin [30]	1,38	Albumin [30]	1,42	Albumin [30]	1,4	Albumin [30]	1,06	Albumin [30]	0,79	Albumin [30]	0,82
Bilirubin_d [30]	1,37	Bilirubin_d [30]	1,36	Bilirubin_d [30]	1,32	Bilirubin_d [30]	1,28	Bilirubin_d [30]	1,42	Bilirubin_d [30]	1,4	Bilirubin_d [30]	0,13	Bilirubin_d [30]	0,14	Bilirubin_d [30]	0,18
Bilirubin_i [30]	1,37	Bilirubin_i [30]	1,37	Bilirubin_i [30]	1,31	Bilirubin_i [30]	1,28	Bilirubin_i [30]	1,41	Bilirubin_i [30]	1,4	Bilirubin_i [30]	0,15	Bilirubin_i [30]	0,12	Bilirubin_i [30]	0,17
Creatinine [30]	1,37	Creatinine [30]	1,39	Creatinine [30]	1,32	Creatinine [30]	1,28	Creatinine [30]	1,41	Creatinine [30]	1,4	Creatinine [30]	0,84	Creatinine [30]	1,02	Creatinine [30]	0,78
Lactate [30]	1,37	Lactate [30]	1,37	Lactate [30]	1,31	Lactate [30]	1,31	Lactate [30]	1,42	Lactate [30]	1,4	Lactate [30]	0,88	Lactate [30]	1,19	Lactate [30]	0,78
Temperatur e [30]	1,37	Temperatur e [30]	1,37	Temperatur e [30]	1,32	Temperatur e [30]	1,43	Temperatur e [30]	1,42	Temperatur e [30]	1,41	Temperatur e [30]	0,68	Temperatur e [30]	0,62	Temperatur e [30]	0,66
Platelets [30]	1,37	Platelets [30]	1,36	Platelets [30]	1,33	Platelets [30]	1,29	Platelets [30]	1,42	Platelets [30]	1,4	Platelets [30]	0,03	Platelets [30]	0,03	Platelets [30]	0,05
Leukocytes [30]	1,37	Leukocytes [30]	1,36	Leukocytes [30]	1,33	Leukocytes [30]	1,28	Leukocytes [30]	1,42	Leukocytes [30]	1,39	Leukocytes [30]	0,39	Leukocytes [30]	0,61	Leukocytes [30]	0,39
HB gasometry [30]	1,37	HB gasometry [30]	1,36	HB gasometry [30]	1,33	HB gasometry [30]	1,28	HB gasometry [30]	1,42	HB gasometry [30]	1,39	HB gasometry [30]	0,97	HB gasometry [30]	0,87	HB gasometry [30]	0,89
pH [30]	1,39	pH [30]	1,51	pH [30]	1,34	pH [30]	1,38	pH [30]	1,44	pH [30]	1,4	pH [30]	1,32	pH [30]	2,91	pH [30]	0,96
INR [30]	1,41	INR [30]	1,37	INR [30]	1,33	INR [30]	1,34	INR [30]	1,42	INR [30]	1,4	INR [30]	0,8	INR [30]	0,8	INR [30]	0,71

Tabla 5.42. Valores de Shapley de las variables predictoras para cada variable objetivo en la configuración "30 Minutes Blinded". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.

La Tabla 5.42, asociada a la configuración “30 Minutes Blinded”, mantiene una distribución semejante, pero con un mayor protagonismo de las mediciones disponibles

en ventanas temporales más amplias. En varios modelos se aprecia un incremento de los porcentajes en variables de ventilación (PEEP, VT, presiones inspiratorias), que aparecen con celdas coloreadas más intensamente. Nuevamente, las variables demográficas se mantienen en valores bajos.

Valores de Shapley con configuración "60 Minutes Blinded"																	
FNN						FNN multitarea						RF					
PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs		PaO ₂		PaCO ₂		Crs	
Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje	Predictor	Porcentaje
Age	1,86	Age	1,81	Age	1,83	Age	1,68	Age	1,96	Age	1,92	Age	1,87	Age	2,24	Age	1,89
Gender	1,85	Gender	1,81	Gender	1,81	Gender	1,65	Gender	1,95	Gender	1,92	Gender	0,43	Gender	0,87	Gender	0,99
Height	1,86	Height	1,83	Height	1,79	Height	1,66	Height	1,96	Height	1,93	Height	0,65	Height	0,52	Height	0,14
Weight	1,85	Weight	2,01	Weight	1,81	Weight	1,73	Weight	1,96	Weight	1,93	Weight	2,04	Weight	2,74	Weight	1,91
PaO ₂ [60]	5,72	PaO ₂ [60]	1,81	PaO ₂ [60]	1,8	PaO ₂ [60]	4,3	PaO ₂ [60]	2,05	PaO ₂ [60]	2	PaO ₂ [60]	15,1	PaO ₂ [60]	1,87	PaO ₂ [60]	1,39
PaO ₂ [120]	1,85	PaO ₂ [120]	1,79	PaO ₂ [120]	1,79	PaO ₂ [120]	1,65	PaO ₂ [120]	1,96	PaO ₂ [120]	1,92	PaO ₂ [120]	4,95	PaO ₂ [120]	1,59	PaO ₂ [120]	1,26
PaO ₂ [240]	1,93	PaO ₂ [240]	1,81	PaO ₂ [240]	1,8	PaO ₂ [240]	1,71	PaO ₂ [240]	1,96	PaO ₂ [240]	1,93	PaO ₂ [240]	4,55	PaO ₂ [240]	1,31	PaO ₂ [240]	1,29
PaO ₂ [480]	1,88	PaO ₂ [480]	1,81	PaO ₂ [480]	1,81	PaO ₂ [480]	2,09	PaO ₂ [480]	1,99	PaO ₂ [480]	1,96	PaO ₂ [480]	2,93	PaO ₂ [480]	1,33	PaO ₂ [480]	1,25
PaCO ₂ [60]	1,85	PaCO ₂ [60]	10,35	PaCO ₂ [60]	1,8	PaCO ₂ [60]	1,86	PaCO ₂ [60]	3,53	PaCO ₂ [60]	1,96	PaCO ₂ [60]	1,49	PaCO ₂ [60]	20,57	PaCO ₂ [60]	1,16
PaCO ₂ [120]	1,85	PaCO ₂ [120]	1,83	PaCO ₂ [120]	1,83	PaCO ₂ [120]	1,65	PaCO ₂ [120]	1,96	PaCO ₂ [120]	1,93	PaCO ₂ [120]	1,08	PaCO ₂ [120]	5,7	PaCO ₂ [120]	1,06
PaCO ₂ [240]	1,85	PaCO ₂ [240]	2,32	PaCO ₂ [240]	1,79	PaCO ₂ [240]	1,77	PaCO ₂ [240]	2,35	PaCO ₂ [240]	1,92	PaCO ₂ [240]	0,91	PaCO ₂ [240]	4,05	PaCO ₂ [240]	1,11
PaCO ₂ [480]	1,9	PaCO ₂ [480]	3,06	PaCO ₂ [480]	1,8	PaCO ₂ [480]	2,06	PaCO ₂ [480]	2,42	PaCO ₂ [480]	1,97	PaCO ₂ [480]	0,92	PaCO ₂ [480]	4,72	PaCO ₂ [480]	1,08
Crs [60]	1,85	Crs [60]	1,82	Crs [60]	4,29	Crs [60]	1,7	Crs [60]	1,96	Crs [60]	1,98	Crs [60]	1,18	Crs [60]	1,82	Crs [60]	13,52
Crs [120]	1,85	Crs [120]	1,81	Crs [120]	2,36	Crs [120]	2,04	Crs [120]	1,97	Crs [120]	2,94	Crs [120]	0,93	Crs [120]	1,42	Crs [120]	8,06
Crs [240]	1,85	Crs [240]	1,8	Crs [240]	1,96	Crs [240]	1,74	Crs [240]	1,96	Crs [240]	2,05	Crs [240]	0,8	Crs [240]	1,21	Crs [240]	5,43
Crs [480]	1,85	Crs [480]	1,8	Crs [480]	2,46	Crs [480]	1,65	Crs [480]	1,95	Crs [480]	1,92	Crs [480]	0,74	Crs [480]	1,21	Crs [480]	7,18
RRset [0]	1,85	RRset [0]	1,79	RRset [0]	1,8	RRset [0]	3,49	RRset [0]	2,3	RRset [0]	2,44	RRset [0]	4,9	RRset [0]	2,02	RRset [0]	4,29
RRset [30]	2,83	RRset [30]	1,94	RRset [30]	1,8	RRset [30]	3,14	RRset [30]	2,17	RRset [30]	2,31	RRset [30]	1,39	RRset [30]	1,65	RRset [30]	1,99
RRset [60]	1,86	RRset [60]	1,82	RRset [60]	1,82	RRset [60]	1,64	RRset [60]	1,96	RRset [60]	1,93	RRset [60]	1,13	RRset [60]	1,28	RRset [60]	1,26
RRset [120]	3,09	RRset [120]	1,81	RRset [120]	1,78	RRset [120]	2,67	RRset [120]	2,11	RRset [120]	2,15	RRset [120]	1,59	RRset [120]	1,11	RRset [120]	1,02
RRmeas [60]	1,91	RRmeas [60]	1,96	RRmeas [60]	1,91	RRmeas [60]	2,6	RRmeas [60]	2,03	RRmeas [60]	2,01	RRmeas [60]	2,45	RRmeas [60]	2,5	RRmeas [60]	1,79
RRmeas [120]	1,85	RRmeas [120]	1,81	RRmeas [120]	1,79	RRmeas [120]	2,31	RRmeas [120]	1,99	RRmeas [120]	1,98	RRmeas [120]	1,33	RRmeas [120]	2,07	RRmeas [120]	1,47
VTset [0]	1,86	VTset [0]	1,85	VTset [0]	4,59	VTset [0]	2,67	VTset [0]	2,07	VTset [0]	3,09	VTset [0]	2,77	VTset [0]	1,98	VTset [0]	5,27
VTset [30]	1,86	VTset [30]	1,82	VTset [30]	2,47	VTset [30]	2,37	VTset [30]	2,06	VTset [30]	2,55	VTset [30]	0,6	VTset [30]	1,23	VTset [30]	2,29
VTset [60]	1,86	VTset [60]	1,83	VTset [60]	1,78	VTset [60]	1,9	VTset [60]	1,97	VTset [60]	1,93	VTset [60]	0,51	VTset [60]	1,25	VTset [60]	1,21
VTset [120]	2,02	VTset [120]	1,81	VTset [120]	1,82	VTset [120]	2,43	VTset [120]	2,02	VTset [120]	1,96	VTset [120]	0,7	VTset [120]	0,95	VTset [120]	1,07

