



Universidad de Cuenca

Facultad de Ingeniería

Carrera de Electrónica y Telecomunicaciones

Implementación de un prototipo de monitoreo de postura a nivel de cabeza, cuello, hombros y cintura escapular usando cámara de profundidad, caso de estudio de problemas músculo esqueléticos

Trabajo de titulación previo a la obtención del título de Ingeniera en Electrónica y Telecomunicaciones

Autor:

Karen Estefanía Carvajal Arias

Director:

Carlos Villie Morocho Zurita

ORCID: 0000-0002-8196-2644

Codirector:

Diego Fernando Cobos Cobos

ORCID: 0000-0003-4724-1517

Cuenca, Ecuador

2023-03-24

Resumen

Existe una brecha en el acceso a la información sobre la conducta postural en los lugares de trabajo por parte de médicos tratantes. Esta información es importante para tener una comprensión completa del contexto del paciente y de los factores de riesgo que contribuyen a la aparición de los trastornos musculoesqueléticos. En este contexto, se presenta la elaboración y pruebas de un prototipo con visión artificial para monitorear en tiempo real las posturas que adopta un individuo mientras se encuentra sentado frente a un computador. El prototipo utiliza una cámara de profundidad para obtener las coordenadas espaciales de los puntos de interés del cuerpo, las mismas que son utilizadas para calcular los ángulos que describen la postura del individuo. Se genera un data set de los ángulos para entrenar 3 métodos de clasificación RNN, RFC y GBC. Para los 3 métodos de clasificación, la tasa de aciertos sobrepasa el 70% en las 5 posturas estudiadas. La tasa de aciertos del prototipo utilizado en un escenario real no se ve afectado en más de un 10% respecto a los resultados obtenidos en condiciones controladas. Además, la información recopilada en el caso de estudio permitió mayor especificidad en el plan de tratamiento elaborado por un especialista.

Palabras clave: postura corporal, inteligencia artificial, sedestación, cámara de profundidad, clasificación de posturas

Abstract

It is difficult for physiotherapists to know in depth the postural behavior of their patients. This is important information to have a complete understanding of the patient's context and the risk factors that contribute to the appearance of musculoskeletal disorders. In this context, we present the development and testing of a real time prototype with skeleton tracking of postures adopted by a person while sitting in front of a computer. The prototype uses a depth camera to obtain the spatial coordinates of the body's joints. These points are used to calculate the angles that describe the individual's posture. A data set of angles is built to train 3 classification methods RNN, RFC and GBC. For all 3 classification methods, the accuracy rate exceeds 70% for the 5 postures studied. The accuracy rate of the prototype used in a physiotherapy case study is not affected by more than 10% compared to the results obtained under controlled conditions. In addition, the results obtained in the study case assisted a specialist to develop a treatment plan.

Keywords: sitting posture, artificial intelligence, depth camera, screen exposure, posture classification

Índice general

1. Introducción	12
1.1. Antecedentes	13
1.1.1. Revisión del Estado del Arte	14
1.2. Identificación del Problema	17
1.3. Alcance	18
1.4. Objetivos	19
1.4.1. Objetivo General	19
1.4.2. Objetivos Específicos	19
1.5. Contribución	20
2. Fundamentos teóricos	21
2.1. Contexto de la Tele Rehabilitación	21
2.1.1. Aplicaciones de la Tele Rehabilitación	21
2.1.2. Sistemas de Monitoreo Remoto	22
2.1.3. Riesgos por exposición a pantallas	23
2.1.3.1. Visión	23
2.1.3.2. Efectos Psico-Fisiológicos	25
2.1.3.3. Trastornos Músculo Esqueléticos	25
2.1.4. Métodos para la Valoración de Posturas	27
2.1.4.1. Método OWAS	28
2.1.4.2. Método REBA	30
2.1.4.3. Biomecánica de Esfuerzos Estáticos	33
2.1.5. Postura correcta en sedestación	34
2.2. Monitoreo y Seguimiento del Esqueleto Humano	37
2.2.1. Inerciales	38
2.2.2. Electromecánicos	38
2.2.3. Electromagnéticos	38
2.2.4. Ópticos	38
2.3. Cámaras de profundidad 3D	39
2.3.1. Sensores de Profundidad	40
2.4. Métodos de Clasificación	43
2.4.1. Redes Neuronales	43
2.4.2. Decision Tree Classifier	44
2.4.3. K-nearest Neighbour	45
2.4.4. Random Forest Classifier	46
2.4.5. Gradient Boosting Classifier	47
3. Prototipado de un Sistema de Monitoreo y Clasificación de Postura en Sedestación en Tiempo Real	49
3.1. Metodología	49
3.2. Identificación y Selección de Posturas	51
3.2.1. Detalle de las Posturas	54
3.3. Selección de Tecnologías de Skeleton Tracking y Recursos	58
3.3.1. Evaluación de cámaras con sensores de profundidad	58
3.3.2. Evaluación de frameworks para cámaras de profundidad 3D	59
3.4. Software de captura de postura en sedestación	61
3.4.1. Ubicación de la cámara	62
3.4.2. Programa de captura	68
3.4.3. Creación del conjunto de datos	72

3.5. Programa de Entrenamiento y Clasificación en tiempo real	74
3.5.1. Red Neuronal Recurrente	74
3.5.2. Gradient Boosting Classifier	75
3.5.3. Random Forest Classifier	77
3.5.4. Clasificación en tiempo real	78
4. Aplicaciones	79
4.1. Validación	79
4.1.1. Validación en condiciones controladas	79
4.1.2. Red Neuronal Recurrente	81
4.1.3. Clasificador Random Forest	83
4.1.4. Clasificador Gradient Boosting	84
4.1.5. Comparaciones	86
4.1.6. Validación en escenario real	89
4.2. Caso de Estudio	96
5. Conclusiones y recomendaciones	100
5.1. Conclusiones	100
5.2. Perspectivas	102
5.3. Trabajos futuros	103

Índice de figuras

2.1. Esquema de Tele fisioterapia con dispositivos IoT.	23
2.2. Anatomía del ojo frente exposición del espectro de luz UV. Tomado de [1].	24
2.3. Códigos para el registro de las posturas y de la fuerza realizada. Basado en [2]	29
2.4. Códigos para el registro de las posturas y de la fuerza realizada del método OWAS. Basado en [2].	30
2.5. Mediciones de los ángulos articulares para la puntuación REBA del Grupo A. [2]	31
2.6. Mediciones de los ángulos articulares para la puntuación REBA del Grupo B. [2]	31
2.7. Diagrama para la puntuación REBA. Basado en [2]	32
2.8. Esquema de momentos y cargas en el codo. Basado en [3]	33
2.9. Ángulos de Confort extremidades superiores. Tomado de [4].	35
2.10. Ángulos de Confort tronco. Basado de [4].	36
2.11. Ángulos de Confort extremidades inferiores. Basado de [4].	36
2.12. Ángulos de Confort de Wisner para la actividad en sedestación. Tomado de [4].	37
2.13. Esquema de la triangulación empleada para obtener el valor de profundidad desde la disparidad captada por el sensor. Tomado de [5]	41
2.14. Articulaciones del cuerpo humano (32), vistas como coordenadas. Tomado de [6]	42
2.15. Neuronas en una Red Neuronal Recurrente. Basado en [7]	43
2.16. Arquitectura Red Neuronal Recurrente. Tomado de [8]	44
2.17. Arquitectura Red Neuronal Recurrente. Basado en [9]	45
2.18. Arquitectura k Nearest Neighbors. Tomado de [10]	46
2.19. Arquitectura Clasificador Random Forest. Tomado de [11]	47
2.20. Esquema del Clasificador Gradient Boosting. Tomado de [12]	48
3.1. Metodología para el Prototipado de un Sistema de Monitoreo y Clasificación de Postura en Sedestación en Tiempo Real SIS-MC-PSTR.	50
3.2. Ángulos considerados para el cuello y torso.	55
3.3. Ángulos considerados para el brazo y antebrazo.	57
3.4. Cámara de profundidad Orbbec Astra Pro, seleccionada para el seguimiento de esqueleto. .	59
3.5. Esquema de los componentes de hardware y software para el prototipo de seguimiento de postura en sedestación.	61
3.6. Prueba de visualización de la cámara ubicada a 1.7m y 85cm de altura.	62
3.7. Escenario para pruebas de ubicación de cámara y captura de datos.	63
3.8. Pruebas de ubicación de cámara a diferentes distancias y altura, con seguimiento de esqueleto.	63
3.9. Pruebas de ubicación de cámara a diferentes distancias y altura.	64
3.10. Escenario para pruebas de ubicación de la cámara a diferentes distancias altura.	65
3.11. Pruebas de ubicación de cámara a diferentes ángulos a una distancia $D = 250\text{cm}$ y una altura $A_t = 60\text{cm}$	65
3.12. Pruebas de ubicación de cámara de $\alpha = 10^\circ$ a $\alpha = 40^\circ$, a una distancia de $D = 250\text{cm}$ y alturas de $A_t = 0.6\text{cm}$ y $A_t = 0.7\text{cm}$ con seguimiento de esqueleto.	66
3.13. Pruebas de ubicación de cámara de $\alpha = 40^\circ$ a $\alpha = 80^\circ$, a una distancia de $D = 250\text{cm}$ y alturas de $A_t = 0.6\text{cm}$ y $A_t = 0.7\text{cm}$ con seguimiento de esqueleto.	67
3.14. Ángulos considerados para la descripción de la postura en el plano (x,y).	69
3.15. Ángulos considerados para la descripción de la postura en el plano (z,y)	70
3.16. Escenario para la captura del conjunto de datos, con un punto de observación que permite medir los ángulos de un individuo, cámara ubicada a una distancia $D = 250\text{cm}$, $A_t = 60\text{cm}$ de altura y ángulo $\alpha = 70^\circ$	72

