

ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA

ARQUITECTURA PARA SISTEMAS IOT

**ESTUDIO DE LAS ALTERNATIVAS QUE PERMITAN MEJORAR EL
RENDIMIENTO ACADÉMICO DE ESTUDIANTES
UNIVERSITARIOS, A TRAVÉS DEL MONITOREO DEL AMBIENTE
DE ESTUDIO, UTILIZANDO APLICACIONES IOT.**

**TRABAJO DE INTEGRACIÓN CURRICULAR PRESENTADO COMO
REQUISITO PARA LA OBTENCIÓN DEL TÍTULO DE INGENIERO EN
INGENIERÍA EN TECNOLOGÍAS DE LA INFORMACIÓN**

DANILO SEBASTIAN CHICANGO QUEL

danilo.chicango@epn.edu.ec

DIRECTOR: SORAYA LUCÍA SINCHE MAITA

soraya.sinche@epn.edu.ec

DMQ, abril 2023

CERTIFICACIONES

Yo, DANILO SEBASTIAN CHICANGO QUEL declaro que el trabajo de integración curricular aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.



DANILO SEBASTIAN CHICANGO QUEL

Certifico que el presente trabajo de integración curricular fue desarrollado por DANILO SEBASTIAN CHICANGO QUEL, bajo mi supervisión.



SORAYA LUCÍA SINCHE MAITA
DIRECTOR

DECLARACIÓN DE AUTORÍA

A través de la presente declaración, afirmamos que el trabajo de integración curricular aquí descrito, así como el (los) producto(s) resultante(s) del mismo, son públicos y estarán a disposición de la comunidad a través del repositorio institucional de la Escuela Politécnica Nacional; sin embargo, la titularidad de los derechos patrimoniales nos corresponde a los autores que hemos contribuido en el desarrollo del presente trabajo; observando para el efecto las disposiciones establecidas por el órgano competente en propiedad intelectual, la normativa interna y demás normas.



DANILO SEBASTIAN CHICANGO QUEL



SORAYA LUCÍA SINCHE MAITA, PHD

DEDICATORIA

Este trabajo va dedicado a mi familia, quienes han sido la base de mi formación personal y académica, ellos han sabido guiarme en toda circunstancia que tuve que enfrentar y que sin duda me apoyarán en las que están por venir. A mis amigos, con los que pasé toda mi vida universitaria llena de momentos de regocijo y hermandad y de los cuales me llevo mucho aprendizaje.

AGRADECIMIENTO

A mis padres

Por su ejemplo, paciencia y apoyo incondicional en todo momento

A mis amigos

Por los momentos pasados, que sin duda serán un grato recuerdo para todos.

A la PhD, Soraya Sinche

Por todo el conocimiento brindado, no solo en este trabajo si no en el transcurso de mi carrera.

A la Escuela Politécnica Nacional

Por abrirme las puertas a descubrir el mundo de la ciencia y la tecnología.

ÍNDICE DE CONTENIDO

CERTIFICACIONES	I
DECLARACIÓN DE AUTORÍA	II
DEDICATORIA	III
AGRADECIMIENTO	IV
ÍNDICE DE CONTENIDO.....	V
ÍNDICE DE FIGURAS	VIII
ÍNDICE DE TABLAS	IX
RESUMEN	X
ABSTRACT.....	XI
1. DESCRIPCIÓN DEL COMPONENTE DESARROLLADO	1
1.1. Objetivo General	1
1.2. Objetivos Específicos.....	2
1.3. Alcance	2
1.4. Marco Teórico	2
1.4.1. Factores que influyen en el rendimiento académico de estudiantes universitarios	3
1.4.2. Indicadores del rendimiento académico	4
1.4.3. La Iluminación.....	5
1.4.4. Definiciones generales de iluminación.....	6
1.4.5. Componentes para una buena visibilidad.....	7
1.4.6. Confort visual.....	7
1.4.7. Medición del nivel de iluminación.....	8
1.4.8. Efectos de la iluminación en un ambiente de estudio	8
1.4.9. El Ruido	9
1.4.10. Efectos en la salud causados por el ruido	9
1.4.11. Definición de un sistema IoT	10
1.4.12. Sensores disponibles en un teléfono móvil.....	11
1.4.13. Técnicas de Aprendizaje de Máquina	11
2. METODOLOGÍA.....	13
2.1. Casos de estudio de iluminación.....	15
2.1.1. Caso 1: Optimización de iluminación natural al interior de una habitación en un campus universitario	15
2.1.2. Caso 2: Análisis comparativo de la sensibilidad espectral de luxómetros y sensores de luz en smartphones.....	15

2.1.3.	Caso 3: Análisis de confort visual utilizando redes neuronales difusas.....	16
2.1.4.	Caso 4: Comparación del rendimiento de algoritmos de aprendizaje automático en la predicción de iluminación diurna en espacios interiores.....	17
2.1.5.	Caso 5: Modelo para evaluar luz diurna haciendo uso de redes neuronales.....	17
2.1.6.	Caso 6: Comparación de algoritmos Random Forest y Artificial Neural Network en la predicción del consumo energético e iluminación de la luz diurna	18
2.1.7.	Caso 7: Investigación del nivel de confort visual individual empleando aprendizaje automático en China	18
2.2.	Casos de estudio de análisis de ruido	20
2.2.1.	Caso 1: Modelo de regresión aplicado al estudio del conocimiento y actitud de estudiantes acerca del uso de PLDs	20
2.2.2.	Caso 2: Generación de un mapa de ruido aplicado a un campus universitario causado por el tráfico en los alrededores de la institución.....	21
2.2.3.	Caso 3: Aplicación de clusterización para detectar eventos de ruido en una base de datos multitudinaria	21
2.2.4.	Caso 4: Predicción de ruido usando aprendizaje automático con análisis de medidas	22
2.2.5.	Caso 5: Predicción del ruido producido por el tráfico en la ciudad de Patiala en India usando aprendizaje automático	22
2.2.6.	Caso 6: Uso de aprendizaje automático para predecir los límites sonoros de un motor automotriz durante su aceleración	23
2.2.7.	Caso 7: Predicción de ruido molesto mediante el uso de aprendizaje automático	23
2.2.8.	Caso 8: Uso de técnicas de aprendizaje automático para predecir el ruido generado por objetos aerodinámicos	23
2.3.	Alternativa para detección del nivel de confort del ambiente de estudio..	26
2.3.1.	Recolección de datos	27
2.3.2.	Tratamiento de datos.....	28
2.3.3.	Procesamiento de datos.....	28
2.3.4.	Propuesta de Aplicación Móvil	29
3.	RESULTADOS, CONCLUSIONES Y RECOMENDACIONES	39
3.1.	Resultados	39
3.1.1.	Comparación de uso de los algoritmos de aprendizaje máquina empleados en los casos de estudio.....	39
3.1.2.	Comparación de las métricas de rendimiento de los algoritmos de aprendizaje de máquina analizados en los casos de estudio.....	42
3.1.3.	Comparación de factores de iluminación y ruido analizados en los casos de estudio	43
3.1.4.	Propuesta de correlación de parámetros de rendimiento académico con medidas de iluminación y ruido obtenidas por sensores	46

3.1.5. Consideraciones para implementar una aplicación móvil para detección del nivel de ambiente de estudio	46
3.2. Conclusiones	48
3.3. Recomendaciones	49
4. REFERENCIAS BIBLIOGRÁFICAS.....	50
5. ANEXOS	
ANEXO I.1 Tablero Kanban (Semana 9)	
ANEXO II.1 Comparación de parámetros de rendimiento para algoritmos usados en estudios de iluminación	
ANEXO II.2 Comparación de parámetros de rendimiento para algoritmos usados en estudios de ruido	

ÍNDICE DE FIGURAS

Figura 1.1	Espectro de luz visible dentro del espectro electromagnético [20].	6
Figura 1.2	Relación de flujo luminoso, intensidad luminosa e iluminancia [21]	7
Figura 1.3	Temperatura de color [20].	7
Figura 1.4	Fases de un sistema IoT basado en [32]	10
Figura 1.5	Taxonomía de las técnicas de aprendizaje máquina más empleadas en el campo de la medicina y minería de texto.	12
Figura 2.1	Captura de estado del tablero Kanban en la semana 6.	14
Figura 2.2	Flujo de trabajo para la detección de nivel de confort.	27
Figura 2.3	Posición sugerida del smartphone para el funcionamiento de la aplicación móvil.	28
Figura 2.4	Diagrama de flujo de la fase de procesamiento de datos	29
Figura 2.5	Interfaz de inicio de la aplicación	30
Figura 2.6	Interfaz de recuperación de contraseña	31
Figura 2.7	Interfaz de registro de una cuenta	32
Figura 2.8	Funciones principales de la aplicación	32
Figura 2.9	Interfaz de la función "Perfil"	33
Figura 2.10	Interfaz de la función "Encuestas"	34
Figura 2.11	Interfaz de encuesta diaria (a); encuesta académica (b)	35
Figura 2.12	Notificación como recordatorio para llenar la encuesta diaria	35
Figura 2.13	Interfaz para iniciar el monitoreo en tiempo real (a); durante monitoreo en tiempo real (b).	36
Figura 2.14	Interfaz de resultados generales (a); resultados por fecha (b)	37
Figura 2.15	Interfaz de usuarios (a); interfaz de los registros de un usuario (b); interfaz de resultados de un usuario en una fecha en específica (c), vistas desde la cuenta de administrador.	38
Figura 3.1	Porcentaje de uso de tipos de algoritmos en análisis de la iluminación	40
Figura 3.2	Porcentaje individual del uso de algoritmos en el análisis de la iluminación	40
Figura 3.3	Porcentaje de uso de tipos de algoritmos en análisis del ruido	41
Figura 3.4	Porcentaje individual del uso de algoritmos en el análisis del ruido	42
Figura 3.5	Factores analizados en los casos de estudio de iluminación	44
Figura 3.6	Factores analizados en los casos de estudio de ruido	45

ÍNDICE DE TABLAS

Tabla 1.1 Factores cualitativos asociados al rendimiento académico en estudiantes universitarios [5]–[7].	3
Tabla 1.2 Factores cuantitativos que afectan el rendimiento académico de estudiantes universitarios [13].	4
Tabla 1.3 Indicadores de rendimiento académico, basados en [14]–[16].	5
Tabla 1.4 Valores recomendados de iluminación en base de [20].	8
Tabla 1.5 Niveles de ruido recomendados de acuerdo a [31].	9
Tabla 1.6 Principales sensores disponibles en teléfonos inteligentes [35].	11
Tabla 2.1 Smartphones y sensores de luz usados en [25].	16
Tabla 2.2 Rendimiento en términos de precisión de los algoritmos comparados en [48].	19
Tabla 2.3 Herramientas y software usados por los casos de estudio de iluminación.	19
Tabla 2.4 Algoritmos usados en casos de estudio de iluminación con métrica de rendimiento R^2 .	20
Tabla 2.5 Algoritmos usados en casos de estudio de ruido empleando la precisión como métrica de rendimiento.	24
Tabla 2.6 Herramientas, software y sensores usados por los casos de estudio de ruido.	24
Tabla 2.7 Algoritmos usados en casos de estudio de ruido con métrica de rendimiento RMSE.	25
Tabla 2.8 Parámetros usados en los casos de estudio para determinar el nivel de confort de iluminación y ruido.	26

RESUMEN

Hay varios factores del ambiente de estudio que afectan el rendimiento académico de jóvenes universitarios, entre ellos destacan el ruido y la iluminación. Por lo tanto, es importante analizar alternativas para trabajar sobre estas dos variables y que así se pueda mejorar del desempeño de los estudiantes.

En este contexto, se realiza una investigación de casos de estudio que tengan como eje principal los parámetros de iluminación y ruido. Con ello se extrae por medio de tablas, información como los algoritmos de machine learning utilizados junto con las métricas de rendimiento para evaluarlos, sensores y herramientas usadas en las investigaciones; así como los factores considerados para establecer un ambiente adecuado en temas de iluminación y ruido. Posteriormente se propone una alternativa para a futuro implementar una aplicación móvil que hace uso del smartphone de los estudiantes como dispositivo IoT, para capturar niveles de iluminancia y ruido y con eso determinar el nivel de confort que percibe el estudiante.

El trabajo está segmentando en 3 capítulos. El primer capítulo detalla factores que influyen en el rendimiento académico, indicadores para medirlo, conceptos básicos de iluminación, ruido, sistemas IoT, sensores en un smartphone y algoritmos de machine learning. El segundo capítulo hace una revisión de varios artículos enfocados en el análisis de iluminación y ruido; además de proponer una aplicación móvil de monitoreo del ambiente de estudio. El tercer capítulo hace una comparación de los artículos a nivel de algoritmos de aprendizaje de máquina y factores que determinen el nivel de confort del ambiente de estudio, para finalmente presentar las conclusiones y recomendaciones obtenidas.

PALABRAS CLAVE: smartphone, iluminancia, detección de ruido, rendimiento académico, ambiente de estudio.

ABSTRACT

There are several factors in the study environment that affect the academic performance of young university students, among these factors are noise and lighting. Therefore, it's important to analyze alternatives to work on these two variables to improve student performance.

In this context, an investigation of a case study is carried out that has as main goal noise and lighting parameters. With this, information such as machine learning algorithms used is extracted, together with the performance metrics to evaluate, sensors and tools used in the research, as well as the factors considered to establish an adequate environment in terms of noise and lighting. Subsequently, an alternative mobile application to apply in the future is proposed that makes use of students' smartphones as an IoT device, to capture illumination and noise levels and thereby, determine the comfort level perceived by the student.

This study is divided into three chapters. The first one details the factors that influence academic performance, indicators to measure it, basic concepts of noise, lighting, IoT systems, smartphones' sensors, and algorithms of machine learning. In the second chapter, there is a review of some articles focused on the analyses of illumination and noise, moreover, it proposes a mobile application to monitor the environment of study. The third chapter makes a comparison of the articles at the level of machine learning logarithms, evaluation metrics and factors that determine the comfort level of the study environment, so finally present the conclusions and recommendations obtained.

KEYWORDS: smartphone, illuminance, noise detection, academic performance, study environment.

1. DESCRIPCIÓN DEL COMPONENTE DESARROLLADO

Los sistemas IoT (*Internet of Things*) son en la actualidad una tecnología que está interactuando en muchos aspectos y campos de la sociedad, por mencionar algunos se tiene hogares inteligentes, aplicaciones destinadas a la supervisión ambiental, atención médica, usos en el sector militar, vigilancia y monitoreo industrial [1]. Los dispositivos móviles son parte de estos sistemas e incluyen varias funcionalidades como recopilar una gran cantidad de información por medio de sensores, que puede ser utilizada para diferentes fines según el campo de aplicación y estudio [2], [3]. Sin embargo, tener la información y no darle un uso es malgastar los recursos que se tiene a disposición, por lo que la información debe ser tratada, para de esa manera proporcionarle un valor de utilidad. Es aquí donde se involucra a las técnicas de aprendizaje de máquina, que pueden ser clasificadas como supervisadas o no supervisadas; con ellas se puede estar en la plena capacidad de realizar predicciones o inferir estados, dependiendo del caso de estudio y datos con los que se entrene el algoritmo, así como permitir la toma de decisiones con una mayor tasa de certeza.

Por otra parte, el ritmo de vida que llevan los estudiantes universitarios y el ambiente de estudio en donde se desenvuelven pueden llegar a influir en su desempeño académico [4]. El rendimiento académico se lo puede definir como el resultado de la interacción de diferentes factores que inciden en aquel individuo que esté en el transcurso de una etapa de aprendizaje, dicho rendimiento por lo general puede medirse de acuerdo a las calificaciones que se obtiene y gracias a lo cual es posible dimensionar el grado de éxito o fracaso académico de un estudiante [5]. Es aquí donde los sistemas IoT, gracias a su diversificada utilidad, juegan un papel muy importante en el estudio de este hecho, ya que por medio de la información recopilada, se podrá determinar en qué medida aspectos como el nivel de ruido o de iluminación en el ambiente de estudio, que son los ejes de estudio de este proyecto, influyen en el rendimiento académico de los alumnos.

En base a lo mencionado, este proyecto tiene como objetivo estudiar alternativas que permitan mejorar el rendimiento académico de estudiantes universitarios, en función de un ambiente de estudio adecuado, mediante la utilización de aplicaciones IoT en dispositivos móviles.

1.1. Objetivo General

Analizar las alternativas que permitan mejorar el rendimiento académico de estudiantes universitarios, a través del monitoreo del ambiente de estudio, utilizando aplicaciones IoT.

1.2. Objetivos Específicos

1. Estudiar los factores relacionados al ambiente de estudio que influyen en el rendimiento académico de los estudiantes universitarios.
2. Estudiar los sensores disponibles en los teléfonos móviles.
3. Comparar las técnicas de aprendizaje de máquina que pueden utilizarse para inferir las condiciones del ambiente de estudio.

Presentar alternativas para la futura implementación de una aplicación móvil para medir el nivel de confort del ambiente de estudio de un estudiante universitario.

1.3. Alcance

La gestión del componente se realiza en base a la metodología Kanban.

Se recopila información de artículos científicos relacionados con los factores que pueden influir en el rendimiento académico de los estudiantes, asociados con nivel de iluminación y ruido del ambiente de estudio.

Se revisan los sensores disponibles en dispositivos móviles que permitan recoger información acerca de parámetros de iluminación y ruido.

Se presenta un cuadro comparativo de técnicas de aprendizaje de máquina que pueden utilizarse para inferir las condiciones del ambiente de estudio, de manera que se destaquen las características principales de cada una, y con ello se pueda determinar cuál es la más conveniente al momento de inferir un entorno confortable para estudiar, tomando en cuenta los factores de iluminación y ruido.

Como resultado del presente trabajo, se plantean las posibles alternativas que se pueden implementar mediante aplicaciones móviles, que involucren sensores de iluminación y ruido presentes en un teléfono móvil. Con la información recopilada y con técnicas de aprendizaje de máquina se pueda inferir el nivel de confort del ambiente de estudio, en busca del mejoramiento del rendimiento académico de los estudiantes.

1.4. Marco Teórico

En esta sección se presenta de forma general los factores que influyen en el rendimiento académico de estudiantes universitarios, así como los indicadores que se pueden emplear para medirlo. Posteriormente se revisa definiciones generales de iluminación, ruido, sistemas IoT y técnicas de aprendizaje de máquina, y como complemento se incluyen los sensores disponibles en teléfonos móviles.

