

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 SUEÑO, UTILIZANDO APLICACIONES IOT

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

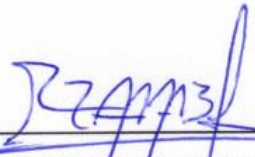
ROMMEL FRANCISCO ARÉVALO MOREIRA

DIRECTOR: SORAYA LUCÍA SINCHE MAITA

DMQ, Febrero 2023

CERTIFICACIONES

Yo, Rommel Francisco Arévalo Moreira 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.



ROMMEL FRANCISCO ARÉVALO MOREIRA

Certifico que el presente trabajo de integración curricular fue desarrollado por Rommel Francisco Arévalo Moreira, bajo mi supervisión.



SORAYA LUCÍA SINCHE MAITA

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.



ROMMEL FRANCISCO ARÉVALO MOREIRA



SORAYA LUCÍA SINCHE MAITA, PHD

DEDICATORIA

Dedico este trabajo a mis padres que son mi fuente de inspiración y mi motor, con ustedes ningún reto es demasiado grande.

A Alexandra, Alberto y en especial a Ronald espero que su cariño y su recuerdo sean atemporales.

AGRADECIMIENTO

Agradezco a mi familia y en especial a mis padres por el cariño, motivación, apoyo y comprensión durante toda mi vida, además de confiar de manera inagotable en mí.

A Ing. Soraya Sinche por su guía y apoyo y la dedicación brindada en la construcción de este trabajo.

A Ing. Pablo Hidalgo por sus consejos y motivación para afrontar distintos retos durante la vida universitaria.

A los amigos obtenidos durante mi formación por la amistad y por compartir distintos momentos y logros durante este proceso.

A Mary por su apoyo y consideración en este tiempo.

A la Escuela Politécnica Nacional por los conocimientos impartidos y por enseñarme a aprender.

ÍNDICE DE CONTENIDO

CERTIFICACIONES	I
DECLARACIÓN DE AUTORÍA	II
DEDICATORIA	III
AGRADECIMIENTO	IV
RESUMEN	X
ABSTRACT	XI
1. DESCRIPCIÓN DEL COMPONENTE DESARROLLADO	1
1.1 Objetivo general	1
1.2 Objetivos específicos.....	1
1.3 Alcance	2
1.4 Marco teórico.....	2
1.4.1. Calidad de sueño	3
1.4.2 Rendimiento académico.....	4
1.4.3 El sueño y el rendimiento académico.....	4
1.4.4 Indicadores que miden el rendimiento académico	5
1.4.5 Factores que afectan el rendimiento académico.....	8
1.4.6 Mecanismos para medición del sueño	9
1.4.7 Sensores que permiten medir el Sueño.....	10
1.4.8 Aprendizaje de máquina.....	10
1.4.8.1 Técnicas de aprendizaje de máquina.....	11
1.4.8.2 Técnicas de aprendizaje de máquina utilizadas para inferir nivel de sueño	12
2. METODOLOGÍA.....	14
2.1 Análisis metodológico	15
2.1.1 Métodos de medición según el dispositivo de medición.....	16
2.1.2 Metodologías utilizadas en análisis de sueño.....	21
2.1.3 Parámetros utilizados para inferir el comportamiento durante el sueño.....	22
2.1.4 Metodología cualitativa para detección de sueño.....	23
2.2 Características de las técnicas de aprendizaje de máquina más utilizadas en el análisis de sueño	25
2.3 Proceso de tratamiento y procesamiento de la información.....	26
2.3.1 Bloque 1: Recolección de datos.....	27
2.3.2 Bloque 2: Preprocesamiento de datos.....	29

2.3.3 Bloque 3: Aprendizaje de máquina	30
2.3.4 Bloque 4: Nivel de calidad de sueño	30
2.3.5 Bloque 5: Correlación	32
2.3.6 Bloque 6: Aplicación (GUI)	32
2.4 Componentes necesarios en la construcción de la aplicación para monitoreo de sueño	33
2.4.1 Inicio de sesión	35
2.4.2 Registro de usuario	35
2.4.3 Recuperación de contraseña	36
2.4.4 Sesiones de usuario	37
2.4.5 Reportes de resultados	42
2.4.6 Alternativas de almacenamiento de datos en la aplicación	42
3. RESULTADOS, CONCLUSIONES Y RECOMENDACIONES	44
3.1 Resultados	44
3.1.1 Requerimientos mínimos para creación de aplicación móvil de monitoreo del sueño	47
3.1.2 Factores que deben ser considerados para la realización del estudio de prueba	49
3.1.3 Alternativas para recolección de datos	50
3.2 Conclusiones	50
3.3 Recomendaciones	51
4. REFERENCIAS BIBLIOGRÁFICAS	53
5. ANEXOS	
ANEXO I.1 Tablero <i>kanban</i> semana 1	
ANEXO I.3 Tablero <i>kanban</i> semana 5	
ANEXO I.2 Tablero <i>kanban</i> semana 8	

ÍNDICE DE ECUACIONES

Ecuación 1.1 Ecuación de cálculo para SGPA	5
Ecuación 1.2 Ecuación de cálculo para CGPA	6
Ecuación 1.3 Ecuación de cálculo para GPA	6
Ecuación 1.4 Ecuación de cálculo para IRA	6
Ecuación 1.5. Ecuación de cálculo para RIA [12]	7
Ecuación 1.6. Ecuación de cálculo para ILC [12].....	7
Ecuación 1.7. Ecuación de cálculo para RAG [12].....	7

ÍNDICE DE FIGURAS

Figura 1.1	Clasificación de técnicas de aprendizaje basado en [36]	12
Figura 2.1.	Tablero <i>kanban</i> en la semana 1 del trabajo de integración	14
Figura 2.2	Flujograma de ejecución de análisis de sueño y rendimiento académico	27
Figura 2.3	Fase de recolección de datos de sueño	27
Figura 2.4	Flujograma de recopilación de horas de sueño mediante encuestas	28
Figura 2.5	Fase de recolección de datos utilizando encuestas para calificaciones	28
Figura 2.6	Flujograma de recopilación de calificaciones mediante encuestas	28
Figura 2.7	Fase de preprocesamiento de datos	29
Figura 2.8	Flujograma de limpieza de datos	30
Figura 2.9	Fase de aplicación de aprendizaje de máquina	30
Figura 2.10	Fase de análisis de resultados preliminares	31
Figura 2.11	Flujograma de detección de sueño en base a señales respiratorias [91].	31
Figura 2.12	Flujograma de ejecución basado en [77] para señales de luz.	32
Figura 2.13	Fase de correlación	32
Figura 2.14	Fase de presentación de resultados	33
Figura 2.15	Flujo de aplicación para inicio de sesión	34
Figura 2.16	Plantilla de inicio de sesión	35
Figura 2.17	Plantilla de registro de usuario	36
Figura 2.18	Plantilla de recuperación de contraseña	37
Figura 2.19	Plantilla de inicio desde usuario	38
Figura 2.20	Plantilla de inicio desde administrador	39
Figura 2.21	Plantilla de lista de usuarios	39
Figura 2.22	Flujo de aplicación para registro de datos	40
Figura 2.23	Plantilla de interfaz de registro de datos para sueño	41
Figura 2.24	Plantilla de interfaz de registro de datos para calificaciones	41
Figura 2.25	Plantilla para presentación de reportes y resultados de los datos obtenidos	42
Figura 2.26	Flujo de almacenamiento de datos con base en el tipo de base de datos	43
Figura 3.1	Estudios analizados según señal utilizada para sensores médicos	44
Figura 3.2	Estudios analizados según señal utilizada para sensores ambientales	45
Figura 3.3	Estudios analizados según técnica utilizada para sensores médicos	45
Figura 3.4	Estudios analizados según técnica utilizada para sensores ambientales	46
Figura 3.5	Estudios analizados según porcentaje de precisión	47

ÍNDICE DE TABLAS

Tabla 1.1 Horas de sueño promedio recomendadas según la <i>National Sleep Foundation</i> [9]	4
Tabla 1.2. Factores que afectan al rendimiento académico.....	8
Tabla 2.1. Resumen de trabajos relacionados con el análisis del sueño utilizando sensores médicos basados en [38]	16
Tabla 2.2. Resumen de ensayos realizados en análisis del sueño utilizando sensores ambientales basados en [38]	19
Tabla 2.3 Comparación de diferentes cuestionarios utilizados en el análisis de sueño [80]	24
Tabla 2.4 Comparación entre las técnicas de aprendizaje más utilizadas en el análisis del sueño [90].....	26

RESUMEN

La creciente utilización de dispositivos móviles permite contar con una herramienta que facilita recopilar distintos datos mediante los sensores propios del dispositivo, utilizando esta oportunidad es posible afrontar una problemática latente en los estudiantes universitarios como lo es la deficiente calidad de sueño y su impacto con su rendimiento académico.

En este contexto, este trabajo plantea un análisis de las distintas técnicas utilizadas en diversos estudios acerca de la calidad de sueño, así como las recomendaciones al momento de seleccionar la técnica apropiada en el análisis de sueño; además de realizar gráficos comparativos de los métodos de medición de sueño tanto de tipo médico como con sensores de tipo ambiental. En adición se analiza las encuestas más utilizadas en el análisis de sueño mediante estas herramientas.

El presente trabajo de integración curricular se estructura en tres capítulos. El primer capítulo incluye el marco teórico con los parámetros que caracterizan el sueño y el rendimiento académico, así como factores que influyen en estos comportamientos. En el segundo capítulo se muestra una recopilación de las técnicas y métodos más utilizados en el análisis de sueño, y se determinan los índices que permiten medir el rendimiento académico. Además, se propone como posible mecanismo de recolección de datos el uso de una aplicación móvil, utilizando los sensores propios del dispositivo. Finalmente, en el tercer capítulo se plantea los requerimientos mínimos que debería cumplir un prototipo de aplicación móvil, así como las sugerencias de aplicabilidad de las técnicas y encuestas analizadas.

PALABRAS CLAVE: detección de sueño, rendimiento académico, análisis de calidad de sueño, lot, dispositivos móviles.

ABSTRACT

The increasing use of mobile devices allows us to have a tool that facilitates the collection of different data through the device's own sensors. Using this opportunity, it is possible to address a latent problem in university students such as poor sleep quality and its impact on their academic performance.

In this context, this work proposes an analysis of the different techniques used in various studies on sleep quality, as well as recommendations when selecting the appropriate technique in the analysis of sleep. In addition to making comparative graphs of methods of measuring sleep both medical and environmental sensors, also to analyzing the most used surveys in the analysis of sleep.

This curricular integration work is structured in 3 chapters. Chapter 1 includes the theoretical framework with parameters that characterize sleep and academic performance, as well as factors that influence these behaviors. Chapter 2 presents a compilation of the most used techniques and methods in sleep analysis and identifies indices to measure academic performance. In addition, the use of a mobile application, utilizing the device's sensors, is proposed as a possible mechanism for data collection. Finally, Chapter 3 presents the minimum requirements that a prototype mobile application should meet, as well as suggestions for the applicability of the techniques and investigations analyzed.

KEYWORDS: sleep detection, academic performance, sleep quality analysis, lot, Mobile Devices.

1. DESCRIPCIÓN DEL COMPONENTE DESARROLLADO

La inclusión de dispositivos IoT (*Internet of Things*) permiten proporcionar diversos servicios y aplicaciones, como lo son las aplicaciones “*Smart Healthcare*”, que posibilitan el monitoreo en tiempo real de diversos parámetros de salud [1].

Por otra parte, los trastornos de sueño o la deficiente calidad de este, son un problema de salud que afecta el rendimiento cotidiano del ser humano. En la población universitaria, la calidad del sueño y la falta de un horario de descanso adecuado, impacta de manera directa en la atención, concentración y por ende en su rendimiento académico [2]–[4].

En diversos estudios se menciona que la falta de sueño en los estudiantes universitarios provoca un rendimiento académico inferior [5], con especial énfasis en épocas de exámenes, en adición a esto, estudios médicos indican que el número de horas promedio de sueño que se recomienda dormir depende de la edad de la persona, como se presenta en la **Tabla 1.1**, la cual indica el número de horas promedio de sueño que una persona debería dormir en base a su edad, dado en [5], se enfoca en el rendimiento de alumnos universitarios, los cuales se encuentran en el rango de edades de adultos jóvenes entre 18 a 25 años.

En el contexto de análisis del sueño. Se recalca la carencia de mediciones que permitan determinar si el sujeto en cuestión cumple con las horas necesarias para completar un sueño reparador, de esta forma se enfatiza en la necesidad de contar con un método de medición eficiente, tomando en cuenta que la construcción de una aplicación. Deberá contemplar la existencia de factores externos tales como ruidos ambientales o del vecindario. Para tener resultados precisos como se indica en [6].

Debido al impacto que puede llegar a producir la calidad de sueño. En el rendimiento académico del estudiante, no solo es necesario disponer de una aplicación que recopile datos, sino que también en base a los datos obtenidos se realice un análisis de los resultados y se pueda ofrecer una retroalimentación al usuario para que mejore sus hábitos de descanso [5].

1.1 Objetivo general

Analizar alternativas que permitan el mejoramiento del rendimiento académico de estudiantes universitarios, a través del monitoreo del sueño, utilizando aplicaciones IoT.

1.2 Objetivos específicos

Los objetivos específicos definidos para el presente trabajo son:

1. Identificar los factores que influyen en el rendimiento académico de los estudiantes.
2. Describir los índices que determinan la calidad de sueño del estudiante.
3. Definir las aplicaciones IoT que posibiliten la medición de parámetros relevantes durante el sueño.
4. Presentar las alternativas para la futura implementación de una aplicación en dispositivos móviles para el monitoreo del sueño.

1.3 Alcance

El presente trabajo de integración se enfoca en el estudio de las alternativas que permitan inferir la calidad de sueño de un estudiante universitario y la influencia en su rendimiento académico, por medio de aplicaciones IoT móviles. Para esto se consideran diversos estudios relacionados con literatura de los últimos 5 años. Adicionalmente, se implementa un tablero basado en la metodología *kanban*, que permita el cumplimiento de los objetivos semanales planteados en el plan de tareas específicas.

Como primer paso, este trabajo se enfoca en la revisión de estudios especializados. Realizados acerca de los factores que afecten al rendimiento académico de los estudiantes y sus métodos de medición, con lo cual se podrá discriminar cuáles son los principales parámetros que deben ser considerados.

Posteriormente, el estudio se enfoca en el factor de calidad de sueño y su relación con el rendimiento académico para determinar las mejores formas de plantear la medición de estos parámetros mediante la utilización de aplicaciones IoT.

Finalmente, se plantean alternativas que permitan recopilar información, para un posterior procesamiento de datos, con el objetivo de mostrar las variables que influyen en la mejora del rendimiento académico de los estudiantes universitarios.

El resultado de este estudio permitirá contar con un sustento teórico para la implementación a futuro de una aplicación móvil que considere el análisis realizado durante este estudio.

1.4 Marco teórico

En esta sección se presenta el sustento teórico que permite desarrollar el estudio de los diferentes métodos de análisis del sueño, exploración del rendimiento académico, la relación entre ambos parámetros y plantear las bases para una futura implementación en una aplicación móvil.

1.4.1. Calidad de sueño

El sueño es un estado de descanso, en donde se produce la disminución de la conciencia y consecuentemente influye en el modo de responder ante los estímulos que rodean al ser humano. Indudablemente, esta acción es el resultado fisiológico de sucesos precoces en la vida, como lo son el apego y la edad. Se puede decir que, dormir es una actividad fisiológica fundamental que permite obtener un balance psíquico y físico en el individuo [7].

En esta línea, en [5] se menciona que el sueño presenta diversas etapas, las cuales responden a necesidades de crecimiento de los individuos al pasar de una etapa de niñez hacia la edad adulta[5]. Es decir que, el sueño se encuentra inmerso en aspectos que cambian conforme a la etapa de vida y elementos propios de la misma.

El primero de ellos hace referencia a un tipo madurativo, a diferencia del segundo que guarda relación con el desarrollo. Cabe recalcar que, los factores biológicos influyen y reflejan cambios en aspectos como la duración, fases del sueño y del mismo modo, en el ritmo circadiano sueño-vigilia. Mientras que, los psicosociales se relacionan con el proceso de individuación en donde se expresa la necesidad de elegir los propios horarios y actividades. Por ello, en este período son comunes problemas asociados con la regularidad, cantidad y calidad del sueño, que, consecuentemente ocasiona la privación parcial crónica de sueño y en el peor de los casos excesiva somnolencia diurna [5].

La etapa universitaria se orienta a seguir un esquema de alta exigencia académica, que sin lugar a duda es lo suficientemente diferente, en relación, con la exigencia experimentada en la etapa escolar, de tal modo que, genera cambios en el estilo de vida. Así pues, el sueño es considerado uno de los principales estados que se alteran con mayor frecuencia y que, evidentemente se hace más visible en días previos a eventos de evaluación, puesto que el sueño promueve el desarrollo de procesos cognitivos que apoyan a la memoria, aprendizaje, procesamiento de información, creatividad y motivación [4]. De tal manera, la ausencia o privación de sueño, genera estados negativos que repercuten en el deterioro cognitivo.

Cabe recalcar que, la mayor parte de los estudiantes universitarios presentan desórdenes en sus hábitos del sueño, esto se evidencian en estados de ánimos alterados, aprendizajes comprometidos con riesgo de fracaso académico y, por ende, disminución del rendimiento académico [8].

De tal manera que, diversos estudios en el ámbito médico se enfocan en determinar cuáles serían las horas promedio recomendadas o necesarias para que un individuo pueda

completar el proceso fundamental y reparador del sueño, con los beneficios ya mencionados. Según la *National Sleep Foundation*, se presenta la **Tabla 1.1**, con la información de las horas promedio de sueño recomendadas según la edad de la persona. En el presente trabajo se enfocará en estudiantes universitarios que se ubican en la categoría de adultos jóvenes.

Tabla 1.1 Horas de sueño promedio recomendadas según *National Sleep Foundation* [9]

Edad	Horas de sueño
Recién nacidos (0 a 3 meses)	14-17 horas
Lactantes (4-11 meses)	12-15 horas
Niños pequeños (1-2 años)	11-14 horas
Preescolares (3-5 años)	10-13 horas
Escolares (6-13 años)	9-11 horas
Adolescentes (14-17 años)	8-10 horas
Adultos jóvenes (18-25 años y adultos de edad media (26-64 años)	7-9 horas
Ancianos (≥ 65 años)	7-8 horas

1.4.2 Rendimiento académico

El rendimiento académico envuelve un concepto que busca cuantificar los resultados obtenidos por un estudiante durante su vida académica; además, permite realizar mediciones de la calidad del sistema educativo, que involucra tanto a profesores como estudiantes, para lo cual se definen indicadores que permiten evaluar a una Institución Educativa[1]. Por otro lado, este concepto puede verse afectado por el entorno en el que se desenvuelve el estudiante, su inteligencia emocional e incluso el manejo del estrés.

Cuantificar el esfuerzo e interés de un estudiante en una materia en específico se torna en un reto, al momento de recopilar los datos y restar subjetividad a estos. Por lo que este estudio se centra en tomar el análisis del rendimiento académico representado únicamente por el promedio de calificaciones obtenidas.