3.17. Medición de ángulos corporales de la postura con ON 2D Measure para dirigir la captura del conjunto de datos, en un escenario controlado.	73
3.18. Esquema del procedimiento de elaboración de la Red Neuronal Recurrente.	74
3.19. Arquitectura de la Red Neuronal Recurrente ..	75
3.20. Esquema del procedimiento de elaboración para el GBC	76
3.21. Esquema del procedimiento de elaboración para el RFC	77
3.22. Captura del programa de detección y clasificación de postura en tiempo real. En la esquina superior izquierda se observa la predicción de los 3 métodos.	78
4.1. Clasificación de la postura A en un escenario controlado, con el uso de la aplicación ON 2D Measure.	79
4.2. Clasificación de la postura B en un escenario controlado, con el uso de la aplicación ON 2D Measure.	79
4.3. Clasificación de la postura C en un escenario controlado, con el uso de la aplicación ON 2D Measure.	80
4.4. Clasificación de la postura D en un escenario controlado, con el uso de la aplicación ON 2D Measure.	80
4.5. Clasificación de la postura E en un escenario controlado, con el uso de la aplicación ON 2D Measure.	80
4.6. Gráfica de la matriz de confusión para el método de clasificación con RNN.	82
4.7. Gráfica de la matriz de confusión para el método de clasificación con RFC.	83
4.8. Gráfica de la matriz de confusión para el método de clasificación con GBC.	85
4.9. Gráfica de la parte asimétrica y simétrica de matriz de confusión para el método de clasificación con Red Neuronal Recurrente.	87
4.10. Gráfica de la parte asimétrica y simétrica de matriz de confusión para el método de clasificación con Random Forest.	87
4.11. Gráfica de la parte asimétrica y simétrica de matriz de confusión para el método de clasificación con Gradient Boosting.	87
4.12. Colocación del prototipo en el lugar de trabajo del individuo	90
4.13. Porcentaje del tiempo de cada día en cada una de las posturas, según la clasificación del especialista y las clasificaciones de los métodos RNN, RFC y GBC.	91
4.14. Pre diagnóstico del paciente para caso de estudio	96
4.15. Prediagnóstico del paciente para caso de estudio.	97
4.16. Escenario: lugar de trabajo del voluntario para caso de estudio.	97
4.17. Diagnóstico final del paciente para caso de estudio, recomendaciones del especialista para adecuar el lugar de trabajo ergonómicamente.	99
4.18. Diagnostico final del paciente para caso de estudio, indicaciones para ejercicios.	99
A.1. Metodología de Investigación de Gorcshek. Tomado de [13]	104
B.1. Arquitectura de NuiTrack API. Tomado de [14].	105

Índice de tablas

2.1. Ángulos de Confort de Wisner para la actividad en sedestación.	35
3.1. Códigos de posiciones para las secciones del cuerpo de una persona en sedestación frente a un computador. Basado en la metodología OWAS	51
3.2. Descripción de las posturas más comunes en sedestación frente a un computador.	52
3.3. Recopilación de las posturas en sedestación frente a un computador y fases de trabajo.	53
3.4. Clasificación de posturas en sedestación frente a un computador. Basado en la metodología OWAS	53
3.5. Codificación de los rangos de movimiento para los ángulos articulares del Tronco en sedestación frente a un computador.	54
3.6. Codificación de los rangos de movimiento para los ángulos articulares del Cuello en sedestación frente a un computador.	55
3.7. Codificación de los rangos de movimiento para los ángulos articulares de las piernas en sedestación frente a un computador.	56
3.8. Codificación de los rangos de movimiento para los ángulos articulares de los brazos en sedestación frente a un computador.	56
3.9. Codificación de los rangos de movimiento para los ángulos articulares de los antebrazos en sedestación frente a un computador.	56
3.10. Clasificación de las posturas posibles por clase y ángulos articulares en sedestación frente a un computador. Basado en la metodología OWAS y REBA	57
3.11. Comparativo de la selección de Cámaras de profundidad 3D	58
3.12. Detalle de los 19 puntos clave y articulaciones del seguimiento de esqueleto de Nuitrack	60
3.13. Parámetros de ubicación de la cámara Orbbec Astra Pro + trípode para la captura de un individuo en sedestación.	67
3.14. Detalle de los 15 puntos clave y articulaciones del seguimiento de esqueleto utilizando Nuitrack para el prototipo de monitoreo en sedestación	68
3.15. Detalle de los ángulos de inclinación considerados en el plano (x,y) para el programa de captura	69
3.16. Detalle de los ángulos de inclinación considerados en el plano (z,y) para el programa de captura	70
3.17. Precisión obtenida con el clasificador por árbol de decisión para diferentes profundidades.	76
3.18. Parámetros para el GBC para una precisión del 95 %.	77
3.19. Parámetros para el RFC para una precisión del 93 %.	78
4.1. Porcentaje de detección correcta e incorrecta de los métodos de clasificación con el set de validación	81
4.2. Matriz de confusión del resultado de la clasificación con RNN.	81
4.3. Parámetros de evaluación de la matriz de confusión de la clasificación con RNN para cada clase.	82
4.4. Matriz de confusión del resultado de la clasificación con RFC.	83
4.5. Parámetros de evaluación de la matriz de confusión de la clasificación con RFC para cada clase.	84

4.6. Matriz de confusión del resultado de la clasificación con GBC.	85
4.7. Parámetros de evaluación de la matriz de confusión de la clasificación con Gradient Boosting para cada clase.	86
4.8. Ejemplo del proceso de clasificación en tiempo real, se presentan los ángulos y los resultados de los clasificadores.	88
4.9. Matriz de coincidencias de las combinaciones los métodos de clasificación para cada clase.	89
4.10. Porcentaje de datos tomados para la validación del prototipo en un escenario real.	91
4.11. Porcentaje del tiempo que el paciente adoptó las diferentes posturas, según el análisis del especialista y los clasificadores RNN, RFC y GBC.	92
4.12. Matriz de confusión de la clasificación con RNN, validación en escenario real.	92
4.13. Parámetros de evaluación de la matriz de confusión de la clasificación con RNN, validación en escenario real	93
4.14. Matriz de confusión de la clasificación con RFC, validación en escenario real.	93
4.15. Parámetros de evaluación de la matriz de confusión de la clasificación con RFC, validación en escenario real	94
4.16. Matriz de confusión de la clasificación con GBC, validación en escenario real.	94
4.17. Parámetros de evaluación de la matriz de confusión del GBC, validación en escenario real	95
4.18. Comparación del rendimiento del prototipo en un escenario real vs pruebas de laboratorio, en función del porcentaje de aciertos.	95

Agradecimientos

Agradezco al laboratorio de Telemedicina por impulsar este proyecto y permitirme ser parte de él. Agradezco a mis directores, Dr. Carlos Villie Morocho Zurita y Lcd. Diego Fernando Cobos Cobos, por su guía y apoyo en este proyecto. Agradezco al voluntario por su colaboración en el caso de estudio. Agradezco al Ing. Alexander Peñafiel por su asesoría. Agradezco a Nicolás Zalamea por su invaluable guía e impulso. Agradezco a mi familia por siempre acompañarme y apoyarme en cada paso.

Dedicado a las personas que amo,
Fabián, Verónica, Jhustyn y Nicolás

Karen Estefanía Carvajal Arias

1. Introducción

El Instituto nacional de estadísticas y censos del Ecuador INEC reporta que en 2022 el 40.4 % de hogares disponen de una computadora de escritorio, laptop o tablet. En total se estiman 2.9 millones de hogares con dispositivos de equipamiento tecnológico [13]. En cuanto a teléfonos inteligentes, en 2014 tan solo el 13.3 % de la población disponía de un teléfono inteligente y para el año 2022 este número incrementó al 52.2 %. En total se reporta que 8.7 millones de ecuatorianos desde los 5 años en adelante, cuentan con un celular smartphone activado. El conjunto de las TICs ha generado el concepto de consumidor digital [14], el uso prolongado de estos dispositivos se convierte en un problema de salud social. Las consecuencias se presentan como trastornos de sueño, ansiedad o conductas adictivas [15], al igual que afecciones musculoesqueléticas y de visión [16].

A diario el número de consumidores digitales incrementan a nivel mundial, asimismo, la velocidad para intercambiar información mejora [14]. En este contexto, la inserción de la tecnología en el ámbito laboral puede incrementar la productividad en un promedio del 18 % [17], y en la academia permite un mayor alcance a los programas de estudio. La pandemia del COVID 19 aceleró la migración de las empresas e instituciones hacia el teletrabajo [18], así como incrementó el tiempo de uso de internet y dispositivos electrónicos de niños, jóvenes, adultos y adultos mayores [19–21]. Esto implica que más porcentaje de población esté expuesta a largos periodos frente a dispositivos. Al no existir un panorama claro sobre los perjuicios a largo plazo de permanecer en posturas nocivas, la tecnología [22], se vuelve un aliado para el monitoreo de estos trastornos.

La fisioterapia puede trabajar en conjunto con las TICs para mejorar la efectividad y eficacia de los tratamientos, tal es el caso de los sistemas de intervención y evaluación de pacientes en rehabilitación o sistemas de entrenamiento deportivo [22]. Son muchos los pacientes que no consiguen transmitir adecuadamente su caso al especialista en salud, razón por la cual, es de utilidad buscar elementos que monitoreen su actividad y ayuden a identificar la raíz del problema. Esto ha motivado la investigación y desarrollo de herramientas tales como la visión artificial para Skeleton Tracking (ST) que ofrecen monitoreo sin ser intrusivas [22], además pueden adaptarse a un lugar de trabajo [23] y seguir la postura de varios individuos a la vez [24]. Por consiguiente, es posible generar sistemas óptimos que monitoreen la salud postural de trabajadores y estudiantes.

En el laboratorio de Telemedicina y Salud Digital de la Universidad de Cuenca se iniciaron varias líneas que relacionan la tecnología con la salud y en especial con fisioterapia, esta temática nace y es adoptada por dicho laboratorio. El propósito de esta tesis, es generar un prototipo para el monitoreo de postura, para un caso de estudio de fisioterapia, de una persona sentada frente a su computador. La extracción de las coordenadas espaciales de la cabeza, cuello y articulaciones se realiza con una cámara de profundidad Orbbec Astra Pro. Con esta información se calculan los ángulos que describen las posiciones de una persona y se genera un dataset de las diferentes posturas.