1.4.1. Factores que influyen en el rendimiento académico de estudiantes universitarios

La etapa académica de los estudiantes universitarios está marcada por diferentes aspectos que pueden afectar su rendimiento académico; y es que como se explica en [5], que el rendimiento académico es multicausal y en él influyen tanto factores externos e internos a la persona. En la **Tabla 1.1** se muestra una recopilación de factores asociados al rendimiento académico en estudiantes universitarios basados en [5]–[7] y que son de carácter cualitativo; mientras que en la **Tabla 1.2** se muestran factores de carácter cuantitativo.

Tabla 1.1 Factores cualitativos asociados al rendimiento académico en estudiantes universitarios [5]–[7].

Factor	Descripción
Motivación	De carácter intrínseca (personal) o extrínseca. Relacionada con aspectos como tipo de Universidad, formación del docente, condiciones económicas, entre otros.
Contexto socioeconómico	Nivel económico y social de la persona. A nivel social relacionado con educación, prestigio familiar, ocupación y etnia y a nivel económico se habla de los ingresos que percibe la persona [8].
Entorno familiar	Referido al nivel de compromiso y confraternidad de los integrantes de la familia, donde se puede lograr una mejora académica si está presente.
Esfuerzo	El tiempo que se dedica para la realización de una tarea [9].
Capital cultural	Facilidades que tiene el alumno como acceso a Internet, o a aquellas actividades que lo puedan enriquecer educativamente.
Variable demográfica	Referido a la distancia entre el lugar de residencia del estudiante y su casa de estudios.
Determinantes institucionales	Metodologías de docentes, horarios de materias, cantidad de alumnos por profesor, dificultad de la materia, etc.
Cualidades del profesor	Relacionadas a la simpatía, respeto, buen humor y motivación que presente el docente [10].
Población de residencia	Si el lugar de residencia del estudiante durante su jornada académica coincide con el de su familia, se reflejará en un mejor rendimiento académico.
Bienestar psicológico	Autoevaluación realizada por un individuo a aspectos de su vida como el trabajo, su vida en familia y sus emociones tanto positivas como negativas para un pleno desarrollo personal [11].

Factor	Descripción
Formación antes de la Universidad	Nivel de educación recibida en las etapas básica, secundaria y preparatoria.
Competencia cognitiva	Autoevaluación de la capacidad del individuo para cumplir una tarea.

El enfoque del proyecto es tratar aquellas variables que en cierto grado puedan ser manipuladas y estén relacionadas con el ambiente de estudio, donde el alumno desempeña su labor de aprendizaje, de tal modo que sea posible controlar el efecto o incidencia sobre los estudiantes y así ver las posibles alternativas que se puedan implementar en busca de su mejoramiento académico.

Dentro de las variables cuantitativas de interés para inferir un ambiente confortable de estudio están el nivel de iluminación y ruido. Estos factores pueden ser medidos y posteriormente controlados en cierta medida; además, también se incluye las horas de estudio como otro factor cuantitativo, aunque podría ser considerado subjetivo, ya que hay la posibilidad de que existan distracciones que impidan que un estudiante realmente se dedique el tiempo que menciona [12]. En la **Tabla 1.2** se da una breve descripción referente a la iluminación y el ruido.

Tabla 1.2 Factores cuantitativos que afectan el rendimiento académico de estudiantes universitarios [13].

Factor	Descripción
Iluminación	Cuantificación de nivel de luz que cae o incurre sobre una superficie.
Ruido	Cualquier sonido que sea considerado como desagradable, que cause disgusto o incomodidad.
Horas de estudio	Cantidad de tiempo medido en horas que una persona dedica a una labor académica [5], [12].

1.4.2. Indicadores del rendimiento académico

El rendimiento académico ha sido el foco central de varios estudios, en donde el indicador más empleado corresponde a las calificaciones como se menciona en [14]; sin embargo, existen otros indicadores que pueden ser tomados en cuenta para determinar el rendimiento académico de los estudiantes. En la **Tabla 1.3** se muestra algunos indicadores de rendimiento académico según [14]–[16].

Tabla 1.3 Indicadores de rendimiento académico, basados en [14]–[16]

Indicador	Cómo se obtiene
Promedio de calificaciones	Suma de los valores de calificaciones sobre la cantidad de calificaciones.
Avance en la carrera	Créditos acumulados durante cierto período de tiempo sobre los créditos que en teoría debió acumular en dicho período según el Plan de estudios establecido.
Basado en créditos	Número de créditos acumulados en un período de tiempo; o como número de créditos acumulados sobre créditos matriculados.
Tasa de rendimiento	Número de créditos que aprueba en un curso sobre el total en que se matriculó en el mismo.
Tasa de éxito	Número de créditos aprobados.
IRA (Índice de Rendimiento Académico)	Indicador del rendimiento académico de un estudiante durante carrera universitaria. $IRA = PPC * CA$ Donde: <ul style="list-style-type: none"> • PPC: Promedio ponderado de calificaciones • CA: Coeficiente de aprobación

1.4.3. La Iluminación

El concepto de iluminación hace referencia al efecto y acción de dar luz a un objeto [17]. Su grado de importancia está relacionado con la capacidad que tiene el ser humano de adaptarse al ambiente que lo rodea, por lo que niveles de iluminación poco eficientes, pueden afectar su bienestar en aspectos como el estado mental y grado de fatiga o incluso que cometa errores en actividades laborales, educativas, entre otras [18], [19].

La luz que percibe el ser humano es una parte del Espectro Electromagnético, a dicha sección se la conoce como Espectro visible [20], la cual corresponde a un rango de longitud de onda entre 380nm y 780nm. En la **Figura 1.1** se puede observar el Espectro Electromagnético junto con la sección que corresponde al Espectro Visible para el ser humano.

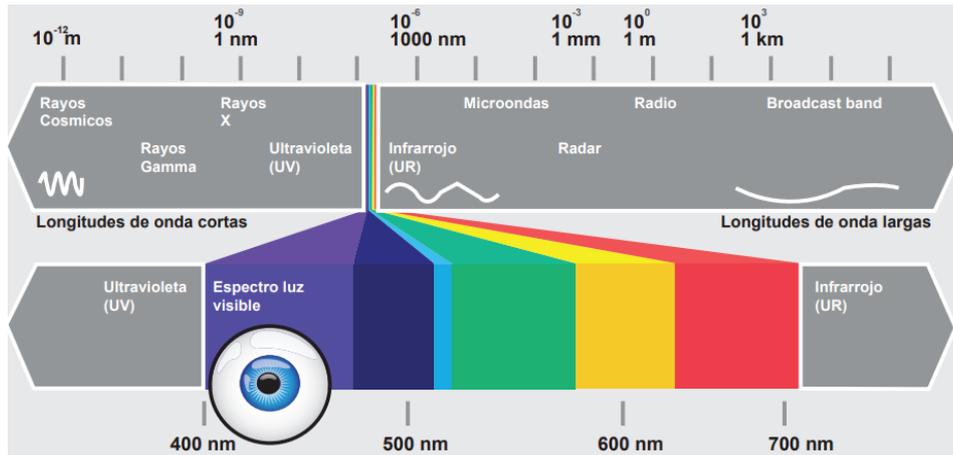


Figura 1.1 Espectro de luz visible dentro del espectro electromagnético [20].

1.4.4. Definiciones generales de iluminación

Basado en el manual técnico de iluminación de Sylvania, se definen los siguientes conceptos básicos: [20]

- **Flujo Luminoso:** Cantidad de energía luminosa que es radiada o producida por una fuente y que puede ser apreciada, en el Sistema Internacional de Unidades (SI) su unidad es el lumen [lm].
- **Iluminancia o Nivel de Iluminación:** Cantidad de luz que cae o incurre sobre una superficie por unidad de área. Su unidad de medida es el lux [lx] en el SI.
- **Intensidad Luminosa:** Cantidad de flujo luminoso que es emitido por alguna fuente por unidad de ángulo sólido, es decir en una dirección determinada. Su unidad en el SI es la candela [cd].

Temperatura del color: Comparación del color que emite una fuente en el espectro luminoso con el que emitiría un cuerpo negro calentado a una cierta temperatura, su unidad en el SI es Kelvin.

La relación entre flujo luminoso, intensidad luminosa e iluminancia se puede observar en la **Figura 1.2.**, mientras que en la **Figura 1.3** se muestra la temperatura de color.

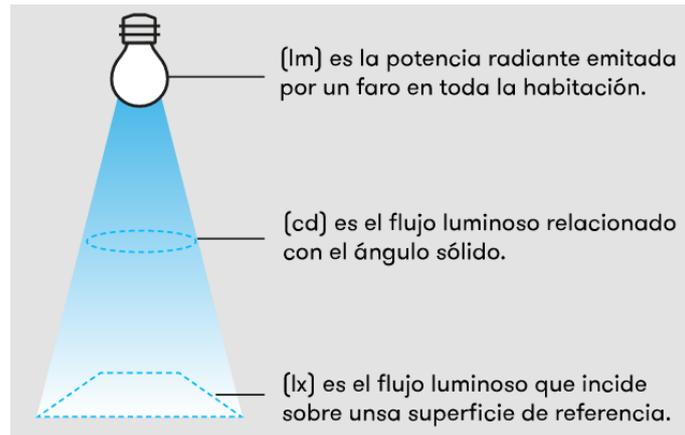


Figura 1.2 Relación de flujo luminoso, intensidad luminosa e iluminancia [21]

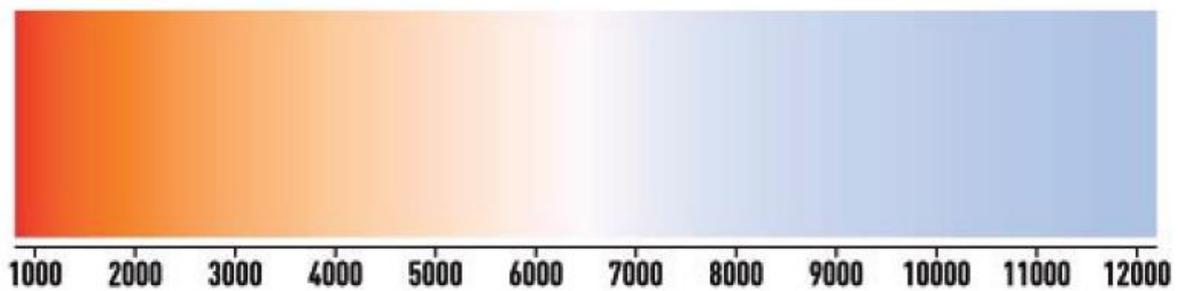


Figura 1.3 Temperatura de color [20]

1.4.5. Componentes para una buena visibilidad

Para una mejor apreciación visual sobre nuestro entorno y los elementos que lo componen, se considera 3 componentes principales: ángulo visual, contraste e iluminancia.

El ángulo visual hace referencia al ángulo en que el ojo humano puede apreciar los objetos que esté enfocando; por su parte el contraste es la diferencia de luminancia (cantidad de luz que se refleja) entre el objeto observado y su fondo [13] y la iluminancia es la cantidad de luz que cae sobre una superficie.

En este contexto, un parámetro importante a tomarse en cuenta al hablar de iluminación para inferir un ambiente confortable será el nivel de iluminancia, para poder trabajar con la medida de la cantidad de luz que cae sobre la superficie del escritorio del estudiante.

1.4.6. Confort visual

Para lograr un confort visual se debe tener una armonía entre una cantidad de variables que varían dependiendo de la actividad que se vaya a desenvolver [22]. De manera general se recomienda usar luz natural en la medida de lo posible, como se menciona en [22]; sin embargo, los estudiantes universitarios, por la naturaleza de su actividad, se ven obligados a emplear también luz artificial producida por diversas fuentes como lámparas LED,

incandescentes, fluorescentes, entre otras. Por ese motivo organizaciones establecen valores recomendados de nivel de iluminación en función de áreas y las actividades inherentes a ellas.

Según lo presentado en [20], que está basado en normativas del Instituto de Normas Técnicas de Costa Rica (INTECO) y del *Illuminating Engineering Society* (IESNA), señala que el nivel de iluminación para áreas de enseñanza en los salones de clase debe tener un mínimo de 200 Lux, 500 Lux se considera bueno y 1000 Lux muy bueno; mientras que para los dormitorios se debe tener mínimo 50 Lux, 100 Lux es bueno y 250 Lux muy bueno.

En cuanto a la temperatura del color, en [23] se menciona que los valores de 3000K a 6000K son percibidos como una luz natural con sensación placentera y comfortable, pero para una mayor concentración se requiere una temperatura superior a 5300K.

Tabla 1.4 Valores recomendados de iluminación en base de [20]

Iluminación	Salones de clase [lx]	Dormitorios [lx]
Mínimo	200	50
Bueno	500	100
Muy bueno	1000	250

1.4.7. Medición del nivel de iluminación

Para medir el nivel de iluminación se puede emplear un luxómetro, que es un dispositivo que mide la cantidad de iluminancia que es ejercida por una fuente sobre un área determinada y la convierte en señal eléctrica para ser mostrada posteriormente en unidades de Lux [18], [24]. La precisión de cada dispositivo dependerá de factores como el número de filtros que use y el costo, como se detalla en [25].

1.4.8. Efectos de la iluminación en un ambiente de estudio

Una falta de iluminación puede influir negativamente en el estado anímico de una persona, haciendo que el cerebro no procese adecuadamente la información; además puede generar cansancio, fatiga muscular, incrementar el estrés, producir falta de atención, depresión, e incluso causar accidentes [19], [26].

Por otro lado, una iluminación adecuada es capaz de causar un mejoramiento anímico y de rendimiento académico [26]. El sistema *School/Vision* de Philips permite acondicionar la iluminación a 4 escenarios diferentes (estándar, energy, focus y calm), dicho sistema fue usado en 2009, demostrando que los estudiantes de una Clínica de Psicología Infantil en Hamburgo-Eppendorf incrementaron en un 35% la velocidad de lectura en comparación cuando usaban luz tradicional. Así mismo, un estudio de 1999 con 21000 estudiantes de

Estados Unidos demostró que el 25% de ellos tuvieron mejores calificaciones en exámenes cuando se usaba más luz natural [26].

1.4.9. El Ruido

El ruido hace referencia a vibraciones de objetos que producen ondas sucesivas que se expanden y comprimen, y que para su transporte utilizan medios como el agua o aire [13]. Dichas vibraciones deben estar dentro del rango de los 20 a 20000 Hertz, para poder ser percibidas por el oído humano [13].

La unidad de medida del ruido es el decibel, el cual representa la intensidad de un sonido producido teniendo como referencia a otro conocido, mediante la relación de voltaje, intensidad, potencia, entre otros [27]; se expresa en dB, y en dBA cuando se usa un filtro de ponderación[28]. El decibel es utilizado debido a la diversidad de intensidades sonoras presentes en la naturaleza y a que el oído humano interpreta los sonidos de una manera aproximadamente logarítmica [13], [29]. Para poder medir el nivel de ruido de un entorno se puede utilizar un sonómetro, dicho elemento trabaja en función de la cantidad de contaminación acústica que detecta en su medio. Suelen utilizarse en diferentes rangos de frecuencias y los campos de aplicación van desde el sector industrial, oficinas o incluso en el hogar [30].

1.4.10. Efectos en la salud causados por el ruido

Cuando una persona está expuesta a valores de frecuencias entre 2400 y 4800 Hz poco a poco irá experimentando una especie de sordera [13], En general la exposición durante tiempos prolongados a altas frecuencias hace que el oído se lastime [13] y es la principal causa de que una persona pierda paulatinamente el sentido del oído. Según [31], los niveles sugeridos de exposición al ruido deben estar entre 68.3 y 84.3 dBA como promedio y entre 96.7 y 107 dBA como valores máximos, de acuerdo a organismos como el *National Institute of Occupational Safety and Health* (NIOSH) y *Occupational Safety and Health Administration* (OSHA).

Tabla 1.5 Niveles de ruido recomendados de acuerdo a [31]

	Nivel de ruido [dBA]
Mínimo	68.3
Máximo	84.3

1.4.11. Definición de un sistema IoT

Un sistema IoT (*Internet of Things*) de acuerdo con [32] está compuesto por 4 bloques: “Cosas”, “Comunicación”, “Computación y Almacenamiento”, y “Servicios y Aplicaciones”, como se muestra en la **Figura 1.4**.

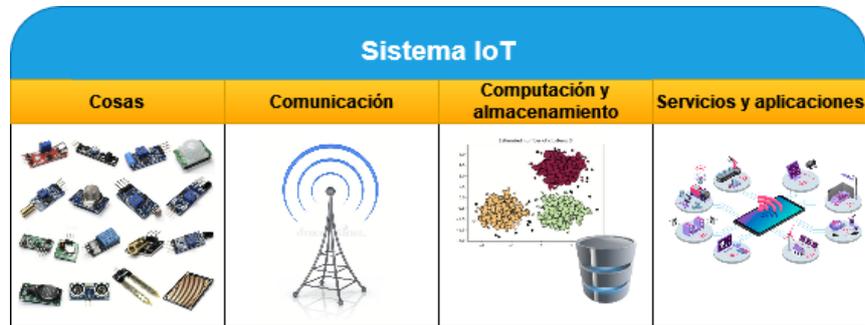


Figura 1.4 Fases de un sistema IoT basado en [32]

- **Cosas:** Sensores o dispositivos móviles, que recolectan información. Cada dispositivo es identificado en una red IoT por métodos como el *Electronic Product Code* (EPC), el *uCode* [33] o direcciones IP.
- **Comunicación:** Infraestructura de red que permite el transporte de los datos de los sensores de un sitio a otro. Se pueden emplear tecnologías como: Bluetooth, WiFi, LTE, Zigbee, entre otros.
- **Computación y almacenamiento:** Análisis, procesamiento y almacenamiento de datos por medio de sistemas como *Machine Learning* e Inteligencia Artificial (IA); además, dada la gran cantidad de dispositivos que se pueden conectar a una red IoT, la masiva información que se genera debe de procesarse y almacenarse usando herramientas de Big Data como redes en la nube.
- **Servicios y aplicaciones:** Es la última fase de todo el sistema IoT, aquí los datos ya han sido convertidos en servicios como aplicaciones de usuario.

Debido a que los dispositivos IoT recopilan gran cantidad de información, se puede aprovechar la misma para estudios y posteriormente definir aplicaciones en diferentes campos. El hecho de que estos elementos involucren varios sensores abre las puertas a la posibilidad de trabajar con los datos de sensores de modo que se ofrezcan alternativas de solución a varios problemas; por ejemplo, intentando determinar un ambiente confortable para estudiar.