1.4.3 El sueño y el rendimiento académico

El sueño es un factor indispensable, que permite el descanso del cuerpo humano y las actividades asociadas con la consolidación de la memoria y el aprendizaje. Sin duda alguna, durante la formación universitaria, dicho estado puede verse alterado debido a exigencias académicas, que ocasionan episodios de estrés lo que puede generar una serie de cambios en los hábitos de sueño, de tal modo que, puede llegar a influir el proceso académico en la universidad, acarreando según [5] un descenso de hasta el 40% de la capacidad de un estudiante para asimilar conocimientos.

1.4.4 Indicadores que miden el rendimiento académico

Dentro del ámbito educativo, existen indicadores que permiten medir de forma detallada, la evolución tanto del proceso de aprendizaje de un estudiante, como de los métodos de enseñanza que adoptan las diferentes instituciones educativas; es decir, evalúan de manera cuantitativa, tanto la eficacia como la eficiencia de los procesos académicos. Adicionalmente, en [10] se menciona que el estudio del rendimiento académico se puede resumir como la representación que ofrece una calificación en la relación a lo que el estudiante aprende y lo que es capaz de lograr desde el punto de vista del proceso de aprendizaje. Para esto se obtiene una sumatoria y el promedio de las calificaciones obtenidas en el desarrollo de distintas actividades académicas dentro de un período académico.

Así pues, existen diversos indicadores, que en conjunto registran la información correspondiente al rendimiento académico de los estudiantes; es decir, aquellas calificaciones obtenidas en las asignaturas cursadas durante cada período o semestre académico, reingresos y/o cambios de carrera.

- Promedio semestral de calificaciones (SGPA)

Representa la nota media que adquiere un estudiante en las evaluaciones del periodo semestral en el cual se encuentra matriculado.

$$SGPA = \frac{\sum_1^n C_i \times (GP)_i}{\sum_1^n C_i}$$

Ecuación 1.1 Ecuación de cálculo para SGPA

Siendo:

n = Número total de materias aprobadas.

i: Asignatura.

C_i = Crédito asignado para un curso.

GP_i = Calificación de cada asignatura.

- Promedio de calificaciones acumuladas (CGPA)

El CGPA (*Cumulative Grade Point Average*) es un indicador que se emplea para calcular el rendimiento general de un estudiante; es decir, indica el promedio general de todas las calificaciones adquiridas durante un año académico o dos semestres, evidenciados en el expediente estudiantil. Además, se calcula en una escala sobre los 10 puntos [11].

$$CGPA = \frac{\sum_{i=1}^n g_i}{n}$$

Ecuación 1.2 Ecuación de cálculo para CGPA

Donde:

g_i : Suma de Calificaciones obtenidas en una asignatura i.

n: número de asignaturas.

i: Asignatura.

- **Promedio de calificaciones (GPA)**

Corresponde al indicador del puntaje promedio evidenciado durante el transcurso de un solo semestre, a través de la aplicación de la **Ecuación 1.3**[11].

$$GPA = \frac{\sum_{i=1}^n w_i g_i}{\sum_{i=1}^n g_i}$$

Ecuación 1.3 Ecuación de cálculo para GPA

Donde:

$w_i g_i$: Producto de número de créditos hora por calificación en una asignatura i.

g_i : Créditos hora en la asignatura i.

n: número de asignaturas.

i: Asignatura.

- **Índice de rendimiento académico (IRA)**

También conocido como Índice de Proceso o Grado. Es uno de los indicadores que se calcula ponderando todas las notas tanto aprobadas como reprobadas, sin incluir aquellas retiradas, el cálculo se realiza según la **Ecuación 1.4**.

$$IRA = \frac{\sum \text{Crédito} \times \text{Nota}}{\sum \text{Crédito}}$$

Ecuación 1.4 Ecuación de cálculo para IRA

- **Rendimiento integral de aprobación (RIA)**

Relación entre el índice de eficiencia y la cantidad de asignaturas que debería el alumno haber aprobado en función de los años de permanencia en la carrera, que se puede calcular en base a la **Ecuación 1.5**.

$$RIA_a = \frac{\sum_{j=1}^n \frac{1}{NER_j} \cdot CA}{MTPE_a}$$

Ecuación 1.5. Ecuación de cálculo para RIA [12]

Donde

n = número total de materias aprobadas.

j: asignatura

NER_j : cantidad de veces que el alumno rindió la asignatura para aprobarla

a = años de permanencia en la carrera.

MTPE = materias que teóricamente debería el alumno haber Aprobado en relación al Plan de Estudio en sus años de permanencia.

CA: coeficiente de ajuste por retraso, adquirido a partir de la relación proporcional entre la duración teórica de la carrera y la permanencia real.

- **Índice de logro cognitivo (ILC)**

Corresponde a la cantidad promedio de conocimientos, habilidades y destrezas adquiridas por el estudiante en cada materia aprobada durante el transcurso de la carrera universitaria. Cabe recalcar que esta cifra de proporcionalidad es para cada asignatura, siendo representada por la nota correspondiente a su calificación final de aprobación.

$$ILC = \frac{\sum_{j=1}^n \frac{CFA}{n}}{n}$$

Ecuación 1.6. Ecuación de cálculo para ILC [12]

Siendo:

ILC = Índice de logro cognitivo.

CFA = Calificación Final de cada materia Aprobada.

n = número total de materias aprobadas.

- **Índice de rendimiento académico general**

Se obtiene como resultado de la suma ponderada de los índices parciales de Regularización, Aprobación y Logro Cognitivo. Su valor varía entre 0 y 1, siendo "1" el de mayor rendimiento

$$RAG = 0.2 RIR + 0.5 RIA + 0,3 ILC$$

Ecuación 1.7. Ecuación de cálculo para RAG [12]

Donde:

RAG= Rendimiento Académico General

RIR= Rendimiento Integral de Regularización

RIA= Rendimiento Integral de Aprobación

ILC= Índice de Logro Cognitivo

1.4.5 Factores que afectan el rendimiento académico

Existen diversos factores que afectan al rendimiento académico de un estudiante, los cuales se pueden derivar de varias situaciones por las que atraviesa o se ve envuelto este, durante el proceso de su vida estudiantil. En la **Tabla 1.2.** se listan algunos de estos factores, los cuales se clasificarán según su naturaleza y la capacidad de medición de los mismos.

Tabla 1.2. Factores que afectan al rendimiento académico

Factor	Concepto
Nivel socioeconómico	La situación socioeconómica afecta en gran porcentaje a los estudiantes universitarios, puesto que, se prioriza el trabajo remunerado con el fin de cubrir las necesidades personales o familiares, dejando de lado las actividades académicas. Este factor trae consigo problemáticas asociadas con la reprobación o bajo rendimiento académico.[13]
Contexto familiar	Las relaciones familiares juegan un importante rol en la formación académica. Un ambiente familiar lleno de discusiones, recriminaciones problemas conlleva a contar con limitado espacio, tiempo y, sobre todo, deficiente calidad para desarrollar actividades académicas. [14].
Motivación	Permite dominar conocimientos y alcanzar académicamente aspectos imprescindibles como lo son la confianza, perseverancia y autonomía que, sin duda alguna, permiten alcanzar un aprendizaje óptimo y, por ende, adquirir un rendimiento académico idóneo en la preparación profesional[15].
Zona de residencia	Ser oriundo de una ciudad diferente a la cual se realiza el proceso de formación académica, genera un proceso más largo de adaptación, lo cual tiende a alterar el desempeño estudiantil[16].
Dominio del tema por parte del instructor	El instructor tendrá un papel de suma importancia en el desenvolvimiento académico en estrecha relación con la metodología y conocimientos con los que se cuente [17].
Sistema de exámenes	Los exámenes en muchas situaciones generan estados de ansiedad, que, repercuten en la concentración y por ende en la

Factor	Concepto
	calificación imprescindible para la aprobación de la asignatura. [18].
Relación estudiante – instructor	Es importante destacar que la relación que tenga el instructor con el alumno, la confianza y los conocimientos que este imparta, desde el primer contacto académico pueden garantizar que el desempeño sea idóneo. [19].
Infraestructura de la institución	Es fundamental que las universidades garanticen condiciones correctas para un óptimo rendimiento académico que conduzca lógicamente a una educación de calidad[20].
Métodos de aprendizaje	Resulta importante utilizar técnicas de aprendizaje que sean didácticas y participativas, con el fin de garantizar calidad educativa[21].
Problemas de salud	El presentar problemas de salud durante la vida estudiantil, impacta de manera directa en el rendimiento obtenido. [22].
Lecturas	La capacidad lectora de un estudiante universitario promueve el éxito en el aprendizaje a lo largo de la carrera universitaria. Sin duda alguna, la lectura es capaz de Mejorar la Comprensión de los estudiantes en diversas asignaturas. [23].
Administración del tiempo	La administración de la cantidad de horas que destina el universitario para el desarrollo de actividades u obligaciones, a más de contar con un horario definido direccionará el éxito en el cumplimiento del total de sus actividades. [24], [25].
Calidad de sueño	El sueño es sin duda uno de los factores más importantes en el ser humano, puesto que, la ausencia de este proceso produce estados de ánimos alterados, aprendizajes comprometidos, con riesgo de fracaso académico y, por ende, disminución de su rendimiento académico[8].

1.4.6 Mecanismos para medición del sueño

En base a los diversos estudios analizados se puede clasificar a las metodologías de medición de sueño en: intrusivas o no intrusivas. Donde las metodologías de medición intrusivas incluyen sensores colocados en el cuerpo, estos sensores son de tipo médico y en su gran mayoría permiten obtener señales del electrocardiograma. Mientras que, las metodologías no intrusivas se relacionan con el uso de sensores de tipo ambiental o localizados de manera externa.

Una de las tecnologías que pueden ser utilizadas para el análisis de sueño son aquellas basadas en las redes de área corporal inalámbricas (WBAN), estandarizadas en IEEE 802.15.6. En este estándar, se define tanto el uso sensores “*on body*” como “*off body*”, para la medición de diferentes parámetros. De manera que, por ejemplo, se puede obtener

información relacionada con la calidad, así como con la cantidad de sueño de la persona [26].

1.4.7 Sensores que permiten medir el sueño

Considerando que el presente trabajo se enfoca en proponer una solución que satisfaga la recolección de datos mediante un dispositivo móvil, es importante observar algunos de los sensores que pueden ayudar con este propósito y se encuentran en la mayoría de este tipo de dispositivos. Es importante recalcar que, en base a los datos obtenidos y utilizando métodos de aprendizaje automático se puede llegar a inferir comportamientos relacionados con el sueño[27].

Entre los sensores más utilizados en la recolección de datos para detección de sueño se tiene:

- Sensor de luminosidad: permite obtener el grado de iluminancia en el lugar donde se realiza la medición.
- Sensor manométrico: sirve para realizar la medición de la relación entre la presión y la presión atmosférica.
- Termistor: este sensor detecta la variación en la temperatura aplicada a una resistencia.
- Cámara: permite capturar imágenes con un obturador incorporado.
- Acelerómetro: permite medir el vector aceleración con el que se mueve un dispositivo y se compone de tres ejes.
- Giroscopio: permite medir la aceleración no gravitacional, lo cual ayuda al dispositivo a orientarse mediante la rotación de este.
- Micrófono: permite receptar las señales acústicas para transducirlas en señales eléctricas.

1.4.8 Aprendizaje de máquina

En una época, donde cada vez más las empresas intentan obtener información valiosa o relevante, para así conseguir una ventaja competitiva en su entorno, el aprendizaje de máquina resulta una solución muy atractiva. El aprendizaje de máquina o aprendizaje automático se puede definir como la capacidad con la que se dota a una computadora para poder identificar patrones, utilizando inteligencia artificial, la cual se basa en el

reconocimiento de patrones y resolución de problemas de manera similar a las conexiones cerebrales del pensamiento humano[28].

Cabe recalcar que, previo a aplicar un algoritmo de aprendizaje de máquina, se utilizan procesos de depuración de datos como es el caso de técnicas de “*Data Mining*”. Estas técnicas son ampliamente utilizadas en diversos ámbitos y se enfoca en la deducción o extracción de datos relevantes para un objetivo establecido. La minería de datos es un proceso que incluye diversos pasos, entre ellos se tiene: definición del problema, definición de los datos a extraer, preprocesamiento de datos como tal, incluyendo la limpieza, reducción y transformación de datos, y finalmente, la selección del modelo e interpretación de resultados[29], [30].

Adicionalmente a esto, la calidad de la predicción para obtener resultados relevantes dependerá de factores de *data Mining* tales como: el conocimiento previo en los datos tratados, la elección correcta del modelo a utilizar y el tratamiento de los datos realizado de manera previa[30]–[32].

1.4.8.1 Técnicas de aprendizaje de máquina

Los algoritmos utilizados en las técnicas de aprendizaje de máquina se pueden dividir en dos grandes grupos, algoritmos supervisados y no supervisados.

- **Algoritmos supervisados:** Se utilizan en la categorización o clasificación en donde el conjunto de datos se encuentra etiquetado, entre ellos se encuentran los árboles de decisión, algoritmo de *Naive Bayes* y *Support Vector Machine*[33].
- **Algoritmos no supervisados:** En este caso no es necesaria la ocupación humana durante la elaboración del conjunto de datos, es decir, se enfoca en encontrar patrones, entre ellos se tiene las técnicas de *clustering* [34].

Por otro lado, en la **Figura 1.1** se presenta la clasificación de técnicas de aprendizaje de máquina desde una visión más general con las técnicas que forman parte de cada categoría.

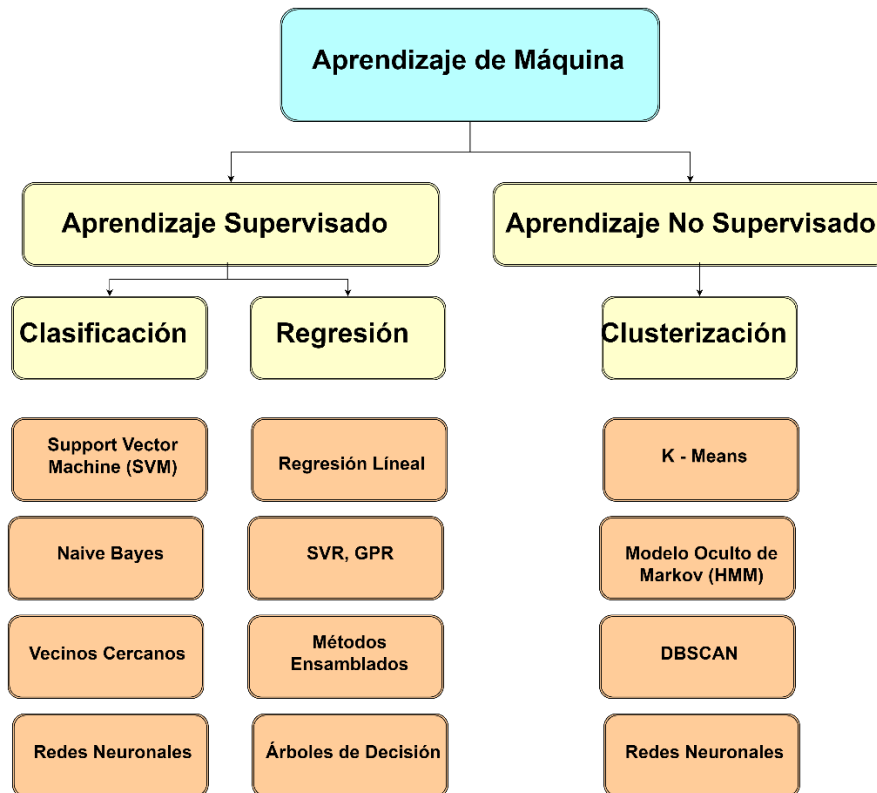


Figura 1.1 Clasificación de técnicas de aprendizaje basado en [36]

Como se pudo observar en **Figura 1.1**, se realiza una primera clasificación en base a si el aprendizaje es supervisado o no supervisado, de la misma manera, se puede visualizar que si se parte del aprendizaje supervisado se tienen dos categorías: las técnicas de clasificación y las técnicas de regresión, las cuales cuentan con un lista de las técnicas que forman parte de cada categoría, por otro lado, en las técnicas de aprendizaje no supervisado, se plantea una única categoría, la cual corresponde a la clusterización, la cual indica los algoritmos que forman parte, cabe recalcar que las redes neuronales se encuentran presentes en la clasificación y la clusterización, dada la flexibilidad y variedad de estas técnicas.

Luego de revisar varios trabajos relacionados con el análisis del comportamiento del sueño, se pudo observar que las soluciones planteadas en la mayor parte de casos coinciden con la utilización de algoritmos de clasificación (algoritmos supervisados), esto se debe a que estas técnicas de aprendizaje de máquina facilitan el proceso de minería, dado que los datos en estos estudios por lo general se encuentran etiquetados.

1.4.8.2 Técnicas de aprendizaje de máquina utilizadas para inferir nivel de sueño

La mayoría de las aplicaciones del aprendizaje de máquina en el análisis del sueño por lo general guardan una relación con el estudio de la apnea obstructiva del sueño; sin embargo, estos estudios sirven de base para determinar qué técnicas de aprendizaje es la más apropiada.

En base al trabajo presentado en [37] y [38], respecto al análisis del sueño mediante señales ECG de canal simple y la detección de señales de parpadeo rápido en fase REM con detección utilizando *machine learning* que propone una solución para la detección de apnea obstructiva con una comparación de diversos estudios en el ámbito del estudio del sueño se plantea el uso de algoritmos de tipo supervisado, los cuales corresponden a los árboles de decisión, redes neuronales, técnica de vecino cercano (KNN), técnica de *Support Vector Machine (SVM)* y redes bayesianas (*Naive Bayes*)

Adicionalmente, en base a [37] y [38] se construyó la **Tabla 2.1** que se presenta en el capítulo 2, en la cual se mencionan alguna de las redes neuronales utilizadas en el estudio del sueño, algunas de ellas son las redes neuronales artificiales (ANN), redes neuronales con memoria a corto plazo (LSTM), la cual cuenta con una variante llamada red recurrente (RNN) o la red de creencia profunda (DBN)[39].

2. METODOLOGÍA

Para la realización de este trabajo de integración curricular, se utiliza como base la metodología *kanban*, la cual cubrirá la asignación de tareas durante 12 semanas, con un tablero en el cual se colocarán las actividades en tres categorías (pendientes, en curso y completadas). Para construir el tablero *kanban* se hizo uso de etiquetas y de la herramienta *Planner* de Office 365. Con el fin de poder identificar de mejor manera las actividades dentro del tablero y su categoría, se clasificó las actividades, en cuatro categorías que son: "Planificación", "Búsqueda de Información", "Análisis" y "Etapa Final", las capturas de la ejecución de esta metodología a lo largo del desarrollo de este trabajo se muestran en los anexos I.