Se utilizan modelos de aprendizaje supervisado RNN, RFC y GBC para la clasificación en tiempo real de la postura de la persona mientras trabaja frente al computador. Este capítulo está organizado de la siguiente manera. La sección 1.1 presenta los antecedentes y estado del arte. La sección 1.2 presenta la identificación del problema. La sección 1.3 presenta el alcance del proyecto. La sección 1.4 presenta los objetivos. Finalmente, la sección 1.5 presenta las contribuciones.

1.1. Antecedentes

Con el crecimiento de la adquisición de dispositivos inteligentes, incrementaron también las ofertas educativas y laborales de modalidad no presencial o semi presencial [25]. La pandemia del COVID 19 apresuró la transición del ambiente laboral y educativo hacia los hogares [26]. A esto se le suma que no necesariamente la población consideraba importante adecuar ergonómicamente sus espacios, debido a que el tiempo que trabajaban en estos no era tan prolongado como lo es ahora. En algunos casos se pueden superar las 8 horas laborales habituales. Los campos de ergonomía y fisioterapia [27], establecen normas para adecuar los espacios de trabajo correctamente y minimizar el riesgo de trastornos musculoesqueléticos. Además, debido al tiempo de concentración frente a pantallas y largos períodos en sedestación (posición anatómica de estar sentado), es importante mantener una postura correcta. Generalmente las personas no son consientes de su posición corporal la mayor parte del tiempo que se encuentra en actividades laborales o académicas frente a un computador. Esto ha motivado el desarrollo de dispositivos tipo *wearable* que emite vibraciones o alertas al usuario como recordatorio de corrección de postura [28].

En otra rama de estudio se encuentran las soluciones no invasivas, por ejemplo, la visión artificial. Gracias a las diferentes técnicas de inteligencia artificial, es posible el monitoreo de las articulaciones de uno o múltiples individuos mediante una cámara especial. Esta línea de investigación ha permitido desarrollar sistemas de diagnóstico para patologías musculoesqueléticas y nerviosas, por ejemplo, detección de marchas defectuosas [29], análisis de movimientos por padecimiento de Parkinson [30], seguimiento de posturas de trabajadores que realizan trabajos de esfuerzo [31]. Así mismo, la visión artificial ha sido utilizada en el monitoreo de ejercicios de rehabilitación [32] [33], permitiendo saber si los movimientos que realiza el paciente son correctos y corregirlos en el momento.

En esta línea, los métodos de clasificación de imágenes juegan un rol esencial, existen diversos métodos de entrenamiento para la detección y seguimiento de articulaciones. Los modelos de clasificación se escogen dependiendo del enfoque del proyecto. Por ejemplo, en el caso de métodos como Redes Neuronales Convolucionales (RNC) se pueden utilizar para la clasificación de posturas estáticas [34], y modelos con Redes Neuronales Long Short-Term Memory (LSTM) permite la detección de acciones [35].

La mayoría de los estudios y prototipos se basan en el seguimiento del esqueleto en movimiento, sin embargo, es conveniente para el tratamiento fisioterapéutico el monitoreo de los pacientes cuando mantienen una postura por largos periodos de tiempo. Esto permitiría al fisioterapeuta comprender de mejor manera el caso de su paciente para generar un diagnóstico y tratamiento más focalizado. Así, el sistema de monitoreo sumaría una nueva perspectiva al profesional de salud para trabajar con sus pacientes. Además, están las ventajas de contar con un monitoreo periódico y que los pacientes pueden realizar desde sus hogares, sumando así elementos de telemedicina.

1.1.1. Revisión del Estado del Arte

En el campo de la salud, en especial la fisioterapia, existe gran interés en la detección y seguimiento de la posición del esqueleto humano en actividad o reposo, para mejorar los diagnósticos y proponer terapias de manera presencial o virtual. Existen dos tipos de soluciones de seguimiento de postura: invasivas (*wearables*), y no invasivas. En [36], los autores proponen un dispositivo tipo *wearable* con el microcontrolador ATmega380 y sensores de medición inercial, los datos de acelerómetros y giroscopios permiten el monitoreo del movimiento del tren

superior del usuario, el dispositivo emite vibraciones y notificaciones mediante una aplicación Android en su celular cuando detecta una postura incorrecta.

De similar desarrollo, en [37], los autores utilizan tres sensores triaxiales para obtener mayor precisión en la detección de postura, los datos son procesados por cuatro clasificadores: Support vector machine (SVM), Multi-Layer-Perceptron (MPL), GBC y Random Forest Classifier (RFC), siendo este último el de mejor precisión logrando en promedio un 95,68 % para 5 posturas en sedestación en pruebas con siete personas de contextura diferente. En [38], se presenta una muñequera mínimamente invasiva, equipada con cuatro cámaras térmicas miniatura para el seguimiento y estimación de las posturas de mano y dedos, el sistema fue entrenado con imágenes de manos sintéticas. Los resultados demuestran que es posible reconstruir la postura de la mano y dedos, con los datos de las imágenes térmicas de las siluetas de la mano, tomadas desde la muñeca.

Por otro lado, se encuentran las soluciones no invasivas que hacen uso de diferentes tipos de cámaras. Los autores de [39], con el uso de una cámara RGB-D Red Green Blue 2D presentan dos sistemas de aprendizaje supervisado para el entrenamiento y detección de posturas corporales, primero utilizando Redes Neuronales Convolucionales (RNC) sumado con Transfer Learning (TL) en RGB e imágenes de profundidad, de igual forma se modela la postura con los datos espaciales de las articulaciones en 3D, a partir de ello con SVM se clasifican las posturas basadas en modelo 3D. Sus resultados presentan alta resiliencia a los cambios de escala y orientación de los sujetos.

Las cámaras de profundidad permiten la captura de coordenadas espaciales en tres dimensiones, aliviando el procesamiento del computador. En el artículo [40], los autores ponen a prueba los modelos Kinect One y Orbbec Astra. En este comparativo utilizan 23 modelos de clasificadores con datos posturales obtenidos de cada cámara, cada clasificador se entrena con ambos grupos de datos por separado y en conjunto para determinar la compatibilidad y eficiencia de la detección. La similitud entre ambos dispositivos permitió, en 16 modelos, intercambiar los grupos de datos, mientras que los siete restantes bajaron su precisión entre el 50 % y 85 %.

En [41], mediante las coordenadas espaciales articulares de un conjunto de datos de acceso público, los autores entrenan tres sistemas de clasificación para la detección de posturas cinemáticas. Exploran los resultados de considerar cada articulación como sensores de posición y orientación. Proponen dos funciones lineales que representan la posición y el ángulo de las articulaciones en 3D, las cuales describen cada cuadro de video para cada acción, en total se clasifican cinco acciones diferentes. Con la información generada se extrae un identificador de las características de la clase. Luegome mediante un filtro Butterworth pasa bajos de primer orden, con frecuencia de corte de 10Hz se consigue la función descriptiva Kinematics Posture Feature (KPF), esta técnica de filtrado aumenta la relación señal/ruido con un mínimo de retraso de la onda. Para la clasificación se utilizan los modelos: SVM, Convolutional Neural Networks- Recurrent Neural Network (CNN-RNN) y Convolutional Recurrent Neural Network (CONVRNN).

Los autores en [42], utilizan la cámara de profundidad Kinect para generar un modelo de análisis de datos de movimiento articular multivariante, considerando las articulaciones interrelacionadas del cuerpo humano en seis secciones: brazos, piernas, cabeza y tronco. El modelo se entrena con datos cinemáticos con la serie: sentado-parado-sentado, los participantes son personas sanas y pacientes con enfermedad de Parkinson. Se generaron cuatro modelos de Analysis of Joint Motion Data (AJMD) multivariante para cuantificar la correlación entre pares de articulaciones de distintas secciones del cuerpo. Los resultados permitieron generar un parámetro de diferenciación entre los grupos de datos de los participantes sanos y pacientes de Parkinson.

En una línea similar [43], presenta el desarrollo de un método de detección en tiempo real de movimientos característicos de niños con Trastorno del Espectro Autista (TEA), el sistema junta la cámara de profundidad Intel Real Sense y el framework NuiTrack SDK para la extracción de datos articulares de los usuarios. Mediante el método RNC se entrena un modelo de clasificación con datos recopilados de diferentes patrones de comportamiento de los niños, los resultados muestran una precisión media de 92,6 % en las pruebas.

En [44], se propone un sistema de detección de cuatro posturas: de pie, inclinación, sedestación y decúbito, los datos se obtienen de dos cámaras y el método de clasificación Hierarchical Fuzzy Classifier (HFC) [45]. El sistema segmenta el cuerpo humano utilizando Gaussian Mixture Model (GMM) [46], luego se genera una guía del cuerpo en 3d con un modelo de intersección de volúmenes, se extraen las características de vóxel del cuerpo en 3D. La clasificación se realiza con un método propuesto Fuzzy Classifier with Soft Margin Minimization (FC-SMM) [47], en la experimentación los resultados son mejores a comparación de otros métodos de extracción y clasificación de posturas.

1.2. Identificación del Problema

En 2019, aproximadamente 43.3 millones de dólares fueron destinados a tratamientos de fisioterapia en Ecuador según el Reporte de Actividades y recursos de Salud (RAS) [48]. Sin embargo, no se constatan datos de tratamientos inconclusos o personas no diagnosticadas. Los autores de [49], realizaron un estudio en un ambiente empresarial para relacionar las posturas con trastornos musculoesqueléticos, y registraron que el 87.50 % de los empleados que trabajan frente al computador entre 10 a 11 horas diarias presentan problemas de este tipo. En [50], los autores concluyen según un estudio cualitativo que los profesionales de área administrativa corren riesgo de adquirir algún trastorno musculoesquelético debido a la postura estática en su horario laboral.

Los pacientes de fisioterapia a menudo no se presentan a las consultas y tratamientos con la periodicidad requerida, aumentando la probabilidad de padecer secuelas en el largo plazo. La normalización por parte de la sociedad de las posturas nocivas por tiempos prolongados surtirá efecto en los próximos años. Las consecuencias se verán reflejadas en un aumento de dolencias de tipo musculoesqueléticas y trastornos derivados. Se requieren programas de salud que implementen protocolos de vigilancia sanitaria para los usuarios de computadores en periodos prolongados [49].