1.4.12. Sensores disponibles en un teléfono móvil

Los teléfonos móviles en la actualidad traen incorporados una gran variedad de sensores con múltiples finalidades. Dentro de los sensores más comunes presentes en los teléfonos inteligentes se tiene el magnetómetro, micrófono, cámara, giroscopio y acelerómetro [34]. Pero los nuevos dispositivos traen presente otros tipos de sensores que se han ido incorporando con el pasar del tiempo, haciendo que cada vez más los teléfonos inteligentes se conviertan en una verdadera herramienta de uso diario. En la **Tabla 1.6** se muestra un listado de los sensores presentes en los dispositivos móviles con la variable que cada uno detecta [35].

Tabla 1.6 Principales sensores disponibles en teléfonos inteligentes [35]

Sensor	Variable medida
Acelerómetro	Aceleración en función de la posición en coordenadas x, y, z [36].
Micrófono	Captación de sonido, nivel de ruido.
Proxímetro	Bloqueo/desactivación de pantalla.
Barómetro/Sensor de Presión	Determinación de la presión atmosférica.
Receptor GPS	Geolocalización.
Giroscopio	Rotación del dispositivo.
Cámara	Captura de imágenes.
Luxómetro	Brillo de la pantalla.
Magnetómetro	Medición del campo magnético.

1.4.13. Técnicas de Aprendizaje de Máquina

El aprendizaje de máquina constituye una rama de la IA por medio de la cual se intenta imitar procesos basados en el comportamiento humano. Se clasifican en dos grupos: supervisados y no supervisados [37].

- **Técnicas de aprendizaje supervisado:** Se caracteriza por tener datos “etiquetados”, es decir, que de entrada se conoce qué es lo que se espera en la salida o respuesta del algoritmo.

Dentro de este grupo existen los algoritmos de clasificación y regresión.

- **Algoritmo de clasificación:** En función de los datos de entrada, el algoritmo los agrupa según características semejantes que encuentre entre ellos y a los nuevos datos que ingresen los clasificará en alguno de estos grupos que ha formado previamente.

- **Algoritmo de regresión:** Devuelve un número a la salida del algoritmo, utiliza diagramas de dispersión y mediante la línea de tendencia puede predecir el resultado.

Técnicas de aprendizaje no supervisado: En estas técnicas el algoritmo infiere grupos según las características de los datos de entrada, pero sin que se le aporte las “etiquetas”, es decir, no se sabe qué es lo que se va a tener en la salida.

En la **Figura 1.5** se muestra la taxonomía de las técnicas de aprendizaje máquina más empleadas en el campo de la medicina y minería de texto [38], [39].

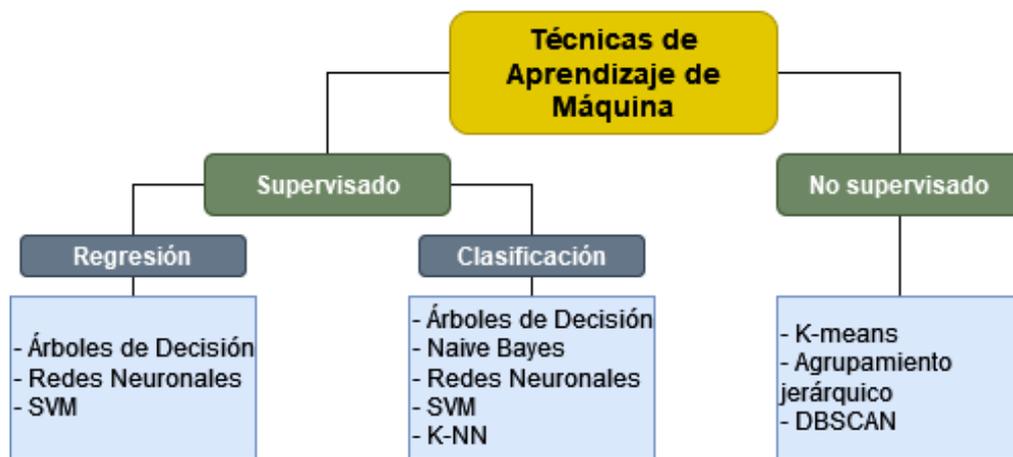


Figura 1.5 Taxonomía de las técnicas de aprendizaje máquina más empleadas en el campo de la medicina y minería de texto.

2. METODOLOGÍA

Para la elaboración del presente proyecto se utiliza como base a la metodología Kanban, la cual ayuda gestionar de forma sencilla e intuitiva las distintas tareas que se tengan planificadas para la elaboración de un proyecto grupal o individual [40].

Kanban permite que las tareas puedan ser ordenadas en 3 columnas diferentes, la primera columna corresponde a las tareas que tengan que cumplirse pero que aún no han empezado a realizarse, en la segunda columna se colocan las tareas que ya están en progreso pero que aún no finalizan y la tercera columna corresponde a aquellas tareas que ya se han completado. Cabe mencionar que el tener gestionado un proyecto de forma gráfica como lo hace Kanban ofrece una vista general del mismo, lo que hace que se pueda continuar con el desarrollo con fluidez y sin estancamientos, ya que conforme se vayan agregando y completando las tareas irán pasando de una columna a otra de forma ordenada, es decir que la tarea que pasa a la siguiente columna se colocará al final [40], para mantener un orden jerárquico y de prioridad en las tareas.

Para este componente las tareas que se agregaron al tablero son las que corresponden a aquellas detalladas en el Plan de Trabajo de Integración Curricular presentado, donde están organizadas por semanas para el seguimiento de su cumplimiento, al momento de la redacción de esta sección, el desarrollo del mismo se encuentra en la semana 6, para evidencia se puede referir a la **Figura 2.1**.

El enfoque del proyecto es de carácter cualitativo y exploratorio, por lo que se comparan diferentes estudios realizados en los últimos 5 años; los cuales se recopilan de repositorios digitales enfocados a los campos de las ciencias y la tecnología. Los repositorios base de consulta son: ACM Digital Library, IEEE Xplore, MDPI, Research Gate y bibliotecas digitales de universidades, entre las principales. La búsqueda de casos de estudio se hace incluyendo palabras clave son “noise”, “light”, “environment”, “students”, “university”, “confortable”, “academic performance” y “machine learning”, haciendo uso también de la combinación entre ellas para realizar la búsqueda más específica.

Por hacer	En Progreso	Completado
+	+	+
Definir el tipo de aprendizaje de máquina recomendado para inferir el nivel de confort del ambiente de estudio.	Estudiar las técnicas de aprendizaje de máquina utilizadas para la detección de factores que influyen en el ambiente de estudio.	Generación del modelo Kanban.
Proponer un esquema que puede ser implementado a futuro para monitorear el ambiente de estudio utilizando un teléfono inteligente	Comparar los parámetros que se utilizan en cada trabajo para determinar el nivel de confort del ambiente de estudio.	Estudiar los factores que influyen en el rendimiento académico de los estudiantes universitarios.
Definir los parámetros que permiten medir el rendimiento académico de los estudiantes universitarios.		Estudiar los sensores disponibles en los teléfonos móviles.
Revisión del borrador por parte del profesor tutor.		Recopilar información de aplicaciones IoT que permitan monitorear el ambiente de estudio con literatura publicada en los últimos 5 años.
Redacción del documento escrito.		Analizar la información recopilada.

Figura 2.1 Captura de estado del tablero Kanban en la semana 6

Para establecer qué algoritmo puede ser empleado en la determinación de un ambiente confortable se han comparado estudios que usan indicadores de evaluación y rendimiento de modelos, como el coeficiente de determinación cuadrado (R^2), la raíz del error medio cuadrático (RMSE) y la precisión. El R^2 se refiere al grado de fiabilidad en las predicciones, su valor oscila entre 0 y 1 y es más fiable mientras más se acerque a 1; por otro lado, RMSE es el grado de concentración de los valores reales con respecto a la línea de ajuste propuesta por el modelo, en función de la distancia a la misma, en este caso lo ideal es tener valores bajos [41]–[43].

2.1. Casos de estudio de iluminación

2.1.1. Caso 1: Optimización de iluminación natural al interior de una habitación en un campus universitario

En [44] se realiza un estudio en la Universidad de Atenas sobre la optimización de la iluminación natural al interior de una habitación en una residencia estudiantil. Se plantea la combinación de diferentes escenarios que se pueden aplicar a la habitación, donde las variables tomadas en cuenta son el uso de estantes de luz (*Light Shelves*), diseño de las ventanas y diseño del techo. Para la optimización se utiliza la herramienta de software jEPlus+EA junto con algoritmos genéticos, los cuales toman en cuenta las diferentes posibilidades de combinación de las tres variables (*Light Shelves*, diseño de ventanas y diseño del techo) a fin de proveer el diseño optimizado correspondiente a iluminancia de la habitación.

2.1.2. Caso 2: Análisis comparativo de la sensibilidad espectral de luxómetros y sensores de luz en smartphones

En [25], se realiza un estudio comparativo que involucra 25 equipos: 22 tipos de luxómetros, de diferentes tipos, marcas y grado de sensibilidad, y 3 teléfonos inteligentes dentro del estudio (Xiaomi 11T Pro, Samsung Galaxy J7, Xiaomi Redmi 4X). El experimento tiene como base la curva de sensibilidad unificada para visión diurna adoptada por la Comisión Internacional de Iluminación (CIE), a partir de ella se hace la comparación con los diferentes equipos para medir su grado de confianza.

Dentro del experimento las fuentes de iluminación empleadas corresponden a una fuente de luz incandescente y fuente del tipo LED. Se menciona, además, que hay celdas fotovoltaicas hechas de silicio (Si) y que comúnmente son las más utilizadas debido a su tolerancia frente a cambios de temperatura, es por eso que es menos común encontrar sensores fabricados con Selenio (Se), ya que a pesar de que se ajustan mejor a la curva estándar del CIE, son muy sensibles a cambios de temperatura. Los 22 tipos de luxómetros son separados en dos grupos: el primero que incluía aquellos que no tenían los fotorreceptores integrados al cuerpo del equipo, mientras que el segundo grupo sí. Basándose en estándares como DIN 5032-7, ISO/CIE 19476:2014 y CIE 231:2019, se detalla que hay 4 tipos de luxómetros usados por los fabricantes: L, A, B y C. Donde la clase L es la de mejores prestaciones y por ende la más costosa y en orden descendente (A - B - C) disminuye la calidad de los luxómetros, así como su precio, grado de sensibilidad y demás características. Los resultados muestran que efectivamente los luxómetros catalogados como clase L son los que mejor se acoplaron a la curva del CIE, mientras que los de clase C son los que menos se acoplaron a la curva y por ende aportaron menos

grados de confianza. En cuanto a los smartphones usados, no presentaron el mismo desempeño que los luxómetros, pues el valor de grado de error comparado con la curva estándar es de 20.81% para el smartphone Xiaomi 11T Pro, 27.65% para el Samsung Galaxy J7 y 55.51% para el Xiaomi Redmi 4X; a pesar de eso reflejaron mejor respuesta frente a algunos luxómetros, los cuales indicaban cierto grado de error, pero en la experimentación dicho valor fue totalmente diferente al especificado.

La **Tabla 2.1** muestra los smartphones con los que trabaja este caso de estudio, junto con el modelo de sensor que trae incorporado cada uno.

Tabla 2.1 Smartphones y sensores de luz usados en [25]

Modelo de sensor	Dispositivo
TCS3701	Xiaomi 11T Pro
TMD3725	Samsung Galaxy J7
stk3x1x alsprx	Xiaomi Redmi 4x

2.1.3. Caso 3: Análisis de confort visual utilizando redes neuronales difusas

En [23] se evalúa el confort visual mediante el análisis de 4 parámetros (iluminancia, índice de reproducción cromática, temperatura de color y frecuencia estroboscópica), tomando como escenario de prueba un aula de clase y estableciendo 9 puntos de estudio situados a 800mm del suelo. La fuente de iluminación son lámparas LED, las condiciones de estudio son realizadas en el día y en la noche, así como las temperaturas de color se establecen en 4500K y 5500K.

El estudio se basa en el estándar “*The Report of Health Lighting Standard Progress Report*” publicado por “*The National Semiconductor Lighting Engineering R&D*” e “*Industry Alliance Standardization Committee*” (CSAS), donde se pone énfasis a dos aspectos: la seguridad fotobiológica, referido al peligro de la luz azul que pueden emitir las lámparas y el segundo aspecto referido a la calidad de la iluminación, en términos de temperatura de color.

La experimentación emplea el algoritmo de redes neuronales difusas, dividida en cuatro capas: capa de entrada, capa de fuzzificación, capa de cálculo de reglas difusas y capa de salida. El algoritmo realiza el análisis multiparamétrico donde como nodos de entrada se establecen 4 nodos (iluminancia, índice de reproducción cromática, temperatura de color y frecuencia estroboscópica) y hay un nodo de salida que es el nivel de evaluación, de modo que se tiene una estructura 4-8-1, donde 8 son las funciones de pertenencia.

El flujo de las redes neuronales difusas se establece en 3 etapas: etapa de construcción de la red, etapa de entrenamiento y etapa de evaluación. Para la etapa de entrenamiento se realiza el análisis de 45 puntos de iluminación con 100 iteraciones y tomando en cuenta las temperaturas de color de 4500K y 5500K. Finalizada esta etapa se evalúa en los 9 puntos objeto del estudio.

Los resultados arrojan que para 4500K se obtiene mejor confort visual y la influencia de la luz externa es mínima, mientras que para 5500K sí hay gran influencia de la luz externa sobre el confort visual.

2.1.4. Caso 4: Comparación del rendimiento de algoritmos de aprendizaje automático en la predicción de iluminación diurna en espacios interiores

En [45] se realiza un estudio comparativo de 4 algoritmos de aprendizaje automático para la distribución de luminarias en un espacio interior. Los algoritmos considerados corresponden a: *Generalized Linear Model* (GLM), *Random Forest* (RF), *Gradient Boosting Model* (GBM) y *Deep Neural Network* (DNN). Además, se implementa el algoritmo *Long Short-Term Memory* (LSTM), el cual corresponde a un tipo especial de redes neuronales recurrentes (RNN) donde destaca principalmente su capacidad de almacenar más información que RNN estándar.

Los datos para el estudio son recopilados mediante un software de simulación para luz diurna (Energy Plus), donde se toma en cuenta como modelo genérico una habitación de 10 x 10 x 2.7 m. Para la parte del seccionamiento de datos, se realiza una partición del 80% para los datos de entrenamiento y 20% para prueba. Las comparaciones realizadas son en base al coeficiente de determinación cuadrado (R^2) y a la raíz del error medio cuadrático (RMSE), determinándose que *Random Forest* y DNN son los algoritmos de mejor rendimiento, pues presentan valores similares de R^2 y sólo difieren en los valores de RMSE.

2.1.5. Caso 5: Modelo para evaluar luz diurna haciendo uso de redes neuronales

En [46] se emplea *Artificial Neural Network* (ANN) con el propósito de predecir los niveles de autonomía de luz diurna (DA) en espacios interiores. DA corresponde al número de horas empleadas en un año en las que un objeto de iluminación es completamente identificable sólo con la luz del día; al usar ANN como método predictivo, se crea una alternativa a las simulaciones computacionales que demandan altos costos.

Se determinan 3 fases en el estudio: la primera es el entrenamiento y validación del algoritmo sólo con un único espacio de diseño, la segunda fase modifica el diseño de ventana, y la tercera considera efectos de sombreado causados por una obstrucción interna. Además, para resaltar el uso de ANN como algoritmo predictivo de niveles iluminación, se hace énfasis en otros estudios que también emplean ANN como algoritmo de predicción; por ejemplo, en el caso de predecir los niveles de iluminancia de un edificio de oficinas se obtuvo una precisión del 97%; también en otro estudio se lo usa para estimar el *Useful Daylight Illuminances* (UDI) donde incluso se compara con *Support Vector Machine* (SVM) que es otro algoritmo, y donde ANN obtiene mejor rendimiento.

2.1.6. Caso 6: Comparación de algoritmos Random Forest y Artificial Neural Network en la predicción del consumo energético e iluminación de la luz diurna

En [47] se compara el rendimiento de predicción de consumo energético e iluminación de la luz de día de dos algoritmos de machine learning: *Random Forest* (RF) y *Artificial Neural Network* (ANN). Dado el enfoque del componente, que es relacionado a determinar un ambiente confortable teniendo en cuenta la iluminación y el ruido, se hizo énfasis en los resultados y procedimientos referidos al caso de la iluminación, dejando de lado el caso asociado a la energía.

El estudio emplea EnergyPlus para el diseño de un aula de clases genérica, similar a las que hay en Cardiff, Reino Unido. Para poder desarrollar los modelos de los algoritmos se emplean los módulos *neurolab* para el caso de ANN y *scikit-learn* basado en Python para la implementación de RF. En la sección de resultados se evidencia que RF tiene mejor capacidad predictiva que ANN, pues por el lado de la raíz del error medio cuadrático (RMSE) la diferencia es más notoria, en comparación con el coeficiente de determinación cuadrado (R^2) donde la diferencia es pequeña.

2.1.7. Caso 7: Investigación del nivel de confort visual individual empleando aprendizaje automático en China

En [48] se realiza una investigación acerca de un modelo de predicción de nivel de confort visual mediante aprendizaje automático en Shanghái, China. Para el estudio se toma en consideración indicadores como la iluminancia vertical, el índice de deslumbramiento, la relación de luminancia y la posición de la sombra para construir el modelo de confort visual

individual con el cual se recogen datos, los cuales junto con la calificación de los 6 participantes involucrados en el estudio sirven para el entrenamiento de los 4 algoritmos correspondientes: RF, *Kernel Support Vector Machine* (KSVM), árbol de clasificación (CTree) y modelo mixto Gaussiano (GMM).

El diseño de cada uno es desarrollado en Python 3.8 mediante Anaconda 3. Además, como métrica de estudio se plantea una escala de 3 niveles para que los sujetos participantes califiquen el nivel de confort visual, siendo estos: tenue, confortable y brillante, en ese orden.

En la **Tabla 2.2** se observa el nivel de precisión de cada algoritmo en nivel confortable, donde se destaca que RF tiene el valor de precisión más alto.

Tabla 2.2 Rendimiento en términos de precisión de los algoritmos comparados en [48]

Algoritmo	Precisión [%]
CTree	70
RF	85
GMM	76
KSVM	71

La **Tabla 2.3** muestra las herramientas o software que se han usado para desarrollar los casos de estudio relacionados a detección de iluminación.

