

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO DE FIN DE MÁSTER

DISEÑO DE UN SISTEMA DE DETECCIÓN TEMPRANA DE OBSTRUCCIÓN DEL TUBO ENDOTRAQUEAL EN PACIENTES COVID-19 BASADO EN MACHINE LEARNING

Titulación: Máster Universitario en Ingeniería de Telecomunicación

Autora: Elena Encinas Pérez

Tutores: Dr. Juan Luis Navarro Mesa

Dr. Antonio Gabriel Ravelo García

Francisco José Suárez Díaz

Fecha: Julio de 2022

AGRADECIMIENTOS

Tras seis años de estudio entre grado y máster, llega la hora de presentar el esperado Trabajo de Fin de Máster, el cierre de otra etapa más, pero el inicio también de otras muchas que están por llegar. Pero a veces me hago una pregunta, “¿Cómo he llegado yo hasta aquí?”. La primera respuesta que se me viene a la cabeza suele ser “No tengo ni idea”. Luego, intento ir un poco más allá en mi cabeza para intentar encontrar una respuesta con un poco más de coherencia. No he llegado hasta aquí yo sola, tampoco con las mismas personas que estaban cuando empecé, pero todas las que en algún momento han estado, por mínimo que fuera, han aportado algo al proceso. Desde la gente que conocí aquella tarde mientras paseaba sola intentando aliviar el estrés y que consiguieron sacarme una sonrisa, o aquellos largos domingos con Lucía surfeando (o intentándolo) mientras me desahogaba entre ola y ola; hasta aquellos que me han estado aguantando un poco más en el día a día de mi evolución. Mamá, papá, Javi, Miriam, Sonia, Jorge, Aron... son solo algunas de las personas que aún no sé cómo no se han cansado de mí y de mis quejas. Que no falte tampoco la mención a mi abuela Pilar, ya que muchas veces he sobrevivido largas horas de estudio gracias a sus queques, sus quesos y todo lo que se le ocurra darme.

Estoy segura de que todas estas personitas, en mayor o menor medida, son los responsables de que siempre consiga todo aquello que me propongo. Así que creo que la respuesta correcta a la pregunta inicial sería: “¡Gracias a ustedes!”

Por último, un poco más centrado en el ámbito profesional, agradecer al CHUIMI por ceder los datos de sus pacientes haciendo posible el desarrollo de este TFM. Y obviamente nada de esto habría salido tan bien sin la ayuda de mis tutores, Antonio Ravelo, Francisco Suárez, y en especial, Juan Luis Navarro, con quien he trabajado más mano a mano y que siempre me ha ayudado en todo lo habido y por haber. Gracias por todo, tanto en lo personal como en lo profesional.

RESUMEN

Fue el 11 de marzo cuando la OMS (Organización Mundial de la Salud) declaró la pandemia mundial debido a la aparición de un virus denominado SARS-CoV-2. Es una enfermedad capaz de ocasionar complicaciones graves o fatales como la obstrucción de la tráquea y los bronquios de los pacientes durante su estancia en UCI, con una tasa de mortalidad cercana al 30%. Una obstrucción endotraqueal es una de las situaciones más difíciles que los médicos deben afrontar y resolver. Por lo tanto, es muy importante saber de antemano cuándo un paciente con COVID-19 podría entrar en la fase de pre-obstrucción. Este problema fue planteado por doctores de la Unidad de Medicina Intensiva del Complejo Hospitalario Universitario Insular Materno Infantil (CHUIMI) de Gran Canaria, y gracias al Colegio Oficial de Médicos de Las Palmas y a la Universidad de Las Palmas de Gran Canaria, se han podido financiar una serie de proyectos de este marco de investigación, donde se incluye el TFM en cuestión. Este trabajo de investigación se centra en el desarrollo de un algoritmo para la detección precoz de la obstrucción del tubo endotraqueal en pacientes con COVID ingresados en UCI (Unidad de Cuidados Intensivos). Los resultados obtenidos del estudio, a pesar de estar basado en un banco de datos de reducido tamaño debido a la reciente situación, indican que nuestra propuesta apunta a un sistema de predicción inteligente eficiente que busca dar respuesta a este importante problema de salud. El estudio concluye demostrando que los sistemas desarrollados son capaces de predecir con suficiente credibilidad si un paciente será obstructivo o no, pudiendo diferenciar, dentro de aquellos considerados obstructivos, el cambio de la fase normal frente al comienzo de la obstrucción o su inicio inminente.

ABSTRACT

On 11th March, the world pandemic was declared by the WHO (World Health Organization) due to the appearance of a virus called SARS-CoV-2. It is a disease capable of causing serious or fatal complications such as obstruction of the trachea and bronchi of patients during their ICU stay, with a mortality rate close to 30%. An endotracheal obstruction is one of the most difficult situations that physicians must deal with and resolve. Therefore, it is very important to know in advance when a COVID-19 patient could enter in the pre-obstruction phase. This problem was raised by doctors from the Intensive Medicine Unit of the Maternal and Child Insular University Hospital Complex in Gran Canaria, and thanks to the Official College of Physicians of Las Palmas and the University of Las Palmas de Gran Canaria, they have been able to finance a series of projects in this research area, where this TFM is included. This research work focuses on the development of an algorithm for the early detection of endotracheal tube obstruction in patients with COVID admitted to the ICU (Intensive Care Unit). The results obtained from the study, despite having a very small database because of the recent situation, indicate that our proposal aims at an efficient intelligent prediction system, which seeks to respond to this healthy problem. The study concludes showing the systems developed can predict with sufficient credibility whether a patient will be obstructive or not, being able to differentiate, within those considered obstructive, the change in the normal phase versus the onset of obstruction or its imminent onset.

ÍNDICE GENERAL

PARTE I

AGRADECIMIENTOS	VII
CAPÍTULO 1. INTRODUCCIÓN	1
1.1 OBJETIVO	2
1.2 ORGANIZACIÓN DE LA MEMORIA	4
CAPÍTULO 2. FUNDAMENTOS TEÓRICOS	7
2.1 INFORMACIÓN EPIDEMIOLÓGICA	7
2.1.1 <i>Evolución de la pandemia en España</i>	8
2.1.2 <i>Fuente de infección</i>	11
2.1.3 <i>Transmisión</i>	12
2.1.3.1 Mecanismo de transmisión humano-humano	12
2.1.4 <i>Letalidad</i>	13
2.2 MECÁNICA RESPIRATORIA	15
2.2.1 <i>Sistema Respiratorio</i>	15
2.2.2 <i>Fisiología del sistema respiratorio</i>	18
2.2.2.1 Proceso de respiración	18
2.3 MECÁNICA VENTILATORIA EN PACIENTES UCI	20
2.3.1 <i>Introducción a la mecánica ventilatoria</i>	20
2.3.1.1 Patrones de la curva de ventilación	23
2.4 INTUBACIÓN ENDOTRAQUEAL	25
2.4.1 <i>Técnica</i>	25
2.4.2 <i>Colocación del paciente</i>	26
2.4.3 <i>Colocación del operador</i>	26
2.4.4 <i>Tubo endotraqueal</i>	27
2.4.5 <i>Traqueobronquitis necrosante</i>	27
2.4.5.1 Traqueobronquitis necrosante en pacientes COVID-19	28
CAPÍTULO 3. PREPARACIÓN DEL ENTORNO DE TRABAJO	33
3.1 FUENTE DE DATOS EMPLEADA	33

3.1.1	<i>Datos de pacientes</i>	33
3.1.2	<i>Características empleadas</i>	35
3.1.2.1	Características de Mecánica Ventilatoria	35
3.1.2.2	Características Fisiológicas	36
3.2	EXTRACCIÓN DE CARACTERÍSTICAS TEMPORALES	38
3.3	HERRAMIENTA DE RECOLECCIÓN DE DATOS	39
 CAPÍTULO 4. ASPECTOS TEÓRICOS SOBRE ALGORITMOS DE MACHINE LEARNING APLICADOS A LA DETECCIÓN TEMPRANA DE OBSTRUCCIÓN DEL TUBO ENDOTRAQUEAL		41
<hr/>		
4.1	INTRODUCCIÓN	41
4.1.1	<i>Breve historia de la inteligencia artificial</i>	43
4.2	INTRODUCCIÓN AL APRENDIZAJE MÁQUINA	45
4.2.1	<i>Formas de aprendizaje</i>	47
4.3	ALGORITMOS DE APRENDIZAJE MÁQUINA	49
4.4	REDES BAYESIANAS	51
4.4.1	<i>Definición de red bayesiana</i>	51
4.4.2	<i>Aprendizaje de clasificadores bayesianos</i>	52
4.4.3	<i>Aprendizaje de redes bayesianas</i>	53
4.4.4	<i>Aplicación del teorema de Bayes en clasificación</i>	54
4.4.4.1	El paradigma Naïve Bayes	55
 CAPÍTULO 5. ALGORITMO DE DETECCIÓN TEMPRANA DE OBSTRUCCIÓN DEL TUBO ENDOTRAQUEAL EN PACIENTES COVID-19		63
<hr/>		
5.1	INTRODUCCIÓN	63
5.2	PARÁMETROS DE CALIDAD	64
5.2.1	<i>Parámetros de calidad basados en la matriz de confusión</i>	64
5.3	SELECCIÓN DE PACIENTES Y CARACTERÍSTICAS	67
5.4	MÓDULO DE APRENDIZAJE	74
5.5	MONITORIZACIÓN DE PACIENTES POTENCIALMENTE OBSTRUCTIVOS	76
5.6	IDENTIFICACIÓN TEMPRANA DE EVENTOS DE PRE-OBSTRUCCIÓN	79
 CAPÍTULO 6. EXPERIMENTOS Y RESULTADOS OBTENIDOS		83
<hr/>		
6.1	EXPERIMENTOS	83
6.1.1	<i>Experimentos para la detección de pacientes obstructivos frente a no obstructivos</i>	83

6.1.2 Experimentos para la detección de zona normal y zona pre-obstruccion en pacientes obstruccion	85
6.2 PRINCIPALES RESULTADOS	87
CAPÍTULO 7. CONCLUSIONES Y LÍNEAS FUTURAS	101
7.1 CONCLUSIONES	101
7.2 LÍNEAS FUTURAS	102
BIBLIOGRAFÍA	103
ANEXO	110

PARTE II

PLIEGO DE CONDICIONES	1
CONDICIONES LEGALES Y ADMINISTRATIVAS	1
DERECHOS DE EXPLOTACIÓN Y RESTRICCIONES DE USO	1
GARANTÍAS Y CONSIDERACIONES ADICIONALES	2
HERRAMIENTAS UTILIZADAS	3

PARTE III

PRESUPUESTO	1
DECLARACIÓN JURADA	1
DESGLOSE DEL PRESUPUESTO	2
C-1. Trabajo tarifado por tiempo empleado	2
C-2. Amortización del inmovilizado material	3
C-3. Costes de redacción del Trabajo de Fin de Máster	5
C-4. Derechos de visado	6
C-5. Gastos de tramitación y envío	7
RESUMEN DEL PRESUPUESTO	8

ÍNDICE DE DIAGRAMAS

DIAGRAMA 1. DIAGRAMA DE FLUJO DE LA MONITORIZACIÓN DE PACIENTES POTENCIALMENTE OBSTRUCTIVOS	77
DIAGRAMA 2. DIAGRAMA DE FLUJO DE LA IDENTIFICACIÓN TEMPRANA DE EVENTOS DE PRE-OBSTRUCCIÓN.....	80

ÍNDICE DE FIGURAS

FIGURA 1. ESTIMACIÓN DE LA GRAVEDAD Y LA LETALIDAD EN DISTINTOS MOMENTOS DE LA PRIMERA OLA DE LA EPIDEMIA: FEBRERO A MAYO DE 2020 [1] _____	14
FIGURA 2. PARTES DEL APARATO RESPIRATORIO [10] _____	16
FIGURA 3. DIAGRAMA DE PRESIÓN-TIEMPO, VOLUMEN CONTROLADO, FLUJO CONSTANTE [28] _____	23
FIGURA 5. ESQUEMA DE LOS DISTINTOS ENFOQUES DE APRENDIZAJE AUTOMÁTICO _____	49
FIGURA 6. EJEMPLO DE UNA RED BAYESIANA. LOS NODOS REPRESENTAN VARIABLES ALEATORIAS Y LOS ARCOS RELACIONES DE DEPENDENCIA [50] _____	52

ÍNDICE DE GRÁFICAS

GRÁFICA 1. EVOLUCIÓN DE LA INCIDENCIA ACUMULADA A LO LARGO DE LA PANDEMIA	9
GRÁFICA 2. EVOLUCIÓN DE CASOS DE LA PRIMERA OLA	10
GRÁFICA 3. EVOLUCIÓN DE LA INCIDENCIA ACUMULADA A LO LARGO DEL PRIMER AÑO DE PANDEMIA.....	11
GRÁFICA 4. EVOLUCIÓN DE LA PANDEMIA POR CONTINENTE. MEDIA DE CASOS DIARIOS REGISTRADOS CADA SIETE DÍAS POR 100.000 HABITANTES [9]	15
GRÁFICA 5. TIEMPO MEDIO DE MUESTREO DE CADA UNO DE LOS PACIENTES DEL ESTUDIO	68
GRÁFICA 6. DATOS ÚTILES REGISTRADOS PARA LOS PACIENTES DE LAS OLAS 1 Y 2 ATENDIENDO A CARACTERÍSTICAS FISIOLÓGICAS Y DE MECÁNICA VENTILATORIA. EN EL EJE HORIZONTAL, PARÁMETROS MV (5) Y PH (5). EN EL EJE VERTICAL LA CANTIDAD DE DATOS ÚTILES PARA EL PACIENTE EN CUESTIÓN	69
GRÁFICA 7. GRÁFICA COMPARATIVA DE PARÁMETROS PH EN LA FILA SUPERIOR (DE IZQUIERDA A DERECHA: FRECUENCIA CARDÍACA, PRESIÓN SISTÓLICA, PRESIÓN DIASTÓLICA, SATURACIÓN DE OXÍGENO Y TEMPERATURA) Y MV EN LA INFERIOR (DE IZQUIERDA A DERECHA: PRESIÓN MEDIA, PRESIÓN PICO Y PRESIÓN DE PLATEAU, COMPLIANCE Y RESISTENCIA) PARA PACIENTES OBSTRUCTIVOS (COLUMNA DE VALOR 1) VS PACIENTES NO OBSTRUCTIVOS (COLUMNA DE VALOR 2)	70
GRÁFICA 8. REPRESENTACIÓN DE DATOS EXISTENTES PARA LA VARIABLE "FRECUENCIA CARDÍACA" Y LOS 96 PACIENTES DEL ESTUDIO COMPARANDO PACIENTES "OBSTRUCTIVOS" Y PACIENTES "NO OBSTRUCTIVOS"	72
GRÁFICA 9. GRÁFICA COMPARATIVA DE PARÁMETROS PH EN LA FILA SUPERIOR (DE IZQUIERDA A DERECHA: FRECUENCIA CARDÍACA, PRESIÓN SISTÓLICA, PRESIÓN DIASTÓLICA, SATURACIÓN DE OXÍGENO Y TEMPERATURA) Y MV EN LA INFERIOR (DE IZQUIERDA A DERECHA: PRESIÓN MEDIA, PRESIÓN PICO Y PRESIÓN DE PLATEAU, COMPLIANCE Y RESISTENCIA), REPRESENTANDO ZONA NORMAL (COLUMNA DE VALOR 1) FRENTE A ZONA PRE-OBSTRUCTIVA (COLUMNA DE VALOR 2)...	73
GRÁFICA 10. REPRESENTACIÓN DE DATOS EXISTENTES PARA LA VARIABLE "FRECUENCIA CARDÍACA" Y LOS 37 PACIENTES "OBSTRUCTIVOS" DEL ESTUDIO COMPARANDO LAS ZONAS NORMAL Y PRE-OBSTRUCTIVO	74
GRÁFICA 11. REPRESENTACIÓN DE VALORES DE CALIDAD PARA PACIENTES CONSIDERADOS OUTLIERS BASADO EN LA TABLA 13...	86

ÍNDICE DE TABLAS

TABLA 1. DIFERENCIAS ENTRE LOS PACIENTES CON COVID-19 SEGÚN PRESENTEN OBSTRUCCIÓN DEL TUBO ENDOTRAQUEAL POR TRAQUEOBRONQUITIS NECROSANTE [32]	29
TABLA 2. DATOS DEMOGRÁFICOS E INFORMACIÓN RELATIVA A LA ESTANCIA DE LOS 96 PACIENTES DEL ESTUDIO	34
TABLA 3. CARACTERÍSTICAS DE MECÁNICA VENTILATORIA	36
TABLA 4. CARACTERÍSTICAS FISIOLÓGICAS	38
TABLA 5. EJEMPLOS DISPONIBLES	46
TABLA 6. PROBLEMA CLÁSICO DE DIAGNÓSTICO	56
TABLA 7. NÚMERO DE PARÁMETROS A ESTIMAR, EN FUNCIÓN DE M (NÚMERO DE ENFERMEDADES) Y N (NÚMERO DE SÍNTOMAS), EN EL PARADIGMA CLÁSICO DE DIAGNÓSTICO	58
TABLA 8. NÚMERO DE PARÁMETROS A ESTIMAR, EN FUNCIÓN DE M (NÚMERO DE ENFERMEDADES) Y N (NÚMERO DE SÍNTOMAS), EN EL PARADIGMA CLÁSICO DE DIAGNÓSTICO CON DIAGNÓSTICOS EXCLUYENTES	59
TABLA 9. NÚMERO DE PARÁMETROS A ESTIMAR EN EL PARADIGMA NAÏVE BAYES EN FUNCIÓN DEL NÚMERO DE DIAGNÓSTICOS POSIBLES (M) Y DEL NÚMERO DE SÍNTOMAS (N)	61
TABLA 10. DEFINICIÓN GRÁFICA DE TRUE POSITIVE, TRUE NEGATIVE, FALSE POSITIVE Y FALSE NEGATIVE	65
TABLA 11. MATRIZ DE CONFUSIÓN DEL MODELO	65
TABLA 12. EJEMPLOS DE VARIACIÓN DE PPV Y NPV SEGÚN PREVALENCIA	67
TABLA 13. RESULTADOS DE EXPERIMENTO PACIENTES OBS. VS PACIENTES NO OBS.: OLA 1, PARÁMETROS PH, CARACTERÍSTICA "VALOR MEDIDO", VENTANA DE 4 HORAS	84
TABLA 14. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1, PARÁMETROS PH, CARACTERÍSTICA "VALOR MEDIDO", VENTANA DE 4 HORAS	85
TABLA 15. RESULTADOS DE EXPERIMENTO: OLA 2, PARÁMETROS PH, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 4 HORAS	86
TABLA 16. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA "VALOR MEDIDO", VENTANA DE 4 HORAS	88
TABLA 17. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA "VALOR MEDIDO", VENTANA DE 4 HORAS	88
TABLA 18. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH Y MV, CARACTERÍSTICA "VALOR MEDIDO", VENTANA DE 4 HORAS	88

TABLA 19. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA "VALOR MEDIDO", VENTANA DE 4 HORAS _____	89
TABLA 20. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 4 HORAS _____	89
TABLA 21. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 4 HORAS _____	90
TABLA 22. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH Y MV, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 4 HORAS _____	90
TABLA 23. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH Y MV, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 4 HORAS _____	90
TABLA 24. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 2, PARÁMETROS PH, CARACTERÍSTICA "ZERO CROSSING + VALOR MEDIDO", VENTANA DE 4 HORAS _____	91
TABLA 25. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 2, PARÁMETROS PH, CARACTERÍSTICA "ZERO CROSSING + VALOR MEDIDO", VENTANA DE 4 HORAS _____	91
TABLA 26. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH Y MV, CARACTERÍSTICA "ZERO CROSSING + VALOR MEDIDO", VENTANA DE 4 HORAS _____	92
TABLA 27. TABLA 21. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH Y MV, CARACTERÍSTICA "ZERO CROSSING + VALOR MEDIDO", VENTANA DE 4 HORAS _____	92
TABLA 28. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA "VALOR MEDIDO", VENTANA DE 8 HORAS _____	93
TABLA 29. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA "VALOR MEDIDO", VENTANA DE 8 HORAS _____	93
TABLA 30. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 8 HORAS _____	94
TABLA 31. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 8 HORAS _____	94
TABLA 32. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH Y MV, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 8 HORAS _____	94
TABLA 33. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH Y MV, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 8 HORAS _____	95
TABLA 34. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 2, PARÁMETROS MV, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 8 HORAS _____	95

TABLA 35. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 2, PARÁMETROS MV, CARACTERÍSTICA "ZERO CROSSING", VENTANA DE 8 HORAS	95
TABLA 36. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1, PARÁMETROS MV, CARACTERÍSTICA "ZERO CROSSING + VALOR MEDIDO", VENTANA DE 8 HORAS	96
TABLA 37. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1, PARÁMETROS MV, CARACTERÍSTICA "ZERO CROSSING + VALOR MEDIDO", VENTANA DE 8 HORAS	96
TABLA 38. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA " VALOR MEDIDO", VENTANA DE 12 HORAS	97
TABLA 39. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA " VALOR MEDIDO", VENTANA DE 12 HORAS	97
TABLA 40. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA " ZERO CROSSING", VENTANA DE 12 HORAS	98
TABLA 41. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA " ZERO CROSSING", VENTANA DE 12 HORAS	98
TABLA 42. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 2, PARÁMETROS PH, CARACTERÍSTICA " ZERO CROSSING + VALOR MEDIDO", VENTANA DE 12 HORAS	99
TABLA 43. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 2, PARÁMETROS PH, CARACTERÍSTICA " ZERO CROSSING + VALOR MEDIDO", VENTANA DE 12 HORAS	99
TABLA 44. RESULTADOS DE EXPERIMENTO PACIENTE OBS. VS PACIENTE NO OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA " ZERO CROSSING + VALOR MEDIDO", VENTANA DE 12 HORAS	99
TABLA 45. RESULTADOS DE EXPERIMENTO ZONA NORMAL VS ZONA PRE-OBS.: OLA 1 Y 2, PARÁMETROS PH, CARACTERÍSTICA " ZERO CROSSING + VALOR MEDIDO", VENTANA DE 12 HORAS	100

ACRÓNIMOS

AC	<i>Assist Control – Control asistido</i>
ARDS	<i>Adult Respiratory Distress Syndrome - Síndrome de Dificultad Respiratoria del Adulto</i>
CHUIMI	<i>Complejo Hospitalario Universitario Insular Materno Infantil</i>
CNMC	<i>Comisión Nacional de los Mercados y la Competencia</i>
COIT	<i>Colegio Oficial Ingenieros de Telecomunicación</i>
COVID19	<i>Coronavirus Disease 2019</i>
ECTS	<i>European Credit Transfer and Accumulation System</i>
EM	<i>Expectation Maximization – Maximización de la expectación</i>
EPI	<i>Equipos de Protección Individual</i>
FIO ₂	<i>Fraction of Inspired Oxygen</i>
FN	<i>False Negative – Falso negativo</i>
FP	<i>False Positive – Falso positivo</i>
HCoV	<i>Human Coronavirus</i>
HIS	<i>Hospital Information System – Sistema de Información Hospitalaria</i>
IA	<i>Inteligencia Artificial</i>
IFR	<i>Inspired Fraction Rate</i>
IMC	<i>Índice de Masa Corporal</i>
IQR	<i>Interquartile Range – Rango intercuartil</i>
LOOCV	<i>Leave One Out Cross-Validation – Validación cruzada dejando uno fuera</i>
LSTM	<i>Long Short-Term Memory</i>
MAD	<i>Median Absolute Deviations</i>

MERS-CoV	<i>Middle East Respiratory Syndrome Coronavirus</i>
MIT	<i>Massachusetts Institute of Technology</i>
ML	<i>Machine Learning</i>
NBC	<i>Naïve Bayes Classifier – Clasificador de Naïve Bayes</i>
NLP	<i>Natural Language Processing</i>
NPV	<i>Negative Predictive Value – Valor Predictivo Negativo</i>
NTB	<i>Necrotizing Tracheobronchitis – Traquebronquitis necrosante</i>
OMS	<i>Organización Mundial de la Salud</i>
PA	<i>Presión Arterial</i>
PAD	<i>Presión Arterial Diastólica</i>
PAS	<i>Presión Arterial Sistólica</i>
PEEP	<i>Positive End-Expiratory Pressure</i>
PH	<i>Physiological - Fisiológico</i>
PPV	<i>Positive Predictive Value – Valor Predictivo Positivo</i>
PSV	<i>Pressure Support Ventilation – Ventilación con Soporte de Presión</i>
RB	<i>Red Bayesiana</i>
RNA	<i>Red Neuronal Artificial</i>
ROC	<i>Receiver Operating Characteristic</i>
RR	<i>Respiratory Rate</i>
SARS	<i>Severe Acute Respiratory Syndrome</i>
SARS-CoV-2	<i>Severe Acute Respiratory Syndrome Coronavirus 2</i>
SD	<i>Standard Deviation – Desviación estándar</i>
SEORL-CCC	<i>Sociedad Española de Otorrinolaringología y Cirugía de Cabeza y Cuello</i>
SpO ₂	<i>Saturación arterial de oxígeno</i>
TFM	<i>Trabajo de Fin de Máster</i>

TN	<i>True Negative – Verdadero Negativo</i>
TP	<i>True Positive – Verdadero Positivo</i>
UCI	<i>Unidad de Cuidados Intensivos</i>
VM/MV	<i>Ventilación Mecánica / Mechanical Ventilation</i>
VMI	<i>Ventilación Mecánica Invasiva</i>

PARTE I – MEMORIA

CAPÍTULO 1.

INTRODUCCIÓN

En diciembre de 2019 comenzó la aparición de algunos problemas respiratorios atípicos en Wuhan, China, y rápidamente se extendieron hacia otras áreas. El responsable fue un nuevo tipo de coronavirus, el llamado SARS-CoV-2 (*Severe Acute Respiratory Syndrome Coronavirus 2*). La infección por causada por este COVID-19 (*Coronavirus Disease 2019*) puede ocasionar complicaciones graves o fatales y la necesidad de ventilación invasiva en pacientes de alto riesgo, y gran parte de los pacientes que contraen este virus evoluciona de tal manera que requiere ingreso en UCI (Unidad de Cuidados Intensivos). En esta situación, se ha demostrado una tasa de mortalidad cercana al 30% debido a las complicaciones que presentan este tipo de pacientes durante su estancia en UCI. Médicos expertos han detectado una serie de casos de traqueobronquitis necrosante, lo cual provoca la obstrucción de las vías respiratorias. Esta complicación representa un aumento del riesgo de contagio por parte del personal sanitario, siendo por ello considerado uno de los procedimientos de mayor riesgo de transmisión viral del paciente al personal sanitario.

El inicio de investigaciones relacionadas con esta complicación se centra en la observación continua de los pacientes por parte de los médicos y el intento de probar su hipótesis de la posible correlación entre dichos parámetros y obstrucción. Esto ha motivado una investigación entre ingenieros y médicos que ha dado como resultado la identificación de dos grupos de variables, fisiológicas y de mecánica ventilatoria. Ambos son objeto de trabajo en esta investigación.

Este estudio presenta una aproximación al problema de la detección precoz de la obstrucción del tubo endotraqueal. En particular, aplicamos técnicas de aprendizaje automático mediante el uso combinado de un clasificador bayesiano.

1.1 Objetivo

Motivación del proyecto:

La obstrucción de tubo endotraqueal es un problema muy serio que se puede producir en pacientes ingresados en una Unidad de Cuidados Intensivos. Uno de los problemas de la obstrucción es que, si bien se produce poco a poco en un intervalo de horas o días, detectarlo es muy difícil y motiva intervenciones de urgencia. Este problema fue planteado por doctores de la Unidad de Medicina Intensiva del Complejo Hospitalario Universitario Insular Materno Infantil (CHUIMI) de Gran Canaria.

Particularmente, nuestro enfoque está centrado en pacientes COVID-19 ingresados en la UCI del CHUIMI. A partir del planteamiento iniciado por los médicos, se ha producido desde 2020 una colaboración que ha dado lugar a una serie de artículos en congresos nacionales e internacionales. Además, hemos colaborado en proyectos sobre esta temática.

En los trabajos iniciales se estudió el uso de *Machine Learning* estadístico [1] y el análisis gráfico de *BigData* en la detección de obstrucción endotraqueal en neumonía COVID-19 [2]. Posteriormente, se avanzó en la idea de hacer los primeros modelos de predicción a partir de variables de mecánica ventilatoria y clínicas [3]. A estos trabajos sucedieron dos más. Uno sobre estudio del poder predictivo de las señales de mecánica ventilatoria sobre la obstrucción del tubo endotraqueal en pacientes COVID-19 basado en modelos de clasificación Bayesiana [4] y la elaboración de modelos más complejos [5]. Estos trabajos

se han financiado con cargo a proyectos del Colegio Oficial de Médicos de Las Palmas [6]¹ y de la Universidad de Las Palmas de Gran Canaria [7]².

En este Trabajo Fin de Máster vamos varios pasos más allá y maduramos los resultados de investigación abordando dos problemas:

- 1) detectar pacientes potencialmente obstructivos frente a no obstructivos, y
- 2) detección de fases normal y pre-obstructiva en pacientes potencialmente obstructivos.

Hasta donde llega nuestro conocimiento, nuestros trabajos son los primeros de carácter interdisciplinar entre las comunidades científico-tecnológica y científico-médica en el diseño de sistemas para la monitorización de obstrucción de tubo endotraqueal en pacientes COVID-19.

Objetivo principal:

Implementación de algoritmos de *Machine Learning* (ML) para el estudio de los datos obtenidos sobre obstrucción del tubo endotraqueal y detección de la misma en pacientes COVID ingresados en UCI. En base a esto, se desglosan una serie de objetivos secundarios que se describen a continuación.

Objetivos secundarios:

- Diseño de un sistema capaz de detectar pacientes potencialmente obstructivos frente a no obstructivos.
- Diseño de un sistema de detección de fases normal y pre-obstructiva en pacientes potencialmente obstructivos.

¹ Guillermo Pérez Acosta; Luciano Santana Cabrera; José Blanco López; Juan Luis Navarro Mesa; Carmen Paz Suárez Araujo. COVID-19. Prevención basada en inteligencia artificial. Proyecto Financiado por el Colegio de Médicos de Las Palmas, 2020-2022.

² Juan Luis Navarro Mesa; Carmen Paz Suárez Araujo; Antonio G. Ravelo Garcia; Eduardo Hernández Pérez; Sofía I. Martín González; Pablo Fernández López; Patricio García Báez; Ylermi Cabrera León; Guillermo Pérez Acosta; Luciano Santana Cabrera; José Blanco López; Juan C. Martín González. Entidad financiadora: Universidad de las Palmas de Gran Canaria, 2020-202.

1.2 Organización de la memoria

La redacción de este documento se ha estructurado en diferentes capítulos, estos son:

Capítulo 1. Introducción.

Hacemos una breve introducción sobre el virus COVID-19 y las complicaciones que este conlleva. Describimos el objetivo principal del proyecto.

Capítulo 2. Fundamentos teóricos.

Ampliamos conocimientos acerca de las complicaciones que produce este virus, centrándonos en la obstrucción del tubo endotraqueal en pacientes ingresado en UCI.

Capítulo 3. Preparación del entorno de trabajo.

Analizamos las distintas fuentes de datos, su procedencia y su organización dentro de la propia base de datos.

Capítulo 4. Aspectos teóricos sobre algoritmos de detección temprana de obstrucción del tubo endotraqueal.

Realizamos una breve introducción al aprendizaje máquina y sus diferentes formas.

Explicamos brevemente los distintos métodos de clasificación que utilizaremos en este Trabajo de Fin de Máster.

Capítulo 5. Algoritmo de detección temprana de obstrucción del tubo endotraqueal en pacientes COVID-19.

Describimos el flujo de trabajo seguido por el algoritmo desarrollado para la detección temprana de la obstrucción del ventilador en pacientes COVID-19 ingresados en UCI.

Capítulo 6. Experimentos y resultados.

Se presenta los parámetros que hemos utilizado para definir la calidad de los experimentos, se detallan los experimentos realizados y se muestran los resultados obtenidos.

Capítulo 7. Conclusiones y Líneas Futuras.

En este capítulo se exponen las conclusiones obtenidas del trabajo y las posibles líneas futuras.

Al final de la memoria se encuentra la bibliografía, donde se enumeran las referencias bibliográficas empleadas en este Trabajo de Fin de Máster.

Además, se incluye un apartado de anexo donde se recogen tablas de datos obtenidos durante el desarrollo del proyecto.

CAPÍTULO 2.

FUNDAMENTOS TEÓRICOS

2.1 Información epidemiológica

La Comisión Municipal de Salud y Sanidad de Wuhan (en Hubei, China) alertó de la existencia de un grupo de 27 personas que padecían neumonía de procedencia desconocida a fecha de 31 de diciembre de 2019. El aspecto común en todas estas personas era la exposición al Mercado de mariscos de Huanan, un mercado mayorista de animales vivos y mariscos en la ciudad de Wuhan, siendo el inicio de los síntomas del primer caso el 8 de diciembre de 2019. El 7 de enero de 2020, las autoridades chinas identificaron como agente causante del brote un nuevo tipo de virus de la familia *Coronaviridae*, posteriormente denominado SARS-CoV-2 (*Severe Acute Respiratory Syndrome Coronavirus 2*).

El día 11 de marzo, la OMS (Organización Mundial de la Salud) declaró la pandemia mundial. Desde el inicio hasta la fecha de este documento de TFM (Trabajo de Fin de Máster) se han alcanzado más de 487 millones de casos notificados en todo el mundo y más de 11 millones de casos en España [8].