Desde un punto de vista tecnológico, se pueden plantear diferentes soluciones a este problema. Entre ellas, se puede incluir sistemas de seguimiento esquelético en el planteamiento de protocolos de monitoreo de postura. Las consultas y tratamientos a distancia cada día tienen más aceptación en la sociedad de la información. Para un profesional de fisioterapia resulta conveniente monitorear el progreso de sus pacientes mientras realizan sus actividades diarias, y de esta manera mejorar los diagnósticos, tratamientos y ofrecer un mejor servicio.

Existe una necesidad creciente de establecer medidas de seguimiento sanitario a los usuarios frecuentes de computadores o laptops. Un alto porcentaje de los trabajadores de áreas administrativas, investigación o docencia, se pueden ver afectados por mantener las posturas inadecuadas y prolongadas que requieren sus labores. Dentro del conjunto de soluciones, las medidas de tipo no invasivo son versátiles y escalables. Por ello, se plantea prototipar un sistema de captura y clasificación en tiempo real de 5 posturas en sedestación con una cámara de profundidad, para monitorear los ángulos de articulaciones y puntos clave de una persona.

1.3. Alcance

El presente trabajo de titulación propone desarrollar un prototipo de monitoreo de postura en sedestación de una persona. Específicamente se capturan las coordenadas espaciales de las articulaciones, cabeza y cuello, para un total de quince puntos mediante el uso de una cámara de profundidad Orbbec Astra Pro. Para la gestión de los datos obtenidos con la cámara se utiliza el middleware de Nitrack para Python. Los datos son utilizados para calcular diez ángulos que describen la postura de la persona mientras está sentada.

Las posiciones son clasificadas en 5 categorías, para esto se utilizan dos métodos de inteligencia artificial Gradient Boosting Classifier (GBC), Random Forest Classifier (RFC) y un método de deep learning Recurrent Neural Networks (RNN) en Python. Los modelos son entrenados con un set de datos de los ángulos que describen la posición del individuo, las muestras son tomadas en un escenario controlado mientras realiza las siguientes posturas: correcta, inclinación hacia adelante, inclinación hacia atrás, brazos por encima de la línea del hombro e inclinación lateral.

El prototipo se valida en un ambiente controlado para realizar un análisis mixto, cualitativo y cuantitativo, de la confiabilidad de la clasificación de los tres métodos. Finalmente se presentan los resultados de un caso de estudio de fisioterapia, en el cual se monitorea con el prototipo a un voluntario en su espacio de trabajo.

El prototipo no pretende dar un diagnóstico, sino ser una herramienta para el seguimiento de casos de estudio de tele-fisioterapia. En resumen, los resultados esperados son los siguientes:

- Programa de obtención de coordenadas espaciales y ángulos de la postura corporal de un individuo, codificado e implementado en Python.
- Data set inicial de los ángulos que describen la postura de un individuo en cinco categorías.
- Programa de entrenamiento de RNN, GBC y RFC, codificado e implementado en Python.
- Programa de detección y clasificación de postura en tiempo real, codificado e implementado en Python.
- Análisis de resultados de cada método de clasificación RNN, GBC y RFC.
- Presentación del caso de estudio del individuo.

1.4. Objetivos

1.4.1. Objetivo General

Implementar un prototipo de seguimiento y clasificación en tiempo real de posturas en sedestación, con enfoque en el monitoreo de trabajo frente ordenadores por periodos largos, como herramienta para un caso de estudio de fisioterapia.

1.4.2. Objetivos Específicos

El presente trabajo tiene los siguientes objetivos específicos:

- Revisar el desarrollo tecnológico de contribuciones previas, relacionadas a la detección de posturas en sedestación y clasificación de ST en general.

- Investigar y elegir las herramientas disponibles de software y hardware en el mercado que permitan el desarrollo del prototipo.
- Generar un set de datos espaciales de la postura de cabeza-cuello y articulaciones (15 puntos coordenadas (x,y,z) y 10 ángulos) de un individuo en condiciones controladas.
- Entrenar el sistema prototipo para la clasificación de las posturas mediante técnicas de Machine Learning (ML).
- Clasificar en tiempo real las posturas de un individuo mientras se encuentra sentado en un escenario controlado.
- Realizar pruebas de laboratorio y presentación de un caso de estudio para identificar los parámetros de confiabilidad del prototipo.

1.5. Contribución

Este proyecto presenta las siguientes contribuciones:

- Revisión conceptual de los diferentes esquemas de monitoreo de postura en trabajos relacionados a los sistemas de Skeleton Tracking.
- Generación de un set de datos de ángulos posturales en condiciones controladas.
- Programa de entrenamiento para RNN, GBC, y RFC.
- Documentación del proceso de prototipado del proyecto y programas de implementación en Python transferibles para futuros trabajos en el Laboratorio de Telemedicina y Salud Digital.
- Guía de las configuraciones para el uso de la cámara de profundidad para la detección de posturas en sedestación.
- Presentación de un caso de estudio de fisioterapia en acompañamiento del prototipo.

2. Fundamentos teóricos

En este capítulo se presenta principios teóricos y conceptos importantes asociados con esta investigación. La Sección 2.1 presenta el contexto de la Tele Rehabilitación. La Sección 2.1.3 presenta un resumen general de los riesgos a la salud por exposición a pantallas. La Sección 2.1.4 presenta los métodos de clasificación de posturas. La Sección 2.1.5 describe de la postura en sedestación. La Sección 2.2 presenta las metodologías de seguimiento en STs. La Sección 2.3 presenta las características de las cámaras de profundidad. Finalmente la Sección 2.4 presenta los diferentes métodos de clasificación para STs.

2.1. Contexto de la Tele Rehabilitación

La tecnología de sensores y monitoreo, de tipo invasivo y no invasivo, han revolucionado diferentes áreas (industrial, entretenimiento, academia, etc.,) mejorando los procesos y resultados. Estos esfuerzos se han visto altamente reflejados en el área de la atención médica, el equipamiento y los sistemas son cada vez más precisos, tanto para la detección de enfermedades, procesos clínicos o el monitoreo de parámetros biométricos. En general, mejoran las condiciones de los servicios sanitarios, brindando eficacia y rapidez y cohesión entre los datos generados [51].

2.1.1. Aplicaciones de la Tele Rehabilitación

Los deportistas de alto rendimiento son ejemplo del uso de dispositivos de monitoreo médico para la mejora continua de sus facultades. Existen diversos dispositivos portátiles que miden en tiempo real los datos biométricos, así como pruebas especializadas de seguimiento de movimientos/acciones para generar estadísticas de rendimiento. En caso de existir lesiones, es importante realizar revisiones inmediatas para evitar secuelas a largo plazo [52]. La fisioterapia virtual es una manera rentable para expandir el alcance de los servicios de rehabilitación, pudiendo llegar a lugares apartados dónde no existan centros especializados.

En un estudio [53], se analizaron 22 estudios (2 cuantitativos y 20 cualitativos) de 1179 participantes de diferentes proveniencias después de sufrir una artroplastia. Los resultados mostraron que desde el 2017 los participantes presentaron una mayor adaptación al modo asíncrono de terapia mediante aplicaciones móviles. Los tratamientos fueron dirigidos por fisioterapeutas y enfermeras, los efectos muestran que las terapias en línea obtuvieron mejorías comparables con las presenciales, los pacientes reportaron mejorías en el alivio del dolor, amplitud de movimiento de la articulación y por ende una mejor calidad de vida.

Un estudio transversal de un mes [54], pacientes ortopédicos recibieron terapias a distancia bajo su consentimiento, la tasa de respuesta fue del 92 % de satisfacción con la tele rehabilitación, un 7,2 % tuvo dificultades para seguir el programa. La tele rehabilitación en diversos diagnósticos, resulta ser una herramienta interesante por la continuidad que se puede dar al tratamiento después de los chequeos en el centro de salud, los pacientes se ven beneficiados debido a que su progreso se realiza en ambientes familiares. También se asegura un registro de los avances del paciente que resulta en motivación para él mismo [55].

2.1.2. Sistemas de Monitoreo Remoto

Los sistemas de rehabilitación remotos son el resultado de la convergencia de diversas áreas de la tecnología [51], los datos extraídos por los sensores (portátiles o no invasivos) son enviados por métodos inalámbricos a los dispositivos con aplicaciones móviles o web. Los datos deben ser correctamente gestionados bajo estándares de seguridad, para el almacenamiento o procesamiento de estos. En caso de contar con un sistema de alerta, es necesario un sistema de respuesta que alerte tanto al paciente como al profesional del incidente. La Figura 2.1 muestra un esquema general de un sistema de tele fisioterapia donde el paciente y fisioterapeuta tienen acceso a los datos y comunicación bidireccional. Entre las ventajas de estos sistemas, se encuentran:

- Control y monitoreo en tiempo real, consulta directamente con el especialista
- Historial clínico accesible desde cualquier ubicación
- Personalización y cambios de la estructura de la rehabilitación
- Libertad de tiempo y ubicación del paciente para cumplir con el tratamiento
- Control en la ejecución correcta de la rehabilitación
- Se evitan tiempos de espera y desplazamiento hacia clínicas o centros de salud.




Figura 2.1: Esquema de Telefisioterapia con dispositivos IoT.

Sin embargo, entre los especialistas de fisioterapia [56], aún existe resistencia a tomar el camino de teleasistencia para el diagnóstico y monitoreo de sus pacientes. Algunos de los factores principales que impiden la adopción del método son de tipo legal o financiero, también existen dudas por la componente técnica de estos sistemas. A diferencia de lo que se podría creer, como resultado la crisis del COVID-19 (que aceleró los procesos de asistencia médica remota), no se generó un cambio notable en la aceptabilidad de la tele fisioterapia por parte de los profesionales. El desarrollo tecnológico en el sistema de salud actual no ha generado el nivel de confiabilidad necesario, tanto en profesionales como en pacientes, para que se acredite la tele fisioterapia. Los principales problemas son la complejidad de las interfaces, la falta de una base legal y las condiciones de remuneración.