Tabla 2.3 Herramientas y software usados por los casos de estudio de iluminación

Estudio	Software/herramienta utilizada
[44]	Revit DesignBuilder EnergyPlus jEPlus+EA
[45]	Open studio EnergyPlus Radiance H2O(R-studio)
[46]	MATLAB DIVA
[47]	EnergyPlus Scikit-learn de Python Neurolab de Python
[48]	Anaconda 3 Revit

La **Tabla 2.4** muestra los valores de R^2 y RMSE de los casos de estudio que los han considerado como métrica de rendimiento para los algoritmos de aprendizaje máquina. Donde R^2_E es coeficiente de determinación cuadrado de entrenamiento, R^2_P es coeficiente de determinación cuadrado de prueba, $RMSE_E$ es error medio cuadrático de entrenamiento, $RMSE_P$ es error medio cuadrático de prueba y N/D no determinado.

Tabla 2.4 Algoritmos usados en casos de estudio de iluminación con métrica de rendimiento R^2

Estudio	Algoritmo	R^2_E	R^2_P	$RMSE_E$	$RMSE_P$
[45]	GLM	0.292	0.289	N/D	N/D
	RF con 10 árboles	0.989	0.954	228.256	155.564
	GBM con 1000 árboles	0.969	0.967	393.956	403.989
	DNN con 4 capas ocultas	0.992	0.990	195.301	211.443
[46]	ANN con 13 capas ocultas	N/D	N/D	N/D	0.63
[47]	RF	0.9870	0.9881	235.738	227.87
	ANN 1 capa oculta	0.9814	0.9799	272.354	278.498

2.2. Casos de estudio de análisis de ruido

2.2.1. Caso 1: Modelo de regresión aplicado al estudio del conocimiento y actitud de estudiantes acerca del uso de PLDs

El uso de *Personal Listening Devices* (PLDs) en estudiantes universitarios es un caso de estudio de alto nivel de importancia como se demuestra en [31], donde se encuesta a 1009 jóvenes utilizando el *Personal Listening Device and Hearing Questionnaire-Korean*, una variación Coreana de 78 preguntas, acerca de su conocimiento de los efectos que pueden generar los PLDs en su salud y en caso de presentar problemas auditivos, determinar si es que conocen de las posibles mitigaciones o buenas prácticas de uso con los dispositivos.

El estudio basa sus criterios de umbrales correctos de audición de acuerdo a los sugeridos por organismos como el *National Institute of Occupational Safety and Health* (NIOSH) y *Occupational Safety and Health Administration* (OSHA), donde se menciona que dichos valores deben estar entre 68.3 y 84.3 dBA como valores promedio y entre 96.7 y 107 dBA como rango de valores máximo.

Del estudio se obtiene que la frecuencia, junto con el tiempo de uso de una fuente de ruido como los PLDs son factores que influyen en la percepción del nivel de confort para los estudiantes; además, con modelos de regresión se analiza las respuestas recolectadas para determinar si existe una relación entre la frecuencia y el tiempo de uso de los PLDs con problemas auditivos.

2.2.2. Caso 2: Generación de un mapa de ruido aplicado a un campus universitario causado por el tráfico en los alrededores de la institución

En [49] se hace un análisis del ruido producido por el tráfico en los alrededores del edificio de enseñanza de la Universidad Guangxi de China, afirmando que las condiciones de ruido en estudiantes universitarios pueden acarrear consecuencias negativas como afecciones en la memoria, falta de atención y poco entendimiento en el aprendizaje del estudiante. De la misma manera se asevera que, en campus universitario, la mayor fuente de ruido es aquel producido por el tráfico en las cercanías del establecimiento.

El estudio hace uso del mapa de ruido como técnica para determinar los requerimientos que se deberían cumplir en su intento de mitigar el ruido, como “alejarse” del campus de la vía principal o colocar fuentes naturales de ruido como cascadas o piletas artificiales de agua, para dicho objetivo el ruido es medido con el sensor BSWA 801, que es un analizador de sonidos y vibraciones, mientras que la generación del mapa de ruido se crea a partir del software Predictor 7810.

2.2.3. Caso 3: Aplicación de clusterización para detectar eventos de ruido en una base de datos multitudinaria

En [50] se utiliza el algoritmo *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN) para agrupar en clusters los eventos espaciales de ruido de una amplia base de datos. El estudio usa como principal herramienta la aplicación de código abierto “*NoiseCapture*” (NC), cuya finalidad es medir el ruido en el entorno, usa los sensores disponibles en los smartphones y posteriormente dichas mediciones pueden ser compartidas con los demás usuarios de la aplicación; con ello se alimenta la base de datos.

La aplicación permite completar con información adicional los registros que cada participante de la comunidad de “*NoiseCapture*” realiza. Pueden agregarse datos como: descripción de la medida realizada, nivel de conformidad captado por el usuario, condiciones de la medición, las fuentes predominantes y la locación de la medida, este último es el que permite cumplir con el objetivo del estudio, ya que con ese dato se forman los clusters; y es que cada registro representa un punto en el mapa global gracias a su ubicación, es así como se genera un mapa de densidad de puntos, del cual DBSCAN forma los clusters.

2.2.4. Caso 4: Predicción de ruido usando aprendizaje automático con análisis de medidas

En [51] se realiza el análisis de nivel de ruido equivalente (Leq) del *National Synchrotron Radiation Research Center (NSRRC)*. Se utiliza el algoritmo de aprendizaje máquina *Gradient Boosting Model (GBM)* para predecir los niveles de ruido, y para poder entrenarlo se usan mediciones anteriores al estudio, con una distribución de los datos de 80% para entrenamiento y 20% para validación. Los parámetros tomados en cuenta son el tiempo de exposición al ruido y la frecuencia del Leq.

El caso de estudio muestra que el algoritmo tiene una gran capacidad de predicción ya que, la zona donde se ubica el sensor 8, que trabaja a una frecuencia de 125 Hz, en las mediciones pasadas había presentado altos niveles de ruido, pero con el actual modelo planteado basado en el algoritmo GBM, se determinó que dicha zona de estudio presenta un valor de R^2 mayor a 0.7 y el de RMSE menor a 1 dBA.

De esa forma por medio de una alerta se advierte de la exposición a largo plazo que tendrá un trabajador.

2.2.5. Caso 5: Predicción del ruido producido por el tráfico en la ciudad de Patiala en India usando aprendizaje automático

En [52] el estudio propone la predicción del nivel de presión sonora generada por el ruido del tráfico en Patiala, una ciudad de La India. Se basa en aprendizaje automático empleando datos recopilados a diferentes momentos del día para tener una mayor diversidad.

Son 502 datos recolectados desde diferentes sitios, pero se usa la simulación monte carlo para poder generar más; usa el algoritmo de Red Neuronal Artificial (ANN) para obtener la predicción. Se tiene como parámetros de entrada el volumen del tráfico que circula por la zona donde se realiza el estudio, el porcentaje de vehículos pesados que circulan y la velocidad media de los mismos, mientras que en la salida se tiene el nivel de presión sonora continua equivalente; además, también se hace una comparación con otros algoritmos de aprendizaje automático como RF, *Generalized Linear Model (GLM)* y *Decision Tree (DT)* para poder contrastar su rendimiento en base al coeficiente de determinación (R^2) y al error cuadrático medio (RMSE).

El estudio muestra que los algoritmos RF y ANN en sus dos variaciones (con y sin la simulación monte carlo) son los de mejor rendimiento para predecir los niveles de ruido causado por el tráfico en Patiala.

2.2.6. Caso 6: Uso de aprendizaje automático para predecir los límites sonoros de un motor automotriz durante su aceleración

En [53] el estudio busca predecir los límites de ruido en la aceleración de los vehículos, basados en las normas de *The United Nations Economic Commission for Europe (UNECE) R51 regulations*.

Para este caso se emplea el algoritmo *Back-Propagation Neural Network (BPNN)*, el cual usa registros históricos de límites de ruido de vehículos durante la aceleración para poder entrenarse; también se utiliza en el estudio otras herramientas como el algoritmo *Levenberg-Marquardt*, el cual permite adoptar de manera automática el aprendizaje y entrenamiento de los datos de entrada a la vez que divide el conjunto para la validación de los datos.

A modo de comparación también se contrasta con otros 4 modelos de aprendizaje automático: *Support Vector Machines (SVM)*, *Gaussian Process Regression (GPR)*, *Ensembles of Trees (ET)* y *Regression Trees (RT)* para observar su rendimiento, siendo BPNN el mejor en términos de R^2 .

2.2.7. Caso 7: Predicción de ruido molesto mediante el uso de aprendizaje automático

En [54] el estudio se realiza en la búsqueda de predecir ruidos que llegan a niveles de molestia y que son producidos por diferentes fuentes sonoras.

El enfoque es en base a 3 objetivos principales: identificar las características principales del audio, construir un modelo predictivo de alta precisión y finalmente cuantificar la influencia de cada característica del ruido; para la parte de adquisición de datos se ayuda de 180 sujetos de entre 20 a 60 años que dan testimonio de su percepción del ruido, el cual es subjetivo a cada persona; el algoritmo que se alimenta de estos datos es *Extreme Gradient Boosting Regressor (XGB)*, mientras que en cuanto a la sección de herramientas, se emplea la grabadora Tascam DR-100 y el micrófono Neuman.

XGB obtiene un valor de R^2 cercano a 1, específicamente 0.916, mientras que de RMSE es 0.2983, estos son valores aceptables para el nivel de predicción de un algoritmo.

2.2.8. Caso 8: Uso de técnicas de aprendizaje automático para predecir el ruido generado por objetos aerodinámicos

En [55] se hace uso de diferentes técnicas de aprendizaje supervisado como *Multilayer Perceptron (MLP)*, J48, redes neuronales de base radial (RBFN), *Bagging*, *Random Forest*

(RF), *Logistic* y SVM para poder comparar qué tan buenos son para predecir el ruido generado por objetos aerodinámicos.

Los datos con los que trabajan los algoritmos se obtienen de la base proporcionada por la NASA llamada “*Airfoil Self-Noise*”; de este estudio se destaca la posibilidad de combinar algoritmos para obtener un mejor desempeño, como el caso del híbrido entre los algoritmos *Bagging* y *Random Forest*, el cual tuvo mejores resultados de precisión y error medio en comparación con los demás. En la **Tabla 2.5** los valores mostrados son aproximaciones de acuerdo con las gráficas presentes en [55].

Tabla 2.5 Algoritmos usados en casos de estudio de ruido empleando la precisión como métrica de rendimiento

Algoritmo	Precisión [%]
Bagging	73
RF	77
J48	72
RBFN	55
Logistic	57
MLP	64
SVM	44
Bagging y RF	77.5

La **Tabla 2.6** muestra las herramientas, software y sensores que se han usado para desarrollar los casos de estudio relacionados al análisis del ruido, donde N/D es no determinado.

Tabla 2.6 Herramientas, software y sensores usados por los casos de estudio de ruido

Estudio	Software/herramienta utilizada	Sensor
[31]	Encuesta PLDHQ-K	N/D
[49]	Predictor 7810	BSWA 801
[50]	NoiseCapture	Micrófono y GPS de smartphone
[51]	N/D	Módulo sensor de ruido
[52]	MATLAB Excel	N/D
[53]	MATLAB	N/D
[54]	Scikit-learn de Python	N/D
[55]	Weka	N/D

La **Tabla 2.7** muestra los valores de R^2 y RMSE de los casos de estudio de ruido que los han considerado como métrica de rendimiento para los algoritmos de aprendizaje máquina. Donde R^2_E es coeficiente de determinación cuadrado de entrenamiento, R^2_P es coeficiente de determinación cuadrado de prueba, $RMSE_E$ es error medio cuadrático de entrenamiento, $RMSE_P$ es error medio cuadrático de prueba y N/D no determinado.

Tabla 2.7 Algoritmos usados en casos de estudio de ruido con métrica de rendimiento RMSE

Estudio	Algoritmo	R^2_E	R^2_P	$RMSE_E$	$RMSE_P$
[52]	ANN	0.9	0.91	0.49	0.45
	GLM	0.86	0.89	0.63	0.58
	DT	0.89	0.89	0.56	0.52
	RF	0.97	0.92	0.28	0.43
	ANN (con monte carlo)	0.99	0.99	0.18	0.22
[53]	BPNN (24 capas ocultas)	0.998	0.999	0.526	1.03
	SVM	N/D	N/D	N/D	0.663
	GPR	N/D	N/D	N/D	0.312
	ET	N/D	N/D	N/D	14.8
	RT	N/D	N/D	N/D	4.76
	BPNN (4 capas ocultas)	N/D	N/D	N/D	0.444
[54]	XGB	N/D	0.916	N/D	0.2983
[55]	Bagging	N/D	N/D	N/D	0.25
	RF	N/D	N/D	N/D	0.24
	J48	N/D	N/D	N/D	0.27
	RBFN	N/D	N/D	N/D	0.30
	Logistic	N/D	N/D	N/D	0.31
	MLP	N/D	N/D	N/D	0.28
	SVM	N/D	N/D	N/D	0.33
	Bagging y RF	N/D	N/D	N/D	0.23

Se observa que, en los casos de estudio de iluminación y ruido, los algoritmos más usados son los basados en árboles de decisión y redes neuronales, específicamente RF y ANN; por lo que se abre la posibilidad de trabajar con los dos para poder predecir si un ambiente es confortable o no y luego comparar cuál es el más adecuado para este componente.

En la **Tabla 2.8** se muestran los diferentes parámetros de iluminación y ruido que son considerados en los casos de estudio para determinar el nivel de confort en los espacios donde fueron desarrollados. La tabla contiene en la sección amarilla los parámetros correspondientes a iluminación, y en la zona azul los de ruido. Además, la columna

“Utilización” indica si el parámetro ha sido tomado en cuenta para la propuesta de una alternativa de detección del nivel de confort del ambiente de estudio que se plantea en este trabajo. El detalle de la definición y justificación de uso de los parámetros se expone en la sección de **Comparación de factores de iluminación y ruido analizados en los casos de estudio**.

Tabla 2.8 Parámetros usados en los casos de estudio para determinar el nivel de confort de iluminación y ruido

Categoría	Parámetro	Utilización
Iluminación	Iluminancia	Sí
	Diseños de ventanas/techo	No
	Sombras de agentes externos	No
	Temperatura de color	No
	Índice de reproducción cromática	No
	Frecuencia estroboscópica	No
	Índice de deslumbramiento	No
	Estantes de luz	No
Ruido	Intensidad de ruido	Sí
	Tiempo de exposición a fuentes de ruido	Sí
	Frecuencia de uso de dispositivos de audio o fuentes de ruido	Sí
	Frecuencia del nivel de ruido equivalente	No
	Volumen de tráfico en las cercanías de la zona de estudio	No
	Porcentaje de vehículos pesados que circulan cerca de la zona de estudio	No
	Velocidad media de circulación de los vehículos cerca de la zona de estudio	No

2.3. Alternativa para detección del nivel de confort del ambiente de estudio

Para determinar el nivel de confort del ambiente de estudio, se plantea como una alternativa el flujo de trabajo presentado en la **Figura 2.2**. Este se compone de 5 fases en todo el proceso, las 4 primeras corresponden al funcionamiento de la aplicación, mientras que la quinta etapa trata de la correlación entre el rendimiento académico y el nivel de confort que perciben los estudiantes en términos de iluminación y ruido, esta es revisada en la sección de **Resultados**.

A continuación, se detalla cada una de las fases.

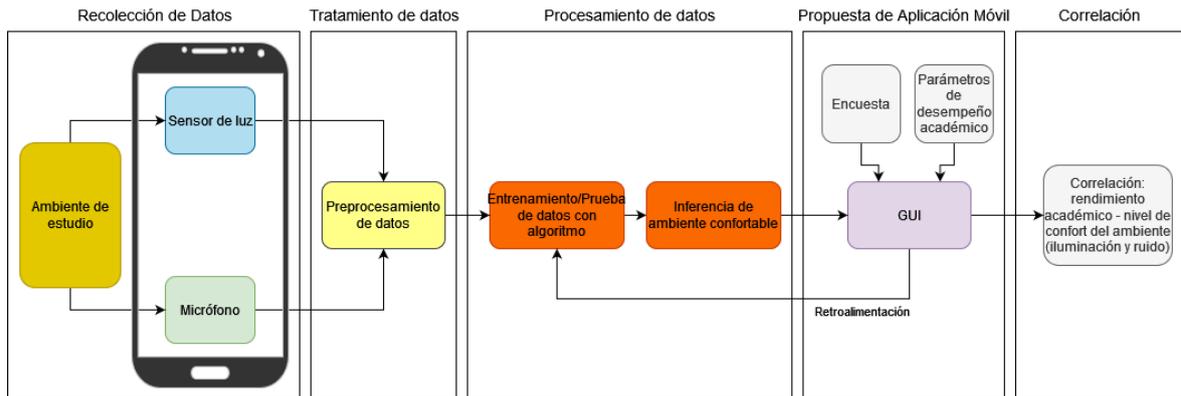


Figura 2.2 Flujo de trabajo para la detección de nivel de confort

2.3.1. Recolección de datos

En base a los trabajos analizados anteriormente se puede observar que los parámetros que pueden permitir analizar el estado de confort de un ambiente son la iluminación y el ruido, como se menciona en la **Tabla 1.2** Factores cuantitativos que afectan el rendimiento académico de estudiantes universitarios [13]. **Tabla 1.2**. Para ello se hace uso del sensor de luz y micrófono que traen incorporados los smartphones para poder captar las mediciones de nivel de iluminancia y ruido respectivamente. Como resultado se debe tener una base de datos con registros de iluminancia en [lux], ruido en dBA o dB y una etiqueta que indique si con dichos valores de iluminación y ruido se considera el ambiente confortable o no, de acuerdo con valores sugeridos como los mostrados en **Tabla 1.4** y **Tabla 1.5**.

Además, se recomienda que el terminal móvil debería ser colocado sobre la superficie donde el estudiante realice sus actividades de estudio, tal como se muestra en la **Figura 2.3**, de esa manera el nivel de iluminación que se refleje en el sensor del terminal móvil sería el mismo que aquel que perciba el estudiante y lo mismo para el caso del ruido.