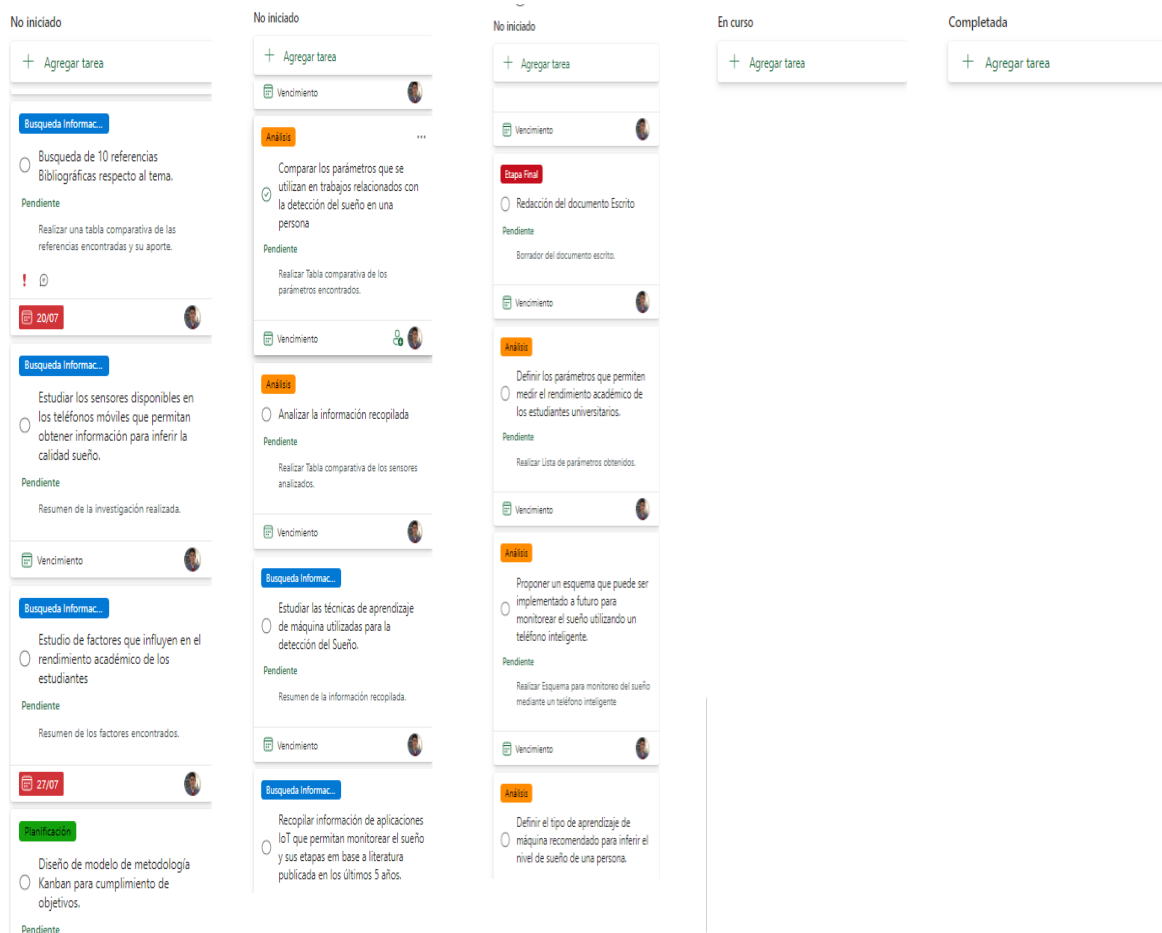


Figura 2.1. Tablero *kanban* en la semana 1 del trabajo de integración.

El proceso de recolección de información se realiza sobre la base de trabajos de investigación y artículos relacionados publicados en los últimos 5 años, utilizando como principales fuentes bibliográficas motores de búsqueda reconocidas como lo son *IEEE Xplore*, *ACM*, *Google Scholar*. Además se revisó proyectos relacionados al tema realizados

por distintas universidades a nivel global, mediante un enfoque de tipo cualitativo con una metodología de análisis documental.

Como primera parte de este trabajo se procedió a la construcción del tablero *kanban* explicado anteriormente, luego se focalizó el cumplimiento del primer objetivo, el cual consistía en la recopilación de información relacionada a los factores que influyen en el rendimiento académico de estudiantes, para su procesamiento y posterior análisis. En esta parte, se utilizó como palabra clave en la búsqueda: “*Student Performance*” en los distintos motores de búsqueda antes mencionados.

Una parte fundamental del estudio del sueño en los estudiantes es obtener información de diferentes parámetros que sean útiles en la detección de las horas de sueño y su calidad, tomando en cuenta que los dispositivos móviles cuentan con diversos sensores para su funcionamiento en común, los cuales se mencionan en la sección 1.4.7, teniendo en cuenta la gran cantidad de tiempo con que los estudiantes tienen contacto con estos dispositivos, por lo cual se optó por la utilización de dispositivos móviles. La información para el análisis del sueño se puede recopilar tanto, por medio de los sensores del terminal móvil como de encuestas. Para esto se procedió a analizar las encuestas más utilizadas en el ámbito médico para determinar la calidad de sueño o la presencia de un posible trastorno de sueño.

Con base a los sensores del dispositivo móvil es posible determinar las propuestas que se puede tomar para determinar si una persona se encuentra dormida o despierta. En adición a esto, el último objetivo se enfoca en la presentación de diversas alternativas para una futura implementación de una aplicación que sea capaz de realizar el monitoreo del sueño y con los datos recolectados, se analice su relación con el rendimiento académico, para esto se presentaron diversos *mockup* y flujos de aplicación en base a los estudios analizados.

2.1 Análisis metodológico

Al revisar los trabajos realizados en el campo del análisis del sueño, se puede concluir que existe una gran cantidad de métodos utilizados; sin embargo, guardan relación entre ellos. Con la información recopilada, se presentan métodos de medición basados en dispositivo de medición (médico o ambiental) y se muestran los parámetros y las metodologías utilizadas para inferir el comportamiento durante el sueño. Finalmente, se presentan las características de distintas técnicas de aprendizaje de máquina utilizadas en el análisis del sueño, así como el posible procedimiento para extracción y procesamiento de datos, y los componentes necesarios para la construcción de la aplicación en cuestión

La elección de la técnica de aprendizaje de máquina utilizada para el análisis del sueño dependerá en gran medida del tipo de dato que se recopila y del dispositivo utilizado para la medición, recordando que se puede utilizar sensores ambientales o sensores invasivos como lo son los sensores médicos que recopilan señales del ECG.

2.1.1 Métodos de medición según el dispositivo de medición

Tomando como referencia el *survey* realizado en [38] en el cual se mencionan las técnicas de aprendizaje de máquina utilizadas en el análisis del sueño, fue posible obtener algunos métodos de medición, lo cual se presenta en la **Tabla 2.1**, la cual recopila los resultados de diversos estudios en base al análisis de sueño utilizando sensores médicos y la **Tabla 2.2** enfocada a análisis de sueño utilizando sensores ambientales.

- Utilizando sensores médicos

Los sensores médicos se caracterizan por tener medidas más precisas que los sensores ambientales, sin embargo, llegan a ser más invasivos en sus estudios, ya que se incluyen sensores en la piel y con distintas ubicaciones en el cuerpo con el fin de obtener las medidas adecuadas para el análisis del comportamiento del sueño de una persona. En la **Tabla 2.1** se presenta un compendio de los diferentes trabajos analizados, donde se considera el año de publicación del trabajo, el tipo de señal analizada, el algoritmo de aprendizaje de máquina utilizado, las características principales del estudio y la precisión o *Accuracy* obtenida.

Tabla 2.1. Resumen de trabajos relacionados con el análisis del sueño utilizando sensores médicos basados en [38]

#	Referencia	Señal analizada	Algoritmo utilizado	Características del estudio	Precisión
1	2019 [40]	ECG	DNN, 1D CNN, 2D CNN, RNN, LSTM, <i>Gated recurrent unit</i>	Se realizó la reducción de dimensionalidad. Se aplicó el estudio en 65 hombres y 21 mujeres.	99%
2	2018 [41]	ECG	DNN, HMM, SVM, ANN	Utiliza codificadores de tipo automáticos, con aprendizaje no supervisado.	85%
3	2019 [42]	ECG	<i>Time window ANN</i>	Se extrae señales ECG en tiempo, así como parámetros pico, además de intervalos R-R.	87.3%

#	Referencia	Señal analizada	Algoritmo utilizado	Características del estudio	Precisión
4	2016 [43]	ECG	<i>Multiple logistic discrimination</i>	Intervalo R-R (tiempo entre ondas R de tipo consecutivo).	89.8%
5	2008 [44]	ECG	LSTM, ANN and <i>Elman Network</i>	Se incluye parámetros del tiempo, parámetros de frecuencia alta y baja.	82.1%
6	2010 [45]	ECG	kNN, QDA, SVM	Contiene mediana y datos de Inter cuartil y análisis cuadrático discriminante (QDA). El estudio se realizó en 5 hombres y 12 mujeres.	90%
7	2015 [46]	ECG	Naive Bayes, kNN, ANN, <i>AdaBoost, Bagging, Random Forest, ELM, DA, Restricted Boltzmann Machine</i>	Contiene media, varianza, curtosis, además de varias medidas de referencia, así como señales ECG.	83.77%
8	2013 [47]	SPO_2	SVM	Se trabaja con señales de 150 segundos, tomando como parámetro principal la desaturación. El estudio se realizó en 40 personas.	93.5%
9	2017 [48]	ECG	SVM	Se incluyen características en tiempo, medidas de referencia, medidas de frecuencia cardiaca y ECG. El estudio se realizó en 32 personas.	100%
10	2017 [49]	ECG	DA, kNN, ANN, ELM, SVM, <i>AdaBoost, Bagging, LogitBoost</i>	Incluye parámetros de medición (varianza, curtosis), y la técnica de aprendizaje de máquina extrema (ELM).	84.4%
11	2017 [50]	ECG, SPO_2	Naïve Bayes, kNN, SVM	Utiliza parámetros de señales ECG y SPO_2 , en el dominio del tiempo.	96.64%
12	2012 [51]	ECG, SPO_2	Adaboost, Decision Trees	Se incluyen parámetros de señales SPO_2 .	82%

#	Referencia	Señal analizada	Algoritmo utilizado	Características del estudio	Precisión
13	2010 [51]	SPO_2	<i>Decision Tree</i>	Incluye índices ODI asociado a señales SPO_2 .	93%
14	2017 [52]	ECG, SPO_2	LSTM-RNN	Se estudian características obtenidas por red neuronal LSTM y señales ECG en la detección del sueño, en este caso los algoritmos no supervisados tuvieron mejor rendimiento.	92.1%
15	2017 [53]	SPO_2	DBN	Se estudian características extraídas por red DBN.	97.64%
16	2009 [54]	ECG	SVM	Incluye señales de ritmo cardíaco HRV y EDR.	100%
17	2017 [55]	SPO_2	<i>Linear Discriminant Analysis</i>	Se incluyen parámetros de señales SPO_2 y de pulso cardíaco y PPG (Ondas de flujo sanguíneo) de ondas de respiración. Se utiliza 52 sujetos de prueba.	87%
18	2020 [56]	ECG	<i>Decision trees, DA, logistic regression, SVM, kNN, ensemble learning</i>	Se estudia señales en dominio de tiempo y frecuencia, con 9 características usadas en el clasificador, así como el análisis discriminatorio conocido como DA.	98.7%
19	2020 [57]	SPO_2 , Heartrate	<i>Gaussian Naïve-Bayes, ANN, kNN</i>	Se obtuvo información de diversos conjuntos de datos utilizando validación cruzada.	95%
20	2020 [58]	ECG	<i>Logistic Regression, SVM and 1D CNN</i>	Se analiza señales en dominio del tiempo e intervalo de tipo R-R.	88.23%
21	2020 [59]	Señales Respiratorias	<i>CNN, Markov Chain</i>	Se utiliza características aprendidas por la red neuronal de tipo CNN.	80.78%
22	2019 [60]	SPO_2	SVM	Se extrajeron señales en dominio de tiempo, señales SPO_2 .	77.7%

#	Referencia	Señal analizada	Algoritmo utilizado	Características del estudio	Precisión
				Se utilizaron 975 sujetos de prueba para el estudio.	
23	2015 [61]	EOG	DBN	Se extrajeron características usando red neuronal DBN.	83.3%
24	2017 [62]	ECG	LSTM-RNN	Se extraen señales en el dominio del tiempo y señales ECG.	99.99%

- Utilizando sensores ambientales

Utilizar sensores ambientales resultan menos invasivos en comparación con los médicos; además, si se toman en cuenta los parámetros de ruido y ambiente donde se desarrollan las mediciones, se pueden tener resultados similares a los sensores médicos. Además, los sensores ambientales pueden ser reemplazados para efectos de realizaciones de estudios por los sensores presentes en dispositivos móviles. Los estudios obtenidos en la **Tabla 2.2** servirán para poder discernir cuál es la técnica de aprendizaje de máquina más apropiada o recomendable.

Tabla 2.2. Resumen de ensayos realizados en análisis del sueño utilizando sensores ambientales basados en [38]

#	Referencia	Señal analizada	Algoritmo utilizado	Características del estudio	Precisión
1	2020 [63]	Movimientos traqueales	CNN y LSTM	Utilización de señales traqueales seleccionadas en base a un rango de frecuencias.	84%
2	2018 [64]	Imágenes faciales	CNN	Utiliza aprendizaje basado en imágenes faciales. Se utilizó 39 hombres y 30 mujeres para el estudio.	69%
3	2019 [65]	Señales UWB	Árboles de decisión, SVM, kNN	Identificación de apnea de sueño utilizando detección fisiológica con banda ultra ancha (UWB). Se utilizó 5 sujetos de prueba con ambientes similares a la condición de apnea obstructiva.	98%

#	Referencia	Señal analizada	Algoritmo utilizado	Características del estudio	Precisión
4	2017 [66]	Señales de movimiento (acelerómetro)	kNN	Utiliza el teléfono en una correa para dormir y detectar movimiento. Se utilizó 4 sujetos de prueba.	97.7%
5	2018 [67]	Señales acústicas desde el micrófono	Regresión logística, SVM y DNN	Utilización de características de señales de audio clasificadas según su frecuencia. Se utilizaron 120 sujetos de prueba incluyendo 3 niños.	92.5%
6	2018 [68]	Señales de flujo de aire recopilado por un termistor	SVM, Regresión logística, DNN	Se colocó un termistor frente a la nariz del sujeto clasificando las señales en 17 características distintas.	92.69%
7	2016 [69]	Señales de flujo respiratorio nasal	SVM, kNN y Regresión lineal	Se utiliza parámetros de medición (varianza, mediana, media), se enfatiza en la duración del flujo nasal.	87.6%
8	2015 [70]	Movimiento abdominal, y señales respiratorias nasales.	<i>Random forest</i> y <i>Random subspace</i>	Señales de respiración con intervalos de 1 minuto.	98.68%
9	2015 [71]	Pulsos reflejados en banda <i>Ultra Wide</i>	Discriminación lineal	Utilización de señales en la banda <i>Ultra Wide</i> , con 15 características extraídas. Se incluyó en el estudio a 3 hombres y 1 mujer.	73%
10	2020 [72]	Señales de presión	Redes convolucionales TCN y LSTM	Se utilizan señales respiratorias. Se incluyeron 9 sujetos de prueba.	95.1%
11	2020 [73]	Señal respiratoria (sensor de presión y acelerómetro)	CNN	Sistema de monitorización continuo de respiración basado en acelerómetro. Se incluyeron en el estudio 4 mujeres y 4 hombres.	88%
12	2019 [74]	Señales de voz	<i>Random forest</i>	Señales obtenidas mediante la voz, selección de características para determinar si existe apnea obstructiva del sueño. Se incluyó 20 sujetos de prueba.	87.5%

Se puede observar en la **Tabla 2.1** que existen diversos enfoques para el análisis de sueño mediante sensores médicos, en su mayoría con el análisis de los picos R-R y las señales SPO_2 . Por otro lado, en la **Tabla 2.2** se indica la existencia de diversos estudios utilizando sensores ambientales; sin embargo, será necesario verificar cuales de ellos obtienen mayor rendimiento y el enfoque que facilitará su implementación, como se analiza en el capítulo 3.

2.1.2 Metodologías utilizadas en análisis de sueño

Existen múltiples enfoques presentados en distintos trabajos donde se realiza el análisis de sueño, las cuales se analizará a continuación:

Por un lado, se puede notar la colocación de sensores de luminosidad y proximidad en la cama de la persona, sea tanto en la almohada como en el colchón, tal como, se propone en [75]. A través del sensor de proximidad se obtienen los datos respecto a la posición de la persona en el colchón, con los cuales se busca mejorar el ambiente donde se realiza el proceso del sueño. Adicionalmente se podría modificar parámetros en el ambiente de reposo, tales como temperatura, luz o aroma de la habitación que conllevarían a tener una mejor calidad de sueño.

En [76], se plantea otra alternativa basada en la utilización de brazaletes durante el sueño, con el fin de obtener valores de posición longitudinal de la persona y los movimientos de vuelco, en conjunto con la utilización de brazaletes con un sensor magnetómetro.

Otro enfoque plantea la recopilación de datos de señales de Electrocardiograma y señales de movimiento del diafragma en la respiración de la persona para la detección de Apnea obstructiva del sueño (OSA, por sus siglas en inglés), como desarrolla [27]. Adicionalmente, con el mismo objetivo de detección de OSA, en [77] también se propone colocar el brazalete mencionado en conjunto con un oxímetro con un led y un Fotodiodo, utilizando una señal(SPO_2) como se propone en [76].

Finalmente, se pudo observar en los estudios recopilados que, en el análisis de sueño se proponen diversas soluciones mediante la recopilación de señales de voz durante el sueño, como plantea [78], en donde junto con la utilización de *machine learning* permiten determinar el estado de una persona y poder clasificarla entre dormida y despierta. Estos métodos utilizan micrófonos colocados en la habitación con frecuencia de muestreo de 44,1 kHz, modulación por codificación de pulsos PCM y 16 bits por muestra, o por otro lado, la recopilación de señales de voz con el micrófono de un dispositivo móvil en la habitación como propone [79].

2.1.3 Parámetros utilizados para inferir el comportamiento durante el sueño

Uno de los parámetros que se puede obtener durante el análisis del sueño resulta ser la cantidad de horas de sueño de la persona en cuestión; sin embargo, este conteo de horas se ve afectado por distintas variables que serán analizadas a continuación [80]:

- Despertares nocturnos: Se trata de contabilizar el número de veces que la persona se despierta durante el proceso de sueño.
- Duración de despertares: Indica la duración de un despertar en una persona.
- Cantidad de horas de sueño: Indica el número de horas que duerme una persona sin diferenciar si se encuentra en etapa de sueño REM (*Rapid Eye Movement*).
- Higiene del sueño: Se relaciona a los factores ambientales donde se desarrolla el sueño de una persona, es decir, luz, temperatura de luz, cafeína, medicamentos ingeridos o posición para dormir.
- Trastornos del comportamiento del sueño: Movimientos realizados por la persona de manera involuntaria.
- Irregularidades de la melatonina: Cambios en liberación de melatonina producto de *jet lag* o trabajo por turnos.
- Alteraciones del ritmo cardiaco: Cambios en el ritmo cardiaco durante el sueño.
- Insomnio: dificultad que presenta una persona para conciliar el sueño.
- Apnea obstructiva del sueño: Se trata de un colapso en las vías respiratorias durante el sueño, lo cual impide alcanzar el sueño profundo.
- Calidad del sueño en escala cualitativa: indica cómo se siente la persona en escala cualitativa luego de un proceso de sueño [81].

Adicionalmente, es importante conocer que el sueño se puede clasificar según etapas, las cuales producen distintos efectos en la salud de la persona, entre los que se tiene [80]:

- Etapa N1: Durante esta etapa la respiración y la frecuencia cardiaca son regulares, es la etapa inicial del sueño en la cual la mente y el cuerpo se relajan, y la persona se mantiene consciente de lo que sucede a su alrededor, con la consideración de que no sucede en personas con trastornos de narcolepsia, es decir somnolencia que produce altos niveles de sueño durante el día.