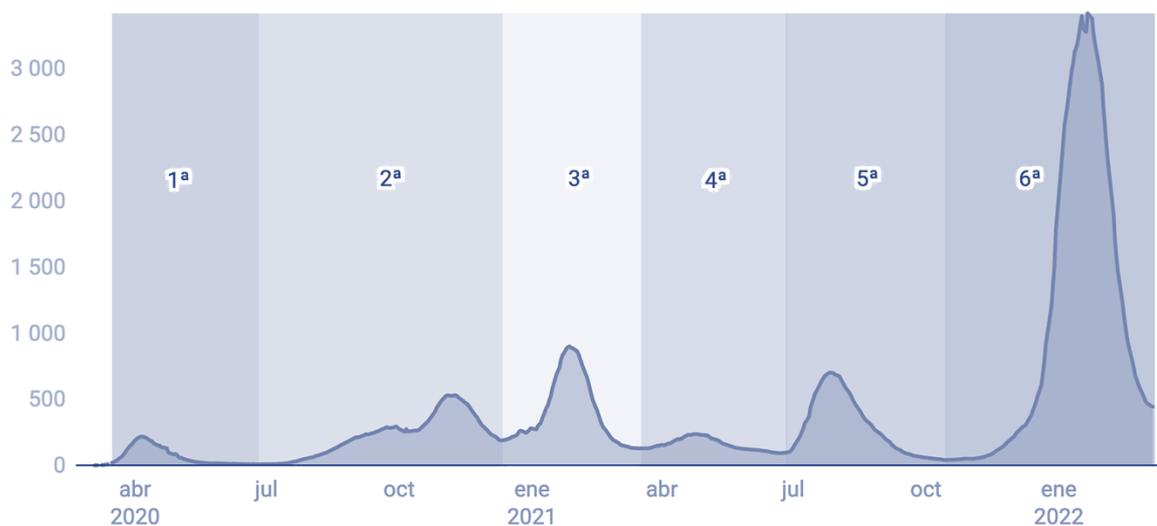
Los coronavirus son una familia de virus que causan infección en los seres humanos y en una variedad de animales, incluyendo aves y mamíferos. Se trata de una enfermedad zoonótica, lo que significa que pueden transmitirse de los animales a los humanos [9]. Los coronavirus que afectan al ser humano (HCoV – *Human Coronavirus*) pueden producir cuadros clínicos que van desde el resfriado común con patrón estacional en invierno hasta otros más graves como los producidos por los virus del Síndrome Respiratorio Agudo Grave (por sus siglas en inglés, SARS – *Severe Acute Respiratory Syndrome*) y del Síndrome

Respiratorio de Oriente Próximo (MERS-CoV – *Middle East Respiratory Syndrome Coronavirus*) [10].

2.1.1 Evolución de la pandemia en España

El 14 de marzo de 2020 se decreta en España el estado de alarma. A partir de ese día dio comienzo una serie de picos de contagios, denominados “olas”, que hasta el momento se siguen registrando. Entre marzo de 2020 y junio de 2022 se han contabilizado un total de 7 olas. Los datos de las primeras 6 olas ya están disponibles (Gráfica 1), sin embargo, de la séptima ola aún no se tienen datos exactos ya que seguimos en ella a fecha de este documento. La gráfica muestra la incidencia acumulada a lo largo de las 6 olas registradas donde se observa que destacan la 3^o ola, coincidiendo con las fechas de navidades, donde tuvieron lugar numerosas reuniones, provocando así este repunte de casos. La quinta ola apareció unas semanas después de que se decretara el fin del estado de alarma y las restricciones de horario. La ola más destacable en este gráfica es la número 6, la cual se debe a la aparición de la variante Ómicron, mucho más contagiosa que las anteriores. La séptima y última ola se declaró a finales de mayo por el repunte de casos, en gran parte debido a la retirada de la obligatoriedad de la mascarilla tanto en interiores como en exteriores. Aún no se sabe si se trata de una nueva variante.

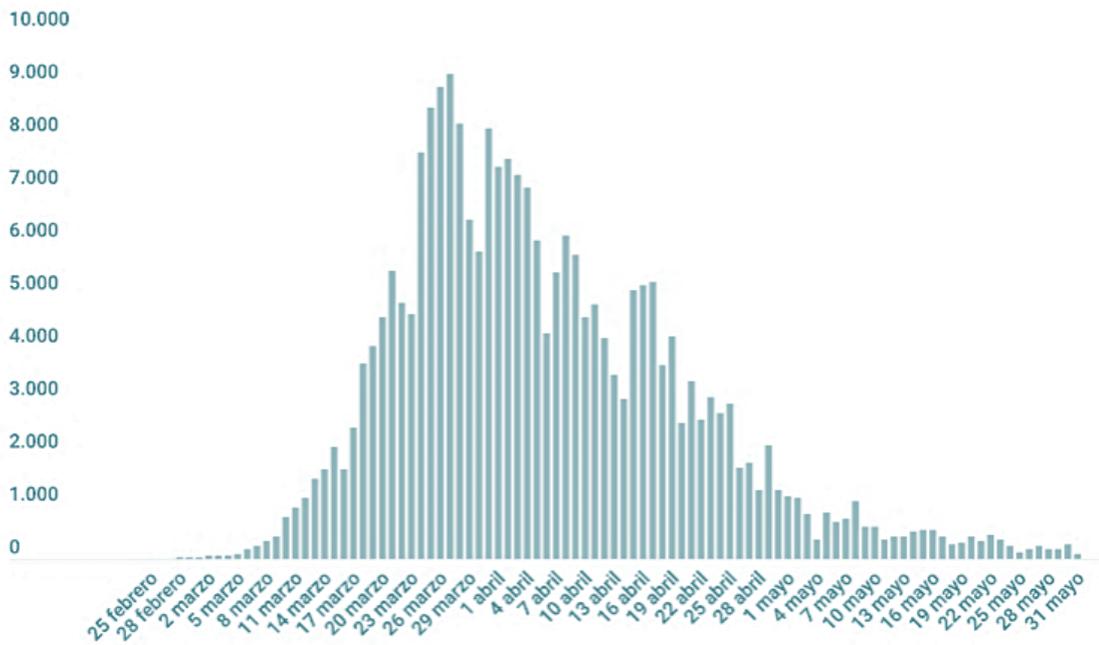
Gráfica 1. Evolución de la incidencia acumulada a lo largo de la pandemia
Fuente: Artículo de 20minutos.es [11], datos extraídos de Ministerio de Sanidad



Para este trabajo hemos desarrollado los modelos empleando los datos de la primera y segunda ola de esta pandemia (de marzo a diciembre de 2020). Un trabajo posterior será incluir todos los datos posibles del mayor número de olas para así obtener resultados más generalizables.

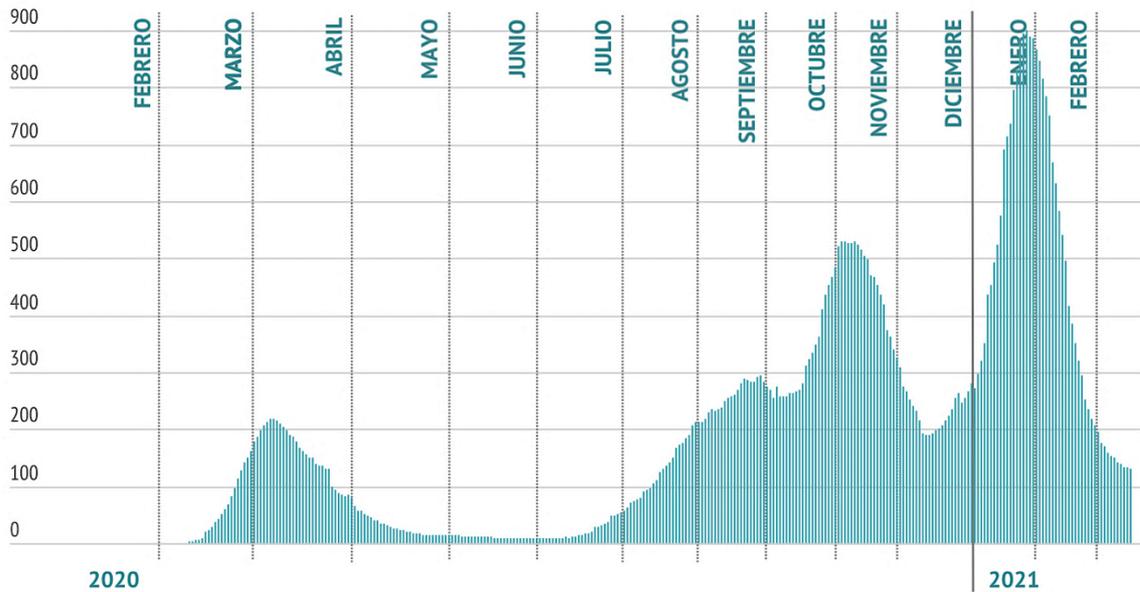
La primera ola tuvo lugar entre marzo de 2020 y junio de ese mismo año (Gráfica 2). La segunda ola se corresponde con los casos registrados entre julio y diciembre de 2020.

Gráfica 2. Evolución de casos de la primera ola
 Fuente: Artículo El Independiente [12], datos extraídos de Ministerio de Sanidad



A continuación se muestra un grafico (Gráfica 3) de la evolución de la incidencia acumulada durante el primer año de pandemia (de febrero de 2020 a febrero de 2021).

Gráfica 3. Evolución de la incidencia acumulada a lo largo del primer año de pandemia
 Fuente: Artículo de El Independiente [12], datos extraídos de Ministerio de Sanidad



En este gráfico anterior (Gráfica 3) se ha de tener en cuenta la baja capacidad diagnóstica de la ola 1. Este hecho terminó en la conclusión de que la incidencia real habría sido 10 veces superior a la registrada, esto lo confirmó Sanidad en informes posteriores. Es decir, se calcula que a mediados de marzo pudo haber una incidencia de más de 2.000 casos. Como resultado de la declaración del estado de alarma en España seguido del confinamiento se produce el valle apreciable entre los meses de marzo de 2020 a finales de junio de 2020.

2.1.2 Fuente de infección

La fuente primaria, y con mayor probabilidad, en la mayoría de los casos de coronavirus es el origen animal. Esto sigue confirmándose para el caso del SARS-CoV-2. Aún no se ha determinado cuál es el reservorio natural y el posible transmisor del virus a los humanos, ya que no se ha detectado en ningún animal vinculado con el momento y el lugar de origen de la pandemia [13],[14]. El biólogo Michael Worobey y su equipo de la Universidad de Arizona, presentaron en febrero de 2022 dos *preprints* [6],[7] donde exponían como

conclusión que "la agrupación geográfica de los primeros casos conocidos de Covid-19 y la proximidad de muestras ambientales positivas a los vendedores de animales vivos sugieren que el mercado mayorista de mariscos de Wuhan fue el sitio de origen del COVID-19".

Los estudios fueron realizados mediante análisis genéticos de muestras de coronavirus obtenidas del mercado y de los primera personas infectadas (registradas oficialmente) en diciembre de 2019, así como un análisis de geolocalización, dando como resultado una relación directa entre los casos registrados y la sección del mercado de venta de animales salvajes.

2.1.3 Transmisión

Aún se desconoce la forma de transmisión que tuvo lugar para que el virus pasase de la fuente animal a los primeros humanos infectados, siendo el contacto directo con estos animales o sus secreciones una de las posibles causas con mayor probabilidad. Algunos estudios desarrollados sobre animales con otros tipos de coronavirus han expuesto como resultado que este virus es capaz de desplazarse por la células de los distintos órganos y generar complicaciones respiratorias y gastrointestinales [17], extrayendo como posible conclusión la posibilidad de que la transmisión animal-humano sea mediante secreciones respiratorias y/o material procedente del aparato digestivo.

2.1.3.1 Mecanismo de transmisión humano-humano

Hasta el momento, la comunidad científica ha determinado que existen diferentes vías de transmisión humano-humano del SARS-CoV-2. La principal fuente de transmisión que se ha establecido es el contacto y la inhalación de las gotas y aerosoles respiratorios producidos por la persona contagiada hasta las vías respiratorias de una persona susceptible. También existe la posibilidad de contagio a través de las manos o materiales contaminados por secreciones respiratorias del transmisor del virus (contacto indirecto). Otro tipo de contagio posible, pero menos frecuente, es la transmisión vertical a través de la placenta también es posible, aunque poco frecuente [8].

2.1.4 Letalidad

En cuanto a la letalidad de un virus, para su estimación se lleva a cabo el cálculo de los fallecimientos que han tenido lugar entre los casos confirmados de la enfermedad en cuestión. Esta estimación se basa en la capacidad que tiene el sistema para detectar los casos en los que se produce fallecimiento. El numerador de esta división es el número de fallecimientos, dato único que queda recogido por el sistema jurídico y sanitario. Sin embargo esta defunción no se puede atribuir a una causa única y concreta, sino que se trata de un proceso complejo donde se ha de aplicar criterios clínicos y epidemiológicos.

Ante una situación de emergencia como puede ser la producida por el COVID-19, esta cuidadosa e individualizada investigación es inviable. Los motivos de esta inviabilidad se basan en la imposibilidad de disponer de datos inmediatos de pacientes, favoreciendo los criterios de sensibilidad ante la detección y notificación del mayor número de casos, pero empeorando a su vez la especificidad del dato. Por ejemplo, cualquier fallecido con una prueba diagnóstica positiva podría ser considerado como fallecido por COVID-19, sin tener en cuenta el motivo de defunción e incluso defunciones por sintomatología compatible y sin llegar a obtener una prueba confirmatoria de laboratorio [8]. Por lo tanto, para el cálculo de la letalidad se incluirían fallecidos por COVID-19 realmente confirmados, pero también personas cuyo fallecimiento se debe a otro motivo. El principal factor que afecta al denominador, siendo este el número total de casos de la enfermedad es la capacidad diagnóstica y de detección de los sistemas de vigilancia. Algunos de los factores que influyen en el cálculo del denominador son la falta de material específico para la realización de pruebas diagnósticas, así como la saturación de los servicios de salud pública y del sistema sanitario, quienes se encargan de investigar y validar la notificación de los casos. Al comienzo de la pandemia, existían muy pocos métodos de diagnóstico en la mayor parte de los países, por lo que se tomó la decisión de dar prioridad a los casos más graves y vulnerables (como son los trabajadores sanitarios). Es por ello por lo que estos datos, al inicio de una pandemia o a lo largo de la etapa de mayor incidencia, deba ser interpretada teniendo en cuenta siempre lo anteriormente comentado.

Desde el inicio de la pandemia, en España los datos de letalidad han sido obtenidos empleando únicamente casos confirmados y notificados por las Comunidades Autónomas al Ministerio de Sanidad y a la Red Nacional de Vigilancia Epidemiológica (Figura 1).

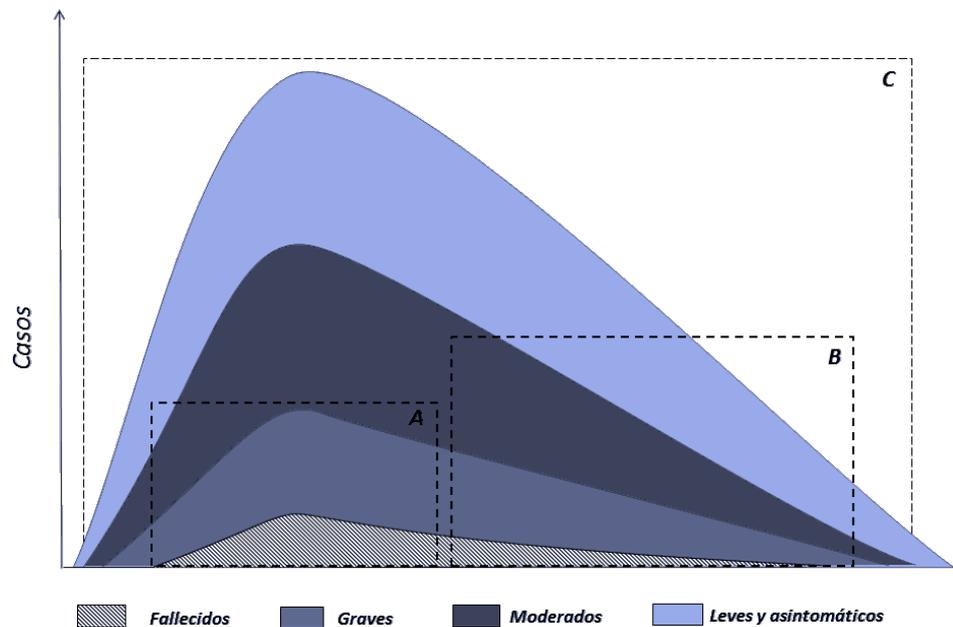
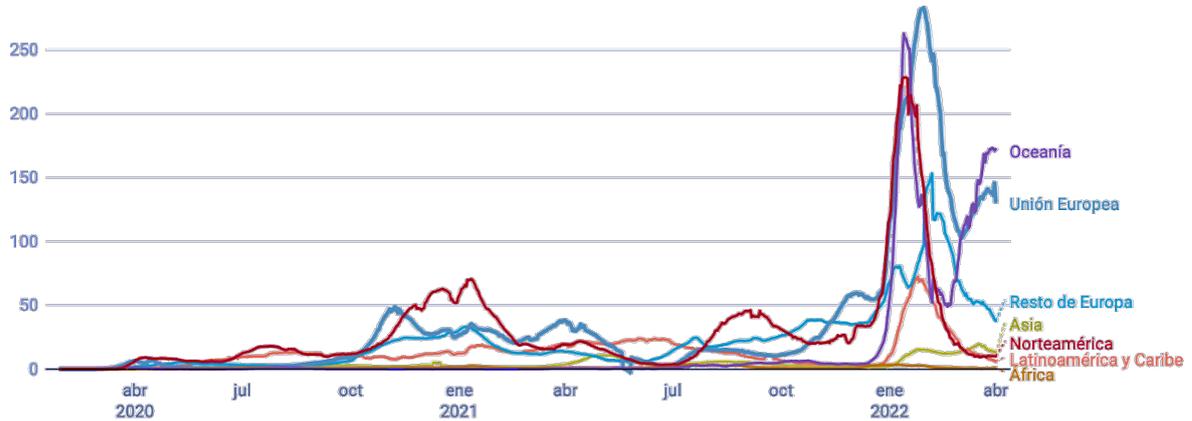


Figura 1. Estimación de la gravedad y la letalidad en distintos momentos de la primera ola de la epidemia: febrero a mayo de 2020 [1]

Debido a la alta intensidad y a las capacidades de atención y de salud públicas necesarias, al inicio y a lo largo de gran parte de la pandemia, se priorizó la detección de los casos en los hospitales y posteriormente, a medida que se iba reduciendo la presión, se fue ampliando la cobertura de pruebas diagnósticas.

Si hacemos una comparación de los datos obtenidos a lo largo de la pandemia en los diferentes países (Gráfica 4) podemos observar las grandes diferencias de uno a otro, pudiendo deberse en gran parte a lo comentado anterior, como pudiera ser la baja capacidad de detección de casos debido a la falta del material específico necesario.

Gráfica 4. Evolución de la pandemia por continente. Media de casos diarios registrados cada siete días por 100.000 habitantes [9]



2.2 Mecánica respiratoria

2.2.1 Sistema Respiratorio

Antes de presentar los principales elementos de la mecánica respiratoria en UCI propiamente dicha, veamos algunos conceptos sobre el sistema respiratorio. Este sistema (Figura 2) está formado consta de una serie de elementos los cuales se encarga de realizar el intercambio de gases entre atmósfera y sangre. El oxígeno (O_2) entra en el sistema respiratorio a través de las principales vías, como son nariz y boca, y se distribuye al resto de tejidos del cuerpo, para luego, mediante metabolismo celular, ser transformado y enviado al exterior en forma de dióxido de carbono (CO_2). La anatomía del sistema respiratorio se divide en dos partes, tracto respiratorio superior y tracto respiratorio inferior. El tracto respiratorio superior consta de nariz, fosas nasales, senos paranasales, boca, faringe, laringe y tráquea. Por otro lado, bronquios y pulmones componen el tracto respiratorio inferior [18].

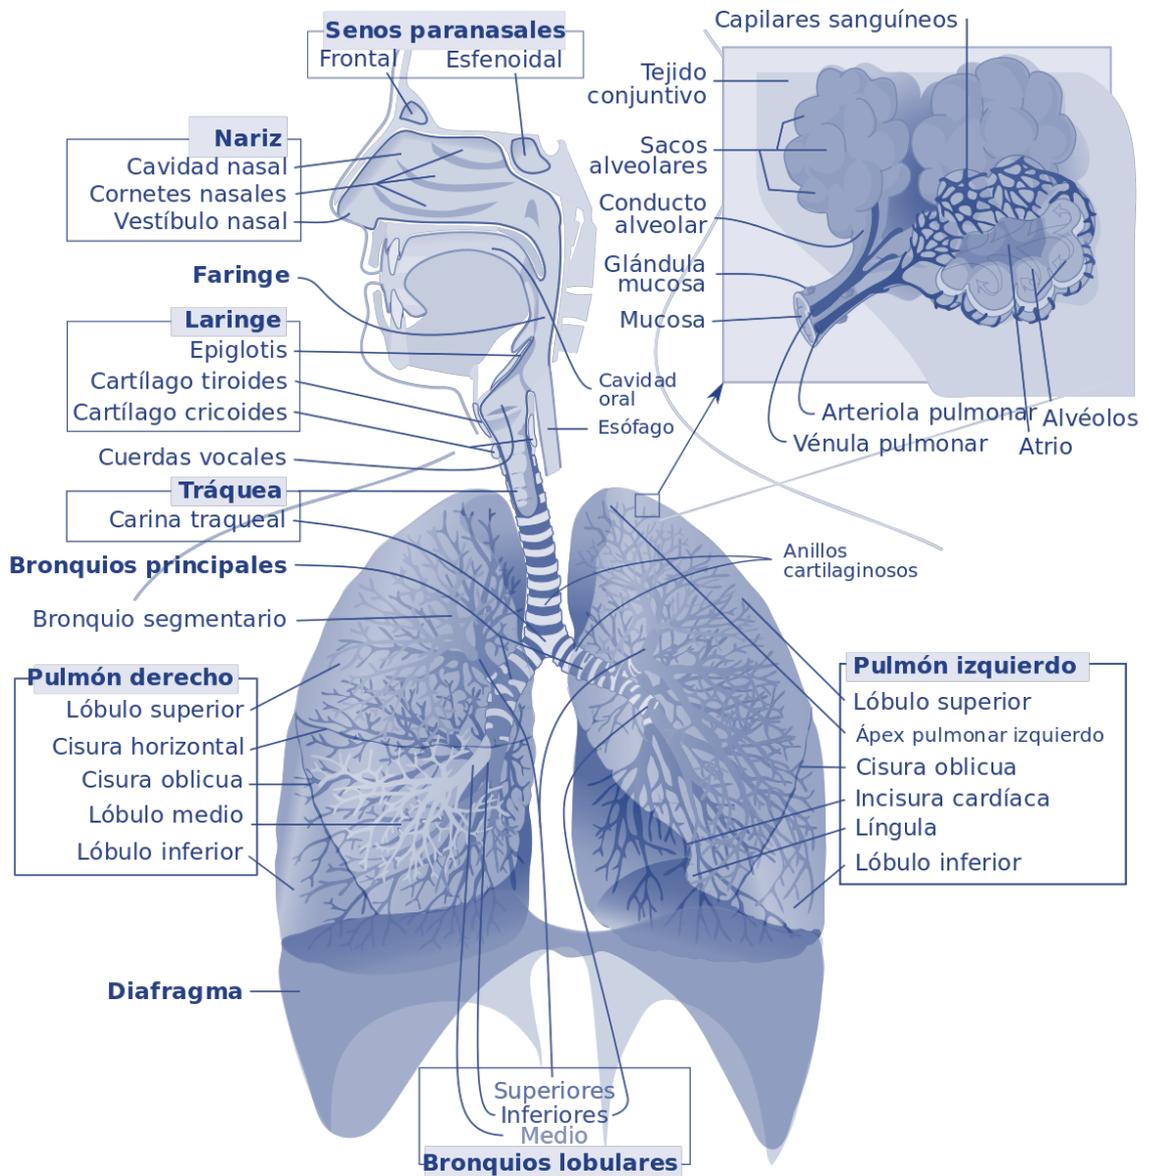


Figura 2. Partes del aparato respiratorio [10]

- Nariz.** Se trata de la parte superior del sistema respiratorio. La nariz consta de una estructura ósea, llamada puente, y en su interior se encuentra el tabique nasal, que

es parcialmente óseo y cartilaginosa y divide a la cavidad nasal en dos partes, las fosas nasales.

- **Fosas nasales.** Son dos orificios en la nariz por los que penetra el aire, filtrado por una serie de vellosidades y mucosas que impiden el acceso a desechos sólidos y otros elementos no gaseosos.
- **Senos paranasales.** Cavidades llenas de aire que se crean cuando la mucosa de la cavidad nasal accede a los huesos del cráneo cercanos. Algunos de los huesos donde se encuentran estos senos paranasales son el frontal, el etmoides, el esfenoides y el maxilar superior.
- **Boca.** Es el inicio del tubo digestivo y se encuentra recubierto de membrana mucosa, llamada mucosa oral. También se emplea para respirar.
- **Faringe.** Se trata del canal de unión entre cavidad bucal, fosas nasales, esófago y laringe.
- **Laringe.** En esta parte encontramos ubicadas las cuerdas vocales y la glotis, es el punto de conexión entre faringe, tráquea y pulmones. Existen además un conjunto de músculos cuya función es actuar en caso de obstrucción de la vía para expulsar el agente que lo está provocando.
- **Tráquea.** El un conducto que establece conexión entre la laringe y los pulmones. Está formado por una serie de cartílagos de forma circular que se encargan de mantener la vía siempre abierta.
- **Bronquios y pulmones.** Los pulmones son dos “bolsas” capaces de recoger el oxígeno que entre en el sistema respiratorio y realizar sus distribución al resto del organismo a través del intercambio entre aire y sangre. Esta distribución se lleva a cabo a través de los denominados bronquios, los cuales se ramifican en bronquiolos, y estos a su vez en alvéolos pulmonares, para llegar finalmente a los alvéolos pulmonares, los cuales se encargan del intercambio de gases ya nombrado.

Otras estructuras del sistema respiratorio son:

- **Músculos intercostales.** Un conjunto de músculos encargados de los movimientos del tórax.
- **Diafragma.** Este músculo se encuentra entre el abdomen y el tórax. Se encarga de realizar los procesos de inhalación y exhalación.
- **Pleura.** Se describe como una membrana serosa que rodea ambos pulmones. Su función es mantener una cavidad entre sus dos capas (con una presión menor a la atmosférica) permitiendo así la expansión de los pulmones durante la inhalación.

2.2.2 Fisiología del sistema respiratorio

2.2.2.1 Proceso de respiración

El proceso de respiración se compone de dos partes, la respiración externa, es decir, el intercambio de oxígeno (O₂) y dióxido de carbono (CO₂) entre la sangre y la atmósfera, y la respiración interna, es decir, el intercambio de gases entre la sangre de los capilares y las células de los tejidos en donde se localizan esos capilares.

Existen 4 fases en respiración externa:

- Inhalación y exhalación: intercambio de aire entre atmósfera y alvéolos pulmonares
- Reparto de O₂ y CO₂ entre los alvéolos y la sangre.
- Distribución de gases a las células a través de la sangre
- Regulación del proceso respiratorio.

La fase inicial del proceso de respiración es la ventilación pulmonar. Esto se basa en la entrada y salida de aire de los pulmones, es decir, la inhalación y la exhalación. En fisiología respiratoria se ha establecido un valor de referencia de presión atmosférica de 0 *mmHg*.

La entrada y salida de aire de los pulmones va en función de la diferencia de presión producida por los músculos respiratorios al contraerse y dilatarse.

Estas presiones pueden ser medidas en los espacios aéreos de los pulmones (presión intrapulmonar) o dentro del espacio pleural (presión intrapleural). En el proceso de inspiración, la contracción del diafragma y de los músculos inspiratorios genera un aumento de la capacidad de la cavidad torácica, consiguiendo así una presión intrapulmonar menor a la de la atmósfera, permitiendo de esta forma la entrada de aire en el sistema respiratorio. El proceso de espiración consiste en la dilatación de los músculos implicados. Esto produce una reducción de la capacidad de la cavidad torácica, aumentando la presión intrapulmonar ($>0 \text{ mmHg}$) y expulsando el aire de los pulmones.

En un proceso de respiración común, durante la inhalación se produce una contracción de los músculos del aparato respiratorio, sin embargo, no se produce ninguna contracción durante la exhalación ya que se produce por la simple relajación de los músculos. Por lo tanto, existen únicamente dos acciones del proceso de respiración en las que se necesita un mayor esfuerzo por parte de los músculos:

- La expansibilidad de los pulmones
- La resistencia de las vías aéreas al flujo del aire

La expansibilidad, también llamada comúnmente por su nombre en inglés *compliance*, es la capacidad de expansión de los pulmones. Si un pulmón tiene una *compliance* alta quiere decir que puede expandirse con facilidad, por el contrario, una *compliance* baja implica la necesidad de aplicar una mayor fuerza por parte de los músculos respiratorios para poder expandirse.

La elasticidad es sinónimo de oposición a la deformación. Es la capacidad de un cuerpo elástico de volver a su forma original una vez ha sido deformado debido a una fuerza externa. El hecho de que un pulmón sea expandido fácilmente (alta *compliance*) no implica que este vaya a volver a su forma y dimensiones originales cuando desaparezca la fuerza aplicada. Debido a la gran capacidad elástica de los pulmones la mayor parte del trabajo del proceso de respiración va destinado a vencer esta resistencia de los pulmones [18].

2.3 Mecánica ventilatoria en pacientes UCI

2.3.1 Introducción a la mecánica ventilatoria

La aparición de lo que podría considerarse la primera intubación endotraqueal y ventilación artificial tuvo lugar en el siglo XVI, cuando Andreas Vesalius propuso la inserción de un tubo de caña en la tráquea de un animal introduciendo aire en los pulmones para mantenerlo vivo. Cuatro siglos después, el pulmón de hierro fue el primer ventilador de presión negativa utilizado con éxito en la práctica clínica.

En torno a 1950, Claus Bang, un médico danés, y Carl-Gunnar Engström, un anestesiólogo sueco, desarrollaron los primeros ventiladores mecánicos eficientes. Los primeros analizadores de gases en sangre arterial se construyeron poco después [19].

El siguiente gran paso en la evolución de la Ventilación Mecánica (VM) fue el uso de presión positiva al final de la espiración (PEEP – *Positive End-Expiratory Pressure*), fomentado principalmente por la identificación del síndrome de dificultad respiratoria del adulto (ARDS – *Adult Respiratory Distress Syndrome*) [20]. El Servo 900A (Siemens - Eléma) data de 1972, y fue el primer respirado mecánico con PEEP puesto a la venta, estaba compuesto por unas servo-válvulas capaces de llevar el control del flujo. Esta innovación permitió la aparición de nuevos modos de ventilación como son la ventilación controlada por presión y la ventilación con soporte de presión (PSV – *Pressure Support Ventilation*) [21]. También existen otros modos como son el control asistido (AC - *Assist-Control*) y la ventilación mecánica intermitente sincronizada (SIMV - *Synchronized Intermittent Mechanical Ventilation*) [22].

Dependiendo del modo de respiración elegido, se debe configurar un conjunto de parámetros en el respirador. Los más comunes son:

- Frecuencia Respiratoria (RR – *Respiratory Rate*)
- Tasa de flujo inspiratorio (IFR – *Inspired Fraction Rate*)
- Fracción de Oxígeno Inspirado (FIO₂ – *Fraction of Inspired Oxygen*)

- Presión espiratoria final positiva (PEEP - *Positive End-Expiratory Pressure*)

La frecuencia respiratoria generalmente se ajusta para avanzar hacia la normocapnia³ o para compensar la acidosis⁴ severa. La tasa de flujo inspiratorio es qué tan rápido se proporciona la inspiración, generalmente expresada en litros/minuto [23]. FIO₂ es la fracción de aire inspirado y debe establecerse en el nivel más bajo para lograr un SpO₂ (saturación arterial de oxígeno) de 92-96% [24]. La PEEP se utiliza para aumentar la capacidad residual funcional y para abrir los alvéolos colapsables mediante endoprótesis⁵ [25].

Una vez ajustadas las entradas de Frecuencia Respiratoria, Tasa de Flujo Inspiratorio, Fracción de Oxígeno Inspirado y Presión Espiratoria Final Positiva, la información obtenida del ventilador mecánico (las salidas o parámetros derivados del ventilador) son:

- Presión pico (P_{peak})
- Presión plateau (P_{plat})
- Resistencia (R)
- *Compliance* (C)

Presión máxima y resistencia:

La presión pico (P_{peak}) es la presión máxima ($P_{m\acute{a}x}$) medida al final de la inspiración. P_{peak} incluye los componentes elásticos y resistivos (vías respiratorias, tejido pulmonar y equipo, por ejemplo, tubo endotraqueal). La diferencia entre P_{peak} y P_{plat} dividida por el flujo de aire es la resistencia (R) de las vías respiratorias. En sujetos normales, los valores de resistencia de las vías respiratorias no superan los 15 – 20 *cmH₂O/L/s* bajo ventilación mecánica

³ Concentración normal de pCO₂ en la sangre. La pCO₂ es la presión parcial del gas carbónico en la circulación sanguínea. La normocapnia designa una respiración normal en un individuo que no tiene ninguna patología, especialmente respiratoria o cardíaca.

⁴ Trastorno del equilibrio ácido-base, caracterizado por un incremento en la acidez del plasma sanguíneo y es, por lo general, una manifestación de trastornos metabólicos en el organismo.

⁵ Dispositivo colocado en una estructura del cuerpo (como un vaso sanguíneo o el tubo digestivo) con el objetivo de mantenerla abierta.

controlada [26]. Varios factores pueden modificar la $P_{m\acute{a}x}$, como el diámetro del tubo endotraqueal [27], la intensidad del flujo de aire, el taponamiento o el broncoespasmo.

Presión plateau:

La presión plateau (P_{plat}) se puede medir durante una pausa inspiratoria cuando los músculos respiratorios están relajados y es igual a la presión alveolar cuando el flujo de aire es cero. No se ve afectado por los cambios en el flujo de aire y la resistencia de las vías respiratorias.