2.1.3. Riesgos por exposición a pantallas

Visión

Los efectos nocivos de las pantallas de dispositivos inteligentes en la visión ha sido objeto de estudio en los últimos 20 años, la literatura especializada reporta una serie de estudios que recopilan diferentes efectos en la fisiología del ojo humano [57]. A continuación se resumen alguno de los síntomas y síndromes relacionados.

Daños en Córnea, Retina y mácula

Las longitudes de onda que utilizan los dispositivos electrónicos generan hiperosmolaridad en las células epiteliales de la córnea, ver Figura 2.2, al igual que mácula por la exposición a longitudes UV y visibles cercanas a la UV. Tanto computadores como smartphones que utilizan pantallas de tipo Light Emitting Diode (LED), producen un pico de intensidad por longitud de onda de 470 nanómetros, según el fabricante. Los estándares internacionales dictaminan que el rango de longitud de onda pueden ser desde 760 nm a 450 nm, en otras palabras, los LEDs azules trabajar al límite de corte de las longitudes de onda de la luz UV, pero se registra que pueden emitir fotones UV por la continuidad del espectro por radiación de cuerpo negro. En consecuencia, las pantallas LED emiten longitudes de onda perjudiciales para el ojo humano [57] [58].




Figura 2.2: Anatomía del ojo frente exposición del espectro de luz UV. Tomado de [1].

Dry Eye Disease

La resequedad patológica de ojos, DED por sus siglas en ingles, se considera como una epidemia emergente, es más común en mujeres y adultos mayores. En promedio un 50 % de los habitantes de algunos países podrían presentar un grado de DED, en niños se encuentra efecto en el desarrollo visual [59]. La hiperosmolaridad, causante de procesos inflamatorios en los conductos del ojo, puede desencadenar DED. El Scientific Committee on Health Environmental and Emerging Risks recomienda 3 horas máximas de exposición a pantallas al día, las personas que exceden este límite comparten el síntoma de resequedad ocular.

Los estudios de laboratorio [57] [58], han demostrado que las longitudes de onda del azul que emiten dispositivos generan irritación en células epiteliales corneales y conjuntivas, impactando en la su morfología y produciendo especies reactivas de oxígeno, como consecuencia se presenta una foto intoxicación celular y el Dry Eye Disease. Estos resultados son bajo niveles altos de luz azul y UV, sin embargo, no se desmerece el contra efecto de usar filtros de luz azul en los dispositivos. Teniendo en cuenta que el mal uso de los filtros está relacionado con alteraciones de ciclo circadiano, daño en la percepción de colores y la visión escotópica.

Miopía y Cataratas

En los últimos años ha existido una discusión sobre los efectos del uso de pantallas en la aparición de miopía y cataratas. Los estudios concluyen que el principal desencadenante de la miopía es el factor genético, y se puede acelerar por el sedentarismo y la distancia a la que se sostiene el dispositivo [57]. Sin embargo, existe una correlación importante que apunta a que la miopía puede presentarse en niños menores a 3 años por el uso inadecuado de pantallas [58].

Efectos Psico-Fisiológicos

De igual importancia que las consecuencias físicas, son los posibles efectos neurológicos por la exposición prolongada a pantallas de dispositivos inteligentes. El ciclo circadiano se regula naturalmente por los niveles de luz, así como la secreción de hormonas que permiten el correcto desempeño cognitivo y emocional a lo largo del día. Existen distinciones de las repercusiones por género y actividad [60]. El cuerpo, estimulado por la oscuridad, incrementa la producción de melatonina entre 8 pm- 11 pm, con un pico alrededor de las 3 am. Para que este proceso se pueda dar con normalidad se necesitan menos de 300 lux, como consecuencia el uso de pantallas (+2 horas) repercute contra la somnolencia de los usuarios al anochecer [57].

Además, se ha registrado que las luces LED generan en el cerebro un estado de alerta y un aumento en los niveles de estrés. También en, [61] se concluye que el uso continuo y sin interrupciones de dispositivos electrónicos fue un factor de riesgo que puede desencadenar estrés y trastornos del sueño en los hombres, en las mujeres los síntomas fueron trastornos del sueño y síntomas de depresión.

Trastornos Músculo Esqueléticos

Los Trastornos Musculoesquelético (TEM) son trastornos comunes de los músculos, huesos, nervios y otros sistemas debido a condiciones de trabajo poco ergonómicas[26]. Los TEM concernientes al trabajo se han convertido en objeto de preocupación en varios países, debido a que el número de trabajadores con desórdenes relacionados ha incrementado en los últimos años. Creando un problema de salud pública debido a que produce días de ausentismo laboral y baja productividad [2][50].

Según el reporte de la Organización Mundial de la salud OMS [62], los problemas musculoesqueléticos se presentan principalmente con dolor (pudiendo ser persistente), disminución los rangos de movilidad y la destreza, en consecuencia la capacidad laboral de las personas disminuye. Algunas afecciones musculoesqueléticas [62], son:

- En articulaciones, osteoartritis, artritis reumatoide, artritis psoriásica, gota, espondilitis anquilosante,
- De tipo óseo, osteoporosis, osteopenia y fracturas por fragilidad asociadas, fracturas traumáticas,
- Músculos, sarcopenia,
- La columna vertebral, lumbalgia y cervicalgia.

Estos trastornos están presentes en varios sectores de la actividad profesional, incluyendo a los administrativos como académicos o en general la población que debe mantenerse por tiempos prolongados frente a su computador. Debido a que existen alrededor de 150 trastornos que afectan al sistema locomotor [62], los factores que intervienen en la aparición de los

TEM son estudiados desde diferentes puntos de vista. Tales como biomecánico, fisiológico y epidemiológico sin que se logre un consenso sobre los elementos y relación que exige cada trabajo con los TEM.

En el caso de la población que trabaja mayoritariamente con visualización de datos, se deben considerar las posiciones del computador, dimensiones de escritorio y silla. La posición y soporte de las muñecas ayudados por un teclado y mouse. Caso contrario, se presentará un aumento en la probabilidad de desarrollar TEM debido a digitaciones incómodas, posiciones articulares sostenidas y extremas de hombros, codos y manos [26, 63, 64]. A continuación, se resumen algunos problemas musculoesqueléticos generados por la exposición prolongada frente a computadores.

Las Trastornos Musculoesquelético se desarrollan gradualmente según cada persona, a medida que pasa el tiempo generan dolencias que pueden terminar en pérdida de funcionalidad. Algunos de los TEM mencionados en el sector administrativo y académico son [63]: distensiones, artritis, artrosis, tendinitis, bursitis, dolor, atrofia muscular, entumecimiento, síndrome del túnel carpiano, fatiga muscular, lumbalgias, tirantez en la nuca, entre otros. Las adecuaciones del lugar de trabajo son un factor de riesgo determinante para que se adopten posturas nocivas y como consecuencia aparezcan síntomas de dolor en las extremidades superiores y en la parte superior e inferior de la columna. En [63], se registra que tan solo el 30 % de los trabajadores cuentan con mobiliario y equipos de cómputo aptos para el trabajo prolongado.

Entre los inconvenientes más comunes se encuentra la Omoalgia (Síndrome del hombro doloroso) y Dorsalgia (dolor interescapular), debido a que el hombro es un conjunto amplio de músculos, tendones, ligamentos y huesos funcionando en una pequeña área se encuentra expuesto a diversas molestias por la postura del trabajador TEM [26]. Cuando existen actividades repetitivas, como es en el caso de trabajar frente a un computador, que exige el gaste excesivo de los mismo grupos musculares, se pueden presentar lesiones por esfuerzos repetitivos [2].

Los músculos con mayor actividad son las manos y las muñecas cuando se trabaja en un ordenador, si a esto se suma el sedentarismo y falta de actividad de otros grupos musculares, el esfuerzo físico podría causar pérdida de la fuerza muscular y en consecuencia el debilitamiento de los músculos [64].

En [50], presentan los resultados de un estudio de TEM en participantes del área administrativo; registraron que el 78 % de los hombres reportaron molestias de cuello, en mujeres el 82 %. La percepción de que el origen de sus molestias en cuello es debido al trabajo fue de un 90 % en hombres y mujeres; en el caso de la lumbalgia, el 80 % de hombres y el 83 % de mujeres atribuyen el dolor al trabajo. Así mismo reporta que las molestias en codo o antebrazo esta completamente relacionado al trabajo según los encuestados.

2.1.4. Métodos para la Valoración de Posturas

Existen diferentes metodologías de medición de factores de carga física en el ambiente laboral, estos se clasifican acorde a las herramientas utilizadas, entrevistas, diarios, observaciones o cuestionarios, el investigador ajusta el método según los recursos disponibles y el caso de estudio.

En el caso de las mediciones directas, es necesario contar con sensores electrónicos u optoelectrónicos que brindan un análisis cuantitativo y mayoritariamente precisos. Sin embargo, representan una mayor inversión debido al costo de los equipos calibración y la cantidad de dispositivos requeridos [2]. A demás, los *wearables* pueden presentar molestias en los trabajadores mientras realizan sus actividades. En el caso del registro óptico se debe adecuar el espacio con iluminación adecuada, lo que no siempre es posible.

Para una revisión de tipo cualitativa se aplican cuestionarios o entrevistas, que debido a su bajo costo se emplean frecuentemente. No obstante, la validez de los resultados obtenidos no puede ser totalmente garantizada, en cuanto a las normativas de la elaboración del cuestionario, condiciones y participantes, las valoraciones logradas usualmente no permiten hacer estudios retrospectivos. Aunque, no se desvaloriza la información de característica subjetiva como apoyo en la evaluación de caso.

También entran en este grupo los métodos basados en la observación que, a diferencia de las mediciones con dispositivos electrónicos, no brindan la misma precisión, pero se han popularizado por cuestión de costos y eficacia. Según las circunstancias del estudio, se aplican diferentes métodos, que pueden ir desde lo general a lo más específico. Mediante ello se realizan valoraciones que se acoplan a diversos sectores industriales o administrativos [2]. Estos métodos están basados, principalmente en la secuencia de posturas adoptadas por los trabajadores en su entorno laboral, en vista de que la postura es determinante en varios síntomas de los TEM [62].

