



Universidad de Concepción
Dirección de Postgrado
Facultad de Ingeniería - Programa de Magíster en Ciencias de la Ingeniería con Mención
en Ingeniería Eléctrica

**Desarrollo de algoritmo de detección de
nivel de saturación para la determinación del estado de
filtros en mascarillas industriales**

Tesis para optar al grado de Magíster en Ciencias de la Ingeniería con
mención en Ingeniería Eléctrica

PAZ ISIDORA GATICA SALGADO
CONCEPCIÓN-CHILE
JULIO 2026

Profesor Guía: Pablo Aqueveque Navarro
Dpto. de Ingeniería Eléctrica, Facultad de Ingeniería
Universidad de Concepción

Resumen

La determinación del estado de saturación de filtros en mascarillas industriales se realiza mediante criterios subjetivos los cuales no reflejan el desgaste real del medio filtrante. Esta tesis propone el desarrollo y validación de un algoritmo capaz de estimar en tiempo real el nivel de saturación de filtros respiratorios a partir del análisis de señales respiratorias medidas dentro del respirador y se enmarca en el proyecto FONDEF código ID24i10487, titulado “Sistema de monitoreo de condiciones de respiradores industriales”.

Se realizó un análisis exploratorio y estadístico de las variables respiratorias, evidenciando que el proceso de saturación es progresivo, no lineal e irreversible. Los resultados mostraron que la presión respiratoria es el indicador más robusto y sensible frente a la degradación del filtro, mientras que la humedad cumple un rol complementario y la temperatura presenta una baja capacidad discriminante.

El problema fue formulado como una tarea de regresión supervisada para la estimación continua del nivel de saturación. Se evaluaron distintos modelos de regresión, seleccionándose un modelo basado en Extreme Gradient Boosting (XGBoost) por su mejor desempeño global y en la zona crítica de operación. El algoritmo incorpora ponderación de muestras, suavizado temporal y restricciones de monotonía, garantizando coherencia física en las estimaciones.

La validación experimental incluyó pruebas en tiempo real bajo condiciones promedio, saturación acelerada y pruebas de larga duración. En escenarios representativos de uso industrial, el sistema mostró una estimación estable y consistente con el ground truth, mientras que en escenarios extremos presentó una respuesta conservadora adecuada desde el punto de vista de seguridad. La evaluación como clasificador evidenció una alta sensibilidad (0.997) y un AUC cercano a 0.96, demostrando su capacidad para detectar oportunamente condiciones críticas.

Abstract

The determination of the saturation state of filters in industrial respirators is commonly based on subjective criteria or usage time, which do not accurately reflect the actual degradation of the filtering medium. This thesis proposes the development and validation of an algorithm capable of estimating, in real time, the saturation level of respirator filters through the analysis of respiratory signals measured inside the respirator, within the framework of the FONDEF project ID24i10487, “Monitoring System for Industrial Respirator Conditions”.

An exploratory and statistical analysis of the respiratory variables was conducted, revealing that the filter saturation process is progressive, non-linear, and irreversible. The results showed that respiratory pressure is the most robust and sensitive indicator of filter degradation, while humidity plays a complementary role and temperature exhibits limited discriminative capability.

The problem was formulated as a supervised regression task aimed at continuous saturation estimation. Several regression models were evaluated, with an Extreme Gradient Boosting-based model selected due to its superior overall performance and accuracy in the critical operating region. The algorithm incorporates sample weighting, temporal smoothing, and monotonicity constraints to ensure physically consistent saturation estimates.

Experimental validation included real-time tests under average conditions, accelerated saturation, and long-duration scenarios. Under representative industrial conditions, the system produced stable estimates consistent with the ground truth, while under extreme scenarios it exhibited a conservative response suitable from a safety perspective. When evaluated as a classifier, the system achieved high sensitivity (0.997) and an AUC close to 0.96, demonstrating its ability to reliably detect critical saturation conditions.

Agradecimientos

En primer lugar, quiero agradecer a mi familia por su apoyo incondicional y por nunca dudar de mí, incluso cuando yo misma lo hacía. Gracias por celebrar cada pequeño avance y por recordarme la importancia de descansar cuando el camino se ponía difícil.

No puedo dejar de agradecer a mis compañeros más fieles de cuatro patas, Oliver y Toffee. Su presencia silenciosa y su compañía incondicional en las noches de desvelo hicieron que las horas de estudio fueran mucho más amenas.

Finalmente, expreso mi gratitud a mis amigos, con quienes compartí risas, cafés, desvelos y la complicidad de saber exactamente lo que significaba este desafío. De manera muy especial, agradezco a Loreto, por su valiosa compañía y apoyo constante a lo largo de todos estos años.

Tabla de Contenidos

CAPÍTULO 1. INTRODUCCIÓN.....	1
1.1. INTRODUCCIÓN GENERAL	1
1.2. HIPÓTESIS.....	2
1.3. OBJETIVO GENERAL	2
1.4. OBJETIVOS ESPECÍFICOS	2
1.5. ALCANCES.....	3
1.6. LIMITACIONES.....	3
CAPÍTULO 2. MARCO TEÓRICO	3
2.1. INTRODUCCIÓN.....	3
2.2. FISIOLÓGÍA DE LA RESPIRACIÓN	4
2.3. VARIACIONES EN EL CICLO RESPIRATORIO	5
2.4. RELACIONES ENTRE CAPACIDAD PULMONAR Y DIMENSIONES ANTROPOMÉTRICAS.....	7
2.5. PRUEBAS DE FILTROS DE MASCARILLAS INDUSTRIALES	9
2.6. NORMATIVAS SOBRE EVALUACIÓN DE MASCARILLAS.....	9
2.7. MODELOS DE REGRESIÓN.....	10
2.7.1 Regresión Lineal	10
2.7.2 Support Vector Regression (SVR)	11
2.7.3 Modelos basados en árboles de decisión.....	11
2.7.4 Métodos de ensamble: Random Forest y Gradient Boosting	11
2.7.5 Extreme Gradient Boosting (XGBoost).....	12
2.8. MÉTRICAS DE EVALUACIÓN DE MODELOS.....	12
2.8.1 Métricas para modelos de regresión	12
2.8.2 Métricas para modelos de clasificación	13
2.8.3 Curvas ROC y POD	14
2.8.4 Estrategias de validación: Leave-One-Subject-Out (LOSO).....	14
CAPÍTULO 3. REVISIÓN BIBLIOGRÁFICA	16
3.1. INTRODUCCIÓN.....	16
3.2. MASCARILLAS INTELIGENTES: SENSORES EMBEBIDOS Y ANÁLISIS DE SEÑALES RESPIRATORIAS.....	17
3.3. EVALUACIÓN DEL DESEMPEÑO Y DESGASTE DE FILTROS RESPIRATORIOS	28
3.4. DISCUSIÓN.....	30
CAPÍTULO 4. METODOLOGÍA	32
4.1. LEVANTAMIENTO DE DATOS EXPERIMENTALES	32
4.2. DEFINICIÓN DEL ESTADO DE SATURACIÓN DEL FILTRO (GROUND TRUTH)	34
4.3. PREPROCESAMIENTO DE LOS DATOS	36

4.4.	ANÁLISIS DE DATOS	38
4.5.	EXTRACCIÓN DE CARACTERÍSTICAS	38
4.6.	DESARROLLO DEL ALGORITMO DE DETECCIÓN DE SATURACIÓN	41
4.7.	VALIDACIÓN EXPERIMENTAL.....	43
4.8.	IMPLEMENTACIÓN DEL MODELO EN TIEMPO REAL.....	45
CAPÍTULO 5. RESULTADOS.....		47
5.1.	LEVANTAMIENTO DE DATOS.....	47
5.2.	CARACTERIZACIÓN DEL PROCESO DE SATURACIÓN	49
5.3.	ANÁLISIS DE DATOS	51
5.3.1	<i>Tendencias globales de las variables respiratorias.....</i>	52
5.3.2	<i>Análisis de variabilidad y esfuerzo respiratorio.....</i>	53
5.3.3	<i>Análisis entre variables respiratorias y saturación.....</i>	54
5.3.4	<i>Distribución estadística por etapas de saturación</i>	56
5.3.5	<i>Síntesis del análisis y selección de variables.....</i>	57
5.4.	DESEMPEÑO MODELO DE REGRESIÓN.....	58
5.4.1	<i>Comparación de modelos de regresión</i>	58
5.4.2	<i>Estimación de saturación en distintos escenarios</i>	59
5.5.	EVALUACIÓN CLASIFICACIÓN DE ESTADOS	62
5.5.1	<i>Matriz de confusión y métricas de clasificación.....</i>	62
5.5.2	<i>Análisis ROC (Receiver Operating Characteristic).....</i>	63
5.5.3	<i>Curva de Probabilidad de Detección (POD).....</i>	64
5.6.	VALIDACIÓN EN TIEMPO REAL.....	65
5.6.1	<i>Validación en condiciones promedio y de larga duración</i>	66
5.6.2	<i>Validación bajo condiciones de estrés (prueba acelerada).....</i>	67
5.7.	RESULTADOS DE DIFUSIÓN CIENTÍFICA	67
CAPÍTULO 6. DISCUSIÓN Y CONCLUSIONES.....		69
6.1.	DISCUSIÓN.....	69
6.1.1	<i>Relación entre variables respiratorias y saturación del filtro.....</i>	69
6.1.2	<i>Definición de ground truth y rol de fantoma respiratorio</i>	70
6.1.3	<i>Desempeño del modelo de regresión</i>	71
6.1.4	<i>Evaluación como sistema clasificador.....</i>	71
6.1.5	<i>Validación en tiempo real y alcance práctico</i>	72
6.2.	LIMITACIONES.....	72
6.3.	TRABAJO FUTURO	73
6.4.	CONCLUSIÓN	74
CAPÍTULO 7. GLOSARIO		76
CAPÍTULO 8. REFERENCIAS.....		77

Lista de Figuras

Fig. 2.1: Esquema de proceso de calentamiento del aire inhalado en las vías respiratorias, desde el ingreso nasal (22 °C, 7 mg/L) hasta los pulmones (37 °C, 44 mg/L).	5
Fig. 3.1: Maniquí de pruebas de fugas en respiradores industriales desarrollado por Liu[32], utilizado para exposición a aerosoles y simular ciclos respiratorios sin control de temperatura y humedad.	17
Fig. 3.2: Detección de fugas en respiradores industriales del sistema propuesto por Liu et.al [32], en celeste se visualizan las muestras indicadoras de sello, en verde las fugas de 5 segundos y en rojo las fugas de 10 segundos.....	18
Fig. 3.3: Implementación de mascarilla inteligente desechable para monitoreo de respiración [34].	19
Fig. 3.4: Detección de condiciones anómalas de respiración y uso correcto de mascarilla [34].	20
Fig. 3.5: Mascarilla inteligente compuesta por mascarilla comercial con sensor de ondas sonoras en estructura de esponja de nanocompuestos [29].	21
Fig. 3.6: Procesamiento de datos y resultados obtenidos por Suo et al [29], para la detección de diversas condiciones de respiración como tos, respiración normal y habla.	22
Fig. 3.7: Mascarilla desechable equipada con sensor de temperatura y humedad, para la estimación de vida útil [30].	23
Fig. 3.8: Obstrucción de respiradores industriales utilizando piezas plásticas de diferentes tamaño [31].	24
Fig. 3.9: Modelo de pruebas desarrollado por Romano et al [22], este modelo replica la respiración en términos de temperatura, humedad y flujo respiratorio utilizando un ventilador mecánico, humidificador de paso y pulmón de prueba.	26
Fig. 3.10: Señales de presión, temperatura y humedad obtenidas por mascarilla inteligente desarrollada por Ponce et al [23], para uso correcto e incorrecto del respirador.	27
Fig. 4.1: Esquema simplificado de la metodología general.	32
Fig. 4.2: Esquema de fantoma y cámara de pruebas propuesto, el cual está compuesto por un ventilador mecánico, humidificador y cámara de pruebas.	33
Fig. 4.3: Vista del sensor respiratorio desarrollado por Aqueveque [31], ubicado en un respirador industrial. Este dispositivo fue utilizado para registrar en tiempo real variables fisiológicas como presión, temperatura y humedad durante las pruebas.	34

Fig. 4.4: Etapas del preprocesamiento de la señal respiratoria de presión. (a) Identificación y exclusión de segmentos inválidos asociados a ausencia de actividad respiratoria. (b) Establecimiento del período de referencia correspondiente a un filtro limpio. (c) Segmentación temporal de la señal normalizada mediante ventanas deslizantes de longitud fija.	37
Fig. 5.1: Implementación de fantoma y cámara de pruebas, en la figura es posible observar componentes importantes de este modelo, como ventilador mecánico, humidificador propuesto y cámara de contaminación.	48
Fig. 5.2: Comparación de señales respiratorias de fantoma y de una persona alineadas y normalizadas.....	49
Fig. 5.3: Evolución del peso del filtro en función del tiempo de exposición a contaminación durante pruebas controladas con el fantoma respiratorio. Se muestran dos pruebas representativas (Sample 1 y Sample 2), junto con su valor medio y el rango mínimo–máximo observado.	50
Fig. 5.4: Comparación del peso de un filtro 3M 2097 P100 antes (izquierda) y después (derecha) de la prueba de exposición prolongada a contaminantes. Se observa un incremento de masa asociado a la acumulación de partículas en el filtro.....	51
Fig. 5.5: Evolución de los valores medios normalizados de presión en azul, humedad en verde y temperatura en rojo, en función del porcentaje de saturación del filtro.	53
Fig. 5.6: Evolución de la amplitud respiratorio (magnitud P2P), de las señales de presión en azul, humedad en verde y temperatura en rojo, en función del nivel de saturación del filtro.	54
Fig. 5.7: Monotonicidad y poder explicativo de las variables respiratorias (presión, humedad y temperatura) respecto al nivel de saturación del filtro. Se presentan los coeficientes de correlación de Spearman (ρ) con intervalos de confianza al 95% y el coeficiente de determinación (R^2).....	56
Fig. 5.8: Distribución de la presión respiratoria normalizada agrupada por etapas de saturación del filtro (0–30%, 30–60%, 60–85% y >85%)......	57
Fig. 5.9: Comparación entre la saturación estimada por el modelo XGBoost y el ground truth para tres escenarios representativos: (A) prueba promedio, (B) prueba de saturación acelerada y (C) prueba de larga duración.	60
Fig. 5.10: Matriz de confusión del algoritmo para la clasificación binaria de los estados Normal (<85%) y Saturado ($\geq 85\%$).	62
Fig. 5.11: Curva ROC (Receiver Operating Characteristic) del clasificador binario Normal/Saturado.	63
Fig. 5.12: Curva de probabilidad de detección (Probability of Detection, POD) del sistema para la identificación de filtros saturados (predicción >85%), en función del nivel real de saturación. La curva muestra un aumento progresivo de la probabilidad de detección, alcanzando niveles superiores al 95% en el rango de saturación crítica.....	64
Fig. 5.13: Evolución temporal de la saturación durante la validación en tiempo real utilizando el fantoma respiratorio bajo tres escenarios operativos: (A) Prueba promedio, (B) Prueba de saturación acelerada, y (C) prueba de larga duración.....	66

Lista de Tablas

Tabla 2-1. Rangos de frecuencia respiratoria, tiempo inspiratorio y volumen tidal según intensidad de actividad física[9][11].	8
Tabla 5-1 Asociación estadística entre variables respiratorias y saturación del filtro.	55
Tabla 5-2 Comparación de rendimiento de modelos de regresión para la estimación del nivel de saturación del filtro, evaluada mediante MAE global y MSE en zona crítica.	59

Capítulo 1. Introducción

1.1. Introducción General

Las mascarillas industriales desempeñan un papel crucial en la protección de los trabajadores frente a contaminantes peligrosos en entornos laborales. Según la organización internacional del trabajo (OIT), alrededor del 50% de los trabajadores de áreas industriales presenta enfermedades respiratorias [1]. Un grupo particularmente vulnerable son los mineros, quienes están en riesgo de desarrollar enfermedades pulmonares debido a la exposición al polvo respirable que se encuentra suspendido en el aire. La organización internacional del trabajo estima que el 37% de los mineros de Latinoamérica tiene silicosis, enfermedad producida por exposición prolongada a sílice [2]. Este polvo contiene partículas extremadamente finas que al inhalarse, pueden penetrar en el tejido pulmonar, causando daños a largo plazo [3]. Ante este riesgo los respiradores industriales juegan un papel crucial en la filtración de estos contaminantes, pero su eficacia puede verse afectada por diversas condiciones ambientales, como la temperatura, la humedad y la concentración de contaminantes [4]. Por esto no existe un momento específico en que se deban cambiar los filtros, generando incertidumbre en los usuarios respecto a la calidad de su mascarilla.

La eficacia de las mascarillas industriales depende de la capacidad de sus filtros para capturar estas partículas y gases nocivos. Sin embargo, los filtros se saturan con el tiempo, lo que disminuye su efectividad y pone en riesgo la salud de los trabajadores. La falta de un método que permita evaluar el nivel de saturación de los filtros en tiempo real puede llevar al mal uso de estos, lo que afecta directamente la salud del usuario. Este mal uso puede, a largo plazo, provocar enfermedades respiratorias graves irreversibles o incluso la muerte, comprometiendo de manera crítica la salud de los trabajadores.

En la actualidad se están desarrollando métodos que permitan un control de la efectividad de las mascarillas, sin embargo, estos dispositivos se centran en analizar señales de la respiración de la persona, sin abordar específicamente el estado de los filtros. Esta información se puede obtener a través del análisis en tiempo real de las señales obtenidas de la respiración. Por lo tanto, esta investigación se centra en el desarrollo de un algoritmo de detección de condiciones que permita evaluar las condiciones de los filtros de las mascarillas industriales, determinando si se encuentran en buen o mal estado, de esta forma, optimizando la protección respiratoria de los trabajadores.

En el contexto de la problemática, la determinación del estado de saturación de los filtros en mascarillas industriales es crucial para garantizar la protección adecuada de los trabajadores expuestos a ambientes contaminados. El objetivo de esta investigación es desarrollar un algoritmo basado en modelos de aprendizaje automático que permita detectar el nivel de saturación de los filtros en tiempo real utilizando señales de respiración obtenidas dentro de un respirador industrial.