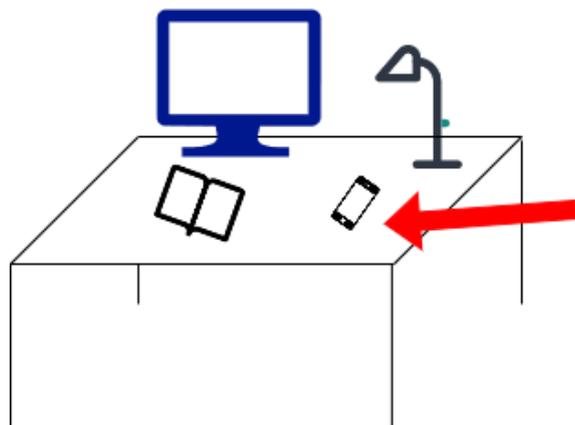


Figura 2.3 Posición sugerida del smartphone para el funcionamiento de la aplicación móvil

2.3.2. Tratamiento de datos

Una vez realizado el proceso de recolección de datos, a esta información se le debe realizar un preprocesamiento para realizar la limpieza y validación de datos, de modo que se eliminen aquellos registros duplicados o faltantes, y de ser necesario, se debe corregir su formato para que todos coincidan en las mismas unidades y tipo de dato, con ello se obtiene un base de datos con registros útiles y de valor para las etapas posteriores.

2.3.3. Procesamiento de datos

Como preámbulo para esta etapa es necesario establecer los porcentajes de datos de entrenamiento, puede ser una relación 80 a 20 o 70 a 30, que suele usarse a menudo en minería de datos [56]. Además, es necesario tener seleccionado el algoritmo de aprendizaje de máquina con el que se va a trabajar, ya que en esta etapa es donde se lo implementa.

Esta etapa es donde el algoritmo va aprendiendo y prediciendo si el nivel del ambiente que percibe el estudiante es confortable o no, de acuerdo a los datos que se le proporcione como entrada. En la **Figura 2.4** se observa el funcionamiento de esta etapa.

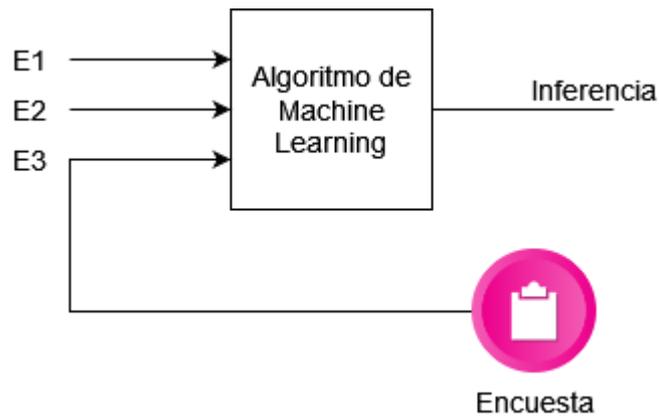


Figura 2.4 Diagrama de flujo de la fase de procesamiento de datos

Las entradas para el algoritmo son representadas como E1, E2 y E3; cada una de ellas corresponde a las variables de: nivel de iluminación (E1), ruido (E2) y la retroalimentación que da el estudiante mediante la encuesta detallada en la fase de Propuesta de Aplicación Móvil (E3).

En un inicio el smartphone capta valores de iluminación (E1) y ruido (E2) que sirven para entrenar al algoritmo de aprendizaje de máquina, para eso, dichos datos deben ser captados en diferentes condiciones, por ejemplo, haciendo que el smartphone mida la iluminancia al apagar y encender varias veces una fuente lumínica que esté cerca del dispositivo, y de la misma manera con una fuente sonora para captar niveles altos y bajos de ruido. Con esos valores el algoritmo realiza el proceso de entrenamiento y validación y como resultado entrega la “Inferencia” del ambiente, es decir, indica si el ambiente es confortable o no; luego para los posteriores procesos de aprendizaje, el algoritmo incorpora la entrada E3, que se obtiene de la encuesta de la **Figura 2.11a**, donde el estudiante bajo su percepción coloca si el ambiente es confortable o no con los niveles de iluminancia y ruido presentes en ese momento, así el algoritmo continúa aprendiendo constantemente con las 3 métricas.

2.3.4. Propuesta de Aplicación Móvil

Esta etapa corresponde al *FrontEnd* de la aplicación, es decir el componente gráfico [57], donde se refleja todas las funciones que pueden ser utilizadas por los usuarios en caso de desarrollar una aplicación, sea los estudiantes o el administrador.

La **Figura 2.5** corresponde a la interfaz de inicio. Donde se solicita ingresar el correo y contraseña de la cuenta para poder acceder a las demás funciones. Además, permite seleccionar opciones como: Recordar contraseña, ¿Olvidó la contraseña? y Regístrate aquí, en caso de que no se tenga una cuenta.

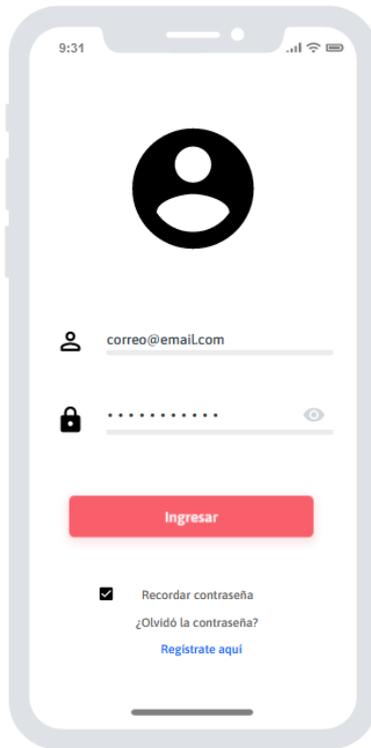


Figura 2.5 Interfaz de inicio de la aplicación

- **Recordar contraseña:** El usuario debe marcar el checkbox si desea que la contraseña de su cuenta sea almacenada en la base de datos de la aplicación, de esa manera en el próximo inicio de sesión, al momento que el estudiante ingrese su correo, la aplicación autocompletará la contraseña asociada a dicho correo, por lo que el ingreso a la cuenta será más rápido y cómodo para el usuario.
- **¿Olvidó la contraseña?:** Se ingresa a esta opción si el usuario ha olvidado la contraseña de su cuenta (**Figura 2.6**). Al inicio todos los campos están deshabilitados (excepto el campo de ingreso de correo) y conforme se vaya ingresado los parámetros solicitados se irán habilitando. Primero se debe de ingresar el correo electrónico con el que el usuario se registró por primera vez, hecho eso, el botón “Enviar” se habilitará y al pulsarlo un código será enviado a la dirección ingresada. Luego se debe colocar el código en la sección correspondiente, si el código coincide con el que fue enviado, se podrá ingresar el valor de la nueva contraseña, junto con otro campo para validarla. Finalmente, si las contraseñas coinciden, el botón “Guardar” se habilitará y una vez pulsado se guardará la nueva contraseña.



Figura 2.6 Interfaz de recuperación de contraseña

- **Regístrate aquí:** Si no se tiene cuenta registrada, es posible crear una con esta opción. Al ingresar a la interfaz de registro por primera vez, como se muestra en la **Figura 2.7**, se despliega una serie de campos donde se debe ingresar datos como el nombre, apellido y correo del usuario; así como la creación de una contraseña para la cuenta, junto con otro campo para ingresarla nuevamente y comprobar que coincidan, y opcionalmente se puede seleccionar una foto de perfil. Algunos datos serán de carácter obligatorio, a los que se identifica con el signo de exclamación "!". Al pulsar "Registrarse" la información se almacena en la base de datos.

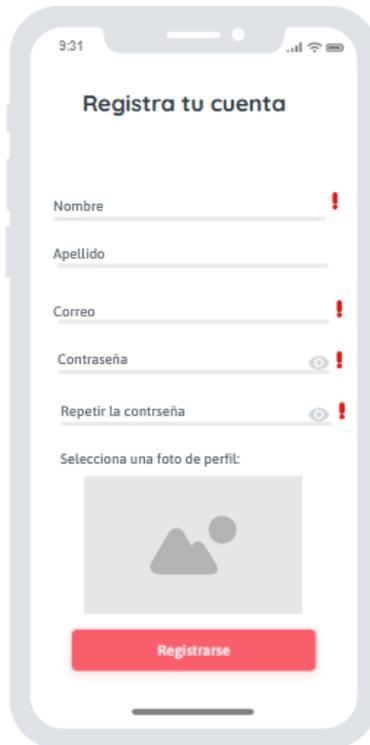


Figura 2.7 Interfaz de registro de una cuenta

Al momento de colocar las credenciales correctamente en la interfaz de la **Figura 2.5** y pulsando el botón “Ingresar”, se accede a las demás funciones de la aplicación. Se puede navegar por 4 funciones principales: perfil, encuestas, monitoreo y resultados, y dependiendo de en qué función se ingrese, se distingue por el color resaltado en su ícono, como se muestra en la **Figura 2.8**.

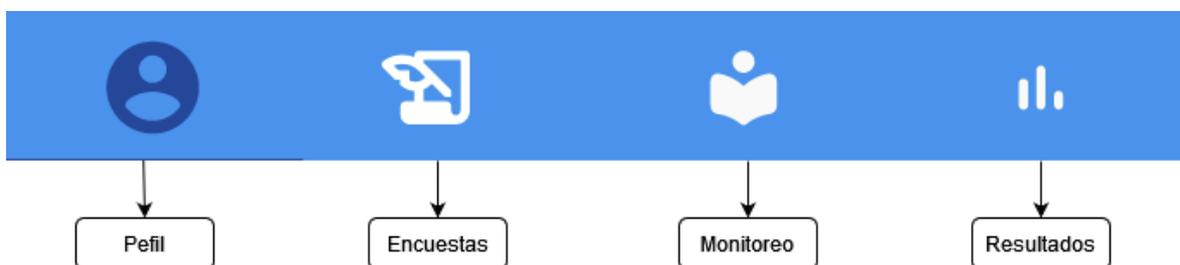


Figura 2.8 Funciones principales de la aplicación

Al seleccionar la función de “Perfil”, se despliega la interfaz correspondiente a la **Figura 2.9**, donde se muestra en la parte superior la foto, nombre y el correo con el que registró el usuario su cuenta; además, se puede realizar actualizaciones de información personal como nombre, apellido, correo y contraseña. Al seleccionar “Guardar”, la información se

actualiza en la base de datos, mientras que escogiendo “Cerrar Sesión” el usuario volvería a la interfaz de la **Figura 2.5**.

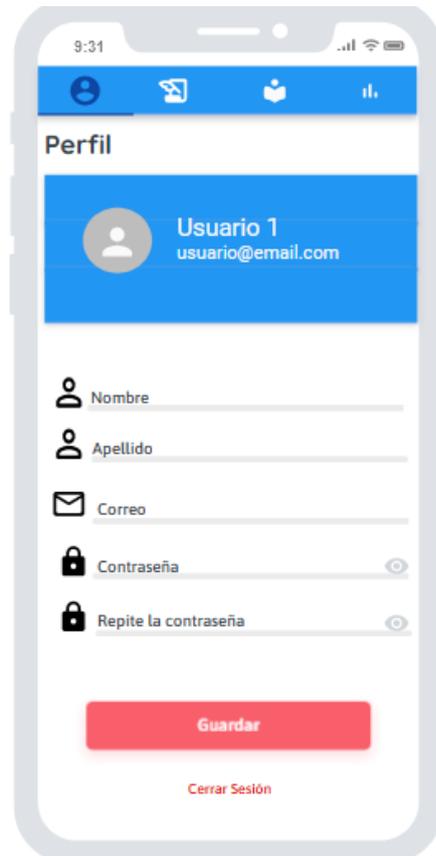


Figura 2.9 Interfaz de la función "Perfil"

La interfaz correspondiente a la función “Encuestas” se muestra en la **Figura 2.10**, en donde se destacan 3 secciones principales: encuesta diaria, encuesta académica y calendario académico. Estas se observan en la **Figura 2.11**, mientras que lo referente al calendario, se muestra de forma desplegada y en él se marcan las fechas de interés del calendario académico en curso, como pruebas, cierre de cada bimestre, entre otras.

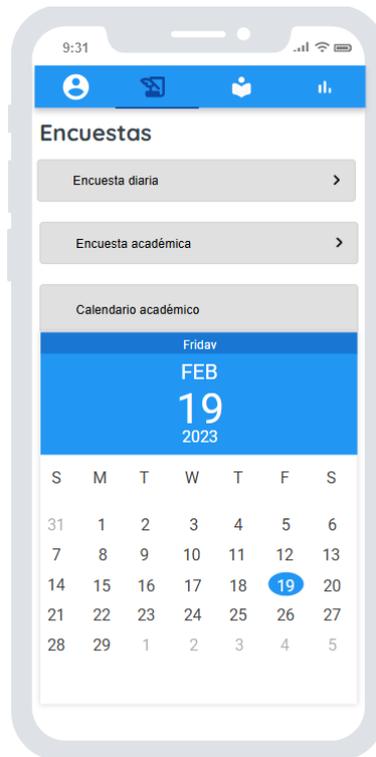


Figura 2.10 Interfaz de la función "Encuestas"

La **Figura 2.11a**, se despliega al seleccionar "Encuesta diaria" en la Función "Encuestas" (**Figura 2.10**). Esta encuesta debería ser llenada diariamente por el estudiante, en ella se presentan los valores de niveles de iluminación y ruido captados en tiempo real por los sensores; además de consultar si es que, con dichos niveles, el estudiante percibe si el ambiente es confortable bajo su percepción, la respuesta es almacenada usando un conmutador. Esta pregunta puede ser contestada en cualquier momento del día y cuantas veces desee. Por último, se puede registrar las horas de estudio que ha empleado el día anterior, esta opción sólo podrá ser completada una vez por día y luego se deshabilitará hasta el día siguiente, pero debe ser validada de que el valor ingresado sólo sea numérico. Pueden presentarse ocasiones donde el estudiante un día olvide llenar la encuesta, por lo que la aplicación debe de considerar una hora límite para contestarla, en donde si el estudiante no ha respondido la encuesta hasta la hora especificada, automáticamente se envía una alerta como recordatorio, tal como se muestra en la **Figura 2.12**.

La **Figura 2.11b**, se despliega al seleccionar "Encuesta académica" en la **Figura 2.10**. Esta encuesta puede ser completada en fechas específicas como al inicio, a mediados y final del ciclo académico. Al inicio del periodo se puede solicitar llenar el valor del Índice de Rendimiento Académico (IRA) (validando que la entrada sea sólo valores numéricos), una vez ingresado se deshabilita la edición hasta el final del semestre, esto con la finalidad de comparar los resultados de la aplicación al inicio y al final del semestre. Además, pulsando

el botón naranja que tiene el símbolo “+” en color blanco, se ingresan las materias que el estudiante va a tomar en ese ciclo y en cada una se crea automáticamente la sección de promedio de primer y segundo bimestre. A mediados del periodo se habilita el campo del promedio del primer bimestre para cada materia y al final del semestre los del segundo, cada una con su validación numérica respectiva. Toda configuración se registra tras pulsar “Guardar”.

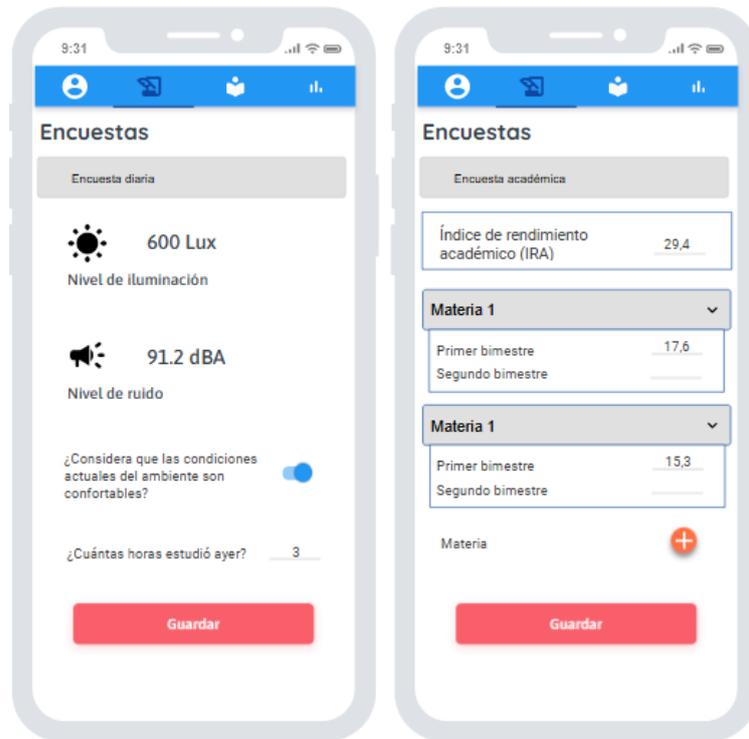


Figura 2.11 Interfaz de encuesta diaria (a); encuesta académica (b)



Figura 2.12 Notificación como recordatorio para llenar la encuesta diaria

La **Figura 2.13**, corresponde a la función de monitoreo antes de que los sensores empiecen a medir los niveles de iluminancia y ruido, en ella se muestra un cronómetro que inicialmente está en cero, junto con las secciones donde se observarán los valores que los sensores midan; además de un mensaje donde se muestre que la aplicación está a espera de iniciar con el monitoreo. Pulsado el botón “Iniciar” se comienza con el proceso.

La **Figura 2.13b**, expone la interfaz que permite al estudiante informar cuando realice una sesión de estudio, en donde al pulsar el botón “Iniciar” de la **Figura 2.13a**, el cronómetro inicia para tener un registro de las horas que se invierten para estudiar en ese lugar. De la misma forma los sensores comienzan a sensor cada t segundos los valores de iluminancia y ruido, y los almacena en la base de datos. También se generan alertas acerca de la condición de las variables, es decir, si el nivel medido es bajo o alto y las acciones que se sugieren hacer para mejorar el nivel de confort, dicho mensaje se muestra en un label. El monitoreo se detendrá cuando el estudiante finalice de estudiar y pulse el botón “Detener”

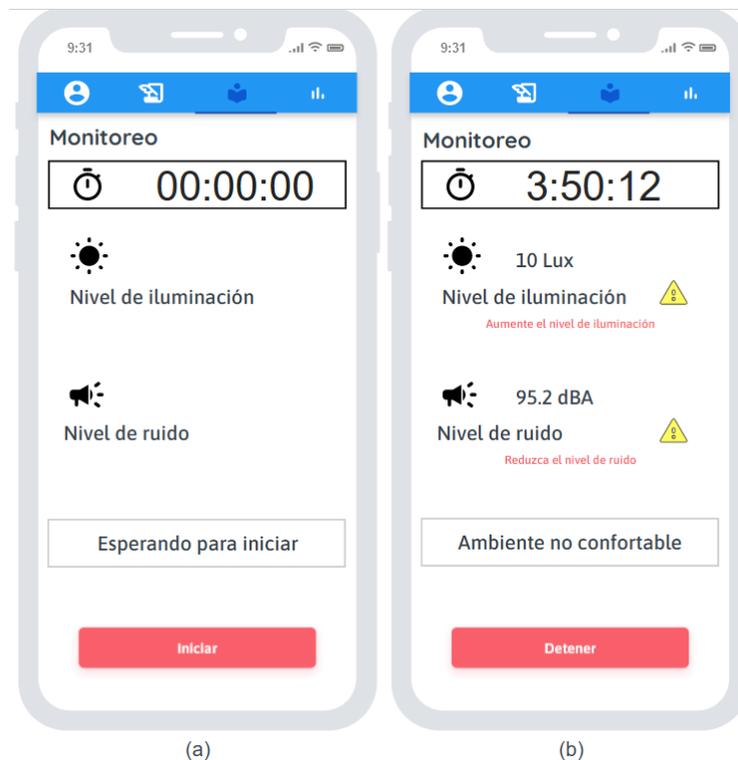


Figura 2.13 Interfaz para iniciar el monitoreo en tiempo real (a); durante monitoreo en tiempo real (b)

La **Figura 2.14a**, corresponde a la interfaz de resultados donde se despliega todos los registros de un usuario, ahí se puede distinguir la fecha en formato día/mes/año, junto con la hora en formato horas:minutos:segundos, en que empezó el monitoreo del ambiente, a

la derecha de cada uno hay un botón con forma de ojo, con el cual se dirige a la interfaz de la **Figura 2.14b**.