Método OWAS

El método Ovako Work Posture Analyzing System (OWAS) presentado en 1978 por un grupo de ergónomos, ingenieros y trabajadores, se utilizó inicialmente en la industria siderúrgica y de construcción. En 1991 se reformó para su aplicación según el esfuerzo realizado. Éste consiste, en la observación de las posturas que adopta el empleado en diferentes labores, a cada postura se le asigna un identificador para el registro. Este código de identificación se compone de 6 dígitos, tres que describen la posición de espalda, brazos y piernas, uno que representa la fuerza realizada, y dos complementarios que identifican la fase de trabajo de la postura registrada [2], ver Figura 2.3.

Se puede conseguir 252 combinaciones para clasificar las posturas del trabajador, esto después de un análisis del trabajo para conocer las características y tiempos de sus fases [2]. Una vez se tiene la clasificación de las posturas, a cada código postural se le agrega una valoración del riesgo o incomodidad, la metodología OWAS valora el riesgo en 4 niveles [65].

A continuación, se valora de manera global el riesgo para las secciones del cuerpo (tronco, brazos y piernas) en un análisis que considera todas las fases de trabajo. Para el registro, se considera la frecuencia relativa de cada fase de trabajo y según esto se determina una categoría de riesgo a cada parte del cuerpo individualmente. Las categorías de riesgo generadas permiten el análisis de cada postura y a su vez, establecer medidas correctivas [65, 66].

Para la aplicación del método se determina un tiempo de observación, usualmente entre 20 a 40 minutos para trabajos con actividades repetitivas. En el caso de trabajos con ciclos de actividad largos o estáticos, se debe tener en cuenta que la muestra obtenida debe ser representativa de todas las posturas y fases de trabajo del empleado. Asimismo, se establece una frecuencia regular para el registro de los datos, este tiempo toma en consideración los lapsos de cambio de posturas del trabajador y de la cantidad de posturas identificadas en un inicio.

En otras palabras, a mayor número de posturas y frecuencia de cambio, mayor frecuencia en el registro de datos. Es importante que la información recopilada sea suficiente para que influya positivamente en la precisión de las valoraciones. También debe considerarse que el error de estimación se incrementa cuando el número de observaciones se reduce. Según [65] el límite de error para 200, 300 y 400 mediciones es respectivamente de 7 %, 6 % y 5 %.

Completadas las etapas de clasificación de fases, periodo de observación y frecuencia de muestreo, se procede a la aplicación del método en el sitio o con registro visual, en la Figura 2.4 se presenta un diagrama ejemplo de la evaluación de cada postura del trabajador. Se debe




Figura 2.3: Códigos para el registro de las posturas y de la fuerza realizada. Basado en [2]

ubicar en la tabla los identificadores correspondientes a las posiciones de brazos, espalda y piernas, el uso de fuerza en esa postura. Finalmente, se le asigna un valor de categoría a cada postura registrada [2]. Se pueden organizar en cuatro categorías siendo cada una:

- Categoría de Acción 1: No se requieren medidas correctivas
- Categoría de Acción 2: Se requieren medidas correctivas en un futuro cercano
- Categoría de Acción 3: Se requieren medidas correctivas tan pronto como sea posible
- Categoría de Acción 4: Se requieren medidas correctivas inmediatas

Los resultados pueden presentarse también mediante una tabla que registre la aceptabilidad de cada postura determinado por el tiempo de exposición de la tarea. En actividades frecuentes, se puede estimar el tiempo que se mantiene esa posición por medio del muestreo [2].

Método REBA

El método Rapid Entire Body Assessment (REBA) Rapid Entire Body Assessment, fue desarrollado en el 2000 con la finalidad de valorar el riesgo del trabajador por permanecer en posturas inconvenientes. Si durante la labor se mantiene una posición incorrecta por largo tiempo o de manera frecuente se produce fatiga y, sin medidas correctivas, se pueden desarrollar problemas de salud [67]. Los TEM son habitualmente relacionados a la carga postural excesiva. Entonces, es importante analizar la carga postural o carga estática como medida de salud en los lugares de trabajo [2].

Evaluación de Posturas												
Espalda	Brazo	1			2			3			Piernas	
		1	2	3	1	2	3	1	2	3	Uso de Fuerza	
1	1	1	1	1	2	2	2	1	1	2		
	2	1	1	1	1	1	1	1	1	2		
	3	1	1	1	2	2	2	2	2	3		
2	1	2	2	1	2	2	1	2	3	1		
	2	2	2	1	2	2	3	2	3	1		
	3	2	2	2	2	2	3	1	1	1		
3	1	1	1	1	2	2	1	2	3	3		
	2	2	2	3	2	2	1	2	3	3		
	3	2	2	3	2	2	1	2	3	3		

Figura 2.4: Códigos para el registro de las posturas y de la fuerza realizada del método OWAS. Basado en [2].

REBA facilita la evaluación grupal de las posiciones que toman los brazos, antebrazo, muñeca, tronco, cuello y piernas. Este método, para su desarrollo, contó con un grupo de ergónomos, fisioterapeutas y enfermeras. Los autores les pidieron valorar varias posturas de trabajo con diferentes esfuerzos y movimientos. Las pruebas estuvieron apoyadas por otros métodos como Rapid Upper Limb Assessment (RULA), Escala de Percepción de Esfuerzo, OWAS y la ecuación de Niosh [67].




Figura 2.5: Mediciones de los ángulos articulares para la puntuación REBA del Grupo A. [2]




Figura 2.6: Mediciones de los ángulos articulares para la puntuación REBA del Grupo B. [2]

Para la aplicación del método, se debe considerar que no se evaluarán secuencias posturales, sino posturas individuales [67]. Se deben escoger las posturas que representen una carga postural mayor, ya sea por el tiempo o frecuencia con la que se ejecuten, también se pueden considerar según la diferencia con relación a una postura base. Una vez identificadas las posturas, se miden los ángulos del cuerpo como se muestra en las Figuras 2.5 y 2.6, se pueden utilizar diferentes herramientas electrónicas, fotografías o in situ con el trabajador [2]. El cuerpo se divide en 2 grupos,

- Grupo A: piernas, tronco y cuello, Figura 2.5;
- Grupo B: brazos, antebrazos y muñeca, Figura 2.6.

La valoración de las posturas se basa en un sistema de puntuaciones de los ángulos formados entre diferentes miembros de los grupos A y B, el método establece como se miden estos ángulos. Después, como se ve en la Figura 2.7, el puntaje global de los grupos se acopla al tipo de actividad muscular, fuerza ejercida o agarre de objetos. Finalmente, se obtiene un valor asociado al riesgo de cada postura, mientras mayor sea la calificación, mayor la probabilidad de padecer de lesiones a nivel musculoesquelético. Al igual que en el método REBA, se otorga un nivel de acción a cada postura, en este caso desde el nivel 0 al 4 [67].

Biomecánica de Esfuerzos Estáticos

La biomecánica asume el cuerpo como una máquina compuesta por palancas y poleas. Las articulaciones funcionarían como punto de apoyo de los huesos largos, como si fuera una palanca. Los músculos pasan a ser la potencia para vencer la resistencia, que serían los pesos de los miembros y una carga sostenida [3]. Con esta analogía, se aplican ecuaciones de la mecánica para determinar las cargas articulares. Las articulaciones soportan los esfuerzos de mantener el peso de los miembros del cuerpo y mantener la postura cuando hay un momento.




Figura 2.7: Diagrama para la puntuación REBA. Basado en [2]

El momento y fuerza se pueden calcular mediante la ecuación (2.1)

$$M = F \cdot d \cdot \sin \alpha \quad (2.1)$$

Siendo M el momento, F la fuerza ejercida por la masa de los miembros del cuerpo involucrado y pesos adicionales en caso de existir y α el ángulo que se forma en la articulación donde se mide el esfuerzo. El análisis de las fuerzas en el codo se ejemplifica en la Figura 2.8, donde:

- C : una carga externa,
- P_p : el peso de la mano y antebrazo,
- R_c : la suma de C y P_p ,
- F_m : Fuerza de contracción del paquete muscular (brazo: bíceps, músculo braquial y braquiorradial),
- M_c : Máxima capacidad de contracción del paquete muscular.

Este método aumenta su complejidad cuando se considera un conjunto más grande de articulaciones, en especial de la zona lumbar. Por ello, se hacen simplificaciones en cuestión de función, disposición o estiramiento muscular, estas características varían según el sujeto por




Figura 2.8: Esquema de momentos y cargas en el codo. Basado en [3]

su composición física. Las modificaciones más comunes para facilitar las mediciones proponen dividir en secciones el tronco, asumiendo que algunas articulaciones permanecen rígidas [3].

Otra de las herramientas son las tablas de parámetros inerciales que varían en cada persona, donde la *masa* de cada segmento se representa como un porcentaje de la masa total de la persona, y se mide con el porcentaje de la longitud del segmento, el cual indica la distancia que hay hasta el centro de gravedad desde el punto proximal. Para las mediciones se dispone también de tablas de estimación de las longitudes de secciones corporales referentes a la altura del individuo [3].

2.1.5. Postura correcta en sedestación


Los principios de la mecánica corporal al sentarse se basan en la alineación corporal, el equilibrio y el movimiento corporal coordinado. Al sentarse los músculos tienden a funcionar mejor en grupos, esta posición permite que los músculos grandes se fatiguen menos a diferencia de los músculos pequeños, pero siempre se encuentra con una ligera contracción [68]. La estabilidad de la persona será óptima cuando la base sobre la que se sienta sea ancha y con centro de gravedad bajo, además desde el centro de gravedad cae una línea perpendicular a la base de sustentación [4]. Para mantener una postura el cuerpo realiza un equilibrio de fuerzas, lo que equivale al esfuerzo muscular, para mantener la postura, se genera un gasto energético; por ejemplo, la postura basal en sedestación, que consume $+0.25 \text{ KJ/min}$, la mientras que una postura con inclinación aumenta el gasto a $+0.63 \text{ KJ/min}$ [68, 69].