VTmeas [60]	1,85	VTmeas [60]	1,83	VTmeas [60]	1,81	VTmeas [60]	1,65	VTmeas [60]	1,96	VTmeas [60]	1,92	VTmeas [60]	1,69	VTmeas [60]	2,45	VTmeas [60]	1,63
VTmeas [120]	1,86	VTmeas [120]	1,8	VTmeas [120]	1,79	VTmeas [120]	1,82	VTmeas [120]	1,97	VTmeas [120]	1,98	VTmeas [120]	1,58	VTmeas [120]	1,95	VTmeas [120]	1,58
VentMode [0]	1,86	VentMode [0]	1,81	VentMode [0]	1,8	VentMode [0]	1,67	VentMode [0]	1,97	VentMode [0]	1,93	VentMode [0]	0,89	VentMode [0]	1,38	VentMode [0]	0,73
PEEPset [30]	1,85	PEEPset [30]	1,82	PEEPset [30]	2,64	PEEPset [30]	2,37	PEEPset [30]	2,02	PEEPset [30]	2,12	PEEPset [30]	0,75	PEEPset [30]	0,8	PEEPset [30]	1,37
PEEPset [60]	1,85	PEEPset [60]	1,83	PEEPset [60]	1,8	PEEPset [60]	1,65	PEEPset [60]	1,96	PEEPset [60]	1,93	PEEPset [60]	0,56	PEEPset [60]	0,63	PEEPset [60]	0,94
PEEPset [120]	1,85	PEEPset [120]	1,82	PEEPset [120]	1,79	PEEPset [120]	1,65	PEEPset [120]	1,96	PEEPset [120]	1,93	PEEPset [120]	0,38	PEEPset [120]	0,48	PEEPset [120]	0,74
PEEPset [240]	1,91	PEEPset [240]	1,81	PEEPset [240]	1,8	PEEPset [240]	1,74	PEEPset [240]	1,95	PEEPset [240]	1,93	PEEPset [240]	0,32	PEEPset [240]	0,43	PEEPset [240]	0,61
PEEPset [480]	1,98	PEEPset [480]	1,81	PEEPset [480]	1,8	PEEPset [480]	1,94	PEEPset [480]	1,97	PEEPset [480]	1,93	PEEPset [480]	0,33	PEEPset [480]	0,44	PEEPset [480]	0,49
Ppeakinsp [60]	1,9	Ppeakinsp [60]	1,83	Ppeakinsp [60]	4,4	Ppeakinsp [60]	1,65	Ppeakinsp [60]	1,96	Ppeakinsp [60]	1,93	Ppeakinsp [60]	1,32	Ppeakinsp [60]	2,02	Ppeakinsp [60]	3,47
Ppeakinsp [120]	1,85	Ppeakinsp [120]	1,82	Ppeakinsp [120]	1,8	Ppeakinsp [120]	2,39	Ppeakinsp [120]	2	Ppeakinsp [120]	2,64	Ppeakinsp [120]	1,17	Ppeakinsp [120]	1,66	Ppeakinsp [120]	2,82
FiO ₂ [0]	3,29	FiO ₂ [0]	2,12	FiO ₂ [0]	1,8	FiO ₂ [0]	2,09	FiO ₂ [0]	2	FiO ₂ [0]	1,95	FiO ₂ [0]	6,36	FiO ₂ [0]	2,15	FiO ₂ [0]	3,35
FiO ₂ [30]	1,86	FiO ₂ [30]	1,81	FiO ₂ [30]	2,69	FiO ₂ [30]	2,76	FiO ₂ [30]	2,01	FiO ₂ [30]	1,97	FiO ₂ [30]	4,97	FiO ₂ [30]	1,81	FiO ₂ [30]	1,53
FiO ₂ [60]	1,85	FiO ₂ [60]	1,83	FiO ₂ [60]	1,8	FiO ₂ [60]	1,66	FiO ₂ [60]	1,96	FiO ₂ [60]	1,92	FiO ₂ [60]	2,56	FiO ₂ [60]	1,52	FiO ₂ [60]	0,91
FiO ₂ [120]	2,43	FiO ₂ [120]	1,81	FiO ₂ [120]	1,8	FiO ₂ [120]	1,84	FiO ₂ [120]	1,97	FiO ₂ [120]	1,93	FiO ₂ [120]	1,79	FiO ₂ [120]	1,35	FiO ₂ [120]	0,85
FiO ₂ [240]	1,96	FiO ₂ [240]	1,81	FiO ₂ [240]	1,81	FiO ₂ [240]	1,73	FiO ₂ [240]	1,97	FiO ₂ [240]	1,93	FiO ₂ [240]	1,54	FiO ₂ [240]	1,23	FiO ₂ [240]	0,75
FiO ₂ [480]	2,01	FiO ₂ [480]	1,8	FiO ₂ [480]	1,8	FiO ₂ [480]	1,85	FiO ₂ [480]	1,99	FiO ₂ [480]	1,93	FiO ₂ [480]	1,09	FiO ₂ [480]	1,29	FiO ₂ [480]	0,72
SpO ₂ [60]	2,07	SpO ₂ [60]	1,85	SpO ₂ [60]	1,8	SpO ₂ [60]	2,74	SpO ₂ [60]	2,04	SpO ₂ [60]	1,98	SpO ₂ [60]	6,52	SpO ₂ [60]	1,91	SpO ₂ [60]	1,03
SpO ₂ [120]	1,85	SpO ₂ [120]	1,8	SpO ₂ [120]	1,81	SpO ₂ [120]	2,14	SpO ₂ [120]	1,98	SpO ₂ [120]	1,97	SpO ₂ [120]	2,55	SpO ₂ [120]	1,29	SpO ₂ [120]	0,78
HR [120]	1,85	HR [120]	1,81	HR [120]	1,81	HR [120]	1,73	HR [120]	1,96	HR [120]	1,93	HR [120]	2,01	HR [120]	1,42	HR [120]	1,26
HR [480]	1,85	HR [480]	1,8	HR [480]	1,8	HR [480]	1,69	HR [480]	1,96	HR [480]	1,93	HR [480]	1,15	HR [480]	1,32	HR [480]	1,2
MAP [120]	1,85	MAP [120]	1,81	MAP [120]	1,8	MAP [120]	1,67	MAP [120]	1,95	MAP [120]	1,93	MAP [120]	1,28	MAP [120]	1,64	MAP [120]	1,53
MAP [480]	1,86	MAP [480]	1,82	MAP [480]	1,78	MAP [480]	1,78	MAP [480]	1,97	MAP [480]	1,93	MAP [480]	1,07	MAP [480]	1,44	MAP [480]	1,33
NE [0]	1,85	NE [0]	1,81	NE [0]	1,8	NE [0]	1,66	NE [0]	1,96	NE [0]	1,93	NE [0]	0,18	NE [0]	0,2	NE [0]	0

Tabla 5.43. Valores de Shapley de las variables predictoras para cada variable objetivo en la configuración "60 Minutes Blinded". Se muestran los porcentajes de contribución relativa para cada modelo: FNN, FNN multitarea y RF.

En la Tabla 5.43, correspondiente a la configuración “60 Minutes Blinded”, se observa que los porcentajes más altos se concentran en los desfases a 60 minutos y superiores. Además, en el caso de Crs aparecen valores relevantes en ventanas largas, junto con contribuciones visibles de FiO₂ y otros parámetros ventilatorios. Al igual que en las configuraciones previas, las variables demográficas permanecen con porcentajes casi nulos.

En conjunto, las seis tablas muestran de manera visual cómo se distribuyen las contribuciones entre predictores. Se observan diferencias claras en función de la configuración temporal utilizada.

5.3. Evaluación de la simulación de los ajustes de la PEEP

En este apartado se muestran algunos ejemplos representativos de simulaciones realizadas para distintos pacientes en momentos específicos de su estancia en UCI.

Las gráficas ilustran la respuesta esperada de los tres parámetros objetivo (PaO_2 , PaCO_2 y Crs) frente a variaciones simuladas en el nivel de PEEP. Los valores reales registrados en ese momento se incluyen como referencia para contextualizar la precisión y utilidad clínica del modelo.

En la Figura 5.28, Figura 5.29 y Figura 5.30 se presentan los resultados obtenidos para tres identificadores de estancia en la UCI distintos. En cada uno de estos pacientes se ha seleccionado un momento específico de su evolución clínica, correspondiente a un único registro dentro de su estancia. Sobre este se ha aplicado la simulación.




Figura 5.28. Simulación de ajustes de PEEP para el paciente con identificador de estancia en la UCI 200229.




Figura 5.29. Simulación de ajustes de PEEP para el paciente con identificador de estancia en la UCI 211202.




Figura 5.30. Simulación de ajustes de PEEP para el paciente con identificador de estancia en la UCI 251077.

En el eje horizontal se representan los valores de PEEP, modificados en un rango de ± 5 cmH₂O respecto al valor aplicado en el momento del registro, que se indica mediante una línea de puntos vertical.

Las curvas de colores muestran las predicciones generadas por el modelo para cada variable: en azul para la PaO₂, en rojo para la PaCO₂ y en verde para la Crs.

Cada una de estas curvas permite observar cómo cambiaría el valor esperado de la variable si se ajustara la PEEP hacia niveles más bajos (movimiento hacia la izquierda) o más altos (movimiento hacia la derecha). Sobre el valor actual de PEEP, se colocan marcadores en forma de círculos que indican el valor real medido de cada una de las variables en ese instante. Esto permite comparar visualmente la predicción del modelo con el dato registrado en el paciente antes de aplicar la simulación.

En la Figura 5.28, la curva de PaO_2 muestra un aumento progresivo desde los valores más bajos de PEEP hasta un punto próximo a 6 cmH_2O , a partir del cual disminuye. La PaCO_2 se mantiene prácticamente constante, sin cambios apreciables. La curva de Cr_s presenta una tendencia ascendente suave a lo largo de todo el rango simulado.

En la Figura 5.29, la curva de PaO_2 se mantiene relativamente estable para valores de PEEP simulada por debajo de 5 cmH_2O , con pequeñas oscilaciones. A partir de ese punto, muestra una tendencia descendente progresiva conforme aumenta la PEEP. La curva de Cr_s permanece prácticamente constante en todo el rango simulado, sin cambios relevantes. La PaCO_2 también se mantiene estable, sin variaciones apreciables a lo largo del intervalo de PEEP representado.

En la Figura 5.30, la curva de PaO_2 presenta una forma no monótona a lo largo del rango de PEEP simulado. En los valores más bajos de PEEP (entre 0 y 1 cmH_2O), se observa un pequeño ascenso. A partir de ese punto, la PaO_2 desciende de forma progresiva hasta alcanzar un mínimo alrededor de 7 cmH_2O , y vuelve a incrementarse ligeramente en los niveles más altos del rango. La PaCO_2 permanece estable en todo el intervalo, sin cambios apreciables frente a los ajustes de PEEP. La curva de Cr_s muestra un aumento suave y continuo a lo largo de toda la simulación, sin caídas ni inflexiones evidentes.

Las figuras presentadas muestran diferentes patrones de respuesta simulada ante variaciones en la PEEP. Reflejan la heterogeneidad de comportamientos que pueden encontrarse entre pacientes y momentos clínicos concretos.

La validación estricta de estas simulaciones no es posible con la base de datos utilizada. El motivo es que MIMIC-III (A. Johnson et al., 2016) solo recoge los valores obtenidos con la PEEP realmente aplicada en cada registro. No existen datos paralelos que muestren cómo habría respondido el mismo paciente si se hubieran aplicado otros niveles de PEEP en ese instante.

Por tanto, no es posible comprobar de forma cuantitativa si las predicciones del modelo en valores alternativos de PEEP coinciden con la realidad clínica. La única comparación directa se da en el punto correspondiente a la PEEP real. En ese valor, los círculos de las figuras permiten confirmar si las estimaciones del modelo se ajustan a las medidas de PaO_2 , PaCO_2 y Crs.

Capítulo 6. Discusión.

6.1. Interpretación de la precisión de los modelos predictivos.

Los resultados obtenidos muestran diferencias claras en el rendimiento de los modelos FNN, FNN multitarea y RF al predecir las variables PaO₂, PaCO₂ y Crs en las tres configuraciones de entrada evaluadas.

Para la predicción de PaO₂, el modelo RF presenta los valores de MAE y MAPE más bajos en todas las configuraciones. Destaca especialmente en la configuración "All Data", donde alcanza un MAE de 21,04 y un MAPE de 16,70 %. Este rendimiento superior se mantiene en las configuraciones "30 Minutes Blinded" y "60 Minutes Blinded", aunque con un ligero incremento en los errores. Esto sugiere que la reducción de información en las entradas impacta negativamente en la precisión, pero de forma controlada. En contraste, los modelos FNN y FNN multitarea muestran un error más elevado y estable en torno a los 22-24 % de MAPE, sin grandes variaciones entre configuraciones.

En la predicción de PaCO₂, RF vuelve a ser el modelo más preciso. Cuenta con valores de MAE entre 2,78 y 4,01 y MAPE inferiores al 10 % en todas las configuraciones. La variabilidad del error en función de la cantidad de datos disponibles es también acusada en este caso, incrementándose el MAPE conforme se limita la ventana de entrada. Los modelos FNN y FNN multitarea, aunque presentan un rendimiento muy similar entre sí, mantienen errores sistemáticamente más altos que RF. Esto se refleja especialmente en MAPE, donde se sitúan en torno al 11 %.

En cuanto a la predicción de Crs, RF sigue obteniendo los mejores valores de MAE y MAPE. En la configuración "All Data", RF presenta un MAPE del 6,71 %, mientras que FNN y FNN multitarea alcanzan valores de 13,51 % y 15,64 % respectivamente. Sin embargo, al reducir la ventana de entrada, el error de RF en Crs aumenta de forma más notable que en el resto de variables. Alcanza un MAPE de 13,51 % en la configuración "60 Minutes Blinded", acercándose a los valores de las NN. Esto sugiere que la predicción de Crs es más sensible a la pérdida de contexto temporal, lo que afecta a todos los modelos. A pesar de esto, RF mantiene una ligera ventaja.

En conclusión, el modelo RF demuestra un rendimiento superior en la predicción de PaO₂, PaCO₂ y Crs con errores claramente inferiores a los de las NN en todas las

configuraciones. Todos los modelos se ven afectados de forma similar por la reducción de información disponible en las entradas.

Las figuras 5.1 a 5.27 muestran la dispersión de los valores predichos frente a los valores reales para las variables PaO_2 , PaCO_2 y Crs bajo distintas configuraciones de entrada y modelos predictivos. A partir de estas representaciones gráficas, se identifican patrones comunes.

En primer lugar, se observa que todos los modelos tienden a generar predicciones que se agrupan en torno a un rango más estrecho que el de los valores reales. Esta concentración de valores predichos sugiere que los modelos tienden a minimizar la varianza de sus predicciones, es decir, a generar valores que se mantienen próximos a la media. Puede interpretarse como un mecanismo de protección frente a outliers. Esto es dado que, al no alejarse demasiado de los valores centrales, el modelo reduce el riesgo de cometer errores graves ante datos extremos. Sin embargo, al hacer esto, también se reduce su capacidad para predecir correctamente aquellos casos en los que el valor real está muy por encima o por debajo de la media.

Este efecto de “compresión” de las predicciones es más acusado en las NN que en RF, lo que se alinea con los valores de MAE y MAPE presentados en la Tabla 5.1.

Este efecto se manifiesta de manera más acusada en PaO_2 , ya que sus valores reales presentan una variabilidad considerablemente mayor que la de PaCO_2 y Crs. Esta amplitud en los datos reales hace que la diferencia con las predicciones se perciba con mayor claridad, reflejando el patrón descrito anteriormente.

En el caso de PaCO_2 , la dispersión de los datos reales es notablemente menor en todas las figuras. Esto facilita a los modelos la predicción de esta variable con precisión. Aquí, la diferencia entre modelos es menos marcada, aunque RF mantiene una nube de predicciones algo más ajustada a la distribución de los valores reales.

Respecto a la variable Crs, los valores reales muestran una dispersión moderada que permite a los modelos mantener errores de predicción bajos. Al igual que en PaCO_2 , las diferencias entre modelos son menos pronunciadas, aunque RF sigue mostrando una ligera ventaja al representar de forma más fiel la distribución de los valores reales.

Otro aspecto relevante es el efecto de la reducción de la ventana temporal en las configuraciones de entrada "30 Minutes Blinded" y "60 Minutes Blinded". La nube de

puntos predichos continúa concentrándose en torno a un rango intermedio, sin grandes variaciones visuales respecto a las figuras iniciales. Esto refleja que, incluso al limitar la información disponible, los modelos tienden a mantener sus estimaciones dentro de un rango moderado.

En conclusión, estas figuras refuerzan las observaciones extraídas de las métricas de error. RF ofrece predicciones más dispersas y cercanas a los valores reales. En cambio, las NN tienden a generar predicciones más concentradas en torno a la media. Este comportamiento limita su capacidad para modelar correctamente los valores extremos.