Compliance:

La *compliance* (C), en español compliancia (también llamada distensibilidad), de un sistema hace referencia a la variación de volumen por unidad de cambio en la presión de un sistema. Es decir, es una medida de la resistencia elástica de un sistema. La distensibilidad pulmonar es la distensibilidad total de ambos pulmones. Es uno de los conceptos más importantes que sustentan la ventilación mecánica utilizada para manejar al paciente en el entorno de la Unidad de Cuidados Intensivos (UCI). La siguiente fórmula es útil para calcular la *compliance*:

$$\begin{aligned} & \text{Distensibilidad pulmonar (C)} = \\ & = \frac{\text{Cambio en el volumen pulmonar (V)}}{\text{Cambio en la presión transpulmonar \{Presión alveolar (P_{alv}) - Presión pleural (P_{pl})\}}} \quad (2.1) \end{aligned}$$

La presión transpulmonar se define como el gradiente de presión entre la presión alveolar interna y la presión pleural externa. Se trata de una medida de la capacidad elástica de los pulmones en cada instante del proceso de respiración. La presión alveolar (P_{alv}) es la presión del aire dentro de los alvéolos. La presión pleural (P_{pl}) es la presión del líquido existente en el espacio entre la pleura visceral (capa adherida a los pulmones) y la pleura parietal (capa que reviste la pared torácica). La distensibilidad total de ambos pulmones en un adulto promedio es de 200 ml/cm H_2O .

2.3.1.1 Patrones de la curva de ventilación

El diagrama de presión-tiempo de la Figura 3 representa los cambios producidos en la vía aérea durante el proceso de respiración con respecto a la presión en el sistema. La presión se mide en este caso en *mbar* y el tiempo en segundos (*s*). Dado un volumen determinado y un flujo constante, la presión de la vía aérea dependerá únicamente de la presión alveolar y de la suma total de la resistencia de la vía aérea. Esta resistencia dependerá de la resistencia y la *compliance* de los pulmones y el ventilador empleado. Teniendo en cuenta que los valores del ventilador son constantes, se pueden extraer una serie de conclusiones sobre el estado de los pulmones a partir del diagrama tiempo-presión, así como detectar los cambios que se puedan producir [28].

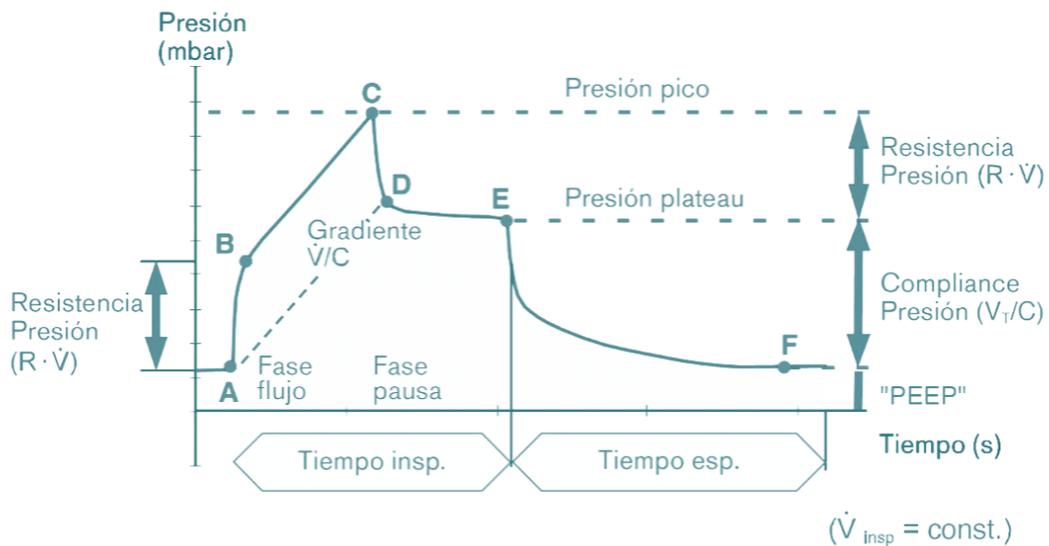


Figura 3. Diagrama de presión-tiempo, volumen controlado, flujo constante [28]

Al inicio de la fase de inspiración la presión entre los puntos A y B aumenta rápidamente como consecuencia de la resistencia del sistema. El nivel de presión en el punto de inflexión B es igual al producto de la resistencia (*R*) por el flujo (*V̇*).

$$\Delta p = R \cdot \dot{V} \quad (2.2)$$

Esta ecuación se confirma en caso de que no haya una PEEP intrínseca. A mayor flujo (\dot{V}), o mayor resistencia (R), mayor será el incremento de la presión en B. Un flujo de inspiración bajo y unos datos de resistencia también bajos producen una menor presión en el punto B.

A partir del punto B la presión se incrementa de forma constante, hasta llegar a C, es decir, hasta alcanzar la presión pico. El gradiente de la curva de presión variará entonces con respecto al flujo (\dot{V}) inspiratorio y la *compliance* C general.

$$\Delta p / \Delta t = \dot{V} / C \quad (2.3)$$

En el punto C el ventilador aplica el volumen tidal⁶ V_T (o volumen corriente) predeterminado, sin suministrar ningún otro flujo ($\dot{V} = 0$).

Finalmente, la presión p cae drásticamente a la presión plateau. Esta disminución en la presión equivale al incremento producido por la resistencia que se genera al inicio del proceso de inspiración. La recta discontinua dibujada del punto A al punto D es paralela a la línea dibujada entre los puntos B y C. Luego tiene lugar una leve disminución de la presión (puntos D a E). Esto se puede deber a la retención de gas por parte del pulmón y a las fugas en el sistema. El nivel de la presión plateau viene definido por la *compliance* (distensibilidad) y el volumen tidal. La diferencia entre la presión plateau (P_{plat}) y la presión espiratoria final positiva (PEEP) se calcula dividiendo entre el volumen tidal entregado entre la *compliance*.

$$\Delta P = P_{plat} - PEEP \quad (2.4)$$

⁶ Volumen de aire que circula entre una inspiración y espiración normal sin realizar un esfuerzo adicional. El valor normal es de aproximadamente 500 ml o 7 ml/kg de peso corporal.

Si la ecuación se invierte se puede calcular fácilmente la *compliance*.

$$C = V_T / \Delta p \quad (2.5)$$

A lo largo del tiempo de meseta (plateau) ningún volumen de gas es entregado a los pulmones, dando lugar a un flujo inspiratorio igual a 0. Por lo tanto, hay un desplazamiento de volumen gracias a las distintas constantes de tiempo, generando una compensación de las presiones entre todas las cavidades del pulmón.

La espiración tiene su inicio en el punto E. Se trata de un proceso donde la elasticidad del tórax hace que el gas sea expulsado hacia el exterior venciendo la presión de la atmósfera. Los cambios en la presión son el resultado de la multiplicación entre la resistencia R exhalatoria del ventilador por el flujo espiratorio \dot{V}_{esp} .

$$\Delta p = R \cdot \dot{V}_{esp} \quad (2.6)$$

Al finalizar la espiración, la presión se establece en el nivel PEEP, una vez más [28].

2.4 Intubación endotraqueal

2.4.1 Técnica

Para la técnica de intubación endotraqueal se emplea un utensilio denominado laringoscopio, al cual se le incorporan unas palas, siendo estas de dos tipos principalmente: Macintosh y Miller.

La pala de Macintosh es de forma curva. La punta de la pala se coloca en el espacio entre la base de la lengua y la epiglotis, también llamado por los médicos “vallécula⁷”. De esta forma se proporciona una visión adecuada de la orofaringe y de la hipofaringe, ofreciendo de este modo mayor espacio para el paso del tubo endotraqueal y reduciendo al mínimo la posibilidad de traumatismos epiglóticos.

La pala de Miller tiene una forma recta y su forma de colocación es introduciéndola de tal modo que su extremo quede por debajo de la superficie laríngea de la epiglotis. El siguiente paso es elevar la epiglotis para comprimirla suavemente contra la pared anterior de la faringe con el objetivo de exponer las cuerdas vocales. Esta pala permite una exposición mejor de la abertura glótica, pero con la desventaja de proporcionar un paso más reducido a través de la orofaringe y de la hipofaringe.

2.4.2 Colocación del paciente

Para la intubación del paciente, la posición correcta debe ser con la cabeza elevada aproximadamente 10 cm, para lo que se emplea unas almohadillas colocadas bajo el occipucio. Además, se debe desplazar la mandíbula hacia delante para colocar al paciente en posición de hiperextensión. De este modo se consigue alinear el eje oral, faríngeo y laríngeo.

2.4.3 Colocación del operador

Una vez el paciente se encuentre en posición de decúbito supino e hiperextensión del cuello, el operador se debe colocar tras él, sosteniendo con la mano izquierda el laringoscopio. Con la mano derecha realizará la apertura bucal del paciente.

⁷ Tiene su origen en la palabra latina *valles*, que significa "valle". Al estar en su forma de diminutivo, sobra el significado literal de "pequeño valle".

El siguiente paso será insertar la pala en el lado derecho de la boca del paciente, evitando así dañar los dientes incisivos, y desplazando la lengua hacia la izquierda.

Una vez la pala se acerca a la base de la lengua, se ejercerá a lo largo del eje del mango de la pala un ligero movimiento hacia delante en un ángulo de 45 grados con el objetivo de visualizar la glotis.

2.4.4 Tubo endotraqueal

El tamaño del tubo endotraqueal varía según la edad, la constitución del paciente y el tipo de cirugía que se vaya a realizar. Con la mano derecha, el operador debe sujetar el tubo como si de un lápiz se tratara, haciéndolo avanzar a través de la cavidad oral desde el lado derecho de la boca y después a través de las cuerdas vocales. En caso de que la visualización de la abertura glótica sea incompleta, se utiliza la epiglotis para así poder introducir el tubo en la tráquea.

La presión cricoidea externa ayuda a visualizar la vía laríngea. Se usa y es discutida en intubaciones de urgencia la presión cricoidea o maniobra de Sellick [29] que consiste en realizar una presión continua y hacia abajo del cartílago cricoides, lo que hace que la laringe se comprima contra el esófago para proteger así la vía aérea frente a una posible broncoaspiración.

El extremo proximal del manguito del tubo se posiciona en la parte inferior de las cuerdas vocales. El mango se infla hasta que se obtiene estanqueidad con una ventilación con presión positiva de 20 – 30 cmH_2O [30].

2.4.5 Traqueobronquitis necrosante

La traqueobronquitis necrosante (NTB – *Necrotizing Tracheobronchitis*) se define como una complicación relacionada a la ventilación mecánica en pacientes con falla respiratoria. NTB se ha definido como un proceso necrótico inflamatorio que afecta los bronquios principales y la tráquea distal en pacientes que requieren ventilación mecánica. Se caracteriza por la sustitución de la mucosa traqueal normal por células inflamatorias, la

mayoría neutrófilos; además de contenido de restos necróticos en la luz de las vías respiratorias.

Clínicamente el diagnóstico de la NTB se realiza sólo en ocasiones cuando se presenta dificultad para la ventilación, incremento en el CO₂, aumento de las secreciones mucosas y obstrucción al flujo de aire en la vía aérea.

El problema en cuestión ya se ha tratado en casos de infecciones debidas al virus influenza H1N1 [31], infecciones bacterianas o enfermedades como la artritis reumatoide o la colitis ulcerosa. Todos estos se han relacionado con la aparición de coágulos sanguíneos bronquiales, la hipersecreción bronquial o la presencia de infección pulmonar bacteriana. Estos coágulos generan la obstrucción severa de la zona bronquial, produciendo un incremento de la presión en la vía aérea y complicando la ventilación. Esto da lugar en la mayoría de los casos a un cambio urgente del tubo endotraqueal del paciente.

Existen dos formas anatómicas de la enfermedad: la forma localizada que por lo general se encuentra a pocos centímetros debajo del tubo traqueal, asociada a pacientes con ventilación de alta frecuencia 16 y el tipo difuso generalmente con poca respuesta inmediata al tratamiento con broncoscopia y representa la lesión más común en autopsias.

Endoscópicamente la NTB se caracteriza por:

- Una apariencia normal en la mucosa de laringe y tráquea próxima a la punta del tubo orotraqueal.
- Eritema o ulceración en el sitio de la punta del tubo orotraqueal.
- Descamación del epitelio secundaria a necrosis y posterior desprendimiento del revestimiento epitelial respiratorio.

2.4.5.1 Traqueobronquitis necrosante en pacientes COVID-19

La COVID-19 (*Coronavirus Disease 2019*) es capaz de ocasionar complicaciones graves o fatales en pacientes de alto riesgo, como puede ser la traqueobronquitis necrosante, la cual provoca la obstrucción de las vías respiratorias debido a los materiales necróticos y hemorrágicos que obstruyen la tráquea y los bronquios.

Esta complicación conlleva un incremento del riesgo de contagio por parte del personal sanitario: es uno de los procedimientos catalogados como de mayor riesgo de transmisión vírica desde los pacientes hacia el personal sanitario.

Durante el período de febrero a abril de 2020 (primera ola) ingresaron en la UCI del Complejo Hospitalario Universitario Insular Materno Infantil un total de 26 pacientes: 22 de ellos necesitaron ventilación mecánica invasiva y, de estos, 16 presentaron al menos un episodio de obstrucción del tubo endotraqueal que precisó cambio. Estas obstrucciones fueron, en los 16 casos registrados, posterior a día 7 del período de intubación, siendo la media del día de aparición de 10,5 días. Algunos pacientes requirieron, incluso, el cambio del tubo en más de una ocasión, con una media de 1,46 veces [32]. Las estadísticas completas se resumen en la Tabla 1.

Tabla 1. Diferencias entre los pacientes con COVID-19 según presenten obstrucción del tubo endotraqueal por traqueobronquitis necrosante [32]

	Total N=22	Obstrucción endotraqueal N = 16 (72,7%)	No obstrucción endotraqueal N = 6 (27,2%)
Edad media (años)	65,2	63,9	68,7
Varones (%)	13 (59,1%)	9 (56,2 %)	4 (66,7%)
Duración de la ventilación (días)	20,5	21,6	17,5
Traqueostomía	16 (72%)	13(81%)	3 (18,8%)
Media de días a los que se produce la obstrucción del tubo endotraqueal		10,5 días	
Media de ocasiones que requieren cambio del tubo endotraqueal		1,5 veces	
Desarrollo de sobreinfecciones respiratorias	11 (50%)	8 (72,2%)	3 (17,3 %)
Uso de azitromicina	15 (68,2 %)	9 (60%)	6 (40%)

	Total N=22	Obstrucción endotraqueal N = 16 (72,7%)	No obstrucción endotraqueal N = 6 (27,2%)
Estancia en la UCI (días)	22,5 días	23,8 días	19 días
Exitus	5 (22,72%)	3 (60%)	2 (40%)

Dividiendo los pacientes intubados en dos grupos, constituyendo el primero de ellos el conjunto de pacientes que presentaron obstrucción (y en consecuencia, cambio de tubo), también llamados pacientes obstructivos, y el segundo grupo aquellos que no (pacientes no obstructivos), se observa una diferencia significativa respecto al número de días en los que precisaron de esta ayuda respiratoria. El primer grupo, es decir, los pacientes obstructivos, estuvieron conectados al respirador una media de 21,6 días, mientras que el segundo grupo, los no obstructivos, presentan una media de 17,5 días. Respecto al proceso de *weaning* o destete, un el 72% del total de los pacientes requirieron una traqueostomía.

11 de los pacientes presentaron sobreinfección respiratoria durante su estancia en la UCI, siendo 8 de ellos pacientes obstructivos.

En relación con el tratamiento recibido, hay que destacar que el 100% de los pacientes que no presentaron obstrucción recibió tratamiento con azitromicina, a diferencia de los del primer grupo, solo el 56,2%.

Por último, fallecieron 5 pacientes: 3 (60%) del primer grupo, proporción mayor al segundo que no sufrió obstrucción (40%).

Como conclusión del estudio realizado por G. Pérez Acosta y L. Santana Cabrera [32], exponen que “los pacientes diagnosticados de neumonía por COVID-19 presentan una elevada frecuencia de traqueobronquitis necrosante, a partir de la primera de semana de ventilación mecánica, causando una obstrucción súbita del tubo endotraqueal que requiere

recambio inmediato del mismo por la hipoxemia y la incapacidad para la ventilación de los pacientes”.

Otro estudio reciente [33] realizado por el Hospital Universitario Príncipe de Asturias, en Madrid, presentan los siguientes resultados: de un total de 37 pacientes, el 70,3% de la muestra son varones de edad media 59,4. Los días medios de ventilación mecánica previa a la realización de traqueostomía fue de 11 días. Se realizó traqueostomía percutánea en el 86,5% de los casos. La media de días desde la traqueostomía hasta la decanulación fue de 17,7 días.

Un tercer estudio [34] trata con pacientes COVID-19 intubados y con VMI (Ventilación Mecánica Invasiva), a los que se ha realizado una traqueotomía quirúrgica, procedentes de cuatro centros en total: dos centros hospitalarios de Barcelona, un hospital público y un hospital privado que ha tratado pacientes tanto del sistema privado como del servicio público de salud a lo largo de la pandemia. Para este estudio se emplean datos de pacientes desde el 16 de marzo hasta el 24 de abril de 2020. Dentro de las variables seleccionadas para el estudio se encuentran sexo, edad, días de intubación, días de traqueotomía, días de VMI tras traqueotomía y complicaciones derivadas de la cirugía. A todos los pacientes se les realizó una traqueotomía de acuerdo con las recomendaciones específicas de la Sociedad Española de Otorrinolaringología y Cirugía de Cabeza y Cuello (SEORL-CCC) para la realización de traqueotomías en pacientes infectados por el SARS-CoV-2 (*Severe Acute Respiratory Syndrome Coronavirus 2*). El cumplimiento de estas recomendaciones se basa en el uso de las medidas de protección adecuadas y de equipos de protección individual (EPI), evitar el uso de sistemas de corte y coagulación eléctricos o ultrasónicos, relajación muscular completa del paciente durante el procedimiento y pre-oxigenación adecuada del paciente, entre otros.

En este estudio participaron 27 pacientes, con una edad media de 65 años. La mediana de días se establece en 19 días desde la intubación hasta la realización de la traqueotomía. Dos pacientes fueron *éxitus* y un paciente fue destetado del ventilador y decanulado. El día 24 de abril, fecha de fin de experimento, 4 de los pacientes siguen en ventilación mecánica, 8 están en proceso de destete y 11 con ventilación espontánea. De los pacientes en los que se ha

podido retirar la VMI, pasaron una media de 4,7 días desde la traqueotomía hasta la retirada de la VMI.

Como resultado del estudio, sus autores concluyen que “la realización de una traqueotomía en aquellos pacientes con infección por el SARS-CoV-2 puede aportar beneficios potenciales en términos de manejo de la vía aérea, reducción de los días de VMI y de la estancia en UCI, con un bajo porcentaje de complicaciones relacionadas con la cirugía. En nuestro caso la mediana de días hasta la realización de la traqueotomía supera los siete días recomendados. Esto se debe a la falta de consenso conforme al momento idóneo de su realización, basándonos en guías de actuación de nuestras unidades de críticos recomendando la traqueotomía entre la segunda y tercera semana de intubación.”

CAPÍTULO 3.

PREPARACIÓN DEL ENTORNO DE TRABAJO

3.1 Fuente de datos empleada

En este capítulo describimos la procedencia de los datos empleados a lo largo del proyecto, así como la forma de almacenaje y el significado de cada uno de ellos. Asimismo, se describen los pasos realizados en el tratamiento previo a su utilización.

3.1.1 Datos de pacientes

Los datos utilizados en este estudio incluyen datos de salud referentes a los ingresos en UCI (Unidad de Cuidados Intensivos) por COVID-19 (*Coronavirus Disease 2019*) en el Complejo Hospitalario Universitario Insular Materno Infantil, Islas Canarias, registrados entre principios de marzo de 2020 y finales de noviembre de 2020, fechas que abarcan las dos primeras olas registradas a nivel mundial de este virus.

Se han combinado dos fuentes de datos. La primera fuente proviene del Sistema de Información Hospitalaria (HIS – *Hospital Information System*) e incluye un conjunto de valores como sexo, edad, IMC (Índice de Masa Corporal), datos de ingreso, etc. La segunda consiste en los datos obtenidos al consultar la historia clínica electrónica en el sistema PICIS [35], e incluye una matriz de datos en la que hay una fila por marca de tiempo y una columna

por cada parámetro medido. La combinación de los datos de ambas fuentes forma nuestros datos crudos, esto es, previos a su tratamiento para poder ser usados.

El estudio se realiza sobre 96 pacientes de la primera y la segunda ola (26 y 70 respectivamente) con neumonía derivada de COVID-19, de los cuales 37 pacientes (16 de la primera ola y 21 de la segunda ola) presentaron al menos un episodio de obstrucción endotraqueal total o parcial durante su ingreso en la UCI.

En la siguiente tabla (Tabla 2) se recogen los datos estadísticos relativos a la estancia de 96 pacientes nombrados anteriormente. La edad se da como media y desviación estándar (SD – *Standard Deviation*) ($\bar{x} \pm \sigma$). El género y la obstrucción bronquial se dan en porcentaje. Los resultados relativos a los días desde el inicio de los síntomas hasta el ingreso hospitalario, intubación, ventilación mecánica y estancia en UCI se expresan en mediana y rango intercuartílico (IQR – *Interquartile Range*).

Tabla 2. Datos demográficos e información relativa a la estancia de los 96 pacientes del estudio

N= 96	Wave 1 (N ₁ =26)	Wave 2 (N ₂ =70)
Edad (años) (media \pm SD)	65.23 \pm 4.96	60.41 \pm 7.45
Género (masculino), n (%)	16 (61.54)	52 (74.29)
Obstrucción bronquial, n (%)	16 (61.54)	22 (31.43)
Días desde inicio de síntomas hasta admisión en hospital, media (IQR)	7 (5-14)	5 (3-7)
Días intubado, media (IQR)	13 (7-16)	7 (0-14)
Días con Ventilación Mecánica Invasiva, media (IQR)	21 (7-30)	8 (0-24)
Días de estancia en UCI, media (IQR)	24 (8-36)	12 (6-26)

Se debe tener en cuenta que los pacientes ingresados en la UCI pueden estar inconscientes o tener poca capacidad de comunicación con los médicos. Esto significa que, desde un punto

de vista científico, necesitamos identificar qué parámetros son los más relevantes para poder hacer una introspección del estado del paciente. Hemos identificado dos grupos de parámetros, fisiológicos y mecánicos ventilatorios. El grupo de fisiológicos (PH) da una idea del estado general del paciente, mientras que el grupo de ventilatorios (MV) muestra la interacción de la máquina de ventilación asistida con el paciente y cómo reacciona el paciente a su acción.

Fruto de los trabajos previos [1]–[5] y por sugerencia de los médicos, se tomaron las siguientes características para cada paciente a lo largo de la estancia en la UCI y se dividieron en dos grupos separados. El grupo 1 está formado por las características fisiológicas (PH): Frecuencia Cardíaca, Presión Sistólica, Presión Diastólica, Saturación de Oxígeno (SatO₂) y Temperatura. El grupo 2 está formado por las características de mecánica ventilatoria (MV): Presión Media, Pico y Meseta (Plateau), Compliance y Resistencia.

Al momento de analizar todos los parámetros seleccionados, encontramos datos perdidos parciales o totales en algunos intervalos de tiempo. Para nuestro estudio, debemos indicar que esta pérdida de datos se ha marcado como ausentes y no se utilizan para nuestros fines.

Se ha de tener en cuenta además que la presencia/ausencia de datos válidos/faltantes es irregular y sin un patrón definido. Por otro lado, se ha detectado que los intervalos en los que se producen faltantes no siguen un patrón conocido y la frecuencia cardíaca y la SatO₂ son las características de las que hay más datos presentes y útiles.

3.1.2 Características empleadas

Para la realización de este trabajo se ha empleado un total de 10 características, las cuales se dividen en dos grupos, características de mecánica ventilatoria y características fisiológicas.

3.1.2.1 Características de Mecánica Ventilatoria

Estas características, abreviadas como “características MV”, (Tabla 3) se corresponden con las salidas generadas por el ventilador mecánico, las cuales se explican en el capítulo

anterior (2.3 *Mecánica ventilatoria en pacientes UCI*). Para cada variable se muestran el rango de valores esperables y las unidades de cada una. Hemos de precisar que las muestras de características en un instante dado que tienen valores fuera del rango son excluidas de nuestro estudio. Por ejemplo, para el caso de la Presión Pico se establece un rango de valores de 10 a 60 cmH_2O , cualquier valor fuera de estos límites se considerará dato no válido. Lo mismo ocurrirá con el resto de las características.

Tabla 3. Características de Mecánica Ventilatoria

Características MV	Límites esperables	Unidades
Presión Pico (respirador/paciente)	10-60	cmH_2O
Presión Plateau y Presión Pausa	10-40	cmH_2O
Presión Media	8-35	cmH_2O
Compliance	2-100	ml/cmH_2O
Resistencia	6-100	$cmH_2O \cdot l^{-1} \cdot s$

3.1.2.2 Características Fisiológicas

Las características fisiológicas (PH) (Tabla 4) son aquellas que se pueden ser medidas en los pacientes y ofrecen una idea del estado de su funcionamiento fisiológico. Al igual que en la Tabla 3, para cada variable se muestran el rango de valores esperables y las unidades de cada una. Igualmente, hemos de precisar que las muestras de características en un instante dado que tienen valores fuera del rango son excluidas de nuestro estudio. A continuación, se describen algunas de las características fisiológicas empleadas en este estudio:

- **Frecuencia Cardíaca:** En el campo de la medicina, el número de veces que el corazón late durante cierto periodo, por lo general un minuto. La frecuencia cardíaca se puede sentir en la muñeca, el lado del cuello, la parte de atrás de las

rodillas, la parte de adelante de los pies, la ingle y otros lugares del cuerpo donde haya una arteria cerca de la piel. En reposo normalmente oscila entre 60 y 100 latidos por minuto en un adulto sano en estado de reposo. La medición de la frecuencia cardíaca proporciona información importante sobre la salud de una persona. También se llama pulso [36].

- **PAS:** La presión arterial (PA) media es el producto del gasto cardíaco por la resistencia periférica total. Es la fuerza que ejerce contra la pared arterial la sangre que circula por las arterias. La presión arterial incluye dos mediciones: la presión sistólica y la presión diastólica. La presión arterial sistólica (PAS) depende del volumen del latido y de la rigidez de los vasos, se mide durante el latido del corazón (momento de presión máxima).
- **PAD:** La presión arterial diastólica (PAD) se correlaciona directamente con la resistencia periférica y se mide durante el descanso entre dos latidos (momento de presión mínima)
- **SatO₂:** El término saturación de oxígeno hace referencia a la cantidad (en %) de oxígeno existente en la sangre, es decir, su nivel de oxigenación. La oxigenación se produce cuando las moléculas de oxígeno (O₂) entran en los tejidos del cuerpo. La saturación de oxígeno en sangre, concretamente la saturación arterial de oxígeno (SatO₂), es un importante parámetro para evaluar la función respiratoria. En muchos casos, según el cuadro clínico, la edad y la situación del paciente, permite sacar conclusiones sobre la función y la actividad del pulmón.
- **Temperatura:** La temperatura normal del cuerpo humano (normotermia, eutermia) es el rango de temperatura típico que se encuentra en los humanos. El rango de temperatura normal del cuerpo humano se establece típicamente entre 36.5– 37.5 °C (97.7– 99.5 °F). La temperatura del cuerpo humano varía dependiendo del sexo, la edad, la hora del día, el nivel de esfuerzo, el estado de salud, en qué parte del cuerpo se realiza la medición, el estado de conciencia

(despierto, dormido, sedado) y las emociones. En este caso se trata de una medición superficial de la temperatura en la piel (temperatura cutánea).

Tabla 4. Características Fisiológicas

Características PH	Límites esperables	Unidades
Frecuencia Cardíaca	30-200	lat/min
PAS i/ni	20-300	mmHg
PAD i/ni	20-180	mmHg
SatO2	40-100	%
Temperatura	30-44	°C

3.2 Extracción de características temporales

Las características principales que usaremos son los valores de las variables clínicas de las que disponemos. No obstante, nos podemos plantear si hay transformaciones de las variables originales que nos pudieran dar más información y que pudieran ser relevantes a efectos de nuestros objetivos. Un requisito que nos hemos planteado, buscando no complicar en exceso la tarea de computación, es usar características temporales. Para ellos usaremos una ventana de análisis deslizante de duración N muestras. Así, hemos optado por las siguientes, y las exploraremos en los resultados.:

- Media.
- Desviación típica.
- Sesgo (*Skewness*): medida estadística que mide la simetría de una distribución en torno a un promedio
- Curtosis (*Kurtosis*): medida estadística del grado de concentración de los valores de una variable en torno a una zona central de la distribución.

- Velocidad de cruces por cero (*Zero Crossing*): medida de la velocidad con la que una forma de onda cruza el eje de valor medio dentro de una ventana de análisis.

3.3 Herramienta de recolección de datos

La recopilación de datos de pacientes ha sido posible gracias al uso de la herramienta *Critical Care Manager* [37]. Esta herramienta recibe datos de dispositivos médicos y los almacena en una base de datos.

CAPÍTULO 4.

ASPECTOS TEÓRICOS SOBRE ALGORITMOS DE MACHINE LEARNING APLICADOS A LA DETECCIÓN TEMPRANA DE OBSTRUCCIÓN DEL TUBO ENDOTRAQUEAL

4.1 Introducción

La neurociencia actual se enfrenta al hecho de que en gran parte de los procesos cognitivos se puede detectar la diferencia entre la dinámica a nivel neuronal y la aparición de actividad mental abstracta. Dicha distinción hace ver que no existe esa correlación entre el hardware (neuronas) y el software de nuestro cerebro (operaciones abstractas, estados mentales), por lo que supone la hipótesis inicial para que los símbolos abstractos puedan ser modificados y tratados por sistemas artificiales que no necesiten de un substrato fisiológico natural. Por tanto, la aparición de la inteligencia artificial se basa en el hecho de manipular expresiones lógicas y esquemas abstractos a través de sistemas artificiales.

Analizando el mecanismo de operación del cerebro humano nos damos cuenta de dos conceptos muy importantes a tener en cuenta, como son la experiencia y el aprendizaje. El cerebro humano de hoy en día es la consecuencia de una evolución biológica debida a alteraciones genéticas, y producto de una serie de técnicas y conocimientos que la

humanidad ha ido acumulando con el tiempo, como pueden ser la cultura o el lenguaje. Desde el punto de vista biológico, encontramos numerosos mecanismos que permiten la existencia de procesos de activación neuronal dependientes de la experiencia previa y del entrenamiento. El mecanismo principal es el llamado ‘plasticidad sináptica’, un proceso mediante el que las conexiones sinápticas entre neuronas modulan su intensidad en relación a la actividad que hayan experimentado anteriormente. De este modo, a mayor actividad neuronal de un canal, más fácil será su activación en un futuro y su integración a nuevos procesos cognitivos de mayor complejidad [38].

La plasticidad neuronal es el pilar principal en la gran parte de los procesos de aprendizaje y memoria. A este paradigma se le conoce como ‘aprendizaje reforzado’, es decir, en este caso la actividad sináptica se refuerza dependiendo del número de veces que se establece una conexión entre neuronas. Esta regla se le conoce como ‘regla de Hebb’, en honor a Donald O. Hebb, neuropsicólogo canadiense. Algunas técnicas de inteligencia artificial como los métodos de aprendizaje supervisado también se basan en reglas similares que permiten modificar de forma adaptativa la forma en que el sistema artificial procesa la información [39].

La inteligencia artificial (IA) es una disciplina científica que tiene que ver con la teoría de la computación. Su fin es simular algunas de las facultades intelectuales humanas en sistemas artificiales. La expresión “inteligencia humana” hace referencia a procesos de percepción sensorial (visión, audición, etc.) y sus posteriores procesos de reconocimiento de patrones, por lo que las aplicaciones más habituales de la IA son el tratamiento de datos y la identificación de sistemas. Desde la aparición de la IA finales de la década de 1950, se ha conseguido resolver problemas de carácter más abstracto, tales como la demostración de teoremas matemáticos, la adquisición del lenguaje, el jugar al ajedrez o la traducción automática de textos. El diseño de un sistema de inteligencia artificial suele necesitar de la utilización de herramientas de disciplinas muy distintas como el cálculo numérico, la estadística, la informática, el procesado de señales, la electrónica sensorial, el control automático, la robótica o la neurociencia. Debido a ello y a pesar de que la inteligencia artificial con frecuencia se considera una rama de las ciencias de la computación, esta es una

disciplina en la que colaboran de forma activa numerosos científicos, ingenieros y matemáticos. Incluso en algunos casos los beneficiarios también pueden ser investigadores del área de la psicología, la sociología o la filosofía.

4.1.1 Breve historia de la inteligencia artificial

Según determinaron los historiadores, el nacimiento de la IA (Inteligencia Artificial) como disciplina de investigación tiene lugar en 1956, fecha en la que los grandes de la inteligencia artificial moderna, John McCarty, Marvin Minsky y Claude Shannon establecieron formalmente el término durante la conferencia de Dartmouth [40], como: “La ciencia e ingenio de hacer máquinas inteligentes, especialmente programas de cálculo inteligente”. La conferencia se financió por la Fundación Rockefeller y se llamó *Dartmouth Summer Research Project on Artificial Intelligence*.

Claude Shannon fue uno de los principales precursores de las telecomunicaciones. Siendo este un TFM para el Máster Universitario en Ingeniería de Telecomunicación, es de esperar que se haga un cierto hincapié en su historia y su contribución en las áreas de telecomunicaciones y de la inteligencia artificial.