El algoritmo se desarrollará utilizando datos obtenidos de un fantoma físico que simula las condiciones respiratorias humanas en entornos industriales controlados, considerando variables como temperatura, presión y humedad generadas durante la respiración. Estas señales serán procesadas para identificar relaciones entre ellas que permitan caracterizar el nivel de saturación de los filtros, proporcionando una evaluación confiable de su estado en diferentes condiciones de uso y niveles de contaminación.

La principal contribución de este trabajo radica en el desarrollo de un algoritmo que detecta en tiempo real la saturación de los filtros en mascarillas industriales. Esto mejorará la seguridad y salud de los trabajadores al optimizar la protección respiratoria de los usuarios, reduciendo el riesgo de enfermedades respiratorias y evitando el uso de filtros saturados.

1.2. Hipótesis

La saturación de filtros en mascarillas industriales puede ser estimada de forma continua mediante la evolución no lineal de variables respiratorias, como presión y humedad, utilizando modelos de aprendizaje automático capaces de operar en tiempo real.

1.3. Objetivo General

Desarrollar y validar un sistema basado en variables respiratorias y aprendizaje automático capaz de estimar de forma continua y detectar condiciones críticas de saturación en filtros de mascarillas industriales en tiempo real.

1.4. Objetivos específicos

- Identificar y analizar las relaciones entre las variables medidas y el nivel de saturación de los filtros, utilizando métodos estadísticos.

- Implementación de fantoma que simule las condiciones de uso humano de mascarillas en el ambiente de trabajo.
- Desarrollar un algoritmo que pueda detectar nivel de saturación en filtros de mascarillas industriales.
- Evaluar desempeño del algoritmo en tiempo real haciendo uso de un fantoma de pruebas, aplicándolo a ambientes con distintos niveles de contaminación.

1.5. Alcances

- El modelo considera variables de humedad y presión de la respiración dentro de un respirador industrial de media máscara.
- Se considera el uso de un fantoma respiratoria para la obtención de datos, con el fin de evitar la exposición de personas a ambientes contaminados.
- El modelo se enfoca en filtros de respiradores industriales de la serie P100 para material particulado, no se evalúan otros tipos de filtros ni dispositivos de protección respiratoria.
- El modelo es aplicable a condiciones de uso industrial controladas, en las cuales la saturación del filtro ocurre de forma progresiva.

1.6. Limitaciones

- El tamaño limitado de los datos podría restringir la capacidad de abordar casos complejos.
- El modelo desarrollado podría no ser aplicable a diferentes tipos de mascarillas industriales o filtros.
- No será posible realizar experimentos en individuos, lo que limita la capacidad de validar los resultados obtenidos con sujetos humanos.

Capítulo 2. Marco Teórico

2.1. Introducción

Este trabajo se basa en el desarrollo de un algoritmo detector del nivel de saturación de los filtros de mascarillas industriales, lo cual considera el desarrollo de un fantoma de simulación respiratoria

que logre emular el ciclo respiratorio humano y reproduzca diversas condiciones ambientales de contaminación a las que están expuestos los usuarios de respiradores industriales diariamente. Para esto, se debe entender la fisiología de la respiración humana y las características que lo definen, comprendiendo los factores que afectan las variables de la respiración. Además, se abordan las normativas que rigen las pruebas que deben superar estos dispositivos a nivel mundial, esto permite comprender el procedimiento actual de evaluación de respiradores industriales. Finalmente, se mencionan los distintos modelos a ser evaluados y las métricas a tener en consideración para la evaluación de algoritmos.

2.2. Fisiología de la respiración

El ciclo respiratorio humano es el proceso fisiológico en el cual se realiza el intercambio de gases entre el organismo y el medio ambiente, permitiendo la captación de oxígeno y la eliminación de dióxido de carbono [5]. Este ciclo está compuesto por dos fases principales: la inhalación (inspiración) y la exhalación (expiración). Durante la inhalación, el diafragma y los músculos intercostales externos se contraen, generando un aumento del volumen torácico y una disminución de la presión intrapulmonar, lo que permite la entrada de aire a los pulmones. En la exhalación, estos músculos se relajan, disminuyendo el volumen torácico y aumentando la presión intrapulmonar, lo que facilita la expulsión del aire [6].

Los principales parámetros que describen el ciclo respiratorio incluyen:

1. **Volumen Tidal (VT):** Representa el volumen de aire inhalado o exhalado en un ciclo respiratorio normal. En un adulto promedio en reposo, este valor oscila entre 400 y 600 ml [7].
2. **Frecuencia Respiratoria (FR):** Corresponde al número de ciclos respiratorios por minuto, que en condiciones normales varía entre 12 y 20 ciclos/minuto.
3. **Volumen Minuto (VM):** Es el producto del VT y la FR, que refleja el volumen total de aire movilizado por los pulmones en un minuto. En un adulto en reposo, el VM típico es de 6 a 8 litros/minuto.
4. **Temperatura del Aire Inhalado y Exhalado:** El aire inhalado a temperatura ambiente ($\sim 20\text{-}25\text{ }^{\circ}\text{C}$) es calentado por las vías respiratorias hasta alcanzar casi la temperatura

corporal ($\sim 37^\circ\text{C}$) al llegar a los pulmones (véase Fig. 2.1). Durante la exhalación, el aire mantiene una temperatura cercana a $34\text{-}36^\circ\text{C}$ [8].

5. **Humedad del Aire Inhalado y Exhalado:** El aire inhalado, dependiendo del ambiente, puede tener niveles de humedad relativa variables ($20\text{-}60\%$). Sin embargo, en las vías respiratorias superiores, el aire es humidificado hasta alcanzar el 100% de saturación con vapor de agua. El aire exhalado típicamente contiene una humedad absoluta de 44 mg/L y una presión de vapor de agua de 47 mmHg a 37°C [8].

Estos parámetros son cruciales al momento de evaluar el desgaste de las mascarillas, ya que influyen directamente en cómo los filtros interactúan con las condiciones propias de la respiración humana. Comprender la fisiología del ciclo respiratorio permite interpretar las señales de presión, temperatura y humedad de la respiración, que son las variables clave para el desarrollo del algoritmo, permitiendo modelar y analizar cómo los cambios en estas señales reflejan el estado de saturación y desgaste de los filtros.




Fig. 2.1: Esquema de proceso de calentamiento del aire inhalado en las vías respiratorias, desde el ingreso nasal (22°C , 7 mg/L) hasta los pulmones (37°C , 44 mg/L).

2.3. Variaciones en el Ciclo Respiratorio

El ciclo respiratorio humano no es estático, ya que, varía en función de factores fisiológicos, ambientales y de esfuerzo físico. Estas variaciones afectan directamente los parámetros respiratorios, como el volumen tidal, la frecuencia respiratoria, la temperatura y la humedad del aire inhalado y exhalado [9]. Comprender estas fluctuaciones es esencial para diseñar un fantoma respiratorio, capaz de replicar condiciones normales y extremas que enfrentan los usuarios de

respiradores industriales. Es importante que esta información se acerque a la realidad, ya que constituye la base de datos con la cual será desarrollado el algoritmo de detección de condiciones. Las características del ciclo respiratorio pueden variar según las necesidades metabólicas y las condiciones de salud de una persona:

- **Ejercicio Físico:** Durante el ejercicio se requiere una mayor captación de oxígeno y eliminación de dióxido de carbono. Esto implica un aumento de la frecuencia respiratoria, que puede alcanzar entre 40 y 60 respiraciones por minuto, y un aumento del volumen tidal, que puede incrementarse hasta 2-3 litros por respiración en individuos entrenados [7]. El diseño de fantoma debe considerar las variaciones en los patrones respiratorios para representar estados de mayor demanda.
- **Condiciones de reposo:** En estado de reposo, el ciclo respiratorio es más uniforme, con una frecuencia de 12-20 respiraciones por minuto y un volumen tidal promedio de 500 ml.
- **Alteraciones patológicas:** Enfermedades como el asma o la enfermedad pulmonar obstructiva crónica (EPOC) afectan el ciclo respiratorio, aumentando la resistencia al flujo de aire y modificando el patrón normal de inhalación y exhalación.

Las condiciones ambientales también influyen en el ciclo respiratorio, alterando la dinámica de los parámetros físicos del aire inhalado y exhalado [10]. Este punto es de gran importancia, ya que se busca imitar condiciones de contaminación a las que están expuestos los trabajadores de áreas industriales. De esta forma será posible evaluar el algoritmo utilizando el fantoma de pruebas, sin necesidad de exponer a las personas a contaminación.

- **Altitud elevada:** En condiciones de baja presión atmosférica, como en altitudes elevadas, la baja disponibilidad de oxígeno produce hiperventilación, aumentando tanto la frecuencia como el volumen tidal para compensar la hipoxia.
- **Ambientes calurosos:** En entornos con altas temperaturas, el cuerpo pierde calor a través del aire exhalado, lo que puede influir en la temperatura y la humedad relativa del aire respirado. Esto aumenta la evaporación en las vías respiratorias y puede acelerar el desgaste de los filtros. La exposición prolongada a temperaturas elevadas podría comprometer la durabilidad y efectividad de los filtros de las mascarillas.

- **Ambientes con alta humedad:** En condiciones de alta humedad, la capacidad de evaporación de las vías respiratorias disminuye, y la condensación en los filtros puede incrementar la resistencia al flujo de aire y reducir la eficiencia de la filtración.

En entornos industriales, los trabajadores suelen estar expuestos a contaminantes y gases tóxicos que pueden alterar el ciclo respiratorio:

- **Exposición a partículas o gases tóxicos:** La inhalación de partículas o sustancias irritantes puede causar broncoconstricción, aumentando la resistencia al flujo de aire y modificando los patrones respiratorios [11].
- **Condiciones de alta demanda respiratoria:** Trabajos físicamente exigentes pueden combinar las demandas respiratorias del esfuerzo físico con la necesidad de filtrar aire contaminado, lo que acelera el desgaste de los filtros.

Comprender estas variaciones en el ciclo respiratorio son fundamentales para desarrollar un algoritmo que pueda adaptarse a diferentes escenarios de uso. Los cambios en los parámetros respiratorios, como la frecuencia, el volumen tidal, la temperatura y la humedad, proporcionan información valiosa para modelar el estado de los filtros en condiciones reales. Además, simular estas condiciones a través del fantoma de pruebas asegura que el algoritmo tenga una base sólida para detectar los signos de desgaste.

2.4. Relaciones entre capacidad pulmonar y dimensiones antropométricas.

Diversos estudios han demostrado que factores antropométricos como el sexo, estatura y peso corporal están estrechamente relacionados con la capacidad respiratoria de una persona. Estos parámetros son fundamentales en el diseño de un fantoma respiratorio, ya que permiten establecer rangos fisiológicamente coherentes para simular la ventilación humana en distintos contextos.

Uno de los parámetros clave es el volumen tidal (VT), que corresponde al volumen de aire movilizado en cada ciclo respiratorio. En condiciones de reposo, el VT suele oscilar entre 7 y 8 ml por kilogramo de peso corporal ideal (PCI) [11]. En cambio, bajo condiciones de esfuerzo físico moderado a intenso, como durante ejercicio, este valor puede aumentar significativamente,

alcanzando entre 30 y 40ml/kg, dependiendo del nivel de actividad y del estado físico del individuo [9].

Es importante destacar que estas estimaciones se basan en el peso corporal ideal, ya que el peso real puede estar afectado por la cantidad de tejido adiposo, el cual no influye directamente en el tamaño de la caja torácica ni en la capacidad pulmonar, por esta razón, se utiliza el PCI como una referencia más precisa. El PCI se puede calcular a partir de la estatura utilizando las fórmulas de Devine:

- Hombre:

$$PCI = 50 + 0.91 \times (\text{altura (cm)} - 152.4) \quad (2.1)$$

- Mujer:

$$PCI = 45.5 + 0.91 \times (\text{altura (cm)} - 152.4) \quad (2.2)$$

Tabla 2-1. Rangos de frecuencia respiratoria, tiempo inspiratorio y volumen tidal según intensidad de actividad física[9][11].

Actividad	Frecuencia Respiratoria (FR)	Tiempo de Inspiración	Volumen Tidal (ml/kg)
Reposo	<12	1.5 - 2	7 - 8
Actividad ligera	12 - 18	1.2 - 1.8	10 - 15
Ejercicio moderado	20 - 25	0.8 - 1.2	30 - 40
Ejercicio intenso	30 - 40	0.6 - 1	30 - 40

Una vez estimado el peso corporal ideal es posible calcular el volumen tidal para distintos niveles de actividad, utilizando los rangos definidos en la Tabla 2-1, en mililitros por kilogramo de peso, esto permite estimar el volumen de aire movilizado por respiración. A partir de esta estimación y combinando con la frecuencia respiratoria correspondiente, se puede calcular el volumen por minuto, lo que entrega un parámetro clave para ajustar el sistema a condiciones fisiológicas realistas.

$$VM = VT \times FR \quad (2.3)$$

Esto permite recrear de forma precisa tanto la respiración en reposo como en condiciones de alta demanda ventilatoria, garantizando la representación del sistema respiratorio frente a distintos escenarios, tanto el reposo o el esfuerzo prolongado en entornos industriales.

2.5. Pruebas de Filtros de Mascarillas Industriales

Los filtros de mascarillas son elementos esenciales para garantizar la seguridad del usuario en entornos de alta contaminación. Las pruebas de estos filtros permiten evaluar su desempeño para diferentes aplicaciones. Las pruebas más relevantes son listadas a continuación:

- **Eficiencia de filtración de partículas (PFE):** Este tipo de prueba mide el porcentaje de partículas retenidas por el filtro, generalmente utilizando aerosoles estandarizados como cloruro de sodio (NaCl) o aceite de parafina. Esta prueba se usa para medir la capacidad de las mascarillas para proteger contra partículas en suspensión [12].
- **Resistencia respiratoria:** Evalúa la resistencia al flujo de aire a través del filtro. Es fundamental para garantizar que el uso prolongado de la mascarilla no cause dificultad respiratoria [13].
- **Pruebas de penetración:** Utilizada para verificar la cantidad de partículas que atraviesan el filtro bajo condiciones específicas. Estas pruebas suelen realizarse a diferentes velocidades de flujo de aire para simular distintas intensidades de respiración [14].
- **Pruebas de exposición prolongada:** Se usa para analizar el desgaste del filtro cuando se utiliza durante un período prolongado, evaluando su eficiencia y estructura bajo condiciones de uso intensivo [9].
- **Pruebas de ajuste y sello (Fit Test):** Esta prueba se realiza para asegurar que la mascarilla se ajuste adecuadamente al rostro del usuario, minimizando fugas de aire no filtrado [15].

2.6. Normativas sobre Evaluación de Mascarillas

Existen diversas normativas que establecen los requisitos mínimos que deben cumplir las mascarillas y sus filtros para garantizar la seguridad de las personas en diferentes aplicaciones, desde entornos industriales hasta el sector médico, las más relevantes son las siguientes:

- **Normativa de Estados Unidos (NIOSH):** Establece los criterios para la aprobación de dispositivos de protección respiratoria. Entre los requisitos que deben superar los respiradores se encuentran pruebas de eficiencia de filtración, resistencia respiratoria, penetración de contaminantes y durabilidad [16].

- **Normativa Europea (EN 149):** Esta normativa regula las mascarillas auto filtrantes contra partículas, clasificándolas en tres categorías según su eficiencia de filtración (FFP1, FFP2 y FFP3). Establece pruebas de fuga total, midiendo el porcentaje de aire que pasa sin filtrar debido al mal ajuste [14].
- **Normativa ISO 16900:** Regula específicamente las pruebas de desempeño de equipos de protección respiratoria, incluyendo métodos para medir la eficiencia de filtración, resistencia respiratoria y la durabilidad bajo diferentes condiciones de uso [17].

2.7. Modelos de Regresión

La regresión es una técnica fundamental del aprendizaje automático supervisado cuyo objetivo es modelar la relación entre un conjunto de variables de entrada y una variable de salida continua. En el contexto de esta tesis, la regresión se utiliza para estimar de forma continua el nivel de saturación de filtros en mascarillas industriales a partir de variables respiratorias medidas en tiempo real.

Dado que el proceso de saturación del filtro es progresivo, acumulativo y potencialmente no lineal, se evaluaron distintos modelos de regresión con capacidades crecientes para capturar relaciones complejas entre las variables de entrada y la variable objetivo. A continuación, se describen los principales modelos considerados en este trabajo.

2.7.1 Regresión Lineal

La regresión lineal es uno de los modelos más simples y ampliamente utilizados para la estimación de variables continuas. Este modelo asume una relación lineal entre las variables de entrada y la variable de salida, y puede expresarse como una combinación lineal ponderada de las características de entrada [18].

Si bien su simplicidad facilita la interpretación del modelo y reduce el riesgo de sobreajuste, la regresión lineal presenta limitaciones importantes cuando el fenómeno a modelar exhibe comportamientos no lineales o dependencias complejas entre variables. En problemas donde la variable objetivo evoluciona de manera progresiva y no proporcional, como es el caso del proceso de saturación de filtros, este tipo de modelo suele mostrar un desempeño limitado.

2.7.2 Support Vector Regression (SVR)

La regresión mediante máquinas de soporte vectorial (Support Vector Regression, SVR) extiende el concepto de support vector machine (SVM) al caso de regresión. Este enfoque busca encontrar una función que aproxime la relación entre entradas y salida manteniendo el error dentro de un margen predefinido, al mismo tiempo que maximiza la capacidad de generalización del modelo [19].

Una de las principales ventajas del SVR es su capacidad para modelar relaciones no lineales mediante el uso de funciones kernel. Sin embargo, su desempeño depende fuertemente de la correcta selección de hiperparámetros y del kernel utilizado. Además, en problemas con grandes volúmenes de datos o múltiples características, el costo computacional puede aumentar significativamente.

2.7.3 Modelos basados en árboles de decisión

Los modelos basados en árboles de decisión representan una familia de algoritmos no paramétricos capaces de modelar relaciones no lineales y capturar interacciones complejas entre variables de entrada [20]. En el contexto de regresión, estos modelos dividen recursivamente el espacio de características en regiones, asignando valores de salida basados en promedios locales.