6.2. Relevancia de las variables de entrada en la explicación de los resultados

En este apartado se examina la contribución de las variables de entrada en la predicción de las salidas.

6.2.1. Interpretación mediante PI

Se interpretan los resultados de relevancia obtenidos mediante el análisis por PI.

Hallazgos principales en la predicción de PaO₂

Las NN (FNN y FNN multitarea) dieron un peso muy elevado a la medición de PaO₂ [30] en la configuración “All Data”. Esta variable concentró el 55,72 % de la relevancia total en la FNN y el 35,72 % en la FNN multitarea, según se observa en la Tabla 5.38. Esto sugiere que el modelo utiliza el valor reciente de PaO₂ como referencia principal para estimar su valor futuro. La variable mantiene una relación directa con sus propias mediciones anteriores.

En contraste, el modelo RF presentó un patrón de distribución de importancia diferente al de las NN. En lugar de centrar la relevancia en la medición reciente de PaO₂ [30], el RF asignó un peso predominante a la variable FiO₂ [480], con un 50,4 % (Tabla 5.38) de la relevancia, seguida de FiO₂ [30] con un 42,71 % (Tabla 5.38). Este resultado sugiere que RF, a diferencia de las NN que se apoyan principalmente en las mediciones recientes de PaO₂ (tendencia autorregresiva), prefiere utilizar variables ventilatorias como FiO₂ para predecir el valor de PaO₂. El hecho de que FiO₂ [480] sea la variable más importante indica que el modelo RF está utilizando datos de momentos anteriores

(patrones históricos más amplios) para hacer sus predicciones. Esta estrategia puede hacer que reaccione peor ante cambios rápidos o recientes en la PaO_2 .

En la configuración “30 Minutes Blinded”, las redes neuronales (FNN y FNN multitarea) mantuvieron a la variable PaO_2 [30] como la más relevante, con un 57,42 % en la FNN (Tabla 5.39) y un 35,72 % en la FNN multitarea (Tabla 5.39). Estos valores son muy similares a los de la configuración “All Data”. Esto confirma que, aunque en la configuración se eliminó la información más reciente de las variables medidas, las NN continúan utilizando la medición disponible de PaO_2 [30] como su principal referencia para estimar el valor futuro.

En cambio, RF mostró de nuevo un comportamiento diferente. PaO_2 [30] no fue relevante, asignándole un 0 % de contribución. En su lugar, centró la mayor parte de la relevancia en VentMode [0] (50,21 %, Tabla 5.39) y FiO_2 [0] (19,75 %, Tabla 5.39). Este patrón confirma que el RF sigue prefiriendo variables relacionadas con la configuración del ventilador.

En la configuración “60 Minutes Blinded”, las NN adaptaron su enfoque desplazando la importancia hacia la medición de PaO_2 [60]. Se convirtió en la variable más relevante con un 55,19 % en la FNN (Tabla 5.40) y un 37,84 % en la FNN multitarea (Tabla 5.40). Esto demuestra que, al no disponer de las mediciones en los últimos 60 minutos, las redes ajustan su referencia temporal y utilizan la medición de PaO_2 más reciente disponible para realizar la predicción. Así, mantienen el mismo enfoque basado en las propias mediciones anteriores de la variable objetivo.

Por el contrario, el RF volvió a priorizar las variables de soporte ventilatorio. La variable con mayor peso fue FiO_2 [120], que alcanzó un 46,16 % de relevancia (Tabla 5.40). También destacaron las variables NE [0] (13,54 %, Tabla 5.40) y VTset [30] (10,11 %, Tabla 5.40). En cambio, las mediciones de PaO_2 no estuvieron entre las variables más importantes.

En resumen, las NN basan sus predicciones en las mediciones previas de PaO_2 , ajustando su referencia temporal según la disponibilidad de datos. El RF mantiene un enfoque constante apoyado en variables de soporte ventilatorio.

Hallazgos principales en la predicción de PaCO_2

En la configuración “All Data”, el modelo FNN individual dio un peso muy elevado a la variable PaCO₂ [30], concentrando el 72,22 % de la relevancia total (Tabla 5.38). Esto indica que este modelo se apoya casi exclusivamente en esta medición reciente para estimar el valor futuro de PaCO₂. Así, refleja una fuerte dependencia de la continuidad temporal de la propia variable.

En cambio, la FNN multitarea distribuyó la importancia de forma más repartida. No utilizó las mediciones de PaCO₂ como variables relevantes para la predicción de PaCO₂. En su lugar, la mayor parte de la relevancia recayó en RRset [0] (20,03 %, Tabla 5.38) y RRset [30] (15,69 %, Tabla 5.38). Esto indica que basó su predicción de PaCO₂ en variables relacionadas con la RR (configurada y medida), en lugar de apoyarse directamente en las propias mediciones de PaCO₂. A diferencia de la FNN individual, que priorizó la medición de PaCO₂ [30], la multitarea mostró una estrategia más orientada al contexto ventilatorio.

El modelo RF no utilizó las mediciones previas de PaCO₂ como variables relevantes para su predicción. En su lugar, asignó la mayor parte de la relevancia a variables relacionadas con la configuración ventilatoria, como PEEPset [240] (36 %, Tabla 5.38) y FiO₂ [480] (24 %, Tabla 5.38). También destacaron otras variables de soporte, como FiO₂ [120] (13,93 %, Tabla 5.38) y RRmeas [30] (5,64 %, Tabla 5.38).

Esto indica, de nuevo, que RF basa su predicción de PaCO₂ en parámetros de ventilación y variables relacionadas con el soporte respiratorio. No aprovecha directamente las mediciones previas de la variable objetivo.

En la configuración “30 Minutes Blinded”, la FNN individual mantuvo la medición de PaCO₂ [30] como la variable más relevante, concentrando un 57,59 % de la relevancia total (Tabla 5.39). Esto refleja que el modelo siguió apoyándose principalmente en la medición más reciente disponible de PaCO₂ para realizar la predicción.

Por otro lado, la FNN multitarea distribuyó de nuevo la relevancia principalmente entre variables relacionadas con la RR, como RRset [0] (20,03 %, Tabla 5.39), RRset [30] (15,69 %, Tabla 5.39) y RRmeas [120] (7,82 %, Tabla 5.39). Este patrón muestra que la FNN multitarea basó su predicción en el contexto ventilatorio del paciente, en lugar de depender directamente de las propias mediciones de PaCO₂.

El modelo RF, por su parte, mostró un patrón similar al observado en la configuración “All Data”. Las mediciones de PaCO₂ no fueron relevantes, y el modelo se apoyó casi exclusivamente en variables ventilatorias. Las más destacadas fueron FiO₂ [0] (64,3 %, Tabla 5.39) y FiO₂ [30] (27,4 %, Tabla 5.39). Este comportamiento confirma que el RF continuó sin utilizar directamente las mediciones de PaCO₂.

En la configuración “60 Minutes Blinded”, el modelo FNN individual desplazó su atención hacia la medición de PaCO₂ [60], que pasó a ser la variable más relevante con un 82,86 % de la importancia total (Tabla 5.40). Esto indica que, al eliminar las mediciones de PaCO₂ en los últimos 60 minutos, el modelo ajustó su foco temporal para seguir utilizando la medición más reciente disponible como referencia principal para la predicción.

En el caso de la FNN multitarea, la estrategia fue distinta. Aunque PaCO₂ [60] tuvo cierta relevancia (5,9 %, Tabla 5.40), el modelo repartió la importancia entre múltiples variables ventilatorias y de soporte. Destacan VTset [30] (17,96 %, Tabla 5.40), FiO₂ [30] (13,44 %, Tabla 5.40) y FiO₂ [0] (11,82 %, Tabla 5.40).

El modelo RF, al igual que en las configuraciones anteriores, no otorgó relevancia a las mediciones de PaCO₂ para la predicción de esta variable. En su lugar, centró su atención en FiO₂ [120] (36,37 %, Tabla 5.40), FiO₂ [240] (21,61 %, Tabla 5.40) y FiO₂ [60] (17,97 %, Tabla 5.40). Este patrón confirma que el RF mantuvo su estrategia de basarse en variables ventilatorias de configuración.

En resumen, la FNN individual basó sus predicciones de PaCO₂ en las mediciones recientes disponibles, ajustando su foco temporal según la configuración. Por el contrario, la FNN multitarea y el RF se apoyaron en variables de soporte ventilatorio y parámetros respiratorios para realizar sus predicciones.

Hallazgos principales en la predicción de Crs

En la configuración “All Data”, el modelo FNN individual basó su predicción de Crs principalmente en variables relacionadas con la configuración ventilatoria. La variable más relevante fue VTset [0], con un 21,14 % de la importancia (Tabla 5.38), seguida de Ppeakinsp [60] (19,78 %, Tabla 5.38) y PaCO₂ [0] (13,78 %, Tabla 5.38). Por tanto, el modelo combinó tantos parámetros de configuración del ventilador como parámetros ventilatorios para realizar la predicción, sin depender de una única variable dominante.

La FNN multitarea presentó un patrón diferente. La variable con mayor peso fue Crs [120], que alcanzó un 19,21 % de relevancia (Tabla 5.38), seguida de VTset [0] (9,96 %, Tabla 5.38). Esto refleja que la multitarea combinó mediciones previas de Crs con variables de soporte respiratorio y configuración ventilatoria.

En cambio, el modelo RF mostró una estrategia muy clara: concentró la mayor parte de la relevancia en Crs [480], con un 48,95 % (Tabla 5.38), y Crs [60] (23,57 %, Tabla 5.38). También otorgó relevancia a Crs [30] (8,15 %, Tabla 5.38) y en menor medida a VTset [0] (5,86 %, Tabla 5.38). Esto indica que el RF priorizó de forma contundente las mediciones anteriores de Crs, especialmente las más alejadas en el tiempo, como referencia principal para realizar la predicción.

En la configuración “30 Minutes Blinded”, el modelo FNN individual centró su predicción de Crs en variables de configuración ventilatoria. Las más relevantes fueron VTset [0], con un 26,53 % (Tabla 5.39), seguida de Ppeakinsp [30] con un 29,04 % (Tabla 5.39). También destacó PEEPset [30] (12,08 %, Tabla 5.39). Las mediciones previas de Crs tuvieron un papel menos relevante.

En el modelo FNN multitarea, Crs [120] fue la variable más relevante con un 19,21 % (Tabla 5.39), seguido de VTset [0] (9,96 %, Tabla 5.39). Las mediciones de Crs en tiempos más cercanos tuvieron menor importancia. Esto sugiere un enfoque mixto que combina parámetros de configuración con variables respiratorias medidas.

Por último, el modelo RF distribuyó la relevancia de forma más dispersa. La variable más importante fue RRset [60], con un 23,11 % de la relevancia total (Tabla 5.39), seguida de Crs [480] (19,71 %, Tabla 5.39). También fueron relevantes Ppeakinsp [30] (16,22 %, Tabla 5.39) y Ppeakinsp [60] (10,96 %, Tabla 5.39), junto con variables de configuración como VTset [120] (13,36 %, Tabla 5.39). A diferencia de la configuración anterior, el RF combinó tanto mediciones de Crs como variables relacionadas con la frecuencia respiratoria y la configuración ventilatoria. Este patrón refleja un enfoque más heterogéneo.

En la configuración “60 Minutes Blinded”, el modelo FNN individual distribuyó la relevancia entre variables de configuración ventilatoria y mediciones de Crs. La variable más importante fue VTset [0], con un 12,95 % de relevancia (Tabla 5.40), seguida de Ppeakinsp [60] (9,93 %, Tabla 5.40). Las mediciones de Crs también tuvieron peso, pero quedaron por debajo de algunas variables de configuración. Por tanto, el modelo combinó

tanto las mediciones previas de Crs como variables de soporte ventilatorio para realizar la predicción.

Por su parte, la FNN multitarea basó su predicción de Crs principalmente en variables de configuración ventilatoria. La más relevante fue VTset [0], con un 19,15 % (Tabla 5.40), seguida de VTset [120] (5,73 %, Tabla 5.40). La medición de Crs [120] tuvo un peso del 5,68 % (Tabla 5.40), pero quedó por detrás de las variables de configuración. Este patrón refleja que la FNN multitarea no dependió exclusivamente de las mediciones de Crs, sino que distribuyó la importancia entre variables de soporte ventilatorio y parámetros respiratorios, priorizando especialmente los ajustes programados en el ventilador.

El modelo RF, en cambio, dio un peso elevado a Crs [60] (36,48 %, Tabla 5.40) y Crs [120] (8,64 %, Tabla 5.40), mientras que Crs [240] alcanzó un 9,1 % (Tabla 5.40). También fueron relevantes variables como RRset [60] (9,26 %, Tabla 5.40), RRset [30] (7,47 %, Tabla 5.40) y VTset [120] (11,27 %, Tabla 5.40). Este patrón muestra que el RF combinó las mediciones de Crs con variables respiratorias y de configuración.

En resumen, la FNN individual y multitarea priorizaron variables de configuración ventilatoria para predecir Crs. Por otro lado, RF mantuvo su enfoque en las mediciones previas de Crs, especialmente en las más alejadas.

6.2.2. Interpretación mediante valores de Shapley.

Se interpretan los resultados de relevancia obtenidos mediante el análisis de los valores de Shapley.

Hallazgos principales en la predicción de PaO₂

En la configuración “All Data”, los modelos basados en NN mostraron un claro predominio de las variables PaO₂ [30] y PaO₂ [60] en la predicción de PaO₂. En el modelo FNN, PaO₂ [30] concentró el 4,08 % de la relevancia total, seguida de FiO₂ [0] con un 2,21 % (Tabla 5.41). En la red multitarea, el patrón fue similar, con PaO₂ [30] aportando un 3,10 % y RRset [0] un 2,39 %. Este comportamiento indica que las NN explotaron la continuidad temporal de la variable PaO₂, utilizando preferentemente las mediciones más recientes disponibles.