Shannon le dio vida al campo de la teoría de la información con la publicación “*A mathematical theory of communication*” [41], que supuso un hito en 1948. Otro de sus logros fue el haber sentado las bases de la teoría del diseño de circuitos digitales en 1937. En su tesis, que desarrolló en el *Massachusetts Institute of Technology* (MIT), demostró que las aplicaciones electrónicas de álgebra booleana serían capaces de crear cualquier relación lógico-numérica. Además ayudó al campo del criptoanálisis para la defensa de Estados Unidos durante la Segunda Guerra Mundial, trabajando sobre el descifrado de códigos y la seguridad en las telecomunicaciones. Quizá en su momento, Shannon no sabía que estaba trabajando en favor de la IA, pero durante los años siguientes a la publicación de su teoría de la comunicación hizo numerosas aportaciones que, a día de hoy, son la base para el desarrollo de cualquier software inteligente.

Al igual que otros muchos científicos, creía que las máquinas podrían pensar. Es por ello que predijo que los ordenadores serían capaces de jugar al ajedrez y, además, derrotar a los seres humanos. Lo hizo en 1950, a través de un artículo titulado “*Programming a computer for playing chess*” [41], publicado en *Philosophical Magazine*, una de las revistas científicas más antiguas.

Su idea acabó siendo un tremendo éxito. De hecho, una de las batallas más legendarias de todos los tiempos fue entre una máquina y un ser humano, concretamente la que libraron Gary Kasparov, un maestro del ajedrez, y Deep Blue en el año 2003.

Entre los asistentes a la conferencia de Darmouth estaban también John McCarthy, Marvin Minsky, Allen Newell y Herbert Simon. Estos dos últimos mencionados, A. Newell y H. Simon, expusieron en 1955 un trabajo que se centraba en la demostración automática de teoremas al que dieron el nombre de *Logic Theorist* [42]. El *Logic Theorist* fue el primer programa de ordenador que imitaba capacidades propias del cerebro humano, por lo tanto, fue denominado el primer sistema de inteligencia artificial de la historia. El sistema tenía la capacidad de demostrar la mayor parte de los teoremas sobre lógica matemática que se presentaban en los tres volúmenes de los Principia Mathematica [43] de Alfred N. Whitehead y Bertrand Russell (1910-1913). Minsky y McCarthy crearon posteriormente el laboratorio de inteligencia artificial del MIT [44], uno de los grupos pioneros en el ámbito.

Uno de los hechos más relevantes en el intento de detectar la presencia de comportamiento inteligente en una máquina fue establecido por Alan Turing en un artículo de 1950 publicado en la revista *Mind* y titulado *Computing Machinery and Intelligence* [45]. Turing proponía un test de inteligencia para máquinas para el que una máquina actuaría con un comportamiento inteligente en la medida de lo posible manteniendo una conversación con un humano sin que una persona externa fuera capaz de distinguir quién es quién (humano u ordenador). Aunque el test de Turing ha sufrido numerosas adaptaciones, correcciones y controversias, se trata de los primeros intentos de alcanzar una definición objetiva de la inteligencia.

El “Teorema de incompletitud de Gödel” [46] también cobra sentido aquí. Este teorema de 1931 expone un conjunto de teoremas de lógica matemática que determinan las

limitaciones que incluye un sistema que esté basado en reglas y procedimientos lógicos (como lo son todos los sistemas de IA). En la década de los setenta, en cierto modo como una contestación al test de Turing, tuvo lugar la aparición de un área nueva, denominada procesamiento del lenguaje natural (NLP, *Natural Language Processing*). Este procesamiento se centra en sistemas artificiales capaces de producir frases inteligentes y de establecer y mantener conversaciones con humanos. El NLP ha permitido la aparición de numerosas áreas de investigación en el campo de la lingüística computacional, incluyendo aspectos como la desambiguación semántica o la comunicación con datos incompletos o erróneos.

En los años ochenta tuvo lugar el desarrollo de las primeras aplicaciones comerciales de la IA, especialmente orientadas a problemas de producción, control de procesos o contabilidad. Con esto nacieron los primeros sistemas expertos, capaces de ejecutar tareas de diagnóstico y toma de decisiones a partir de información cedida por profesionales expertos.

A pesar de los grandes avances en este ámbito, sigue sin existir una máquina que pueda pasar el test de Turing tal y como se planteó en el artículo original. Esto no es tanto debido a un fracaso de la IA como a que los intereses del área se han ido redefiniendo a lo largo de la historia.

4.2 Introducción al aprendizaje máquina

El aprendizaje máquina (también conocido por su acepción en inglés *Machine Learning*, *ML*) se centra en obtener, a partir de un estado inicial, una serie de pasos que, después de pasar a través de un conjunto de estados de búsqueda provisionales, nos conducen a un estado final predefinido.

Esta búsqueda se realiza siguiendo unos pasos individuales, que son ejecutados por operadores de búsqueda que han sido determinados previamente por el programador.

El objetivo de este trabajo no es reclasificar objetos cuyas clases ya son conocidas, lo que realmente se pretende es etiquetar ejemplos futuros (incluso pasados o presentes), aquellos cuyas clases aún se ignoran. Por ello no se puede medir la tasa de error comparando las

clases conocidas de los ejemplos de entrenamiento o aprendizaje con las recomendadas por el clasificador. El funcionamiento del clasificador se estudia experimentalmente.

En un caso sencillo los ejemplos preclasificados disponibles serán trabajados por parejas (Tabla 5): un conjunto de entrenamiento a partir del cual se crea el clasificador, y un conjunto de prueba en el que se evalúa el modelo entrenado.

Tabla 5. Ejemplos disponibles

EJEMPLOS DISPONIBLES	
Conjunto de entrenamiento	Conjunto de prueba

Una división diferente de entrenamiento/prueba dará lugar a un clasificador diferente, y también a una predicción diferente del funcionamiento futuro. Esto podría dar lugar a problemas si el número de ejemplos preclasificados es pequeño.

Una solución para evadir estos problemas podría ser repetir el proceso de división aleatoria en las parejas de entrenamiento y prueba varias veces, siempre produciendo un clasificador del conjunto de entrenamiento i -ésimo, y luego midiendo la tasa de acierto, A_i , de su correspondiente conjunto de prueba. En este punto, se ha de resaltar el hecho de que las tasas de acierto son medidas de calidad del clasificador y hay variantes que se utilizarán convenientemente.

En algunos casos, el conjunto de entrenamiento se crea manualmente: un experto prepara los ejemplos, los etiqueta con etiquetas de clase, elige los atributos y especifica el valor de cada atributo en cada ejemplo. En otros, el proceso está automatizado.

A veces, los vectores de atributos se extraen automáticamente de una base de datos y son etiquetados por un experto. También, se pueden obtener algunos ejemplos de una base de datos, y otros añadirlos manualmente o combinar dos o más bases de datos. El número de

variaciones es prácticamente ilimitado, pero sea cual sea la fuente de los ejemplos, es probable que haya errores. Algunos problemas que se suelen presentar son:

- **Atributos irrelevantes.** Algunos atributos son importantes, mientras que otros no lo son.
- **Falta de Atributos.** A veces pueden faltar algunos atributos críticos.
- **Atributos redundantes.** No son especialmente dañinos, son los atributos que son redundantes en el sentido de que sus valores pueden obtenerse de otros atributos.
- **Valores de atributos faltantes.** El valor de algunos atributos no se conoce. Este es el caso que se nos ha dado en este proyecto.

Además, los valores de los atributos y las etiquetas de clase a menudo no son verídicos debido a que las fuentes de información son poco fiables, los dispositivos de medición son deficientes, errores tipográficos y muchas otras razones. Afortunadamente, este no es el caso de este proyecto, pues la relación entre atributos y etiquetas de eventos de interés ha sido realizada de conjuntamente entre médicos especialistas en medicina intensiva e ingenieros.

A veces, establecer la clase de cada ejemplo no es suficiente en algunas aplicaciones, también se requiere conocer las razones detrás de dicha clasificación [47].

4.2.1 Formas de aprendizaje

Existen dos tipos comunes de aprendizaje, supervisado y no supervisado.

El aprendizaje supervisado se utiliza para estimar un mapeo desconocido (entrada, salida) a partir de muestras conocidas (entrada, salida). Las tareas de clasificación y regresión suelen abordarse utilizando este tipo de aprendizaje. El término supervisado denota el hecho de que se conocen valores de salida para muestras de entrenamiento (es decir, proporcionados por un maestro o un sistema que se está modelando). Esta es la forma de aprendizaje adecuada para aplicar a nuestro proyecto.

En el aprendizaje no supervisado, solo se dan muestras de entrada a un sistema de aprendizaje, y no existe valores conocidos de la salida durante el aprendizaje. El objetivo del

aprendizaje no supervisado puede ser aproximar la distribución de probabilidad de las entradas o descubrir una estructura natural (es decir, grupos) en los datos de entrada.

En los sistemas biológicos, las tareas de reconocimiento y percepción de bajo nivel se aprenden a través del aprendizaje no supervisado, mientras que las capacidades de nivel superior generalmente se adquieren a través del aprendizaje supervisado.

Por ejemplo, los bebés aprenden a reconocer rostros familiares mucho antes de que puedan entender el habla humana. Por el contrario, las habilidades de lectura y escritura no se pueden adquirir de manera no supervisada; necesitan ser enseñados. Esta observación sugiere que los esquemas biológicos de aprendizaje no supervisado se basan en estructuras internas potentes (para una representación y procesamiento óptimos de datos sensoriales) desarrollados a través de los años de evolución, en el proceso de adaptación a la naturaleza estadística del entorno. Por lo tanto, puede ser beneficioso utilizar estructuras inspiradas biológicamente para el aprendizaje no supervisado en sistemas de aprendizaje artificial [48].

A diferencia de los dos enfoques más tradicionales (entrenamiento supervisado y entrenamiento no supervisado), en una posición híbrida, los algoritmos semi-supervisados emplean pocos datos etiquetados y muchos datos no etiquetados como parte del conjunto de entrenamiento. Dichos algoritmos tratan de explorar la información estructural que contienen los datos no etiquetados con el objetivo de generar modelos predictivos que funcionen mejor que los que sólo utilizan datos etiquetados [49].

Todas estas opciones de aprendizaje automático se exponen de forma sencilla en el siguiente esquema (Figura 4).

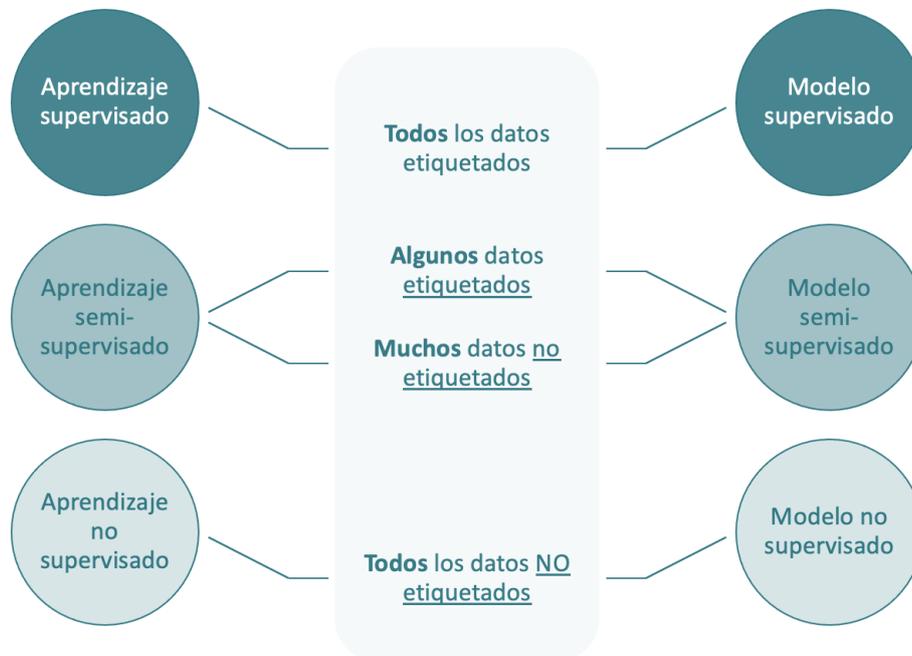


Figura 4. Esquema de los distintos enfoques de aprendizaje automático

4.3 Algoritmos de aprendizaje máquina

Una vez se conoce qué es y cómo funciona el aprendizaje máquina se explica a continuación algunos de los algoritmos más comunes.

- **Algoritmos de regresión:** En las tareas de regresión, el programa de aprendizaje automático debe estimar y comprender las relaciones entre las variables. El análisis de regresión se enfoca en una variable dependiente y una serie de otras variables cambiantes, lo que lo hace particularmente útil para la predicción y el pronóstico.
- **Algoritmos bayesianos:** Este tipo de algoritmos por clasificación están basados en el teorema de Bayes y clasifican cada valor como independiente de cualquier otro. Lo que permite predecir una clase o categoría en función de un conjunto dado de características, utilizando la probabilidad. A pesar de su simplicidad, con frecuencia

el clasificador funciona sorprendentemente bien y se usa a menudo porque supera a los métodos de clasificación más sofisticados.

- **Algoritmos de agrupación:** Se utilizan en el aprendizaje no supervisado, y sirven para categorizar datos no etiquetados, es decir, datos sin categorías o grupos definidos. El algoritmo funciona mediante la búsqueda de grupos dentro de los datos, con el número de grupos representados por la variable K . A continuación, funciona de manera iterativa para asignar cada punto de datos a uno de los K grupos según las características proporcionadas.
- **Algoritmos de árbol de decisión:** Un árbol de decisión es una estructura de árbol similar a un diagrama de flujo que utiliza un método de bifurcación para ilustrar cada resultado posible de una decisión. Cada nodo dentro del árbol representa una prueba en una variable específica, y cada rama es el resultado de esa prueba.
- **Algoritmos de redes neuronales:** Una red neuronal artificial (RNA) comprende unidades dispuestas en una serie de capas, cada una de las cuales se conecta a las capas anexas. Las RNA se inspiran en los sistemas biológicos, como el cerebro, y en cómo procesan la información. Por lo tanto, son esencialmente un gran número de elementos de procesamiento interconectados, que trabajan al unísono para resolver problemas específicos. También aprenden con el ejemplo y la experiencia, y son extremadamente útiles para modelar relaciones no lineales en datos de alta dimensión, o donde la relación entre las variables de entrada es difícil de entender.
- **Algoritmos de reducción de dimensión:** La reducción de dimensión reduce el número de variables que se consideran para encontrar la información exacta requerida.
- **Algoritmos de Aprendizaje Profundo:** Los algoritmos de aprendizaje profundo ejecutan datos a través de varias capas de algoritmos de redes neuronales, las cuales pasan a una representación simplificada de los datos a la siguiente capa. La mayoría funciona bien en conjuntos de datos que tienen hasta unos cientos de características o columnas. Sin embargo, un conjunto de datos no estructurado, como el de una

imagen, tiene una cantidad tan grande de características que este proceso se vuelve engorroso o completamente inviable.

4.4 Redes Bayesianas

Las redes bayesianas modelan un fenómeno mediante un conjunto de variables y las relaciones de dependencia entre ellas. Dado este modelo, se puede hacer inferencia bayesiana; es decir, estimar la probabilidad posterior de las variables no conocidas, en base a las variables conocidas. Estos modelos pueden tener diversas aplicaciones, para clasificación, predicción, diagnóstico, etc. Además, pueden dar información interesante en cuanto a cómo se relacionan las variables del dominio, las cuales pueden ser interpretadas en ocasiones como relaciones de causa–efecto.

Inicialmente, estos modelos eran construidos “a mano” basados en un conocimiento experto, pero con los años han evolucionado hacia el desarrollado de diversas técnicas para aprender a partir de datos, tanto la estructura como los parámetros asociados al modelo. También es posible el combinar conocimiento experto con los datos para aprender el modelo [50].

4.4.1 Definición de red bayesiana

Las redes bayesianas son una representación gráfica de dependencias para razonamiento probabilístico, en la cual los nodos representan variables aleatorias y los arcos representan relaciones de dependencia directa entre las variables. La Figura 5 muestra un ejemplo hipotético de una red bayesiana (RB) que representa cierto conocimiento sobre medicina. En este caso, los nodos representan enfermedades, síntomas y factores que causan algunas enfermedades. La variable a la que apunta un arco es dependiente de la que está en el origen de éste, por ejemplo fiebre depende de tifoidea y gripe en la red de la Figura 5. La topología o estructura de la red nos da información sobre las dependencias probabilísticas entre las variables. La red también representa las independencias condicionales de una variable (o conjunto de variables) dada(s) otra(s) variable(s).

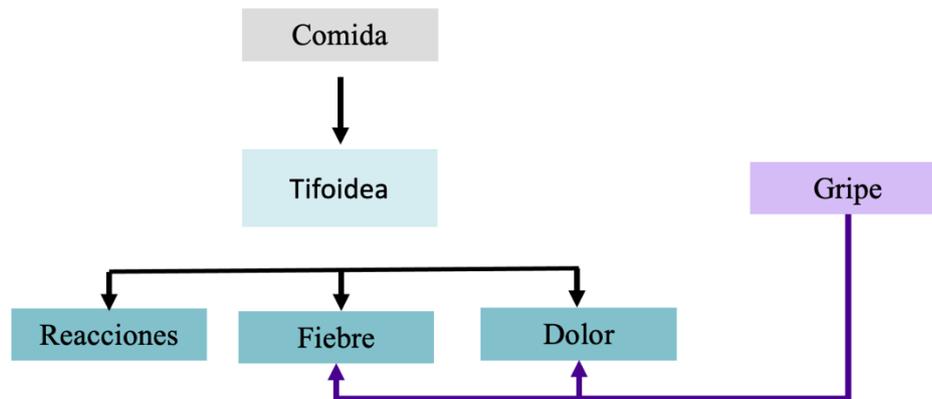


Figura 5. Ejemplo de una red bayesiana. Los nodos representan variables aleatorias y los arcos relaciones de dependencia [50]

4.4.2 Aprendizaje de clasificadores bayesianos

Un clasificador, en general, suministra una función que mapea (clasifica) un dato (instancia), especificado por una serie de características o atributos, en una o diferentes clases predefinidas. Los clasificadores bayesianos son ampliamente utilizados debido a que presentan ciertas ventajas:

- Generalmente, son fáciles de construir y de entender.
- Las inducciones de estos clasificadores son extremadamente rápidas, requiriendo sólo un paso para hacerlo.
- Es muy robusto considerando atributos irrelevantes.
- Toma evidencia de muchos atributos para realizar la predicción final.

Un clasificador bayesiano se puede ver como un caso especial de una red bayesiana en la cual hay una variable especial que es la clase y las demás variables son los atributos. La estructura de esta red depende del tipo de clasificador.

4.4.3 Aprendizaje de redes bayesianas

El aprendizaje, en general, de redes bayesianas consiste en inducir un modelo, estructura y parámetros asociados, a partir de datos. Este puede dividirse naturalmente en dos partes:

- **Aprendizaje estructural:** Obtener la estructura o topología de la red.
- **Aprendizaje paramétrico:** Dada la estructura, obtener las probabilidades asociadas.

En la práctica, en muchas ocasiones los datos no están completos. Hay dos tipos básicos de información incompleta: Valores faltantes: Faltan algunos valores de una de las variables en algunos casos. Nodos ocultos: Faltan todos los valores de una variable. Cuando existen valores faltantes, que es el caso más habitual, existen varias alternativas, entre ellas:

- Eliminar los casos (registros) donde aparecen valores faltantes.
- Considerar un nuevo valor adicional para la variable, como 'desconocido'.
- Tomar el valor más probable (promedio) de la variable.
- Considerar el valor más probable en base a las otras variables.
- Considerar la probabilidad de los diferentes valores en base a las otras variables.

Las primeras dos alternativas pueden ser adecuadas cuando se tienen muchos datos, pero si no, se está de alguna manera desaprovechando información. La tercera alternativa no considera las demás variables del modelo, por lo que normalmente no da los mejores resultados. La cuarta y quinta alternativa son las más interesantes y en general las mejores. Para el caso del valor más probable se parte de una red bayesiana inicial construida en base a los datos completos. Posteriormente, se podría complementar el modelo usando los registros con datos incompletos, en base al siguiente algoritmo:

1. Asignar todas las variables observadas en el registro.
2. Propagar su efecto y obtener las probabilidades posteriores de las no observables.

3. Para las variables no observables, asumir el valor con probabilidad mayor como observado.
4. Actualizar las probabilidades previas y condicionales en el modelo.
5. Repetir 1 a 4 para cada observación.

Esto se puede mejorar si, en vez de tomar el valor más probable, se considera cada caso como varios casos parciales, en base a la probabilidad posterior de cada valor de la variable faltante. Cuando existen nodos ocultos, se pueden también estimar las tablas de probabilidad condicional faltantes. El método más comúnmente utilizado es el de la “maximización de la expectación” (EM, por sus siglas en inglés, *Expectation Maximization*).

4.4.4 Aplicación del teorema de Bayes en clasificación

Para abordar la tarea de clasificación se ha escogido trabajar con el clasificador *Naïve Bayes* (NBC - *Naïve Bayes Classifier*).

El algoritmo NBC, es un clasificador probabilístico fundamentado en el teorema de Bayes y algunas hipótesis simplificadoras adicionales. Es a causa de estas simplificaciones, que se suelen resumir en la hipótesis de independencia entre las variables predictoras, que recibe el apelativo de *naïve*, es decir, “ingenuo”.

Aunque la suposición de la independencia de los atributos es generalmente una suposición pobre, suele proporcionar una mejor precisión de clasificación en conjuntos de datos en tiempo real que cualquier otro clasificador. Además, una ventaja de este clasificador es que solo se requiere una pequeña cantidad de datos de entrenamiento para estimar los parámetros (las medias y las varianzas de las variables) necesarias para la clasificación. Como las variables independientes se asumen, solo es necesario determinar las varianzas de las variables de cada clase.

El NBC aprende de los datos de entrenamiento y luego predice la clase de la instancia de prueba con la mayor probabilidad posterior. También es útil para datos dimensionales altos ya que la probabilidad de cada atributo se estima independientemente [51].

4.4.4.1 El paradigma Naïve Bayes

(Bayes, 1764)

Sean A y B dos sucesos aleatorios cuyas probabilidades se denotan por $p(A)$ y $p(B)$ respectivamente, verificándose que $p(B) > 0$. Supongamos conocidas las probabilidades a priori de los sucesos A y B , es decir, $p(A)$ y $p(B)$, así como la probabilidad condicionada del suceso B dado el suceso A , es decir $p(B|A)$. La probabilidad a posteriori del suceso A conocido que se verifica el suceso B , es decir $p(A|B)$, puede calcularse a partir de la siguiente fórmula:

$$p(A|B) = \frac{p(A,B)}{p(B)} = \frac{p(A)p(B|A)}{p(B)} = \frac{p(A)p(B|A)}{\sum_{A'} p(A')p(B|A')} \quad (4.1)$$

Planteando el supuesto de un *problema clásico de diagnóstico* empleando terminología del ámbito de medicina (pudiendo emplearse también en ingeniería y otras ramas), encontramos los siguientes términos [52]:

- *hallazgo*, haciendo referencia a la determinación del valor de una variable predictora X_r . Así por ejemplo x_r (valor de la variable X_r) puede estar representando la existencia de vómitos en un determinado enfermo;
- *evidencia*, denota el conjunto de todos los hallazgos para un determinado individuo. Es decir $x = x_1, \dots, x_n$ puede estar denotando (si $n = 4$) que el individuo en cuestión es joven, hombre, presenta vómitos y además no tiene antecedentes familiares;
- *diagnóstico*, denota el valor que toman las m variables aleatorias Y_1, \dots, Y_n , cada una de las cuales se refiere a una enfermedad;

- *probabilidad a priori del diagnóstico*, $p(y)$ o $p(Y_1 = y_1, \dots, Y_m = y_m)$, se refiere a la probabilidad de un diagnóstico concreto, cuando no se conoce nada acerca de los hallazgos, es decir, cuando se carece de evidencia;
- *probabilidad a posteriori de un diagnóstico*, $p(y|x)$ o $p(Y_1 = y_1, \dots, Y_m = y_m | X_1 = x_1, \dots, X_n = x_n)$, es decir, la probabilidad de un diagnóstico concreto cuando se conocen n hallazgos (*evidencia*).

En el planteamiento clásico del diagnóstico (Tabla 6) se supone que los m diagnósticos posibles son *no excluyentes*, es decir, pueden ocurrir a la vez, siendo cada uno de ellos dicotómico⁸. Volviendo al ámbito médico, asignamos cada uno de los m posibles diagnósticos no excluyentes a una enfermedad, pudiendo tomar dos valores: 0 = *no existencia* y 1 = *existencia*. Las n variables aleatorias X_1, \dots, X_n representarán los hallazgos o síntomas, asumiéndolas también como dicotómicas, con valores 0 y 1. En este caso el valor 0 en la variable X_i indica la ausencia del i -ésimo hallazgo o síntoma mientras que el valor 1 indica la presencia del hallazgo o síntoma correspondiente.

Tabla 6. Problema clásico de diagnóstico

	X_1	...	X_n	Y_1	...	Y_m
$(x^{(1)}, y^{(1)})$	$x_1^{(1)}$...	$x_n^{(1)}$	$y_1^{(1)}$...	$y_m^{(1)}$
$(x^{(2)}, y^{(2)})$	$x_1^{(2)}$...	$x_n^{(2)}$	$y_1^{(2)}$...	$y_m^{(2)}$
...
$(x^{(N)}, y^{(N)})$	$x_1^{(N)}$...	$x_n^{(N)}$	$y_1^{(N)}$...	$y_m^{(N)}$

⁸ Dicotómico: De la dicotomía o relacionado con ella. Dicotomía: División de un concepto o una materia teórica en dos aspectos, especialmente cuando son opuestos o están muy diferenciados entre sí.

Una vez conocido el valor de la evidencia, el problema del diagnóstico consiste en encontrar la diagnosis de mayor probabilidad. En notación matemática el diagnóstico óptimo, (y_1^*, \dots, y_m^*) será aquel cumpla lo siguiente:

$$(y_1^*, \dots, y_m^*) = \arg \max_{(y_1, \dots, y_m)} p(Y_1 = y_1, \dots, Y_m = y_m | X_1 = x_1, \dots, X_n = x_n) \quad (4.2)$$

Aplicando el teorema de Bayes para calcular

$$p(Y_1 = y_1, \dots, Y_m = y_m | X_1 = x_1, \dots, X_n = x_n) \quad (4.3)$$

obtenemos:

$$\begin{aligned} & p(Y_1 = y_1, \dots, Y_m = y_m | X_1 = x_1, \dots, X_n = x_n) = \\ &= \frac{p(Y_1 = y_1, \dots, Y_m = y_m) p(X_1 = x_1, \dots, X_n = x_n | Y_1 = y_1, \dots, Y_m = y_m)}{\sum_{y_1', \dots, y_m'} p(Y_1 = y_1', \dots, Y_m = y_m') p(X_1 = x_1, \dots, X_n = x_n | Y_1 = y_1, \dots, Y_m = y_m')} \end{aligned} \quad (4.4)$$

Para estimar $p(Y_1 = y_1, \dots, Y_m = y_m)$, y teniendo en cuenta que cada variable Y_i es dicotómica, necesitaremos un total de $2^m - 1$ parámetros. Del mismo modo, por cada una de las distribuciones de probabilidad condicionadas, $p(X_1 = x_1, \dots, X_n = x_n | Y_1 = y_1, \dots, Y_m = y_m)$, se necesitan estimar $2^n - 1$ parámetros. Al tener un total de 2^m de tales distribuciones de probabilidad condicionadas, debemos estimar $(2^n - 1)2^m$ parámetros. Por lo que, para calcular un modelo del clásico diagnóstico, serán necesarios un total de $2^m - 1 + 2^m(2^n - 1)$ parámetros. En la Tabla 7 se muestra una serie de ejemplos a modo de orientación respecto al número de parámetros necesarios dependiendo de los valores de m (número de enfermedades) y n (número de hallazgos) [52].

Tabla 7. Número de parámetros a estimar, en función de m (número de enfermedades) y n (número de síntomas), en el paradigma clásico de diagnóstico

m	n		Parámetros
3	10	\cong	$8 \cdot 10^3$
5	20	\cong	$33 \cdot 10^6$
10	50	\cong	$11 \cdot 10^{17}$

Para facilitar la estimación del gran número de parámetros necesarios para el paradigma, el siguiente paso será simplificar las premisas sobre las que se sostiene.

El primer punto será considerar que los *diagnósticos son excluyentes*, es decir, que dos diagnósticos no pueden darse simultáneamente. La consecuencia de esto será considerar una única variable aleatoria unidimensional siguiendo una distribución polinomial con m valores posibles.

De esta forma tenemos n variables predictoras, denominadas X_1, \dots, X_n , consideradas además como binarias. La letra C representa la variable de diagnóstico, sobre la cual se establece la suposición de poder tomar m posibles valores.

La búsqueda del diagnóstico más probable a posteriori, c^* , una vez conocidos los síntomas de un determinado paciente, $x = (x_1, \dots, x_n)$, puede plantearse como la búsqueda del estado de la variable C con mayor probabilidad a posteriori. Es decir

$$c^* = \arg \max_c p(C = c | X_1 = x_1, \dots, X_n = x_n) \quad (4.5)$$

El cálculo de $p(C = c | X_1 = x_1, \dots, X_n = x_n)$ puede llevarse a cabo utilizando el teorema de Bayes, y ya que el objetivo es calcular el estado de C , c^* , con mayor probabilidad a posteriori, no es necesario calcular el denominador del teorema de Bayes. Es decir,

$$p(C = c | X_1 = x_1, \dots, X_n = x_n) \propto p(C = c)p(X_1 = x_1, \dots, X_n = x_n | C = c) \quad (4.6)$$

Por tanto, en el paradigma en el que los distintos diagnósticos son excluyentes, y considerando que el número de posibles diagnósticos es m , y que cada variable predictora X_i es dicotómica, tenemos que el número de parámetros a estimar es $(m - 1) + m(2^n - 1)$, de los cuales:

- $m - 1$ se refiere a las probabilidades a priori de la variable C ;
- $m(2^n - 1)$ se relacionan con las probabilidades condicionadas de cada posible combinación de las variables predictoras dado cada posible valor de la variable C .

Una aproximación del número de parámetros a estimar para distintos valores de m y n se muestra en la siguiente tabla (Tabla 8).

Tabla 8. Número de parámetros a estimar, en función de m (número de enfermedades) y n (número de síntomas), en el paradigma clásico de diagnóstico con diagnósticos excluyentes

m	n		Parámetros
3	10	≈	$8 \cdot 10^3$
5	20	≈	$5 \cdot 10^6$
10	50	≈	$11 \cdot 10^{15}$

Observando los datos de la tabla anterior (Tabla 8), podemos seguir confirmando que se trata de un número elevado de parámetros a estimar. Es por ello por lo que se imponen nuevas suposiciones aún más restrictivas con el objetivo de convertir estos paradigmas en modelos implementables.

Finalmente se introduce el paradigma *Naïve Bayes: diagnósticos excluyentes y hallazgos condicionalmente independientes dado el diagnóstico*. El paradigma *Naïve Bayes* se basa en dos premisas establecidas sobre las variables predictoras (hallazgos, síntomas) y la variable a predecir (diagnóstico). Dichas premisas son:

- los diagnósticos son excluyentes, es decir, la variable C a predecir toma uno de sus m posibles valores: c_1, \dots, c_m ;

- los hallazgos son condicionalmente independientes dado el diagnóstico, es decir, que si uno conoce el valor de la variable diagnóstico, el conocimiento del valor de cualquiera de los hallazgos es irrelevante para el resto de los hallazgos. Esta condición se expresa matemáticamente por medio de la fórmula:

$$p(X_1 = x_1, \dots, X_n = x_n | C = c) = \prod_{i=1}^n p(X_i = x_i | C = c) \quad (4.7)$$

ya que por medio de la regla de la cadena se obtiene:

$$\begin{aligned} p(X_1 = x_1, \dots, X_n = x_n | C = c) &= p(X_1 = x_1 | X_2 = x_2, \dots, X_n = x_n, C = c) \\ &\quad p(X_2 = x_2 | X_3 = x_3, \dots, X_n = x_n, C = c) \quad (4.8) \\ &\quad \dots p(X_n = x_n | C = c) \end{aligned}$$

Por otra parte teniendo en cuenta la independencia condicional entre las variables predictoras dada la variable clase, se tiene que:

$$p(X_i = x_i | X_{i+1} = x_{i+1}, \dots, X_n = x_n, C = c) = p(X_i = x_i | C = c) \quad (4.9)$$

para todo $i = 1, \dots, n$. De ahí que se verifique la ecuación 1.

Por tanto, en el paradigma *Naïve Bayes*, la búsqueda del diagnóstico más probable, c^* , una vez conocidos los síntomas (x_1, \dots, x_n) de un determinado paciente, se reduce a:

$$\begin{aligned} c^* &= \arg \max_c p(C = c | X_1 = x_1, \dots, X_n = x_n) = \\ &= \arg \max_c p(C = c) \prod_{i=1}^n p(X_i = x_i | C = c) \quad (4.10) \end{aligned}$$

Suponiendo que todas las variables predictoras son dicotómicas, el número de parámetros necesarios para especificar un modelo *Naïve Bayes* resulta ser $(m - 1) + mn$, ya que

- se necesitan $(m - 1)$ parámetros para especificar la probabilidad a priori de la variable C ;
- para cada variable predictora X_i se necesitan m parámetros para determinar las distribuciones de probabilidad condicionadas.

La Tabla 9 muestra finalmente el número de parámetros necesarios calculados tras todas estas premisas. Estos datos han sido calculados en función del número de posibles diagnósticos y del número de síntomas necesarios para especificar el paradigma *Naïve Bayes*.

Tabla 9. Número de parámetros a estimar en el paradigma *Naïve Bayes* en función del número de diagnósticos posibles (m) y del número de síntomas (n)

m	n	<i>Parámetros</i>
3	10	32
5	20	104
10	50	509

En el caso de que las n variables predictoras X_1, \dots, X_n sean continuas, se tiene que el paradigma *Naïve Bayes* se convierte en buscar el valor de la variable C , que denotamos por c^* , que maximiza la probabilidad a posteriori de la variable C , dada la evidencia expresada como una instanciación de las variables X_1, \dots, X_n , esto es, $x = (x_1, \dots, x_n)$.