La **Figura 2.14b** corresponde a los resultados de una fecha en específico, en ella se reflejan en un plano cartesiano cada una de las medidas que han hecho los sensores de luz y micrófono del smartphone. En el eje de las X se coloca la hora en la que se tomaron las muestras y en el eje Y los diferentes niveles de iluminancia y ruido con sus correspondientes unidades de medida. Si se desea exportar los datos se lo puede hacer con la opción “Exportar”, la cual permite obtener la información en formatos como csv, txt, json, pdf, entre otros. Para regresar a la pantalla anterior se pulsa en botón “volver”.

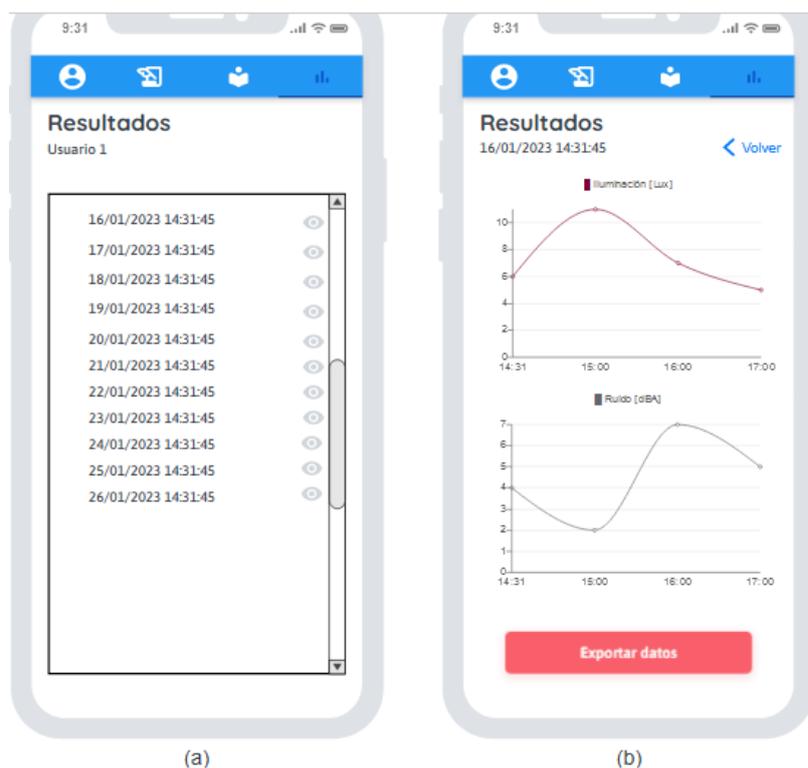


Figura 2.14 Interfaz de resultados generales (a); resultados por fecha (b)

Para la cuenta de administrador se puede navegar por dos funciones: “Perfil” y “Resultados”. La función “Perfil” tiene la misma lógica que la interfaz de la **Figura 2.9**, mientras que “Resultados” permite ver todos los usuarios que utilicen la aplicación, tal como se muestra en la **Figura 2.15a**, además, es posible descargar los datos de uno o varios usuarios seleccionando los checkbox frente a ellos, o si se requiere se puede descargar los datos de todos los usuarios escogiendo “seleccionar todo”. Para observar los registros de un usuario se selecciona el ícono con forma de ojo que está a su derecha, en ese caso se despliega la interfaz de la **Figura 2.15b**, donde el funcionamiento de descargas es igual que la interfaz de la **Figura 2.15a**; y, si se requiere observar los resultados de las mediciones de iluminancia y ruido en una fecha específica, se debe pulsar el ícono de ojo

que está a la derecha de la fecha requerida, con eso se muestra la interfaz de la **Figura 2.15c**, donde es posible exportar los datos de la gráfica. Para regresar entre las interfaces, se debe seleccionar el botón “volver”.

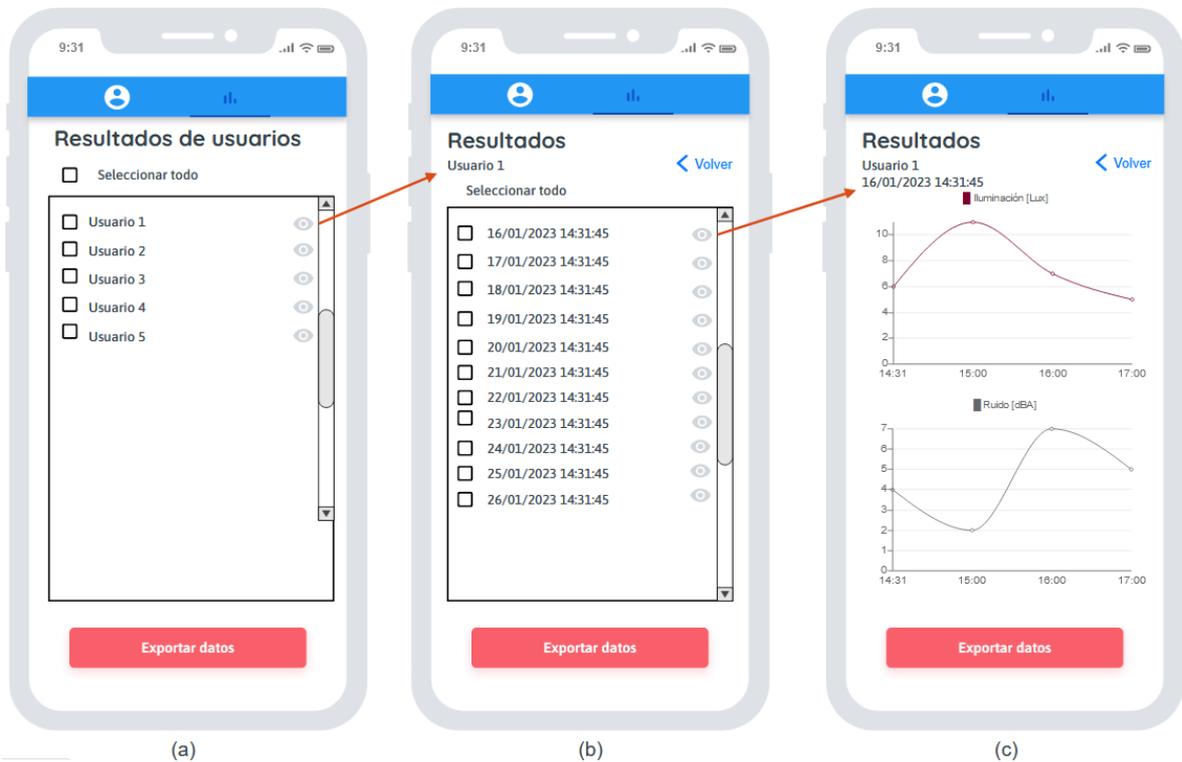


Figura 2.15 Interfaz de usuarios (a); interfaz de los registros de un usuario (b); interfaz de resultados de un usuario en una fecha en específica (c), vistas desde la cuenta de administrador

Como la cantidad de datos que se generen está determinado por el número de usuarios que utilicen la aplicación, la frecuencia con que se tomen los valores de iluminación y ruido durante una sesión de estudio y el número de veces que se responda a la encuesta diaria, puede optarse por un almacenamiento en nube para que de esa manera se pueda tener acceso a los datos desde cualquier plataforma o dispositivo. También hay otros beneficios como evitar que un equipo local se sature por guardar todo el volumen de datos y además sirve de respaldo para toda la información recolectada.

3. RESULTADOS, CONCLUSIONES Y RECOMENDACIONES

3.1. Resultados

Los resultados del análisis comparativo de los casos de estudio de iluminación y ruido se enfocan principalmente en los algoritmos que se utilizaron, las métricas de rendimiento para determinar cuál era el mejor y los factores de nivel de confort que cada caso de estudio consideró.

3.1.1. Comparación de uso de los algoritmos de aprendizaje máquina empleados en los casos de estudio

Se analizaron un total de 15 estudios, de los cuales 7 están asociados al análisis de la iluminación, y 8 al análisis del ruido.

En la **Figura 3.1** se muestra en valores porcentuales el uso de los diferentes algoritmos empleados en el análisis de la iluminación en los casos de estudio revisados. En vista de que algunos estudios presentaban algoritmos similares, pero en diferentes versiones, se agrupó por tipos de algoritmos de aprendizaje de máquina (en caso de ser posible).

Redes neuronales y árboles de decisión son los más utilizados, cada uno con un porcentaje del 31%, por lo que son candidatos a utilizarse para determinar el nivel de confort en cuanto a iluminación; mientras que los demás como *Support Vector Machine* (SVM), modelo mixto Gaussiano (GMM) y *Gradient Boosting Model* (GBM) tienen una utilización del 8%, en tanto que los que menos porcentaje de uso tienen son los algoritmos genéticos (GA) y *Generalized Linear Model* (GLM) con un 7%.

Obtenidos los tipos de algoritmos candidatos, se analiza de forma individual cada uno para determinar de forma explícita el algoritmo que se puede usar. Para ello, en la **Figura 3.2**, se observa el porcentaje individual de uso de cada algoritmo (tomando en cuenta solo los de tipo redes neuronales y árboles de decisión). En este caso RF con 37,5% y ANN con 25% son lo más usados.

Con el análisis realizado, se determina que para la detección de nivel de confort en torno a niveles de iluminación el algoritmo a usarse es RF ya que es el que mayor uso ha tenido en los diferentes casos de estudio revisados.

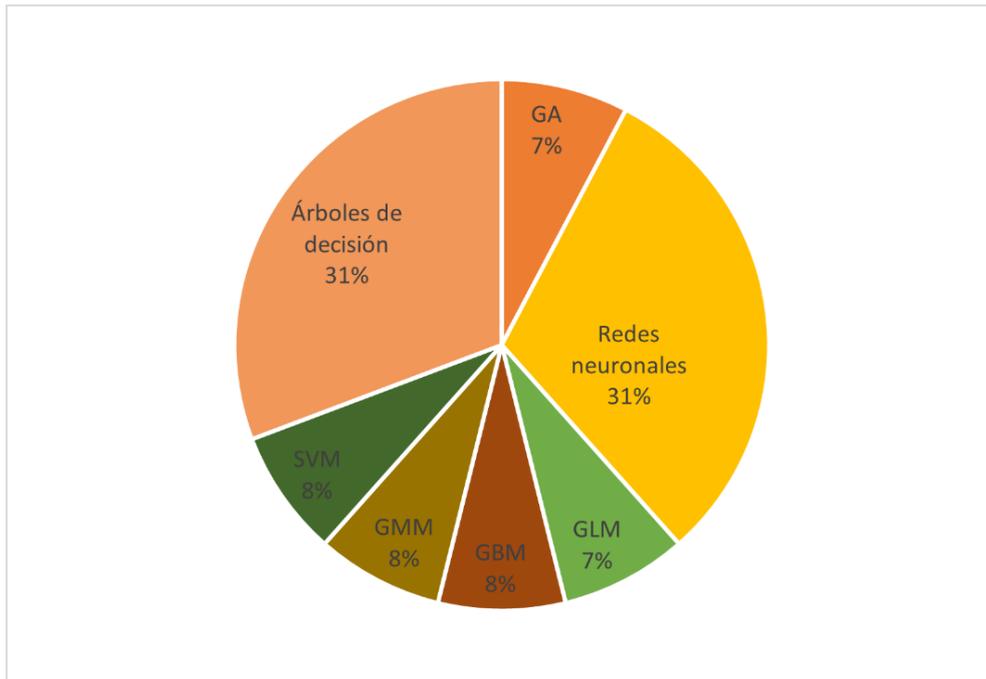


Figura 3.1 Porcentaje de uso de tipos de algoritmos en análisis de la iluminación

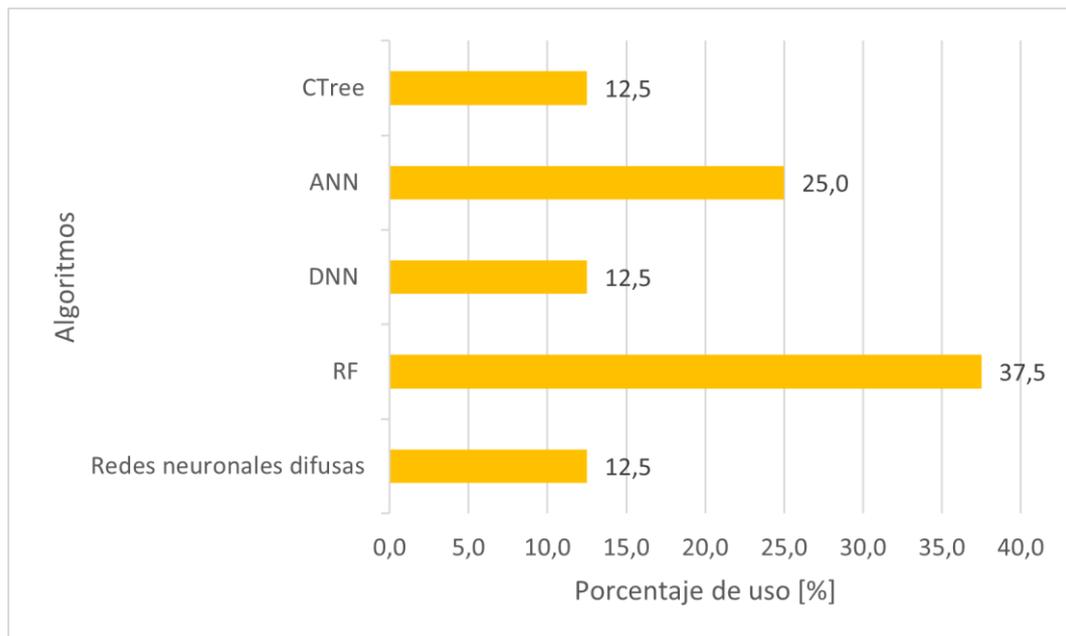


Figura 3.2 Porcentaje individual del uso de algoritmos en el análisis de la iluminación.

En la **Figura 3.3** se muestra en valores porcentuales el uso de los diferentes algoritmos empleados en el análisis del ruido agrupados por tipos, se evidencia que, al igual que el caso de la iluminación, árboles de decisión con un 33% y redes neuronales con 28% son los tipos de algoritmos más usados, por lo que nuevamente son los principales candidatos

para implementarlos, los demás como SVM con 9%, GRP, XGB, Logistic, DBSCAN, GBM y GLM con 5% de uso, pueden descartarse.

Para determinar el algoritmo específico que se puede usar, se presenta la **Figura 3.4**, donde se observa el porcentaje individual de uso de cada algoritmo para el análisis del ruido (considerando sólo los de tipo árboles de decisión y redes neuronales). Se distingue que BPNN, RF y ANN son los más usados, con un porcentaje de 15,4% para cada uno, por lo que cualquiera de estos puede ser usado para analizar el confort del ambiente de estudio a nivel de ruido.