Una ventaja clave de los árboles de decisión es su interpretabilidad y su capacidad para manejar variables con distintas escalas y distribuciones. Sin embargo, los árboles individuales suelen ser sensibles al ruido y propensos al sobreajuste, especialmente cuando se entrenan de forma aislada.

2.7.4 Métodos de ensamble: Random Forest y Gradient Boosting

Con el objetivo de mejorar la robustez y capacidad predictiva de los árboles individuales, se han desarrollado métodos de ensamble que combinan múltiples modelos base.

El algoritmo Random Forest construye un conjunto de árboles de decisión entrenados sobre subconjuntos aleatorios de los datos y de las características, promediando sus predicciones para reducir la varianza del modelo [21].

Por otro lado, los métodos de Gradient Boosting entrenan árboles de manera secuencial, donde cada nuevo modelo se enfoca en corregir los errores cometidos por los modelos anteriores. Este enfoque permite capturar patrones complejos y suele ofrecer un alto desempeño en problemas de regresión no lineales [22].

2.7.5 Extreme Gradient Boosting (XGBoost)

XGBoost es una implementación optimizada del algoritmo de Gradient Boosting que incorpora técnicas avanzadas de regularización, paralelización y control de sobreajuste. Gracias a estas características, XGBoost ha demostrado un desempeño sobresaliente en una amplia variedad de problemas de regresión y clasificación [23].

Este modelo resulta particularmente adecuado para fenómenos con dinámicas no lineales, relaciones complejas entre variables y presencia de ruido, como el proceso de saturación de filtros respiratorios. Su capacidad para manejar características heterogéneas y capturar dependencias no lineales lo convierte en una alternativa robusta para aplicaciones en tiempo real.

2.8. Métricas de Evaluación de Modelos

La evaluación del desempeño de modelos de aprendizaje automático es un aspecto fundamental para validar su capacidad predictiva, robustez y generalización. En el contexto de esta tesis, el problema se aborda desde dos perspectivas complementarias: la estimación continua del nivel de saturación del filtro (regresión) y la detección de condiciones críticas de saturación (clasificación). Por esta razón, se emplean métricas de evaluación específicas para cada tipo de problema.

2.8.1 Métricas para modelos de regresión

En el caso de la regresión, el objetivo es cuantificar la discrepancia entre el valor continuo de saturación estimado por el modelo y el valor de referencia (ground truth). Para ello, se utilizan métricas orientadas a medir el error de predicción:

Error Absoluto Medio (MAE): Mide el valor promedio de las diferencias absolutas entre las predicciones del modelo y los valores reales [24]. Esta métrica entrega una interpretación directa del error medio cometido por el modelo en la misma escala de la variable estimada.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (2.4)$$

Donde y_i corresponde al valor real de saturación, $\hat{y}_i$ a la estimación del modelo y N al número total de muestras.

Error Cuadrático Medio (MSE): Penaliza de manera más severa los errores de mayor magnitud, lo que resulta especialmente relevante en zonas críticas de operación, donde desviaciones grandes pueden tener implicancias operativas importantes[24].

$$MAE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (2.5)$$

2.8.2 Métricas para modelos de clasificación

Matriz de Confusión: Permite analizar cómo el modelo clasifica cada observación, destacando errores como falsos positivos y falsos negativos [25]. Esta representación resulta especialmente útil para analizar errores críticos en aplicaciones de seguridad.

Exactitud (Accuracy): Indica la proporción de predicciones correctas entre el total de observaciones[26].

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.6)$$

donde,

TP: Verdaderos positivos.

TN: Verdaderos negativos.

FP: Falsos positivos.

Recall (Sensibilidad): Evalúa la capacidad del modelo para identificar correctamente los casos positivos, en este contexto, condiciones de saturación del filtro:[27].

$$Recall = \frac{TP}{TP+FN} \quad (2.7)$$

Esta métrica resulta especialmente relevante en aplicaciones de seguridad industrial, donde los falsos negativos implican un riesgo mayor que los falsos positivos.

Precisión y F1-Score: La precisión mide la proporción de predicciones positivas que son correctas, mientras que el F1-score combina precisión y sensibilidad en una única métrica, permitiendo evaluar el balance entre ambas [28].

$$F1\ Score = \frac{2 \cdot Precisión \cdot Recall}{Precisión + Recall} \quad (2.8)$$

2.8.3 Curvas ROC y POD

Para complementar las métricas puntuales de clasificación, se utilizan herramientas basadas en el análisis del desempeño a lo largo de distintos umbrales de decisión.

La curva ROC (Receiver Operating Characteristic) representa la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos para distintos umbrales [29], mientras que el área bajo la curva (AUC) entrega una medida global de separabilidad entre clases.

Adicionalmente, se emplea la curva POD (Probability of Detection), ampliamente utilizada en aplicaciones de detección y confiabilidad, la cual describe la probabilidad de detección de una condición crítica en función del nivel de saturación del filtro [30]. Esta representación resulta especialmente útil para evaluar la capacidad del sistema de detectar de manera temprana condiciones cercanas al umbral operativo.

2.8.4 Estrategias de validación: Leave-One-Subject-Out (LOSO)

Con el fin de evaluar la capacidad de generalización del modelo frente a variaciones entre ensayos, se emplea un esquema de validación cruzada Leave-One-Subject-Out (LOSO). En este enfoque,

cada ensayo experimental completo se utiliza de forma iterativa como conjunto de validación, mientras que los restantes se emplean para el entrenamiento del modelo [31].

Este esquema permite evitar la mezcla de ventanas temporales provenientes de una misma prueba entre los conjuntos de entrenamiento y validación, proporcionando una evaluación más realista del desempeño del sistema frente a condiciones no vistas durante el entrenamiento.

Capítulo 3. Revisión bibliográfica

3.1. Introducción

La detección y monitoreo de condiciones respiratorias durante el uso de mascarillas industriales constituye un problema relevante en el ámbito de la seguridad y salud ocupacional, especialmente en entornos con presencia de contaminantes particulados. Tradicionalmente, la evaluación del estado de los respiradores se ha basado en criterios subjetivos, tales como la percepción de dificultad respiratoria por parte del usuario, la cual puede verse influenciada por factores individuales, fatiga o adaptación progresiva al esfuerzo respiratorio, dificultando una detección oportuna del agotamiento real del filtro.

En respuesta a estas limitaciones, diversos estudios han explorado el uso de sensores embebidos y algoritmos de procesamiento de señales para evaluar condiciones asociadas al uso de mascarillas, tales como la calidad del sello, patrones respiratorios, frecuencia respiratoria o el uso correcto del equipo de protección personal. En estos trabajos, variables como la presión, la humedad y la temperatura dentro del respirador han emergido como indicadores relevantes del comportamiento respiratorio y del entorno interno de la mascarilla.

Paralelamente, el avance de técnicas de aprendizaje automático ha permitido abordar problemas de clasificación y detección de eventos respiratorios complejos, demostrando que el análisis de señales adquiridas dentro de la mascarilla puede revelar información valiosa sobre el estado del respirador. Sin embargo, la mayoría de estos enfoques se ha centrado en la detección de eventos discretos o condiciones de uso, sin abordar de manera explícita la degradación progresiva del filtro ni su relación cuantitativa con el proceso de saturación.

En este contexto, persiste una brecha relevante en el estado del arte respecto al desarrollo de metodologías que permitan estimar de forma continua y objetiva el nivel de saturación de los filtros en mascarillas industriales, considerando la naturaleza progresiva, no lineal e irreversible de este fenómeno. Asimismo, la obtención de datos experimentales representativos constituye un desafío significativo, debido a las limitaciones éticas y prácticas asociadas a la exposición de usuarios a ambientes altamente contaminados.

La presente revisión bibliográfica analiza los principales avances relacionados con mascarillas inteligentes, monitoreo respiratorio y algoritmos de detección, identificando sus aportes y limitaciones, y estableciendo el marco conceptual que justifica el desarrollo de un sistema de estimación continua del nivel de saturación de filtros respiratorios basado en sensores, un ground truth físico y modelos de aprendizaje automático.

3.2. Mascarillas Inteligentes: Sensores Embebidos y Análisis de Señales Respiratorias

En 2018, Liu et al [32]. desarrollaron un equipo de monitoreo en tiempo real de la integridad del sello de respiradores industriales, para eso utilizaron un sensor de partículas de bajo costo. El objetivo de esta investigación fue diseñar un sistema que mediante la recolección de señales dentro de la mascarilla permitiera determinar si el sello de la mascarilla era el adecuado. Se utilizó el sensor PPD42 el cual entrega información sobre la concentración de partículas, este fue ubicado dentro de la mascarilla. Se realizaron pruebas de detección de fugas usando un fantoma de pruebas, de forma de evitar exponer a personas a entornos peligrosos, el sistema usado puede verse en Fig. 3.1.




Fig. 3.1: Maniquí de pruebas de fugas en respiradores industriales desarrollado por Liu[32], utilizado para exposición a aerosoles y simular ciclos respiratorios sin control de temperatura y humedad.

Luego se desarrolló un algoritmo para analizar los datos del sensor de partículas y determinar si existían fugas en el sello del respirador. Un ejemplo de aplicación del algoritmo puede verse en la Fig. 3.2. Este algoritmo se basa en un umbral de detección de partículas medido dentro y fuera del respirador, los resultados de las pruebas mostraron una precisión del 98.9%. Aunque el

dispositivo demostró ser efectivo, al ser un algoritmo basado en análisis de umbrales, podría verse limitado a situaciones más complejas de exposición. Sin embargo, este trabajo representa un avance significativo en la detección en tiempo real de fugas de respiradores, lo cual podría ser aplicable para estimar el nivel de saturación de filtros.




Fig. 3.2: Detección de fugas en respiradores industriales del sistema propuesto por Liu et.al [32], en celeste se visualizan las muestras indicadoras de sello, en verde las fugas de 5 segundos y en rojo las fugas de 10 segundos.

En 2020 McClure et al [33] los autores emplearon sensores portátiles y redes neuronales profundas para clasificar patrones de respiración en tiempo real, para mejorar la detección temprana de problemas respiratorios. La metodología usada consistió en la adquisición de los datos a través de los sensores portátiles. Luego, se emplearon técnicas como la transformada de Fourier y transformada Wavelet para extraer características de las señales, como cambios en la frecuencia y amplitud que distinguen diferentes patrones respiratorios. Con esta información se entrenó una red neuronal convolucional de una dimensión (1D-CNN) para clasificar eventos respiratorios como apnea central, apnea obstructiva, tos, suspiros y bostezos. Una vez entrenado, se evaluó el rendimiento del modelo obteniendo un F1-score promedio del 92% para respiración normal y 87% para apnea central, mostrando eficacia para el monitoreo continuo en aplicaciones de salud. Sin embargo, estas pruebas fueron realizadas en ambientes altamente controlados, lo que puede limitar su eficacia en entornos con variabilidad ambiental. Además, la precisión puede verse afectada por la posición de los sensores, por lo que no es aplicable para entornos en los que el sensor se mueva constantemente. Este estudio mostró nuevamente el uso de una red neuronal convolucional para

determinar condiciones en la respiración. Esto podría ser aplicable a la detección de niveles de saturación, ya que, como se ha visto en los estudios anteriores, a medida que se saturan los filtros se ven cambios en el patrón respiratorio del usuario de la mascarilla.

En 2022, Ye et al [34], desarrollaron una mascarilla inteligente y reutilizable, diseñada para el monitoreo inalámbrico de la frecuencia de tos y el correcto uso de mascarillas. Este sistema utiliza un transpondedor armónico de radiofrecuencia (RF) incorporado en mascarillas desechables, como se ve en Fig. 3.3. Este diseño resulta novedoso, ya que no necesita baterías, lo que reduce los costos operativos y mejora su sostenibilidad. Las señales obtenidas son procesadas para identificar patrones de uso, como la presencia de tos o el uso incorrecto de la mascarilla, ofreciendo un monitoreo en tiempo real.




Fig. 3.3: Implementación de mascarilla inteligente desechable para monitoreo de respiración [34].

El enfoque se centra principalmente en el monitoreo del correcto uso de la mascarilla, a través del análisis de las señales obtenidas del modelo, el cual entrega información acerca de la distancia entre la mascarilla y el rostro del usuario. Si bien no evalúa el desempeño de los filtros, desarrolla un algoritmo para detectar patrones de uso, lo cual podría ser aplicable para detectar patrones de cambios en parámetros como presión, humedad y temperatura y de esta forma conocer el desgaste de los filtros de mascarillas. Es posible observar el funcionamiento del algoritmo en Fig. 3.4. En este ejemplo de aplicación se observan diferencias claras entre respiraciones normales (destacadas en verde) y respiraciones anómalas (destacadas en rojo). Además, se observan patrones de uso correcto e incorrecto de la mascarilla. Este trabajo plantea un algoritmo de reglas, analizando otro tipo de datos, esto es importante ya que refuerza la idea de que es posible conocer características

de las mascarillas a través del análisis de diversos datos. Además, menciona como trabajo futuro la posibilidad de desarrollar un algoritmo más complejo aplicando técnicas de machine learning para identificar los diferentes estados de uso de forma precisa.




Fig. 3.4: Detección de condiciones anómalas de respiración y uso correcto de mascarilla [34].

En 2022, Suo et al [35]. desarrollaron una mascarilla inteligente equipada con sensores basados en nanocompuestos, diseñados para captar señales acústicas con alta sensibilidad. El modelo se puede observar en la Fig. 3.5. Este dispositivo fue utilizado para detectar diferentes condiciones respiratorias, como tos, respiración y habla, mediante el análisis de señales de audio, con el fin de

desarrollar una mascarilla que sea capaz de monitorear la actividad respiratoria diaria del usuario, lo cual podría ser aplicado para la detección de enfermedades respiratorias.



Fig. 3.5: Mascarilla inteligente compuesta por mascarilla comercial con sensor de ondas sonoras en estructura de esponja de nanocompuestos [29].

Se adquirieron datos de 31 sujetos utilizando la mascarilla. Inicialmente se realizó una segmentación manual de las señales para identificar distintos patrones de uso. En esta segmentación se identificaron 3 patrones claros, respiración, tos y habla. Luego se usaron diversas técnicas de procesamiento de señales como la transformada de fourier rápida (FFT) y el análisis de espectrogramas, para extraer características relevantes de las señales capturadas. De esta forma fue posible emplear técnicas de aprendizaje automático. Inicialmente utilizaron support vector machine (SVM), para evaluar la clasificación de condiciones para cada sujeto, obteniendo una precisión del 95,23%. Finalmente, aplicaron redes neuronales convolucionales (CNN), para clasificar estas actividades en forma global, obteniendo una precisión del 94,54%. Estos resultados indican que el modelo desarrollado es capaz de detectar y clasificar diferentes actividades respiratorias. En la Fig. 3.6, es posible ver la metodología que utilizaron y los resultados obtenidos.




Fig. 3.6: Procesamiento de datos y resultados obtenidos por Suo et al [29], para la detección de diversas condiciones de respiración como tos, respiración normal y habla.

Si bien el tema de investigación desarrollado en este paper presenta un enfoque distinto al de esta investigación, la metodología utilizada en este trabajo permite identificar patrones complejos en señales, lo que podría ser aplicable a señales de temperatura, presión y humedad para determinar las condiciones de saturación en los filtros de mascarillas. Este trabajo plantea el uso de Machine Learning para evaluar condiciones de la respiración, si bien no evalúa condiciones de desgaste de las mascarillas, nombra la adquisición de datos dentro de una y que es posible detectar condiciones anómalas con estos datos.

Un estudio realizado en 2022 por Ratnayake et.al [36], se enfocó en desarrollar una mascarilla inteligente equipada con sensores IoT para determinar la vida útil de las mascarillas. Utilizaron sensores de humedad y temperatura para recopilar datos sobre el uso de las mascarillas y analizar

factores como el tiempo de uso, la humedad interna y externa, la presión de aire y la temperatura. En la Fig. 3.7 se puede observar la implementación del modelo .




Fig. 3.7: Mascarilla desechable equipada con sensor de temperatura y humedad, para la estimación de vida útil [30].

Los datos obtenidos fueron procesados para determinar patrones de deterioro de los filtros. A través de este análisis se planteo la ecuación 3.1:

$$AL = \{100 - ((T * TW) + (Ehum * EhumW) + (Ihum * IhumW) + (Temp * TempW) + (Air * AirW))\} \quad (3.1)$$

donde,

AL: tiempo de vida útil.

T: Tiempo de uso.

Ehum: Humedad externa.

Ihum: Humedad interna.

Temp: Temperatura.

Air: Presión de aire.

W: Peso

Esta fórmula entrega un porcentaje de la vida útil restante de la mascarilla. Se basa en pesos asignados a cada variable, los cuales pueden ser ajustados según las condiciones de uso. Este

trabajo no solo permitió identificar el estado actual de la mascarilla, sino que también proporcionó una base para desarrollar mascarillas que alerten a los usuarios la necesidad de reemplazo. Sin embargo, una limitación destacada de este estudio fue la dependencia de la humedad como principal indicador, lo que podría no ser fiable en todas las condiciones ambientales o para diferentes tipos de mascarillas, afectando la precisión del sistema en ciertos escenarios. Este trabajo es de interés, ya que plantea por primera vez el análisis de los filtros a través de señales obtenidas con sensores dentro de una mascarilla.

A fines de 2022, Aqueveque et al [37]. desarrollaron un dispositivo electrónico pensado para ser ubicado dentro de los respiradores industriales con el fin de monitorear la actividad respiratoria en tiempo real. El dispositivo mide presión, temperatura y humedad dentro del respirador y envía los datos de forma inalámbrica a un dispositivo externo para su procesamiento y análisis. A partir de estos datos fue posible estimar frecuencia respiratoria, condición de ajuste del respirador y nivel de obstrucción del filtro. Se realizaron pruebas de laboratorio con 10 participantes sanos para poner a prueba el dispositivo. Los resultados mostraron que es posible discriminar entre una condición de ajuste del respirador bien ajustado y suelto utilizando las señales de presión y humedad. Además, se realizaron pruebas de saturación de filtros, simulando diferentes niveles de saturación, obstruyendo la mascarillas con piezas 3D de diferente tamaño, como se puede ver en Fig. 3.8. Con las señales obtenidas se realizó un análisis de varianza (ANOVA), el cual permitió identificar tres niveles de obstrucción, tan solo con el análisis de la presión.