CAPÍTULO 5.

ALGORITMO DE DETECCIÓN TEMPRANA DE OBSTRUCCIÓN DEL TUBO ENDOTRAQUEAL EN PACIENTES COVID-19

En este capítulo se pretende describir paso a paso las distintas fases por las que han pasado los datos de cada uno de los pacientes hasta llegar al paso final, donde se realizará el entrenamiento y test.

5.1 Introducción

Los módulos de programas desarrollados a lo largo de este Trabajo de Fin de Máster han sido dos:

- **Módulo de identificación de paciente potencialmente obstructivo.** El objetivo de este módulo es identificar en las fases más tempranas de entrada a la UCI (por ejemplo, los primeros días) qué pacientes presentan más riesgo de evolucionar a una obstrucción de tubo endotraqueal y, posteriormente, a una traqueobronquitis necrotizante. Se pretende así intentar evitar alarmas posteriores debidas a obstrucción con el consiguiente beneficio para el paciente.
- **Módulo de detección de las fases normal, pre-obstructiva y obstructiva.** El objetivo de este módulo es detectar de forma lo más temprana posible el instante en que se va a producir una obstrucción. Para ello discriminamos periodos

normales y su posible evolución a pre-obstructivos que, una vez detectados, permitan tomar medidas que eviten la obstrucción en sí misma.

Con cada uno de estos programas se ofrecen unas métricas de calidad, dadas en porcentajes, que en nuestro trabajo son: sensibilidad, especificidad, Valor Predictivo Positivo (*PPV - Positive Predictive Value*) y Valor Predictivo Negativo (*NPV - Negative Predictive Value*). Con esto, el médico dispone de una ayuda para tomar sus propias decisiones atendiendo a las probabilidades calculadas por la máquina.

Ambos programas siguen, en rasgos generales, el mismo flujo de trabajo. Se comienza realizando un procesamiento de los datos paciente a paciente para, a continuación, realizar los correspondientes entrenamientos y test.

5.2 Parámetros de calidad

Para definir los parámetros de calidad tendremos en cuenta que estamos haciendo predicciones aplicadas a detección. A tal efecto, utilizamos unos parámetros calidad que se definen a partir de las detecciones, según el tipo de acierto o error.

5.2.1 Parámetros de calidad basados en la matriz de confusión

Para poder comprender los parámetros de calidad utilizados es necesario primero entender el significado de los siguientes parámetros previos: TP: True Positive, FN: False Negative, TN: True Negative y FP: False Positive, veamos qué significan:

- *True Positive* (verdadero positivo): el modelo predice correctamente la clase positiva.
- *False Positive* (falso positivo): el modelo predice incorrectamente la clase positiva.
- *True Negative* (verdadero negativo): el modelo predice correctamente la clase negativa.

- *False Negative* (falso negativo): el modelo predice incorrectamente la clase negativa.

En la Tabla 10 se muestran estos conceptos visualmente:

Tabla 10. Definición gráfica de True Positive, True Negative, False Positive y False Negative

		<i>Predicción</i>	
		Positiva	Negativa
<i>Observación</i>	Positiva	Verdadero Positivo <i>True Positive (TP)</i>	Falso Negativo <i>False Negative (FN)</i>
	Negativa	Falso Positivo <i>False Positive (FP)</i>	Verdadero Negativo <i>True Negative (TN)</i>

Lo anterior es una matriz de confusión y nos permite visualizar el desempeño de un algoritmo de clasificación. Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias en la clase real. En la Tabla 11 se presenta nuestro modelo casos de pacientes obstructivos con una matriz de confusión de 2x2 que muestra los cuatro resultados posibles.

Tabla 11. Matriz de confusión del modelo

		<i>Valores predichos</i>	
		Predicción (1)	Predicción (0)
<i>Valores reales</i>	Valor real (1)	Detectamos obstrucción y hay obstrucción recogida en los datos (TP)	Hay obstrucción en los datos, pero no la detectamos en la señal (FN)
	Valor real (0)	Detectamos obstrucción, pero la hay recogida en los datos (FP)	No detectamos obstrucción en el paciente y tampoco hay en los datos (TN)

Para evaluar el rendimiento de la clasificación hemos utilizado los parámetros: sensibilidad, especificidad, PPV y NPV. Estudiamos así la calidad desde varios puntos de vista. La sensibilidad es la proporción de casos positivos que fueron correctamente identificados del total de positivos y la especificidad es la proporción de casos negativos que fueron correctamente identificados del total de negativos, tal y como se especifica en las ecuaciones 5.1 y 5.2.

$$\text{Sensibilidad} = \frac{\text{n}^\circ \text{ eventos detectados}}{\text{n}^\circ \text{ eventos meteorología}} = \frac{TP}{TP + FN} \quad (5.1)$$

$$\text{Especificidad} = \frac{\text{n}^\circ \text{ falsas alarmas}}{\text{n}^\circ \text{ totales de muestras sin evento}} = \frac{TN}{TN + FP} \quad (5.2)$$

El valor predictivo positivo (PPV – *Positive Predictive Value*) y el valor predictivo negativo (NPV – *Negative Predictive Value*) están directamente relacionados con la prevalencia y le permiten decir clínicamente la probabilidad de que un paciente tenga una enfermedad específica.

El valor predictivo positivo (PPV) es la probabilidad de que después de un resultado positivo en detección de obstrucción, ese individuo realmente haya sufrido una obstrucción.

$$PPV = \frac{TP}{TP + FP} \quad (5.3)$$

El valor predictivo negativo (NPV) es la probabilidad de que después de un resultado negativo en la detección de obstrucción, ese paciente realmente no presente ningún episodio de obstrucción.

$$NPV = \frac{TN}{TN + FN} \quad (5.4)$$

En general, para cualquier prueba dada (es decir, la sensibilidad y la especificidad siguen siendo las mismas), a medida que disminuye la prevalencia, el PPV disminuye porque habrá más falsos positivos por cada verdadero positivo [53]. Esto se debe a que está buscando una "aguja en un pajar" y es probable que encuentre muchas otras cosas que se parecen en el camino: cuanto más grande es el pajar, con más frecuencia confunde las cosas con una aguja.

Por lo tanto, a medida que disminuye la prevalencia, aumenta el NPV porque habrá más verdaderos negativos por cada falso negativo. Esto se debe a que un falso negativo significaría que un paciente realmente ha presentado obstrucción, lo cual es poco probable con baja prevalencia.

A continuación (Tabla 12) se pueden ver ejemplos de cómo el PPV y el NPV podrían variar con la prevalencia para una prueba específica.

Tabla 12. Ejemplos de variación de PPV y NPV según prevalencia

Prevalencia	PPV	NPV
1%	8%	> 99%
10%	50%	99%
20%	69%	97%
50%	90%	90%

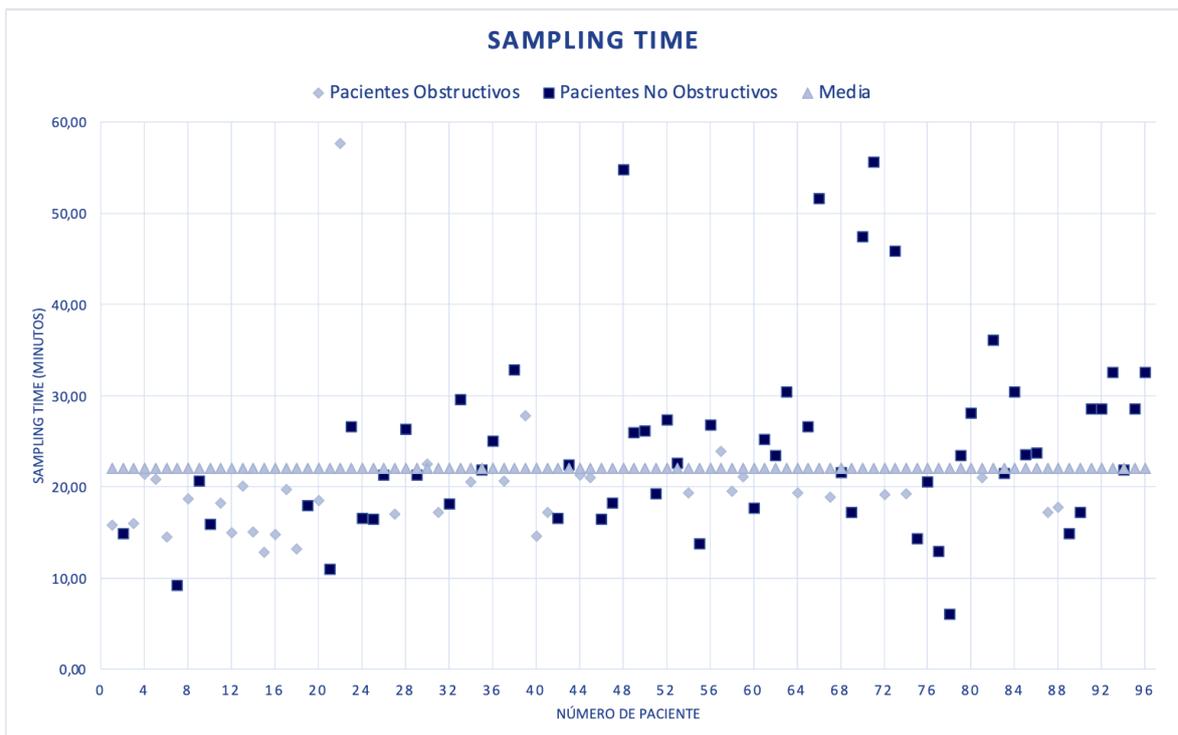
5.3 Selección de pacientes y características

Para la realización de los experimentos se han empleado datos de un total de 96 pacientes, de los cuales 37 presentaron al menos un episodio de obstrucción parcial o total del tubo endotraqueal, los otros 59 pacientes no presentaron obstrucción de dicho tubo.

Atendiendo al tiempo de muestreo, representado en el Gráfica 5 en los pacientes considerados obstructivos se obtuvo una media de tiempo de muestreo de 19,74 minutos, mientras que para los pacientes no obstructivos asciende a 24,52 minutos. Haciendo la media

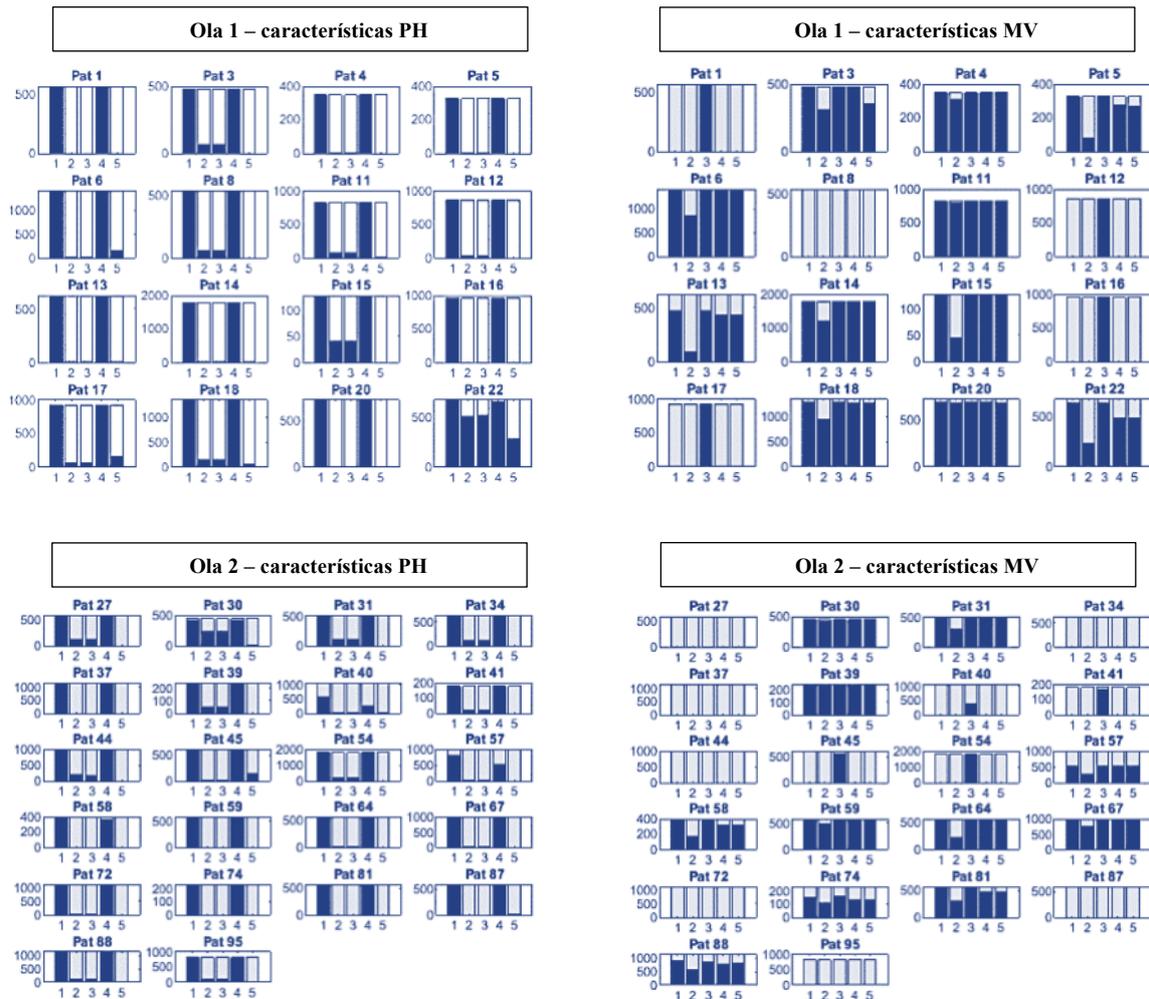
de estos datos, obtenemos una media de tiempo de muestreo de todos los pacientes de 22,13 minutos.

Gráfica 5. Tiempo medio de muestreo de cada uno de los pacientes del estudio



A la hora de seleccionar los datos útiles para los experimentos se han descartado los 12 primeros datos de cada uno de los pacientes, que se corresponden con una media de las tres primeras horas de ingreso hospitalario. Esto se debe a que, por lo general, durante las primeras horas de estancia de los pacientes en UCI estos se ven sometidos a numerosas alteraciones, ya sea por cambio de ubicación del paciente, conexión y desconexión del aparato de medidas por parte del personal médico. Y es por todo ello por lo que estos datos no suponen datos fiables para nuestro estudio. Además de estos instantes iniciales, a lo largo del ingreso hospitalario también existen numerosos datos que han de ser desechados. En la Gráfica 6 se muestra la cantidad de datos útiles registrados para los pacientes de las olas 1 y 2 atendiendo a características fisiológicas y de mecánica ventilatoria.

Gráfica 6. Datos útiles registrados para los pacientes de las olas 1 y 2 atendiendo a características fisiológicas y de mecánica ventilatoria. En el eje horizontal, parámetros MV (5) y PH (5). En el eje vertical la cantidad de datos útiles para el paciente en cuestión



Esta gráfica se divide en 4 grupos, cada uno de ellos consta de una serie de sub-gráficas que muestran los datos válidos (barras oscuras) registrados para los pacientes de cada ola y tipo de característica. Cada una de las sub-gráficas constan de cinco columnas, correspondientes a las características, representadas en el eje horizontal. El eje vertical representa el número de muestras.

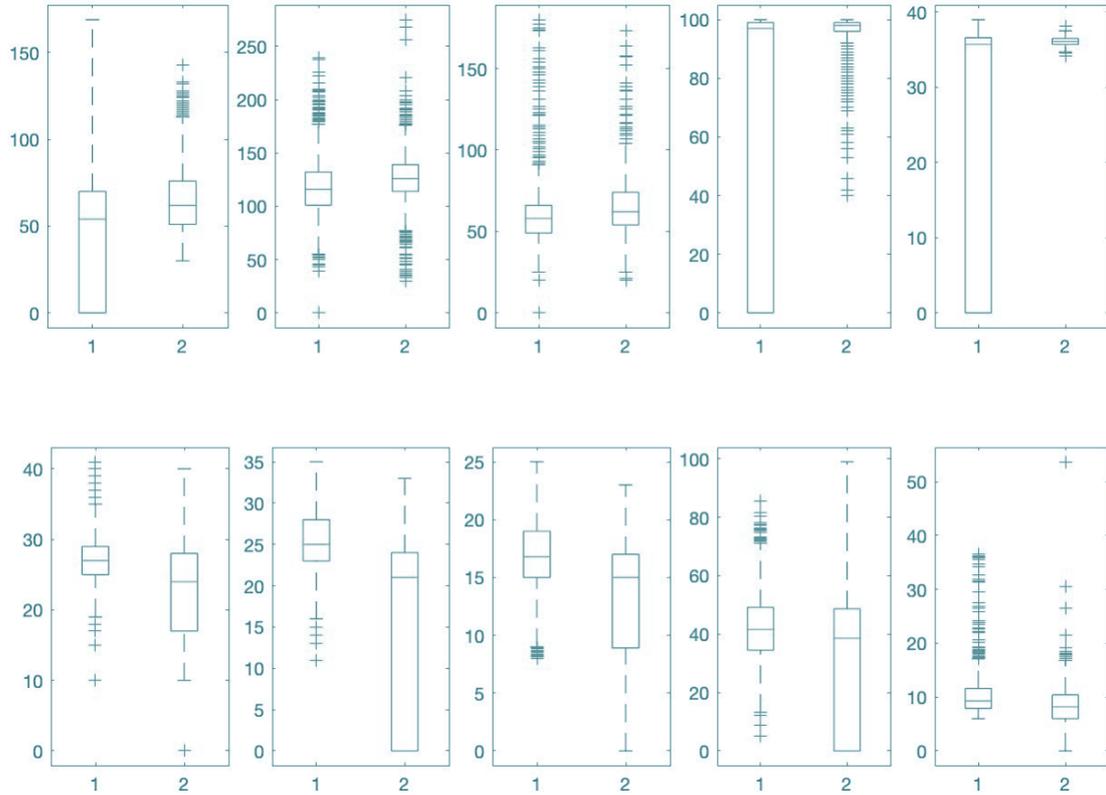
Las características, como ya se mencionó en el Capítulo 3, se dividen en dos grupos, características fisiológicas (PH) y características de mecánica ventilatoria (MV). El grupo 1 está formado por las características fisiológicas (PH): Frecuencia Cardíaca, Presión Sistólica, Presión Diastólica, Saturación de Oxígeno (SatO₂) y Temperatura. El grupo 2 está formado por las características de mecánica ventilatoria (MV): Presión Media, Pico y Meseta (*Plateau*), *Compliance* y Resistencia.

A la hora de realizar los experimentos se ha dado la opción de seleccionar, por un lado, la primera ola, la segunda ola o ambas. Por otro lado, también se puede elegir entre las características PH, las características MV o ambas.

Una pregunta que surge una vez se plantean estos experimentos en su etapa más inicial es “¿Cuál es la capacidad predictiva del modelo desarrollado?”, para contestar se ha de tener en cuenta la capacidad discriminante del modelo. Una forma fácil de ver estos resultados gráficamente es representar para cada una de las diez características elegidas (fisiológicas y de mecánica ventilatoria) los parámetros obtenidos para los pacientes considerados “obstructivos” y los “no obstructivos”. A continuación se muestran las gráficas obtenidas (Gráfica 7), con los parámetros fisiológicos en la primera fila y los de mecánica ventilatoria en la segunda. En cada una de las sub-gráficas se representan los pacientes “obstructivos” en la columna 1 y los “no obstructivos” en la columna 2. En la primera fila de gráficas, de izquierda a derecha, encontramos: Frecuencia Cardíaca, Presión Sistólica, Presión Diastólica, Saturación de Oxígeno y Temperatura. La segunda fila, también de izquierda a derecha, Presión Media, Presión Pico y Presión de *Plateau*, *Compliance* y Resistencia.

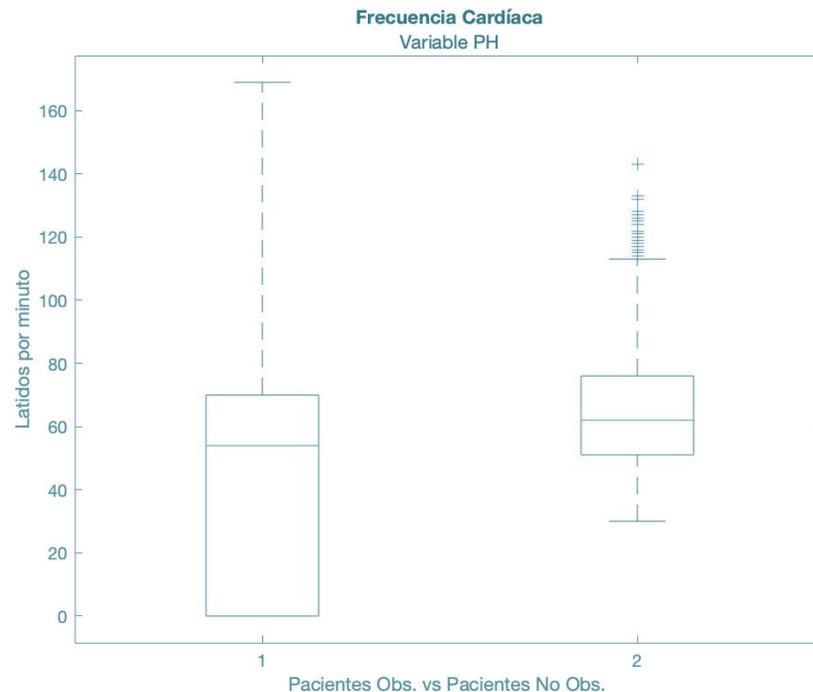
Gráfica 7. Gráfica comparativa de parámetros PH en la fila superior (de izquierda a derecha: Frecuencia Cardíaca, Presión Sistólica, Presión Diastólica, Saturación de Oxígeno y Temperatura) y MV en la inferior (de izquierda a

derecha: Presión Media, Presión Pico y Presión de Plateau, Compliance y Resistencia) para pacientes obstructivos (columna de valor 1) vs pacientes no obstructivos (columna de valor 2)



Haciendo zoom por ejemplo a la primera gráfica, es decir, la de frecuencia cardíaca para los parámetros fisiológicos, observamos los detalles de esta (Gráfica 8).

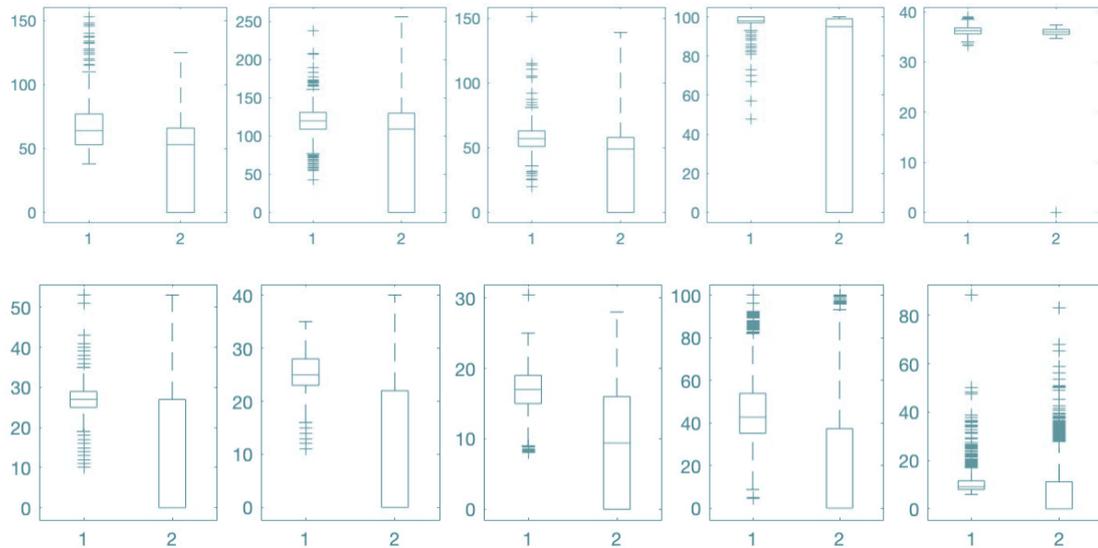
Gráfica 8. Representación de datos existentes para la variable "Frecuencia Cardíaca" y los 96 pacientes del estudio comparando pacientes "obstructivos" y pacientes "no obstructivos"



En cada caja, la marca central indica la mediana, y los extremos inferior y superior de la caja indican los percentiles 25 y 75, respectivamente. Los bigotes se extienden hasta los puntos de datos más extremos que no se consideran valores atípicos, y los valores atípicos se representan individualmente mediante el símbolo del marcador '+'.

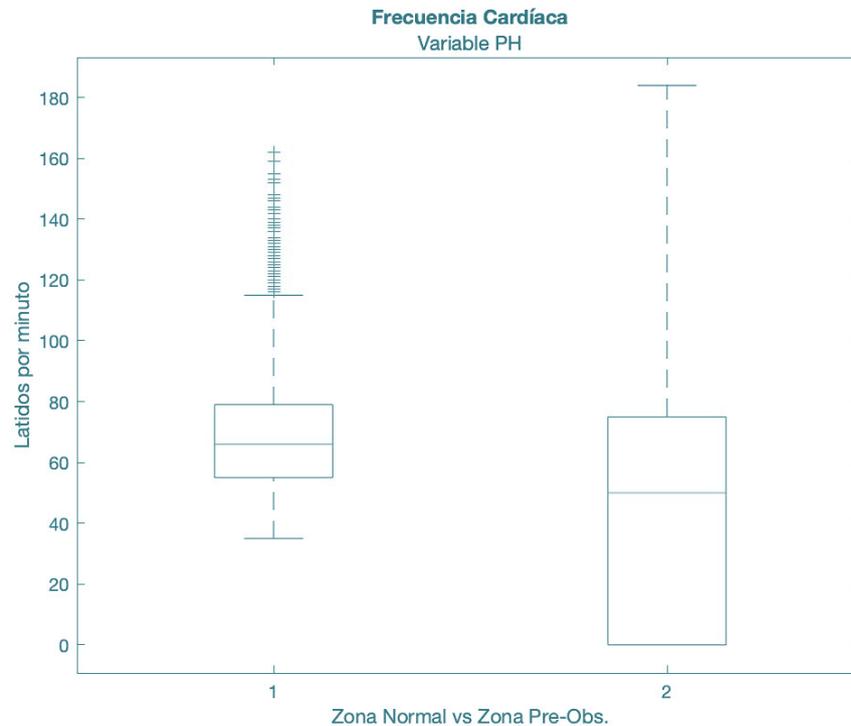
Por otro lado, también hemos representado, dentro de los pacientes obstructivos, los datos correspondientes a la zona considerada normal, es decir, donde no hay indicios de obstrucción, frente a los datos de la zona pre-obstructiva. Estos datos se representan de igual modo que los anteriores en la siguiente gráfica (Gráfica 9).

Gráfica 9. Gráfica comparativa de parámetros PH en la fila superior (de izquierda a derecha: Frecuencia Cardíaca, Presión Sistólica, Presión Diastólica, Saturación de Oxígeno y Temperatura) y MV en la inferior (de izquierda a derecha: Presión Media, Presión Pico y Presión de Plateau, Compliance y Resistencia), representando zona normal (columna de valor 1) frente a zona pre-obstructiva (columna de valor 2)



En este caso, la primera columna (columna 1) hace alusión a la zona normal, mientras que la segunda (columna 2) representa la zona pre-obstructiva. Hacemos zoom en la siguiente gráfica (Gráfica 10).

Gráfica 10. Representación de datos existentes para la variable "Frecuencia Cardíaca" y los 37 pacientes "obstructivos" del estudio comparando las zonas normal y pre-obstructivo



5.4 Módulo de aprendizaje

Una vez se han generado correctamente todos los archivos con los datos de los pacientes, habiéndolos organizados para poder tratarlos con mayor facilidad, procedemos a ejecutar el módulo de aprendizaje.

Debido a la escasa cantidad de pacientes en los experimentos y la necesidad de tratarlos de forma individualizada, se ha optado por emplear el método *Leave One Out Cross-Validation (LOOCV)*. Este es de uso común cuando se tienen pocos pacientes. Se trata de un método iterativo donde utilizamos como conjunto de entrenamiento todos los pacientes excepto uno, el cual se utilizará para la validación o test. Pero, para que este método sea efectivo, falta algo, y es que se realizarán tantas iteraciones como pacientes haya, dejando en cada uno de los casos a un paciente distinto fuera del entrenamiento, por los que el error resultante estimado por el *LOOCV* es el promedio de todos los errores calculados.

Una vez hecho esto, ya han quedado casi preparados los datos para realizar el entrenamiento. A cada característica (o variable) se le aplica un cuantificador escalar basado el algoritmo de Lloyd. Pero ¿en qué consiste el algoritmo de Lloyd? Pues, explicado brevemente, se trata de una técnica de agrupamiento que permite unificar n objetos en k clases. Este algoritmo comienza dividiendo los elementos de entrada en las distintas clases iniciales al azar, para proceder posteriormente con el cálculo del punto medio o centro de gravedad de cada conjunto. De esta forma se construye una nueva partición, asociando cada elemento con el centro de gravedad más cercano y recalculando de nuevo los centroides. El algoritmo de Lloyd es pues un método de aprendizaje no supervisado debido a que nos permite obtener información sobre los objetos sin que aportemos de forma explícita un conocimiento previo sobre los mismos [54].

El siguiente paso será realizar los *test* y calcular las métricas de calidad, tanto para el conjunto de entrenamiento como de test. Los datos que se extraen de aquí son el número de TN (*True Positive*), TN (*True Negative*), FP (*False Positive*) y FN (*False Negative*). A partir de estas métricas se calculan otras que son de interés durante el diseño de la metodología en el ámbito científico-técnico. Estas son *Sensitivity (Sen)*, *Specificity (Spe)*, *Accuracy (ACC)* y *F1-Score (F1)*.

Entre los datos obtenidos en las métricas de calidad, existen algunos que destacan notablemente con el resto, para detectar estos datos se ha utilizado una función de Matlab llamada *isoutlier*, la cual considera de forma predeterminada que un valor atípico es un valor que está a más de tres desviaciones medianas absolutas (*Median Absolute Deviations, MAD*) escaladas de la mediana.

Una vez se han generado todos los datos y se han desechado aquellos considerados aberrantes (esto es, no válidos por estar fuera de rango), procedemos al cálculo de la probabilidad de detección de nuestros modelos.

5.5 Monitorización de pacientes potencialmente obstructivos

El principal objetivo de este módulo es obtener probabilidades de detección de pacientes obstructivos frente a no obstructivos lo suficientemente altas que permitan dar una idea al personal sanitario del estado del paciente, facilitando así sus labores en los centros sanitarios. A continuación, se muestra el diagrama de flujo de esta sección (Diagrama 1).

- **Bloque 1. Parámetros de diseño:** El primer bloque se corresponde con la selección de características. Este se refiere a la selección de opciones con las que queremos realizar los experimentos, donde podemos seleccionar: el tamaño de la ventana de análisis, pudiendo elegir entre 4, 8 y 12 horas; el número de bins para la representación de los niveles de cuantificación, pudiendo seleccionar el cálculo óptimo para cada caso en particular o establecer un valor fijo; también podemos elegir la forma de procesado de los datos, pudiendo ser directamente el dato medido, la aplicación del *zero crossing* o una combinación de ambas. Los dos últimos elementos a establecer serán el tipo de parámetros (de mecánica ventilatoria, fisiológicos o ambos) y el número de la ola, donde están disponibles, por ahora, las opciones de la primera ola, la segunda ola o ambas.
- **Bloque 2. Carga de ficheros de datos:** Este bloque se centra en la carga de los ficheros de datos de los pacientes, entre los que se encuentran los datos proporcionados desde el hospital, con un total de 97 parámetros por paciente, de los cuales se han seleccionado 5 parámetros MV y 5 PH. Disponemos de un archivo que indica los límites superior e inferior de cada uno de los 97 parámetros, de este modo se podrán descartar con mayor facilidad aquellos datos que por algún error muestren un valor fuera de lo considerado lógico. Como resultado de un trabajo conjunto entre médicos e ingenieros, se nos ha proporcionado además un fichero con marcas de principio y fin de zona normal, zona pre-obstructiva y el instante de obstrucción de cada uno de los pacientes del estudio.