En contraste, el modelo RF mostró una distribución más concentrada, asignando un 12,27 % de relevancia a PaO₂ [30]. Este enfoque refuerza la tendencia de RF a centrar sus predicciones en un subconjunto reducido de variables con alta relación directa con la salida.

El análisis de otras variables, como FiO₂ [0], reveló un impacto limitado en las NN (2,21 % en FNN y 1,69 % en FNN multitarea), mientras que en RF ascendió a un 3,73 %. Esto refleja de nuevo la mayor selectividad de este modelo hacia variables de control ventilatorio. El resto de variables de FiO₂ (a 30, 60, 120, 240 y 480 minutos) y otras constantes fisiológicas (SpO₂, HR, MAP, etc.) presentaron contribuciones minoritarias y homogéneas en los modelos de NN (alrededor del 1,3-1,5 % cada una). Por el contrario, en RF se observó un patrón de relevancias dispersas, con algunos picos de importancia, pero sin alcanzar el peso de la variable PaO₂ [30].

Finalmente, variables demográficas como Age, Gender, Height y Weight mantuvieron relevancias constantes en torno al 1,3 % en FNN y FNN multitarea, reduciéndose ligeramente en RF. Esto sugiere que las NN utilizan las variables demográficas como un parámetro de corrección constante en la predicción, mientras que RF reduce su peso al mínimo.

En la configuración “30 Minutes Blinded”, los modelos FNN y FNN multitarea volvieron a dar más importancia a PaO₂ [30], con un peso del 4,04 % en FNN y 3,10 % en la red multitarea (Tabla 5.42). A diferencia de la configuración “All Data”, en esta la variable PaO₂ [60] ganó peso en el modelo RF, alcanzando un 6,54 %, mientras que PaO₂ [30] adquirió un valor de 10,69 % (Tabla 5.42). Esto refuerza la tendencia del RF a concentrar sus predicciones en un pequeño grupo de variables de entrada, dándoles un peso mucho mayor que las NN.

Variables de control ventilatorio como FiO₂ [0] también aumentaron su relevancia en el modelo RF (5,60 %), superando ampliamente a FNN (2,05 %) y FNN multitarea (1,69 %) (Tabla 5.42). Las variables de FiO₂ en otros tiempos (30, 60, 120 minutos) mantuvieron relevancias uniformes en FNN y FNN multitarea (1,3-1,5 %). En RF destacaron algunos picos, como FiO₂ [30] con 3,99 % (Tabla 5.42).

Las NN, igual que en la configuración anterior, repartieron el peso entre múltiples variables fisiológicas (SpO₂, HR, MAP, etc.) con valores en torno al 1,3-1,5 %. RF, en

cambio, amplificó la importancia de algunas mediciones recientes, como SpO₂ [30] con un 7,04 %, confirmando su estrategia de apoyarse en las variables más inmediatas para la predicción (Tabla 5.42).

Las variables demográficas mantuvieron una importancia estable en FNN y FNN multitarea (1,3-1,4 %). RF volvió a reducir su peso, asignando valores mínimos a Gender (0,26 %) y Height (0,48 %) (Tabla 5.42). Esto vuelve a indicar que las NN usan estas variables como un ajuste de fondo, mientras que RF apenas las incorpora en el proceso de predicción.

En la configuración “60 Minutes Blinded”, el modelo RF incrementó notablemente la relevancia de las variables PaO₂ [60] (15,10 %) y PaO₂ [120] (4,95 %) (Tabla 5.43). Esta tendencia a concentrar la predicción en pocas variables clave se mantuvo. En cambio, FNN y FNN multitarea distribuyeron de forma más equilibrada la relevancia entre las ventanas de PaO₂, destacando PaO₂ [60] con 5,72 % en FNN y 4,30 % en FNN multitarea (Tabla 5.43).

El impacto de FiO₂ [0] en RF fue el más alto de todas las configuraciones (6,36 %), reflejando su uso como variable de referencia para estimaciones a largo plazo. En FNN y FNN multitarea su importancia fue menor (3,29 % y 2,09 % respectivamente), manteniendo la tendencia de las redes a repartir el peso entre múltiples entradas (Tabla 5.43). Otras variables de FiO₂ (30, 60, 120 minutos) se mantuvieron en torno al 1,5-2,5 % en los modelos de redes, mientras que RF volvió a concentrar relevancia en FiO₂ [30] (4,97 %) (Tabla 5.43).

Las mediciones de SpO₂ [60] fueron particularmente relevantes en RF (6,52 %). En FNN y FNN multitarea, por el contrario, rondaron el 2 % (Tabla 5.43). Esta diferencia refuerza la preferencia de RF por las variables recientes más relacionadas con la oxigenación.

Las variables demográficas conservaron en las redes neuronales importancias similares a las de configuraciones anteriores (entre 1,6 % y 1,9 %). RF siguió reduciendo su impacto, con valores de Gender (0,43 %) y Height (0,65 %) (Tabla 5.43).

Hallazgos principales en la predicción de PaCO₂

En la configuración “All Data”, los modelos FNN y FNN multitarea dieron mayor importancia a PaCO₂ [30], con valores del 5,60 % y 1,91 % respectivamente (Tabla 5.41). A diferencia de lo observado en la predicción de PaO₂, en este caso las NN aumentaron el peso de las mediciones recientes de PaCO₂, especialmente en el modelo FNN individual.

El modelo RF mostró un patrón más concentrado, asignando un 16,05 % de relevancia a PaCO₂ [30] y un 7,56 % a PaCO₂ [60] (Tabla 5.41).

Otras variables como PaO₂ [0] mantuvieron relevancias bajas en las NN y moderadas en RF (11,65 %) (Tabla 5.41), lo que indica que RF utilizó las mediciones de PaO₂ para ajustar la predicción de PaCO₂.

Las variables de FiO₂, SpO₂ y constantes fisiológicas se mantuvieron con valores estables en FNN y FNN multitarea (alrededor del 1,3-1,5 %), mientras que en RF algunas ventanas mostraron picos.

Finalmente, las variables demográficas conservaron su peso estable en las NN (1,4 % en FNN y multitarea), mientras que RF redujo su importancia (Gender 0,47 %, Height 0,36 %, Tabla 5.41). Las NN las usaron como un factor de corrección constante, mientras que RF apenas las tuvo en cuenta.

En la configuración “30 Minutes Blinded”, la variable PaCO₂ [30] fue la más importante en los tres modelos, aunque con diferencias notables en magnitud (Tabla 5.42). En el modelo FNN, PaCO₂ [30] alcanzó un 4,99 %, mientras que en FNN multitarea su peso fue de 1,91 %. RF, por su parte, concentró su predicción en PaCO₂ [30] con un 15,20 %, seguido de PaCO₂ [60] con 6,70 % (Tabla 5.42). Esto muestra que las redes neuronales utilizaron las ventanas recientes de PaCO₂ como referencia, pero sin depender exclusivamente de ellas. En cambio, RF basó sus predicciones principalmente en esas dos mediciones, asignándoles un peso mucho mayor.

Variables de soporte ventilatorio tuvieron relevancias bajas en RF, sin destacar como variables principales. Las redes neuronales también asignaron a estas variables un peso bajo, manteniéndose en torno al 1,5-2 %.

Las variables demográficas mantuvieron importancias similares a las configuraciones anteriores en FNN y FNN multitarea (alrededor del 1,3-1,4 %). RF

volvió a reducir su peso: Gender quedó en 0,49 % y Height en 0,42 % (Tabla 5.42). De nuevo, las NN las incorporaron como parámetro constante de ajuste, mientras que RF apenas las consideró.

En la configuración “60 Minutes Blinded”, RF volvió a concentrar su predicción en las mediciones recientes de PaCO₂. La variable PaCO₂ [60] fue la más relevante, con un 20,57 %, seguida de PaCO₂ [120] (5,70 %), PaCO₂ [480] (4,72 %) y PaCO₂ [240] (4,05 %) (Tabla 5.43). Este patrón muestra cómo RF priorizó de forma contundente la medición de la variable más cercana a la predicción, además de otras ventanas temporales.

A diferencia de RF, los modelos FNN y FNN multitarea distribuyeron la relevancia de forma más equilibrada. En FNN, PaCO₂ [60] fue la más relevante con un 10,35 %, mientras que en la FNN multitarea bajó a un 3,53 % (Tabla 5.43). Las demás ventanas de PaCO₂ se mantuvieron en torno al 1,5-2,3 %.

Variables de soporte ventilatorio tampoco destacaron. Aunque alcanzaron valores más altos que en las configuraciones anteriores, siguieron lejos de la relevancia de las mediciones directas de PaCO₂.

Las variables demográficas mantuvieron su relevancia en FNN y FNN multitarea (alrededor del 1,6-2 %), mientras que en RF su peso continuó siendo mínimo (Gender 0,87 %, Height 0,52 %) (Tabla 5.43).

Hallazgos principales en la predicción de Crs

En la configuración “All Data”, el modelo RF dio mayor relevancia a las variables Crs [30] (8,29 %) y Crs [60] (7,67 %) (Tabla 5.41). También se apoyó en Crs [480] (6,22 %), en Crs [120] (4,29 %) y en menor medida en Crs [240] (3,60 %). Esto refleja la tendencia de RF a priorizar las mediciones más cercanas de la variable, pero manteniendo cierto peso en registros más antiguos.

En contraste, las NN distribuyeron la relevancia de forma homogénea. Las variables Crs [30], [60], [120], [240] y [480] se mantuvieron alrededor del 1,3-2,5 % en ambos modelos (Tabla 5.41). Este patrón indica que las NN integraron toda la evolución temporal de Crs, sin depender de una ventana concreta.

El resto de variables ventilatorias y fisiológicas (FiO_2 , SpO_2 , HR, MAP, etc.) presentaron relevancias muy bajas, tanto en RF como en FNN y FNN multitarea.

Las variables demográficas mantuvieron su relevancia estable en FNN y FNN multitarea (alrededor del 1,3-1,4 %), mientras que en RF su peso fue marginal (Gender 1,28 %, Height 0,09 %, Tabla 5.41).

En la configuración “30 Minutes Blinded”, el modelo RF mantuvo el patrón de concentrar la predicción en pocas variables. La más importante fue Crs [30], que alcanzó un 10,49 %, seguida de Crs [60] (7,85 %) y Crs [120] (7,24 %) (Tabla 5.42). Las ventanas más alejadas (Crs [240]: 4,81 %, Crs [480]: 6,52 %) también tuvieron un peso relevante, aunque menor. Esto muestra que RF continuó priorizando las mediciones más recientes de Crs, pero sin descartar referencias más antiguas.

Las NN, en cambio, mantuvieron una distribución equilibrada entre todas las ventanas temporales de Crs. En FNN, la variable Crs [30] tuvo un 2,63 %, mientras que en la FNN multitarea fue de 1,42 % (Tabla 5.42). Las demás ventanas temporales (60, 120, 240, 480 min) se mantuvieron en torno al 1,3-2,1 %, lo que indica que las redes neuronales siguieron integrando la evolución completa de la variable Crs en la predicción.

Las variables de soporte ventilatorio y constantes fisiológicas (FiO_2 , SpO_2 , HR, MAP, etc.) se mantuvieron en valores bajos en todos los modelos.

Las variables demográficas continuaron estables en FNN y FNN multitarea (1,3-1,4 %), mientras que en RF su relevancia fue mínima (Gender 0,81 %, Height 0,10 %, Tabla 5.42).

En la configuración “60 Minutes Blinded”, RF concentró la predicción de Crs de nuevo en las ventanas más recientes. Crs [60] fue la variable más relevante con un 13,52 %, seguida de Crs [120] (8,06 %), Crs [240] (5,43 %) y Crs [480] (7,18 %) (Tabla 5.43). Continuamos con el mismo patrón: RF se apoya fuertemente en las mediciones de Crs cercanas a la ventana de predicción sin dejar de lado referencias más desplazadas.

FNN y FNN multitarea distribuyeron la importancia de manera más homogénea entre todas las ventanas temporales. En FNN, Crs [60] tuvo un 4,29 %, mientras que en la red multitarea fue de 1,98 % (Tabla 5.43). Las demás ventanas de Crs (120, 240, 480 minutos)

mantuvieron relevancias entre el 1,7-2,9 % en multitarea y 2-4,2 % en FNN, sin que ninguna ventana destacase de forma clara.

El resto de variables ventilatorias y fisiológicas mantuvieron pesos bajos en todos los modelos, sin desempeñar un papel relevante en la predicción de Crs.

Las variables demográficas se mantuvieron estables en FNN y FNN multitarea (entre 1,8-2 %), mientras que en RF su peso fue muy bajo (Gender 0,99 %, Height 0,14 %) (Tabla 5.43).

En resumen, RF basó la predicción de Crs en las ventanas recientes (30-120 min), asignándoles la mayor relevancia. Las NN, en cambio, distribuyeron el peso de forma equilibrada entre todas las ventanas temporales. El resto de variables tuvieron un impacto menor en todos los modelos.

6.2.3. Comparación entre PI y valores de Shapley: análisis conjunto de patrones

En este apartado se compara la relevancia de las variables de entrada obtenida mediante PI y mediante valores de Shapley. La comparación se organiza por variable objetivo (PaO_2 , PaCO_2 y Crs), y dentro de cada una se analizan las coincidencias y diferencias según el modelo empleado. Se destacan las similitudes y discrepancias en las variables más importantes identificadas por cada técnica. Asimismo, se examina cómo evolucionan estos patrones al cambiar la configuración de entrada de datos.

Patrones en el análisis de importancia de PaO_2

En el modelo de FNN, PI y Shapley coinciden en que la PaO_2 [30] es la variable más importante para predecir la PaO_2 . Ambos métodos la sitúan como la número uno, aunque difieren en la manera de repartir su relevancia. PI muestra que la red depende fuertemente de PaO_2 [30] para mantener el rendimiento. Los valores de Shapley, en cambio, reflejan que la red también reparte la predicción entre muchas otras variables, aunque ninguna aporte tanto como la PaO_2 [30].