Fig. 3.8: Obstrucción de respiradores industriales utilizando piezas plásticas de diferentes tamaño [31].

Entre las principales limitaciones de este trabajo se tiene que contaban con un número limitado de participantes en las pruebas. Además la simulación de obstrucción de filtros se aleja de la saturación progresiva que ocurre en la realidad. Como trabajo futuro destacan el desarrollo de modelos de aprendizaje automático para predecir los niveles de obstrucción de filtros. En este trabajo a diferencia de lo visto en los años anteriores, lograron identificar 3 estados de saturación tan solo a través de análisis estadístico. Esto indica que sería posible caracterizar mejor estos niveles de saturación a través de un algoritmo más complejo.

En 2023, Manchanda et al [38]. desarrollaron un mecanismo diseñado para mantener un ajuste óptimo de mascarillas mediante el uso de sensores integrados. Este sistema, utiliza sensores de temperatura, presión y luz para evaluar continuamente la calidad del ajuste de la mascarilla y realizar ajustes automáticos en las correas cuando se detectan desviaciones. Este enfoque se basa en un algoritmo de reglas que opera mediante el monitoreo de las lecturas de los sensores y la comparación con umbrales. Este enfoque presenta un avance importante, ya que destaca la viabilidad de combinar sensores y algoritmos simples para mejorar el funcionamiento de equipos de protección personal. Sin embargo, el modelo tiene un costo elevado y al usar un algoritmo de reglas no es capaz de aprender ni ajustarse dinámicamente a variaciones significativas en el entorno o en los usuarios, lo que limita su eficacia en situaciones más complejas. Este trabajo es relevante, ya que, plantea un algoritmo basado en umbrales proporcionando una metodología inicial que podría ser útil para el análisis de los filtros de mascarillas. Un enfoque similar podría ser incorporado al desarrollo de un algoritmo para evaluar el estado de los filtros de mascarillas.

En 2023 Cheraghi et al, desarrollaron una mascarilla inteligente basada en grafeno, diseñada para monitorear la respiración humana en tiempo real mediante sensores piezoresistivos integrados. La investigación incluyó la fabricación de líneas de grafeno depositadas sobre mascarillas quirúrgicas comerciales, capaces de detectar cambios en la resistencia eléctrica provocados por los movimientos respiratorios. Los datos recogidos se transmiten a una aplicación móvil, permitiendo la detección inmediata de condiciones anómalas, como tos o dificultad para respirar. Si bien este trabajo no analiza los filtros de las mascarillas, es relevante para esta investigación, ya que, se desarrolló un algoritmo para detectar condiciones anómalas como tos o disnea, utilizando técnicas de procesamiento de señales que podrían ser útiles para detectar la saturación de los filtros en

maskas industriales [39]. Este trabajo es similar al desarrollado por Suo et al. en 2022 [35], los que en este caso no utilizan técnicas de aprendizaje automático para detectar patrones. Sin embargo, desarrollando un algoritmo de reglas fue posible identificar condiciones anómalas en la respiración. Esto refuerza la posibilidad de uso de un algoritmo de reglas, destacando su aplicabilidad a bases de datos pequeñas.

En 2023, Romano et al. [40], presentaron una mascarilla inteligente diseñada para monitorear la frecuencia respiratoria durante el ejercicio en bicicleta. Esta mascarilla incorpora sensores de temperatura que registran cambios en el flujo de aire, permitiendo estimar la frecuencia respiratoria. Para generar datos realizaron un modelo de pruebas compuesto por un ventilador mecánico, un humidificador y un simulador pulmonar que imitaba las vías respiratorias humanas. Este modelo permitió generar señales variando rangos de frecuencias respiratorias típicas, desde reposo hasta esfuerzo. Su diseño se puede observar en Fig. 3.9.




Fig. 3.9: Modelo de pruebas desarrollado por Romano et al [22], este modelo replica la respiración en términos de temperatura, humedad y flujo respiratorio utilizando un ventilador mecánico, humidificador de paso y pulmón de prueba.

Una vez desarrollado el levantamiento de datos, se desarrolló un algoritmo basado en detección de peaks para identificar eventos respiratorios, logrando buenos resultados principalmente en la estimación de la frecuencia respiratoria. Este modelo es de gran interés, ya que plantea el uso de un set up de pruebas para generar datos y su previo análisis a través de un análisis de la señal para detectar distintos eventos respiratorios obteniendo buenos resultados. Si bien este trabajo no se centra en el análisis del estado de la mascarilla, plantea una metodología interesante en la obtención

de datos, diferente a los trabajos mencionados anteriormente. Por otro lado, se menciona nuevamente que es posible definir parámetros para identificar condiciones respiratorias.

Finalmente, en 2024 Ponce et al. [41], desarrollaron un dispositivo electrónico pensado para ser ubicado dentro de respiradores industriales, con el fin de evaluar el ajuste correcto del respirador. El dispositivo se basa en la medición de la presión absoluta dentro de la mascarilla. Se basa en el fundamento de que cuando una mascarilla está correctamente ajustada, la presión en su interior aumenta con respecto a la presión externa. Para detectar los estados de suelto y ajustado, se analizaron las señales de presión en busca de patrones. En este trabajo solo realizaron un análisis visual de las señales, como se puede ver en la Fig. 3.10, declarando que fue posible identificar diferencias entre estados. En el caso de señales de temperatura y humedad, no fue posible ver un patrón claro, pero dejan como trabajo futuro el desarrollo de un algoritmo que detecte patrones tras el análisis de tres parámetros (temperatura, presión y humedad).




Fig. 3.10: Señales de presión, temperatura y humedad obtenidas por mascarilla inteligente desarrollada por Ponce et al [23], para uso correcto e incorrecto del respirador.

Si bien en este trabajo simplemente realizaron un análisis visual de las señales, sus resultados destacan la importancia del parámetro de presión para el análisis de estados de mascarillas. Según lo visto en trabajos anteriores, sería posible implementar un algoritmo para que el sistema propuesto sea capaz de detectar condiciones de forma autónoma.

En conjunto, los trabajos revisados demuestran que la adquisición de señales dentro de la mascarilla permite caracterizar múltiples aspectos del uso del respirador, incluyendo patrones respiratorios, calidad del sello y condiciones de uso anómalo. Sin embargo, la mayoría de los enfoques se centra en la detección de eventos discretos o estados categóricos, utilizando algoritmos de reglas o clasificadores entrenados para tareas específicas.

A pesar de que varios estudios reconocen implícitamente el rol de la presión como variable sensible a cambios en el estado del respirador, ninguno aborda de forma sistemática la estimación continua del desgaste progresivo del filtro ni su relación cuantitativa con un ground truth físico del proceso de saturación. Esta limitación motiva la necesidad de un enfoque que integre sensores embebidos, criterios físicos objetivos y modelos capaces de capturar dinámicas no lineales.

3.3. Evaluación del Desempeño y Desgaste de Filtros Respiratorios

La evaluación del desempeño de filtros respiratorios ha sido tradicionalmente abordada desde un enfoque normativo y experimental, centrado principalmente en la eficiencia de filtración y la resistencia al flujo bajo condiciones controladas de laboratorio. Organismos como la National Institute for Occupational Safety and Health (NIOSH) establecen criterios de certificación basados en la capacidad del filtro para retener partículas de un tamaño específico y en la caída de presión asociada al flujo de aire [42]. Si bien estos parámetros son fundamentales para garantizar la seguridad inicial del respirador, no consideran mecanismos de monitoreo continuo que permitan evaluar el desgaste progresivo del filtro durante su uso real.

La evaluación del desempeño de los filtros respiratorios ha evolucionado desde pruebas de laboratorio hacia la búsqueda de sistemas de monitoreo en tiempo real. Para el desarrollo de un algoritmo de detección de saturación, es esencial comprender los mecanismos físicos y químicos que rigen el desgaste de estos dispositivos.

En 1999 Hinds [43], establece que la acumulación de partículas en las fibras del filtro altera drásticamente su comportamiento hidrodinámico. Según Hinds, la caída de presión es el indicador principal del nivel de carga de un filtro de partículas. A medida que los intersticios de la estructura porosa se llenan, se genera una "torta de filtración" que aumenta la resistencia al paso del aire. Matemáticamente, esta relación permite inferir el estado de obstrucción del filtro a través de señales de presión diferencial. En 2021 Xia et al. (2021) evidenciaron que el desgaste del filtro no es un proceso lineal uniforme. Existen fluctuaciones en la presión vinculadas a la tasa de inhalación, la frecuencia respiratoria del usuario y la carga súbita de partículas [44].

Sin embargo, la eficiencia no siempre es constante. En el año 2000, Moyer y Bergman advierten que, en filtros con medios electrostáticos, ciertos contaminantes pueden neutralizar las cargas de las fibras, provocando una caída en la eficiencia de filtrado antes de que se observe un aumento perceptible por la persona en la variable de presión. Este hallazgo justifica la necesidad de algoritmos que no solo lean datos aislados, sino que interpreten la tasa de cambio en la señal para predecir el agotamiento de manera robusta.

Respecto a la variable de humedad, estudios fundacionales como los de Nelson y Harder [45], que demostraron que humedades relativas superiores al 50% reducen drásticamente la capacidad de los filtros químicos, ya que el vapor de agua compite con los gases por los sitios activos del carbón. En el caso de los filtros de partículas, la humedad también afecta la señal de presión al inducir el crecimiento higroscópico de las partículas capturadas, acelerando el taponamiento. Por tanto, como proponen revisiones modernas como las de Sen et al. sobre indicadores de fin de vida útil (ESLI), un sistema de detección preciso debe integrar sensores ambientales para compensar estas variaciones y evitar falsos positivos en la estimación de la saturación [46], la compensación por humedad es crítica para evitar errores de lectura, pero no requiere de un análisis de alta frecuencia o múltiples derivados, ya que la humedad no varía con la cadencia respiratoria del trabajador, sino con el entorno macroscópico.

Investigaciones como las de Gupta et al. sobre el efecto de la humedad en la caída de presión en filtros de fibra de vidrio, demuestran que, si bien la humedad relativa influye en la resistencia al flujo, su comportamiento es de carácter global y de evolución lenta. La humedad altera la

estructura del aerosol (crecimiento higroscópico) y la morfología de la torta de filtración, pero actúa como un factor de sesgo o de escala sobre la señal principal [47].

Por el contrario, la presión diferencial es una señal rica en información dinámica, estas fluctuaciones vinculadas tanto al usuario como a la carga del filtro, refuerzan la necesidad de emplear modelos capaces de capturar relaciones y dependencias temporales, más allá de enfoques basados en umbrales fijos o análisis estáticos.

3.4. Discusión

El análisis bibliográfico evidencia un interés creciente en el desarrollo de mascarillas inteligentes y sistemas de monitoreo respiratorio, impulsado principalmente por la necesidad de mejorar la seguridad, el confort y la eficiencia del uso de equipos de protección personal en entornos contaminados. En este contexto, numerosos estudios han demostrado que la adquisición de señales fisiológicas y ambientales desde el interior de la mascarilla permite caracterizar distintos aspectos del uso del respirador, tales como la calidad del sello, patrones respiratorios, frecuencia respiratoria, eventos anómalos y condiciones de uso incorrecto.

Sin embargo, la mayoría de los trabajos revisados aborda el problema desde una perspectiva discreta, centrándose en la detección de eventos puntuales (fugas, tos, apnea, uso incorrecto) o en la clasificación de estados bien definidos mediante algoritmos de reglas o modelos supervisados. Si bien estos enfoques han demostrado altos niveles de precisión en escenarios controlados, presentan limitaciones importantes cuando se trata de caracterizar fenómenos progresivos, continuos e irreversibles, como el desgaste y la saturación de los filtros respiratorios.

Desde el punto de vista de las variables analizadas, la literatura converge en identificar la presión diferencial como un indicador particularmente sensible a cambios en el estado del respirador. Diversos estudios muestran que la presión permite discriminar condiciones de ajuste, obstrucción parcial y aumento del esfuerzo respiratorio, incluso mediante análisis estadísticos simples. En contraste, la humedad y la temperatura han sido utilizadas principalmente como variables auxiliares o ambientales, mostrando una relación menos directa y menos discriminante cuando se consideran de forma aislada. Estos antecedentes son coherentes con la interpretación física del

proceso de filtración, donde el aumento de la resistencia al flujo constituye una manifestación directa del deterioro del medio filtrante.

No obstante, pese a reconocer la relevancia de la presión, los trabajos existentes tienden a evaluar el desempeño del respirador mediante simulaciones simplificadas, obstrucciones artificiales o análisis visual de señales, sin establecer una relación cuantitativa clara entre las variables medidas y un ground truth físico del proceso de saturación. En particular, no se identifican metodologías orientadas a definir una referencia objetiva del nivel de desgaste del filtro, lo que limita la capacidad de entrenar y validar modelos predictivos robustos.

Otro aspecto relevante identificado en la revisión bibliográfica es la limitada disponibilidad de datos experimentales obtenidos bajo condiciones controladas y reproducibles. La mayoría de los estudios depende de ensayos con un número reducido de participantes o de pruebas de corta duración, lo que restringe la exploración de escenarios exigentes o extremos. En este sentido, el uso de fantasmas respiratorios aparece como una estrategia poco explorada pero prometedora, ya que permite generar datos prolongados, reproducibles y éticamente viables, imposibles de obtener mediante pruebas directas en personas.

Finalmente, aunque algunos trabajos recientes incorporan técnicas de aprendizaje automático para analizar señales respiratorias, estas se aplican principalmente a tareas de clasificación de eventos o estados discretos. Existe una brecha clara en el uso de modelos orientados a la estimación continua del estado del filtro, capaces de capturar la naturaleza no lineal y acumulativa del proceso de saturación, y de operar en tiempo real bajo condiciones variables de uso.

Capítulo 4. Metodología

La metodología de esta investigación se estructura en varias fases, las cuales comprenden desde la adquisición de datos mediante un fantoma de pruebas, hasta el desarrollo y validación de un algoritmo de detección de saturación de filtros en mascarillas industriales. En la Fig. 4.1 se puede observar un esquema de la metodología. En este capítulo se describen los pasos de manera detallada.



Fig. 4.1: Esquema simplificado de la metodología general.

4.1. Levantamiento de Datos Experimentales

La primera etapa consiste en la recolección de los datos utilizando un fantoma de pruebas en conjunto con una cámara de contaminación, sistema utilizado en estudios previos para evaluar mascarillas [32], [48], [49]. Este sistema busca reproducir de manera realista y controlada condiciones de respiración humana durante el uso de respiradores industriales, así como escenarios de exposición progresiva a material particulado, permitiendo generar señales fisiológicas representativas del proceso de saturación de filtros.

El sistema está compuesto por un fantoma respiratorio programable acoplado a una cámara de contaminación cerrada (véase Fig. 4.2), en la cual se expone una mascarilla industrial a partículas de polvo en suspensión. El fantoma permite controlar parámetros respiratorios relevantes, tales como la frecuencia respiratoria y el volumen tidal, mientras que la cámara de pruebas posibilita la acumulación progresiva de polvo en el filtro bajo distintas condiciones de uso.




Fig. 4.2: Esquema de fantoma y cámara de pruebas propuesto, el cual está compuesto por un ventilador mecánico, humidificador y cámara de pruebas.

Durante los ensayos, se registraron de forma continua señales de presión, temperatura y humedad a una frecuencia de muestreo de 10 Hz al interior de la mascarilla haciendo uso del sensor embebido desarrollado por Aqueveque et al [37] (véase Fig. 4.3). Estas señales reflejan los cambios inducidos por el aumento de la resistencia al flujo a medida que el filtro se satura. De esta forma los datos obtenidos constituyen la base para la definición del estado de saturación del filtro y el desarrollo del algoritmo propuesto en este trabajo.



Fig. 4.3: Vista del sensor respiratorio desarrollado por Aqueveque [31], ubicado en un respirador industrial. Este dispositivo fue utilizado para registrar en tiempo real variables fisiológicas como presión, temperatura y humedad durante las pruebas.

4.2. Definición del Estado de Saturación del Filtro (Ground Truth)

En esta etapa de desarrollo se definió una referencia cuantitativa (ground truth) que permitiera asociar las señales respiratorias adquiridas con un estado físico representativo del nivel de saturación del filtro. Durante el desarrollo de las pruebas con el fantoma se observó que los filtros aumentaban su masa de forma consistente a lo largo del tiempo de exposición, es por esto que se implementó un procedimiento de calibración basado en mediciones de peso de los filtros bajo condiciones controladas, con el objetivo de caracterizar el comportamiento de la saturación en función del tiempo.

El procedimiento consistió en exponer filtros nuevos a ambientes contaminados, manteniendo condiciones estables de respiración mediante el uso del fantoma de pruebas. Durante este proceso, los filtros fueron retirados cada 24 horas y pesados utilizando una balanza, de esta forma se obtuvieron curvas de masa en función del tiempo de exposición.

Estas curvas fueron utilizadas como referencia del proceso progresivo de saturación del filtro, permitiendo caracterizar de manera objetiva la evolución de su estado desde un 0%, correspondiente a un filtro nuevo, hasta un 100%, que representa la condición de carga máxima alcanzada durante las pruebas experimentales. Con el fin de obtener una referencia representativa

del comportamiento observado, se realizaron dos pruebas experimentales independientes, a partir de las cuales se construyó una curva promedio utilizada como modelo de referencia del proceso de saturación.

Para expresar el estado del filtro en una escala continua e interpretable, la curva de referencia fue normalizada entre sus valores mínimo y máximo, definiendo una escala de saturación entre 0% y 100%. Esta función normalizada permitió asignar un valor continuo de saturación a cualquier instante dentro del proceso de carga, y fue utilizada para asociar cada segmento de señal respiratoria con un nivel de saturación estimado. Dicho valor constituye la variable objetivo empleada para el entrenamiento y evaluación del algoritmo de detección de saturación.

A partir del análisis de las curvas de masa acumulada y de la evolución de las señales respiratorias, se definió un umbral operativo de saturación asociado a un aumento de masa aproximado de 1.3 g en el filtro. Este valor fue seleccionado considerando dos criterios complementarios: por una parte, se observó que en este rango el diferencial de presión, tras un incremento inicial significativo, tiende a estabilizarse, lo cual es indicativo de un aumento relevante de la resistencia al flujo; por otra parte, la acumulación de material particulado en este nivel implica un riesgo operativo asociado a la obstrucción del filtro.