Diagrama 1. Diagrama de flujo de la monitorización de pacientes potencialmente obstructivos



- **Bloque 3. Generación de paquetes de parámetros útiles:** El tercer bloque se encarga de recoger todos los datos acordes a lo seleccionado en los bloques anteriores, preparándolos para su posterior tratamiento. Es decir, como resultado obtenemos ficheros con los datos únicamente de los pacientes y características deseados, donde además ya se habrán descartado aquellos datos considerados anormales (fuera de los límites establecidos).
- **Bloque 4. Entrenamiento y test de los modelos:** El bloque cuatro es el bloque de entrenamiento y test de los modelos. El primer paso será la generación de los valores para *train* (entrenamiento) y para *test*, para lo cual ya hemos comentado que se emplea el método *Leave-One-Out*. El siguiente paso será el entrenamiento. Este se repetirá tantas veces como pacientes haya, dejando en cada una de las repeticiones uno de los pacientes fuera, con el cual se realizará el test posteriormente. Tanto para *train* como para *test* se empleará el modelo bayesiano con el que se obtendrán las diferentes probabilidades. También se estimará el umbral óptimo empleando la curva ROC (*Receiver Operating Characteristic*).
- **Bloque 5. Cálculo de probabilidad de detección:** El quinto bloque consiste en el cálculo de los parámetros finales de probabilidades de detección de pacientes obstructivos frente a no obstructivos. Los datos que resultan de aquí son sensibilidad (*Sen*), especificidad (*Spe*), PPV (*Positive Predictive Value*) y NPV (*Negative Predictive Value*). El siguiente paso será la competición de los clasificadores. Este apartado consiste en obtener una probabilidad acumulada de cada uno de los clasificadores, esto es, para cada una de las características seleccionadas (*PH*, *MV* o *PH + MV*) se obtiene una probabilidad acumulada; una vez obtenidas todas estas probabilidades, se escoge la que haya obtenido mejores resultados. También se han obtenido los valores Q, es decir primer, segundo y tercer cuartil. El primer cuartil (Q1) es la mediana de la primera mitad de valores; el segundo cuartil (Q2) la propia mediana de la serie; y el tercer cuartil (Q3) la mediana de la segunda mitad de valores. Es interesante remarcar que, si bien

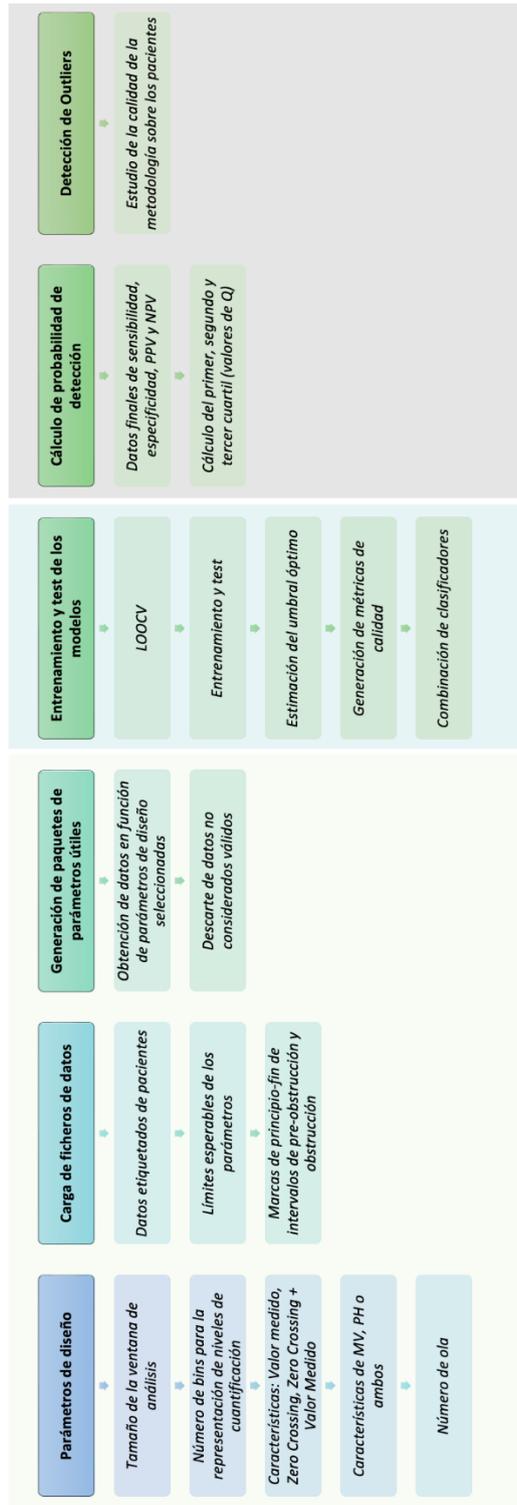
sensibilidad y especificidad son de interés en el ámbito científico-técnico pues definen la calidad del test diseñado, en el ámbito científico-médico son PPV y NPV unas métricas de gran ayuda ya que dan idea a los médicos de cuán fiable es el test (en nuestro caso, obstrucción vs no obstrucción) que se les está proporcionando.

- **Bloque 6. Detección de *outliers*:** En el sexto y último bloque se lleva a cabo la detección de aquellos pacientes para los cuales se han obtenido métricas de calidad que dan a entender que son estadísticamente atípicos, a los cuales denominamos *outliers*. El concepto de *outliers* no tiene sentido negativo. Aplicamos este concepto para preguntarnos acerca de cuán buena es nuestra metodología a la hora de describir los pacientes y ulteriormente abordar con éxito la detección temprana de obstrucción de tubo endotraqueal. Se ha considerado como pacientes atípicos aquellos cuyo valor esté a más de tres MAD (*Median Absolute Deviations* – Desviación Absoluta Media) escalados de distancia de la mediana.

5.6 Identificación temprana de eventos de pre-obstrucción

Al igual que en el apartado anterior, este (Diagrama 2) es el diagrama de flujo que ha seguido esta parte del código, correspondiente la detección del inicio de la fase pre-obstructiva en pacientes considerados como “obstructivos”. Es decir, dentro de los datos de un paciente será capaz de diferenciar entre la zona considerada normal, donde no hay indicios de pre-obstrucción, la zona considerada pre-obstructiva, es decir, donde algunos parámetros empiezan a dar señales de una posible obstrucción, y finalmente se dará el evento como tal de esta obstrucción, pudiendo ser parcial o total.

Diagrama 2. Diagrama de flujo de la identificación temprana de eventos de pre-obstrucción



Los bloques se desarrollan prácticamente igual que para el diagrama de la diferenciación entre pacientes obstructivos y no obstructivos. Una breve explicación es la siguiente:

- **Bloque 1. Parámetros de diseño:** Elección del tamaño de la ventana de análisis (4, 8 y 12 horas), número de bins para la representación de los niveles de cuantificación, (cálculo óptimo o valor fijo), forma de procesado de los datos (dato medido, *zero crossing*, o la combinación de ambas), tipo de parámetros (MV, PH o ambas opciones) y número de la ola (ola 1, ola 2 o ambas).
- **Bloque 2. Carga de ficheros de datos:** 97 parámetros por pacientes, de los cuales se han seleccionado 10 para el estudio (5 parámetros MV y 5 PH). También disponemos de un archivo que indica los límites superior e inferior de cada uno de los 97 parámetros, y otro que contiene las marcas de principio y fin de zona normal, zona pre-obstructiva y el instante de obstrucción.
- **Bloque 3. Generación de paquetes de parámetros útiles:** Obtenemos ficheros con los datos únicamente de los pacientes y características deseados, donde además ya se habrán descartado aquellos datos que se encuentran fuera de los límites establecidos.
- **Bloque 4. Entrenamiento y test de los modelos:** Se generan los valores para *train* y para *test*, empleando la estrategia de aprendizaje *Leave-One-Out*. El entrenamiento utilizado es mediante modelos bayesianos para obtener las diferentes probabilidades. Se obtienen también las curvas ROC (*Receiver Operating Characteristic*) para estimar el umbral óptimo y se generan las métricas de calidad.
- **Bloque 5. Cálculo de probabilidad de detección:** Obtención de los valores de sensibilidad (Sen), especificidad (Spe), PPV (*Positive Predictive Value*) y NPV (*Negative Predictive Value*). Además del primer, segundo y tercer cuartil (Q1, Q2, Q3, respectivamente). En este caso se realiza una combinación de clasificadores, esto es, combinación de los resultados obtenidos en cada instante de las características seleccionadas (*PH*, *MV* o ambas) mediante un combinador

de votación por mayoría (*Majority Voting*), saliendo como resultado la opción (característica) más votada.

- **Bloque 6. Detección de *outliers*:** Al igual que en el apartado 5.5, en este bloque se lleva a cabo la detección de aquellos pacientes para los cuales se han obtenido métricas de calidad que dan a entender que son estadísticamente atípicos.

CAPÍTULO 6.

EXPERIMENTOS Y RESULTADOS OBTENIDOS

En este capítulo se presentan las diferentes combinaciones de experimentos realizados junto con sus respectivos resultados, así como las conclusiones generadas en base a todos los datos obtenidos.

6.1 Experimentos

Se han realizado dos tandas de experimentos, uno para la diferenciación de pacientes obstructivos y no obstructivos, y otro para la distinción entre la zona considerada normal y la zona pre-obstructiva. Dentro de cada uno de estos grupos de experimentos se han realizado seleccionado diferentes características, variando por ejemplo el tamaño de la ventana de análisis de datos o la forma de procesado de los datos.

6.1.1 Experimentos para la detección de pacientes obstructivos frente a no obstructivos

Dentro de las variantes a la hora de realizar los experimentos encontramos:

- El tamaño de la ventana: puede variar entre 4, 8 y 12 horas;
- La forma de procesar los datos: se realizaron experimentos con un total de 15 posibilidades, entre las cuales encontramos: Valor Medido, Valor Medido + Desviación Estándar, Media + Desviación Estándar, Sesgo (*skewness*),

Apuntamiento (*kurtosis*), Mínimo, Máximo, Mediana, *Zero Crossing*, *Zero Crossing* + Valor Medido;

- El número de las olas a analizar: ola 1, ola 2 o ambas;
- Características: de mecánica ventilatoria, fisiológicas o ambas.

Los resultados de estos experimentos se han recogido en un conjunto de tablas, algunas de las cuales se muestran a continuación. (La totalidad de las tablas se encuentran en el ANEXO).

Observando dichas tablas de datos que hemos ido obteniendo, se han seleccionado finalmente tres tipos de procesamiento de datos, los cuales daban los mejores resultados, estos son: Valor medido (sin aplicar procesado), *Zero Crossing* y *Zero Crossing* + Valor Medido. La función *Zero Crossing*, como ya se explicó anteriormente, mide el número de veces que la forma de onda cruza el eje de valor medio dentro de una ventana de análisis.

Los valores Q1, Q2 y Q3 son una medida de la dispersión estadística. Q2 representa la mediana de los valores, la diferencia entre Q1 y Q3 es el rango intercuartil de la distribución.

Las tablas incluyen una columna, denominada *Pacientes Out*, con aquellos pacientes que el programa ha detectado como *outliers* (empleando la función Matlab *isoutlier*).

La Tabla 13 muestra un ejemplo de los datos obtenidos para el caso de la primera ola, empleando parámetros fisiológicos y la característica “Valor medido”. El tamaño de la ventana de análisis en este caso es de 4 horas.

Tabla 13. Resultados de experimento *Pacientes Obs. Vs Pacientes No Obs.: Ola 1, parámetros PH, característica "Valor Medido", ventana de 4 horas*

OLA: Ventana Parámetros: Característica:	1 4 horas PH Valor Medido			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,941	0,960	0,987	1
<i>Spe</i>	0,024	0,787	1,000	
<i>PPV</i>	0,879	0,958	0,990	
<i>NPV</i>	0,969	0,980	0,993	

6.1.2 Experimentos para la detección de zona normal y zona pre-obstructiva en pacientes obstructivos

La realización de estos experimentos ha sido muy similar a los del apartado anterior, ya que se emplea la misma variedad de opciones tanto de tamaño de ventana como de número de ola, tipo de características y tipo de procesado de los datos.

La tabla siguiente (Tabla 14) muestra los resultados obtenidos empleando sólo los pacientes de la ola 1 y parámetros fisiológicos. No se ha hecho ningún tratamiento previo a los datos, es decir, se ha entrenado directamente con los valores medidos.

Tabla 14. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1, parámetros PH, característica "Valor Medido", ventana de 4 horas

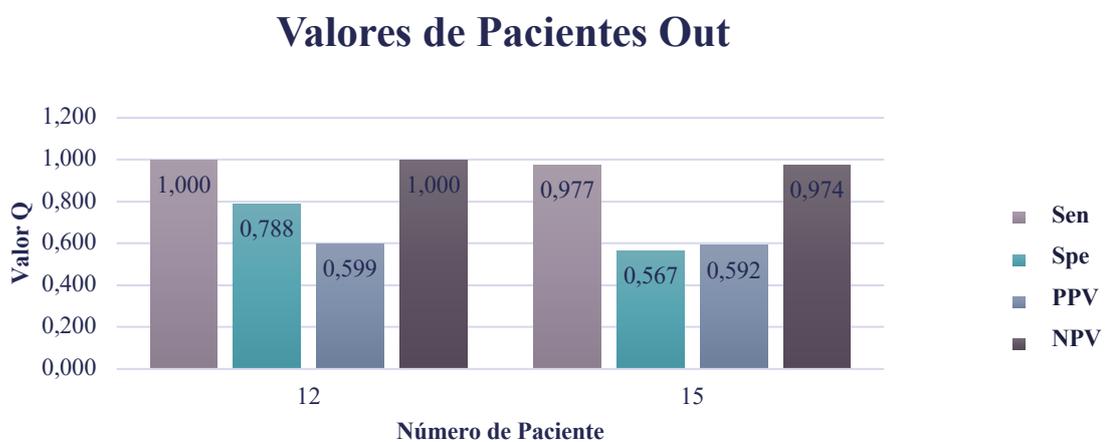
OLA: Ventana Parámetros: Característica:	1 4 horas PH Valor Medido			
	Q1	Q2	Q3	Pacientes Out
Sen	0,991	0,998	1,000	
Spe	0,494	0,516	0,530	12
PPV	0,357	0,598	0,691	
NPV	0,995	0,998	1,000	15

Como podemos observar, obtenemos muy buenos valores de sensibilidad (*Sen*) y NPV, sin embargo, los valores de especificidad (*Spe*) y PPV resultan ser bastante más bajos, en torno a 0,5, teniendo un valor incluso de 0,28. Es decir el sistema detecta muy bien los casos positivos pero no tan bien los casos negativos, lo cual no es preocupante ya que nos interesan más los falsos positivos que los falsos negativos.

La Gráfica 11 muestra los valores de los pacientes considerados fuera de la media con el fin de identificar por qué se les ha considerado como tal, pudiendo ser por un valor muy alto o bajo respecto a los demás. Esto nos permite valorar si de verdad debiera ser considerado *outlier* o no. En el caso del paciente 12 (paciente *outlier* respecto a *Spe*), podemos deducir

que se ha detectado “fuera de lo normal” por estar a más de tres MAD escalados de distancia por encima de la mediana. Podemos observar también el caso contrario para los valores NPV, donde se considera *outlier* al paciente 15.

Gráfica 11. Representación de valores de calidad para pacientes considerados outliers basado en la Tabla 13



La Tabla 15 recoge los valores correspondientes a la aplicación del *Zero Crossing*, en este caso para la ola 2 y parámetros fisiológicos (Frecuencia Cardíaca, Presión Sistólica, Presión Diastólica, Saturación de Oxígeno (SatO₂) y Temperatura). En este caso no se detecta ningún paciente *outlier*.

Tabla 15. Resultados de experimento: Ola 2, parámetros PH, característica "Zero Crossing", ventana de 4 horas

OLA: Ventana Parámetros: Característica:	2 4 horas PH Zero Crossing			Pacientes Out
	Q1	Q2	Q3	
Sen	0,993	0,997	1,000	
Spe	0,700	0,739	0,782	
PPV	0,618	0,703	0,809	
NPV	0,996	0,997	1,000	

También se puede observar que para esta combinación de características los resultados obtenidos son bastante buenos, los tres cuartiles resultan por encima de 0,5, llegando incluso en algún caso a situarse en el valor 1.

6.2 Principales resultados

Tras haber realizado experimentos con todas las combinaciones posibles (dentro de las opciones que hemos establecido), hemos obtenido una serie de conclusiones generales.

En primer lugar, vamos a diferenciar según el tamaño de la ventana de análisis, que, como ya se ha nombrado, hemos establecido tres opciones: 4, 8 y 12 horas. Para cada uno de los tamaños de ventana se han realizado experimentos con combinaciones de las distintas olas (*ola 1* y *ola 2*) y distintos parámetros (*PH*, *MV*). Las conclusiones se han generado a partir de los datos de ambos módulos (Módulo de identificación de paciente potencialmente obstructivo y Módulo de detección de las fases normal, pre-obstructiva y obstructiva). Empezaremos por los resultados obtenidos para un tamaño de ventana de análisis de 4 horas.

Para este primer caso (ventana de 4 horas) las conclusiones que se pueden extraer son:

- Cuando se emplea el *Valor Medido* se obtienen muy buenos resultados cuando se realizan los experimentos con los pacientes de ambas olas (*ola 1 + ola 2*) y los parámetros *PH* (Tabla 16, Tabla 17) o las combinaciones de *PH* y *MV* (Tabla 18, Tabla 19). Para el caso de *MV* no se obtienen buenos datos en la mayoría de los experimentos debido a que se dispone de una menor cantidad de datos (como se pudo observar en la Gráfica 6 del capítulo anterior).

Tabla 16. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros PH, característica "Valor Medido", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Valor Medido			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,969	0,986	0,995	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	0,986	1,000	1,000	6,12,16,87
<i>NPV</i>	0,984	0,993	0,998	

Tabla 17. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros PH, característica "Valor Medido", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Valor Medido			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,992	0,996	0,999	57
<i>Spe</i>	0,698	0,785	0,831	
<i>PPV</i>	0,577	0,735	0,822	
<i>NPV</i>	0,996	0,997	0,999	57

Tabla 18. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros PH y MV, característica "Valor Medido", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Y MV Valor Medido			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,907	0,970	0,991	
<i>Spe</i>	0,987	1,000	1,000	19,53
<i>PPV</i>	0,975	1,000	1,000	1,12,16,54,87
<i>NPV</i>	0,951	0,985	0,996	

Tabla 19. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros PH, característica "Valor Medido", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Valor Medido</i>			
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,993	0,997	1,000	15
<i>Spe</i>	0,570	0,689	0,789	
<i>PPV</i>	0,460	0,675	0,829	
<i>NPV</i>	0,995	0,997	1,000	41

Al aplicar Zero Crossing, se obtienen muy buenos resultados cuando se emplean los datos de ambas olas a la vez (ola 1 + ola 2) y los parámetros PH (Tabla 20,

- Tabla 21) o la combinación de PH + MV (Tabla 22, Tabla 23).

Tabla 20. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros PH, característica "Zero Crossing", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Zero Crossing</i>			
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,978	0,985	0,990	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	0,985	1,000	1,000	
<i>NPV</i>	0,989	0,992	0,995	6,11,20,45,57,81

Tabla 21. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros PH, característica "Zero Crossing", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,992	0,996	0,999	31
<i>Spe</i>	0,730	0,777	0,800	
<i>PPV</i>	0,575	0,724	0,834	
<i>NPV</i>	0,995	0,997	0,999	31

Tabla 22. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros PH y MV, característica "Zero Crossing", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Y MV Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,983	0,993	0,995	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	0,993	1,000	1,000	8,27,34,44,37,87,34
<i>NPV</i>	0,991	0,996	0,998	

Tabla 23. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros PH y MV, característica "Zero Crossing", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Y MV Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,993	0,997	1,000	4

<i>Spe</i>	0,678	0,743	0,795	
<i>PPV</i>	0,546	0,729	0,811	
<i>NPV</i>	0,996	0,997	1,000	39

Para el caso de Zero Crossing + Valor Medido, se obtienen muy buenos resultados cuando se emplea solo los datos de la ola 2. Esto se cumple con las características PH (Tabla 24, Tabla 25) y la combinación de ambas (PH + MV) (

- Tabla 26, Tabla 27).

Tabla 24. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 2, parámetros PH, característica "Zero Crossing + Valor Medido", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	2 PH <i>Zero Crossing + Valor Medido</i>			Pacientes Out
	Q1	Q2	Q3	
<i>Sen</i>	1,000	1,000	1,000	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	1,000	1,000	1,000	
<i>NPV</i>	1,000	1,000	1,000	

Tabla 25. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 2, parámetros PH, característica "Zero Crossing + Valor Medido", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	2 PH <i>Zero Crossing + Valor Medido</i>			Pacientes Out
	Q1	Q2	Q3	
<i>Sen</i>	0,993	0,996	0,999	
<i>Spe</i>	0,704	0,744	0,776	
<i>PPV</i>	0,552	0,697	0,793	
<i>NPV</i>	0,996	0,997	0,999	41

Tabla 26. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros PH y MV, característica "Zero Crossing + Valor Medido", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	2 <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,980	0,995	0,995	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	0,995	1,000	1,000	
<i>NPV</i>	0,990	0,997	0,998	

Tabla 27. Tabla 21. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros PH y MV, característica "Zero Crossing + Valor Medido", ventana de 4 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	2 <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,995	0,998	1,000	
<i>Spe</i>	0,508	0,569	0,735	
<i>PPV</i>	0,428	0,642	0,763	
<i>NPV</i>	0,996	0,999	1,000	

Analizando ahora los datos de la ventana de 8 horas, se expone lo siguiente:

- Empleando el *Valor medido*, se obtienen muy buenos resultados cuando se emplean los datos fisiológicos (*PH*) y la combinación de *PH + MV* con la segunda ola. El caso de las dos olas (96 pacientes en total) con los parámetros de *MV* no suele aportar tan buenos resultados como los nombrados anteriormente en ninguno de los casos probados. Los mejores resultados en este caso se obtienen

cuando se emplean solo los datos *PH* y la combinación de ambas olas (*ola 1 + ola 2*) (Tabla 28, Tabla 29).

Tabla 28. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros *PH*, característica "Valor Medido", ventana de 8 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Valor Medido			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,978	0,990	0,995	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	0,990	1,000	1,000	37
<i>NPV</i>	0,989	0,995	0,998	

Tabla 29. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros *PH*, característica "Valor Medido", ventana de 8 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Valor Medido			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,992	0,996	0,998	57
<i>Spe</i>	0,706	0,785	0,830	
<i>PPV</i>	0,579	0,738	0,831	
<i>NPV</i>	0,995	0,997	0,999	57

- *Zero Crossing* genera muy buenos resultados cuando se emplean datos de las dos olas (*ola 1 + ola 2*) y para los parámetros *PH* (Tabla 30, Tabla 31) o la combinación de *PH + MV* (Tabla 32, Tabla 33). Como se nombró en el punto anterior, sólo con los parámetros *MV* y *ola 1 + ola 2* no genera tan buenas métricas, sin embargo, empleando solo la *ola 2* (Tabla 34, Tabla 35) sí que genera considerablemente muy buenos resultados respecto a los demás.

Tabla 30. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros PH, característica "Zero Crossing", ventana de 8 horas

OLA: Parámetros: Característica:	1 y 2 PH Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,954	0,972	0,991	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	0,972	1,000	1,000	59
<i>NPV</i>	0,976	0,986	0,995	

Tabla 31. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros PH, característica "Zero Crossing", ventana de 8 horas

OLA: Parámetros: Característica:	1 y 2 PH Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,993	0,996	0,998	15
<i>Spe</i>	0,906	0,963	0,989	72,74
<i>PPV</i>	0,847	0,935	0,987	72
<i>NPV</i>	0,996	0,998	0,998	41

Tabla 32. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros PH y MV, característica "Zero Crossing", ventana de 8 horas

OLA: Parámetros: Característica:	1 y 2 PH Y MV Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,939	0,979	0,990	
<i>Spe</i>	0,993	1,000	1,000	53,93
<i>PPV</i>	0,980	1,000	1,000	59
<i>NPV</i>	0,968	0,989	0,995	

Tabla 33. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros PH y MV, característica "Zero Crossing", ventana de 8 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Y MV Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,994	0,997	1,000	4
<i>Spe</i>	0,542	0,669	0,807	
<i>PPV</i>	0,490	0,662	0,874	
<i>NPV</i>	0,995	0,998	1,000	41

Tabla 34. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 2, parámetros MV, característica "Zero Crossing", ventana de 8 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	2 MV Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,962	0,970	0,980	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	0,970	1,000	1,000	40,45
<i>NPV</i>	0,981	0,985	0,990	

Tabla 35. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 2, parámetros MV, característica "Zero Crossing", ventana de 8 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	2 MV Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,990	0,995	1,000	
<i>Spe</i>	0,563	0,705	0,781	
<i>PPV</i>	0,470	0,716	0,804	
<i>NPV</i>	0,982	0,995	1,000	

- Cuando se aplica *Zero Crossing + Valor Medido*, el mejor resultado de todas las combinaciones posibles se obtiene con la *ola 1* los parámetros de *MV* (Tabla 36, Tabla 37).

Tabla 36. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1, parámetros *MV*, característica "Zero Crossing + Valor Medido", ventana de 8 horas

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing + Valor Medido</i>			
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,947	0,994	0,995	
<i>Spe</i>	0,956	1,000	1,000	21
<i>PPV</i>	0,965	0,995	0,998	1
<i>NPV</i>	0,973	0,997	0,998	

Tabla 37. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1, parámetros *MV*, característica "Zero Crossing + Valor Medido", ventana de 8 horas

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing + Valor Medido</i>			
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,992	0,998	1,000	
<i>Spe</i>	0,509	0,618	0,687	
<i>PPV</i>	0,425	0,687	0,766	
<i>NPV</i>	0,992	0,997	1,000	22

A continuación, analizamos los datos recogidos al emplear una ventana de análisis de 12 horas:

- Realizando los experimentos con los datos sin procesado (*Valor Medido*), los mejores resultados coinciden con los de los parámetros de diseño: *ola 2* y *ola 1 + ola 2* y parámetros *PH* y *PH + MV*. Entre todos ellos, los valores más altos en

promedio resultan ser para las olas *ola 1 + ola 2* junto con los parámetros *PH* (Tabla 38, Tabla 39).

Tabla 38. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros *PH*, característica " Valor Medido", ventana de 12 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Valor Medido			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,978	0,989	0,995	
<i>Spe</i>	0,992	1,000	1,000	29,95
<i>PPV</i>	0,990	0,996	1,000	87
<i>NPV</i>	0,989	0,995	0,997	

Tabla 39. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros *PH*, característica " Valor Medido", ventana de 12 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Valor Medido			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,993	0,996	0,999	57
<i>Spe</i>	0,715	0,787	0,827	
<i>PPV</i>	0,586	0,747	0,818	
<i>NPV</i>	0,996	0,997	0,999	57

- Cuando se emplea el procesado *Zero Crossing*, los resultados coinciden con lo expuesto en el punto anterior, la combinación ganadora es *ola 1 + ola 2* y parámetros fisiológicos (*PH*) (Tabla 40, Tabla 41).

Tabla 40. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros PH, característica "Zero Crossing", ventana de 12 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,978	0,990	0,995	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	0,990	1,000	1,000	37
<i>NPV</i>	0,989	0,995	0,998	

Tabla 41. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros PH, característica "Zero Crossing", ventana de 12 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH Zero Crossing			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,992	0,996	0,998	11
<i>Spe</i>	0,747	0,793	0,825	
<i>PPV</i>	0,592	0,748	0,827	
<i>NPV</i>	0,996	0,997	0,999	11

- Finalmente, la última tanda de experimentos se corresponde con el uso de *Zero Crossing + Valor Medido*. Los mejores resultados para este conjunto son con las combinaciones de parámetros PH y las ola 2 (Tabla 42, Tabla 43) o el total de los 96 pacientes (*ola 1 + ola 2*) (Tabla 44, Tabla 45).

Tabla 42. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 2, parámetros PH, característica " Zero Crossing + Valor Medido", ventana de 12 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	2 PH <i>Zero Crossing + Valor Medido</i>			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	1,000	1,000	1,000	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	1,000	1,000	1,000	
<i>NPV</i>	1,000	1,000	1,000	

Tabla 43. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 2, parámetros PH, característica " Zero Crossing + Valor Medido", ventana de 12 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	2 PH <i>Zero Crossing + Valor Medido</i>			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	0,993	0,995	0,997	72
<i>Spe</i>	0,978	0,986	0,998	
<i>PPV</i>	0,952	0,984	0,997	
<i>NPV</i>	0,996	0,997	0,998	72

Tabla 44. Resultados de experimento Paciente Obs. vs Paciente No Obs.: Ola 1 y 2, parámetros PH, característica " Zero Crossing + Valor Medido", ventana de 12 horas

OLA: <i>Parámetros:</i> <i>Característica:</i>	1 y 2 PH <i>Zero Crossing + Valor Medido</i>			
	Q1	Q2	Q3	Pacientes Out
<i>Sen</i>	1,000	1,000	1,000	
<i>Spe</i>	1,000	1,000	1,000	
<i>PPV</i>	1,000	1,000	1,000	
<i>NPV</i>	1,000	1,000	1,000	

Tabla 45. Resultados de experimento Zona Normal vs Zona Pre-Obs.: Ola 1 y 2, parámetros PH, característica "Zero Crossing + Valor Medido", ventana de 12 horas

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>			
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,923	0,989	0,996	72
<i>Spe</i>	0,997	1,000	1,000	40,57
<i>PPV</i>	0,989	1,000	1,000	40,57
<i>NPV</i>	0,964	0,991	0,997	

Principales conclusiones a partir de los resultados

Como conclusión de este apartado, los mejores resultados del conjunto de todos los experimentos y probando todas las combinaciones que hemos establecido, en rasgos generales observamos que se suelen dar para la selección de los parámetros fisiológicos y los 96 pacientes del estudio y con un tamaño de ventana de 12 horas. Esto nos genera varias ideas que podemos considerar como patrones: por lo general, los parámetros *PH* generan mejores resultados que los de *MV* ya que estos últimos suele contener menor cantidad de datos útiles; el uso de olas 1 y 2 a la vez enriquece los resultados, por lo que se espera que al incorporar nuevos datos de otras olas estos sean mucho más completos y veraces. Finalmente, respecto al procesado de los datos, se ha podido observar que los datos por sí solos, es decir, el dato medido sin tratamiento alguno produce muy buenos resultados. En alguno de los casos la aplicación del *Zero Crossing* es lo que ha resultado con los mejores datos, pero existiendo unas diferencias inferiores al 0'5% respecto al *Valor Medido*, por lo que habría que considerar y valorar el tiempo de procesado que esto conlleva para elegir la mejor opción: procesamiento o no de los datos.

CAPÍTULO 7.

CONCLUSIONES Y LÍNEAS FUTURAS

En este capítulo se presentan las conclusiones obtenidas tras el desarrollo del TFM. Además, se exponen las posibles líneas de investigación para futuros trabajos relacionados con la predicción con suficiente antelación del instante de obstrucción de las vías respiratorias en pacientes COVID-19 que dispongas de respiración asistida.

7.1 Conclusiones

La labor de investigación llevada a cabo en este TFM se enmarca en la línea de investigación que mis tutores llevan a cabo sobre el problema de la detección precoz de la obstrucción del tubo endotraqueal desde un punto de vista tecnológico. Hasta donde llega nuestro conocimiento esta línea es pionera en este tema.

El propósito desde el inicio de este trabajo ha sido sentar las bases para desarrollar un sistema inteligente capaz de proporcionar a los médicos indicadores confiables de riesgo de obstrucción del tubo endotraqueal, permitiéndoles predecir el instante de obstrucción con suficiente antelación. A tal efecto, en nuestra metodología integramos clasificadores base a partir de cada una de las variables registradas de cada paciente, combinación de esos clasificadores y generación de probabilidades de aparición del problema de obstrucción.

Asimismo, este objetivo principal se ha visto complementado por unos objetivos secundarios como son:

- La generación, por un lado, de un modelo capaz de aportar datos lo suficientemente fiables de distinción entre pacientes potencialmente obstructivos frente a aquellos que no lo son.
- Por otro lado, el diseño de un sistema para la diferenciación entre la fase normal de los pacientes y la entrada a la fase pre-obstructiva.

De los resultados obtenidos y presentados se extraen las siguientes conclusiones:

- Los sistemas son capaces de predecir con suficiente credibilidad si un paciente será obstructivo o no, pudiendo diferenciar, dentro de aquellos considerados obstructivos, el cambio de la fase normal frente al comienzo de la obstrucción o su inicio inminente gracias al análisis de un total de 10 parámetros.

7.2 Líneas futuras

Las posibles líneas futuras de trabajos que se podrían llevar a cabo para complementar este Trabajo de Fin de Máster son:

- Abordar el uso de otros clasificadores base para nuevas estrategias de conjuntos o el desarrollo de indicadores mejorados.
- Ampliar la base de datos de pacientes para que el estudio sea más completo y realista con el fin de mejorar los resultados de las pruebas de credibilidad y reproducibilidad.
- Estudio específico de los pacientes outliers que presentan métricas indicativas de una calidad baja de la metodología presentada, con vistas a posibles mejoras que hagan todavía más fiable el test diseñado.
- Combinar detección y predicción a futuro para adelantar la eventualidad de que se produzcan obstrucciones.
- Utilizar *Deep Learning* para detección temprana y predicción, por ejemplo, basado en redes *Long Short-Term Memory* (LSTM).

BIBLIOGRAFÍA

- [1] G. P. Acosta, J. L. Navarro Mesa, J. B. López, L. S. Cabrera, C. P. S. Araujo, and J. C. M. González, “Una aproximación a la detección temprana de obstrucción del tubo endotraqueal en pacientes COVID-19 basada en Machine Learning estadístico,” in *LV Congreso Nacional de La Sociedad Española de Medicina Intensiva, Crítica y Unidades Coronarias (SEMICYUC)*, 2020.
- [2] G. Pérez Acosta, J. L. Navarro Mesa, J. Blanco López, L. Santana Cabrera, C. P. Suárez-Araujo, and J. C. Martín González, “Aplicación de análisis gráfico de BigData en la detección de obstrucción endotraqueal en neumonía COVID-19,” *LV Congr. Nac. La Soc. Española Med. Intensiva, Crítica y Unidades Coronarias (SEMICYUC)*, 2020.
- [3] G. European Society of Intensive Care Medicine, J. L. Navarro Mesa, J. Blanco López, L. Santana Cabrera, C. P. Suárez Araujo, and J. C. Martín González, *Intensive care medicine experimental*. 2020.
- [4] G. Pérez-Acosta *et al.*, “Un estudio del poder predictivo de las señales de mecánica ventilatoria sobre la obstrucción del tubo endotraqueal en pacientes COVID-19 basado en modelos de clasificación Bayesiana,” *LVI Congr. Nac. La Soc. Española Med. Intensiva, Crítica y Unidades Coronarias*, 2021.
- [5] F. J. Suárez-Díaz *et al.*, “A Bayesian Classifier Combination Methodology for Early Detection of Endotracheal Obstruction of COVID-19 Patients in ICU,” in *International Work-Conference on Artificial Neural Networks*, 2021, pp. 49–60.
- [6] “Colegio de Médicos de Las Palmas.” [Online]. Available: <https://www.medicoslaspalmas.es/>. [Accessed: 13-Jul-2022].
- [7] “ULPGC - Universidad de Las Palmas de Gran Canaria.” [Online]. Available: <https://www.ulpgc.es/>. [Accessed: 13-Jul-2022].