Esta diferencia ocurre porque PI mide cuánto se deteriora el modelo si se altera la variable, mientras que SHAP calcula cómo cada variable contribuye al valor de salida. Por eso, aunque la PaO_2 [30] sea esencial para el rendimiento, su aporte individual en Shapley aparece más diluido, ya que la red también utiliza otras variables.

Al cambiar la configuración de entrada, el patrón se mantiene. En “30 Minutes Blinded”, la PaO_2 [30] sigue siendo la referencia principal, siendo la última medición disponible de la variable objetivo. No es hasta la configuración “60 Blinded” cuando la red desplaza su foco a la PaO_2 [60], utilizándola como nueva referencia.

En resumen, la FNN mantiene una estrategia autorregresiva clara. Siempre utiliza la PaO_2 más reciente disponible, ajustando su referencia según la ventana temporal. PI refleja lo crítica que es esta variable para el rendimiento. Por otro lado, SHAP muestra cómo la red reparte la predicción entre todas las variables relevantes. Ambos métodos coinciden en el patrón general de funcionamiento.

En la FNN multitarea, PI y Shapley coinciden en que la PaO_2 [30] es la variable más importante para predecir la PaO_2 . Sin embargo, la dependencia de esta variable es menor que en la FNN individual. La multitarea reparte más la importancia entre otras variables, como la FiO_2 y la RRset , integrando más datos de configuración del ventilador en la predicción.

Esta diferencia se debe a que la red multitarea está entrenada para predecir varias salidas a la vez. Esto obliga al modelo a apoyarse en variables que afectan a todas ellas, en lugar de centrarse exclusivamente en la PaO_2 reciente. Este enfoque reduce la dependencia excesiva de una sola variable.

En ambos métodos, la jerarquía es la misma: primero la PaO_2 previa, seguida de las variables de soporte ventilatorio, y después el resto de entradas con menor impacto.

Al modificar la ventana temporal, la FNN multitarea mantiene la misma lógica que la FNN individual. Cuando faltan datos recientes, desplaza su referencia a la última PaO_2 disponible. Sin embargo, también incrementa el uso de variables de configuración ventilatoria para compensar la falta de información. Este ajuste es coherente con su arquitectura multitarea, ya que busca pistas en variables que afectan simultáneamente a las tres salidas.

En resumen, la FNN multitarea utiliza una estrategia similar a la red individual, apoyándose principalmente en la PaO_2 más reciente, pero distribuyendo más la importancia entre otras variables. Ambos métodos captan que la FNN multitarea ajusta su foco según la disponibilidad de datos.

En el modelo RF, tanto PI como los valores de Shapley coinciden en señalar que las variables de oxigenación son las más relevantes para predecir la PaO_2 . Sin embargo, difieren en cuál consideran predominante. PI otorga una gran importancia a la FiO_2 , especialmente en mediciones de 480 y 30 minutos antes. En cambio, SHAP destaca la PaO_2 medida 30 minutos antes como la principal variable influyente.

Esta diferencia se explica porque el modelo RF utiliza tanto la PaO_2 previa como la FiO_2 para predecir la PaO_2 . Ambas variables están estrechamente relacionadas, ya que al aumentar la FiO_2 suele aumentar también la PaO_2 del paciente. Al calcular PI, se desordenan los valores de la variable objetivo y se observa cuánto empeora la predicción. Sin embargo, si la información de la PaO_2 puede ser reemplazada por la FiO_2 , el rendimiento del modelo apenas se ve afectado al permutarla. Por este motivo, PI puede dar la impresión de que la PaO_2 no es relevante, cuando en realidad el modelo sí la está utilizando, pero dispone de otra variable similar que compensa su ausencia.

En cambio, los valores de Shapley no miden la importancia eliminando o desordenando variables, sino que calculan cómo cada una aporta al resultado teniendo en cuenta las combinaciones con las demás. Así, aunque el RF pueda apoyarse en la FiO_2 para predecir la PaO_2 , SHAP refleja que la PaO_2 previa sigue contribuyendo de manera significativa a la predicción.

Cuando se eliminan las mediciones recientes, como en las configuraciones “30 Minutes Blinded” y “60 Minutes Blinded”, el RF ajusta su estrategia. Al perder acceso a la PaO_2 más cercana, el modelo da mayor peso a variables ventilatorias, como el VentMode y la FiO_2 . Aun así, los valores de Shapley muestran que la PaO_2 disponible sigue contribuyendo a la predicción, aunque con menor peso.

En resumen, PI y Shapley identifican las mismas variables clave, pero difieren en cómo reparten la importancia cuando hay correlaciones entre ellas.

Patrones en el análisis de importancia de PaCO_2

En la FNN individual, tanto PI como Shapley coinciden en que la PaCO_2 [30] es la variable más importante para predecir la PaCO_2 . Sin embargo, la FNN mostró una dependencia aún mayor de este valor previo en comparación con lo observado en la predicción de PaO_2 . PI reflejó que el modelo se apoya de forma casi exclusiva en la PaCO_2

más reciente. SHAP, aunque reparte la contribución entre más variables, confirma que la PaCO_2 [30] domina claramente sobre el resto.

La red también utiliza la PaCO_2 [60], pero con menor peso. Otras variables como la FiO_2 o la SpO_2 aportan muy poco a la predicción de PaCO_2 en este modelo. Esto sugiere que la FNN aprendió un patrón muy autorregresivo para la PaCO_2 .

A diferencia de la PaO_2 , donde la red combinaba la medición previa con otras variables ventilatorias, en PaCO_2 la FNN apenas necesitó recurrir a variables adicionales. Esta diferencia puede deberse a que la PaCO_2 varía de forma más predecible si no hay cambios en la ventilación, mientras que la PaO_2 depende de más factores fisiológicos.

Al cambiar la configuración de entrada, la FNN mantuvo su estrategia. Cuando se eliminó la PaCO_2 de los últimos 30 o 60 minutos, el modelo simplemente desplazó su referencia a la medición más cercana disponible. PI y Shapley mostraron que la red seguía confiando en la última PaCO_2 accesible como su principal fuente de información.

Un aspecto destacable es que la FNN no compensó la falta de datos recientes utilizando variables de ventilador, a diferencia del RF.

En resumen, la FNN individual aplicó una estrategia autorregresiva muy marcada para la predicción de PaCO_2 . Se adaptó a la disponibilidad de datos, priorizando siempre la medición más reciente. PI y SHAP mostraron el mismo patrón, aunque reflejado con diferente escala.

La FNN multitarea mostró un enfoque distinto al de la FNN individual para predecir la PaCO_2 . PI y Shapley coincidieron en que la no dependió tanto de la PaCO_2 reciente, sino que distribuyó la importancia entre variables de ventilación como el VTset y la FiO_2 . A diferencia de la FNN individual, donde la PaCO_2 [30] era el factor clave, en la multitarea su relevancia fue mucho menor. Las variables de configuración ventilatoria tomaron mayor protagonismo.

Este cambio de estrategia se debe a la propia arquitectura multitarea. Al predecir simultáneamente PaO_2 , PaCO_2 y Crs , la red tiende a apoyarse en variables que son útiles para todas las salidas, en lugar de centrarse exclusivamente en la historia de PaCO_2 .

Al eliminar datos recientes, la multitarea mantuvo esta estrategia. La red no se apoyó fuertemente en la PaCO_2 más antigua. Reforzó el uso de variables de soporte ventilatorio para compensar. PI y SHAP captaron este ajuste de forma coherente, mostrando que la multitarea prefirió seguir usando un conjunto amplio de variables.

En resumen, PI y Shapley coinciden en que la FNN multitarea no prioriza la PaCO_2 previa como lo hace la FNN individual. La predicción se basa más en las variables de ventilador y en una combinación de entradas moderadamente informativas. Esta estrategia refleja que el modelo busca entradas que sean útiles para todas sus salidas.

En la predicción de PaCO_2 , el RF mostró una gran discrepancia entre PI y Shapley. PI indicaba que el modelo no utilizaba directamente las mediciones previas de PaCO_2 , sino que se apoyaba casi por completo en variables de configuración ventilatoria. Especialmente, en la FiO_2 en distintas ventanas de tiempo. Esto resultaba poco lógico desde el punto de vista fisiológico, ya que la PaCO_2 previa suele ser el mejor predictor del valor futuro.

Sin embargo, los valores de Shapley revelaron que el RF sí consideraba la PaCO_2 previa como una de sus variables más influyentes. Según SHAP, el modelo utilizaba principalmente las mediciones recientes de PaCO_2 y, en menor medida, la PaO_2 actual como referencia.

La discrepancia se debe a que PI mide el impacto de eliminar una variable en el rendimiento, y en este caso, la PaCO_2 estaba correlacionada con otras variables como la FiO_2 . Al permutar la PaCO_2 , RF podía mantener su precisión usando la FiO_2 como sustituta, lo que hacía parecer que la PaCO_2 no era importante. SHAP, en cambio, mostró que la importancia de la PaCO_2 se compartía con variables de soporte ventilatorio. Este contraste ilustra cómo PI puede ocultar variables que el modelo realmente está utilizando, especialmente cuando hay correlaciones fuertes entre los predictores.

Cuando se eliminaron datos recientes, el RF ajustó su estrategia. SHAP mostró que el modelo utilizaba la PaCO_2 más antigua disponible como referencia principal. Por otro lado, PI seguía resaltando las variables de configuración ventilatoria como las más relevantes.

En resumen, PI reflejó que el RF podía prescindir de la PaCO₂ previa sin perder rendimiento, mientras que Shapley mostró que el modelo realmente la usaba para mejorar sus predicciones cuando estaba disponible. Esta diferencia metodológica resalta la importancia de combinar PI y Shapley para obtener una interpretación completa de cómo el modelo toma sus decisiones.

Patrones en el análisis de importancia de Crs

En la predicción de Crs, la FNN mostró un patrón distinto al observado en PaO₂ y PaCO₂. PI indicó que la red no dependió fuertemente de las mediciones previas de Crs, sino que basó su predicción en variables de configuración ventilatoria. Aun así, SHAP mostró que la red utilizó mediciones previas de Crs, pero sin centrarse en una única ventana de tiempo. En lugar de ello, repartió la importancia entre varias mediciones antiguas de Crs y parámetros ventilatorios.

Esta diferencia entre PI y Shapley se explica porque la red combina distintas variables para estimar la Crs. Si quitamos una de esas variables, el modelo pierde una parte clave de su cálculo y el error aumenta mucho. Eso es lo que detecta PI. Sin embargo, SHAP no mide qué pasa si eliminamos la variable, sino cómo se reparte la influencia entre todas las que participan en la predicción. Como la red utiliza varias variables a la vez para estimar la Crs, la importancia de cada una aparece más repartida en SHAP.

Cuando se eliminaron datos recientes, la red intensificó el uso de variables de configuración del ventilador cuando no disponía de mediciones recientes de Crs. SHAP también reflejó este ajuste, con una distribución más repartida. Las mediciones de Crs más antiguas seguían aportando, pero con menor peso.

En resumen, la FNN individual predijo la Crs combinando información ventilatoria actual con la tendencia global de Crs. No dependió de una única medición reciente.

La FNN multitarea mostró un enfoque intermedio entre el RF y la FNN individual para predecir la Crs. Según PI, la FNN multitarea utilizó mediciones anteriores de Crs, como Crs [120]. También dio un peso importante a variables de configuración ventilatoria, especialmente VTset. SHAP confirmó este patrón, mostrando que la red combinaba la información de Crs previas con parámetros ventilatorios, sin depender exclusivamente de ninguna de ellas.

A diferencia de la FNN individual, que priorizaba más los parámetros de ventilador, la FNN multitarea utilizó parte de las mediciones previas de Crs. Esto se debe a que, al predecir múltiples salidas a la vez, la red multitarea favoreció el uso de variables que son útiles para todas (como VTset o RRset). Las mediciones específicas de Crs se mantuvieron como un apoyo adicional.

Al eliminar datos recientes, la FNN multitarea aumentó su dependencia de los parámetros ventilatorios. PI mostró cómo el modelo priorizó el VTset. SHAP reflejó que ninguna ventana de Crs asumió un rol dominante, manteniendo un equilibrio entre múltiples entradas.

En resumen, la FNN multitarea predijo la Crs combinando mediciones previas de Crs con parámetros de configuración del ventilador. Ajustó su enfoque según la disponibilidad de datos.

En la predicción de la Crs, RF mostró un patrón muy consistente entre PI y Shapley. Ambos métodos coincidieron en que el RF basó sus predicciones principalmente en las mediciones previas de Crs. PI destacó especialmente la Crs de 8 horas antes como la variable más importante, mientras que SHAP dio más peso a las mediciones recientes (30 y 60 minutos antes). Difieren en qué ventana temporal es la más crítica.

Cuando se eliminaron datos recientes, el RF adaptó su estrategia. Sin las mediciones inmediatas de Crs, el modelo recurrió a las ventanas de tiempo más cercanas disponibles.

En resumen, el RF predijo la Crs principalmente en función de las mediciones de Crs previas, priorizando las más recientes disponibles. Solo utilizaba variables de ventilador como apoyo secundario cuando era necesario.

6.2.4. Perspectiva fisiológica de los resultados

La PaO_2 refleja directamente el nivel de oxigenación en la sangre arterial. En los modelos, las variables más importantes para su predicción han sido aquellas que tienen una relación fisiológica directa con el intercambio gaseoso. Una de las más relevantes es la FiO_2 . Al aumentar la FiO_2 , también sube la PaO_2 , y eso favorece que más oxígeno pase a la sangre. La ecuación del gas alveolar explica esta relación, mostrando cómo la PaO_2 depende principalmente de la FiO_2 administrada. También influye, en menor medida, la $PaCO_2$.

$$PaO_2 = (PB - PH_2O) \times FiO_2 - PaCO_2/R \quad [22]$$

Donde:

- PB es la presión barométrica,
- PH_2O es la presión de vapor de agua,
- R es el cociente respiratorio (habitualmente 0,8) (Oliver et al., 2014).