- Etapa N2: En esta etapa la temperatura corporal empieza a descender, pueden suceder ronquidos, la persona desconoce lo que sucede a su alrededor; además, esta etapa contribuye a la salud de la memoria a largo plazo.
- Etapa N3: Esta etapa conocida como sueño profundo, se caracteriza por tener presión arterial baja, respiración ralentizada, dificultad para despertar. Se produce reparación de tejidos y se restaura la energía de la persona.
- Etapa de movimiento ocular rápido (REM, por sus siglas en inglés): Se define como el intervalo de tiempo desde donde empieza el sueño hasta que el sueño se presente como sueño de tipo REM, lo cual se presenta entre 70 y 90 minutos desde que la persona se duerme. Se considera que este intervalo de sueño ocupa el 25% de todo el ciclo, durante esta etapa del sueño se presentan los sueños ya que el cerebro se encuentra muy activo.

2.1.4 Metodología cualitativa para detección de sueño

El estudio del sueño, mediante la compilación de información de tipo cualitativa resulta bastante común a nivel médico, producto de esto, la incorporación de encuestas en los análisis resulta de gran ayuda al momento de recopilar información del sueño y su calidad. Esta información puede ser comparada con la obtenida producto del análisis con sensores de medición y aprendizaje de máquina. Basándose en este enfoque se han desarrollado varias encuestas desde el punto de vista médico para poder evaluar y clasificar la calidad de sueño en una escala cualitativa, mismas que servirán como insumos en la implementación de las aplicaciones que puedan desarrollarse en el futuro. En la **Tabla 2.3**, se presenta una comparación de diferentes cuestionarios utilizados según las referencias [82]–[85]:

- Cuestionario Berlín: examina si la persona presenta síntomas relacionados con ronquidos o apnea en situaciones diurnas o en la conducción de vehículos.
- Escala de somnolencia de Epworth: utilizada como una herramienta para identificar el trastorno de la apnea obstructiva del sueño, se califica en escala de 1 a 24. Donde un puntaje entre 1 a 6 puntos se considera que una persona tiene un sueño normal, entre 7 a 8 puntos se considera somnolencia media y entre 9 a 24 puntos se considera somnolencia anómala.
- Cuestionario Stop Bang: es una herramienta de detección simple que se basa en el análisis de *Stop* (ronquido, cansancio, apnea y presión arterial); y *Bang* (índice de

masa corporal, edad, circunferencia del cuello y sexo); además existe una versión más simple que únicamente evalúa los parámetros *Stop*.

- Escala de insomnio de Pittsburgh: se utiliza en el ámbito médico para la detección de insomnio y su clasificación según una escala de gravedad. Se divide en 3 secciones: angustia subjetiva, parámetros subjetivos del sueño y la calidad de vida; con 46, 10 y 9 preguntas respectivamente.
- Escala índice de calidad de sueño de Pittsburg: evalúa la calidad del sueño. Este cuestionario consta de 19 ítems que analizan la cantidad, calidad, duración, latencia y eficiencia del sueño. Cada componente en dicha escala PSQI (*pittsburgh sleep quality index*), también conocido como Calidad de sueño según la escala índice de calidad de sueño de Pittsburg, la cual puntúan de 0 a 3. El valor total puede variar de 0 a 21 puntos, por lo que, a mayor puntuación, peor calidad del sueño.

Tabla 2.3 Comparación de diferentes cuestionarios utilizados en el análisis de sueño [80]

Cuestionarios	Características
Cuestionario Berlín	<ul style="list-style-type: none"> ✓ Cuenta con 10 preguntas de diversos ámbitos y similares a las presentadas en <i>Stop Bang</i>. ✓ Sensibilidad cerca del 97.3%. ✓ Evalúa criterios de ronquidos, somnolencia diurna y antecedentes médicos.
Escala de somnolencia de Epworth	<ul style="list-style-type: none"> ✓ Se basa de 8 preguntas que hacen referencia a 8 distintos escenarios en los cuales la persona se ha quedado dormida. ✓ Analiza la somnolencia diurna. ✓ Sensibilidad entre 46% a 80%
Cuestionario Stop Bang	<ul style="list-style-type: none"> ✓ Obtiene resultados más precisos que los cuestionarios de Berlín y Epworth. ✓ Amplia la posibilidad de diagnóstico para la detección de OSA. ✓ Es utilizada para entrevistas en la detección temprana de OSA. ✓ Cuenta con 8 preguntas de diferentes ámbitos. ✓ Analiza parámetros de ronquidos, cansancio, hipertensión, circunferencia del cuello, entre otros.
Escala de insomnio de Pittsburgh	<ul style="list-style-type: none"> ✓ Cuenta con 65 preguntas en base a su comportamiento durante el sueño. ✓ Sensibilidad cercana a 94%. ✓ Analiza la calidad general del sueño.

Escala índice de calidad de sueño de Pittsburgh	<ul style="list-style-type: none"> ✓ Cuenta con 19 preguntas. ✓ Sensibilidad cercanos a 89.6%. ✓ Evalúa la calidad de sueño general.
---	---

Cabe recalcar que los resultados que se obtengan de las encuestas se van a ver influenciados de manera directa en distintos parámetros como lo son la edad, sexo y el índice de masa corporal.

2.2 Características de las técnicas de aprendizaje de máquina más utilizadas en el análisis de sueño

De la revisión bibliográfica de trabajos donde se analiza el sueño se puede observar que la mayoría utilizan técnicas tales como:

- **Redes neuronales:** Esta técnica se basa en el comportamiento de las redes neuronales biológicas. Se compone de 3 partes. En primer lugar, una capa de entrada donde ingresan los parámetros que utilizará la red. Como segunda parte se tiene una o varias capas ocultas, las cuales se conocen como capas de nodos que conectan las capas de entrada con las capas de salida, y como última parte, se tiene la capa de salida que genera la salida de la red.

Su funcionamiento se basa en enviar la información desde la capa de entrada a las capas ocultas mediante la selección de funciones de activación, las que generan que los nodos de las capas ocultas se activen en base a los resultados de la función. Entre los parámetros necesarios para el funcionamiento de este algoritmo se incluyen los parámetros de aprendizaje, el número de muestras de entrenamiento; así como el modelo y el tamaño. Para la parte del entrenamiento de esta técnica, es necesario realizar el ajuste de los respectivos pesos de las neuronas, con lo cual se asigna un peso a cada conexión de dato procesado[86].

- **Support Vector Machine (SVM):** Esta técnica se basa en separar datos en dos clases: en modo de clasificador lineal, se centra en maximizar la distancia entre instancias de distintas clases, apoyándose en una función separadora. Por otro lado, se caracteriza por tener un desempeño alto si el número de características en el conjunto de datos es alto. Permite realizar tanto la clasificación como regresión [87],[88].
- **K-NN:** Esta técnica conocida como K vecinos cercanos o clasificador K, se basa en la clasificación de nuevas instancias, basándose en los datos que ya fueron

clasificados, luego procede a comparar los datos ya clasificados y calcula la distancia que existe entre las instancias más próximas, con el fin de asignar una clase a la nueva instancia. Por otro lado, K-NN se caracteriza por ser fácil de implementar y basa su rendimiento en la elección del valor de k vecinos [89].

Tabla 2.4 Comparación entre las técnicas de aprendizaje más utilizadas en el análisis del sueño [90]

Técnica	Características
Redes neuronales	<ul style="list-style-type: none"> ➤ Más compleja de implementar. ➤ Requiere configurar varios parámetros para su funcionamiento. ➤ Robusta en conjunto de datos que presentan ruido.
SVM	<ul style="list-style-type: none"> ➤ El tiempo de respuesta aumenta de manera cuadrática en función de la cantidad de datos en relación con K-NN. ➤ La predicción es numérica.
K-NN	<ul style="list-style-type: none"> ➤ Mayor facilidad de implementación. ➤ Solo requiere 1 parámetro de configuración.

La elección del algoritmo a utilizarse en el aprendizaje de máquina resulta importante ya que determinará los resultados del estudio. Es por esta razón, que se recomienda evaluar el rendimiento que se obtenga con los posibles algoritmos seleccionados a fin de obtener mejores características; además de tener en cuenta que, la elección correcta facilitará la implementación y construcción de una aplicación en el futuro.

2.3 Proceso de tratamiento y procesamiento de la información

Para abordar el proceso de tratamiento y procesamiento de la información se plantea el diagrama presentado en la **Figura 2.2**, el cual se segmenta en seis Bloques con el fin de poder explicar las etapas utilizadas en la recopilación e inferencia de resultados.

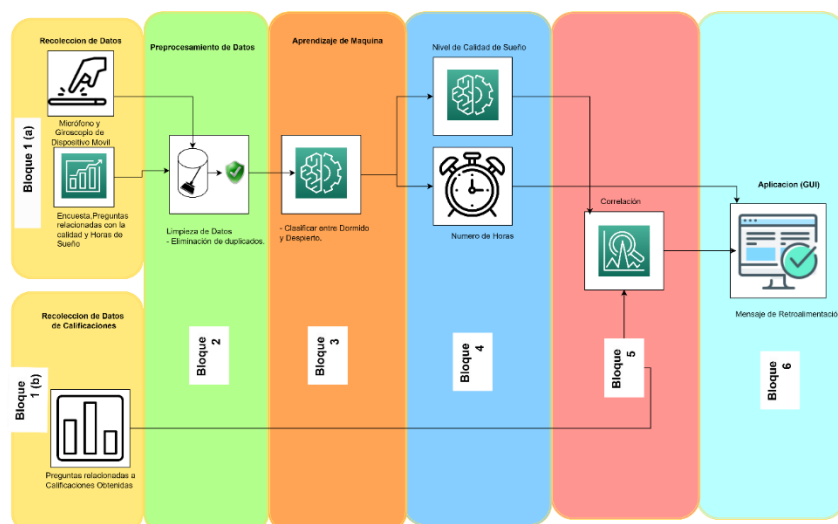


Figura 2.2 Flujograma de ejecución de análisis de sueño y rendimiento académico

A continuación, se explicarán cada uno de los bloques que forman parte del flujograma.

2.3.1 Bloque 1: Recolección de datos

Es el bloque inicial en todo el proceso, donde se realiza la recolección de datos desde el terminal móvil. Este bloque consta de dos partes como se observa en la **Figura 2.3**, la adquisición de datos a través de los sensores del terminal móvil y encuestas con información ingresada por el usuario y la recolección de datos de las calificaciones ingresadas por el usuario.

Bloque 1(a): Recolección de datos referente al sueño

Este primer bloque se enfoca en la recolección de datos mediante los sensores que se encuentran en el dispositivo móvil, los sensores considerados son el micrófono y sensor de luminosidad, los cuales realizarán la recolección de datos referentes a los sonidos de respiración y cantidad de luminosidad. En este proceso es importante definir los intervalos de medición, los mismos que deben considerar la cantidad de batería consumida. Por otro lado, se propone la utilización de encuestas para la recolección de información que complementa el análisis del sueño.



Figura 2.3 Fase de recolección de datos de sueño

Con el fin de presentar mayor detalle en la recolección de la información relacionada con el sueño en base a encuestas se propone el diagrama de flujo de la **Figura 2.4**, en el cual luego de realizar el ingreso a la aplicación, se procede a registrar la semana y posteriormente el día a consignar, recordando que los ingresos deberían ser diarios. Luego se solicita que el usuario ingrese el número de horas de sueño

que durmió y la calidad del mismo, para esta parte se procederá a presentar una escala de cinco valores similar a la propuesta para registro de satisfacción de un servicio, las cuales representan de manera numérica un valor cualitativo del usuario, de esta forma se tendrá : “1. Muy Mal”, “2. Mal”, “3. Moderado”, “4. Bien”, “5. Excelente”, como se puede notar los números en orden ascendente representan la calidad de sueño registrada por el usuario partiendo desde “Muy mal” representada por el número 0 y finalizando en “Excelente” representada por el número 5.



Figura 2.4 Flujograma de recopilación de horas de sueño mediante encuestas

Bloque 1(b): Recolección de datos referente a las calificaciones del estudiante

En este bloque que se muestra en la **Figura 2.5**, se realizará la recopilación de información mediante encuestas a ser llenadas por el usuario. La información ingresada incluye las calificaciones obtenidas por el estudiante en distintos periodos académicos, la explicación más específica de este proceso se presenta en el flujograma de ejecución.




Figura 2.5 Fase de recolección de datos utilizando encuestas para calificaciones

Para el proceso de recolección de datos que servirán de insumos para el cálculo de los parámetros de rendimiento académico, se plantea el flujograma de la **Figura 2.56**. Este proceso inicia con el ingreso a la aplicación móvil, donde se plantea registrar el semestre en el que el estudiante se encuentra matriculado, además de

especificar la base de calificación del estudiante para poder normalizar los datos de manera posterior en caso de ser necesario, luego se incorporará el número de horas tomadas por el estudiante en total durante un semestre en estudio, finalmente este flujo acaba con el ingreso de las materias y su respectiva calificación en un proceso repetitivo de las materias.




Figura 2.6 Flujograma de recopilación de calificaciones mediante encuestas

2.3.2 Bloque 2: Preprocesamiento de datos

Una vez recopilada la información, el siguiente proceso a realizar es el preprocesamiento de datos como se muestra en la **Figura 2.6**. Parte de preprocesamiento de datos es la limpieza de estos, para esto se verificará cuáles son los datos que se necesita para el estudio y se realizara el preprocesamiento de datos, de igual manera se explica con más detalle en el flujo de esta sección en la **Figura 2.7**.



Figura 2.6 Fase de preprocesamiento de datos

En base a los datos recopilados, se procede a realizar la limpieza de datos, para lo cual se aplica la eliminación de duplicados, relleno de datos vacíos y eliminación de datos atípicos de ser el caso. Además, se incluye la normalización en el caso de comparar resultados

obtenidos en dos instituciones con diferente base de calificación como se indica en la **Figura 2.7**.



Figura 2.7 Flujograma de limpieza de datos

2.3.3 Bloque 3: Aprendizaje de máquina

Con los datos depurados, se procede a aplicar un algoritmo de aprendizaje de máquina (**Figura 2.8**), con el propósito de clasificar si la persona se encuentra dormida o despierta, cuantizando las horas de sueño de la persona en estudio.



Figura 2.8 Fase de aplicación de aprendizaje de máquina

2.3.4 Bloque 4: Nivel de calidad de sueño

Producto de la aplicación del algoritmo de aprendizaje de máquina se obtienen los resultados de clasificación en base al número de horas de sueño y el nivel de la calidad de sueño, como se observa en la **Figura 2.9**.




Figura 2.9 Fase de análisis de resultados preliminares

El objetivo principal del análisis del sueño será conocer si la persona se encuentra o no dormida, para esto, en conjunto con la utilización con técnicas de aprendizaje de máquina, se procederá a ingresar a los escenarios de entrenamiento del algoritmo, las señales (respiración y luz) que permitan determinar el comportamiento de la persona. Luego se propone de manera general, la selección de datos, la cual se ve representada por el Bloque 3 de la **Figura 2.2** o llamada como “Fase de preprocesamiento de datos”, para posteriormente llevar los datos a las secciones finales y detectar el estado del sueño de la persona.

Para representar este flujo de detección de sueño partiendo de la recolección de señales se propone la **Figura 2.10** Basada en estudios de sueño relacionados, para el caso de la recopilación de datos utilizando la respiración como parámetro principal.




Figura 2.10 Flujograma de detección de sueño en base a señales respiratorias [91].

De la misma forma, utilizando como parámetro de entrada las señales de luminosidad, los mismos que pueden ser utilizados para reforzar los datos obtenidos en la respiración, se pretende recopilar siguiendo el flujograma de la **Figura 2.11**. Además de esto, las señales

de luminosidad pueden ser utilizadas como disparador en la aplicación para empezar a realizar la recopilación de datos de sueño, únicamente censando si los niveles de luminosidad se encuentran bajo o sobre umbrales definidos durante la construcción de la aplicación.




Figura 2.11 Flujograma de ejecución basado en [77] para señales de luz.

2.3.5 Bloque 5: Correlación

Los resultados preliminares obtenidos del aprendizaje de máquina serán utilizados para poder ser correlacionados y así determinar si existe una relación estrecha entre los parámetros analizados del sueño y las calificaciones obtenidas, las cuales representan el rendimiento académico (**Figura 2.12**).




Figura 2.12 Fase de correlación

2.3.6 Bloque 6: Aplicación (GUI)

Finalmente, los resultados obtenidos serán presentados en la aplicación que se desarrolle en un futuro, con el fin de ofrecer una retroalimentación al usuario, en la cual, se indicarán las horas de sueño, el rendimiento académico obtenido, y una alerta en caso de que los resultados obtenidos se encuentran por debajo del umbral que se define en la **Tabla 1.1**, como se observa en la **Figura 2.13**.



Figura 2.13 Fase de presentación de resultados

Para implementar la aplicación móvil se necesita definir al menos dos roles, un rol de usuario y un rol de administrador.

El rol usuario contempla tener privilegios limitados y podrá acceder únicamente a los datos ingresados por él, así como reportes en intervalos de tiempo y las pantallas de ingreso de valores.

El rol administrador podrá tener acceso a los reportes globales, así como a la lista de usuarios para poder editarlos y eliminarlos de ser el caso.

Para lograr obtener una funcionalidad limitada con base en los usuarios descritos, se propone un inicio de sesión (**Figura 2.15**), reinicio de contraseña y registro como se indica en la **Figura 2.14** en la cual se establece cuatro secciones, las cuales se utilizarán en el caso de olvidar la contraseña o no estar registrado en la aplicación.

2.4 Componentes necesarios en la construcción de la aplicación para monitoreo de sueño

Se plantean posibles componentes que puede incluir una aplicación móvil para realizar el monitoreo del sueño en base a los roles planteados en 2.1.6. Los cuales son:

- Inicio de sesión (administrador y usuario)
- Registro
- Recuperación de contraseña

En primer lugar, se presenta un diagrama completo del flujo de la aplicación para el inicio de sesión según la **Figura 2.14**, en la cual se diferencia el flujo hacia “Inicio de Sesión”, “Recuperación de contraseña” y “Registro”.