- [8] Ministerio de sanidad igualdad y asuntos sociales, “Información Científica-Técnica Coronavirus,” *Cent. Coord. Alertas y Emergencias Sanit.*, vol. 1, p. 73, 2021.
- [9] “Coronavirus Disease (COVID-19) Situation Reports.” [Online]. Available: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/situation-reports>. [Accessed: 31-Mar-2022].
- [10] C. I. Paules, H. D. Marston, and A. S. Fauci, “Coronavirus Infections—More Than Just the Common Cold,” *JAMA*, vol. 323, no. 8, pp. 707–708, Feb. 2020.
- [11] C. Chiaroni and J. Millán, “Radiografía de dos años de pandemia: seis olas, 10 millones de casos y 100.000 muertos por covid en España,” *20 minutos*, 14-Mar-2022.
- [12] C. Vivas and C. Castro, “El año del Covid: cronología de la pandemia en España,” *El Independiente*, 15-Mar-2021.
- [13] W. H. Organization and M. C. Joint, “Report of the WHO-China Joint Mission on Coronavirus Disease 2019 (COVID-19),” *WHO-China Jt. Mission Coronavirus Dis. 2019*, vol. 2019, no. February, pp. 16–24, 2020.
- [14] D. Cyranoski, “Mystery deepens over animal source of coronavirus.,” *Nature*, vol. 579, no. 7797. England, pp. 18–19, Mar-2020.
- [15] M. Worobey *et al.*, “The Huanan market was the epicenter of SARS-CoV-2 emergence,” Feb. 2022.
- [16] J. E. Pekar *et al.*, “SARS-CoV-2 emergence very likely resulted from at least two zoonotic events,” Feb. 2022.
- [17] “ANIMAL CORONAVIRUSES: LESSONS FOR SARS - Learning from SARS - NCBI Bookshelf.” [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK92442/>. [Accessed: 04-Apr-2022].
- [18] J. R. Palacios, “Sistema Respiratorio: Anatomía,” *Col. Int. Enfermería Barcelona* <[http://www. Inferm. com/ca-es/activitats-de-la-vida-diaria/lapersona/dimensio-biologica/sistema-respiratori/pdf/sistema-respiratori. pdf](http://www.Inferm.com/ca-es/activitats-de-la-vida-diaria/lapersona/dimensio-biologica/sistema-respiratori/pdf/sistema-respiratori.pdf)>[en línea], *Dispon. Consult. 3 Diciembre*, 2007.
- [19] G. Grasselli *et al.*, “Mechanical ventilation parameters in critically ill COVID-19

- patients: a scoping review,” *Crit. Care*, vol. 25, no. 1, pp. 1–11, 2021.
- [20] D. Ashbaugh, D. B. Bigelow, T. Petty, and B. Levine, “Acute respiratory distress in adults,” *Lancet*, vol. 290, no. 7511, pp. 319–323, 1967.
- [21] S. Prof, B. Jonson, L. Nordström, and S.-G. Olsson, “A Servo-Controlled Ventilator Measuring Expired Minute Volume, Airway Flow and Pressure,” *Acta Anaesthesiol. Scand.*, vol. 16, pp. 7–27, Dec. 2008.
- [22] P. L. Silva, P. Pelosi, and P. R. M. Rocco, “Optimal mechanical ventilation strategies to minimize ventilator-induced lung injury in non-injured and injured lungs,” *Expert Rev. Respir. Med.*, vol. 10, no. 12, pp. 1243–1245, 2016.
- [23] B. D. Singer and T. C. Corbridge, “Basic invasive mechanical ventilation,” *South Med J*, vol. 102, no. 12, pp. 1238–1245, 2009.
- [24] M. Girardis *et al.*, “Effect of conservative vs conventional oxygen therapy on mortality among patients in an intensive care unit: the oxygen-ICU randomized clinical trial,” *Jama*, vol. 316, no. 15, pp. 1583–1589, 2016.
- [25] T. Pham, L. J. Brochard, and A. S. Slutsky, “Mechanical ventilation: state of the art,” in *Mayo Clinic Proceedings*, 2017, vol. 92, no. 9, pp. 1382–1400.
- [26] N. MacIntyre *et al.*, “Evidence-based guidelines for weaning and discontinuing ventilatory support: A collective task force facilitated by the American College of Chest Physicians; the American Association for Respiratory Care; and the American College of Critical Care Medicine,” *Chest*, vol. 120, pp. 375S–95S, Jan. 2002.
- [27] K. R. Bock, P. Silver, M. Rom, and M. Sagy, “Reduction in tracheal lumen due to endotracheal intubation and its calculated clinical significance,” *Chest*, vol. 118, no. 2, pp. 468–472, Aug. 2000.
- [28] F. Rittner and M. Döring, “Curves and Loops in Mechanical Ventilation,” *Drager*, p. 60, 2015.
- [29] J. J. Páez and J. R. Navarro, “Controversias sobre la presión cricoidea o maniobra de Sellick,” *Colomb. J. Anesthesiol.*, vol. 38, no. 3, pp. 377–383, 2010.
- [30] C. Fernández Galguera, “Complicaciones de la intubación endotraqueal en la Unidad de Reanimación Quirúrgica del Centro General del Hospital Universitario Central de

- Asturias,” *Repos. Inst. la Univ. Oviedo*, 2012.
- [31] S. M. Zimmer and D. S. Burke, “Historical perspective—emergence of influenza A (H1N1) viruses,” *N. Engl. J. Med.*, vol. 361, no. 3, pp. 279–285, 2009.
- [32] G. Pérez Acosta and L. Santana Cabrera, “Traqueobronquitis necrosante con obstrucción del tubo endotraqueal en pacientes COVID-19,” *Rev. Clínica Española*, vol. 220, no. 8, pp. 531–533, 2020.
- [33] J. Higuera *et al.*, “Traqueostomía en cuidados intensivos en pacientes COVID-19,” *Acta Colomb. Cuid. Intensivo*, vol. 21, no. 3, pp. 228–233, Jul. 2021.
- [34] E. Martínez-Téllez *et al.*, “Traqueotomía en pacientes COVID-19: un procedimiento necesario de alto riesgo. Experiencia de dos centros,” *Arch. Bronconeumol.*, vol. 56, no. 10, pp. 673–674, Oct. 2020.
- [35] “Critical Care Management Software | ICU Patient Software.” [Online]. Available: <https://www.picis.com/en/solution/clinical-information-system-suite/critical-care-manager/>. [Accessed: 07-Jul-2022].
- [36] “Definición de frecuencia cardíaca - Diccionario de cáncer del NCI - Instituto Nacional del Cáncer.” [Online]. Available: <https://www.cancer.gov/espanol/publicaciones/diccionarios/diccionario-cancer/def/frecuencia-cardiaca>. [Accessed: 25-Apr-2022].
- [37] “ICU Care Manager Software | Critical Patient Care Management.” [Online]. Available: <https://www.picis.com/en/solution/clinical-information-system-suite/critical-care-manager/>. [Accessed: 11-Apr-2022].
- [38] R. Benítez, G. Escudero, and S. Kanaan, *Inteligencia Artificial Avanzada*. 2013.
- [39] D. O. Hebb, *The organization of behavior: a neuropsychological theory*. J. Wiley; Chapman & Hall, 1949.
- [40] R. R. Kline, “Cybernetics, Automata Studies, and the Dartmouth Conference on Artificial Intelligence,” *IEEE Ann. Hist. Comput.*, vol. 33, pp. 5–16, 2011.
- [41] C. E. Shannon, “A mathematical theory of communication,” *Bell Syst. Tech. J.*, vol. 27, no. 3, pp. 379–423, 1948.

- [42] A. Newell and H. Simon, “The logic theory machine--A complex information processing system,” *IRE Trans. Inf. theory*, vol. 2, no. 3, pp. 61–79, 1956.
- [43] A. N. Whitehead and B. Russell, *Principia mathematica*, vol. 2. Cambridge University Press, 1997.
- [44] “MIT - Massachusetts Institute of Technology.” [Online]. Available: <https://www.mit.edu/>. [Accessed: 24-May-2022].
- [45] A. M. Turing, “Computing machinery and intelligence,” in *Parsing the turing test*, Springer, 2009, pp. 23–65.
- [46] C. Gutiérrez, “El Teorema de Incompletitud de Gödel,” *Cubo, A Math. J.*, vol. 1, no. 1, pp. 68–75, 1999.
- [47] S. Fuente González, “Técnicas de aprendizaje máquina para detección y cuantificación de lluvia mediante radioenlaces terrenos a frecuencia de gigahercios,” 2020.
- [48] V. Cherkassky and F. M. Mulier, *Learning from data: concepts, theory, and methods*. John Wiley & Sons, 2007.
- [49] “Semi-Supervised Learning...el gran desconocido - Think Big Empresas.” [Online]. Available: <https://empresas.blogthinkbig.com/semi-supervised-learningel-grandesconocido/>. [Accessed: 18-Dec-2020].
- [50] L. E. Sucar, “Introduction to bayesian networks and influence diagrams,” *Decis. Theory Model. Appl. Artif. Intell. Concepts Solut.*, pp. 9–32, 2011.
- [51] B. Chandra, M. Gupta, and M. P. Gupta, “Robust Approach for Estimating Probabilities in Naive-Bayes Classifier,” in *Proceedings of the 2nd International Conference on Pattern Recognition and Machine Intelligence*, 2007, pp. 11–16.
- [52] P. Larrañaga, I. Inza, and A. Moujahid, “Tema 6. clasificadores bayesianos,” *Dep. Ciencias la Comput. e Intel. Artif. del País Vasco-Euskal Herriko Unibertsitatea*, 1997.
- [53] “Statistics | Sensitivity, Specificity, PPV and NPV | Geeky Medics.” [Online]. Available: <https://geekymedics.com/sensitivity-specificity-ppv-and-npv/>. [Accessed: 06-Jul-2022].

- [54] J. Colome Abril, “Aproximación al reajuste automático de centroides mediante la heurística de Lloyd para resolver el problema de las K-Medias,” 2012.

ANEXO

TABLAS DE DATOS DE RESULTADOS DE LOS EXPERIMENTOS

Pacientes Obstructivos vs Pacientes No Obstructivos

Ventana de 4 horas

<i>OLA: Parámetros: Característica:</i>	<i>1 PH Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,941	0,960	0,987	0	1
<i>Spe</i>	0,024	0,787	1,000	0	1	
<i>PPV</i>	0,879	0,958	0,990	0	2	1
<i>NPV</i>	0,969	0,980	0,993	0	1	

<i>OLA: Parámetros: Característica:</i>	<i>1 MV Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,921	0,965	0,993	0	1
<i>Spe</i>	0,511	1,000	1,000	0	1	21
<i>PPV</i>	0,931	0,991	1,000	0	2	
<i>NPV</i>	0,959	0,982	0,996	0	1	

<i>OLA: Parámetros: Característica:</i>	<i>1 PH Y MV Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,960	0,991	0,991	0	1
<i>Spe</i>	0,747	0,966	1,000	0	1	24
<i>PPV</i>	0,937	0,991	0,996	0	2	1
<i>NPV</i>	0,980	0,996	0,996	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,960	0,982	0,995	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,982	1,000	1,000	0	28	54,64,81,87
<i>NPV</i>	0,980	0,991	0,997	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>MV</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,924	0,975	0,984	0	30	
<i>Spe</i>	0,994	1,000	1,000	0	28	62
<i>PPV</i>	0,978	1,000	1,000	0	28	45,54
<i>NPV</i>	0,961	0,987	0,992	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH Y MV</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,963	0,978	0,993	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,978	1,000	1,000	0	28	87
<i>NPV</i>	0,981	0,989	0,997	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,969	0,986	0,995	0	1
<i>Spe</i>	1,000	1,000	1,000	0	1	
<i>PPV</i>	0,986	1,000	1,000	0	2	6,12,16,87
<i>NPV</i>	0,984	0,993	0,998	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,516	0,614	0,765	0	1
<i>Spe</i>	0,959	1,000	1,000	0	1	53
<i>PPV</i>	0,688	0,930	1,000	0	2	
<i>NPV</i>	0,681	0,760	0,866	0	1	14

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,907	0,970	0,991	0	1
<i>Spe</i>	0,987	1,000	1,000	0	1	19,53
<i>PPV</i>	0,975	1,000	1,000	0	2	1,12,16,54,87
<i>NPV</i>	0,951	0,985	0,996	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,938	0,969	0,982	0	1
<i>Spe</i>	0,532	0,693	0,792	0	1	
<i>PPV</i>	0,792	0,939	0,975	0	2	
<i>NPV</i>	0,968	0,984	0,991	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,944	0,975	0,988	0	1
<i>Spe</i>	0,751	0,987	1,000	0	1	2
<i>PPV</i>	0,925	0,975	0,993	0	2	16
<i>NPV</i>	0,971	0,988	0,994	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,982	0,987	0,993	0	1
<i>Spe</i>	0,699	0,806	0,957	0	1	24
<i>PPV</i>	0,946	0,985	0,991	0	2	
<i>NPV</i>	0,991	0,994	0,997	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	1,000	0,104	1,000	0	27	
<i>Spe</i>	0,843	1,000	1,000	0	27	62
<i>PPV</i>	0,473	1,000	1,000	0	28	
<i>NPV</i>	1,000	0,188	1,000	0	27	34

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,982	0,991	0,995	0	30	
<i>Spe</i>	0,718	1,000	1,000	0	28	69
<i>PPV</i>	0,990	1,000	1,000	0	28	40,45
<i>NPV</i>	0,991	0,995	0,997	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH Y MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,946	0,991	0,995	0	27	
<i>Spe</i>	0,843	1,000	1,000	0	27	62
<i>PPV</i>	0,990	1,000	1,000	0	28	27,37,87,44
<i>NPV</i>	0,972	0,995	0,998	0	27	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,978	0,985	0,990	0	1
<i>Spe</i>	1,000	1,000	1,000	0	1	
<i>PPV</i>	0,985	1,000	1,000	0	2	
<i>NPV</i>	0,989	0,992	0,995	0	1	6,11,20,45,57,81

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,935	0,982	0,992	0	1
<i>Spe</i>	0,958	1,000	1,000	0	1	93
<i>PPV</i>	0,947	0,990	1,000	0	2	6
<i>NPV</i>	0,966	0,991	0,996	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,983	0,993	0,995	0	1
<i>Spe</i>	1,000	1,000	1,000	0	1	
<i>PPV</i>	0,993	1,000	1,000	0	2	8,27,34,44,37,87,34
<i>NPV</i>	0,991	0,996	0,998	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,918	0,958	0,974	0	1
<i>Spe</i>	0,794	0,851	0,922	0	1	26
<i>PPV</i>	0,826	0,933	0,965	0	2	6
<i>NPV</i>	0,957	0,979	0,987	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,905	0,973	0,991	0	1
<i>Spe</i>	0,811	0,946	1,000	0	1	19
<i>PPV</i>	0,874	0,973	0,995	0	2	1
<i>NPV</i>	0,950	0,986	0,996	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,972	0,987	0,991	0	1
<i>Spe</i>	0,874	0,921	0,941	0	1	26
<i>PPV</i>	0,932	0,977	0,991	0	2	3
<i>NPV</i>	0,986	0,994	0,996	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	1,000	1,000	1,000	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	1,000	1,000	1,000	0	28	
<i>NPV</i>	1,000	1,000	1,000	0	27	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>MV</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,960	0,983	0,995	0	30	
<i>Spe</i>	0,995	1,000	1,000	0	28	68
<i>PPV</i>	0,985	1,000	1,000	0	28	45,54
<i>NPV</i>	0,980	0,991	0,997	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH Y MV</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,980	0,995	0,995	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,995	1,000	1,000	0	28	
<i>NPV</i>	0,990	0,997	0,998	0	27	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,918	0,967	0,991	0	1
<i>Spe</i>	0,995	1,000	1,000	0	1	25,46,79
<i>PPV</i>	0,970	1,000	1,000	0	2	6
<i>NPV</i>	0,957	0,983	0,995	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,039	0,072	0,286	0	1
<i>Spe</i>	0,836	0,977	1,000	0	1	62
<i>PPV</i>	0,735	0,880	1,000	0	2	
<i>NPV</i>	0,075	0,134	0,439	0	1	4,58

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,721	0,899	0,941	0	1
<i>Spe</i>	0,992	1,000	1,000	0	1	19,53
<i>PPV</i>	0,917	0,996	1,000	0	2	3,13,14
<i>NPV</i>	0,838	0,947	0,970	0	2	

Ventana de 8 horas

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,940	0,957	0,990	0	1
<i>Spe</i>	0,028	0,655	1,000	0	1	
<i>PPV</i>	0,866	0,956	0,990	0	2	1
<i>NPV</i>	0,969	0,978	0,995	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,920	0,945	0,986	0	1
<i>Spe</i>	0,753	1,000	1,000	0	1	19
<i>PPV</i>	0,929	0,954	0,995	0	2	
<i>NPV</i>	0,958	0,972	0,993	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,971	0,986	0,990	0	1
<i>Spe</i>	0,376	0,881	1,000	0	1	
<i>PPV</i>	0,922	0,985	0,991	0	2	6
<i>NPV</i>	0,985	0,993	0,995	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,915	0,966	0,980	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,966	1,000	1,000	0	28	37,54,81,87
<i>NPV</i>	0,956	0,983	0,990	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>MV</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,869	0,958	0,980	0	30	
<i>Spe</i>	0,957	1,000	1,000	0	28	62
<i>PPV</i>	0,958	1,000	1,000	0	28	45,54
<i>NPV</i>	0,929	0,979	0,990	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH Y MV</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,928	0,970	0,994	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,970	1,000	1,000	0	28	37,87
<i>NPV</i>	0,962	0,985	0,997	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,978	0,990	0,995	0	1
<i>Spe</i>	1,000	1,000	1,000	0	1	
<i>PPV</i>	0,990	1,000	1,000	0	2	37
<i>NPV</i>	0,989	0,995	0,998	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,339	0,641	0,766	0	1
<i>Spe</i>	0,937	0,967	1,000	0	1	7
<i>PPV</i>	0,700	0,930	0,994	0	2	
<i>NPV</i>	0,506	0,781	0,867	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,853	0,959	0,987	0	1
<i>Spe</i>	0,971	1,000	1,000	0	1	19,29,93
<i>PPV</i>	0,965	1,000	1,000	0	2	1,16,1,16,37,54
<i>NPV</i>	0,921	0,979	0,993	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,944	0,955	0,987	0	1
<i>Spe</i>	0,731	0,914	0,938	0	1	7,21
<i>PPV</i>	0,876	0,947	0,977	0	2	
<i>NPV</i>	0,971	0,977	0,994	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,848	0,950	0,959	0	1
<i>Spe</i>	0,246	0,929	1,000	0	1	21
<i>PPV</i>	0,554	0,950	0,997	0	2	
<i>NPV</i>	0,918	0,974	0,979	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,870	0,985	0,990	0	1
<i>Spe</i>	0,770	0,898	0,963	0	1	21
<i>PPV</i>	0,858	0,940	0,990	0	2	14
<i>NPV</i>	0,930	0,992	0,995	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,240	0,708	0,868	0	27	
<i>Spe</i>	0,971	1,000	1,000	0	27	36
<i>PPV</i>	0,942	1,000	1,000	0	28	
<i>NPV</i>	0,387	0,829	0,929	0	27	30,67,81

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,962	0,970	0,980	0	30	
<i>Spe</i>	1,000	1,000	1,000	0	28	
<i>PPV</i>	0,970	1,000	1,000	0	28	40,45
<i>NPV</i>	0,981	0,985	0,990	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH Y MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,881	0,964	0,989	0	27	
<i>Spe</i>	0,979	1,000	1,000	0	27	36,79
<i>PPV</i>	0,977	1,000	1,000	0	28	34,37,57
<i>NPV</i>	0,937	0,981	0,994	0	27	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,954	0,972	0,991	0	1
<i>Spe</i>	1,000	1,000	1,000	0	1	
<i>PPV</i>	0,972	1,000	1,000	0	2	59
<i>NPV</i>	0,976	0,986	0,995	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,010	0,011	0,364	0	1
<i>Spe</i>	0,874	0,938	1,000	0	1	10,62
<i>PPV</i>	0,711	0,913	1,000	0	2	
<i>NPV</i>	0,020	0,022	0,439	0	1	6

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,939	0,979	0,990	0	1
<i>Spe</i>	0,993	1,000	1,000	0	1	53,93
<i>PPV</i>	0,980	1,000	1,000	0	2	59
<i>NPV</i>	0,968	0,989	0,995	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,895	0,925	0,971	0	1
<i>Spe</i>	0,589	0,833	0,954	0	1	
<i>PPV</i>	0,874	0,920	0,959	0	2	16
<i>NPV</i>	0,945	0,961	0,985	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,947	0,994	0,995	0	1
<i>Spe</i>	0,956	1,000	1,000	0	1	21
<i>PPV</i>	0,965	0,995	0,998	0	2	1
<i>NPV</i>	0,973	0,997	0,998	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,969	0,991	0,995	0	1
<i>Spe</i>	0,854	0,946	1,000	0	1	25
<i>PPV</i>	0,947	0,983	0,995	0	2	
<i>NPV</i>	0,984	0,995	0,998	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	1,000	0,887	1,000	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,887	1,000	1,000	0	28	
<i>NPV</i>	1,000	0,940	1,000	0	27	34

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>MV</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,958	0,981	0,984	0	30	
<i>Spe</i>	0,994	1,000	1,000	0	28	62
<i>PPV</i>	0,982	1,000	1,000	0	28	45
<i>NPV</i>	0,979	0,990	0,992	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH Y MV</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,949	0,987	0,995	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,987	1,000	1,000	0	28	
<i>NPV</i>	0,974	0,994	0,997	0	27	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,950	0,975	0,986	0	1
<i>Spe</i>	0,988	1,000	1,000	0	1	80
<i>PPV</i>	0,979	1,000	1,000	0	2	
<i>NPV</i>	0,974	0,988	0,993	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,177	0,506	0,703	0	1
<i>Spe</i>	0,936	0,961	1,000	0	1	19,93
<i>PPV</i>	0,604	0,917	0,986	0	2	
<i>NPV</i>	0,301	0,670	0,826	0	1	5,30

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,903	0,972	0,990	0	1
<i>Spe</i>	0,969	1,000	1,000	0	1	9,47,80,93
<i>PPV</i>	0,961	0,995	1,000	0	2	27,44,72,87
<i>NPV</i>	0,949	0,986	0,995	0	2	

Ventana de 12 horas

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,930	0,969	0,987	0	1
<i>Spe</i>	0,635	0,864	1,000	0	1	21
<i>PPV</i>	0,865	0,967	0,992	0	2	1
<i>NPV</i>	0,964	0,984	0,993	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,884	0,947	0,988	0	1
<i>Spe</i>	0,927	0,993	1,000	0	1	19
<i>PPV</i>	0,895	0,962	0,994	0	2	
<i>NPV</i>	0,938	0,973	0,994	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,964	0,980	0,990	0	1
<i>Spe</i>	0,762	0,925	1,000	0	1	25
<i>PPV</i>	0,943	0,977	0,995	0	2	6
<i>NPV</i>	0,982	0,990	0,995	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,954	0,984	0,990	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,984	1,000	1,000	0	28	37,40,81,87
<i>NPV</i>	0,977	0,992	0,995	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	MV					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,940	0,958	0,984	0	30	
<i>Spe</i>	0,994	1,000	1,000	0	28	62
<i>PPV</i>	0,968	1,000	1,000	0	28	45
<i>NPV</i>	0,969	0,979	0,992	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH Y MV					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,922	0,981	0,994	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,981	1,000	1,000	0	28	37,87
<i>NPV</i>	0,960	0,990	0,997	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,978	0,989	0,995	0	1
<i>Spe</i>	0,992	1,000	1,000	0	1	29,95
<i>PPV</i>	0,990	0,996	1,000	0	2	87
<i>NPV</i>	0,989	0,995	0,997	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,644	0,850	0,869	0	1
<i>Spe</i>	0,917	1,000	1,000	0	1	47
<i>PPV</i>	0,840	0,922	1,000	0	2	
<i>NPV</i>	0,783	0,919	0,930	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,929	0,989	0,995	0	1
<i>Spe</i>	0,991	1,000	1,000	0	1	73,93
<i>PPV</i>	0,987	0,995	1,000	0	2	4,87
<i>NPV</i>	0,963	0,994	0,997	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,895	0,945	0,971	0	1
<i>Spe</i>	0,040	0,377	0,773	0	1	
<i>PPV</i>	0,773	0,910	0,961	0	2	4
<i>NPV</i>	0,944	0,972	0,985	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,921	0,972	0,990	0	1
<i>Spe</i>	0,420	0,822	1,000	0	1	19
<i>PPV</i>	0,883	0,972	0,994	0	2	
<i>NPV</i>	0,959	0,986	0,995	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,947	0,987	0,995	0	1
<i>Spe</i>	0,290	0,773	0,865	0	1	
<i>PPV</i>	0,798	0,949	0,995	0	2	12
<i>NPV</i>	0,973	0,993	0,998	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,729	0,911	0,942	0	27	
<i>Spe</i>	0,991	1,000	1,000	0	27	62
<i>PPV</i>	0,912	1,000	1,000	0	28	31,81
<i>NPV</i>	0,843	0,954	0,970	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,980	0,986	0,992	0	30	
<i>Spe</i>	0,902	1,000	1,000	0	28	73
<i>PPV</i>	0,986	1,000	1,000	0	28	40,45
<i>NPV</i>	0,990	0,993	0,996	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	<i>PH Y MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,806	0,984	0,994	0	27	
<i>Spe</i>	0,991	1,000	1,000	0	27	62
<i>PPV</i>	0,985	1,000	1,000	0	28	81
<i>NPV</i>	0,892	0,992	0,997	0	28	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,978	0,990	0,995	0	1	
<i>Spe</i>	1,000	1,000	1,000	0	1	
<i>PPV</i>	0,990	1,000	1,000	0	2	37
<i>NPV</i>	0,989	0,995	0,998	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>VM</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,403	0,734	0,853	0	1	
<i>Spe</i>	0,873	0,949	1,000	0	1	9
<i>PPV</i>	0,670	0,847	0,946	0	2	
<i>NPV</i>	0,575	0,846	0,921	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH Y MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,964	0,990	0,995	0	1	
<i>Spe</i>	0,971	1,000	1,000	0	1	68
<i>PPV</i>	0,990	1,000	1,000	0	2	6,12,87
<i>NPV</i>	0,982	0,995	0,997	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,905	0,950	0,978	0	1
<i>Spe</i>	0,616	0,892	0,954	0	1	10
<i>PPV</i>	0,859	0,936	0,965	0	2	
<i>NPV</i>	0,950	0,974	0,989	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,975	0,986	0,991	0	1
<i>Spe</i>	1,000	1,000	1,000	0	1	
<i>PPV</i>	0,979	0,991	1,000	0	2	
<i>NPV</i>	0,987	0,993	0,995	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,968	0,992	0,995	0	1
<i>Spe</i>	0,866	1,000	1,000	0	1	24,26
<i>PPV</i>	0,949	0,994	0,995	0	2	16
<i>NPV</i>	0,983	0,996	0,997	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2 <i>PH</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	1,000	1,000	1,000	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	1,000	1,000	1,000	0	28	
<i>NPV</i>	1,000	1,000	1,000	0	27	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2 <i>MV</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,542	0,754	0,844	0	30	
<i>Spe</i>	0,974	1,000	1,000	0	28	68
<i>PPV</i>	0,844	1,000	1,000	0	28	
<i>NPV</i>	0,688	0,858	0,915	0	28	30

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2 <i>PH Y MV</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,380	0,810	0,886	0	27	
<i>Spe</i>	1,000	1,000	1,000	0	27	
<i>PPV</i>	0,810	1,000	1,000	0	28	
<i>NPV</i>	0,551	0,894	0,939	0	27	30,88

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	1,000	1,000	1,000	0	1
<i>Spe</i>	1,000	1,000	1,000	0	1	
<i>PPV</i>	1,000	1,000	1,000	0	2	
<i>NPV</i>	1,000	1,000	1,000	0	1	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,670	0,915	0,951	0	1
<i>Spe</i>	0,917	0,946	1,000	0	1	32
<i>PPV</i>	0,841	0,936	0,967	0	2	18,20
<i>NPV</i>	0,802	0,956	0,975	0	2	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,982	0,990	0,995	0	1
<i>Spe</i>	0,961	1,000	1,000	0	1	7,19
<i>PPV</i>	0,988	1,000	1,000	0	2	8,27,34,37,44,87
<i>NPV</i>	0,991	0,995	0,997	0	2	

Zona Normal vs Zona Pre-obstructiva

Ventana de 4 horas

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>I</i> <i>PH</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,9913	0,9984	1,0000	0,9767	15	
<i>Spe</i>	0,4939	0,5159	0,5302	0,4568	5	12
<i>PPV</i>	0,3573	0,5983	0,6911	0,2842	4	
<i>NPV</i>	0,9948	0,9981	1,0000	0,9744	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>I</i> <i>MV</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,9738	0,9902	0,9985	0,1084	12	12
<i>Spe</i>	0,6012	0,8556	0,9546	0,3773	17	
<i>PPV</i>	0,4453	0,7686	0,9656	0,2454	17	
<i>NPV</i>	0,9763	0,9953	0,9988	0,7661	12	12

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>I</i> <i>PH Y MV</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,9904	0,9955	0,9982	0,9767	15	
<i>Spe</i>	0,7784	0,8162	0,8822	0,5263	8	
<i>PPV</i>	0,5719	0,7965	0,8634	0,3219	8	
<i>NPV</i>	0,9955	0,9971	0,9987	0,9818	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>2</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,9925	0,9958	0,9992	0,9097	57
<i>Spe</i>	0,6994	0,7895	0,8364	0,5898	40	
<i>PPV</i>	0,5560	0,7250	0,8588	0,3333	72	
<i>NPV</i>	0,9931	0,9970	0,9996	0,9197	57	57

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>2</i> <i>MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	-1,0000	0,9924	0,9968	0,9818	74
<i>Spe</i>	-1,0000	0,5835	0,7645	0,3301	30	
<i>PPV</i>	-1,0000	0,5560	0,8100	0,3007	30	
<i>NPV</i>	-1,0000	0,9903	0,9970	0,9545	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>2</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,996	0,999	0,987	41
<i>Spe</i>	0,601	0,768	0,811	0,343	30	
<i>PPV</i>	0,521	0,667	0,831	0,310	30	
<i>NPV</i>	0,995	0,997	0,999	0,963	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,992	0,996	0,999	0,928	57
<i>Spe</i>	0,698	0,785	0,831	0,594	40	
<i>PPV</i>	0,577	0,735	0,822	0,333	72	
<i>NPV</i>	0,996	0,997	0,999	0,935	57	57

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,748	0,990	0,998	0,350	5
<i>Spe</i>	0,410	0,576	0,819	0,368	18	
<i>PPV</i>	0,296	0,485	0,825	0,255	4	
<i>NPV</i>	0,741	0,986	0,997	0,493	5	5

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,997	1,000	0,977	15
<i>Spe</i>	0,570	0,689	0,789	0,391	12	
<i>PPV</i>	0,460	0,675	0,829	0,309	4	
<i>NPV</i>	0,995	0,997	1,000	0,963	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,683	0,793	0,876	0,372	15
<i>Spe</i>	0,842	0,882	0,928	0,630	6	
<i>PPV</i>	0,672	0,821	0,891	0,433	4	
<i>NPV</i>	0,773	0,910	0,953	0,671	15	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,998	0,999	0,968	5
<i>Spe</i>	0,638	0,759	0,833	0,575	20	
<i>PPV</i>	0,559	0,713	0,804	0,373	17	
<i>NPV</i>	0,995	0,997	0,999	0,970	5	5

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,992	0,997	0,998	0,758	8
<i>Spe</i>	0,765	0,809	0,849	0,676	6	
<i>PPV</i>	0,658	0,749	0,824	0,482	4	
<i>NPV</i>	0,995	0,997	0,999	0,944	8	8

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH					
	Zero Crossing					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,993	0,997	1,000	0,989	74	
<i>Spe</i>	0,700	0,739	0,782	0,590	72	
<i>PPV</i>	0,618	0,703	0,809	0,206	72	
<i>NPV</i>	0,996	0,997	1,000	0,982	58	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	MV					
	Zero Crossing					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	-1,000	0,990	1,000	0,990	30	
<i>Spe</i>	-1,000	0,242	0,457	0,242	67	
<i>PPV</i>	-1,000	0,328	0,546	0,328	30	
<i>NPV</i>	-1,000	0,971	1,000	0,971	58	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH Y MV					
	Zero Crossing					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,994	1,000	1,000	0,989	74	
<i>Spe</i>	0,497	0,596	0,758	0,344	67	
<i>PPV</i>	0,525	0,632	0,760	0,206	72	
<i>NPV</i>	0,994	1,000	1,000	0,969	58	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,992	0,996	0,999	0,251	31	31
<i>Spe</i>	0,730	0,777	0,800	0,595	74	
<i>PPV</i>	0,575	0,724	0,834	0,331	72	
<i>NPV</i>	0,995	0,997	0,999	0,678	31	31

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>VM</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,989	0,996	0,998	0,987	41	
<i>Spe</i>	0,540	0,693	0,822	0,471	45	
<i>PPV</i>	0,386	0,640	0,819	0,372	54	
<i>NPV</i>	0,985	0,996	0,999	0,967	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH Y MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,993	0,997	1,000	0,982	4	4
<i>Spe</i>	0,678	0,743	0,795	0,518	45	
<i>PPV</i>	0,546	0,729	0,811	0,331	72	
<i>NPV</i>	0,996	0,997	1,000	0,983	39	39