Si bien el 100% de saturación fue definido como el punto en el cual el filtro alcanza una carga de aproximadamente 1.3 g de material particulado, se observó que alrededor del 85% de saturación el diferencial de presión aumenta hasta valores del orden de 60 a 80 Pa (6–7,6 mmH₂O). Estos valores se encuentran reportados en la literatura como umbrales a partir de los cuales se comienza a percibir dificultad o resistencia para respirar. En concordancia con ello, y considerando que las recomendaciones del fabricante establecen que el filtro debe ser reemplazado cuando el usuario percibe dificultad respiratoria, este punto fue definido como el inicio de la condición de saturación crítica.

Finalmente, para cada una de las pruebas realizadas, el tiempo total de exposición del filtro fue mapeado sobre la curva de referencia normalizada, permitiendo asignar un valor de saturación a cada instante de las muestras adquiridas. Este procedimiento permitió generar etiquetas de saturación consistentes y reproducibles para todo el conjunto de datos, garantizando que la variable

objetivo utilizada en el desarrollo del algoritmo represente un estado físico del filtro independiente de las señales empleadas como entrada al modelo.

4.3. Preprocesamiento de los Datos

Las señales adquiridas durante los ensayos experimentales fueron sometidas a un proceso de preprocesamiento con el objetivo de asegurar su calidad y consistencia para el posterior análisis y desarrollo del algoritmo de detección de saturación. Este proceso permitió eliminar segmentos no representativos, establecer una referencia basal y organizar temporalmente los datos de forma estructurada.

En primer lugar, se realizó una inspección de las señales de presión, temperatura y humedad con el fin de identificar intervalos correspondientes a condiciones no válidas de operación, tales como pausas del sistema, transitorios asociados al inicio o término de las pruebas, o intervenciones manuales durante los ensayos. Estos segmentos fueron excluidos del análisis para evitar la introducción de artefactos que pudieran afectar la estimación de características relevantes.

Posteriormente, se estableció una referencia basal para cada señal utilizando los primeros instantes de cada ensayo, correspondientes a la fase inicial con el filtro en condición limpia. A partir de esta referencia, las señales fueron expresadas en términos relativos respecto de su valor basal, permitiendo compensar variaciones entre pruebas asociadas a diferencias iniciales en las condiciones ambientales o en la configuración del sistema experimental.

Con el fin de capturar adecuadamente la dinámica respiratoria y reducir la influencia de ruido de alta frecuencia, las señales fueron segmentadas temporalmente en ventanas de duración fija, sobre las cuales se realizó el análisis posterior. Este esquema de segmentación permitió preservar la evolución temporal del proceso de saturación del filtro, al mismo tiempo facilitó la extracción de características estadísticas y dinámicas a partir de cada segmento. Cada uno de los pasos descritos anteriormente se puede observar en Fig. 4.4.




Fig. 4.4: Etapas del preprocesamiento de la señal respiratoria de presión. (a) Identificación y exclusión de segmentos inválidos asociados a ausencia de actividad respiratoria. (b) Establecimiento baseline correspondiente a un filtro limpio. (c) Segmentación temporal de la señal normalizada mediante ventanas deslizantes de longitud fija.

Finalmente, las señales preprocesadas fueron sincronizadas con los valores de saturación definidos en la etapa de ground truth, de modo que cada ventana temporal quedara asociada a un nivel de saturación específico. El conjunto resultante de señales preprocesadas y etiquetadas constituyó la base de datos utilizada para la extracción de características y el entrenamiento del algoritmo de detección de saturación.

4.4. Análisis de Datos

Previamente a la extracción de características y al desarrollo del algoritmo de detección de saturación, se realizó un análisis exploratorio de las señales adquiridas con el objetivo de identificar indicadores asociados al proceso de saturación del filtro y orientar la selección de características utilizadas posteriormente.

Este análisis se llevó a cabo sobre las señales de presión, temperatura y humedad, calculando métricas estadísticas clásicas para cada ventana temporal, tales como valor medio, valor pico a pico, root mean square (RMS), desviación estándar, entre otras. Estas métricas permitieron caracterizar el comportamiento general de cada variable y evaluar su variabilidad a lo largo del proceso de saturación.

Adicionalmente, se analizaron las relaciones entre cada una de las variables y el nivel de saturación definido en el ground truth, mediante el cálculo de coeficientes de correlación. Este análisis permitió evaluar la sensibilidad de cada señal frente al aumento progresivo de la carga particulada en el filtro.

Este análisis tuvo un carácter metodológico y exploratorio, y su objetivo fue fundamentar las decisiones adoptadas en las etapas posteriores del desarrollo del algoritmo.

4.5. Extracción de Características

Una vez preprocesadas las señales respiratorias, se procedió a la extracción de características con el objetivo de obtener indicadores cuantitativos capaces de representar la evolución del estado del filtro a partir de las mediciones disponibles. Esta etapa es fundamental, ya que las características extraídas constituyen las variables de entrada utilizadas por el algoritmo de detección de saturación.

La extracción de características se realizó sobre cada una de las ventanas temporales definidas en la etapa de preprocesamiento. Para cada ventana, se calcularon métricas derivadas principalmente de las señales de presión y humedad relativa, las cuales mostraron una mayor sensibilidad frente a la acumulación progresiva de material particulado en el filtro.

En particular, a partir de la señal de presión se calcularon características asociadas a la amplitud y comportamiento dinámico de la respiración, tales como el valor pico a pico del diferencial de presión y el valor medio dentro de cada ventana. Estas métricas permiten capturar el aumento gradual de la resistencia al flujo respiratorio a medida que el filtro se aproxima a condiciones de saturación.

Adicionalmente, se calcularon características estadísticas básicas de la señal de humedad relativa, incluyendo su valor medio, con el fin de incorporar información asociada a la acumulación de aire exhalado y a las condiciones del microclima interno de la mascarilla, las cuales pueden verse afectadas por la degradación del filtro. Si bien la humedad mostró una tendencia creciente durante las pruebas realizadas con el fantoma respiratorio, su comportamiento presentó una mayor variabilidad y menor estabilidad en escenarios reales, particularmente en pruebas realizadas con personas en el marco del proyecto FONDEF ID24i10487 en el cual se encuentra este trabajo.

En dichas condiciones, la señal de humedad tiende a saturarse y a exhibir comportamientos no estacionarios, lo que reduce su sensibilidad como indicador continuo del estado del filtro y aumenta el riesgo de sobreajuste cuando se incorporan múltiples métricas derivadas de esta variable. Considerando estas limitaciones, así como la necesidad de garantizar un desempeño robusto en la implementación en tiempo real, se optó por restringir el uso de la señal de humedad a una única característica representativa.

Si bien la señal de temperatura fue registrada durante los ensayos experimentales, esta no fue incorporada en el conjunto final de características. Esto se debe a que, bajo las condiciones experimentales altamente controladas, la temperatura se mantuvo estable y se observó una alta correlación con la humedad relativa, aportando información redundante que no contribuyó significativamente a la discriminación del estado de saturación.

Con el propósito de reducir la influencia de la variabilidad entre sujetos y enfocarse en los cambios inducidos exclusivamente por la saturación del filtro, se obtuvieron características expresadas de forma relativa respecto a una referencia basal obtenida al inicio de cada ensayo, correspondiente a la condición de respiración en reposo con un filtro nuevo. Este enfoque permite que el análisis se

centre en las desviaciones respecto de la condición basal del propio sujeto, más que en los valores absolutos de las señales.

El uso de características relativas resulta particularmente relevante considerando que las señales respiratorias están influenciadas por variaciones en el patrón respiratorio asociadas a diferencias en frecuencia respiratoria y nivel de actividad física. En este contexto, el fantoma respiratorio permitió simular de forma controlada distintos patrones ventilatorios representativos de personas con diferentes condiciones fisiológicas, introduciendo variabilidad respiratoria en el conjunto de datos.

Al utilizar una ventana basal como referencia, el algoritmo es capaz de adaptarse al comportamiento respiratorio inicial bajo cada condición simulada, facilitando la generalización del modelo a sujetos no vistos y reduciendo la dependencia de calibraciones específicas. De este modo, el uso de características relativas permite identificar cambios progresivos asociados a la degradación del filtro de manera robusta, independientemente del nivel basal de las señales.

Además de las características instantáneas calculadas en cada ventana, se incorporaron características temporales calculadas a partir de la dinámica local de las señales dentro de cada ventana temporal. Estas características incluyen medidas de variabilidad y tendencias suavizadas, las cuales permiten capturar cambios progresivos en el comportamiento respiratorio sin requerir acceso al historial completo de las señales desde el inicio del uso del filtro.

El análisis temporal se realiza sobre ventanas deslizantes de duración fija, actualizadas de forma periódica, de modo que cada estimación del estado de saturación se basa únicamente en información reciente. Este enfoque permite representar la naturaleza progresiva e irreversible del proceso de saturación, manteniendo al mismo tiempo un esquema de procesamiento compatible con la operación en tiempo real y sin dependencia de memoria a largo plazo.

El conjunto final de características resultante de este proceso fue organizado en vectores de características asociados a cada ventana temporal y etiquetados con el nivel de saturación correspondiente. Dichos vectores constituyen la base de datos utilizada en la etapa posterior de desarrollo y entrenamiento del algoritmo de detección de saturación.

4.6. Desarrollo del Algoritmo de Detección de Saturación

El desarrollo del algoritmo de detección de saturación tuvo como objetivo estimar de manera continua el estado del filtro a partir de las características extraídas de las señales respiratorias. Dado que el proceso de saturación del filtro es progresivo y acumulativo, el problema fue formulado como una regresión supervisada, en la cual cada vector de características es asociado a un valor continuo de saturación expresado en porcentaje.

Con el fin de identificar la estrategia de aprendizaje más adecuada para el problema planteado, se evaluaron distintos modelos de regresión con capacidades crecientes de modelamiento no lineal. Entre los modelos considerados se incluyeron enfoques lineales y no lineales, tales como regresión lineal, support vector regressor, random forest, gradient boosting y xgboost regressor. La comparación de desempeño entre los distintos modelos se realizó posteriormente mediante métricas cuantitativas, descritas en la etapa de validación experimental.

Para cada uno de los modelos evaluados, se realizó un proceso de ajuste de hiperparámetros mediante Grid Search, con el objetivo de identificar la configuración óptima de cada algoritmo. Este procedimiento permitió explorar de forma exhaustiva combinaciones relevantes de hiperparámetros, utilizando validación cruzada independiente por ensayo, asegurando una selección robusta y evitando sesgos derivados de configuraciones arbitrarias.

El entrenamiento de los modelos se realizó utilizando el conjunto de datos etiquetado obtenido a partir de las etapas previas. Con el fin de priorizar la correcta estimación del estado del filtro en condiciones cercanas a la saturación (las cuales son más relevantes desde el punto de vista de seguridad) se incorporó una ponderación de muestras durante el entrenamiento, de esta forma las observaciones correspondientes a niveles de saturación elevados recibieron un mayor peso relativo, incentivando al modelo a reducir el error en esta región crítica.

Asimismo, se realizó una validación independiente por ensayo, de manera de evaluar la capacidad de generalización del algoritmo frente a condiciones no vistas durante el entrenamiento. Esta estrategia permitió reducir el riesgo de sobreajuste y obtener una estimación más realista del desempeño del modelo en la realidad.

Dado que la saturación del filtro es un proceso inherentemente irreversible, se incorporaron mecanismos adicionales para garantizar la coherencia temporal de las estimaciones generadas por el algoritmo. En particular, las predicciones obtenidas fueron sometidas a un proceso de suavizado temporal con el fin de reducir fluctuaciones suaves entre ventanas consecutivas producidas por la variabilidad del proceso respiratorio.

Adicionalmente, se implementó una restricción de monotonidad en la evolución temporal de la saturación estimada, impidiendo decrementos no físicos en el valor predicho. A diferencia del suavizado temporal, esta restricción impone una condición basada en la naturaleza acumulativa del fenómeno, asegurando que la saturación estimada no disminuya a lo largo del tiempo y refleje adecuadamente el carácter irreversible del proceso.

Si bien el algoritmo fue formulado y entrenado como un modelo de regresión continua, su aplicación práctica requiere la identificación de estados operativos que permitan tomar decisiones de mantenimiento y reemplazo del filtro. Para esto, se definió un umbral funcional de saturación que permite discriminar entre estado normal y saturado.

El umbral fue definido a partir del análisis conjunto del ground truth y del comportamiento de las señales respiratorias. En particular, durante pruebas realizadas en condiciones de respiración en reposo, se observó que alrededor del 85% de saturación normalizada se produce un incremento marcado del diferencial de presión, alcanzando valores del orden de 60 a 80 Pa (6–7,6 mmH₂O). Este rango ha sido reportado en la literatura como un umbral fisiológico asociado a la percepción de dificultad respiratoria [50]. Este comportamiento no se manifiesta de forma consistente bajo condiciones de mayor actividad física o patrones respiratorios forzados, por esta razón no se utiliza este umbral de presión como un criterio directo de decisión, sino como una referencia funcional para interpretar estimaciones continuas de saturación generadas por el algoritmo.

Adicionalmente, las recomendaciones de los fabricantes de filtros industriales establecen que el reemplazo del filtro debe realizarse cuando el usuario comienza a percibir molestias o dificultades para respirar [51]. En concordancia con estos criterios, el nivel de saturación correspondiente al 85% fue adoptado como umbral funcional para definir el inicio de la condición de saturación.

A partir de este umbral, las estimaciones continuas de saturación generadas por el modelo de regresión fueron discretizadas en dos estados operativos: Normal, correspondiente a niveles de saturación inferiores al 85%, y Saturado, correspondiente a niveles iguales o superiores a dicho umbral. Esta discretización permitió evaluar el desempeño del sistema como una clasificación binaria, complementando la evaluación basada en métricas de regresión y facilitando su interpretación en un contexto de seguridad ocupacional.

4.7. Validación Experimental

La validación experimental del algoritmo de detección de saturación tuvo como objetivo evaluar su desempeño cuantitativo y su capacidad de generalización utilizando datos independientes a aquellos empleados durante el entrenamiento. Esta etapa permitió analizar el comportamiento del modelo como estimador del estado del filtro, previo a su implementación en tiempo real.

Para la evaluación del algoritmo se utilizó un esquema de validación Leave One Subject Out (LOSO), en el cual cada sujeto corresponde a una muestra completa de saturación del filtro obtenido mediante el fantoma respiratorio. Bajo este método, en cada iteración el modelo fue entrenado utilizando los datos de todos los ensayos excepto uno, el cual fue reservado exclusivamente para validación.

Este procedimiento se repitió de forma iterativa hasta que cada ensayo experimental fue utilizado una vez como conjunto de validación. El uso de validación LOSO permite evaluar la capacidad de generalización del algoritmo frente a variaciones entre ensayos, tales como diferencias en las condiciones iniciales, patrones respiratorios o dinámica de saturación del filtro, evitando además la mezcla de ventanas temporales provenientes de una misma prueba entre los conjuntos de entrenamiento y validación.

Para evaluar el rendimiento del algoritmo de regresión supervisado, se utilizaron métricas orientadas a cuantificar el error en la estimación continua del nivel de saturación. En particular, se utilizaron el error absoluto medio (MAE) y el error cuadrático medio en zona crítica (MSE), los cuales permiten medir la magnitud promedio del error y penalizar desviaciones de mayor amplitud, respectivamente.

Considerando la relevancia operacional de los estados cercanos a la saturación, el MSE fue analizado de manera específica en la región de alta saturación, con el objetivo de evaluar la precisión del modelo en el rango más crítico desde el punto de vista de seguridad. Este enfoque permitió complementar la evaluación global del modelo con un análisis enfocado en condiciones de mayor riesgo.

Adicionalmente, y con el fin de evaluar la interpretación operativa del sistema, las estimaciones continuas de saturación fueron discretizadas en dos estados: Normal y Saturado, definidos en torno al umbral funcional del 85% de saturación. A partir de esta discretización, se evaluó el desempeño del sistema como clasificador binario utilizando métricas tales como la matriz de confusión, la exactitud (accuracy), la sensibilidad (recall), la precisión y el F1-score. Estas métricas permitieron analizar la capacidad del algoritmo para identificar correctamente condiciones de saturación crítica, priorizando la reducción de falsos negativos debido a su impacto en la seguridad del usuario.

Considerando que el proceso de saturación del filtro es progresivo y que el nivel de saturación definido mediante el ground truth corresponde a una estimación continua, se incorporó un intervalo de tolerancia en torno al umbral de saturación para la evaluación del desempeño como problema de clasificación. En particular, se definió un intervalo de $\pm 3\%$ alrededor del umbral del 85%, dentro del cual diferencias entre la saturación estimada por el modelo y el valor de referencia no fueron consideradas críticas desde el punto de vista funcional. Esta decisión se fundamenta en que pequeñas discrepancias en este rango pueden deberse tanto a la naturaleza gradual del proceso de saturación como a incertidumbres inherentes a la estimación del ground truth, y no necesariamente representan un error relevante en la identificación del estado físico del filtro.

Como complemento a las métricas de clasificación puntuales, se construyó la curva ROC (Receiver Operating Characteristic) y se calculó el área bajo la curva (AUC), con el objetivo de evaluar la separabilidad entre los estados Normal y Saturado a lo largo de distintos umbrales de decisión.

Finalmente, se calculó la curva POD (Probability of Detection), la cual permite evaluar la probabilidad de detección correcta del estado de saturación en función del nivel real de saturación

del filtro. Este análisis resulta particularmente relevante desde el punto de vista de seguridad, ya que permite caracterizar de manera continua el desempeño del sistema para distintos niveles de degradación del filtro, en lugar de limitarse a una evaluación binaria en torno a un único umbral. La curva POD proporciona así una visión complementaria del comportamiento del algoritmo, orientada a su aplicación en escenarios operativos reales.

4.8. Implementación del modelo en tiempo real

Una vez verificado el desempeño del algoritmo mediante la validación experimental, se procedió a su implementación en tiempo real con el objetivo de evaluar su comportamiento bajo condiciones de operación continua. Esta etapa permitió validar el funcionamiento del sistema completo, integrando adquisición de señales, procesamiento y estimación en tiempo real del estado del filtro.