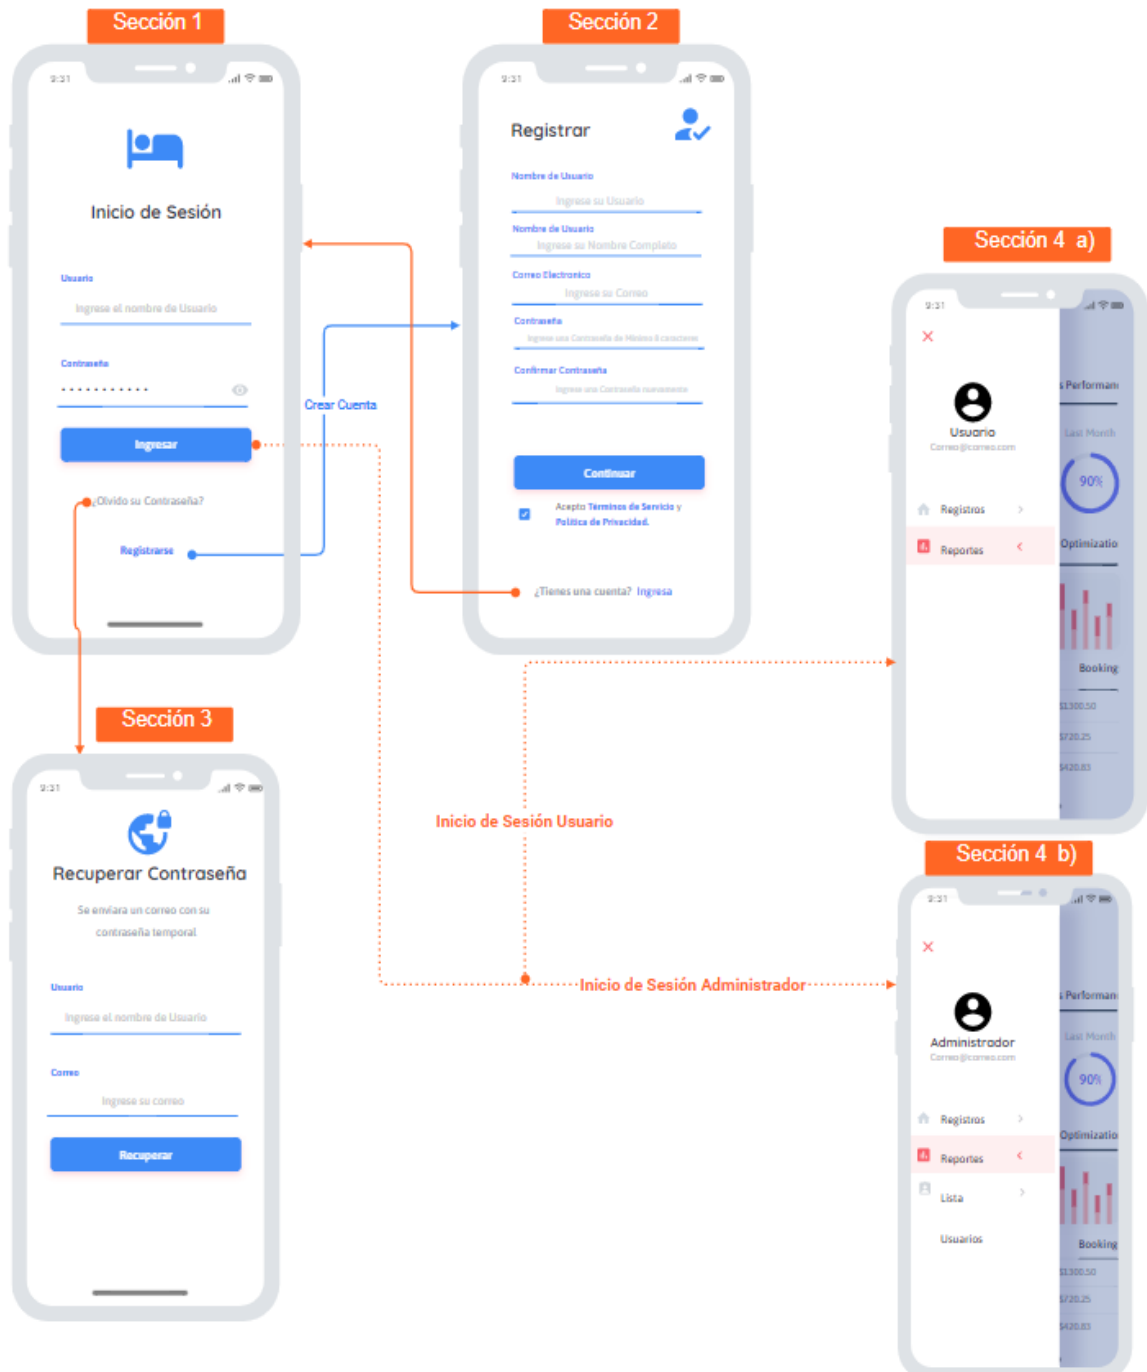


Figura 2.14 Flujo de aplicación para inicio de sesión

A continuación, se explicará las secciones de la **Figura 2.14**:

2.4.1 Inicio de sesión

En esta sección se tiene una pantalla de lanzamiento como se indica en la **Figura 2.15**, en la cual se muestran dos campos para llenar, el nombre de usuario y la contraseña, además, se tiene un botón de “Ingresar”, el cual solicita la verificación de las credenciales, de ser correctas se enviará a la sección 4, luego, en caso de no recordar la contraseña, se tiene un botón de “¿Olvido su Contraseña?”, el cual llevara a la sección 3, finalmente, en caso de no tener usuario, se tiene un botón de “Registrarse”, que conducirá a la sección 2.

Es importante considerar que en caso de que no se ingrese de forma correcta las credenciales se genere un mensaje de error.

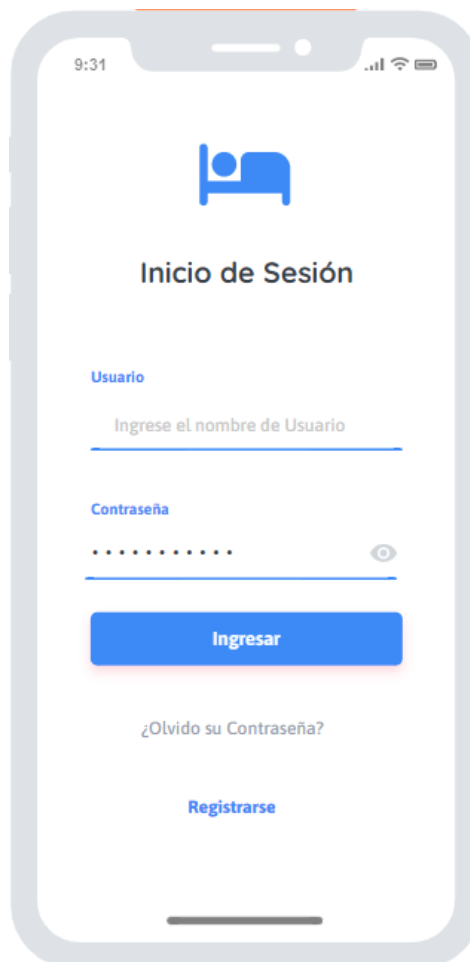


Figura 2.15 Plantilla de inicio de sesión

2.4.2 Registro de usuario

Para el registro del usuario, se solicita que el usuario ingrese un nombre de usuario, el nombre completo del usuario, el correo electrónico, y la contraseña, como se indica en la **Figura 2.16**, tomar en cuenta que se deberá realizar varias verificaciones, en primer lugar,

es necesario que se tome en cuenta que el nombre de usuario esté disponible, además que el formato del correo electrónico sea el correcto y que la contraseña cumpla parámetros básicos de seguridad como son la longitud de la clave y la presencia de mayúsculas, números, entre otros.

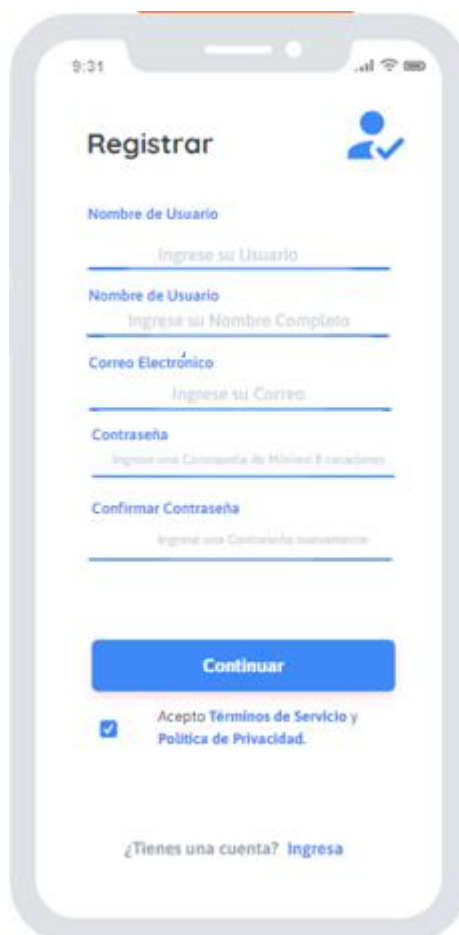
Una captura de pantalla de una aplicación móvil que muestra la pantalla de registro. El título es "Registrar" con un ícono de usuario y una marca de verificación. Hay cuatro campos de entrada: "Nombre de Usuario" (con el texto "Ingrese su Usuario"), "Nombre de Usuario" (con el texto "Ingrese su Nombre Completo"), "Correo Electrónico" (con el texto "Ingrese su Correo") y "Contraseña" (con el texto "Ingrese una Contraseña de Mínimo 8 caracteres"). Debajo del campo de contraseña hay un campo "Confirmar Contraseña" (con el texto "Ingrese una Contraseña nuevamente"). Un botón azul "Continuar" está centrado. Debajo del botón hay un ícono de casilla de verificación marcada y el texto "Acepto Términos de Servicio y Política de Privacidad.". En la parte inferior, hay un enlace "¿Tienes una cuenta? Ingresar".

Figura 2.16 Plantilla de registro de usuario

2.4.3 Recuperación de contraseña

En el caso de que el usuario no recuerde su contraseña, se procederá a llegar a la pantalla de restablecimiento de contraseña como se indica en la **Figura 2.17**, en este punto, se solicita como parámetros necesarios para verificar la identidad del usuario el ingreso de su usuario y correo electrónico, en caso de coincidir, se reiniciará la contraseña y se enviará un correo a la dirección ingresada informando la contraseña temporal que se cambió, con esto el usuario puede recuperar el acceso a la aplicación.

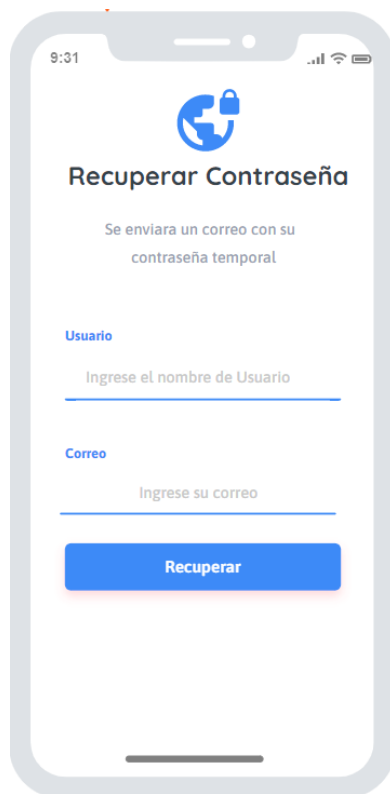


Figura 2.17 Plantilla de recuperación de contraseña

2.4.4 Sesiones de usuario

En caso de que el usuario tenga una cuenta, se procederá al inicio de sesión, para este caso se divide esta sección en dos puntos, por un lado, se tiene el inicio de sesión para el usuario común y por otro lado el inicio de sesión para el usuario administrador.

Sección 4(a) representa el inicio de sesión en el usuario común, para esto se indica la pantalla de inicio con un menú lateral que consta de registro (ingreso de los datos a la aplicación) y reporte (visualización de los reportes en base a los datos ingresados), así como el nombre de usuario y su correo, tal como se indica en la **Figura 2.18**.

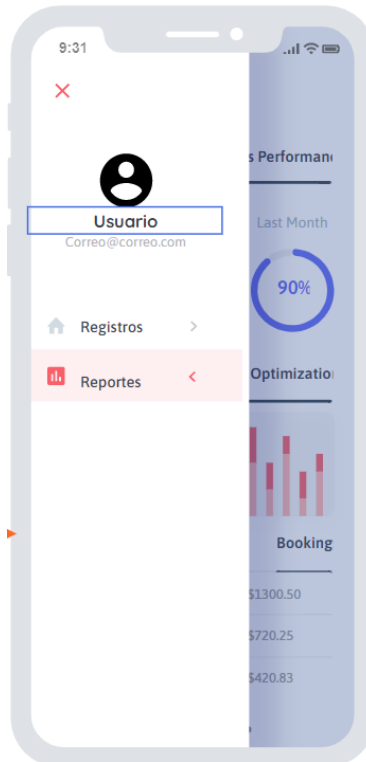


Figura 2.18 Plantilla de inicio desde usuario

Sección 4(b) contempla el inicio de sesión del usuario administrador, de manera similar al ingreso como usuario común, se indica en la **Figura 2.19** en donde a diferencia del usuario común, se tendrá acceso también a la lista de usuarios, la cual indicará la lista total de los usuarios, la cual se indica en la **Figura 2.20**

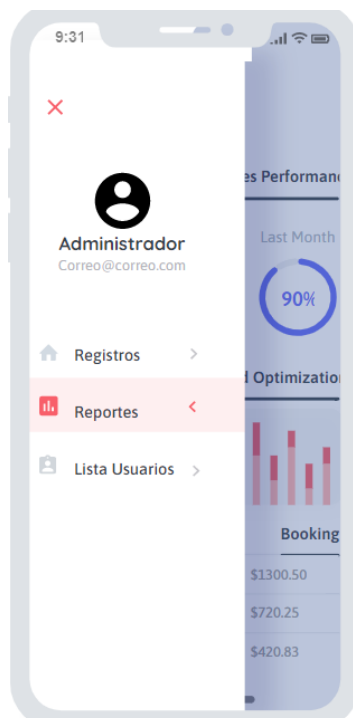


Figura 2.19 Plantilla de inicio desde administrador

En el caso de presionar en la lista de usuarios, se propone una pantalla similar a la mostrada en la **Figura 2.20**, en la cual se tiene la lista de los usuarios, se permite buscarlos por nombre, y se tienen 2 botones, el primero permite visualizar el reporte de un usuario en particular, mientras que el segundo permite eliminar al usuario.

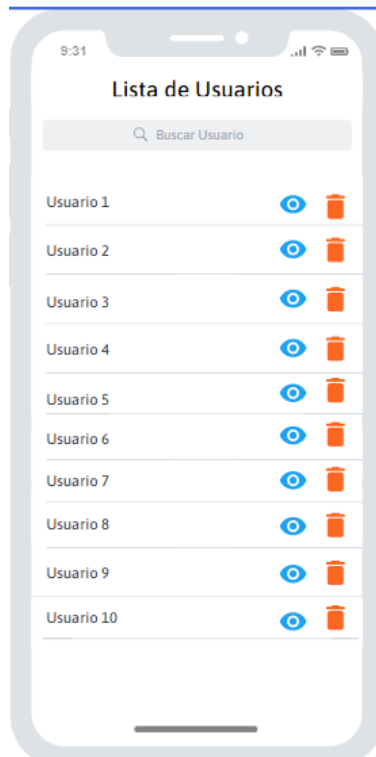


Figura 2.20 Plantilla de lista de usuarios

De manera similar a la **Figura 2.14**, se construyó el diagrama de flujo para el registro de la información desde el inicio de sesión hacia el menú de registro, con el fin de seleccionar el tipo de información a registrar (calificaciones o sueño).

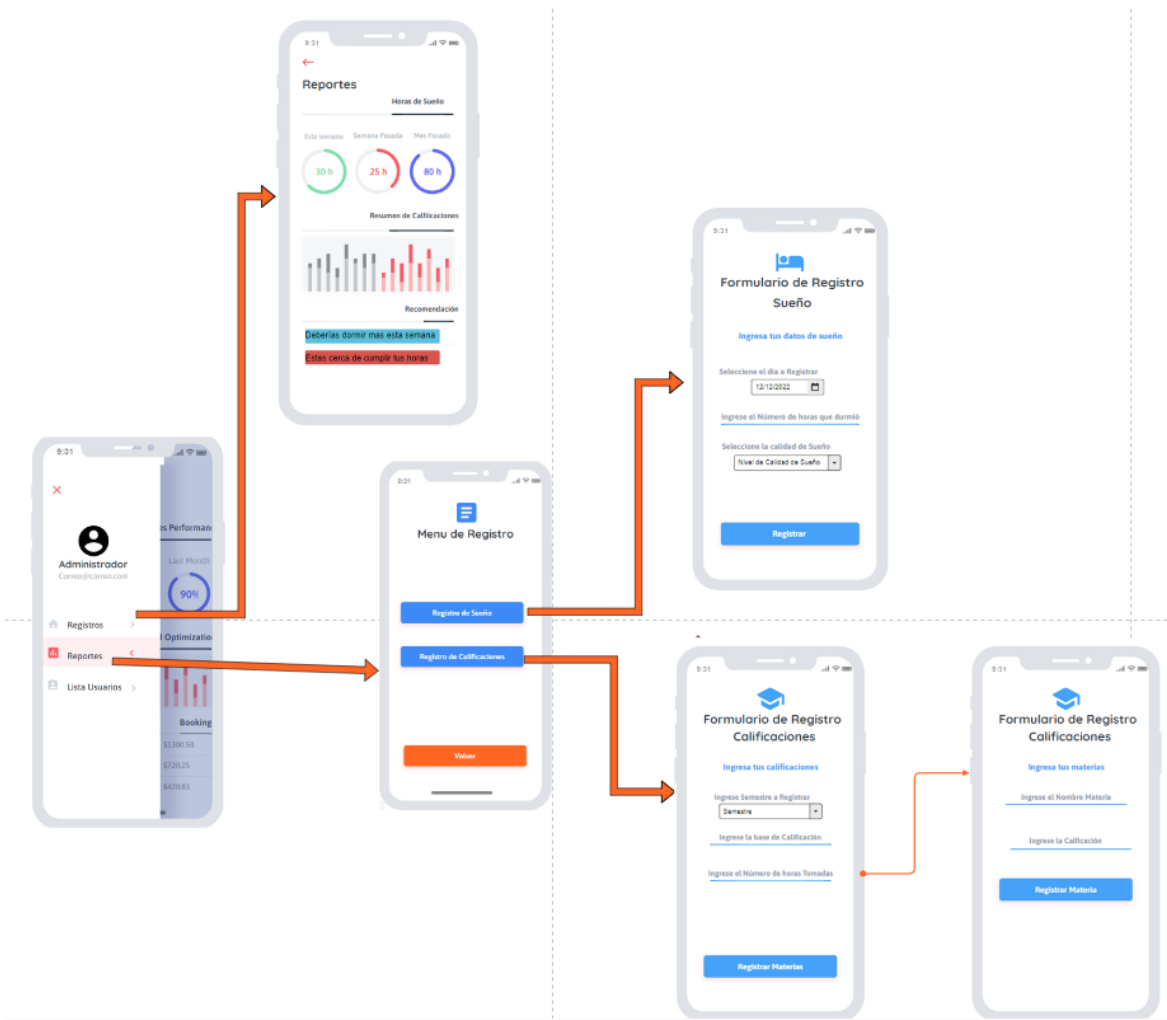


Figura 2.21 Flujo de aplicación para registro de datos

Posteriormente, el ingreso de datos en el registro de sueño se realiza mediante un formulario similar a la **Figura 2.22**, en donde se selecciona la fecha a registrar desde un calendario, luego se ingresa el número de horas que el estudiante durmió, además, de ingresar la calidad de sueño según la escala del 1 a 5 que se indicó anteriormente, finalmente se colocó un botón de registro, el cual finaliza el proceso.

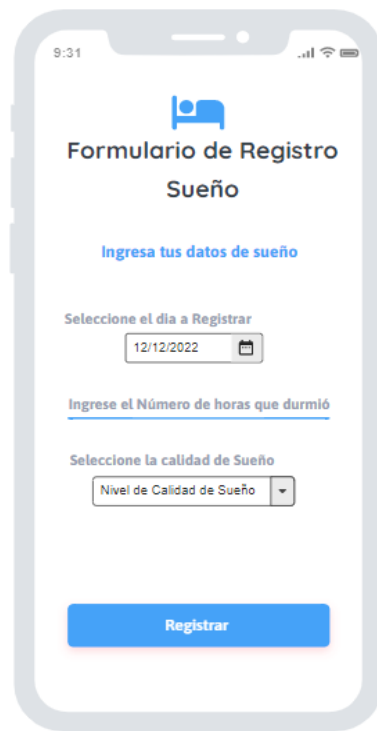


Figura 2.22 Plantilla de interfaz de registro de datos para sueño

De la misma forma, al momento de registrar las calificaciones, se plantean las siguientes interfaces de ejemplo para la construcción de la aplicación de acuerdo con el diagrama de flujo de la **Figura 2.23**, donde debe ingresarse el semestre, la base de la calificación y las materias con su respectiva calificación.