Desde esta perspectiva, es comprensible que la FiO_2 haya aparecido como una variable de entrada clave.

Otro hallazgo importante fue la relevancia de la PaO_2 más reciente del paciente. La FNN y la FNN multitarea priorizaron claramente este valor. Esto es razonable, ya que la PaO_2 no suele cambiar bruscamente en cuestión de minutos. Si un paciente presenta una PaO_2 baja, lo normal es que siga en rangos bajos a menos que se realicen ajustes en la ventilación o en la FiO_2 . Por eso, la última medición de PaO_2 actúa como una referencia muy fuerte para predecir el valor actual.

Este comportamiento es característico de las NN, que se apoyan en la continuidad temporal de los datos. Por el contrario, el RF mostró preferencia por utilizar variables de configuración del ventilador.

En resumen, la PaO_2 se ve influenciada principalmente por la FiO_2 administrada y por el estado de oxigenación reciente del paciente. Los modelos de ML reflejaron fielmente esta relación fisiológica.

La $PaCO_2$ es un buen reflejo de la ventilación alveolar. En condiciones normales, representa el equilibrio entre la producción de CO_2 por el metabolismo celular y su eliminación a través de los pulmones. Fisiológicamente, la forma más directa de reducir la $PaCO_2$ es aumentando la ventilación alveolar. Esto se consigue respirando más rápido o más profundo, lo que permite eliminar más CO_2 . En cambio, si la ventilación es insuficiente, el CO_2 se acumula en la sangre y la $PaCO_2$ sube (Grippi, 2020).

Esta relación quedó bien capturada por los modelos. Las variables más importantes para predecir la $PaCO_2$ fueron las relacionadas con la ventilación minuto, como el VTset y la RRset. Esto refleja que cuanto más aire llega a los alvéolos por minuto, más CO_2 se puede eliminar. Si el ventilador entrega respiraciones más grandes o más frecuentes, es

esperable una reducción de la PaCO_2 . Por el contrario, si el volumen o la frecuencia son bajos, la eliminación de CO_2 será menor, y la PaCO_2 tenderá a subir.

También hay que tener en cuenta el espacio muerto fisiológico. Parte del aire inspirado no participa en el intercambio gaseoso, y en enfermedades pulmonares este espacio muerto puede aumentar. Esto hace que una fracción mayor de cada respiración no elimine CO_2 de forma efectiva. Por tanto, incluso con ventilaciones aparentemente adecuadas, la PaCO_2 puede mantenerse elevada si hay problemas estructurales o funcionales en el pulmón (Grippi, 2020).

En algunos modelos, especialmente en NN, también destacó la relevancia de la PaCO_2 medida recientemente. Si no ha habido grandes cambios en la ventilación, lo más probable es que el valor de PaCO_2 actual no se desvíe mucho del anterior. El CO_2 en sangre no suele cambiar de forma brusca sin un motivo claro. Su variación responde a cambios ventilatorios más que a otros factores.

Sin embargo, no todos los modelos siguieron esta lógica. En el caso del RF, variables como la FiO_2 o la PEEPset fueron más importantes. Aunque en principio estas no regulan directamente el CO_2 , sí pueden dar información indirecta. Por ejemplo, una PEEP alta o una FiO_2 elevada suelen asociarse a pacientes con pulmones más comprometidos. En ellos, la eliminación de CO_2 puede estar dificultada por alteraciones en la relación ventilación/perfusión o por un aumento del espacio muerto. En ese sentido, el modelo RF podría estar usando esas variables como señales indirectas de hipoventilación o de patología pulmonar grave.

En resumen, los resultados concuerdan bastante bien con la fisiología respiratoria.

La variable Crs representa la distensibilidad del sistema respiratorio. En términos fisiológicos, es la capacidad que tienen los pulmones y el tórax para expandirse ante una presión aplicada. Se define como el cociente entre el cambio de volumen y el cambio de presión necesario para conseguirlo. Es decir, cuánto volumen se consigue introducir por cada centímetro de presión generada en la vía aérea.

Cuando la Crs es alta, el pulmón se deja inflar fácilmente con muy poca presión. Cuando es baja, ocurre lo contrario: los pulmones están rígidos y requieren presiones más elevadas para un mismo volumen. Esto se ve, por ejemplo, en pacientes con SDRA o

fibrosis pulmonar. En cambio, patologías como el enfisema tienden a aumentar la Crs (Clínica Universidad de Navarra, 2025).

En los modelos de ML, se observó que las variables más importantes para predecir la Crs fueron aquellas que, desde el punto de vista fisiológico, están directamente relacionadas con su cálculo. La FNN y la FNN multitarea dieron mucho peso al VTset y a las presiones de vía aérea, como la Ppeakinsp. Si para introducir un volumen determinado el ventilador necesita aplicar una presión alta, es señal de que el sistema respiratorio es poco distensible. Si en cambio se alcanza ese volumen con presiones bajas, la Crs es alta. En esencia, los modelos están utilizando las mismas relaciones que se usan en la práctica clínica para estimar la distensibilidad.

También se identificó la PEEPset como una variable relevante. No tanto porque entre directamente en el cálculo de Crs, sino porque puede modificar las condiciones mecánicas del pulmón. Por ejemplo, una PEEP bien ajustada puede reclutar alvéolos colapsados y mejorar la compliance. En cambio, si la PEEP es demasiado alta, puede distender de más el pulmón y empeorarla. Así que, aunque indirecta, su influencia es lógica y relevante.

Por otro lado, los modelos también aprovecharon información histórica sobre la Crs. Esto sugiere que la Crs tiene cierta continuidad en el tiempo. Salvo cambios agudos o intervenciones específicas, la distensibilidad no suele variar bruscamente.

Todo esto encaja con la forma en la que se entiende y se mide la Crs.

6.3. Análisis crítico de la simulación de los ajustes de la PEEP

La simulación de cambios en la PEEP a partir de datos reales permite estimar, sin intervenir sobre el paciente, la respuesta de las variables objetivo PaO₂, PaCO₂ y Crs. En este trabajo se muestran solo tres casos representativos. Estos son suficientes para apreciar la variabilidad que puede existir entre pacientes y en diferentes momentos de su evolución.

En estos ejemplos aparecen patrones muy distintos. En la Figura 3.28, la PaO₂ aumenta de forma progresiva hasta alcanzar un punto de inflexión. En la Figura 3.29 desciende con el aumento de PEEP. En la Figura 3.30 aparece una respuesta no monótona, con un valor óptimo intermedio. Estos patrones confirman que el ajuste de la PEEP no sigue una norma general. Una misma modificación puede tener efectos opuestos según el

momento y el estado del paciente. El modelo permite representar estas tendencias, lo que aporta al clínico una referencia más completa para valorar posibles cambios.

En los escenarios simulados, la PaCO_2 y la Crs apenas varían, mientras que la PaO_2 es más sensible a los cambios de PEEP. Esto sugiere que, al menos en los casos analizados, el principal efecto del ajuste recae sobre la oxigenación. Aunque estos ejemplos son limitados, muestran el potencial del modelo para anticipar la respuesta a cambios de PEEP en distintos contextos clínicos.

Las simulaciones se han realizado con la configuración “30 Minutes Blinded”. Esto significa que predicen el efecto de un ajuste de PEEP con un horizonte temporal de 30 a 60 minutos. Este intervalo es relevante. Por un lado, deja tiempo suficiente para que PaO_2 , PaCO_2 y Crs alcancen un nuevo estado estable tras el cambio. Por otro, es lo bastante corto para que la predicción sea útil en la práctica clínica.

Más allá de los tres ejemplos mostrados, este enfoque tiene un gran potencial. Permite anticipar de forma individualizada la respuesta a cambios de PEEP y reducir la dependencia de ajustes basados en prueba y error. En un hospital con sistemas de monitorización y registro adecuados, podría ayudar a realizar cambios más rápidos y seguros, disminuir riesgos de atelectrauma o sobredistensión y optimizar la oxigenación de forma personalizada.

6.4. Comparación con otros estudios.

El presente trabajo sigue un enfoque metodológico muy próximo al descrito por (Händel et al., 2024). Se utilizó la misma base de datos, MIMIC-III (A. Johnson et al., 2016). Se aplicó un preprocesamiento equivalente de las variables, empleando también las configuraciones de entrada “All Data” y “30 Minutes Blinded”. Esta similitud metodológica nos permite comparar directamente los resultados de ambos trabajos y analizar en qué medida coinciden o difieren las métricas obtenidas.

En el trabajo de Händel et al., aunque inicialmente se evaluó una FNN multitarea, finalmente se optó por presentar únicamente los resultados de la FNN individual y RF. Esto es porque al observó en estos modelos un mejor rendimiento en la predicción de las variables objetivo. Por este motivo, en la comparación cuantitativa únicamente se incluyen los resultados para RF y FNN.

En la Tabla 6.1 se muestran las métricas MAE y MAPE obtenidas en cada uno de los modelos para ambas configuraciones.

		(Händel et al., 2024)			Este trabajo		
		FNN	FNN multitarea	RF	FNN	FNN multitarea	RF
“All Data”							
PaO ₂ (mmHg)	MAE	26,61	—	26,69	32,05	28,35	21,04
	MAPE	20,64 %	—	20,79 %	23,53 %	22,39 %	16,70 %
PaCO ₂ (mmHg)	MAE	4,251	—	4,398	4,36	4,53	2,78
	MAPE	9,95 %	—	10,26 %	10,84 %	11,28 %	6,76 %
Crs (mL/cmH ₂ O)	MAE	4,805	—	4,924	3,43	3,70	1,86
	MAPE	15,73 %	—	15,94 %	13,51 %	15,64 %	6,71 %
“30 Minutes Blinded”							
PaO ₂ (mmHg)	MAE	27,32	—	27,62	32,59	28,35	26,57
	MAPE	21,67 %	—	21,79 %	24,19 %	22,44 %	21,24 %
PaCO ₂ (mmHg)	MAE	4,285	—	4,453	4,32	4,52	3,95
	MAPE	10,02 %	—	10,37 %	10,62 %	11,23 %	9,69 %
Crs (mL/cmH ₂ O)	MAE	4,804	—	4,938	3,57	3,71	3,22
	MAPE	15,82 %	—	16,07 %	14,62 %	15,47 %	13,27 %
“60 Minutes Blinded”							
PaO ₂ (mmHg)	MAE	—	—	—	33,36	29,60	27,33
	MAPE	—	—	—	24,70 %	24,04 %	22,01 %
PaCO ₂ (mmHg)	MAE	—	—	—	4,32	4,35	4,01
	MAPE	—	—	—	10,50 %	10,60 %	9,83 %
Crs (mL/cmH ₂ O)	MAE	—	—	—	3,56	3,72	3,28
	MAPE	—	—	—	14,81 %	15,39 %	13,51 %

Tabla 6.1. Comparación de MAE y MAPE entre Händel et al. y este trabajo para FNN, FNN multitarea y RF en las configuraciones “All Data”, “30 Minutes Blinded” y “60 Minutes Blinded”.

En términos generales, los resultados de este trabajo se sitúan en valores muy próximos a los publicados por Händel et al. Las ligeras diferencias detectadas pueden deberse a variaciones en el muestreo, la implementación o el entorno de ejecución.

En el análisis de importancia de variables, en ambos trabajos se utilizó PI. Sin embargo, en el estudio de Händel et al. no se emplearon valores de Shapley. Los autores no proporcionan el ranking completo de variables para cada modelo y variable objetivo, pero sí describen de forma cualitativa los predictores más relevantes.

Para la predicción de cada variable objetivo, su medición más reciente se situó entre las de mayor peso, acompañada de variables estrechamente relacionadas.

En PaO_2 , ambos estudios identificaron a FiO_2 como predictor clave junto al valor previo de PaO_2 . En PaCO_2 , coincidimos en la relevancia del VTset y la RRset, aunque el orden y peso relativo de estos factores difirió entre modelos. En Crs, los dos trabajos señalaron al VTset y a la Ppeakinsp como variables destacadas.

En conjunto, los resultados de PI obtenidos en este trabajo reproducen las tendencias generales descritas por Händel et al., manteniendo la lógica fisiológica.

En relación con la simulación de ajustes de PEEP, los patrones observados en este trabajo coincidieron con los descritos por Händel et al. En ambos casos se identificaron respuestas heterogéneas de PaO_2 ante cambios en la PEEP. Entre estas se encuentran incrementos sostenidos, disminuciones progresivas y curvas no monótonas con valores óptimos intermedios. En línea con lo observado en el estudio original, las simulaciones mostraron que PaCO_2 y Crs presentaron cambios menores o poco significativos en la mayoría de escenarios. Esto sugiere una menor sensibilidad de estas variables a variaciones de PEEP a corto plazo.

Respecto a otros estudios revisados en el estado del arte, no es posible establecer comparaciones directas debido a las diferencias en objetivos y metodología. Trabajos como los de Ghazal et al. (2019), Luo et al. (2016), Peine et al. (2021) o Komorowski et al. (2018) abordan problemas distintos dentro del ámbito de la IA en entornos críticos.

6.5. Limitaciones.

Este trabajo presenta diversas limitaciones que deben considerarse al interpretar los resultados y al valorar su aplicabilidad clínica.

En primer lugar, la base de datos utilizada fue exclusivamente MIMIC-III (A. Johnson et al., 2016). Esto implica que tanto el entrenamiento como la evaluación del modelo se realizaron en un único entorno hospitalario, con unas características poblacionales concretas y unas prácticas clínicas determinadas. Aunque es amplia y diversa, su procedencia de un único sistema de salud condiciona la generalización de los resultados a otros hospitales o regiones con protocolos, recursos y perfiles de pacientes diferentes. Por ejemplo, la implementación en contextos europeos podría verse limitada por diferencias en la estrategia ventilatoria, como un mayor uso de modos controlados por presión.