El modelo entrenado descrito previamente fue implementado en una Raspberry Pi, la estimación de saturación se realizó de manera periódica utilizando ventanas temporales deslizantes, permitiendo actualizar el estado del filtro de forma continua a partir de datos adquiridos en tiempo real.

Como sujeto de prueba se utilizó el fantoma respiratorio, el cual permitió simular de forma controlada distintos escenarios representativos de condiciones de uso industrial. En particular, se realizaron tres pruebas experimentales representativas: (i) una prueba de larga duración, caracterizada por un patrón de respiración correspondiente a actividad ligera y niveles bajos de contaminación; (ii) una prueba de respiración promedio, representativa de una actividad laboral moderada bajo condiciones de contaminación alta; y (iii) una prueba acelerada, con respiración forzada y altos niveles de contaminación, orientada a evaluar el comportamiento del sistema bajo condiciones exigentes.

Durante cada una de estas pruebas, las señales de presión, temperatura y humedad fueron adquiridas de forma continua y procesadas en línea por el sistema embebido, utilizando el pipeline completo de preprocesamiento, segmentación temporal y extracción de características descrito previamente. La validación en tiempo real permitió evaluar la evolución temporal de la saturación estimada a lo largo de ensayos completos, verificando que el algoritmo genera predicciones

coherentes, estables y consistentes con la naturaleza progresiva e irreversible del proceso de saturación del filtro.

Adicionalmente, con el fin de corroborar que las pruebas alcanzaron efectivamente condiciones de saturación, los filtros fueron retirados y pesados al finalizar cada ensayo. Estas mediciones permitieron verificar que el proceso de carga alcanzó niveles compatibles con el estado de 100% de saturación definido en la etapa de ground truth, proporcionando una referencia física independiente para la validación funcional del sistema en tiempo real.

Esta etapa permitió confirmar la factibilidad de implementar el algoritmo como un sistema de monitoreo en tiempo real, capaz de operar de forma autónoma, sentando las bases para su futura aplicación en sistemas inteligentes de protección respiratoria.

Capítulo 5. Resultados

5.1. Levantamiento de datos

Como fue mencionado anteriormente, para la obtención de datos se utilizó un fantoma de pruebas, desarrollado con el objetivo de replicar de manera controlada las condiciones fisiológicas de la respiración y las variaciones ambientales asociadas al uso de mascarillas industriales.

El fantoma fue diseñado para simular las fases de inhalación y exhalación, permitiendo el control de parámetros tales como el volumen tidal, la frecuencia respiratoria, la temperatura y la humedad. El sistema integra tanto el control del patrón respiratorio como la generación de un entorno ambiental controlado, lo que posibilita la adquisición de señales reproducibles bajo distintas condiciones experimentales.

Para el control respiratorio fue utilizado un ventilador mecánico conectado a un humidificador, el ventilador mecánico permitió reproducir patrones respiratorios típicos mediante el ajuste preciso de los ciclos de inhalación y exhalación. Por otro lado, el humidificador permitió regular la temperatura y humedad, características importantes de la respiración, las cuales tienen alta implicancia en el desgaste de filtros de mascarillas.

Para replicar ambientes industriales, se construyó una cámara sellada, la cual consta de una cabeza impresa en 3D dentro de una caja de acrílico. Esta cámara fue sellada usando silicona y un mecanismo de cierre con ganchos metálicos. En Fig. 5.1 es posible ver la implementación del modelo.




Fig. 5.1: Implementación de fantoma y cámara de pruebas, en la figura es posible observar componentes importantes de este modelo, como ventilador mecánico, humidificador propuesto y cámara de contaminación.

Una vez ensamblado el sistema, se realizaron pruebas preliminares destinadas a verificar el correcto funcionamiento del fantoma respiratorio. Durante estas evaluaciones se identificaron y corrigieron problemas asociados a fugas en distintas secciones del sistema, lo que permitió estabilizar los parámetros de operación. En general, los resultados obtenidos demostraron que el fantoma es capaz de reproducir de forma confiable los parámetros respiratorios necesarios para la evaluación del desempeño de filtros de mascarillas industriales.

En la Fig. 5.2 se presenta una comparación entre el patrón respiratorio de un sujeto humano y el generado por el fantoma. Para facilitar la comparación, las señales fueron alineadas temporalmente, normalizadas y centradas respecto de su valor medio. En la figura se observa que el fantoma reproduce de manera clara la secuencia cíclica de la respiración, evidenciando una alta

similitud en la forma de las señales respecto a las obtenidas en el sujeto humano, particularmente en las variables de temperatura y humedad, donde ambos presentan formas de onda comparables.




Fig. 5.2: Comparación de señales respiratorias de fantoma y de una persona alineadas y normalizadas.

Las diferencias observadas en la señal de presión se explican por el funcionamiento de la válvula espiratoria del sistema, la cual genera una caída abrupta al final de la fase inspiratoria, dando lugar a una señal de carácter más triangular en comparación con la forma más cercana a una onda cuadrada típicamente observada en personas. No obstante, esta diferencia no impide la identificación clara de las fases respiratorias y no afecta la capacidad del fantoma para reproducir de manera adecuada el comportamiento respiratorio relevante para los análisis posteriores.

5.2. Caracterización del Proceso de Saturación

En Fig. 5.3 se muestran las curvas de incremento de masa obtenidas para dos ensayos representativos de exposición de filtros a contaminante. En ambos casos se observa un aumento progresivo de la masa del filtro, reflejando la acumulación gradual de contaminante a lo largo del tiempo. La forma de las curvas evidencia un comportamiento no lineal, caracterizado por una

pendiente inicial más pronunciada y una tendencia a la estabilización a medida que el filtro se aproxima a condiciones de saturación.




Fig. 5.3: Evolución del peso del filtro en función del tiempo de exposición a contaminación durante pruebas controladas con el fantoma respiratorio. Se muestran dos pruebas representativas (Sample 1 y Sample 2), junto con su valor medio y el rango mínimo-máximo observado.

La alta similitud observada entre las curvas correspondientes a distintos ensayos indica una buena reproducibilidad del proceso de saturación bajo condiciones controladas. Las diferencias entre ensayos se mantienen acotadas y no alteran la tendencia global del fenómeno, lo que permite considerar estas curvas como representativas del comportamiento típico de saturación del filtro en el contexto experimental analizado. A partir de estos resultados se obtuvo una curva promedio de referencia, utilizada como representación del proceso de saturación del filtro.

En los ensayos con seguimiento temporal, donde se registró la evolución de la masa cada 24 horas se observó un incremento de masa de 1.3 g. Asimismo, en el resto de las pruebas, en las cuales el peso del filtro fue evaluado únicamente al inicio y al término del ensayo, se observó de forma

consistente un aumento promedio de masa cercano a 1.3 g. Estos resultados indican que dicho valor representa el nivel de carga máxima alcanzado por el filtro bajo las condiciones experimentales consideradas. En la Fig. 5.4 se presenta una comparación visual entre un filtro nuevo y un filtro expuesto a contaminación prolongada, donde se aprecia claramente el aumento de masa producto de la acumulación de material particulado en el medio filtrante.



Fig. 5.4: Comparación del peso de un filtro 3M 2097 P100 antes (izquierda) y después (derecha) de la prueba de exposición prolongada a contaminantes. Se observa un incremento de masa asociado a la acumulación de partículas en el filtro.

La representación del proceso de saturación en una escala continua permitió asociar cada instante temporal de las señales respiratorias adquiridas a un nivel de saturación. Esta caracterización experimental constituye la base física del ground truth utilizado en el desarrollo y evaluación del algoritmo de detección de saturación, asegurando que las estimaciones posteriores se encuentren asociadas a un fenómeno medible y reproducible.

5.3. Análisis de datos

Con el fin de entender la relación entre las variables respiratorias adquiridas y el proceso de saturación del filtro, se realizó un análisis descriptivo de los datos obtenidos mediante el fantoma respiratorio. Este análisis permitió identificar tendencias, patrones y comportamientos

característicos de las señales de presión, humedad y temperatura a lo largo del proceso de degradación progresiva del filtro, así como evaluar su aporte para la estimación del estado de saturación.

Para este propósito, se analizaron tanto los valores medios de las señales como métricas asociadas a su variabilidad y amplitud respiratoria, permitiendo caracterizar la evolución del sistema bajo distintos niveles de saturación. Los resultados presentados en esta sección constituyen la base para la selección de variables relevantes y el posterior desarrollo del algoritmo de detección de saturación.

5.3.1 Tendencias globales de las variables respiratorias

Se analizó la evolución temporal de los valores medios, en la Fig. 5.5 se puede observar la evolución de los valores medios normalizados de presión, humedad y temperatura en función del porcentaje de saturación del filtro. En el caso de la presión, se observa que sus valores medios se mantienen relativamente bajos y estables durante las primeras etapas del proceso, correspondientes a niveles de saturación inferiores al 40–50%. A partir de este punto, la presión comienza a incrementarse de forma sostenida, exhibiendo un aumento más pronunciado en niveles altos de saturación. Este comportamiento sugiere una relación no lineal entre la presión respiratoria y la saturación del filtro, coherente con el aumento progresivo de la resistencia al flujo producto de la acumulación de material particulado en el medio filtrante.




Fig. 5.5: Evolución de los valores medios normalizados de presión en azul, humedad en verde y temperatura en rojo, en función del porcentaje de saturación del filtro.

La humedad relativa presenta una tendencia creciente más suave y gradual a lo largo del proceso de saturación. Este incremento se asocia al cambio del microclima interno de la mascarilla, producto de la reducción de la capacidad de intercambio de aire a medida que el filtro se degrada. No obstante, la pendiente observada es menor que la de la presión, indicando una sensibilidad más limitada frente al estado físico del filtro.

En contraste, la temperatura muestra un comportamiento no monótono, con oscilaciones y variaciones que no siguen de forma consistente la progresión del proceso de saturación. Estas fluctuaciones sugieren una mayor dependencia de condiciones externas o del control térmico del sistema, más que del estado del filtro propiamente tal.

5.3.2 Análisis de variabilidad y esfuerzo respiratorio

Con el objetivo de evaluar cambios dinámicos asociados al esfuerzo respiratorio, se analizó la evolución de la amplitud respiratoria de las señales, cuantificada mediante la magnitud peak to peak (P2P), tal como se muestra en la Fig. 5.6. En el caso de la presión, la amplitud P2P presenta un incremento progresivo y casi monótono a medida que aumenta la saturación del filtro. Este resultado refleja una mayor variabilidad del diferencial de presión entre ciclos respiratorios,

consistente con un aumento del esfuerzo requerido para mantener la ventilación frente a una mayor resistencia al flujo.




Fig. 5.6: Evolución de la amplitud respiratoria (magnitud P2P), de las señales de presión en azul, humedad en verde y temperatura en rojo, en función del nivel de saturación del filtro.

La amplitud P2P de la humedad también muestra una tendencia creciente, aunque más tardía y con mayor dispersión, indicando que esta variable aporta información complementaria sobre la dinámica del sistema, pero con menor robustez que la presión. Por su parte, la amplitud de la señal de temperatura se mantiene prácticamente constante a lo largo de todo el rango de saturación, evidenciando una baja sensibilidad frente a la degradación del filtro.

5.3.3 Análisis entre variables respiratorias y saturación

Con el fin de cuantificar de manera objetiva la relación entre las variables respiratorias medidas y el nivel de saturación del filtro, se realizó un análisis estadístico de asociación utilizando el coeficiente de correlación de Spearman. Este enfoque permite capturar relaciones monótonas sin asumir linealidad, lo cual resulta adecuado considerando la naturaleza progresiva y no lineal del proceso de saturación observado experimentalmente.

La Tabla 5.1 resume los valores obtenidos para cada variable, junto con sus intervalos de confianza al 95% y el coeficiente de determinación asociado. Los resultados indican que la presión

diferencial presenta la asociación más fuerte con el nivel de saturación ($\rho = 0.916$, IC 95%: [0.897–0.933]), además de un alto poder explicativo ($R^2 = 0.95$). Este comportamiento confirma que la presión constituye el principal indicador físico del estado de degradación del filtro.

Tabla 5-1 Asociación estadística entre variables respiratorias y saturación del filtro.

Variable	ρ (Spearman)	IC 95%	R^2
Presión	0.916	[0.897 – 0.933]	0.95
Humedad	0.788	[0.745 – 0.826]	0.85
Temperatura	0.195	[0.099 – 0.289]	0.20

Por otro lado, la humedad muestra una correlación moderada-alta ($\rho = 0.788$, IC 95%: [0.745–0.826]) y un R^2 de 0.85, lo que sugiere un rol complementario relevante, particularmente en etapas intermedias y avanzadas de saturación. En contraste, la temperatura muestra una relación débil con la saturación ($\rho = 0.195$, $R^2 = 0.20$), con intervalos de confianza amplios, evidenciando su limitado aporte explicativo.

La Fig. 5.7 complementa estos resultados mostrando la monotonicidad de cada variable y su respectivo poder explicativo, reforzando visualmente la clara jerarquía entre presión, humedad y temperatura. En conjunto, estos hallazgos respaldan cuantitativamente la selección de variables utilizada en el desarrollo del algoritmo y justifican el descarte de la temperatura como entrada, además de reforzar la necesidad de emplear modelos capaces de capturar dinámicas no lineales.




Fig. 5.7: Monotonidad y poder explicativo de las variables respiratorias (presión, humedad y temperatura) respecto al nivel de saturación del filtro. Se presentan los coeficientes de correlación de Spearman (ρ) con intervalos de confianza al 95% y el coeficiente de determinación (R^2).

5.3.4 Distribución estadística por etapas de saturación

Para evaluar la separabilidad estadística de las señales en distintas etapas del proceso, la Fig. 5.8 presenta la distribución de la presión respiratoria agrupada en rangos de saturación (0–30%, 30–60%, 60–85% y >85%). En niveles bajos de saturación, la presión se concentra en valores reducidos con baja dispersión, reflejando condiciones respiratorias estables. En la etapa intermedia (30–60%) se observa un aumento significativo de la dispersión, indicando un régimen transicional en el cual la presión comienza a verse influenciada tanto por el estado del filtro como por variaciones en el patrón respiratorio.




Fig. 5.8: Distribución de la presión respiratoria normalizada agrupada por etapas de saturación del filtro (0–30%, 30–60%, 60–85% y >85%).

En el rango 60–85%, la presión alcanza valores más elevados, aunque con una dispersión aún considerable, lo que sugiere el inicio de condiciones de resistencia respiratoria relevante, pero todavía heterogéneas entre ensayos. Finalmente, para niveles de saturación superiores al 85%, la distribución se concentra en valores altos con baja variabilidad, evidenciando un estado de saturación plenamente desarrollado y físicamente distinguible.

Estos resultados muestran que el proceso de saturación es progresivo y continuo, sin una frontera abrupta entre estados, lo que explica el solapamiento observado entre etapas intermedias y refuerza la necesidad de un enfoque de estimación continua en lugar de una clasificación rígida.

5.3.5 Síntesis del análisis y selección de variables

A partir de los análisis realizados, se observa que las características derivadas de la señal de presión concentran la mayor parte de la información relevante para la estimación del nivel de saturación del filtro. Tanto los valores medios como las métricas asociadas a la variabilidad y amplitud

respiratoria presentan una relación fuerte y consistente con el proceso de degradación progresiva del filtro, además de una clara separabilidad estadística en estados de alta saturación.

La señal de humedad relativa, si bien exhibe una correlación moderada-alta con la saturación, presenta una mayor variabilidad y menor estabilidad, particularmente en escenarios de uso real. En este contexto, se optó por incorporar únicamente su valor medio como característica complementaria, con el fin de capturar información asociada al microclima interno de la mascarilla sin introducir una dependencia del algoritmo a una señal potencialmente errática.

Por el contrario, la temperatura no mostró una relación estable ni monotónica con el nivel de saturación, ni en su componente media ni en métricas de variabilidad, evidenciando un bajo poder explicativo. En consecuencia, esta variable fue descartada del conjunto final de características utilizadas por el algoritmo.

En conjunto, estos resultados fundamentan la selección del conjunto de características empleado, compuesto principalmente por métricas derivadas de la presión respiratoria y una única característica representativa de la humedad.

5.4. Desempeño Modelo de Regresión

Para evaluar la capacidad del sistema para estimar de forma continua el nivel de saturación del filtro, se comparó el desempeño de distintos modelos de regresión supervisada utilizando las variables seleccionadas a partir del análisis de datos. La evaluación se realizó considerando tanto métricas globales de error como un análisis específico en la zona crítica de saturación, definida por su relevancia operacional desde el punto de vista de la seguridad del usuario.

5.4.1 Comparación de modelos de regresión

La Tabla 5.2 presenta una comparación del desempeño de los distintos modelos evaluados, incluyendo regresión lineal, Support Vector Regressor, Random Forest, Gradient Boosting y XGBoost. Como métricas de evaluación se utilizaron el error absoluto medio global (MAE) y el error cuadrático medio (MSE) calculado específicamente en la zona crítica de saturación.

Tabla 5-2 Comparación de rendimiento de modelos de regresión para la estimación del nivel de saturación del filtro, evaluada mediante MAE global y MSE en zona crítica.

Modelo	MAE global (%)	MSE zona crítica (%)
Regresión Lineal	18.25	14.27
Support Vector Regressor	13.56	12.54
Random Forest	11.73	8.67
Gradient Boosting	10.45	8.21
XGBoost	9.32	7.71

Los resultados muestran que los modelos no lineales presentan un desempeño superior a los enfoques lineales, lo que sugiere que la relación entre las variables respiratorias y el nivel de saturación del filtro no puede ser descrita adecuadamente mediante un modelo lineal. En particular, el modelo XGBoost presentó el mejor desempeño global, alcanzando un MAE de 9.32% y el menor error en la zona crítica (7.71%), lo que indica una mayor precisión en el rango de saturación más relevante desde el punto de vista operativo.

Estos resultados confirman que la relación entre las variables respiratorias y el estado de saturación del filtro no puede ser capturada adecuadamente mediante modelos lineales simples, y justifican la selección de XGBoost como modelo final para la estimación continua de saturación.