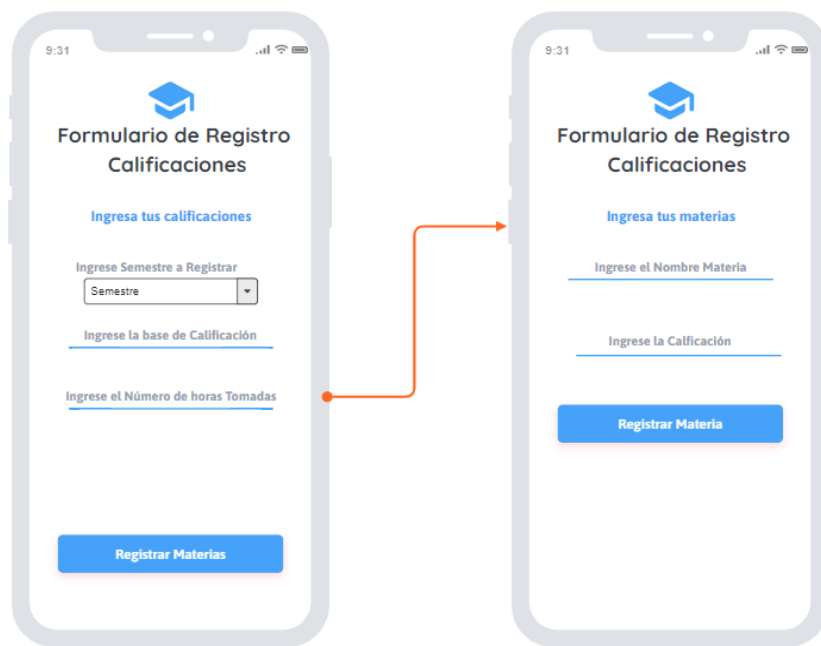


Figura 2.23 Plantilla de interfaz de registro de datos para calificaciones

2.4.5 Reportes de resultados

Dado que se propone retroalimentación de los resultados obtenidos, en donde con base en reportes delimitados por fechas, se indica el número de horas de sueño, recopilación de datos obtenidos y las calificaciones obtenidas e ingresadas en los formularios mencionados anteriormente, con el fin de obtener un mensaje de retroalimentación, como se propone según la **Figura 2.24**.



Figura 2.24 Plantilla para presentación de reportes y resultados de los datos obtenidos

2.4.6 Alternativas de almacenamiento de datos en la aplicación

Con base en el enfoque que se tenga, se propone dos vías para el almacenamiento de los datos, por un lado, una alternativa revisada es aplicar una base de datos local ubicada en el dispositivo móvil propio de cada usuario con el fin de obtener retroalimentación, teniendo en cuenta que esta solución, mostrada en la **Figura 2.25** sección a), dificultará que el desarrollador obtenga los resultados propios de los usuarios de la aplicación desarrollada, mientras que por otra parte, utilizando la sección b) la cual representa utilizar una base de datos alojada en un servidor externo, posibilita que los datos puedan ser tratados desde la perspectiva de un gran número de usuarios.

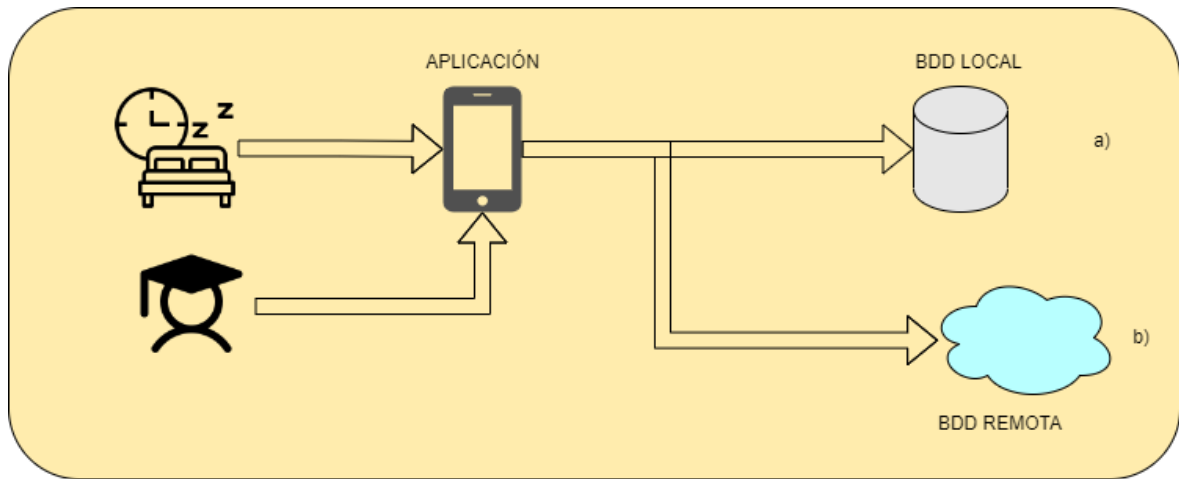


Figura 2.25 Flujo de almacenamiento de datos con base en el tipo de base de datos

3. RESULTADOS, CONCLUSIONES Y RECOMENDACIONES

3.1 Resultados

Se analizó un total de 24 estudios relacionados directamente con el análisis del sueño utilizando sensores médicos. Basándose en la **Tabla 2.1**, de donde se procedió a realizar una representación gráfica según la señal utilizada, como se puede visualizar en la **Figura 3.1**; en la cual utilizando un gráfico de tipo pastel es posible visualizar que la señal más utilizada con sensores médicos es la ECG o señal de electrocardiograma, la cual registra el comportamiento del corazón en un periodo de tiempo, seguida por la señal SPO_2 , la cual hace referencia al porcentaje de saturación de oxígeno en sangre.

Por otro lado, se recalca que utilizando la señal ECG es posible obtener diversos parámetros como lo son el intervalo R-R, que resultó ser muy utilizado en los diferentes estudios que utilizaron la señal ECG.

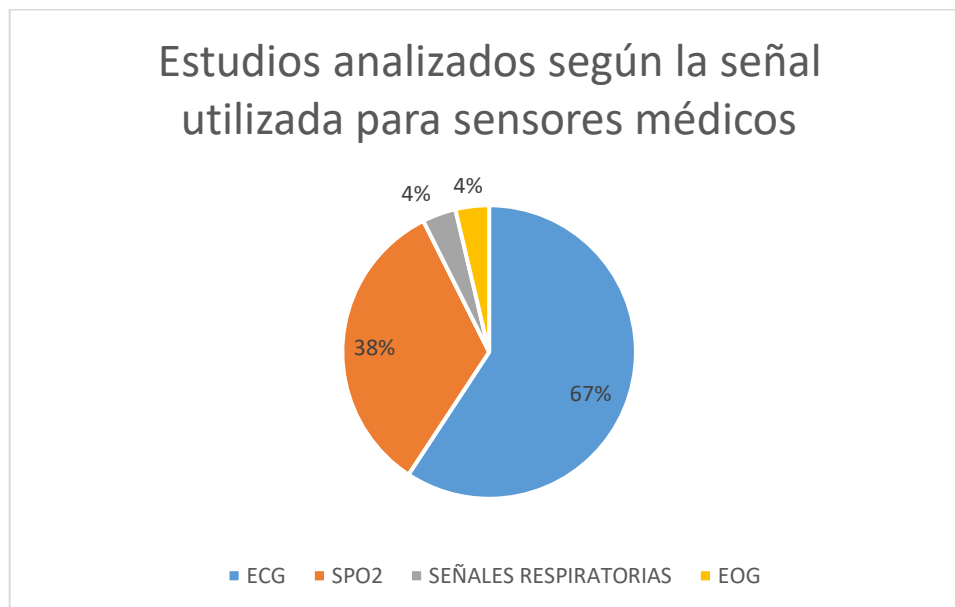


Figura 3.1 Estudios analizados según señal utilizada para sensores médicos

De la misma manera, en el caso de los sensores ambientales se analizaron 12 estudios, los cuales se presentaron en la **Tabla 2.2**, de donde se generó la **Figura 3.2**, el cual indica que la señal más utilizada se asocia al flujo de aire o señal de voz, seguido de la recopilación de datos tomando como punto de estudio el movimiento de las personas, el cual implica la utilización de la cámara del dispositivo.




Figura 3.2 Estudios analizados según señal utilizada para sensores ambientales

Por otro lado, como segundo enfoque se segmentó los estudios con base en la técnica de aprendizaje utilizada. En primer lugar, para los sensores médicos, se tiene la **Figura 3.3**, donde se puede observar que las técnicas más utilizadas fueron las redes neuronales y SVM.

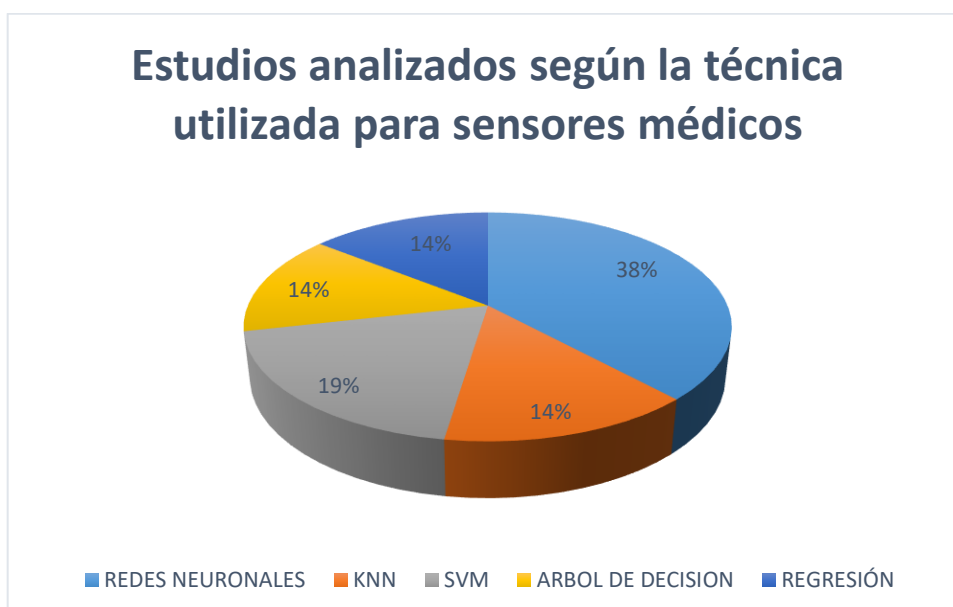


Figura 3.3 Estudios analizados según técnica utilizada para sensores médicos

De la misma forma con base en la técnica de aprendizaje en estudios que involucren a los sensores ambientales, se pudo evidenciar en la **Figura 3.4**, que las técnicas de aprendizaje

de máquina más utilizadas corresponden a las redes neuronales en sus distintas configuraciones, seguidas de la técnica de *Support Vector Machine* y de la técnica KNN.




Figura 3.4 Estudios analizados según técnica utilizada para sensores ambientales

Con base en los resultados obtenidos tanto con sensores médicos como con sensores ambientales se puede concluir que el utilizar técnicas de redes neuronales para el análisis y determinación de resultados son la mejor opción.

Es así que se recomienda utilizar en este estudio el tipo de técnica de aprendizaje de máquina de red neuronal, además de utilizar las señales respiratorias como parámetro principal de medición, mientras que se recomienda utilizar un parámetro secundario como es el caso de la cantidad de luz en la habitación para reforzar la información obtenida.

Finalmente, como tercer enfoque se tomó como base el porcentaje de precisión obtenido por cada uno de los estudios que se analizó, de donde en la **Figura 3.5**, indica la compilación mediante un diagrama de barras de esta información. Se puede notar que las 3 técnicas que obtuvieron un mayor porcentaje de precisión corresponden a los árboles de decisión, KNN y las redes neuronales.




Figura 3.5 Estudios analizados según porcentaje de precisión

Otro aspecto a tomar en cuenta es el tipo de encuesta seleccionada para la inclusión y presentación en la aplicación móvil. Utilizando la **Tabla 2.3**, se pudo determinar las principales características de cada tipo de encuesta, según esto las mejores opciones de encuestas son: Escala índice de calidad de sueño de Pittsburg y el cuestionario Berlín, dado que las demás soluciones presentan el problema de contener un número alto de preguntas lo cual puede resultar tedioso para el usuario, o solicitar datos que no sean fáciles de responder mediante sensores del dispositivo como es el caso de la circunferencia del cuello en el cuestionario *Stop Bang*.

3.1.1 Requerimientos mínimos para creación de aplicación móvil de monitoreo del sueño

En base al análisis realizado de los diferentes trabajos se pudo determinar algunas recomendaciones al momento de desarrollar la aplicación, en primer lugar, se recomienda utilizar las señales de voz, luminosidad y tiempo de utilización del dispositivo para el análisis de sueño. Además, en relación a lo observado en el capítulo 2 se sugiere la implementación de encuestas en la aplicación, las cuales permitan realizar el registro del número de horas de sueño y la calidad del sueño.

En primer lugar, la construcción de la aplicación deberá contemplar las pantallas de usuario y los requerimientos y requisitos funcionales y no funcionales necesarios para su diseño, para esto se recomienda como pantallas mínimas una pantalla de ingreso a la aplicación mediante usuario y contraseña, una pantalla de ingreso de calificaciones por semestre, una

pantalla de ingreso de horas de sueño y calificación de calidad de sueño (puede incluir una encuesta analizada en la **Tabla 2.3** y una pantalla de visualización de reportes donde se puede incluir los mensajes de retroalimentación.

La base de datos debe contar con algunos parámetros mínimos en los 3 escenarios (encuesta de sueño, encuesta de rendimiento y recolección de datos de sueño), se plantea que los datos mínimos a obtener deberán ser el número de horas de sueño y un promedio de calificaciones por un periodo de tiempo en el cual se desee realizar el análisis. Por otro lado, al momento de obtener estos datos, se recomienda realizar una correlación de los parámetros, los cuales permitirán ver el grado de relación y la manera en la que influyen unos parámetros con otros; también se recomienda utilizar herramientas de análisis de datos para poder simplificar el proceso de *machine learning*, por un lado, para la obtención de la matriz de correlación y el coeficiente de correlación se propone el software de Weka[92], el cual posibilita realizar el análisis de distintas pruebas de manera sencilla.

Luego para la limpieza de datos y el procesamiento de los datos para poder tenerlos como parámetros de entrada para la técnica de aprendizaje de máquina se tienen varias opciones, la primera será mantenerse en el ambiente de Weka, que permite realizar la limpieza de datos y probar varias técnicas de aprendizaje. Además, se debe considerar la utilización de Python mediante librerías creadas para el procesamiento de datos, tales como Pandas, *Numpy*, *Matplotlib*, entre otras.

Al momento de realizar la elección del algoritmo de aprendizaje de máquina a utilizarse en el procesamiento de los datos se recomienda utilizar las técnicas de redes neuronales, dada la gran utilización y documentación que existe acerca de estas técnicas, así como su posibilidad de implementación mediante el software de procesamiento de datos. Sin embargo, es posible utilizar otras técnicas como *Support Vector Machine* o K-NN, dado que obtuvieron resultados favorables en el estudio del sueño, sin embargo, cabe mencionar que la elección de la técnica dependerá de la facilidad de implementarla y de los resultados obtenidos en cada una de ellas para el conjunto de datos que se obtenga, lo cual se debe tener en cuenta.

Es importante que los campos que se rellenen por parte del usuario sean validados en la aplicación, en caso de número de horas se recomienda restringir que los valores ingresados sean únicamente numéricos, a más de validar que los datos tengan concordancia con las preguntas que se realice para la recolección de datos mediante encuestas.

Otro parámetro a tener en cuenta es que debido a que se trabajará con datos sensibles de los estudiantes, en adición con la presencia de leyes de protección de datos, es necesario que se anonimice los datos mediante un código que identifique a una persona y que se incluya un formulario de consentimiento que deberá aceptar el usuario, en el cual se debe especificar el uso que se le dará a los datos e incluir que el tratamiento de los datos se enfocará en usos académicos.

Finalmente, se sugiere que desde la aplicación se muestre un mensaje de retroalimentación en el caso de que las horas de sueño detectadas estén debajo del umbral definido según la edad de la persona en la **Tabla 1.1**, con el fin de poder informarle al usuario que debería dormir más, cumplir con su horario de sueño y así mejorar la calidad de vida, lo que ayudará a mejorar su rendimiento académico.

3.1.2 Factores que deben ser considerados para la realización del estudio de prueba

Considerando que el ámbito donde se enfocó este estudio es el análisis de la relación del sueño con el rendimiento académico en estudiantes universitarios, se propone que los escenarios de prueba se basen en distintos cursos, semestres y materias, con el fin de poder obtener diversidad de resultados. Además, se recomienda que se realice un estudio preliminar con un conjunto de participantes de distintos géneros, edades, con el fin de obtener un grupo lo más heterogéneo posible, con la única condición de que cuenten con la posibilidad de obtener su información académica

Se debería también realizar pruebas en ambientes controlados antes de enviar la aplicación a producción, tomando como punto de partida el inicio del semestre, así poder analizar los resultados durante al menos un semestre académico. Finalmente, se deberían realizar pruebas de los roles mencionados anteriormente, con el fin de validar el alcance de cada tipo de usuario, es decir, que el usuario que recopila la información solo tenga acceso a sus propios datos, mientras que el usuario administrador pueda visualizar la lista de usuarios como se mostró en las pantallas de la aplicación planteadas en la sección 2.7.

Además, se recomienda generar la aplicación con el fin de que pueda ser accedida desde múltiples plataformas, dado que según [93] a finales del 2022 el 70% de los usuarios a nivel mundial utilizaba Android como sistema operativo para su dispositivo móvil, mientras que el 28% utilizaba iOS, porcentaje a tomarse en cuenta en caso de enfocar la aplicación a un mayor número de potenciales usuarios.

Otro punto importante para tomar en cuenta es conocer las fechas durante las cuales se finaliza o inicia un periodo o bimestre, con el fin de poder mostrarle un mensaje al usuario que sirva como recordatorio de llenado de las encuestas en caso de que no lo haya realizado.

3.1.3 Alternativas para recolección de datos

En adición a las alternativas planteadas con el uso de un dispositivo móvil en la Sección 2, se recomienda que se incluyan sensores de tipo médico, como sensores de ECG para la medición de señales de pulso cardiaco. También se podría incluir una cámara con alta sensibilidad, con el fin de obtener resultados del movimiento de una persona durante el proceso de sueño. Otra alternativa interesante que se incluye en [63] es la utilización de un sensor que permita recopilar información del movimiento del diafragma de la persona en el estudio para determinar si se encuentra en un ciclo de sueño.

Otras alternativas planteadas, se basan en la inclusión de diversos dispositivos que han tomado fuerza en la actualidad como lo son los distintos *wearables*, los cuales cuentan en su mayoría con distintos sensores con rendimiento similar a los sensores médicos, que permitirán obtener resultados más precisos. Finalmente, se recomienda contrastar los resultados obtenidos en la aplicación con los que se pueden obtener por las librerías existentes en el análisis del sueño como lo es la API de Google llamada *Sleep API*, o en contraparte con las demás aplicaciones desarrolladas disponibles en las tiendas de aplicaciones de Android y iOS.