Además, no se realizó una validación externa con una base de datos independiente. La ausencia de este paso impide estimar el rendimiento del modelo en contextos clínicos diferentes. Este aspecto se ve reforzado por la antigüedad de los datos de MIMIC-III (2001 a 2012). No reflejan cambios recientes en la demografía de los pacientes, en los protocolos de cuidados intensivos ni en el equipamiento empleado.

Asimismo, no se emplearon otras bases de datos disponibles, como eICU (Pollard et al., 2019), ya que la incorporación de múltiples fuentes excedía el alcance y la viabilidad establecidos para este trabajo.

También, la calidad y disponibilidad de las variables dependen de los registros clínicos originales, que contienen datos ausentes, valores anómalos o anotaciones inconsistentes. Aunque se aplicaron estrategias de imputación y normalización para mitigar estos problemas, dichas técnicas no sustituyen a mediciones reales y pueden introducir sesgos. Esto es porque la frecuencia y el número de mediciones de cada variable varían entre pacientes. Aunque el tipo de variable registrada sea el mismo para todos, en algunos casos hay muchas mediciones y en otros muy pocas o más espaciadas en el tiempo. Esto hace que el modelo disponga de distinta cantidad de información según el paciente, lo que puede influir en cómo aprende los patrones y en la precisión de sus predicciones.

Adicionalmente, el conjunto de variables empleadas corresponde a las que se registran de forma rutinaria en la UCI y están disponibles en la base de datos. El objetivo es que el modelo pueda estimar la PEEP óptima con la información habitual de seguimiento de los pacientes. La inclusión de parámetros como la presión esofágica,

índices de reclutamiento alveolar o imágenes dinámicas de ventilación podría haber ofrecido estimaciones más robustas. Sin embargo, estos datos requieren procedimientos y recursos que no están disponibles en todos los entornos clínicos.

Además, los modelos utilizados tienen una arquitectura sencilla. No se exploraron configuraciones más complejas. Esto facilita la implementación y reduce el tiempo de entrenamiento. Sin embargo, el uso de arquitecturas más avanzadas o un ajuste más detallado de los parámetros podría mejorar el rendimiento en futuros desarrollos.

En cuanto a la interpretabilidad, se usaron PI y valores de Shapley para identificar qué variables influyen más en las predicciones. Estas técnicas no muestran si una variable provoca directamente un cambio en el resultado, sino cuánto la utiliza el modelo para predecir. Cuando dos variables están muy relacionadas entre sí, su importancia individual puede verse reducida. En PI, esto ocurre porque al alterar una variable la otra sigue aportando casi la misma información. En valores de Shapley, la contribución tiende a repartirse entre ambas. Por este motivo, la relevancia de cada variable se ve limitada a interpretarse con cautela y siempre junto al contexto clínico.

.

Capítulo 7. Conclusiones y líneas futuras.

A lo largo de este TFG, se ha investigado el uso de modelos de IA para predecir y simular el efecto de la PEEP en pacientes con VM. El estudio se ha basado en datos rutinarios de pacientes ingresados en UCI de la base MIMIC-III. Una vez alcanzados los objetivos principales, este capítulo presenta las contribuciones realizadas, las conclusiones extraídas y varias líneas de investigación que podrían explorarse en trabajos futuros.

7.1. Contribuciones.

En este trabajo se han conseguido varias aportaciones relevantes en el ámbito de la VM y la optimización de la PEEP mediante ML. Estas contribuciones pueden resumirse en los siguientes puntos:

- Se han implementado y comparado tres modelos predictivos: una FNN individual, una FNN multitarea y un RF. El objetivo ha sido estimar los valores de PaO_2 , PaCO_2 y Crs en diferentes configuraciones de entrada.
- Se han realizado análisis de interpretabilidad mediante PI y valores de Shapley. Estos han permitido identificar las variables clínicas más influyentes en cada modelo y configuración. Así, se ha mejorado la transparencia y comprensión del comportamiento predictivo.
- Se ha desarrollado una herramienta de simulación que estima, de forma individualizada, el efecto de distintos niveles de PEEP sobre los parámetros de ventilación. Esta herramienta facilita la identificación de un rango óptimo de PEEP adaptado a cada paciente.

7.2. Conclusiones.

De los resultados obtenidos en este trabajo se extraen las siguientes conclusiones principales:

- RF ha sido el modelo con mejor rendimiento global en la predicción de las tres variables objetivo, superando de forma consistente a las NN en todas las configuraciones. Este comportamiento sugiere que, para el tipo de datos y

número de muestras empleados, los modelos de tipo *ensamble* pueden ofrecer una mayor estabilidad en la predicción.

- La reducción de datos recientes en las configuraciones *blinded* ha aumentado de forma moderada el error de predicción en la mayoría de los modelos. Sin embargo, no ha modificado las tendencias generales de rendimiento.
- El análisis de importancia de variables ha permitido identificar los parámetros clínicos con mayor peso en las predicciones de cada modelo y configuración. Estos resultados han aportado interpretabilidad al sistema, facilitando la comprensión de las relaciones entre variables de entrada y la respuesta ventilatoria. Así, se consigue aumentar la confianza en su aplicación clínica.
- Las simulaciones de respuesta a la PEEP han mostrado que la PaO_2 es la variable más sensible a los cambios en este parámetro. En contraste, PaCO_2 y Crs han mostrado variaciones menores ante modificaciones moderadas de la PEEP. Este patrón confirma que la principal influencia de la PEEP a corto plazo se produce sobre la oxigenación. Otros efectos requieren periodos de observación más prolongados o intervenciones de mayor magnitud para ser detectables.
- La herramienta de simulación desarrollada ha permitido anticipar el rango de PEEP potencialmente óptimo para cada caso, reduciendo la necesidad de ajustes por ensayo y error. Su aplicación en un contexto clínico podría contribuir a optimizar la oxigenación y a minimizar riesgos como la sobredistensión o el colapso alveolar.

En conjunto, el trabajo ha cumplido los objetivos propuestos. Se ha demostrado que un enfoque basado en IA puede predecir y simular de forma no invasiva el efecto de la PEEP. Además, se ha planteado una metodología adaptable a diferentes entornos clínicos. Cuenta con potencial para integrarse en sistemas de soporte a la decisión y favorecer una VM más segura y personalizada.

7.3. Líneas futuras.

Durante el desarrollo de este TFG, se han identificado varias áreas de interés que pueden ser objeto de un análisis más profundo en futuras investigaciones:

- En primer lugar, sería conveniente validar los modelos con bases de datos más recientes y de diferentes entornos clínicos. Esto permitiría comprobar su

capacidad de generalización y su adaptación a distintas poblaciones y protocolos de ventilación.

- Sería interesante incorporar nuevas variables clínicas rutinarias no incluidas en este estudio. Por ejemplo, parámetros adicionales de gases arteriales o promedios de ventilación a lo largo de intervalos prolongados. Su adición podría mejorar la precisión sin aumentar la complejidad de adquisición de datos.
- Por último, se propone desarrollar una herramienta de apoyo a la decisión clínica en tiempo real. El modelo se integraría en un entorno hospitalario y se validaría mediante estudios prospectivos. Esto permitiría evaluar su impacto en la práctica clínica y su aceptación por parte del personal sanitario.

La aplicación de estas mejoras podría aumentar la precisión del modelo, facilitar su adopción en la práctica clínica y contribuir a una VM más segura y personalizada.

Anexo.

8.1. Gráficas SHAP de importancia de variables

En este apartado se muestran las gráficas de importancia de variables obtenidas a partir de los valores de Shapley para los distintos modelos desarrollados. Complementan el análisis presentado en el capítulo de Resultados.

8.1.1. Configuración “All Data”

FNN




Figura A.1. Importancia de variables basada en valores de Shapley para el modelo FNN en la predicción de PaO₂ — configuración “All Data”.




Figura A.2. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaCO₂ — configuración “All Data”.




Figura A.3. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de Crs — configuración “All Data”.

FNN multitarea




Figura A.4. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaO_2 — configuración “All Data”.




Figura A.5. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaCO_2 — configuración “All Data”.




Figura A.6. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de Crs — configuración “All Data”.

RF




Figura A.7. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaO₂ — configuración “All Data”.




Figura A.8. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaCO₂ — configuración “All Data”.




Figura A.9. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de Crs — configuración “All Data”.

8.1.2. Configuración “30 Minutes Blinded”

FNN




Figura A.10. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaO₂ — configuración "30 Minutes Blinded".




Figura A.11. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaCO₂ — configuración "30 Minutes Blinded".




Figura A.12. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de Crs — configuración “30 Minutes Blinded”.

FNN multitarea




Figura A.13. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaO₂ — configuración “30 Minutes Blinded”.




Figura A.14. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaCO_2 — configuración “30 Minutes Blinded”.




Figura A.15. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de Crs — configuración “30 Minutes Blinded”.


RF

Figura A.16. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaO₂ — configuración “30 Minutes Blinded”.




Figura A.17. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaCO₂ — configuración “30 Minutes Blinded”.




Figura A.18. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de Crs — configuración “30 Minutes Blinded”.

8.1.3. Configuración “60 Minutes Blinded”

FNN




Figura A.19. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaO_2 — configuración “60 Minutes Blinded”.




Figura A.20. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de PaCO_2 — configuración “60 Minutes Blinded”.




Figura A.21. Importancia de variables basada en valores de Shapley para el modelo de FNN en la predicción de Crs — configuración “60 Minutes Blinded”.

FNN multitarea




Figura A.22. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaO₂ — configuración “60 Minutes Blinded”.




Figura A.23. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de PaCO_2 — configuración “60 Minutes Blinded”.




Figura A.24. Importancia de variables basada en valores de Shapley para el modelo de FNN multitarea en la predicción de Crs — configuración “60 Minutes Blinded”.

RF




Figura A.25. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaO_2 — configuración “60 Minutes Blinded”.




Figura A.26. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de PaCO_2 — configuración “60 Minutes Blinded”.




Figura A.27. Importancia de variables basada en valores de Shapley para el modelo de RF en la predicción de Crs — configuración “60 Minutes Blinded”.

Bibliografía

- Abdelbaky, A. M., Elmasry, W. G., & Awad, A. H. (2025). Comparison Between Synchronized Intermittent Mandatory Ventilation (SIMV) and Adaptive Support Ventilation (ASV) on Patient Outcomes in Critically Ill Patients: A Systematic Review and Meta-Analysis. *Cureus*. <https://doi.org/10.7759/cureus.81165>
- Agarap, A. F. (2019). *Deep Learning using Rectified Linear Units (ReLU)*. <http://arxiv.org/abs/1803.08375>
- Aguilar, E. F., Ramos, Á. C. R., Flores, M. C., Alatorre, A. G., Barba, J. P., Carranco, J. B. V., Vargas, A. T., Alarcón, J. R., & Pintos, R. V. (2024). *Temas selectos en terapia intensiva pediátrica* (S. A. de C. V. Editorial Alfil, Ed.).
- Arnaldo, A., García, H., & Triolet Gálvez, A. (2002). MODOS DE VENTILACION MECANICA. In *Revista Cubana de Medicina Intensiva y Emergencias Rev Cub Med Int Emerg* (Vol. 1).
- Bertona, L. F. (2005). *ENTRENAMIENTO DE REDES NEURONALES*.
- Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197–227. <https://doi.org/10.1007/s11749-016-0481-7>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*.
- Bobadilla, J. (2021). *Machine Learning y Deep Learning Usando Python, Scikit y Keras Informática* (Ediciones de la U, Ed.).
- Breiman, L. (2001). *Random Forests* (Vol. 45).
- Cardoso, D. de F. F., de Lima, F. C., Teixeira, E., de Souza, E. R. C., de Santana, M. E., Simor, A., & Santos, A. L. S. dos. (2025). Nursing care for patients with tracheostomy in mechanical ventilation: educational video. *Cogitare Enfermagem*, 30. <https://doi.org/10.1590/ce.v30i0.98935>
- Carlucci, A., & Fusar Poli, B. (2023). Getting It Right in Restrictive Lung Disease. In *Journal of Clinical Medicine* (Vol. 12, Issue 10). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/jcm12103353>
- Caruana, R., Pratt, L., & Thrun, S. (1997). *Multitask Learning* (Vol. 28). Kluwer Academic Publishers.
- Castillo, E. G., Chicot Llano, M., Serrano, D. A. R., & Zamora García, E. (2014). Ventilación mecánica no invasiva e invasiva. In *Medicine* (Vol. 11, Issue 63).
- Castillo M, & Andrés E. (2017). PEDIATRIC INVASIVE MECHANICAL VENTILATION ARTÍCULOS ORIGINALES / ORIGINAL ARTICLES. In *Neumol Pediatr* (Vol. 12, Issue 1).
- Castuera Gil, A. I., Macías Bou, B., Cano Ballesteros, J. C., & Andueza Lillo, J. A. (2023). Asistencia ventilatoria de la insuficiencia respiratoria aguda en urgencias. Ventilación mecánica no invasiva y alto flujo nasal. *Medicine*, 13, 5231–5238.