5.4.2 Estimación de saturación en distintos escenarios

Con el fin de evaluar el comportamiento del modelo seleccionado en condiciones representativas de uso, la Fig. 5.9, presenta la estimación de saturación generada por el modelo XGBoost en comparación con el ground truth para tres escenarios experimentales: un caso promedio, una prueba de saturación acelerada y una prueba de larga duración.




Fig. 5.9: Comparación entre la saturación estimada por el modelo XGBoost y el ground truth para tres escenarios representativos: (A) prueba promedio, (B) prueba de saturación acelerada y (C) prueba de larga duración.

En el caso de la prueba promedio, realizado mediante el fantoma respiratorio y correspondiente a un nivel de actividad física moderado y un nivel de contaminación elevado, el modelo reproduce de manera adecuada la tendencia general del proceso de saturación. En particular la estimación sigue de forma consistente la evolución progresiva del ground truth, capturando correctamente las distintas fases del proceso, incluyendo el crecimiento inicial y la aproximación gradual a la

saturación máxima. Este resultado evidencia la capacidad del modelo para representar la dinámica típica de degradación del filtro en condiciones operativas habituales.

En la prueba de saturación acelerada, que simula respiración forzada bajo un nivel de contaminación aproximadamente diez veces superior al límite permitido por la normativa de la NIOSH [51], la curva de saturación se caracteriza por una rápida acumulación de contaminante. En este escenario altamente exigente, el modelo mantiene una adecuada capacidad de seguimiento, adaptándose al incremento abrupto de la saturación. Este comportamiento demuestra la sensibilidad del sistema frente a cambios rápidos en las condiciones de operación y su estabilidad ante escenarios extremos, reproducibles únicamente en entornos controlados como el fantoma de pruebas.

Por su parte, en la prueba de larga duración, correspondiente a una simulación de actividad ligera y niveles bajos de contaminación, escenario que se asemeja en mayor medida a condiciones reales de uso industrial, el modelo muestra una estimación estable y coherente a lo largo de todo el ensayo. La saturación estimada mantiene una alta concordancia con el ground truth incluso durante períodos prolongados de operación, y no se observan decrementos no físicos en la señal, lo que refuerza la consistencia temporal del modelo y su aplicabilidad para aplicaciones de monitoreo continuo.

En conjunto, estos resultados demuestran que el modelo de regresión seleccionado es capaz de estimar de forma robusta y continua el estado de saturación del filtro bajo distintos casos de operación, constituyendo una base sólida para su posterior uso como sistema de detección de condiciones de saturación.

Si bien el modelo permite una estimación continua del nivel de saturación, desde un punto de vista operacional resulta relevante evaluar su desempeño como sistema de detección de condiciones críticas. En la siguiente sección se analiza el comportamiento del sistema al discretizar la estimación continua en estados operativos, evaluando su capacidad de detección mediante distintas métricas de clasificación.

5.5. Evaluación Clasificación de Estados

Si bien el sistema fue desarrollado inicialmente como un estimador continuo del nivel de saturación del filtro, desde un punto de vista operacional y de uso en terreno es importante evaluar su desempeño como un sistema de detección de condiciones críticas. Para ello, la estimación generada por el modelo de regresión fue discretizada en dos estados operativos: Normal (saturación $< 85\%$) y Saturado (saturación $\geq 85\%$), de acuerdo con el umbral definido previamente.

5.5.1 Matriz de confusión y métricas de clasificación

La Fig. 5.10 presenta la matriz de confusión obtenida para el problema de clasificación binaria. Se observa que el algoritmo identifica correctamente la gran mayoría de los casos correspondientes al estado Saturado, con una cantidad muy reducida de falsos negativos. En particular, el sistema alcanza una sensibilidad (recall) de 0.997 para la clase Saturado, lo que indica una probabilidad altamente baja de no detectar un filtro efectivamente saturado.




Fig. 5.10: Matriz de confusión del algoritmo para la clasificación binaria de los estados Normal ($<85\%$) y Saturado ($\geq 85\%$).

Este comportamiento es especialmente relevante en aplicaciones de seguridad ocupacional, donde un error en la detección de un filtro obstruido representa un riesgo significativamente mayor que

la generación de falsas alarmas. A nivel global, el clasificador alcanza una exactitud (accuracy) de 0.944 y un F1-score de 0.961, lo que evidencia un balance adecuado entre sensibilidad y precisión.

Estos resultados confirman que el sistema presenta un desempeño robusto para la identificación de condiciones críticas de saturación, priorizando la reducción de falsos negativos.

5.5.2 Análisis ROC (Receiver Operating Characteristic)

Para evaluar la capacidad de separabilidad del clasificador a lo largo de distintos umbrales de decisión, se construyó la curva ROC, mostrada en la Fig. 5.11. El área bajo la curva (AUC) alcanzó un valor de 0.957, lo que indica una excelente capacidad del modelo para discriminar entre los estados Normal y Saturado.




Fig. 5.11: Curva ROC (Receiver Operating Characteristic) del clasificador binario Normal/Saturado.

La forma de la curva evidencia que es posible alcanzar altos niveles de sensibilidad manteniendo una tasa de falsos positivos relativamente baja, reforzando la capacidad del sistema para ser aplicado en situaciones donde la detección temprana y confiable de saturación es prioritaria.

5.5.3 Curva de Probabilidad de Detección (POD)

Con el fin de evaluar el desempeño del sistema desde una perspectiva operacional, se construyó la curva de Probabilidad de Detección (POD), la cual relaciona la probabilidad de que el sistema indique un estado Saturado con el nivel real de saturación del filtro. La Fig. 5.12 muestra que la probabilidad de detección aumenta de manera progresiva a medida que el filtro se aproxima al umbral crítico.




Fig. 5.12: Curva de probabilidad de detección (Probability of Detection, POD) del sistema para la identificación de filtros saturados (predicción >85%), en función del nivel real de saturación. La curva muestra un aumento progresivo de la probabilidad de detección, alcanzando niveles superiores al 95% en el rango de saturación crítica.

En particular, el sistema alcanza una probabilidad de detección superior al 95% para niveles de saturación cercanos al 85%, cumpliendo con criterios de confiabilidad típicamente exigidos en aplicaciones de monitoreo y seguridad. Este comportamiento indica que el sistema no solo detecta adecuadamente filtros claramente saturados, sino que además incrementa gradualmente su nivel de alerta en la zona de transición, coherente con la naturaleza progresiva del proceso de degradación del filtro.

La curva POD complementa las métricas clásicas de clasificación al proporcionar una interpretación directa del desempeño del sistema en términos de confiabilidad de detección, reforzando su potencial aplicación en escenarios industriales reales.

En conjunto, los resultados obtenidos demuestran que el algoritmo no solo presenta un alto desempeño cuantitativo, sino que además exhibe un comportamiento coherente con la naturaleza del proceso de saturación del filtro, lo que respalda su potencial aplicación como sistema de monitoreo y detección temprana en entornos industriales reales.

5.6. Validación en tiempo real

Con el fin de evaluar el desempeño del algoritmo en condiciones operativas representativas de la industria, el sistema fue validado en tiempo real utilizando el fantoma respiratorio bajo tres escenarios representativos: (i) prueba promedio, (ii) prueba acelerada, y (iii) prueba de larga duración. Estos escenarios fueron diseñados para analizar el comportamiento del sistema frente a distintos perfiles de progresión de saturación del filtro, considerando tanto condiciones cercanas al uso real como situaciones de estrés controlado, estos resultados se encuentran desplegados en Fig 5.13.




Fig. 5.13: Evolución temporal de la saturación durante la validación en tiempo real utilizando el fantoma respiratorio bajo tres escenarios operativos: (A) Prueba promedio, (B) Prueba de saturación acelerada, y (C) prueba de larga duración.

5.6.1 Validación en condiciones promedio y de larga duración

En la prueba promedio, el sistema mostró un comportamiento estable y coherente con la evolución esperada del proceso de saturación. La estimación entregada por el algoritmo siguió de forma consistente la tendencia del ground truth, permitiendo identificar oportunamente la transición hacia

la zona crítica y la condición de saturación elevada del filtro. Este resultado confirma la capacidad del sistema para operar correctamente bajo condiciones representativas de uso industrial real.

De manera similar, en la prueba de larga duración, el algoritmo mantuvo un desempeño robusto durante todo el periodo de evaluación. La respuesta del sistema mostró una alta estabilidad, sin fluctuaciones ni activaciones prematuras, incluso frente a cambios graduales en las condiciones respiratorias. Estos resultados son especialmente relevantes desde el punto de vista operativo, ya que reflejan el comportamiento esperado del sistema en aplicaciones reales, donde la saturación del filtro ocurre de forma progresiva a lo largo del tiempo.

5.6.2 Validación bajo condiciones de estrés (prueba acelerada)

En contraste, durante la prueba acelerada se observó una respuesta anticipada del algoritmo, manifestada en una respuesta temprana de la estimación de saturación elevada. Este comportamiento se atribuye a la naturaleza extrema de este escenario, en el cual la tasa de acumulación de material particulado supera ampliamente las condiciones realistas de exposición.

Es importante destacar que esta prueba fue diseñada como un escenario de estrés, reproducible únicamente mediante un entorno artificial como el fantoma respiratorio. En particular, la concentración de contaminante utilizada corresponde a valores del orden de diez veces superiores a los límites de exposición permisibles, lo que representa una condición prácticamente imposible de alcanzar en entornos industriales reales bajo normativas de seguridad vigentes.

Desde esta perspectiva, la respuesta anticipada del algoritmo no se interpreta como una falla funcional del sistema, sino como una consecuencia esperable al someterlo a un escenario de operación fuera de su dominio de validez práctica.

5.7. Resultados de Difusión Científica

El desarrollo del fantoma respiratorio dio origen al artículo científico titulado “*Modular and Programmable Breathing Phantom Station for Accelerated Degradation Testing of Industrial Respirator Filters*”, el cual fue enviado para su evaluación a la revista *HardwareX*. Asimismo, el

fantoma desarrollado se encuentra actualmente en proceso de solicitud de patente bajo el número de tramitación CL202503527.

Por otro lado, los resultados asociados al desarrollo del algoritmo de detección de saturación de filtros fueron enviados a la revista *IEEE Sensors Journal* con el título “*IoT-Enabled Sensor Framework for Real-Time Dust Filter Saturation Estimation in Industrial Respirators Using Machine Learning*”.

Capítulo 6. Discusión y Conclusiones

6.1. Discusión

El presente trabajo abordó el problema de la detección de saturación de filtros respiratorios desde una perspectiva integral, combinando análisis físico, estadístico y aprendizaje automático. A diferencia de enfoques tradicionales basados en criterios subjetivos, esta tesis propone un sistema de estimación continua, orientado al monitoreo en tiempo real del estado del filtro.

6.1.1 Relación entre variables respiratorias y saturación del filtro

En primer lugar fue posible identificar relaciones entre las variables respiratorias medidas y el nivel de saturación del filtro. Los resultados del análisis estadístico evidenciaron que el proceso de saturación presenta un comportamiento progresivo y no lineal, lo que se manifiesta tanto en los valores medios como en la variabilidad de las señales respiratorias.

En particular, la presión respiratoria mostró una asociación fuerte y consistente con el nivel de saturación, tanto en términos de correlación monótonica ($\rho = 0.916$) como de poder explicativo ($R^2 \approx 0.95$). Este comportamiento se alinea con lo reportado en la literatura, donde la presión diferencial ha sido identificada como uno de los principales indicadores del desgaste y la obstrucción progresiva de filtros respiratorios [44], [52]. Desde el punto de vista físico, este resultado es coherente con el fenómeno de acumulación de material particulado en el medio filtrante, el cual incrementa gradualmente la resistencia al flujo de aire y exige mayores diferenciales de presión para mantener la ventilación.

La humedad relativa, por su parte, presentó una correlación moderada-alta con la saturación ($\rho \approx 0.79$), reflejando cambios en el microclima interno de la mascarilla asociados a la reducción del intercambio de aire. Sin embargo, su menor pendiente y mayor dispersión indican que esta variable actúa como un indicador complementario, más que como un descriptor principal del estado del filtro.

En contraste, la temperatura no mostró una relación con el nivel de saturación, presentando baja correlación y escaso poder explicativo. Este resultado respalda cuantitativamente su descarte como

variable de entrada del algoritmo, evitando introducir ruido o sesgos derivados de factores externos al proceso de degradación del filtro.

6.1.2 Definición de ground truth y rol de fantoma respiratorio

Un aspecto central del presente trabajo corresponde a la definición y caracterización del ground truth utilizado para entrenar y evaluar el algoritmo de detección de saturación. A diferencia de otros problemas de clasificación o regresión, el nivel de saturación de un filtro respiratorio no cuenta con una referencia directa ni estandarizada, especialmente en condiciones reales de uso industrial.

En este contexto, el aumento de masa del filtro debido a la acumulación de material particulado fue utilizado como una referencia física objetiva del proceso de saturación. La alta reproducibilidad observada entre las curvas de masa obtenidas en distintos ensayos permitió validar este enfoque como una aproximación consistente para representar la degradación progresiva del filtro. Asimismo, la normalización de estas curvas permitió expresar el proceso de saturación en una escala continua e interpretable, facilitando su uso como variable objetivo del modelo.

El uso de un fantoma respiratorio resultó clave para la construcción de este ground truth, ya que permitió realizar mediciones prolongadas, controladas y repetibles, imposibles de obtener mediante pruebas en personas. La imposibilidad práctica y ética de exponer usuarios humanos a condiciones de alta contaminación, así como de monitorear de forma continua la masa del filtro durante su uso, hace que la utilización de un sistema artificial controlado sea una alternativa necesaria para el estudio sistemático del fenómeno.

Además, el fantoma permitió evaluar escenarios extremos, como pruebas aceleradas de saturación, que si bien no representan condiciones realistas de operación, resultan valiosas para explorar los límites del sistema y validar su comportamiento bajo condiciones de estrés. De este modo, el uso del fantoma no solo habilitó la obtención de datos para el entrenamiento del algoritmo, sino que también aportó un método robusto para la validación de sus resultados.

En conjunto, la definición del ground truth basada en criterios físicos y el uso de un fantoma respiratorio constituyen elementos fundamentales de este trabajo, permitiendo abordar un problema para el cual actualmente no existen bases de datos públicas ni referencias estandarizadas, y sentando las bases para futuras extensiones hacia estudios con usuarios reales en entornos industriales.

6.1.3 Desempeño del modelo de regresión

La comparación entre distintos modelos de regresión evidenció que los enfoques basados en árboles y boosting superan consistentemente a los modelos lineales, lo que confirma la naturaleza no lineal del proceso de saturación. En particular, el modelo XGBoost presentó el mejor compromiso entre precisión global y desempeño en la zona crítica, alcanzando el menor error medio absoluto y el menor error cuadrático medio en el rango operacionalmente más relevante. Este resultado no solo valida la elección del modelo, sino que también refuerza la decisión de formular el problema como una estimación continua, en lugar de una clasificación directa desde etapas tempranas.

La evaluación del modelo bajo distintos escenarios experimentales (prueba promedio, acelerada y de larga duración) mostró que el algoritmo es capaz de reproducir de manera robusta la tendencia general del proceso de saturación, manteniendo coherencia temporal.

6.1.4 Evaluación como sistema clasificador

Desde un punto de vista práctico, el interés principal de detección de saturación radica en la capacidad del sistema para detectar condiciones críticas de saturación, es decir, el momento en el que el filtro debe ser reemplazado. La discretización de la estimación continua permitió evaluar el algoritmo como clasificador, obteniendo métricas destacadas, especialmente en términos de sensibilidad.

El alto recall obtenido para la clase “saturado” (0.997) resulta particularmente relevante en aplicaciones de seguridad industrial, donde una detección tardía implica mayores riesgos que una activación conservadora. La elevada área bajo la curva ROC ($AUC \approx 0.96$) y el balance reflejado

en el F1-score confirman que el sistema mantiene un buen compromiso entre sensibilidad y precisión.

6.1.5 Validación en tiempo real y alcance práctico

La validación en tiempo real constituye uno de los principales aportes prácticos de este trabajo. Las pruebas realizadas mediante el fantoma respiratorio permitieron evaluar el comportamiento del sistema bajo condiciones representativas y escenarios de estrés controlado.

En las pruebas promedio y de larga duración, el algoritmo mostró una respuesta estable y coherente con la evolución física del proceso, lo que respalda su uso potencial en aplicaciones industriales reales, donde la saturación ocurre de manera gradual.

En la prueba acelerada, la respuesta rápida del sistema evidenció un comportamiento conservador frente a condiciones extremas. Dado que este escenario supera ampliamente los límites normativos de exposición, este resultado no se interpreta como una falla, sino como una consecuencia esperable al operar fuera del dominio de uso realista del sistema.

6.2. Limitaciones

Si bien los resultados obtenidos demuestran el correcto funcionamiento del algoritmo propuesto y su potencial aplicación en entornos industriales, es importante reconocer ciertas limitaciones inherentes al alcance del presente trabajo.

En primer lugar, la validación experimental se realizó utilizando un número limitado de ensayos, todos ellos efectuados mediante un fantoma respiratorio. Si bien este enfoque permite un alto grado de control experimental y reproducibilidad, implica que algunas variables, como la temperatura, se mantuvieron altamente controladas y no reflejan completamente la variabilidad presente en escenarios reales de uso humano.

Adicionalmente, el sistema entrega actualmente una actualización del estado de saturación cada 5 minutos, lo cual resulta adecuado para un monitoreo continuo del desgaste del filtro, pero podría

optimizarse en futuras implementaciones reduciendo este intervalo para permitir una respuesta más rápida en aplicaciones críticas.

Otra limitación relevante es que el estudio se centró exclusivamente en un tipo de contaminante particulado y en filtros diseñados para polvo, por lo que los resultados no pueden generalizarse directamente a otros tipos de filtros, como aquellos destinados a vapores, gases o contaminantes químicos.

Asimismo, las pruebas realizadas con el fantoma simulaban únicamente patrones respiratorios sanos y constantes, incluyendo escenarios de respiración normal y agitada. No se evaluó el comportamiento del algoritmo frente a situaciones más complejas propias del uso humano real, tales como usuarios con enfermedades respiratorias, hablando, pausas respiratorias irregulares, o la acción de poner y quitar la mascarilla durante la jornada laboral. Estas condiciones podrían introducir dinámicas adicionales que el fantoma, en su configuración actual, no logra emular completamente.