Varios autores han establecido ángulos de Confort para calificar la postura de sedestación en rangos que disminuyan la probabilidad de padecer síntomas de TEM, la Tabla 2.1 presenta los ángulos de confort de Wisner para la actividad mientras se está sentado [69]. Las Figuras 2.9, 2.10 y 2.11 grafican los rangos de movimiento especificados para las extremidades superiores, el tronco y extremidades inferiores respectivamente. En la Figura 2.12 se visualiza una representación gráfica del conjunto de los ángulos para mejor comprensión [4].


Tabla 2.1: Ángulos de Confort de Wisner para la actividad en sedestación.

Definición	Ángulo	Límites
Eje tronco-vertical	1	10° - 20°
Eje tronco-eje cadera	2	90° - 100°
Eje cadera-eje pierna	3	95 - 120°
Eje pierna paralela al suelo	4	90 - 110°
Eje brazo-vertical (flexión)	5	10 - 35°
Eje brazo-vertical (abducción)	5	8 - 30°
Eje brazo-antebrazo	6	80 - 160°
Eje antebrazo-eje mano (flexión)	7	180 - 190°
Eje antebrazo-eje mano (incl. lateral)	8	170 - 190°


Flexión de Codo




Flexión de Hombro



Rotación interna del Hombro



Extencion de Codo



Extencion de Hombro



Figura 2.9: Ángulos de Confort extremidades superiores. Tomado de [4].

Flexión de Tronco




Extensión de Tronco




Figura 2.10: Ángulos de Confort tronco. Basado de [4].

Flexión de Cadera



Extensión de Cadera



Flexión y extensión de pierna





Figura 2.11: Ángulos de Confort extremidades inferiores. Basado de [4].



2.2. Monitoreo y Seguimiento del Esqueleto Humano

En las dos últimas décadas la demanda de dispositivos de reconocimiento y seguimiento postural y facial humano ha incrementado exponencialmente. Inicialmente estos dispositivos se desarrollaron en el ámbito del entretenimiento, facilitando la animación de películas o la inmersión a la realidad virtual de videojuegos. El potencial de esta tecnología provocó un rápido esparcimiento de la herramienta hacia otros campos de investigación, en consecuencia, los costes de adquisición bajaron gradualmente. En general, según la revisión bibliográfica, los dispositivos se dividen en cuatro tecnologías para ST: electromecánicos, electromagnéticos, inerciales y ópticos, los que se describen a continuación.

2.2.1. Inerciales

Los sistemas de sensores inerciales Inertial Measurement Unit (IMU), se componen por una serie de sensores, acelerómetros triaxiales, giroscopios o magnetómetros. Se caracterizan por procesar tres ejes de movimiento (frontal, coronal y transversal) de manera simultánea, además, funcionan con pequeños voltajes. Estos sistemas se consideran invasivos, debido que deben ser colocados estratégicamente en partes del cuerpo que se quieran monitorear [70]. Cuando existen múltiples sensores inerciales es importante considerar una sincronización óptima para evitar errores en la medición de la posición, sin embargo, presentan una ventaja a la hora de medir datos de aceleración y orientación.

2.2.2. Electromecánicos

Los sistemas de captura de movimiento de tipo electromecánico se caracterizan por el uso de trajes adaptados al cuerpo compuestos por sensores mecánicos, usualmente potenciómetros conectados por barras metálicas. Este mecanismo permite medir los movimientos angulares del cuerpo sin considerar el desplazamiento del individuo ni rotaciones complejas de las articulaciones. Su uso se ve restringido a escenarios específicos, normalmente en el entretenimiento, para animaciones [71].

2.2.3. Electromagnéticos

Los sistemas electromagnéticos se conforman por un conjunto transmisores, receptores, una unidad central de procesamiento y un software para representar los datos. El funcionamiento se basa en la generación de un campo electromagnético de baja frecuencia con el transmisor. Luego los sensores ubicados en el cuerpo del individuo reciben la señal, a partir de ello, calculan la posición y orientación de cada sensor. La información es enviada a la unidad central y se presentan los datos en un ordenador. A pesar de que el costo de los dispositivos es menor que otros métodos, su mayor desventaja es el excesivo procesamiento computacional requerido para su uso en tiempo real [72].

2.2.4. Ópticos

Existe una gran diversidad en los sistemas ópticos, en general funcionan con una o varias cámaras que determinan la posición del individuo por inferencias de las proyecciones. Una de las mayores ventajas es la posibilidad del monitoreo en tiempo real y el uso de grabaciones

para el post procesamiento. Para el uso de este método, los primeros sistemas utilizaban marcadores para mejorar la precisión, algunos de ellos luminosos para entornos oscuros. Para su funcionamiento se colocan marcadores en diversas articulaciones del cuerpo, así, los sensores de imágenes calculan la posición espacial y orientación de cada uno respecto al resto [73]. Los sistemas más modernos complementan las cámaras de video con un conjunto de sensores, permitiendo capturar la profundidad a la que se encuentra un elemento o individuo, sin la necesidad de marcadores. El funcionamiento de las cámaras de profundidad se estudia en la Sección 2.3. Actualmente, los programas de visión artificial, potenciado por la Inteligencia Artificial presentan diversas soluciones para el monitoreo del cuerpo o rostro humano [74]. Existen algunos frameworks que facilitan el desarrollo de aplicaciones de seguimiento, por ejemplo:

- OpenPose

Sus desarrolladores, presentaron en 2018 un sistema de código abierto para el seguimiento corporal multi-persona 2D en tiempo real de alta precisión. Su arquitectura predicción supervisada permite detectar 120 puntos estratégicos en el cuerpo, manos, pies y rostro. Dependiendo de los requerimientos se pueden optar hasta 25 puntos en el cuerpo y pie, y 70 en el rostro [74].

- OpenCv

Open Source Computer Vision (OpenCV) (Open Source Computer Vision) es una librería de código abierto para la visión artificial y machine learning, cuenta con más de 2500 algoritmos para la infraestructura de aplicaciones de identificación y seguimiento de personas u objetos, categorización de tareas, modelos 3D, edición de fotografía y reconocimiento de escenarios. OpenCV es utilizado por varias empresas, Google, Microsoft, Zeite y Honda son algunos ejemplos [75]. Ejemplos de uso localmente pueden verse en [76, 77].

2.3. Cámaras de profundidad 3D

Las cámaras de profundidad comprenden una serie de componentes que permiten la grabación de escenas y sonidos, su mayor ventaja son los sistemas de percepción de profundidad, lo que las convierte en una herramienta muy útil en el desarrollo de aplicaciones de realidad virtual, seguimiento de personas o modelado 3D [78]. Algunos de los sensores, dependiendo de la marca y modelo [79, 80], con los que viene equipados son:

1. Micrófonos, se componen por dos o más micrófonos, para aplicaciones que requieran acciones por comando de voz, además permiten localizar en donde se origina el sonido dentro de una habitación.
2. Cámara RGB, son dispositivos que disponen de un sensor que mide la capacidad de luz dentro del espectro visible en tres colores primarios, aquí las marcas ofrecen distintas capacidades de resolución, filtrado, velocidad de muestreo y compatibilidad.
3. Proyector Láser, usualmente difractados para la proyección de patrones, se controla el nivel de temperatura debido a que el nivel y longitud de onda deben ser constantes.
4. Sensor infrarrojo, en el mercado se encuentran distintas capacidades de resolución, fps programables, filtrado, ángulos de campo de visión, etc. La elección dependerá de los requerimientos del proyecto.

2.3.1. Sensores de Profundidad

Los sistemas de percepción de profundidad tienen como base tres módulos: emisor láser infrarrojo y sensor infrarrojo, microcontrolador para el procesamiento de datos [5]. El emisor se proyecta en un área y el sensor recepta las señales reflejadas en las superficies, se calculan las distancias en función del tiempo de viaje del pulso de luz (ida y regreso) conocido como Time-of-Flight (ToF). Existen dos tipos de sensores ToF:

- Light Detection And Ranging (LiDAR), un sensor ToF puntual montado en un mecanismo de escaneo bidimensional.
- Matrix ToF, estiman la profundidad en un solo disparo utilizando una matriz de sensores ToF, pueden ser CMOS o CCD acoplados a un sistema de lentes [81].

Para determinar las posiciones y forma de los objetos se proyectan patrones (pseudo-aleatorios pero constantes) de puntos de luz y, mediante la triangulación de la distorsión que percibe el sensor del patrón de puntos, se obtiene información de los objetos [78]. En otras palabras, el sistema establece un plano de referencia sobre el cual está proyectado el patrón de puntos, cuando un objeto está a una distancia x de este plano de referencia, el sensor de la cámara registra que el patrón está distorsionado. Esta alteración se interpreta como el desplazamiento de los puntos. Las distancias se calculan con triangulación, que correlaciona el patrón del plano referencia y los puntos de la imagen capturada [5].




Figura 2.13: Esquema de la triangulación empleada para obtener el valor de profundidad desde la disparidad captada por el sensor. Tomado de [5]

La Figura 2.13 describe gráficamente este proceso [5], en base a ello la disparidad se presenta como una medida de profundidad inversa. En este sentido, valores mayores implican menores distancias, pero mediante un offset, como en la ecuación (2.2) se normalizan los valores y el valor crece con la distancia.

$$d' = d_{\text{offset}} - 8d \quad (2.2)$$

La aplicación que compete a este documento es la obtención de coordenadas espaciales de las articulaciones y puntos clave del cuerpo humano, las cámaras de profundidad 3D se puede equipar con SDK especializados en Skeleton Tracking (ST) para conseguir un monitoreo en tiempo real. Dependiendo de las características del dispositivo y software, la Figura 2.14 muestra las 32 articulaciones corporales que se pueden considerar en la toma de datos [80].