- Chen, N., Xiong, C., Du, W., Wang, C., Lin, X., & Chen, Z. (2019). An improved genetic algorithm coupling a back-propagation neural network model (IGA-BPNN) for water-level predictions. *Water (Switzerland)*, 11(9). <https://doi.org/10.3390/w11091795>
- Cielo, C. M., & Marcus, C. L. (2014). Central hypoventilation syndromes. In *Sleep Medicine Clinics* (Vol. 9, Issue 1, pp. 105–118). W.B. Saunders. <https://doi.org/10.1016/j.jsmc.2013.10.005>
- Clínica Universidad de Navarra. (2025). *Compliance pulmonar*.
- Correa, L. S., Giraldo, B., Correa, R., Arini, P. D., & Laciari, E. (2014). *Estudio de la Pausa Espiratoria en Pacientes con Enfermedades Obstructivas en proceso de desconexión de la Ventilación Mecánica*.
- Cottin, V., & Cordier, J. F. (2009). The syndrome of combined pulmonary fibrosis and emphysema. In *Chest* (Vol. 136, Issue 1, pp. 1–2). American College of Chest Physicians. <https://doi.org/10.1378/chest.09-0538>
- de Vries, H., Jonkman, A., Shi, Z.-H., Spoelstra-de Man, A., & Heunks, L. (2018). Assessing breathing effort in mechanical ventilation: physiology and clinical implications. *Annals of Translational Medicine*, 6(19), 387–387. <https://doi.org/10.21037/atm.2018.05.53>
- Domor Mienye, I., & Jere, N. (2016). *A Survey of Decision Trees: Concepts, Algorithms, and Applications*. <https://doi.org/10.1109/ACCESS.2017.DOI>
- Dubey, S. R., Singh, S. K., & Chaudhuri, B. B. (2022). *Activation Functions in Deep Learning: A Comprehensive Survey and Benchmark*. <http://arxiv.org/abs/2109.14545>
- Ezugwu, A. E., Ikotun, A. M., Oyelade, O. O., Abualigah, L., Agushaka, J. O., Eke, C. I., & Akinyelu, A. A. (2022). A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects. In *Engineering Applications of Artificial Intelligence* (Vol. 110). Elsevier Ltd. <https://doi.org/10.1016/j.engappai.2022.104743>
- Fisher, A., Rudin, C., & Dominici, F. (2019). *All Models are Wrong, but Many are Useful: Learning a Variable's Importance by Studying an Entire Class of Prediction Models Simultaneously*.
- Gestal, M. (2014). *Introducción a las Redes de Neuronas Artificiales*. <https://www.researchgate.net/publication/242099672>
- Ghazal, S., Sauthier, M., Brossier, D., Bouachir, W., Jouvet, P. A., & Noumeir, R. (2019). Using machine learning models to predict oxygen saturation following ventilator support adjustment in critically ill children: A single center pilot study. *PLoS ONE*, 14(2). <https://doi.org/10.1371/journal.pone.0198921>
- Gómez Mendoza, R. A., Carrillo Esper, R., & González Moreno, F. J. (2024). *Medicina crítica* (Editorial Alfíl, Ed.).

- Grinsztajn, L., Oyallon, E., & Varoquaux, G. (2022). Why do tree-based models still outperform deep learning on typical tabular data? In S. Koyejo, S. Mohamed, A. Agarwal, D. Belgrave, K. Cho, & A. Oh (Eds.), *Advances in Neural Information Processing Systems* (Vol. 35, pp. 507–520). Curran Associates, Inc. https://proceedings.neurips.cc/paper_files/paper/2022/file/0378c7692da36807bdec87ab043cdadc-Paper-Datasets_and_Benchmarks.pdf
- Grippi, M. A. (2020). *¿Cómo se relacionan la PaCO₂ y la ventilación minuto?* MED Mastery.
- Guo, C., & Berkhahn, F. (2016). *Entity Embeddings of Categorical Variables*. <http://arxiv.org/abs/1604.06737>
- Händel, C., Frerichs, I., Weiler, N., & Bergh, B. (2024). Prediction and simulation of PEEP setting effects with machine learning models. *Medicina Intensiva (English Edition)*, 48(4), 191–199. <https://doi.org/10.1016/j.medine.2023.09.005>
- Helm, J. M., Swiergosz, A. M., Haeberle, H. S., Karnuta, J. M., Schaffer, J. L., Krebs, V. E., Spitzer, A. I., & Ramkumar, P. N. (2020). Machine Learning and Artificial Intelligence: Definitions, Applications, and Future Directions. In *Current Reviews in Musculoskeletal Medicine* (Vol. 13, Issue 1, pp. 69–76). Springer. <https://doi.org/10.1007/s12178-020-09600-8>
- Hickey, S. M., Sankari, A., Al, :, & Giwa, O. (2024). *Ventilación mecánica*.
- Isasi Viñuela, P., & Galván León, I. M. (2004). *Redes de neuronas artificiales: un enfoque práctico* (Pearson Educación, Ed.).
- Izaurieta, F., & Saavedra, C. (2000). *Redes Neuronales Artificiales*.
- Jiang, Q., Jin, X., Lee, S. J., & Yao, S. (2017). Protein secondary structure prediction: A survey of the state of the art. In *Journal of Molecular Graphics and Modelling* (Vol. 76, pp. 379–402). Elsevier Inc. <https://doi.org/10.1016/j.jmgm.2017.07.015>
- Johnson, A. E. W., Pollard, T. J., Shen, L., Lehman, L. W. H., Feng, M., Ghassemi, M., Moody, B., Szolovits, P., Anthony Celi, L., & Mark, R. G. (2016). MIMIC-III, a freely accessible critical care database. *Scientific Data*, 3. <https://doi.org/10.1038/sdata.2016.35>
- Johnson, A., Pollard, T., & Mark, R. (2016). *Base de datos clínica MIMIC-III*. <https://doi.org/10.13026/C2XW26>
- José Tincani, A., Oscar Noguera Servin, S., Barreto, G., Cláudio Martins, L., Mello Moreira, M., Meirelles, L., Alexandre Colli Neto, J., & Hélio Zen Júnior, J. (2011). Atraumatic Endotracheal Tube for Mechanical Ventilation. In *Revista Brasileira de Anestesiologia* (Vol. 311).
- Komorowski, M., Celi, L. A., Badawi, O., Gordon, A. C., & Faisal, A. A. (2018). The Artificial Intelligence Clinician learns optimal treatment strategies for sepsis in intensive care. *Nature Medicine*, 24(11), 1716–1720. <https://doi.org/10.1038/s41591-018-0213-5>

- Laaban, J.-P., Ayed, M. Ben, & Fevrier, M.-J. (2020). *Mandatory Minute Volume Ventilation Principle of Operation*.
- Laaban, J.-P., Ayed, M. Ben, & Fevrier, M.-J. (2023). *Mandatory Minute Volume Ventilation Principle of Operation*.
- Lao-León, Y. O., Rivas-Méndez, A., Pérez-Pravia, M. C., & Marrero-Delgado, F. (2017). Procedimiento para el pronóstico de la demanda mediante redes neuronales artificiales. *Ciencias Holguín*, 23, 49–53.
- Lopez, R. (2015). *Powered by Pelican Machine Learning con Python*.
- Lundberg, S. M., Allen, P. G., & Lee, S.-I. (2017). *A Unified Approach to Interpreting Model Predictions*. <https://github.com/slundberg/shap>
- Luo, P., Wang, X., Shao, W., & Peng, Z. (2019). *Towards Understanding Regularization in Batch Normalization*. <http://arxiv.org/abs/1809.00846>
- Luo, Y., Szolovits, P., Dighe, A. S., & Baron, J. M. (2016). Using machine learning to predict laboratory test results. *American Journal of Clinical Pathology*, 145(6), 778–788. <https://doi.org/10.1093/ajcp/aqw064>
- Martinez, C. H., Okajima, Y., Yen, A., Maselli, D. J., Nardelli, P., Rahaghi, F., Young, K., Kinney, G., Hatt, C., Galban, C., Washko, G. R., Han, M. L., Estépar, R. S. J., & Diaz, A. A. (2021). Paired CT Measures of Emphysema and Small Airways Disease and Lung Function and Exercise Capacity in Smokers with Radiographic Bronchiectasis. *Academic Radiology*, 28(3), 370–378. <https://doi.org/10.1016/j.acra.2020.02.013>
- Misseri, G., Piattoli, M., Cuttone, G., Gregoretti, C., & Bignami, E. G. (2024). Artificial Intelligence for Mechanical Ventilation: A Transformative Shift in Critical Care. *Therapeutic Advances in Pulmonary and Critical Care Medicine*, 19. <https://doi.org/10.1177/29768675241298918>
- Molnar, C. (2025). *Interpretable Machine Learning A Guide for Making Black Box Models Explainable*. <http://leanpub.com/interpretable-machine-learning>
- Oliver, P., Rodríguez, O., Marín, J. L., Muñoz, M., Guillén, E., Valcárcel, G., Galán, A., & Rodríguez Cantalejo, F. (2014). *Estudio de la oxigenación e interpretación de la gasometría arterial*.
- Ondiviela, D. T. (2024). *Machine Learning: Regresión logística multiclase y aplicación para la clasificación de terrenos*.
- Orenes, Y., Rabasa, A., Rodriguez-Sala, J. J., & Sanchez-Soriano, J. (2021). Benchmarking analysis of the accuracy of classification methods related to entropy. *Entropy*, 23(7). <https://doi.org/10.3390/e23070850>
- Ossai, C. I., & Wickramasinghe, N. (2021). Intelligent decision support with machine learning for efficient management of mechanical ventilation in the intensive care unit – A critical overview. In *International Journal of Medical Informatics* (Vol. 150). Elsevier Ireland Ltd. <https://doi.org/10.1016/j.ijmedinf.2021.104469>

- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., & Cournapeau, D. (2024). *Árboles de decisión*. Scikit-Learn. https://scikit-learn.org/stable/modules/tree.html?utm_source=chatgpt.com
- Pedro Martinez-Pitre, A. J., Sabbula, B. R., & Cascella Affiliations, M. (2023). *Restrictive Lung Disease Continuing Education Activity*.
- Peine, A., Hallawa, A., Bickenbach, J., Dartmann, G., Fazlic, L. B., Schmeink, A., Ascheid, G., Thiemermann, C., Schuppert, A., Kindle, R., Celi, L., Marx, G., & Martin, L. (2021). Development and validation of a reinforcement learning algorithm to dynamically optimize mechanical ventilation in critical care. *Npj Digital Medicine*, 4(1). <https://doi.org/10.1038/s41746-021-00388-6>
- PhysioNet. (2025). *PhysioNet*. <https://physionet.org>
- Pollard, T., Johnson, A., Raffa, J., Celi, L. A., Badawi, O., & Mark, R. (2019). *Base de datos de investigación colaborativa de eICU*. <https://doi.org/10.13026/C2WM1R>
- Popat, B., & Jones, A. T. (2012). *Invasive and non-invasive mechanical ventilation*.
- Puppo, K. H., Fernández, B. R., Gonzalo Hidalgo, K., Fernández, R., & Av, A. (2021). FISIOLÓGIA RESPIRATORIA FISIOLÓGIA DE LOS MÚSCULOS DE LA RESPIRACIÓN PHYSIOLOGY OF THE RESPIRATORY MUSCLES SECCIÓN SERIE / SERIES. In *Neumol Pediatr* (Vol. 16, Issue 4). www.neumologia-pediatrica.cl
- Ramos Gómez, L. A. (2012). *Fundamentos de la ventilación mecánica* (S. Benito Vales, Ed.). Marge Medica Books.
- Rojas, E. M. (2020). *Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo*.
- Rozemberczki, B., Watson, L., Bayer, P., Yang, H.-T., Kiss, O., Nilsson, S., & Sarkar, R. (2022). *The Shapley Value in Machine Learning*. <https://github.com/AstraZeneca/awesome-shapley-value>.
- Salas Flores, R., González Pérez, B., De León Escobedo, R., & Altamira García, J. (2024). *Inteligencia artificial y educación médica: Un análisis futurista*. Editorial Fontamara, S.A. de C.V. <https://doi.org/10.29059/luat.398>
- Shillan, D., Sterne, J. A. C., Champneys, A., & Gibbison, B. (2019). Use of machine learning to analyse routinely collected intensive care unit data: A systematic review. *Critical Care*, 23(1). <https://doi.org/10.1186/s13054-019-2564-9>
- Singer, B. D., & Corbridge, T. C. (2011). Pressure modes of invasive mechanical ventilation. In *Southern Medical Journal* (Vol. 104, Issue 10, pp. 701–709). <https://doi.org/10.1097/SMJ.0b013e31822da7fa>
- Sitio Big Data. (2019). *Árbol de decisión en Machine Learning*.
- Spatenkova, V., Mlcek, M., Mejstrik, A., Cisar, L., & Kuriscak, E. (2024). Standard versus individualised positive end-expiratory pressure (PEEP) compared by electrical

- impedance tomography in neurocritical care: a pilot prospective single centre study. *Intensive Care Medicine Experimental*, 12(1). <https://doi.org/10.1186/s40635-024-00654-3>
- Swindin, J., Sampson, C., & Howatson, A. (2020). Airway pressure release ventilation. In *BJA Education* (Vol. 20, Issue 3, pp. 80–88). Elsevier Ltd. <https://doi.org/10.1016/j.bjae.2019.12.001>
- Tangirala, S. (2020). Evaluating the impact of GINI index and information gain on classification using decision tree classifier algorithm. *International Journal of Advanced Computer Science and Applications*, 2, 612–619. <https://doi.org/10.14569/ijacsa.2020.0110277>
- Van Oosten, J. P., Akoumianaki, E., & Jonkman, A. H. (2025). Monitoring respiratory muscles effort during mechanical ventilation. In *Current Opinion in Critical Care* (Vol. 31, Issue 1, pp. 12–20). Lippincott Williams and Wilkins. <https://doi.org/10.1097/MCC.0000000000001229>
- Ying, X. (2019). An Overview of Overfitting and its Solutions. *Journal of Physics: Conference Series*, 1168(2). <https://doi.org/10.1088/1742-6596/1168/2/022022>
- Zarzuela, M. M. (2023). *Introducción a las Redes Neuronales Artificiales*.
- Zersen, K. M. (2023). Setting the optimal positive end-expiratory pressure: a narrative review. In *Frontiers in Veterinary Science* (Vol. 10). Frontiers Media SA. <https://doi.org/10.3389/fvets.2023.1083290>
- Zhang, C., & Ma, Y. (2012). *Ensemble Machine Learning*.