6.3. Trabajo Futuro

A partir de las limitaciones identificadas, se abren diversas oportunidades de mejora o trabajo futuro orientadas a fortalecer y ampliar el alcance del sistema propuesto.

Una primera línea consiste en la recolección de un mayor volumen de datos experimentales, lo que permitiría entrenar modelos más robustos y explorar el uso de técnicas de aprendizaje profundo (deep learning), capaces de capturar relaciones aún más complejas entre las variables respiratorias y el estado del filtro.

En este contexto, la obtención de datos provenientes de usuarios reales en entornos industriales representa un punto altamente relevante en este trabajo. Este tipo de datos permitiría observar comportamientos y relaciones entre variables que el fantoma respiratorio no logra reproducir, además de evaluar el desempeño del algoritmo frente a una mayor diversidad de patrones respiratorios y condiciones de uso.

Otra línea de investigación futura corresponde a la evaluación del algoritmo en otros tipos de filtros, incluyendo filtros para contaminantes químicos y gases, lo que ampliaría significativamente el campo de aplicación del sistema desarrollado.

Finalmente, la validación del algoritmo en entornos industriales reales, integrándolo a sistemas de monitoreo ocupacional, permitiría evaluar su desempeño bajo condiciones operativas reales, considerando factores ambientales, variabilidad humana y condiciones de trabajo prolongadas, constituyendo un paso clave hacia su eventual transferencia tecnológica.

6.4. Conclusión

En este trabajo se desarrolló y validó exitosamente un algoritmo de detección de condiciones de saturación de filtros en mascarillas industriales, capaz de operar en tiempo real y adaptarse a distintos escenarios de uso. A partir de los resultados obtenidos, se puede concluir que el sistema propuesto logró con éxito la caracterización del estado del filtro bajo diversas condiciones de uso.

En primer lugar, se logró identificar y analizar las relaciones entre las variables respiratorias y el nivel de saturación del filtro, demostrando que el proceso de degradación es progresivo y no lineal. Los resultados evidenciaron que la presión respiratoria constituye el indicador más robusto del estado del filtro, mientras que la humedad aporta información complementaria asociada al microclima interno de la mascarilla, y la temperatura presenta un aporte limitado para la estimación de la saturación.

Un aporte relevante de este trabajo corresponde a la definición de un ground truth basado en criterios físicos, utilizando el aumento de masa del filtro como referencia objetiva del proceso de saturación. La alta reproducibilidad observada entre ensayos permitió validar este enfoque como una aproximación consistente y cuantitativa, especialmente en un contexto donde no existen referencias estandarizadas para este problema. En este sentido, el uso de un fantoma respiratorio resultó fundamental, ya que permitió realizar mediciones controladas, prolongadas y reproducibles, imposibles de obtener mediante pruebas en personas bajo condiciones reales de exposición.

En cuanto al desarrollo del algoritmo, la comparación entre distintos modelos permitió establecer que los enfoques basados en árboles y boosting capturan de mejor manera la dinámica no lineal del proceso de saturación. El modelo XGBoost presentó el mejor desempeño global y en la zona crítica de operación, validando la formulación del problema como una estimación continua del estado del filtro. La posterior discretización de esta estimación permitió evaluar el sistema como clasificador, obteniendo una elevada sensibilidad para la detección de condiciones críticas, aspecto clave en aplicaciones de seguridad industrial.

La validación en tiempo real mediante el fantoma respiratorio permitió demostrar la viabilidad práctica del sistema, evidenciando un comportamiento estable y coherente bajo condiciones representativas de uso y escenarios prolongados. En escenarios de estrés extremo, el sistema mostró una respuesta conservadora, consistente con un enfoque preventivo frente a condiciones fuera del dominio operativo realista.

En conjunto, los resultados obtenidos confirman que el sistema desarrollado constituye una base sólida para el diseño de soluciones de monitoreo del estado de filtros respiratorios, con potencial aplicación en entornos industriales. Este trabajo aporta un marco experimental, metodológico y algorítmico que contribuye al avance de tecnologías orientadas a mejorar la seguridad ocupacional y la gestión del uso de equipos de protección respiratoria.

Capítulo 7. Glosario

AUC :Área bajo la curva.

FR : Frecuencia respiratoria.

IC :Intervalo de confianza

MAE : Error absoluto medio.

MSE : Error cuadrático medio.

P2P : Peak to peak.

PCI : Peso corporal ideal.

POD : Curva de probabilidad de detección.

ROC : Receiver operating characteristic.

TLV : Threshold Limit Value.

VT : Volumen tidal.

Capítulo 8. Referencias

- [1] R. F. Hoy, «Current global perspectives on silicosis—Convergence of old and newly emergent hazards», *Respirol. Carlton Vic*, vol. 27, n.º 6, p. 387, mar. 2022, doi: 10.1111/resp.14242.
- [2] C.-C. N. del C. Chile, «Una batalla que Codelco está decidida a ganar». Accedido: 14 de diciembre de 2024. [En línea]. Disponible en: <https://www.codelco.com/sustentabilidad/publicaciones/informe-sustentable/una-batalla-que-codelco-esta-decidida-a-ganar>
- [3] «Advertencia de Peligro: Polvo de Sílice Generado».
- [4] «3m-psd-wiya-rr-white-paper-spanish.pdf». Accedido: 6 de enero de 2025. [En línea]. Disponible en: <https://multimedia.3m.com/mws/media/2076093O/3m-psd-wiya-rr-white-paper-spanish.pdf>
- [5] «Respiración: MedlinePlus enciclopedia médica ilustración». Accedido: 6 de enero de 2025. [En línea]. Disponible en: https://medlineplus.gov/spanish/ency/esp_imagepages/9026.htm
- [6] D. A. León-Figueroa, «Fisiología Linda S. Costanzo 7a Edición», *Fisiol. Linda Costanzo 7a Ed.*, ene. 2020, Accedido: 15 de noviembre de 2024. [En línea]. Disponible en: https://www.academia.edu/44166294/Fisiolog%C3%ADa_Linda_S_Costanzo_7a_Edici%C3%B3n
- [7] J. A. Dempsey y B. J. Whipp, «The Respiratory System», en *Exercise Physiology: People and Ideas*, C. M. Tipton, Ed., New York, NY: Springer, 2003, pp. 138-187. doi: 10.1007/978-1-4614-7543-9_4.
- [8] A. Yartsev, «Heating and humidification in the normal respiratory tract | Deranged Physiology». Accedido: 15 de noviembre de 2024. [En línea]. Disponible en: <https://derangedphysiology.com/main/cicm-primary-exam/required-reading/respiratory-system/Chapter 006/heating-and-humidification-normal-respiratory-tract>
- [9] M. C. Valenza, «La función pulmonar, factores físicos que la determinan y su importancia para el fisioterapeuta», *Rev. Iberoam. Fisioter. Kinesiol.*, vol. 14, n.º 2, pp. 83-89, jul. 2011, doi: 10.1016/j.rifk.2012.02.005.
- [10] M. Oyarzún G, «Contaminación aérea y sus efectos en la salud», *Rev. Chil. Enfermedades Respir.*, vol. 26, n.º 1, pp. 16-25, mar. 2010, doi: 10.4067/S0717-73482010000100004.
- [11] «Introducción a las enfermedades pulmonares ambientales y profesionales - Trastornos del pulmón y las vías respiratorias», Manual MSD versión para público general. Accedido: 6 de enero de 2025. [En línea]. Disponible en: <https://www.msdmanuals.com/es/hogar/trastornos-del-pulmón-y-las-vías-respiratorias/enfermedades-pulmonares-ambientales-y-ocupacionales/introducción-a-las-enfermedades-pulmonares-ambientales-y-profesionales>
- [12] «National Institute for Occupational Safety and Health».
- [13] «TEB-APR-STP-0007-508.pdf». Accedido: 16 de noviembre de 2024. [En línea]. Disponible en: <https://www.cdc.gov/niosh/npptl/stps/pdfs/TEB-APR-STP-0007-508.pdf>
- [14] «UNE-EN 149:2001+A1:2010 Dispositivos de protección respiratori...» Accedido: 16 de noviembre de 2024. [En línea]. Disponible en: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0044643>

- [15] I. J. A. Lara, I. C. A. Villagra, E. L. C. Marchant, I. C. F. Tirapegui, y I. P. Q. Barros, «En la elaboración de este protocolo han participado los siguientes profesionales del Departamento de Salud Ocupacional del Instituto de Salud Pública de Chile».
- [16] «Respirator Selection Guide for the Healthcare Industry», nov. 2024, doi: 10.26616/NIOSH PUB2025102.
- [17] «ISO 16900-5:2016», ISO. Accedido: 16 de noviembre de 2024. [En línea]. Disponible en: <https://www.iso.org/standard/52478.html>
- [18] «Simple Linear Regression», en *Regression Analysis by Example*, John Wiley & Sons, Ltd, 2006, pp. 21-51. doi: 10.1002/0470055464.ch2.
- [19] Burges, «A tutorial on support vector machines for pattern recognition». Accedido: 28 de enero de 2026. [En línea]. Disponible en: <https://www.scopus.com/pages/publications/27144489164?inward=>
- [20] «Decision Tree Model - an overview | ScienceDirect Topics». Accedido: 28 de enero de 2026. [En línea]. Disponible en: <https://www.sciencedirect.com/topics/computer-science/decision-tree-model>
- [21] L. Breiman, «Random Forests», *Mach. Learn.*, vol. 45, n.º 1, pp. 5-32, oct. 2001, doi: 10.1023/A:1010933404324.
- [22] «GradientBoostingRegressor», scikit-learn. Accedido: 28 de enero de 2026. [En línea]. Disponible en: <https://scikit-learn/stable/modules/generated/sklearn.ensemble.GradientBoostingRegressor.html>
- [23] T. Chen y C. Guestrin, «XGBoost: A scalable tree boosting system», en *Proc. ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, Association for Computing Machinery, 2016, pp. 785-794. doi: 10.1145/2939672.2939785.
- [24] R. D. Snee, «Validation of Regression Models: Methods and Examples», *Technometrics*, vol. 19, n.º 4, pp. 415-428, 1977, doi: 10.1080/00401706.1977.10489581.
- [25] «Confusion Matrix - an overview | ScienceDirect Topics». Accedido: 8 de enero de 2025. [En línea]. Disponible en: <https://www.sciencedirect.com/topics/engineering/confusion-matrix>
- [26] «Accuracy vs. Precision vs. Recall in Machine Learning: What is the Difference?» Accedido: 15 de diciembre de 2024. [En línea]. Disponible en: <https://encord.com/blog/classification-metrics-accuracy-precision-recall/>
- [27] J. Brownlee, «How to Calculate Precision, Recall, and F-Measure for Imbalanced Classification», *MachineLearningMastery.com*. Accedido: 8 de enero de 2025. [En línea]. Disponible en: <https://www.machinelearningmastery.com/precision-recall-and-f-measure-for-imbalanced-classification/>
- [28] «F1 Score in Machine Learning: Intro & Calculation». Accedido: 8 de enero de 2025. [En línea]. Disponible en: <https://www.v7labs.com/blog/f1-score-guide>
- [29] «Receiver Operating Characteristic - an overview | ScienceDirect Topics». Accedido: 28 de enero de 2026. [En línea]. Disponible en: <https://www.sciencedirect.com/topics/engineering/receiver-operating-characteristic>
- [30] «Probability of Detection - an overview | ScienceDirect Topics». Accedido: 28 de enero de 2026. [En línea]. Disponible en: <https://www.sciencedirect.com/topics/engineering/probability-of-detection>
- [31] «LeaveOneOut», scikit-learn. Accedido: 28 de enero de 2026. [En línea]. Disponible en: https://scikit-learn/stable/modules/generated/sklearn.model_selection.LeaveOneOut.html

- [32] Y. Liu, J. Corey, M. V. Yermakov, B. Wu, y S. A. Grinshpun, «Preliminary Development of a Real-Time Respirator Seal Integrity Monitor With Low-Cost Particle Sensor», *IEEE Trans. Ind. Appl.*, vol. 54, n.º 4, pp. 3928-3933, jul. 2018, doi: 10.1109/TIA.2018.2816907.
- [33] K. McClure, B. Erdreich, J. H. T. Bates, R. S. McGinnis, A. Masquelin, y S. Wshah, «Classification and Detection of Breathing Patterns with Wearable Sensors and Deep Learning», *Sensors*, vol. 20, n.º 22, p. 6481, nov. 2020, doi: 10.3390/s20226481.
- [34] Z. Ye, «A Breathable, Reusable, and Zero-Power Smart Face Mask for Wireless Cough and Mask-Wearing Monitoring», *ACS Nano*, vol. 16, n.º 4, pp. 5874-5884, abr. 2022, doi: 10.1021/acsnano.1c11041.
- [35] J. Suo, «Wide-Bandwidth Nanocomposite-Sensor Integrated Smart Mask for Tracking Multiphase Respiratory Activities», *Adv. Sci.*, vol. 9, n.º 31, p. 2203565, 2022, doi: 10.1002/advs.202203565.
- [36] V. Ratnayake Mudiyansele, K. Lee, y A. Hassani, «Integration of IoT Sensors to Determine Life Expectancy of Face Masks», *Sensors*, vol. 22, n.º 23, p. 9463, dic. 2022, doi: 10.3390/s22239463.
- [37] P. Aqueveque, «Embedded Electronic Sensor for Monitoring of Breathing Activity, Fitting and Filter Clogging in Reusable Industrial Respirators», *Biosensors*, vol. 12, n.º 11, p. 991, nov. 2022, doi: 10.3390/bios12110991.
- [38] A. Manchanda, K. Lee, G. D. Poznanski, y A. Hassani, «Automated Adjustment of PPE Masks Using IoT Sensor Fusion», *Sensors*, vol. 23, n.º 3, Art. n.º 3, ene. 2023, doi: 10.3390/s23031711.
- [39] H. Cheraghi Bidsorkhi, «Wearable Graphene-based smart face mask for Real-Time human respiration monitoring», *Mater. Des.*, vol. 230, p. 111970, jun. 2023, doi: 10.1016/j.matdes.2023.111970.
- [40] C. Romano, A. Nicolò, L. Innocenti, M. Sacchetti, E. Schena, y C. Massaroni, «Design and Testing of a Smart Facemask for Respiratory Monitoring during Cycling Exercise», *Biosensors*, vol. 13, n.º 3, p. 369, mar. 2023, doi: 10.3390/bios13030369.
- [41] D. Ponce y E. Toledo, «Design and Development of Electronic Devices for Assessing Correct Use of Respirator Masks at Workplaces», *IEEE Instrum. Meas. Mag.*, vol. 27, n.º 2, pp. 23-29, abr. 2024, doi: 10.1109/MIM.2024.10472983.
- [42] «NIOSH Policy Statement: Respiratory protection recommendations for airborne exposures to crystalline silica | 2013-01-02 | ISHN». Accedido: 28 de enero de 2026. [En línea]. Disponible en: <https://www.ishn.com/articles/94795-niosh-policy-statement-respiratory-protection-recommendations-for-airborne-exposures-to-crystalline-silica>
- [43] J. Wiley, «erosol Technology Properties, Behavior, and Measurement of Airborne Particles».
- [44] T. Xia y C. Chen, «Evolution of pressure drop across electrospun nanofiber filters clogged by solid particles and its influence on indoor particulate air pollution control», *J. Hazard. Mater.*, vol. 402, p. 123479, ene. 2021, doi: 10.1016/j.jhazmat.2020.123479.
- [45] G. O. Nelson y C. A. Harder, «Respirator cartridge efficiency studies: VI. Effect of concentration», *Am. Ind. Hyg. Assoc. J.*, vol. 37, n.º 4, pp. 205-216, abr. 1976, doi: 10.1080/0002889768507444.
- [46] G. Favas, «End of Service Life Indicator (ESLI) for Respirator Cartridges, Part I: Literature Review».

- [47] A. Gupta, P. Biswas, P. R. Monson, y V. J. Novick, «Effect of humidity and particle hygroscopicity on the mass loading capacity of high efficiency particulate air (HEPA) filters», *Aerosol Sci. Technol. U. S.*, vol. 19:1, jul. 1993, doi: 10.1080/02786829308959624.
- [48] D. I. A. Dhanraj, «Size-Dependent Filtration Efficiency of Alternative Facemask Filter Materials», *Materials*, vol. 14, n.º 8, p. 1868, abr. 2021, doi: 10.3390/ma14081868.
- [49] X. He, M. Yermakov, T. Reponen, R. T. McKay, K. James, y S. A. Grinshpun, «Manikin-Based Performance Evaluation of Elastomeric Respirators Against Combustion Particles», *J. Occup. Environ. Hyg.*, vol. 10, n.º 4, pp. 203-212, abr. 2013, doi: 10.1080/15459624.2012.760063.
- [50] R. J. Roberge, J.-H. Kim, J. B. Powell, R. E. Shaffer, C. M. Ylitalo, y J. M. Sebastian, «Impact of Low Filter Resistances on Subjective and Physiological Responses to Filtering Facepiece Respirators», *PLOS ONE*, vol. 8, n.º 12, p. e84901, dic. 2013, doi: 10.1371/journal.pone.0084901.
- [51] «Cartridge and Filter Replacement | Worker Health & Safety | 3M US». Accedido: 28 de enero de 2026. [En línea]. Disponible en: https://www.3m.com/3M/en_US/worker-health-safety-us/personal-protective-equipment/respirator-cartridge/
- [52] «Permissible Exposure Limits – OSHA Annotated Table Z-1 | Occupational Safety and Health Administration». Accedido: 26 de enero de 2026. [En línea]. Disponible en: <https://www.osha.gov/annotated-pels/table-z-1>
- [53] «Aerosol Technology: Properties, Behavior, and Measurement of Airborne Particles, 2nd Edition | Wiley», Wiley.com. Accedido: 28 de diciembre de 2025. [En línea]. Disponible en: <https://www.wiley.com/en-gb/Aerosol+Technology%3A+Properties%2C+Behavior%2C+and+Measurement+of+Airborne+Particles%2C+2nd+Edition-p-9781118591970>