3.2 Conclusiones

Durante el presente trabajo de integración curricular se recopiló información referente al estudio del sueño mediante distintas técnicas y enfoques, se pudo notar que las soluciones que proponían la utilización de sensores intrusivos de tipo médico obtenían resultados más precisos dado que analizaban las variaciones en los picos del ritmo cardiaco; sin embargo, estas soluciones se ven limitadas por la dificultad de implementarse, producto del tipo de sensor utilizado.

Utilizar sensores ambientales o no intrusivos tienen como principal ventaja la facilidad de implementarlas en diferentes ambientes de prueba, así como la suplantación de estos sensores por los existentes en un dispositivo móvil, presente en una gran cantidad de personas a nivel mundial y más aún en estudiantes universitarios, lo cual facilita la creación de una aplicación que permita la recopilación de información, procesamiento de datos y finalmente la retroalimentación entregada al usuario final.

Incluir encuestas que se implementen en la aplicación permitirá obtener datos de refuerzo que posibiliten ser comparados mediante el aprendizaje de máquina.

Trasladar los datos obtenidos de tipo cualitativo en relación con la calidad de sueño a una escala numérica, será de gran ayuda al momento de realizar el pre procesamiento de datos, tomando en cuenta que estos datos representarán la opinión subjetiva de la persona.

Por otro lado, la elección de la encuesta a utilizar es de suma importancia a fin de obtener un conjunto de datos específico, dado que se enfocan a un público específico como se pudo notar en el caso de la **Tabla 2.3**, en la cual se puede observar que algunas encuestas se enfocan en el análisis de calidad de sueño y otros en la detección de trastornos de sueño.

Utilizar los resultados del estudio con el fin de realimentar la planificación de clases y su respectiva carga horaria de los estudiantes universitarios resulta de suma importancia con el fin de que puedan mejorar la calidad de sueño de los estudiantes y por ende el rendimiento académico obtenido durante la vida universitaria. Además de poder modificar parámetros del ámbito donde se desarrolla el ciclo del sueño de la persona como el aroma, música, temperatura o luminosidad con el fin de obtener un periodo de sueño óptimo.

La importancia de monitorear el sueño se convierte en una herramienta muy útil en la detección temprana de problemas médicos que pueden ser identificados en alteraciones en el comportamiento normal del ciclo de sueño de una persona, o en la aparición de trastornos de sueño como la apnea obstructiva, es decir, enfocar este estudio en temas de bienestar de la persona con el fin de mejorar la calidad de vida.

3.3 Recomendaciones

La elección del algoritmo de aprendizaje de máquina para inferir en los resultados va a depender en gran medida del tipo de datos que se recopile, producto del tipo de sensores y parámetros elegidos para la realización del estudio, por lo tanto, se recomienda que se realice pruebas del rendimiento obtenido por cada técnica a fin de obtener óptimos resultados.

Se recomienda que la persona objetivo en la cual se implemente el estudio mantenga el dispositivo móvil cercano al momento de realizar su ciclo de sueño, a más de verificar si esta persona se encuentra matriculada en un periodo académico durante la realización del estudio.

Contrastar los resultados obtenidos en la aplicación con las soluciones existentes tanto librerías de análisis de sueño relacionadas al uso del dispositivo, así como los resultados obtenidos por los *wearables*.

Se recomienda que el escenario de prueba de la aplicación sea de al menos 1 semestre académico, con el fin de obtener resultados que puedan ser comparables con el rendimiento de los estudiantes en un periodo.

Tener en cuenta la base de calificaciones utilizada por la institución donde se encuentra realizando su proceso académico el estudiante, con el fin de poder normalizar las calificaciones y procesar los datos de la manera más eficiente posible.

4. REFERENCIAS BIBLIOGRÁFICAS

- [1] S. Narasimha, S. Raju, (2020, October 9). An Empirical Study on System Level Aspects of Internet of Things (IoT) [Online]. Available: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9218916>. (Accessed Nov. 14, 2022).
- [2] B. Rathakrishna, S. Bikar, MR. Kamaluddin, A. Yahaya, MA. Mohd, F. Ibrahim, Z. Rahman, “Smartphone Addiction and Sleep Quality on Academic Performance of University Students: An Exploratory Research”, *Int J Environ Res Public Health*, vol. 18, no. 16, August 2021. Doi: <https://doi.org/10.3390/ijerph18168291>. (Accessed Nov. 14, 2022).
- [3] P. Gargantilla, N. Arroyo, E. Pintor, “Arritmias en la distrofia miotónica de Steinert”, *Rev Clín Med Fam*, vol. 8, no. 3, pp. 265–265, October 2015. Doi: 10.4321/s1699-695x2015000300014. (Accessed Nov. 14, 2022).
- [4] S. García, B. Navarro, (2017, Octubre). Higiene del sueño en estudiantes universitarios: conocimientos y hábitos. Revisión de la Bibliografía [Online]. ISSN 2386-8201. (Accessed Nov. 15, 2022).
- [5] M. Suardiaz, M. Morante, M. Ortega, MA. Ruiz, P. Martín, A. Vela-Bueno. [Sleep and academic performance in university students: a systematic review], *Rev Neurol*, vol.71, no. 2, pp.43-53, July 2020. Doi: 10.33588/rn.7102.2020015. PMID: 32627159. (Accessed Nov. 17, 2022).
- [6] Y. Perdomo. “Clasificación de las fases y la calidad del sueño en señales de electroencefalografía (EEG)”. Maestría en Ingeniería Electrónica. Facultad de Ingeniería, Pontificia Universidad Javeriana, Bogotá, Colombia, 2017. [Online]. <https://repository.javeriana.edu.co/handle/10554/34058>. (Accessed Nov. 15, 2022).
- [7] L. Fabres, P. Moya. “Sueño: conceptos generales y su relación con la calidad de vida”, *Rev Méd Clín Las Condes*, vol. 32, no. 5, pp. 527-534, Septiembre 2021. Doi: 10.1016/J.RMCLC.2021.09.001. (Accessed Nov. 21, 2022).
- [8] M. Duque, (2022, Abril 9). An Empirical Study on System Level Aspects of Internet of Things (IoT) [Online]. Available: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9218916>. (Accessed Nov. 19, 2022).[9] M. Hirshkowitz et al., “National Sleep Foundation’s updated sleep duration recommendations: final report,” *Sleep Health*, vol. 1, no. 4, pp. 233–243, December. 2015, doi: 10.1016/J.SLEH.2015.10.004. (Accessed Nov. 14, 2022).
- [10] G. Garbanzo, “Factores asociados al rendimiento académico en estudiantes universitarios, una reflexión desde la calidad de la educación superior pública”, *Revista Educación*, vol. 31, no 1, pp.43-63, 2007. ISSN: 0379-7082, 2007. (Accessed Nov. 16, 2022).
- [11] B. Sharma (2023, January 5). Difference Between GPA & CGPA with Definition & Importance [Online]. Available: <https://www.upgradabroad.com/articles/difference-between-gpa-and-cgpa/>. (Accessed Nov. 20, 2022).

- [12] G. Devincenzi, G. Rohde, M. Bonaffini, M. Giraudo, A. Piccini, "Determinación de un índice de rendimiento académico general para medir el riesgo de deserción universitaria", *Revista de la Facultad de Ciencias Económicas*, no. 20, pp. 109–121, Octubre 2018, doi: <http://dx.doi.org/10.30972/rfce.0203257>. (Accessed Nov. 17, 2022).
- [13] E. Chong, "Factores que inciden en el rendimiento académico de los estudiantes de la Universidad Politécnica del Valle de Toluca", *Revista Latinoamericana de Estudios Educativos* (México, vol. 47, no. 1, pp. 91-108, 2017. Available: <https://www.redalyc.org/journal/270/27050422005/html/>. (Accessed Nov. 17, 2022).
- [14] L. Torres, N. Rodríguez, "Rendimiento académico y contexto familiar en estudiantes universitarios", *Enseñanza e Investigación en Psicología*, vol. 11, no. 2, pp. 255-270, Julio-Diciembre 2006, ISSN: 0185-1594.
- [15] R. Oré, "Comprensión lectora, hábitos de estudio y rendimiento académico en estudiantes de primer año de una universidad privada de Lima Metropolitana". *Maestría en Psicología con mención en Psicología Educativa*. Facultad de Psicología, Universidad Nacional Mayor de San Marcos, Lima. Perú, 2012. [Online]. Available: <https://core.ac.uk/download/pdf/323350327.pdf>. (Accessed Nov. 14, 2022).
- [16] M. Jayawardhana, P. De Chazal, "Enhanced detection of sleep apnoea using heart-rate, respiration effort and oxygen saturation derived from a photoplethysmography sensor", *Annu Int Conf IEEE Eng Med Biol Soc*, pp. 121-124, July 2017. Doi: 10.1109/EMBC.2017.8036777. (Accessed Nov. 14, 2022).
- [17] E. Cohen, United Nations, y Organization of American States, Eds., *Educación, eficiencia y equidad*. Santiago, Chile: CEPAL/OEA/SUR, 1996.
- [18] Chadwick (1979). "Relación entre el rendimiento académico y Marco Teórico." [Online]. Available: https://sisbib.unmsm.edu.pe/bibvirtual/tesis/salud/reyes_t_y/cap2.htm (accessed Nov. 15, 2022).
- [19] W. Meneses, S. Morillo, G. Navia, M. Grisales "Factores que afectan el rendimiento escolar en la institución educativa rural Las mercedes desde la perspectiva de los actores institucionales", *Dialnet*, vol. 11, no. 1, pp. 433-452, 2013, ISSN-e 1657-4672. (Accessed Nov. 15, 2022).
- [20] G. Borja, J. Martínez, S. Barreno, O, Haro, (2021, Octubre 25). Factores asociados al rendimiento académico: Un estudio de caso [Online]. Available: <http://portal.amelica.org/ameli/jatsRepo/375/3752842004/index.html>. (Accessed Nov. 14, 2022).
- [21] R. Ramirez-Vazquez, I. Escobar, A. Beléndez, y E. Arribas, «Factores que afectan el Rendimiento Académico», *Revista REAMEC*, vol. 8, n.º 3, pp. 210-226, sep. 2020, doi: 10.26571/reamec.v8i3.10842. (Accessed Nov. 15, 2022).
- [22] M. Suhrcke, C. De Paz, *The impact of health and health behaviours on educational outcomes in high-income countries: a review of the evidence*. Copenhagen, WHO Regional Office for Europe. 2011.

- [23] J. Plúa- Baque, R. Vera- Zavala, S. Gutiérrez- Regalado, C. Aguilar- Cano, “Actividades Extracurriculares y su incidencia en el aprendizaje significativo”, *Polo del Conocimiento*, vol. 7, n.º 9, pp. 555-570, Septiembre 2022, ISSN: 2550-682X. (Accessed Nov. 15, 2022).
- [24] A. Murillo, L. Rangel, G. Pulido, “Rendimiento académico y tiempo de lectura en estudiantes universitarios de cultura física, deporte y recreación”, *Rev Cub de Investigaciones Biomédicas*, 2021. Available: <http://www.revibiomedica.sld.cu/index.php/ibi/article/view/971/1095>. (Accessed Nov. 15, 2022).
- [25] A. Garzón, J. Gil, “Gestión del tiempo en alumnado universitario con diferentes niveles de rendimiento académico”, *SciELO*, 2018, Doi: <https://doi.org/10.1590/S1678-4634201708157900>. (Accessed Nov. 15, 2022).
- [26] S.M. Shimly, S. Movassaghi, D.B. Smith, “Cooperative communications for sleep monitoring in wireless body area networks”, *Biomedical technology*, vol. 52, no. 8, pp. 594-596, Doi: <https://doi.org/10.1049/el.2015.3008>. (Accessed Nov. 15, 2022).
- [27] S. Milici, A. Lázaro, R. Villarino, D. Girbau, M. Magnarosa, "Wireless Wearable Magnetometer-Based Sensor for Sleep Quality Monitoring", *IEEE Sensors Journal*, vol. 18, no. 5, pp. 2145-2152, 1 March 2018, doi: 10.1109/JSEN.2018.2791400. (Accessed Nov. 22, 2022).
- [28] I. Khokhlov, L. Reznik and S. Ajmera, "Sensors in Mobile Devices Knowledge Base", *IEEE Sensors Letters*, vol. 4, no. 3, pp. 1-4, March 2020, Doi: 10.1109/LSSENS.2020.2975161. (Accessed Nov. 17, 2022).
- [29] H. Bulbul, Ö. Unsal, "Comparison of Classification Techniques used in Machine Learning as Applied on Vocational Guidance Data", *10th International Conference on Machine Learning and Applications and Workshops*, Honolulu, HI, USA, 2011, pp. 298-301, Doi: 10.1109/ICMLA.2011.49. (Accessed Nov. 17, 2022).
- [30] W. Chango, R. Cerezo, C. Romero, “Predicting academic performance of university students from multi-sources data in blended learning”, *Proceedings of the Second International Conference on Data Science, E-Learning and Information Systems (DATA '19)*, Association for Computing Machinery, New York, NY, USA. Doi: <https://doi.org/10.1145/3368691.3368694>. (Accessed Nov. 18, 2022).
- [31] M. Hammad, M. Shahzad, N. Shafi, R. Maqsood, A. Azam, M. Ahmad, "Predicting the Impact of Academic Key Factors and Spatial Behaviors on Students' Performance", *Applied Sciences*, vol. 12, no. 19, October 2022, Doi: <https://doi.org/10.3390/app121910112>. (Accessed Nov. 17, 2022).
- [32] L.Von Rueden, S. Mayer, K. Beckh, B. Georgiev, S. Giesselbach, R. Heese , B. Kirsch , J. Pfrommer , A. Pick , R. Ramamurthy , M. Walczak , J. Garcke , C. Bauckhage , J. Schuecker, “Informed Machine Learning – A Taxonomy and Survey of Integrating Prior Knowledge into Learning Systems”, *IEEE Transactions on knowledge and data engineering*, vol. 35, no. 1, January 2023, Doi: 10.1109/TKDE.2021.3079836. (Accessed Nov. 22, 2022).
- [33] J. Rodrigues, J-L. Pepin, L. Goeriot, S. Amer-Yahia, “An Extensive Investigation of Machine Learning Techniques for Sleep Apnea Screening”, In *Proceedings of the 29th ACM International Conference on Information & Knowledge Management (CIKM '20)*.

- Association for Computing Machinery, New York, USA, October 2020, pp. 2709–2716. Doi: <https://doi.org/10.1145/3340531.3412686>. (Accessed Nov. 23, 2022).
- [34] A. Godoy, “Técnicas de aprendizaje de máquina utilizadas para la minería de texto”, Scielo, vol. 31, no. 71, pp.103-126, 2017, Doi: <https://doi.org/10.22201/iibi.0187358xp.2017.71.57812>. (Accessed Nov. 23, 2022).
- [35] S. Kristiansen, K. Nikolaidis, T. Plagemann, V. Goebel, G. Marit, B. Øverland, L. Aakerøy, T-E. Hunt, J. Pål, S. Loe, C. Holt, O-G. Anfinsen, L. Gullestad, H. Akre, “Machine Learning for Sleep Apnea Detection with Unattended Sleep Monitoring at Home”, *ACM Trans. Comput. Healthcare*, vol. 2, no. 2, April 2021, pp. 1-25, Doi: <https://doi.org/10.1145/3433987>. (Accessed Nov. 23, 2022).
- [36] D. Sharma, N. Kumar, (2017, October). A Review on Machine Learning Algorithms, Tasks and Applications [Online]. Available: <https://www.researchgate.net/publication/320609700>. (Accessed Nov. 14, 2022).
- [37] K. Aboalayon, W. Almuhammadi, M. Faezipour, "A comparison of different machine learning algorithms using single channel EEG signal for classifying human sleep stages", Long Island Systems, Applications and Technology, Farmingdale, NY, USA, 2015, pp. 1-6, Doi: 10.1109/LISAT.2015.7160185. (Accessed Nov. 18, 2022).
- [38] A. Ramachandran, A. Karuppiyah. "A Survey on Recent Advances in Machine Learning Based Sleep Apnea Detection Systems", *Healthcare*, vol. 9, no. 7, pp. 914, July 2021, Doi: <https://doi.org/10.3390/healthcare9070914>. (Accessed Nov. 18, 2022).
- [39] R. M. Miranda, “Redes Neuronales Artificiales”, Accessed: Feb. 17, 2023. [Online]. Available: https://www.academia.edu/29894308/Redes_Neuronales_Artificiales.
- [40] U. Erdenebayar, YJ. Kim, JU. Park, EY. Joo, KJ. Lee, “Deep learning approaches for automatic detection of sleep apnea events from an electrocardiogram”, *Comput Methods Programs Biomed*, October 2019. Doi: 10.1016/j.cmpb.2019.105001. (Accessed Nov. 20, 2022).
- [41] L. Kunyang, P. Weifeng, L. Yifan, J. Qing, L. Guanzheng, “A method to detect sleep apnea based on deep neural network and hidden Markov model using single-lead ECG signal”, *Neurocomputing*, vol. 294, no. 14, pp. 94-101, June 2018. Doi: <https://doi.org/10.1016/j.neucom.2018.03.011>. (Accessed Nov. 22, 2022).
- [42] T. Wang, C. Lu, S. Guohao, “Detection of Sleep Apnea from Single-Lead ECG Signal Using a Time Window Artificial Neural Network”, *Biomed Res Int*, 2019. Doi: 10.1155/2019/9768072. (Accessed Nov. 24, 2022).
- [43] P. De Chazal, N. Sadr, “Sleep apnoea classification using heart rate variability, ECG derived respiration and cardiopulmonary coupling parameters”, *Annu Int Conf IEEE Eng Med Biol Soc*, August 2016, pp. 3203-3206. Doi: 10.1109/EMBC.2016.7591410. (Accessed Nov. 25, 2022).
- [44] D. Novák, K. Mucha, T. Al-Ani, “Long short-term memory for apnea detection based on Heart Rate Variability”, *Annu Int Conf IEEE Eng Med Biol Soc*, 2008. Doi: 10.1109/IEMBS.2008.4650394. (Accessed Nov. 26, 2022).