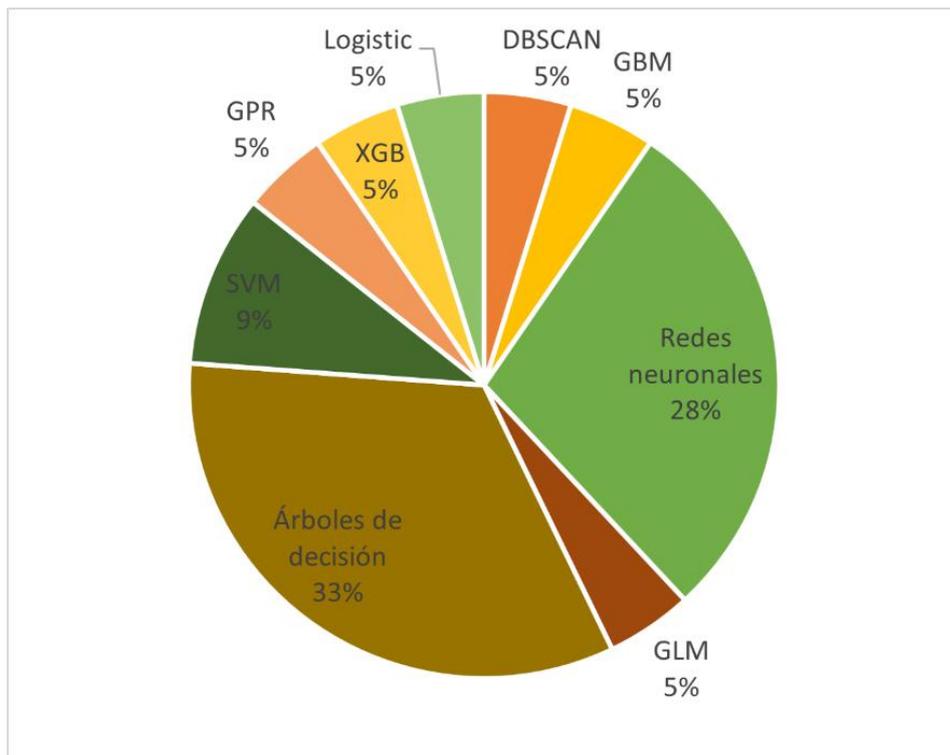


Figura 3.3 Porcentaje de uso de tipos de algoritmos en análisis del ruido

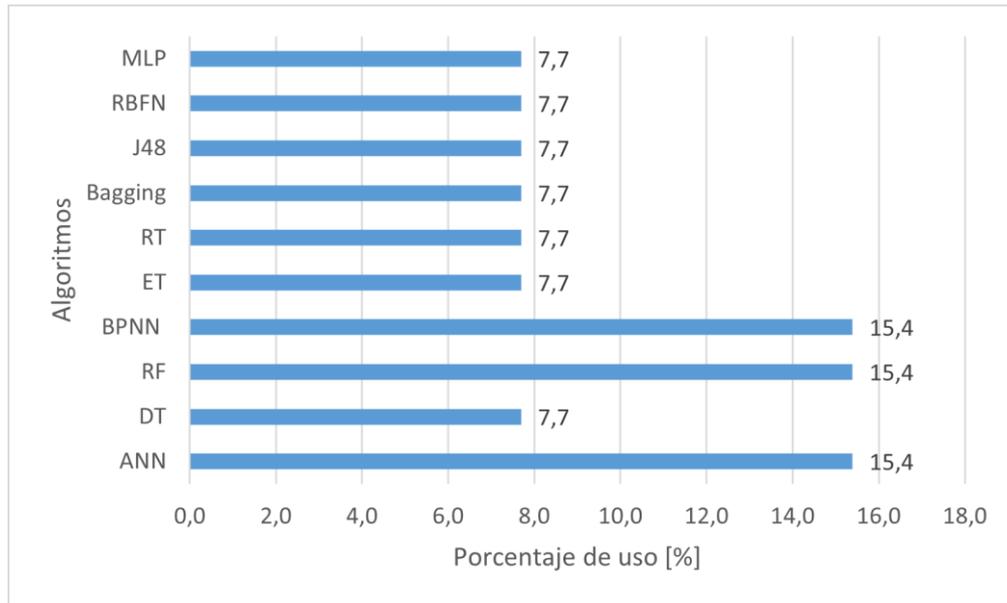


Figura 3.4 Porcentaje individual del uso de algoritmos en el análisis del ruido

Teniendo en cuenta que RF es de mayor uso en el análisis del ruido junto con BPNN y ANN, a la vez que en el análisis de iluminación es el más usado, se concluye que es el algoritmo que se debería usar para detectar el nivel de confort en el ambiente de estudio de jóvenes universitarios.

3.1.2. Comparación de las métricas de rendimiento de los algoritmos de aprendizaje de máquina analizados en los casos de estudio

De acuerdo a las métricas usadas en los casos de estudio revisados, a un algoritmo se lo considera de buen rendimiento cuando: Su valor RMSE es más bajo que el de los otros algoritmos con los que se lo compara y también cuando los valores de R^2 y precisión son más altos.

Para los estudios relacionados al análisis de la iluminación, hay casos que han establecido desde un inicio el algoritmo de machine learning que se iba a utilizar, tal es el caso de los estudios [23], [44], [46]; mientras que otros como [45], [47], [48], se enfocaron en comparar el rendimiento de los algoritmos para determinar cuál es el que mejor predice.

En ese caso en [45], RF y DNN con 4 capas ocultas pueden considerarse que tienen un buen rendimiento, pues DNN tiene valores de R^2 de entrenamiento y prueba ligeramente mayores a los de RF, mientras que RF tiene un valor de RMSE de prueba menor a DNN. En [47], se observa que RF es el algoritmo de mejor rendimiento, pues los valores de R^2 son mayores y los de RMSE menores que los de ANN. En [48] la precisión de RF es mayor que la de los demás algoritmos, por lo que es el que mejor rendimiento tiene en ese caso.

Para observar los valores de R^2 y RMSE de los algoritmos en los casos de estudio asociados a la iluminación, refiérase a la **Tabla 2.4**, y a la **Tabla 2.2** para ver los valores de precisión.

Para los estudios relacionados al ruido, también hay casos que usan un único algoritmo como en [50], [51], [54], mientras que en [52], [53], [55] sí se hace una comparación.

En [52], ANN con la simulación monte carlo, es la de mejor rendimiento, pues tiene los valores más altos de R^2 y los más bajos de RMSE, aun así, RF también tiene valores similares que ANN en términos de R^2 , pero en cuanto a RMSE sus valores son mayores, lo que indica que ANN es mejor en este caso. En [53], BPNN con 24 capas ocultas es el que tiene los mejores valores de R^2 , por otro lado, GPR y BPNN con 4 capas ocultas tienen valores de RMSE mucho más bajos, por lo que aquí es más difícil determinar cuál es el mejor, pero como BPNN con diferente número de capas ocultas ofrece diferentes valores de R^2 y RMSE, se tendría que probar BPNN con diferentes números de capas para ver con qué configuración se tiene mejores resultados. En [55], directamente se observa que el mejor algoritmo es el que combina a Bagging con RF, sin embargo, usando sólo RF también se tiene valores cercanos, por lo que individualmente es el algoritmo de mejor rendimiento en este caso.

Para observar los valores de R^2 y RMSE de los algoritmos en los casos de estudio asociados al ruido, refiérase a la **Tabla 2.7**, y a la **Tabla 2.5** para ver los valores de precisión.

Después de analizar las métricas de rendimiento en los estudios asociados a iluminación, se determina que RF es el algoritmo indicado para predecir niveles de iluminancia, mientras que en los estudios relacionados al ruido, aunque RF no fue el mejor en ninguno de ellos, sí obtuvo un rendimiento similar a aquellos que fueron los mejores, por lo que sí puede ser considerado también para predecir niveles de ruido.

3.1.3. Comparación de factores de iluminación y ruido analizados en los casos de estudio

Los factores o parámetros analizados en los casos de estudio relacionados a la iluminación son los que se muestran en la **Figura 3.5**. Se observa que son 6 parámetros revisados y que se consideran afectan al nivel de confort de una persona.

De acuerdo a los estudios revisados, el parámetro “Estantes de luz” hace referencia al hecho de que una habitación tenga este tipo de diseño, “Índice de deslumbramiento” es el grado o intensidad la luz que recibe la vista de una persona, “Índice de reproducción

cromática” es la capacidad de una fuente de luz para reproducir los colores en comparación con la luz natural, “Sombras de agentes externos” es la sombra producida por agentes ajenos a una habitación como árboles, postes, entre otros, “Diseño de ventanas/techos” es la geometría, forma o características físicas de ventanas y techos e “Iluminancia” que es la cantidad de luz que incide sobre una superficie.

De la **Figura 3.5** se observa que el parámetro “Iluminancia” es el único que se revisa en todos los casos de estudio, teniendo una presencia del 100%; dicho valor se refleja normalizado y en color naranja en la **Figura 3.5**, mientras que en color amarillo se muestra el número de veces que se revisa en los 7 casos de estudio de iluminación.

Se concluye entonces que la iluminancia es un factor relevante que afecta el nivel de confort de un ambiente, y que debe ser considerado para la propuesta de una alternativa de detección del nivel de confort del ambiente de estudio.

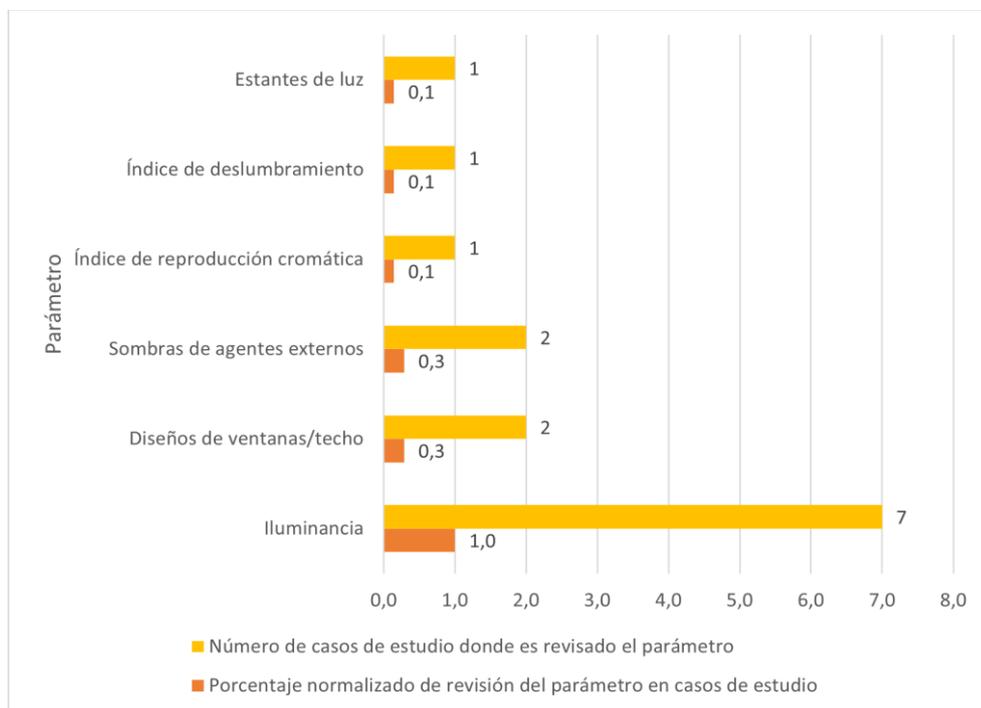


Figura 3.5 Factores analizados en los casos de estudio de iluminación

Los factores que afectan la percepción de confort de acuerdo a los estudios relacionados al ruido son 5 y son los que se presentan en la **Figura 3.6**.

Los casos de estudio revisados mencionan el parámetro “Velocidad media de circulación” como la velocidad promedio con la que circulan los vehículos cerca de la zona donde se desarrolló el estudio, “Volumen de tráfico” es la cantidad de vehículos que circulan en las

cercanías de la zona del estudio, “Frecuencia de uso de dispositivos de audio o fuentes de ruido” es la cantidad de veces que se utiliza una fuente sonora, “Tiempo de exposición a fuentes de ruido” es el tiempo que se usa una fuente sonora e “Intensidad de ruido” son los niveles de ruido que genera una fuente de audio.

De la **Figura 3.6** se distingue que la intensidad de ruido tiene una presencia en el 100% de los casos revisados, por lo que, al igual que la iluminancia, es un factor que se debe considerar en la propuesta de una alternativa de detección del nivel de confort del ambiente de estudio, sin embargo, los parámetros: “Tiempo de exposición a fuentes de ruido” y “Frecuencia de uso de dispositivos de audio o fuentes de ruido” son factores que se pueden controlar y medir mediante un smartphone, convirtiéndolos también en parámetros a considerar para la propuesta de una alternativa de detección del nivel de confort del ambiente de estudio.

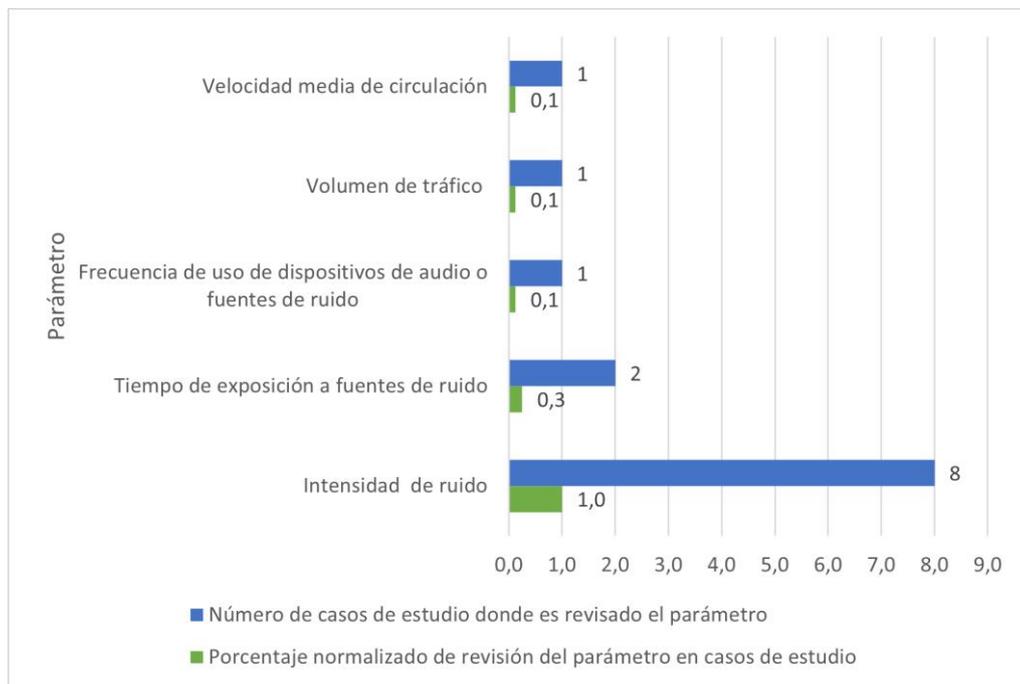


Figura 3.6 Factores analizados en los casos de estudio de ruido

Después de revisar los factores de ruido e iluminación presentes en los casos de estudio, se determina que tanto la iluminancia, la frecuencia de uso de una fuente de audio, el tiempo de exposición a una fuente sonora y la intensidad de ruido, son variables cuantificables que pueden ser medidas y controladas mediante un smartphone, lo que justifica la consideración de estos parámetros en la **Tabla 2.8**.

3.1.4. Propuesta de correlación de parámetros de rendimiento académico con medidas de iluminación y ruido obtenidas por sensores

Con los datos que se recopilan de los sensores (medidas de iluminancia y ruido), los promedios bimestrales de cada materia y el tiempo dedicado a cada sesión de estudio (obtenido a partir de las encuestas), pueden ser parámetros considerados en la fase de correlación, pero de acuerdo con la **Figura 3.6**, se aprecia que el tiempo de exposición a una fuente de ruido también tiene influencia en el nivel de confort que percibe una persona, por lo que es otro factor que se podría considerar; de modo que la correlación se realice sobre estos 5 parámetros (iluminancia, ruido, promedios, tiempo de estudio y tiempo de exposición a fuentes de ruido).

En esta etapa para hacer la correlación, es posible valerse de la ayuda de herramientas de software como Risk [58], donde se puede realizar la matriz de correlación para determinar el grado de dependencia entre las variables mencionadas, un aspecto importante a tomar en cuenta es que se debe de establecer un umbral o valor base a partir del cual se pueda concluir si hay o no correlación entre las variables consideradas.

3.1.5. Consideraciones para implementar una aplicación móvil para detección del nivel de ambiente de estudio

La primera consideración que se debe hacer por parte del desarrollador de la aplicación es que, se debe elaborar un acuerdo donde los usuarios de la aplicación autoricen bajo su pleno conocimiento, el uso de sus datos personales por parte del administrador de la aplicación. [59].

De la misma manera, se tomó en consideración que el periodo de prueba de la aplicación debe ser al menos un ciclo académico universitario, por ejemplo, durante un semestre.

De acuerdo con la **Figura 3.2** y **Figura 3.4**, se propone trabajar con los algoritmos ANN o RF, ya que son los que mejor rendimiento demuestran en los casos de estudio donde se ha analizado iluminancia y ruido.

Para el análisis del algoritmo escogido en la fase de tratamiento de datos de la **Figura 2.2**, es posible emplear herramientas como WEKA [60], que es un software dentro del cual se puede realizar funciones como entrenamiento, validación y configuración de los parámetros del algoritmo con el que se vaya a trabajar. También se puede considerar Risk, una herramienta de software complementaria a Excel para hacer análisis de datos y con la que se puede crear la matriz de correlación de variables [58].

En cuanto a la escritura en código del algoritmo de aprendizaje máquina, se debe hacer uso de algún lenguaje que permita desarrollar aplicaciones móviles y que cuente con la ayuda de un *Integrated Development Environment* (IDE) para una mayor facilidad y comodidad, por ejemplo, el framework Kivy, el cual al ser un kit de desarrollo con características de multiplataforma basado en Python ofrece la gran ventaja de poder ser utilizado para el desarrollo de aplicaciones móviles para sistemas operativos como Android e iOS, incluso puede expandirse a ordenadores Linux, Windows y macOS [61], otras opciones también pueden ser Pycharm, Eclipse, AndroidStudio, NetBeans, entre otros [62]–[65];

3.2. Conclusiones

A nivel de utilización en los casos de estudio, el algoritmo *Random Forest* (RF), es el principal candidato para implementarse en la propuesta de detección del nivel de confort en un ambiente de estudio, ya que es el que tiene más presencia en detección de nivel de iluminación, y en cuanto a ruido también junto con ANN y BPNN.

A nivel de métricas de rendimiento, para los casos de iluminación RF fue el de mejor rendimiento, mientras que para los de ruido no, sin embargo, en los estudios de ruido su rendimiento fue cercano a los algoritmos que sí tuvieron el mejor desempeño, por lo que sí puede ser considerado para predecir niveles de ruido, y de esa manera se evitaría tener un algoritmo para predecir iluminación y otro para ruido.

En base a que RF es el algoritmo más usado en los casos de estudio, además de que sí puede emplearse para predecir niveles de iluminancia y ruido, lo cataloga como el algoritmo que se debe emplear para la propuesta de detección de nivel de confort de un ambiente de estudio.

Se puede implementar algoritmos híbridos para tener un mejor desempeño predictivo acerca de la percepción del nivel de confort que aprecia el usuario, de la misma manera para su análisis es posible emplear herramientas como WEKA para probar el rendimiento de los diferentes algoritmos.

Los factores analizados en los diferentes casos de estudio tienen la particularidad de que en el apartado de la iluminación, el que se toma en cuenta en todos los estudios es la iluminancia, mientras que para el caso del ruido, es la intensidad del ruido, por lo que en base a esos hechos se genera una tendencia directa a considerar estos dos parámetros como entradas para el algoritmo de machine learning de la propuesta de aplicación móvil.

El hecho de usar los sensores del smartphone para censar continuamente los valores de iluminación y ruido hace que los recursos del dispositivo sean malgastados durante gran parte del tiempo, ya que el estudiante a lo largo del día destina una parte específica para estudiar, por lo que se empleó un mecanismo que mediante un botón active y desactive los sensores para inferir el nivel de confort del ambiente de estudio, de esa manera se resguardan aspectos como la batería del smartphone.

Hay otros factores que no son mencionados en los casos de estudio, pero que de la misma forma influyen en el rendimiento académico de los estudiantes, por ejemplo, el horario de clases, el cual está fuera del alcance del control de la aplicación móvil

3.3. Recomendaciones

Considerar en implementaciones futuras indicadores de rendimiento académico basados en créditos, de esa forma se puede extender el alcance de la aplicación para su uso en instituciones donde utilicen en estas métricas.