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,994	0,998	1,000	0,977	15
<i>Spe</i>	0,469	0,513	0,565	0,452	17	
<i>PPV</i>	0,363	0,593	0,708	0,267	4	
<i>NPV</i>	0,993	0,997	1,000	0,974	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,994	0,998	1,000	0,982	4
<i>Spe</i>	0,543	0,767	0,929	0,422	16	
<i>PPV</i>	0,497	0,746	0,953	0,322	17	
<i>NPV</i>	0,995	0,998	1,000	0,994	5	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,994	0,998	1,000	0,982	4
<i>Spe</i>	0,628	0,756	0,791	0,471	8	
<i>PPV</i>	0,469	0,718	0,821	0,284	4	
<i>NPV</i>	0,996	0,998	1,000	0,993	4	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,993	0,996	0,999	0,987	41	
<i>Spe</i>	0,704	0,744	0,776	0,529	74	
<i>PPV</i>	0,552	0,697	0,793	0,324	72	
<i>NPV</i>	0,996	0,997	0,999	0,969	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	MV					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	-1,000	0,993	0,999	0,982	74	
<i>Spe</i>	-1,000	0,504	0,615	0,304	30	
<i>PPV</i>	-1,000	0,473	0,710	0,293	30	
<i>NPV</i>	-1,000	0,994	0,999	0,985	74	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH Y MV					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,995	0,998	1,000	0,989	30	
<i>Spe</i>	0,508	0,569	0,735	0,355	30	
<i>PPV</i>	0,428	0,642	0,763	0,312	30	
<i>NPV</i>	0,996	0,999	1,000	0,991	30	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,996	0,999	0,977	15
<i>Spe</i>	0,703	0,743	0,771	0,529	74	
<i>PPV</i>	0,529	0,697	0,793	0,316	72	
<i>NPV</i>	0,996	0,997	0,999	0,969	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,989	0,995	1,000	0,976	15
<i>Spe</i>	0,463	0,602	0,704	0,433	40	
<i>PPV</i>	0,347	0,631	0,753	0,320	17	
<i>NPV</i>	0,981	0,996	1,000	0,975	39	39

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,994	0,998	1,000	0,977	15
<i>Spe</i>	0,528	0,620	0,735	0,391	41	
<i>PPV</i>	0,432	0,672	0,737	0,316	72	
<i>NPV</i>	0,996	0,998	1,000	0,969	15	15,39

Ventana de 8 horas

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,991	0,998	1,000	0,977	15
<i>Spe</i>	0,494	0,519	0,532	0,455	22	12
<i>PPV</i>	0,358	0,614	0,696	0,286	4	
<i>NPV</i>	0,995	0,998	1,000	0,967	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,976	0,990	0,999	0,108	12
<i>Spe</i>	0,619	0,922	0,983	0,361	17	
<i>PPV</i>	0,579	0,804	0,988	0,246	17	
<i>NPV</i>	0,976	0,996	0,999	0,761	12	12

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,990	0,996	0,998	0,977	15
<i>Spe</i>	0,773	0,829	0,888	0,527	8	
<i>PPV</i>	0,587	0,813	0,877	0,329	8	
<i>NPV</i>	0,995	0,997	0,999	0,976	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,993	0,996	1,000	0,925	57	57
<i>Spe</i>	0,717	0,789	0,838	0,593	40	
<i>PPV</i>	0,563	0,739	0,865	0,339	72	
<i>NPV</i>	0,992	0,997	1,000	0,930	57	57

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	MV					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,992	0,997	1,000	0,982	74	
<i>Spe</i>	0,530	0,603	0,704	0,305	30	
<i>PPV</i>	0,447	0,671	0,854	0,305	30	
<i>NPV</i>	0,989	0,995	1,000	0,875	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH Y MV					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,993	0,997	1,000	0,987	41	
<i>Spe</i>	0,594	0,674	0,789	0,329	30	
<i>PPV</i>	0,470	0,645	0,842	0,318	30	
<i>NPV</i>	0,996	0,998	1,000	0,923	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,992	0,996	0,998	0,919	57
<i>Spe</i>	0,706	0,785	0,830	0,586	12	
<i>PPV</i>	0,579	0,738	0,831	0,339	72	
<i>NPV</i>	0,995	0,997	0,999	0,928	57	57

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,959	0,992	0,998	0,325	5
<i>Spe</i>	0,467	0,659	0,853	0,321	58	
<i>PPV</i>	0,412	0,704	0,854	0,248	4	
<i>NPV</i>	0,961	0,991	0,997	0,488	5	5

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,997	1,000	0,977	15
<i>Spe</i>	0,584	0,695	0,796	0,391	12	
<i>PPV</i>	0,458	0,684	0,866	0,297	4	
<i>NPV</i>	0,995	0,997	1,000	0,923	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,994	0,999	1,000	0,486	3
<i>Spe</i>	0,371	0,400	0,478	0,196	15	
<i>PPV</i>	0,317	0,531	0,654	0,194	3	
<i>NPV</i>	0,987	0,999	1,000	0,625	15	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,994	0,998	1,000	0,982	4
<i>Spe</i>	0,487	0,596	0,640	0,365	20	
<i>PPV</i>	0,403	0,631	0,737	0,281	4	
<i>NPV</i>	0,993	0,998	1,000	0,985	22	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,994	0,998	1,000	0,982	4
<i>Spe</i>	0,515	0,586	0,739	0,387	13	
<i>PPV</i>	0,436	0,627	0,740	0,304	13	
<i>NPV</i>	0,994	0,998	1,000	0,987	22	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH					
	Zero Crossing					
	Q1	Q2	Q3	Lower Limit	Paciente	Pacientes Out
<i>Sen</i>	0,993	0,996	0,997	0,915	67	67
<i>Spe</i>	0,922	0,952	0,987	0,620	74	74
<i>PPV</i>	0,893	0,937	0,979	0,552	30	
<i>NPV</i>	0,991	0,998	0,998	0,880	67	67

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	MV					
	Zero Crossing					
	Q1	Q2	Q3	Lower Limit	Paciente	Pacientes Out
<i>Sen</i>	0,990	0,995	1,000	0,407	54	
<i>Spe</i>	0,563	0,705	0,781	0,200	41	
<i>PPV</i>	0,470	0,716	0,804	0,307	54	
<i>NPV</i>	0,982	0,995	1,000	0,813	45	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH Y MV					
	Zero Crossing					
	Q1	Q2	Q3	Lower Limit	Paciente	Pacientes Out
<i>Sen</i>	0,993	0,996	1,000	0,989	74	
<i>Spe</i>	0,695	0,841	0,928	0,541	64	
<i>PPV</i>	0,646	0,835	0,933	0,505	30	
<i>NPV</i>	0,996	0,998	1,000	0,981	39	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,993	0,996	0,998	0,977	15	15
<i>Spe</i>	0,906	0,963	0,989	0,341	72	72,74
<i>PPV</i>	0,847	0,935	0,987	0,142	72	72
<i>NPV</i>	0,996	0,998	0,998	0,952	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>VM</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,994	0,998	1,000	0,982	4	4
<i>Spe</i>	0,470	0,522	0,596	0,365	20	6
<i>PPV</i>	0,403	0,600	0,737	0,281	4	
<i>NPV</i>	0,993	0,998	1,000	0,970	39	39

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH Y MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,994	0,997	1,000	0,982	4	4
<i>Spe</i>	0,542	0,669	0,807	0,341	72	
<i>PPV</i>	0,490	0,662	0,874	0,142	72	
<i>NPV</i>	0,995	0,998	1,000	0,944	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,997	1,000	0,434	20
<i>Spe</i>	0,679	0,713	0,735	0,608	15	
<i>PPV</i>	0,497	0,662	0,768	0,417	4	
<i>NPV</i>	0,992	0,997	1,000	0,542	20	20

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,992	0,998	1,000	0,982	4
<i>Spe</i>	0,509	0,618	0,687	0,442	22	
<i>PPV</i>	0,425	0,687	0,766	0,267	4	
<i>NPV</i>	0,992	0,997	1,000	0,977	22	22

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,998	1,000	0,941	20
<i>Spe</i>	0,516	0,573	0,645	0,449	4	
<i>PPV</i>	0,439	0,661	0,717	0,267	4	
<i>NPV</i>	0,990	0,997	1,000	0,909	20	20

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,994	0,996	0,999	0,987	41	
<i>Spe</i>	0,659	0,733	0,760	0,510	74	
<i>PPV</i>	0,577	0,683	0,781	0,309	72	
<i>NPV</i>	0,995	0,997	0,999	0,952	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	MV					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	-1,000	0,993	1,000	0,963	67	67
<i>Spe</i>	-1,000	0,569	0,687	0,400	74	
<i>PPV</i>	-1,000	0,514	0,807	0,366	54	
<i>NPV</i>	-1,000	0,994	1,000	0,918	67	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH Y MV					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,996	1,000	1,000	0,987	41	
<i>Spe</i>	0,521	0,636	0,721	0,360	74	
<i>PPV</i>	0,480	0,623	0,781	0,309	72	
<i>NPV</i>	0,996	1,000	1,000	0,941	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,995	0,998	1,000	0,982	4
<i>Spe</i>	0,465	0,487	0,512	0,373	15	6,67
<i>PPV</i>	0,371	0,573	0,695	0,168	72	
<i>NPV</i>	0,994	0,998	1,000	0,889	41	41

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,979	0,993	0,998	0,812	67
<i>Spe</i>	0,394	0,785	0,838	0,292	17	
<i>PPV</i>	0,368	0,753	0,872	0,228	17	
<i>NPV</i>	0,965	0,996	0,997	0,732	67	67

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,994	0,996	0,999	0,982	4
<i>Spe</i>	0,608	0,706	0,762	0,476	72	
<i>PPV</i>	0,492	0,647	0,820	0,168	72	
<i>NPV</i>	0,995	0,997	0,999	0,952	41	41

Ventana de 12 horas

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>I</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,991	0,998	1,000	0,977	15
<i>Spe</i>	0,495	0,521	0,533	0,448	5	12
<i>PPV</i>	0,362	0,619	0,720	0,289	4	
<i>NPV</i>	0,995	0,998	1,000	0,941	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>I</i> <i>MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,976	0,990	0,999	0,108	12
<i>Spe</i>	0,625	0,921	0,973	0,363	17	
<i>PPV</i>	0,500	0,924	0,967	0,250	17	
<i>NPV</i>	0,971	0,996	0,999	0,754	12	12

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>I</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,990	0,996	0,998	0,977	15
<i>Spe</i>	0,761	0,813	0,880	0,530	8	
<i>PPV</i>	0,581	0,838	0,876	0,337	8	
<i>NPV</i>	0,995	0,997	0,999	0,957	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>2</i>					
	<i>PH</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,993	0,997	1,000	0,925	57	57
<i>Spe</i>	0,713	0,789	0,827	0,608	40	
<i>PPV</i>	0,566	0,721	0,818	0,345	72	
<i>NPV</i>	0,996	0,997	1,000	0,930	57	57

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>2</i>					
	<i>MV</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,992	0,996	1,000	0,982	74	
<i>Spe</i>	0,542	0,704	0,855	0,313	30	
<i>PPV</i>	0,486	0,623	0,946	0,310	30	
<i>NPV</i>	0,989	0,996	1,000	0,981	39	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>2</i>					
	<i>PH Y MV</i>					
	<i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,994	0,997	1,000	0,989	74	
<i>Spe</i>	0,600	0,727	0,826	0,330	30	
<i>PPV</i>	0,478	0,629	0,847	0,321	30	
<i>NPV</i>	0,995	0,997	1,000	0,980	39	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,996	0,999	0,916	57
<i>Spe</i>	0,715	0,787	0,827	0,586	12	
<i>PPV</i>	0,586	0,747	0,818	0,345	72	
<i>NPV</i>	0,996	0,997	0,999	0,925	57	57

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>VM</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,979	0,996	0,998	0,350	5
<i>Spe</i>	0,476	0,655	0,837	0,365	18	
<i>PPV</i>	0,411	0,693	0,865	0,263	4	
<i>NPV</i>	0,972	0,995	0,998	0,493	5	5

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i> <i>PH Y MV</i> <i>Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,997	1,000	0,977	15
<i>Spe</i>	0,572	0,698	0,794	0,391	12	
<i>PPV</i>	0,458	0,682	0,795	0,316	4	
<i>NPV</i>	0,995	0,997	1,000	0,968	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,996	0,999	1,000	0,523	3
<i>Spe</i>	0,575	0,680	0,704	0,233	15	
<i>PPV</i>	0,462	0,642	0,790	0,335	3	
<i>NPV</i>	0,997	0,999	1,000	0,822	3	3

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,995	0,998	1,000	0,991	3
<i>Spe</i>	0,388	0,471	0,541	0,271	17	
<i>PPV</i>	0,358	0,618	0,696	0,261	17	
<i>NPV</i>	0,995	0,998	1,000	0,967	22	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,997	0,998	0,474	8
<i>Spe</i>	0,875	0,981	0,996	0,548	1	
<i>PPV</i>	0,864	0,975	0,996	0,616	12	
<i>NPV</i>	0,995	0,997	0,999	0,887	8	8

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH					
	Zero Crossing					
	Q1	Q2	Q3	Lower Limit	Paciente	Pacientes Out
<i>Sen</i>	0,993	0,996	0,997	0,417	72	72
<i>Spe</i>	0,983	0,994	1,000	0,849	58	58
<i>PPV</i>	0,974	0,991	1,000	0,898	57	57
<i>NPV</i>	0,996	0,997	0,998	0,939	72	72

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	MV					
	Zero Crossing					
	Q1	Q2	Q3	Lower Limit	Paciente	Pacientes Out
<i>Sen</i>	0,993	0,995	0,997	0,987	41	
<i>Spe</i>	0,988	1,000	2,000	0,952	31	
<i>PPV</i>	0,993	1,000	1,000	0,935	31	31
<i>NPV</i>	0,996	0,997	0,998	0,983	39	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	2					
	PH Y MV					
	Zero Crossing					
	Q1	Q2	Q3	Lower Limit	Paciente	Pacientes Out
<i>Sen</i>	0,993	0,996	0,997	0,417	72	72
<i>Spe</i>	0,988	0,999	1,000	0,932	58	58
<i>PPV</i>	0,979	0,997	1,000	0,953	37	
<i>NPV</i>	0,996	0,997	0,998	0,939	72	72

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,992	0,996	0,998	0,619	11	11
<i>Spe</i>	0,747	0,793	0,825	0,575	58	
<i>PPV</i>	0,592	0,748	0,827	0,389	72	
<i>NPV</i>	0,996	0,997	0,999	0,646	11	11

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>VM</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,992	0,996	0,997	0,977	15	15
<i>Spe</i>	0,678	0,819	0,998	0,455	64	
<i>PPV</i>	0,595	0,858	0,994	0,446	4	
<i>NPV</i>	0,993	0,996	0,998	0,969	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH Y MV</i>					
	<i>Zero Crossing</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,445	0,930	0,979	0,200	8	
<i>Spe</i>	0,928	1,000	2,000	0,919	64	64,67
<i>PPV</i>	0,920	1,000	1,000	0,877	64	57,64
<i>NPV</i>	0,777	0,922	0,983	0,588	16	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,989	0,995	0,997	0,648	3
<i>Spe</i>	0,998	1,000	1,000	0,998	13	13
<i>PPV</i>	0,995	1,000	1,000	0,992	13	13
<i>NPV</i>	0,994	0,997	0,998	0,903	3	3

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,990	0,995	0,997	0,976	15
<i>Spe</i>	0,970	1,000	1,000	0,946	1	1
<i>PPV</i>	0,968	1,000	1,000	0,955	1	1
<i>NPV</i>	0,995	0,997	0,998	0,969	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,991	0,995	0,998	0,977	15
<i>Spe</i>	0,985	0,999	1,000	0,960	12	
<i>PPV</i>	0,976	0,996	1,000	0,894	12	12
<i>NPV</i>	0,996	0,997	0,998	0,968	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>2</i> <i>PH</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,995	0,997	0,359	72
<i>Spe</i>	0,978	0,986	0,998	0,963	31	
<i>PPV</i>	0,952	0,984	0,997	0,897	30	
<i>NPV</i>	0,996	0,997	0,998	0,934	72	72

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>2</i> <i>MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,992	0,994	0,997	0,987	41
<i>Spe</i>	0,995	1,000	1,000	0,995	45	45
<i>PPV</i>	0,986	1,000	1,000	0,986	45	45
<i>NPV</i>	0,996	0,997	0,998	0,983	39	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>2</i> <i>PH Y MV</i> <i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
	<i>Sen</i>	0,993	0,995	0,997	0,359	72
<i>Spe</i>	0,988	0,997	1,000	0,972	34	
<i>PPV</i>	0,977	0,995	1,000	0,940	34	
<i>NPV</i>	0,996	0,997	0,998	0,934	72	72

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,583	0,670	0,737	0,443	12	
<i>Spe</i>	0,996	1,000	1,000	0,699	40	40,57
<i>PPV</i>	0,988	1,000	1,000	0,496	40	40,57
<i>NPV</i>	0,717	0,839	0,913	0,440	58	

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>VM</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,990	0,994	0,997	0,975	5	
<i>Spe</i>	0,969	1,000	1,000	0,924	12	12
<i>PPV</i>	0,936	1,000	1,000	0,815	12	12
<i>NPV</i>	0,994	0,997	0,998	0,969	15	15

<i>OLA:</i> <i>Parámetros:</i> <i>Característica:</i>	<i>1 y 2</i>					
	<i>PH Y MV</i>					
	<i>Zero Crossing + Valor Medido</i>					
	<i>Q1</i>	<i>Q2</i>	<i>Q3</i>	<i>Lower Limit</i>	<i>Paciente</i>	<i>Pacientes Out</i>
<i>Sen</i>	0,923	0,989	0,996	0,466	72	72
<i>Spe</i>	0,997	1,000	1,000	0,750	57	40,57
<i>PPV</i>	0,989	1,000	1,000	0,672	40	40,57
<i>NPV</i>	0,964	0,991	0,997	0,760	44	



PARTE II – PLIEGO DE CONDICIONES

PLIEGO DE CONDICIONES

El presente Trabajo Fin de Máster comprende toda una serie de métodos y aplicaciones con técnicas de aprendizaje máquina para detección temprana de obstrucción del tubo endotraqueal en pacientes COVID-19. En el presente pliego de condiciones se trata tanto las condiciones legales, administrativas, derechos de explotación, restricciones de uso y garantías adicionales como las herramientas software como hardware necesarios para la elaboración del presente trabajo.

Condiciones legales y administrativas

A continuación, se exponen los aspectos de tipo legal y administrativo que habrán de ser tenidos en cuenta para los futuros usuarios. Estas condiciones establecen las obligaciones, derechos y deberes que los autores adquieren con los usuarios del sistema implementado en este Trabajo de Fin de Máster, y a su vez de los usuarios con los autores.

Derechos de explotación y restricciones de uso

La Universidad de Las Palmas de Gran Canaria es quien ostenta los derechos de explotación y cualquier usuario debe de estar de acuerdo en obligarse por los términos y condiciones establecidas en este Pliego de Condiciones, aceptando todos sus términos y estipulaciones; de igual manera se deberá de cumplir lo establecido en el “Reglamento general de los trabajos de fin de grado y de fin de máster de las titulaciones oficiales de la Universidad de Las Palmas de Gran Canaria”, aprobado por acuerdo de Consejo de Gobierno de la ULPGC de 28 de noviembre de 2019 (BOULPGC 5 diciembre 2019), que

en su capítulo VI reglamenta los derechos de propiedad intelectual, de explotación industrial y protección de datos personales.

El uso de programas o partes de estos, y base de datos o de una copia en ordenador personal de los mismos, será bajo la autorización expresa del autor, el o los tutores del Trabajo de Fin de Máster y el director de la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria.

El usuario no podrá realizar ingeniería inversa, decompilación o desensamblado de los programas o partes de estos. El usuario podrá transferir los programas y bases de datos a un tercero, siempre que no tenga copias de estos, incluyendo posibles actualizaciones o retener material escrito adicional que acompañe a los programas y la base de datos.

Garantías y consideraciones adicionales

La autora y los directores del TFM garantizan que los programas o partes de estos, y la base de datos funcionarán correctamente en el momento de la correcta instalación. También se garantiza que el soporte en el cual está grabado el programa no contendrá defectos en el momento de la adquisición de este.

Con la única excepción de lo expresamente expuesto en el párrafo anterior, los programas y bases de datos han sido creados sin garantías de ningún tipo. No se asegura, garantiza, o realiza ninguna declaración respecto al uso o los resultados derivados de la utilización de los programas o la base de datos. Tampoco se garantiza que la operación de los programas sea ininterrumpida o sin errores.

La confiabilidad de operación del programa puede ser afectada por factores adversos a los que se denominan fallas del sistema. En estos se incluyen fluctuaciones en el sistema de alimentación eléctrico, errores en el funcionamiento del hardware del ordenador personal, sistema operativo o entorno del ordenador personal o entorno de desarrollo y ejecución usado para realizar la aplicación, errores de instalación, problemas de compatibilidad de software y hardware, fallas o funcionamientos incorrectos de equipos de control, fallas por uso, o errores por parte del usuario o autor de la aplicación.

Cualquier aplicación donde una falla de sistema pueda crear un riesgo de daño a la propiedad o personas, no puede ser imputada al programa. Para evitar daños, el usuario deberá tomar razonablemente, todas las precauciones necesarias.

Las garantías y consideraciones aquí expresadas se regirán por las leyes del estado español. El usuario acepta la jurisdicción exclusiva de los tribunales de este país con relación a cualquier disputa que pudiera derivarse de los derechos y garantías estipuladas en este documento.

En ningún caso serán la autora, ni los tutores del TFM, ni la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria responsables de los perjuicios directos, indirectos, incidentales, probatorios o de los consiguientes, gastos, lucro cesante, pérdida de ahorros, interrupción de negocios, pérdida de información comercial o de negocio, o cualquier otra pérdida que resulte del uso o de la incapacidad de usar los programas o la base de datos. El usuario conoce y acepta esta asignación de riesgo, así como el resto de las garantías, derechos, deberes y restricciones. Se rechaza cualquier otra garantía, derecho, deber o restricción que no haya sido citada directamente en el Pliego de Condiciones.

Herramientas utilizadas

Los recursos empleados para el desarrollo del presente Trabajo Fin de Máster son:

Ordenadores: En los que se ha llevado a cabo todas las modificaciones de los programas, toda la batería de experimentos, fase de pre-procesado, extracción de características, entrenamiento, test y extracción de resultados finales.

Las características técnicas de los equipos son las siguientes:

- *Procesador Intel® Core™ i7 a 3 GHz, 16 GB de memoria RAM y disco duro de 1 TB SSD y Sistemas Operativos macOS Mojave (ver. 10.14.6) a 64 bits.*

- *Procesador Quad-Core Intel Core i5 a 1,4GHz (4 núcleos), 8 GB de memoria RAM, disco duro de 121 GB y Sistemas Operativos macOS Catalina (ver. 10.15.4) a 64 bits.*

Microsoft Office Word para Mac versión 16.39: Aplicación de la suite ofimática Microsoft Office utilizada para la redacción del documento.

Microsoft Office Excel para Mac versión 16.39: Aplicación de la suite ofimática Microsoft Office utilizada para la elaboración de las tablas presentes en el TFM.

Microsoft Office Power Point para Mac versión 16.39: Aplicación de la suite ofimática Microsoft Office utilizada para la elaboración de la presentación del presente TFM.

MatLab® versión 2019b, 64 bits, para el desarrollo de la totalidad de los algoritmos implementados en este TFM.

Base de datos: Específica para el presente TFM en el marco del Proyecto “Aplicación de técnicas de *Machine Learning* para la detección temprana de obstrucción del tubo endotraqueal en pacientes COVID-19 en UCI”, ref. COVID 19-11. Este trabajo de investigación ha sido financiado por la Universidad de Las Palmas de Gran Canaria en la convocatoria “Proyectos de Investigación COVID-19”.

Los datos expuestos en este TFM han sido totalmente anonimizados además de contar con el permiso del comité de ética del CHUIMI (Complejo Hospitalario Universitario Insular Materno Infantil) para su tratamiento.

PARTE III – PRESUPUESTO

PRESUPUESTO

Declaración Jurada

Doña Elena Encinas Pérez, autora del presente Trabajo Fin de Máster, declara que:

El Trabajo de Fin de Máster con título “*Diseño de un sistema de detección temprana de obstrucción del tubo endotraqueal en pacientes COVID-19 basado en Machine Learning*”, desarrollado en la Escuela de Ingeniería de Telecomunicación y Electrónica de la Universidad de Las Palmas de Gran Canaria, con un peso de 12 ECTS (*European Credit Transfer and Accumulation System*), correspondiente a 300 horas, de trabajo presencial y no presencial, tiene un coste total de *dieciocho mil trescientos cincuenta y un euros y ochenta y tres céntimos (18.351,83 €)*, correspondiente a la suma de las cantidades consignadas y justificadas en los apartados que se señalan a continuación.

Firmando la presente para que así conste a los efectos oportunos.

Autora del TFM:

Elena Encinas Pérez

Las Palmas de Gran Canaria, a 19 de julio de 2022

Desglose del presupuesto

El presupuesto del TFM realizado se ha obtenido según los precios de mercado actual, y de las orientaciones del Colegio Oficial Ingenieros de Telecomunicación (COIT).

Dicho informe alberga la estimación de los gastos generados durante su realización y se fundamenta sobre los siguientes conceptos, detallados a continuación:

- C-1. Trabajo tarifado por tiempo empleado.
- C-2. Amortización del inmovilizado material.
- C-3. Costes de redacción del Trabajo de Fin de Máster.
- C-4. Derechos de visado del COIT.
- C-5. Gastos de tramitación y envío.

C-1. Trabajo tarifado por tiempo empleado

A partir del 2008 la Comisión Nacional de los Mercados y la Competencia (CNMC) estableció la liberalización del mercado y por tanto está prohibido el establecimiento de honorarios profesionales por parte de los Colegios Profesionales, no pudiéndose establecer precios de los trabajos profesionales.

La información obtenida, a través del COIT de Canarias, nos indica que el rango en el que se mueve lo que debe de cobrar un ingeniero por su trabajo está entre los 50 y 75 €/hora en función del tipo de proyecto; por lo cual para mi TFM he optado por un precio de 50 €/hora.

Para la realización del presente TFM, se ha empleado 300 horas de trabajo efectivo (*3 horas × 5 días × 4 semanas × 5 meses*), por lo tanto, los honorarios asociados al total de horas trabajadas en este TFM han sido:

$$H = N_h * C_h = 300 * 50 = 15.000,00 \text{ €}$$

Los honorarios totales por tiempo dedicado libres de impuestos ascienden a *quince mil euros* (15.000,00 €).

C-2. Amortización del inmovilizado material

Entre los recursos materiales utilizados para la realización de este TFM se incluyen las herramientas software de desarrollo de los algoritmos del sistema, los paquetes software usados para la redacción de la memoria, y el sistema operativo bajo el que se ejecutó el trabajo. Asimismo, se incluyen los equipos hardware usados para dar soporte a estas herramientas.

Se estipula el coste de amortización para un período de 3 años. Para ello, se utilizará un sistema de amortización lineal o constante, en el que se supone que el inmovilizado material se deprecia de forma constante a lo largo de su vida útil. La cuota de amortización anual se calcula usando la siguiente fórmula:

$$\text{Cuota de amortización anual} = \frac{\text{Valor de adquisición} - \text{Valor residual}}{\text{Número de años de vida útil}}$$

El valor residual es el valor teórico que se supone que tendrá el elemento después de su vida útil.

Amortización del material hardware

Puesto que la elaboración del TFM ha precisado de 4 meses de trabajo y el cálculo del coste de amortización se estipula en un periodo de tres años, los costes serán calculados como los derivados del tiempo de utilización que se ha requerido por cada uno de los elementos hardware.

En la siguiente tabla se muestra la relación de cada uno de los elementos hardware con su valor de adquisición, su valor residual y el coste de amortización finalmente obtenido.

<i>Elementos Hardware</i>	<i>Coste</i>	<i>Valor residual (3 años)</i>	<i>Amortización (11 meses)</i>
<i>Ordenador Quad-Core Intel Core i5 a 1,4GHz (4 núcleos)</i>	<i>1.377 €</i>	<i>300 €</i>	<i>119,67 €</i>
<i>Ordenador Intel® Core™ i7 a 3 GHz, 16 GB de memoria RAM</i>	<i>1.299 €</i>	<i>350 €</i>	<i>105,44 €</i>
<i>Total, Hardware</i>			<i>225,11 €</i>

Por tanto, el coste total del hardware empleado ha sido de *doscientos veinticinco euros con once céntimos (225,11 €)*.

Amortización del material software

Para el cálculo del coste de amortización del software se manejan las mismas premisas que en el caso anterior. En la tabla se presentan los costes de amortización del material software:

<i>Software</i>	<i>Nº de elementos</i>	<i>Coste</i>	<i>Valor residual (3 años)</i>	<i>Amortización (11 meses)</i>
<i>MatLab® versión 2019b, 64 bits Educativa</i>	<i>1</i>	<i>250 €/año</i>	<i>0 €</i>	<i>83,33 €</i>
<i>Sistema Operativo macOS Mojave versión 10.14.6</i>	<i>1</i>	<i>0,00 €</i>	<i>0 €</i>	<i>0,00 €</i>
<i>Sistema Operativo macOS Catalina versión 10.15.4</i>	<i>1</i>	<i>0,00 €</i>	<i>0 €</i>	<i>0,00 €</i>
<i>Paquete Microsoft Office para Mac versión 16.39</i>	<i>2</i>	<i>7,00 €/mes</i>	<i>0 €</i>	<i>28,00 €</i>

<i>Bases de datos</i>	---	0,00 €	0 €	0,00 €
<i>Total, Software</i>				111,33 €

Por tanto, el coste total del software empleado ha sido de *ciento once euros con treinta y tres céntimos (111,33 €)*.

C-3. Costes de redacción del Trabajo de Fin de Máster

El coste asociado a la redacción del TFM se ha calculado según la siguiente expresión recomendada por el COIT:

$$R = 0,07 \cdot P \cdot C_h$$

Donde P es el presupuesto del TFM obtenido y C_h un coeficiente de ponderación en función del presupuesto estipulado por el COIT, que varía según el valor de P . Dicho valor se ha calculado sumando los costes de las secciones anteriores correspondientes a la amortización del inmovilizado material, tanto hardware como software, al trabajo tarifado por tiempo empleado y los gastos por desplazamiento. Así, el valor de P asociado a este TFM ha sido:

<i>Concepto</i>	<i>Coste</i>
<i>Trabajo tarifado por tiempo empleado</i>	15.000,00 €
<i>Amortización del material hardware</i>	225,11 €
<i>Amortización del material software</i>	111,33 €
<i>Total</i>	15.336,44 €

Que según el COIT tiene un coeficiente de ponderación de 1.00, pues es el valor fijado para proyectos cuyo presupuesto es inferior a 30.050 €, que es nuestro caso. Teniendo en cuenta el presupuesto calculado en la tabla anterior, se tiene que:

$$R = 0,07 \cdot P \cdot Ch = 0,07 \cdot 15.336,44 \cdot 1 = 1.073,55 \text{ €}$$

Por lo tanto, el importe final de redacción del TFM asciende a la cantidad de *mil setenta y tres euros con cincuenta y cinco céntimos (1.073,55 €)*.

C-4. Derechos de visado

En cuanto al visado, hoy en día no es obligatorio, y sus gastos depende mucho del tipo de proyecto, por tanto, me he ceñido a un formulario genérico utilizado por el COIT, que establece que para la redacción de proyectos y trabajos en general, los derechos de visado se calculan de acuerdo con la siguiente expresión:

$$V = 0,006 \cdot P \cdot C$$

Donde P representa el presupuesto total y C es el coeficiente reductor en función de dicho presupuesto. El presupuesto total se obtiene de la suma de las secciones anteriores correspondientes al trabajo tarifado por tiempo empleado, la amortización del inmovilizado material y la redacción del TFM, como se observa en la tabla:

<i>Concepto</i>	<i>Coste</i>
<i>Trabajo tarifado por tiempo empleado</i>	<i>15.000,00 €</i>
<i>Amortización del material hardware</i>	<i>225,11 €</i>
<i>Amortización del material software</i>	<i>111,33 €</i>

<i>Redacción del TFM</i>	<i>1.073,55 €</i>
<i>Total</i>	<i>16.409,99 €</i>

En función del presupuesto obtenido, se extrae el valor del coeficiente reductor del presupuesto C, según el COIT para presupuestos menores de 30.050 € viene definido con un valor de 1,00. Por consiguiente:

$$V = 0,006 \cdot P \cdot C = 0,006 \cdot 16.409,99 \cdot 1,00 = 98,46 \text{ €}$$

Finalmente, los costes por derecho de visado del TFM ascienden a *noventa y ocho euros y cuarenta y seis céntimos (98,46€)*

C-5. Gastos de tramitación y envío

En cuanto a los gastos de tramitación y envío son fijos y se estipulan hoy en día, por parte del COIT en *nueve euros (9,00 €)*.

Resumen del presupuesto

Resumen de presupuesto

<i>C-1. Trabajo tarifado por tiempo empleado</i>	<i>15.000,00 €</i>
<i>C-2. Amortización del inmovilizado material</i>	<i>336,44 €</i>
<i>- Material de hardware: 225,11 €</i>	
<i>- Material de software: 111,33 €</i>	
<i>C-3. Costes de redacción del Trabajo de Fin de Máster</i>	<i>1.073,55 €</i>
<i>C-4. Derechos de visado del COIT</i>	<i>98,46 €</i>
<i>C-5. Gastos de tramitación y envío</i>	<i>9,00 €</i>
<i>Presupuesto total antes de impuestos:</i>	<i>16.517,45 €</i>
<i>Aplicación de Impuestos (7% IGIC):</i>	<i>1.156,22 €</i>
<i>PRESUPUESTO TOTAL:</i>	<i>17.673,67 €</i>

El presupuesto total, con los impuestos incluidos, asciende a la cantidad de *diecisiete mil seiscientos setenta y tres euros y sesenta y siete céntimos (17.673,67 €)*.

Fdo.: Elena Encinas Pérez

Las Palmas de Gran Canaria, a 19 de julio de 2022