- [45] B. Yilmaz, MH. Asyali, E. Arıkan, S. Yetkin, F. Ozgen, (2010, August). Sleep stage and obstructive apneic epoch classification using single-lead ECG [Online]. Doi: 10.1186/1475-925X-9-39. (Accessed Nov. 27, 2022).
- [46] A. Hassan, "A comparative study of various classifiers for automated sleep apnea screening based on single-lead electrocardiogram", in International Conference on Electrical & Electronic Engineering (ICEEE), 2015, pp. 45-48.
- [47] J. Zhang, Q. Zhang, Y. Wang, C. Qiu, "A real-time auto-adjustable smart pillow system for sleep apnea detection and treatment", in Proceedings of the 12th international conference on Information processing in sensor networks (IPSN '13). Association for Computing Machinery, New York, NY, USA, pp. 179–190. Doi: <https://doi.org/10.1145/2461381.2461405>. (Accessed Nov. 30, 2022).
- [48] A. Prabha, A. Trivedi, A. Anand, C. Santhosh, "Automated system for obstructive sleep apnea detection using heart rate variability and respiratory rate variability", in International Conference on Advances in Computing, Communications and Informatics, Near Mangalore, India, September 13-16, 2017, pp. 1303-1307. Doi: 10.1109/ICACCI.2017.8126021. (Accessed Nov. 30, 2022).
- [49] A. Rashik, M. Aynal, (2016, April). Computer-aided obstructive sleep apnea identification using statistical features in the EMD domain and extreme learning machine [Online]. Doi: 10.1088/2057-1976/2/3/035003. (Accessed Nov. 27, 2022).
- [50] G. Memis, M. Sert, "Multimodal Classification of Obstructive Sleep Apnea Using Feature Level Fusion", IEEE 11th International Conference on Semantic Computing (ICSC), 2017, pp. 85-88. Doi: 10.1109/ICSC.2017.87. (Accessed Nov. 29, 2022).
- [51] B. Xie, H. Minn, "Real-time sleep apnea detection by classifier combination", IEEE Trans Inf Technol Biomed, vol. 16, no. 3, pp. 469-477, May 2012. Doi: 10.1109/TITB.2012.2188299. (Accessed Nov. 17, 2022).
- [52] R. Pathinarupothi, D. Prathap, E. Srihai, E. Gopalakrishnan, R. Vinaykumar, K. Soma, "Single Sensor Techniques for Sleep Apnea Diagnosis Using Deep Learning", in IEEE International Conference on Healthcare Informatics (ICHI), Park City, UT, USA, 2017, pp. 524-529, Doi: 10.1109/ICHI.2017.37. (Accessed Nov. 17, 2022).
- [53] S. Mostafa, F. Mendonça, F. Morgado, A. Ravelo, "SpO2 based sleep apnea detection using deep learning", in IEEE 21st International Conference on Intelligent Engineering Systems (INES), 2017, Doi: 10.1109/INES.2017.8118534. (Accessed Dec. 1, 2022).
- [54] A. Khandoker, M. Palaniswami, C. Karmakar, "Support vector machines for automated recognition of obstructive sleep apnea syndrome from ECG recordings", IEEE Trans Inf Technol Biomed, vol. 13, no.1, pp. 37-48, January 2009. Doi: 10.1109/TITB.2008.2004495. (Accessed Dec. 1, 2022).
- [55] M. Jayawardhana, P. De Chazal, "Enhanced detection of sleep apnoea using heart-rate, respiration effort and oxygen saturation derived from a photoplethysmography sensor", Annu Int Conf IEEE Eng Med Biol Soc, 121-124, July 2017. Doi: 10.1109/EMBC.2017.8036777. (Accessed Dec. 2, 2022).

- [56] K. Ivanko, N. Ivanushkina, A. Rykhalska, "Identifying episodes of sleep apnea in ECG by machine learning methods", in IEEE 40th International Conference on Electronics and Nanotechnology (ELNANO), Kyiv, Ukraine, 2020, pp. 588-593, Doi: 10.1109/ELNANO50318.2020.9088749. (Accessed Dec. 2, 2022).
- [57] J. Yeong, K. Hoand, S. Ju- Kang, "Real-Time Sleep Apnea Diagnosis Method Using Wearable Device without External Sensors", in IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops), 2020, pp. 1-5. Doi: <https://doi.org/10.1109/percomworkshops48775.2020.9156119>. (Accessed Dec. 2, 2022).
- [58] R. Sharan, S. Berkovsky, H. Xiong, E. Coiera, "ECG-Derived Heart Rate Variability Interpolation and 1-D Convolutional Neural Networks for Detecting Sleep Apnea", Annu Int Conf IEEE Eng Med Biol Soc, July 2020, pp. 637-640. Doi: 10.1109/EMBC44109.2020.9175998. (Accessed Dec. 2, 2022).
- [59] R. Haidar, I. Koprinska, B. Jeffries, "Sleep Apnea Event Prediction Using Convolutional Neural Networks and Markov Chains", International Joint Conference on Neural Networks (IJCNN), July 2020, pp. 1-8. Doi: <https://doi.org/10.1109/IJCNN48605.2020.9207345>. (Accessed Nov. 22, 2022).
- [60] M. Deviaene, P. Borzée, B. Buyse, D. Testelmans, S. Van- Huffel, C. Varon, "Pulse Oximetry Markers for Cardiovascular Disease in Sleep Apnea", in Computing in Cardiology (CinC), Singapore, September 2019, pp. 1-4. Doi: 10.22489/CinC.2019.205. (Accessed Dec. 3, 2022).
- [61] B. Xia, L. Qianyun, J. Jia, J. Wang, U. Chaudhary, A. Ramos, N. Birbaumer, "Electrooculogram based sleep stage classification using deep belief network", in Proceedings of the International Joint Conference on Neural Networks, Institute of Electrical and Electronics Engineers Inc, September 2015. ISBN: 9781479919604.
- [62] R. Pathinarupothi, R. Vinaykumar, E. Rangan, E. Gopalakrishnan, K. Soman, "Instantaneous heart rate as a robust feature for sleep apnea severity detection using deep learning", IEEE EMBS International Conference on Biomedical & Health Informatics, 2017, pp. 293-296. Doi: <https://doi.org/10.1109/BHI.2017.7897263>. (Accessed Dec. 2, 2022).
- [63] M. Hafezi, N. Montazeri, S. Saha, K. Zhu, B. Gavrilovic, A. Yadollahi, B. Taati, "Sleep Apnea Severity Estimation from Tracheal Movements Using a Deep Learning Model," in IEEE Access, vol. 8, pp. 22641-22649, 2020, Doi: 10.1109/ACCESS.2020.2969227. (Accessed Dec. 2, 2022).
- [64] S. Islam, H. Mahmood, A. Al-Jumaily, S. Claxton, "Deep Learning of Facial Depth Maps for Obstructive Sleep Apnea Prediction", in International Conference on Machine Learning and Data Engineering (iCMLDE), Sydney, NSW, Australia, 2018, pp. 154-157, Doi: 10.1109/iCMLDE.2018.00036. (Accessed Dec. 1, 2022).
- [65] C. Wang, J. Chan, S. Fang, H. Cheng, Y. Hsu, "Novel Sleep Apnea Detection Based on UWB Artificial Intelligence Mattress", in IEEE International Conference on Artificial Intelligence Circuits and Systems (AICAS), Hsinchu, Taiwan, 2019, pp. 158-159, Doi: 10.1109/AICAS.2019.8771598. (Accessed Dec. 1, 2022).

- [66] B. Camcı, A. Kahveci, B. Arnrich, C. Ersoy, "Sleep apnea detection via smart phones", in 25th Signal Processing and Communications Applications Conference (SIU), Antalya, Turkey, 2017, pp. 1-4, Doi: 10.1109/SIU.2017.7960484. (Accessed Dec. 3, 2022).
- [67] T. Kim, J.W. Kim, K. Lee, (February, 2018). Detection of sleep disordered breathing severity using acoustic biomarker and machine learning techniques [Online]. Doi: <https://doi.org/10.1186/s12938-018-0448-x>. (Accessed Nov. 27, 2022).
- [68] L. Payongkit, A. Dittthapron, N. Banluesombatkul, T. Wilaiprasitporn, (August, 2018). Deep Neural Networks with Weighted Averaged Overnight Airflow Features for Sleep Apnea-Hypopnea Severity Classification [Online]. Doi: <https://doi.org/10.48550/arXiv.1808.10845>. (Accessed Nov. 27, 2022).
- [69] C. Avci and A. Akbaş, "Sleep apnea classification based on respiration signals by using ensemble methods," BME, vol. 26, no. s1, pp. S1703–S1710, Aug. 2015, doi: 10.3233/BME-151470.
- [70] G. Ozdemir, H. Nasifoglu, O. Erođul, "A Time-Series Approach to Predict Obstructive Sleep Apnea (OSA) Episodes", July 2016. Doi: 10.11159/ICBES16.117. (Accessed Nov. 28 2022).
- [71] A. Cafer, A. Ahmet, "Sleep Apnea Classification Based on Respiration Signals by Using Ensemble Methods", Bio-Medical Materials and Engineering, vol. 26, no. 1, January 2015. Doi: 10.3233/BME-151470. (Accessed Dec. 27, 2022).
- [72] H. Azimi, P. Xi, M. Bouchard, R. Goubran, F. Knoefel, "Machine Learning-Based Automatic Detection of Central Sleep Apnea Events from a Pressure Sensitive Mat", in IEEE Access, vol. 8, pp. 173428-173439, 2020, Doi: 10.1109/ACCESS.2020.3025808. (Accessed Jan. 3, 2023).
- [73] A. Petrenko, "Breathmonitor: Sleep Apnea Mobile Detector", in IEEE 2nd International Conference on System Analysis & Intelligent Computing (SAIC), Kyiv, Ukraine, 2020, pp. 1-4. Doi: 10.1109/SAIC51296.2020.9239236. (Accessed Dec. 22, 2022).
- [74] M. Botelho, I. Trancoso, A. Abad, T. Paiva, "Speech as a Biomarker for Obstructive Sleep Apnea Detection", IEEE Signal Processing Society SigPort, 2019. [Online]. Available: <https://sigport.org/documents/speech-biomarker-obstructive-sleep-apnea-detection>. (Accessed: Feb. 17, 2023).
- [75] Y-Zeng. Hsieh, "Internet of Things Pillow Detecting Sleeping Quality", in 1st International Cognitive Cities Conference (IC3), Okinawa, Japan, 2018, pp. 266-267. Doi: 10.1109/IC3.2018.000-3. (Accessed Dec. 22, 2022).
- [76] H. Miwa, S. Sasahara, T. Matsui, "Roll-over Detection and Sleep Quality Measurement using a Wearable Sensor", in 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Lyon, France, 2007, pp. 1507-1510. Doi: 10.1109/IEMBS.2007.4352587. (Accessed Jan. 12, 2023).
- [77] D. J. Choi, M. S. Choi, and S. J. Kang, "A wearable device platform for the estimation of sleep quality using simultaneously motion tracking and pulse oximetry," in 2016 IEEE International Conference on Consumer Electronics (ICCE), Jan. 2016, pp. 49–50. Doi: 10.1109/ICCE.2016.7430518.

- [78] E. Dafna, A. Tarasiuk, and Y. Zigel, "Sleep-quality assessment from full night audio recordings of sleep apnea patients," in 2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Aug. 2012, pp. 3660–3663. Doi: 10.1109/EMBC.2012.6346760.
- [79] Y. Ren, C. Wang, J. Yang, and Y. Chen, "Fine-grained sleep monitoring: Hearing your breathing with smartphones," in 2015 IEEE Conference on Computer Communications (INFOCOM), Apr. 2015, pp. 1194–1202. Doi: 10.1109/INFOCOM.2015.7218494.
- [80] B. Amra, B. Rahmati, F. Soltaninejad, and A. Feizi, "Screening Questionnaires for Obstructive Sleep Apnea: An Updated Systematic Review," *Oman Med J*, vol. 33, no. 3, p. 184, May 2018, doi: 10.5001/OMJ.2018.36.
- [81] M. Á. Iáñez, E. Miró, A. Catena, and G. Buéla-Casal, "Calidad de sueño en sujetos con diferentes patrones habituales de sueño," *Psicología y Salud*, vol. 13, no. 2, Art. no. 2, 2003, Doi: 10.25009/pys.v13i2.891.
- [82] Z. Veqar, J. A. Moiz, and M. E. Hussain, "Psychometric Analysis of the Pittsburgh Insomnia Rating Scale among University Population of Poor Sleepers in India," *N Am J Med Sci*, vol. 6, no. 4, p. 161, 2014, Doi: 10.4103/1947-2714.131238.
- [83] H. Y. Chiu et al., "Diagnostic accuracy of the Berlin questionnaire, STOP-BANG, STOP, and Epworth sleepiness scale in detecting obstructive sleep apnea: A bivariate meta-analysis," *Sleep Med Rev*, vol. 36, pp. 57–70, Dec. 2017, Doi: 10.1016/J.SMRV.2016.10.004.
- [84] J. Guo, W. Huang, C. Y. Tang, G. L. Wang, F. Zhang, and L. P. Wang, "Effect of acupuncture on sleep quality and hyperarousal state in patients with primary insomnia: study protocol for a randomized controlled trial," *BMJ Open*, vol. 6, no. 3, 2016, Doi: 10.1136/BMJOPEN-2015-009594.
- [85] K. Schroeder and J. R. Gurenlian, "Recognizing Poor Sleep Quality Factors During Oral Health Evaluations," *Clin Med Res*, vol. 17, no. 1–2, p. 20, Jun. 2019, Doi: 10.3121/CMR.2019.1465.
- [86] J. I. Jiménez León and J. J. Martínez Vera, "Análisis comparativo entre modelos de Machine Learning para la predicción de fallo en áreas axiales de un recipiente toroidal de sección recta circular para el almacenamiento de GNC," bachelor Thesis, Universidad de Guayaquil. Facultad de Ciencias Matemáticas y Físicas. Carrera de Ingeniería en Sistemas Computacionales., 2021. Accessed: (Jan. 03, 2023). [Online]. Available: <http://repositorio.ug.edu.ec/handle/redug/56968>
- [87] D. A. Pabón Correa. Aprendizaje utilizando Support Vector Machines distribuidos basados en consenso. Universidad de los Andes, 2018, Accessed: (Jan. 07, 2023). [Online]. Available en: <https://repositorio.uniandes.edu.co/handle/1992/39056>
- [88] E. A. Galindo, J. A. Perdomo, and J. C. Figueroa-García, "Estudio comparativo entre máquinas de soporte vectorial multiclase, redes neuronales y sistema de inferencia neuro-difuso auto organizado para problemas de clasificación," *Publicado Información Tecnológica*, vol. 31, no. 1, pp. 273–286, 2020, Doi: 10.4067/S0718-07642020000100273.
- [89] Á. F. Godoy Viera. Técnicas de aprendizaje de máquina utilizadas para la minería de texto. *IB*, vol. 31, n.o 71, p. 103, mar. 2017, Doi: 10.22201/iibi.0187358xp.2017.71.57812.

- [90] A. Rivero Castro, L. M. Cruz Correa, J. Artiles Lezcano. Selección de un algoritmo para la clasificación de Nódulos Pulmonares Solitarios», *Revista Cubana de Informática Médica*. vol. 8, n.º 2, pp. 166-177, dic. 2016.
- [91] M. B. Uddin, C. M. Chow, S. W. Su. Classification methods to detect sleep apnea in adults based on respiratory and oximetry signals: a systematic review. *Physiol Meas*, vol. 39, n.º 3, p. 03TR01, mar. 2018, doi: 10.1088/1361-6579/aaafb8 (accessed Nov. 10, 2022).
- [92] University of Waikato. Weka 3 - Data Mining with Open Source Machine Learning Software in Java. [Online] <https://www.cs.waikato.ac.nz/ml/weka/> (Accessed Jan. 20, 2023).
- [93] B. Szczygieł. (2022, Dec 13). iPhone vs Android Users: Key Differences. Netguru [Online] Available <https://www.netguru.com/blog/iphone-vs-android-users-differences> (Accessed: Jan. 10, 2023).

5. ANEXOS

Anexo I. Tablero *kanban*

ANEXO I.1 Tablero *kanban* semana 1

The Kanban board is organized into five columns: 'No iniciado', 'En curso', and 'Completada'. Each column contains task cards with the following details:

- Column 1 (No iniciado):**
 - Card 1: **Busqueda Informac...**, **Busqueda de 10 referencias Bibliográficas respecto al tema.**, **Pendiente**, **20/07**.
 - Card 2: **Busqueda Informac...**, **Estudiar los sensores disponibles en los teléfonos móviles que permitan obtener información para inferir la calidad sueño.**, **Pendiente**, **Resumen de la investigación realizada.**
 - Card 3: **Busqueda Informac...**, **Estudio de factores que influyen en el rendimiento académico de los estudiantes**, **Pendiente**, **Resumen de los factores encontrados.**, **27/07**.
 - Card 4: **Planificación**, **Diseño de modelo de metodología Kanban para cumplimiento de objetivos.**, **Pendiente**.
- Column 2 (No iniciado):**
 - Card 1: **Análisis**, **Comparar los parámetros que se utilizan en trabajos relacionados con la detección del sueño en una persona**, **Pendiente**, **Realizar Tabla comparativa de los parámetros encontrados.**
 - Card 2: **Análisis**, **Analizar la información recopilada**, **Pendiente**, **Realizar Tabla comparativa de los sensores analizados.**
 - Card 3: **Busqueda Informac...**, **Estudiar las técnicas de aprendizaje de máquina utilizadas para la detección del Sueño.**, **Pendiente**, **Resumen de la información recopilada.**
 - Card 4: **Busqueda Informac...**, **Recopilar información de aplicaciones IoT que permitan monitorear el sueño y sus etapas em base a literatura publicada en los últimos 5 años.**
- Column 3 (No iniciado):**
 - Card 1: **Etapas Final**, **Redacción del documento Escrito**, **Pendiente**, **Borrador del documento escrito.**
 - Card 2: **Análisis**, **Definir los parámetros que permiten medir el rendimiento académico de los estudiantes universitarios.**, **Pendiente**, **Realizar Lista de parámetros obtenidos.**
 - Card 3: **Análisis**, **Proponer un esquema que puede ser implementado a futuro para monitorear el sueño utilizando un teléfono inteligente.**, **Pendiente**, **Realizar Esquema para monitoreo del sueño mediante un teléfono inteligente**.
 - Card 4: **Análisis**, **Definir el tipo de aprendizaje de máquina recomendado para inferir el nivel de sueño de una persona.**
- Column 4 (En curso):**
 - Card 1: **+ Agregar tarea**
- Column 5 (Completada):**
 - Card 1: **+ Agregar tarea**

ANEXO I.2 Tablero *kanban* semana 5

The Kanban board for week 5 is organized into three columns: 'No iniciado', 'En curso', and 'Completada'. Each column contains several task cards with details on their status and progress.

- No iniciado:** Contains four cards. The top card is 'Etapa Final' (Redacción del documento Escrito) with a 'Pendiente' status. Below it are three 'Análisis' cards and one 'Busqueda Informac...' card, all with 'Pendiente' status.
- En curso:** Contains five cards. The top card is 'Análisis' (Comparar los parámetros que se utilizan en trabajos relacionados con la detección del sueño en una persona) with 'Pendiente' status. Below it are four 'Busqueda Informac...' cards, all with 'Pendiente' status.
- Completada:** Contains five cards. The top card is 'Análisis' (Proponer un esquema que puede ser implementado a futuro para monitorear el sueño utilizando un teléfono inteligente) with a green checkmark and 'Completada por ROMMEL FRAN...' status. Below it are three 'Busqueda Informac...' cards and one 'Planificación' card, all with 'Completada por ROMMEL FRAN...' status.

ANEXO I.3 Tablero *kanban* semana 8

The Kanban board for week 8 is organized into three columns: 'No iniciado', 'En curso', and 'Completada'. Each column contains several task cards with details on their status and progress.

- No iniciado:** Contains one card: 'Etapa Final' (Ajustes finales y presentación del Trabajo de Integración Curricular) with 'Pendiente' status.
- En curso:** Contains two cards. The top card is 'Etapa Final' (Ajuste del documento Escrito en base a observaciones) with 'Pendiente' status. The bottom card is 'Etapa Final' (Redacción del documento Escrito) with 'Pendiente' status.
- Completada:** Contains eight cards. The top card is 'Planificación' (Diseño de modelo de metodología Kanban para cumplimiento de objetivos) with a green checkmark and 'Completada por ROMMEL FRAN...' status. Below it are seven 'Busqueda Informac...' cards, all with 'Completada por ROMMEL FRAN...' status.