Al momento de obtener los valores de iluminación y ruido de un lugar durante una sesión de estudio, el periodo de muestreo que se va registrando cada t segundos, puede ser cambiado por otra unidad de tiempo, como minutos u horas, de acuerdo con la conveniencia o finalidad que se tenga con los datos.

A futuro, la alternativa de aplicación móvil propuesta puede incorporar funciones como un chatbot donde se muestren mensajes con información y sugerencias para influir en el comportamiento del estudiante y que de esa manera mejore las condiciones de iluminación y ruido en su lugar de estudio.

Una alternativa que posteriormente se podría agregar al funcionamiento de la propuesta de aplicación móvil es que, al momento de iniciar un monitoreo en tiempo real, se deshabiliten funciones como wifi, sonido y bluetooth, o simplemente que se active el “modo avión” del smartphone, para que se reduzcan las distracciones sobre estudiante y de esa manera incrementar su atención en la sesión de estudio.

4. REFERENCIAS BIBLIOGRÁFICAS

- [1] K.-K. R. Choo, "Internet of Things (IoT) Security and Forensics," pp. 27–28, Nov. 2021, doi: 10.1145/3462633.3484691.
- [2] A. Páez Montoro, M. García Valderas, E. Olías Ruíz, and C. López Ongil, "Solar Energy Harvesting to Improve Capabilities of Wearable Devices," *Sensors* 2022, Vol. 22, Page 3950, vol. 22, no. 10, p. 3950, May 2022, doi: 10.3390/S22103950.
- [3] J. Ramos Fernández, "Aprendizaje automático para flujos de datos," 2019.
- [4] R. Xiong, "Research on the Effects of Learning environment on Students' Academic Performance," *ACM International Conference Proceeding Series*, pp. 91–94, Jul. 2019, doi: 10.1145/3345094.3345104.
- [5] G. M. Garbanzo Vargas, "Factores asociados al rendimiento académico en estudiantes universitarios, una reflexión desde la calidad de la educación superior pública ." Accessed: Aug. 22, 2022. [Online]. Available: <https://www.redalyc.org/pdf/440/44031103.pdf>
- [6] S. N. Barreno Freire, O. Haro Jácome, and P. Flores Yandún, "Relación entre rendimiento académico y asistencia como factores de promoción estudiantil," *Cátedra*, vol. 2, no. 1, pp. 44–59, Jan. 2019, doi: 10.29166/catedra.v2i1.1552.
- [7] J. Tejedor Tejedor, "Poder explicativo de algunos determinantes del rendimiento en los estudios universitarios," pp. 5–32, 2003.
- [8] D. E. Agualongo Quelal and A. C. Garcés Alencastro, "El nivel socioeconómico como factor de influencia en temas de salud y educación," *Revista Vínculos*, vol. 5, no. 2, May 2020, doi: 10.24133/vinculospe.v5i2.1639.
- [9] S. Maris Vazquez, "RENDIMIENTO ESCOLAR Y ESFUERZO: HACIA LA REVALORACIÓN DE LA AUTONOMÍA PERSONAL EN EL PROCESO EDUCATIVO".
- [10] R. Ramirez-Vazquez, I. Escobar, A. Beléndez, and E. Arribas, "FACTORES QUE AFECTAN EL RENDIMIENTO ACADÉMICO FATORES QUE AFETAM O DESEMPENHO ACADÊMICO", doi: 10.26571/reamec.v8i3.10842.
- [11] L. F. Barrera Hernández, M. A. Sotelo Castillo, R. A. Barrera Hernández, and J. Aceves Sánchez, "Bienestar psicológico y rendimiento académico en estudiantes universitarios," 2018.
- [12] R. O. Chang Mata, "Relación entre el desempeño académico y las horas de estudio invertidas en un Colegio de Bachilleres," 2016.
- [13] B. W. Niebel and A. Freivalds, *Ingeniería industrial métodos, estándares y diseño del trabajo*.
- [14] M. Noel, R. Ayán, M. Ángel, and R. Díaz, "Indicadores de rendimiento de estudiantes universitarios: calificaciones versus créditos acumulados University students' academic achievement indicators: grades versus cumulative credits," *Fecha de entrada*, vol. 355, pp. 6–11, 2011.

- [15] I. Bernal Carrillo *et al.*, “ACTA RESOLUTIVA SESIÓN ORDINARIA 23-CD-EPN-2021 CONSEJO DE DOCENCIA ESCUELA POLITÉCNICA NACIONAL.” Dec. 22, 2021.
- [16] S. Muñoz Muñoz, “INDICADORES DE RENDIMIENTO ACADÉMICO DEL ALUMNADO DE LA UNIVERSIDAD DE LA LAGUNA”.
- [17] Á. J. Morejón Miniguano, “CONDICIONES DE ILUMINACIÓN QUE INCIDEN EN EL CONFORT VISUAL DE LOS OCUPANTES DE LABORATORIOS DE LA UNIVERSIDAD TÉCNICA DE AMBATO - CAMPUS HUACHI”, 2017.
- [18] R. Forster, F. Ramos, A. Hernández, A. Smith, and J. Guasch, “ILUMINACION.”
- [19] Instituto Nacional de Seguridad e Higiene en el Trabajo (INSHT, “ILUMINACIÓN EN EL PUESTO DE TRABAJO Criterios para la evaluación ergonómica y acondicionamiento de los puestos,” 2015.
- [20] SYLVANIA, “Guía Técnica de Iluminación.”
- [21] “Todo sobre la intensidad luminosa, el flujo luminoso y la iluminancia.” <https://www.auersignal.com/es/datos-tecnicos/indicacion-luminos/intensidad-luminosa/> (accessed Nov. 15, 2022).
- [22] Mutua Colaboradora con la Seguridad Social nº 61, “RECOMENDACIONES BÁSICAS SOBRE ILUMINACIÓN.”
- [23] G. Qiang, Z. Kun, and L. Dahua, “Research on Visual Comfort Based on Fuzzy Neural Network.” Aug. 2018.
- [24] MS Schippers, “LUX Meter Operating instructions 4309781,4309782”.
- [25] P. Tabaka and J. Wtorkiewicz, “Analysis of the Spectral Sensitivity of Luxmeters and Light Sensors of Smartphones in Terms of Their Influence on the Results of Illuminance Measurements—Example Cases,” *Energies (Basel)*, vol. 15, no. 16, Aug. 2022, doi: 10.3390/en15165847.
- [26] Universidad de Nebrija, “Estudio sobre la influencia de la iluminación en el rendimiento escolar.”
- [27] A. Laquidara, I. Pablo Perez, D. Carlos, A. Giordana, and N. Vechiatti, “El Decibel.”
- [28] STAR-ORION SOUTH DIAMOND PROJECT ENVIRONMENTAL IMPACT STATEMENT, “APPENDIX 5.2.5-A FUNDAMENTALS OF ACOUSTICS,” 2010.
- [29] P. F. Pérez, “Boletín Informativo Decibel.”
- [30] TROTEC, “MANUAL DE INSTRUCCIONES SONÓMETRO DIGITAL.” [Online]. Available: <http://hub.trotec.com/?id=39644>
- [31] S. You, C. Kwak, and W. Han, “Use of personal listening devices and knowledge/attitude for greater hearing conservation in college students: Data analysis and regression model based on 1009 respondents,” *Int J Environ Res Public Health*, vol. 17, no. 8, Apr. 2020, doi: 10.3390/ijerph17082934.
- [32] S. L. Sinche Maita, “NEW MODELS OF RELIABILITY IN THE NEW GENERATION OF INTERNET OF THINGS,” 2020.

- [33] D. F. Buitrón Ruiz, “ESTADO DEL ARTE DE LAS ARQUITECTURAS PARA SISTEMAS IOT”.
- [34] M. Liu, “A study of mobile sensing using smartphones,” *Int J Distrib Sens Netw*, vol. 2013, 2013, doi: 10.1155/2013/272916.
- [35] M. Monteiro, C. Stari, and A. C. Marti, “Los sensores de los dispositivos móviles: una herramienta innovadora en la enseñanza de las ciencias físicas.”
- [36] P. M. Parra, “USO DE LOS SMARTPHONES EN LOS LABORATORIOS DE PRÁCTICAS DE FÍSICA,” Universidad de Valladolid, 2017.
- [37] L. Judith Sandoval, “ALGORITMOS DE APRENDIZAJE AUTOMÁTICO PARA ANÁLISIS Y PREDICCIÓN DE DATOS.”
- [38] J. di Deco Sampedro, “Estudio y aplicación de técnicas de aprendizaje automático orientadas al ámbito médico: estimación y explicación de predicciones individuales”.
- [39] Á. F. Godoy Viera, “Técnicas de aprendizaje de máquina utilizadas para la minería de texto,” pp. 103–126.
- [40] “Tablero Kanban Explicado en 6 Minutos | Kanban Tool.” <https://kanbantool.com/es/tablero-kanban> (accessed Nov. 22, 2022).
- [41] “Regresión lineal simple”.
- [42] J. Martinez Heras, “Error Cuadrático Medio para Regresión - IArtificial.net,” Oct. 10, 2020. <https://www.iartificial.net/error-cuadratico-medio-para-regresion/> (accessed Jan. 14, 2023).
- [43] ORACLE, “RMSE (Error cuadrático medio).” https://docs.oracle.com/cloud/help/es/pbcs_common/PFUSU/insights_metrics_RMSE.htm#PFUSU-GUID-FD9381A1-81E1-4F6D-8EC4-82A6CE2A6E74 (accessed Jan. 14, 2023).
- [44] S. Ruggiero *et al.*, “Multi-Objective Optimization for Cooling and Interior Natural Lighting in Buildings for Sustainable Renovation,” *Sustainability (Switzerland)*, vol. 14, no. 13, Jul. 2022, doi: 10.3390/su14138001.
- [45] J. Ngarambe, A. Irakoze, G. Y. Yun, and G. Kim, “Comparative performance of machine learning algorithms in the prediction of indoor daylight illuminances,” *Sustainability (Switzerland)*, vol. 12, no. 11, Jun. 2020, doi: 10.3390/su12114471.
- [46] C.-L. Lorenz, M. Packianather, A. B. Spaeth, C. Bleil, and D. Souza, “Artificial Neural Network-Based Modelling for Daylight Evaluations,” 2018.
- [47] M. W. Ahmad, J. L. Hippolyte, M. Mourshed, and Y. Rezgui, “Random forests and artificial neural network for predicting daylight illuminance and energy consumption,” in *Building Simulation Conference Proceedings*, 2017, vol. 2, pp. 943–949. doi: 10.26868/25222708.2017.525.
- [48] G. Ma and X. Pan, “Research on a Visual Comfort Model Based on Individual Preference in China through Machine Learning Algorithm,” *Sustainability (Switzerland)*, vol. 13, no. 14, Jul. 2021, doi: 10.3390/su13147602.

- [49] X. Huang, J. Liu, and Z. Meng, "Application of University Campus Noise Map Based on Noise Propagation Model: A Case in Guangxi University," *Sustainability (Switzerland)*, vol. 14, no. 14, Jul. 2022, doi: 10.3390/su14148613.
- [50] A. Boumchich, J. Picaut, and E. Bocher, "Using a Clustering Method to Detect Spatial Events in a Smartphone-Based Crowd-Sourced Database for Environmental Noise Assessment," *Sensors*, vol. 22, no. 22, Nov. 2022, doi: 10.3390/s22228832.
- [51] P. J. Wen and C. Huang, "Noise prediction using machine learning with measurements analysis," *Applied Sciences (Switzerland)*, vol. 10, no. 18, Sep. 2020, doi: 10.3390/APP10186619.
- [52] D. Singh, P. Kaler, I. Lyall, A. Singh, and H. S. Pannu, "Traffic noise prediction using machine learning and monte carlo data augmentation: A case study on the Patiala city in India," in *Journal of Physics: Conference Series*, Jan. 2022, vol. 2162, no. 1. doi: 10.1088/1742-6596/2162/1/012021.
- [53] G. Tan, Q. Chen, C. Li, and R. Yang, "A machine learning model for predicting noise limits of motor vehicles in unece r51 regulations," *Applied Sciences (Switzerland)*, vol. 10, no. 22, pp. 1–16, Nov. 2020, doi: 10.3390/app10228092.
- [54] Z. Huan, S. Haiyan, and S. Ying, *Using Machine Learning to Predict Noise-induced Annoyance*. 2018.
- [55] A. Abdulla Shaltooqi and M. Jamshidi, "The Use of Data Mining Techniques in Predicting the Noise Emitted by the Trailing Edge of Aerodynamic Objects," 2019.
- [56] "Entrenamiento y pruebas de conjuntos de datos | Microsoft Learn." <https://learn.microsoft.com/es-es/analysis-services/data-mining/training-and-testing-data-sets?view=asallproducts-allversions> (accessed Jan. 15, 2023).
- [57] S. Graciela, P. Ibarra, R. Quispe, F. F. Mullicundo, D. A. Lamas, and L. Presente, *HERRAMIENTAS Y TECNOLOGÍAS PARA EL DESARROLLO WEB DESDE EL FRONTEND AL BACKEND*. [Online]. Available: <https://www.campusmvp.es/recursos/post/Desar>
- [58] "@RISK | Risk Analysis using Monte Carlo Simulation in Excel | Palisade." <https://www.palisade.com/risk/> (accessed Jan. 30, 2023).
- [59] S. Sinche *et al.*, "Analysis of Student Academic Performance Using Human-in-the-Loop Cyber-Physical Systems," *Telecom*, vol. 1, no. 1, pp. 18–31, Mar. 2020, doi: 10.3390/telecom1010003.
- [60] "Weka 3 - Data Mining with Open Source Machine Learning Software in Java." <https://www.cs.waikato.ac.nz/ml/weka/> (accessed Jan. 15, 2023).
- [61] "Kivy: Cross-platform Python Framework for GUI apps Development." <https://kivy.org/> (accessed Jan. 30, 2023).
- [62] "PyCharm: the Python IDE for Professional Developers by JetBrains." <https://www.jetbrains.com/pycharm/> (accessed Jan. 15, 2023).
- [63] "Eclipse Desktop & Web IDEs | The Eclipse Foundation." <https://www.eclipse.org/ide/> (accessed Jan. 30, 2023).

- [64] "Download Android Studio & App Tools - Android Developers."
<https://developer.android.com/studio> (accessed Jan. 30, 2023).
- [65] "Welcome to Apache NetBeans." <https://netbeans.apache.org/> (accessed Jan. 30, 2023).

5. ANEXOS

Anexo I. Tablero Kanban

Anexo II. Tabla comparativa de los parámetros de rendimiento para algoritmos usados en estudios de iluminación y ruido

ANEXO I.1 Tablero Kanban (Semana 9)

Por hacer	En Progreso	Completado
+	+	+
Definir los parámetros que permiten medir el rendimiento académico de los estudiantes universitarios	Proponer un esquema que puede ser implementado a futuro para monitorear el ambiente de estudio utilizando un teléfono inteligente	Generación del modelo Kanban
Revisión del borrador por parte del profesor tutor.		Estudiar los factores que influyen en el rendimiento académico de los estudiantes universitarios
Redacción del documento escrito		Estudiar los sensores disponibles en los teléfonos móviles.
		Recopilar información de aplicaciones IoT que permitan monitorear el ambiente de estudio con literatura publicada en los últimos 5 años.
		Analizar la información recopilada.
		Estudiar las técnicas de aprendizaje de máquina utilizadas para la detección de factores que influyen en el ambiente de estudio.
		Comparar los parámetros que se utilizan en cada trabajo para determinar el nivel de confort del ambiente de estudio
		Definir el tipo de aprendizaje máquina recomendado para inferir el nivel de confort del ambiente de estudio

ANEXO II.1 Comparación de parámetros de rendimiento para algoritmos usados en estudios de iluminación

Estudio	Algoritmo	R ² _E	R ² _P	RMSE _E	RMSE _P	Precisión [%]
[44]	GA	N/D	N/D	N/D	N/D	N/D
[23]	Redes neuronales difusas	N/D	N/D	N/D	N/D	N/D
[45]	GLM	0.292	0.289	N/D	N/D	N/D
	RF con 10 árboles	0.989	0.954	228.256	155.564	N/D
	GBM con 1000 árboles	0.969	0.967	393.956	403.989	N/D
	DNN con 4 capas ocultas	0.992	0.990	195.301	211.443	N/D
[46]	ANN con 13 capas ocultas	N/D	N/D	N/D	0.63	N/D
[47]	RF	0.9870	0.9881	235.738	227.87	N/D
	ANN 1 capa oculta	0.9814	0.9799	272.354	278.498	N/D
[48]	CTree	N/D	N/D	N/D	N/D	70
	RF	N/D	N/D	N/D	N/D	85
	GMM	N/D	N/D	N/D	N/D	76
	KSVM	N/D	N/D	N/D	N/D	71

ANEXO III.2 Comparación de parámetros de rendimiento para algoritmos usados en estudios de ruido

Estudio	Algoritmo	R ² _E	R ² _P	RMSE _E	RMSE _P	Precisión [%]
[50]	DBSCAN	N/D	N/D	N/D	N/D	N/D
[51]	GBM	N/D	> 0.7	N/D	N/D	N/D
[52]	ANN	0.9	0.91	0.49	0.45	N/D
	GLM	0.86	0.89	0.63	0.58	N/D
	DT	0.89	0.89	0.56	0.52	N/D
	RF	0.97	0.92	0.28	0.43	N/D
	ANN (monte carlo)	0.99	0.99	0.18	0.22	N/D
[53]	BPNN (24 capas ocultas)	0.998	0.999	0.526	1.03	N/D
	SVM	N/D	N/D	N/D	0.663	N/D
	GPR	N/D	N/D	N/D	0.312	N/D
	ET	N/D	N/D	N/D	14.8	N/D
	RT	N/D	N/D	N/D	4.76	N/D
	BPNN (4 capas ocultas)	N/D	N/D	N/D	0.444	N/D
[54]	XGB	N/D	0.916	N/D	0.2983	N/D
[55]	Bagging	N/D	N/D	N/D	0.25	73
	RF	N/D	N/D	N/D	0.24	77
	J48	N/D	N/D	N/D	0.27	72
	RBFN	N/D	N/D	N/D	0.30	55
	Logistic	N/D	N/D	N/D	0.31	57
	MLP	N/D	N/D	N/D	0.28	64
	SVM	N/D	N/D	N/D	0.33	44
Bagging y RF	N/D	N/D	N/D	0.23	77.5	