Figura 2.14: Articulaciones del cuerpo humano (32), vistas como coordenadas. Tomado de [6]

2.4. Métodos de Clasificación

La Inteligencia Artificial se deriva en múltiples ramas de desarrollo, entre ellas se encuentra el ML, que a su vez se desprenden varias opciones como el Deep Learning (DL). En general ML se refiere a los sistemas capaces de aprender basados en el set de datos, sin requerir programación explícita para ello. Estos modelos mejoran su desempeño dependiendo de cantidad de datos utilizados en el entrenamiento, para probar su efectividad después del entrenamiento, se utiliza un nuevo set de datos para analizar las salidas. Se encuentran diferentes modelos de aprendizaje, cuando se tiene un conjunto categorizado de datos que define el tipo de respuesta que se busca, se habla de aprendizaje supervisado. Por el contrario, cuando el set de datos no cuenta con identificadores o etiqueta, es no supervisado.

2.4.1. Redes Neuronales

Las RNN, son modelos para datos en secuencia que permite la retroalimentación por medio de bucles en su estructura que permiten analizar secuencias de tiempo [7]. Así, una neurona se encuentra enlazada a la capa anterior, a la siguiente y también a sí misma, ver Figura 2.15, donde x representa las entradas y y las salidas. Estas neuronas se conectan por medio de vectores de pesos variables que cambian en cada epoch o ciclo. En este modelo la comunicación entre neuronas es más complejo, según sea necesario, para hacer predicciones la información puede intercambiarse hacia adelante en el tiempo [8].




Figura 2.15: Neuronas en una Red Neuronal Recurrente. Basado en [7]

Sus características permiten buenos resultados en la identificación de patrones de estados sucesivos y variantes en el tiempo gracias a su arquitectura [8]. En la Figura 2.16 se muestra la arquitectura básica de una RNN, los retardos Z^{-1} son las salidas de las neuronas del medio, $S_{mn}(t+1)$ retroalimentan a la red y se guarda la información previa. Todos los nodos se conectan por medio de retardos o directamente entre ellos antes de cada capa [7].




Figura 2.16: Arquitectura Red Neuronal Recurrente. Tomado de [8]

2.4.2. Decision Tree Classifier

Los DTC son algoritmos de clasificación de aprendizaje supervisado, se asemejan a un diagrama de flujo donde los nodos y las ramas pueden ser análogamente los atributos y las reglas de decisión, y de ellos se desprenden nuevos nodos respuesta [82]. Desde el nodo superior o nodo raíz, es decir no tiene ramas entrantes, ocurre una partición recursiva. Algunas de sus ventajas son mayor rapidez en el entrenamiento (depende número de atributos y de registros), y transparencia en lógica de la toma de decisiones, no depende de la distribución de probabilidad [83]. Su algoritmo se puede resumir como (ver Figura 2.17):

- Seleccionar un atributo basado en el Attribute Selection Measures (ASM) para dividir los registros.
- El atributo se convierte en un nodo de decisión y el conjunto de datos se subdivide,
- El proceso es reiterativo para cada nodo hijo hasta que pase una de las siguientes:
 - Todas las tuplas tengan el mismo valor de atributo,
 - No existen más atributos,
 - No existan más instancias.




Figura 2.17: Arquitectura Red Neuronal Recurrente. Basado en [9]

Las ASM o reglas de división, permiten crear los criterios de división para un grupo de datos de manera heurística, brindando un puntaje para cada característica, con este valor se decide que atributo pasará a ser un nodo fuente. Dependiendo de la complejidad del árbol de decisión todos los puntos de datos se pueden clasificar o no como conjuntos homogéneos. Los Decision Tree Classifier (DTC) usan atributos para modificar la complejidad, los más comunes son: Information Gain, Gain Ratio y Gini Index [82].

2.4.3. K-nearest Neighbour

K-Nearest Neighbors (k-NN) es un modelo de clasificación de aprendizaje supervisado, las predicciones se basan en la proximidad entre los nodos, donde k es la cantidad de puntos vecinos. Se utiliza para problemas de clasificación y regresión, presentando un mejor desempeño como clasificador [84].

Algoritmo:

1. Se calcula cada distancia entre el nuevo dato con cada ítem del set de entrenamiento.
2. Las k distancias más cortas se seleccionan; la consideración del camino depende de la función que se utilice.
3. La clasificación se realiza por un “voto mayoritario” entre los k vecinos seleccionados, dependerá de su clase
4. Se selecciona los k elementos más cercanos, esta consideración de menor distancia, estará en función del método que se use para su cálculo.
5. Se realiza una **votación por mayoría** entre los k puntos, la clasificación final será según la etiqueta o clase más significativa ver Figura 2.18.




Figura 2.18: Arquitectura k Nearest Neighbors. Tomado de [10]

El valor de k es determinante en la clasificación en las **fronteras** de las clases, y mientras mayor sea, mayor el tiempo que el algoritmo tardará. Los métodos más comunes para calcular la cercanía entre “vecinos” son Distancia Euclidiana o Cosine Similarity; esta última calcula el ángulo de los vectores.

2.4.4. Random Forest Classifier

El RFC es un método ensamblador tipo *Bagging*, es decir, que es una combinación de modelos predictivos (árboles) que mejora la precisión y estabilidad del método. RFC combate algunos errores de sesgo y varianza de los DTC, solución conocida como *trade-off*. Cada clasificador se genera utilizando un vector aleatorio muestreado independiente del vector de entrada. Se genera un voto unitario por cada árbol para la clase más significativa, y así se clasifica un vector de entrada. Ningún árbol ve todos los datos de entrenamiento [84].

El *Bagging* es un método de combinación de clasificadores que permite minimizar el efecto de la varianza en las predicciones, cada modelo tiene distintos subconjuntos tomados del set principal.

El funcionamiento de RFC es el siguiente (ver Figura 2.19).

1. Para un número N de casos en el set de entrenamiento, se toma una muestra aleatoria N_i para construir el árbol A_i .
2. Para M variables de entrada, se selecciona un número m de variables aleatorias, tal que $m < M$; la división óptima de estos m atributos se utiliza para ramificar el árbol; m es constante durante el proceso de ramificación del bosque completo.
3. No hay procedimiento de poda, cada árbol crece hasta su máxima extensión.
4. Los nuevos atributos se predicen a partir de la adición de las predicciones de los árboles generados hasta ese momento, por ejemplo, la clasificación se realiza por mayoría de votos y se promedia para regresión [85].

2.4.5. Gradient Boosting Classifier

Los modelos tipo ensamble *Boosting*, se compone de múltiples modelos simples de manera secuencial, así cada modelo aprende de los errores del anterior, conocidos como *weak learners*. El resultado final comprende los valores de todas las predicciones o de la clase más significativa, similar al *Bagging*. Los algoritmos de tipo boosting se identifican por la cantidad de




Figura 2.19: Arquitectura Clasificador Random Forest. Tomado de [11]

hiperparámetros, estos valores se calculan mediante una validación cruzada según el número de *weak learners* y *learning rate* (determina la influencia de cada weak learner) [86].

El GBC es una combinación de Decision Tree Classifier individuales que se entrenan secuencialmente, permitiendo que los nuevos árboles mejoren los errores de sus predecesores. Las observaciones de los árboles individuales se distribuyen por bifurcaciones individualmente, creando la distribución del árbol hasta que llegan a un nodo terminal. Así la nueva predicción es obtenida añadiendo todas las predicciones de cada uno de los árboles que forman toda la estructura del modelo [84], ver Figura 2.20.




Figura 2.20: Esquema del Clasificador Gradient Boosting. Tomado de [12]

En otras palabras, GBC considera posible mejorar el rendimiento del modelo siguiente, combinándolo con los modelos anteriores y tener un error de predicción menor. En el modelo, cuando un cambio en la predicción de un caso genera una disminución significativa del error, entonces el resultado objetivo para el siguiente caso es un valor alto. Caso contrario si el cambio no provoca ningún cambio el siguiente resultado objetivo será cero. El modelo obtiene este nombre debido a que los resultados objetivos de cada caso se establecen con la función del gradiente del error con respecto a la predicción [87].

3. Prototipado de un Sistema de Monitoreo y Clasificación de Postura en Sedestación en Tiempo Real

Este capítulo describe el proceso del prototipado del Sistema de Monitoreo y Clasificación de Postura en Sedestación en Tiempo Real (SIS-MC-PSTR). Se comienza con una etapa de observación, para determinar cinco posiciones en sedestación frente a una computadora. La captura de los datos espaciales se realiza en un escenario controlado mediante el uso de una cámara de profundidad. Las librerías de NuiTrack en Python [88], servirán de middleware para la gestión de los datos de la cámara. Luego, se calculan los ángulos corporales para ser almacenados en un archivo .csv, el mismo que se usa como conjunto de datos para el entrenamiento del SIS-MC-PSTR. Se utilizan tres clasificadores Recurrent Neural Networks (RNN), Gradient Boosting Classifier (GBC) y Random Forest Classifier (RFC). El prototipo une el resultado de los clasificadores con la detección de la postura en tiempo real y finalmente se realizan las pruebas de funcionamiento.

3.1. Metodología

Este documento se acoge a la modalidad de Propuesta Tecnológica o Prototipo, para ello se ha revisado la bibliografía pertinente para escoger la metodología acorde a la propuesta. Se utilizan las Metodologías Gorschek [89] y Goudswaard [90] como base del desarrollo del prototipo, apoyados en las herramientas Prototyping Canvas y Prototyping Planner [91, 92].

El modelo creado por Goecshek [89] recalca la importancia de construir una evidencia alrededor del desarrollo del prototipo y la documentación de cada etapa del proceso hasta llegar a los resultados, esto además de la generación de conclusiones y el prototipo físico. Este proyecto se acoge a los cinco primeros pasos del modelo, que son: i) buscar las necesidades en la industria; ii) formulación del problema; iii) formulación de una solución candidata; iv) validación de laboratorio; v) validación dinámica. El esquema completo se presenta en el Anexo ??.

En la Metodología Goudswaard [90] se establece el prototipado bajo una perspectiva de fungibilidad, donde el método debe acoplarse de la mejor manera al contexto del proyecto. Además, priorizando la generación de *dimensiones* de conocimiento, las cuales pueden ser funcionamiento, recursos, diseño, proceso de creación, configuración o explicación. Se combina esta metodología con la anterior para extender la tercera etapa: Formulación de la solución.

Acorde a las necesidades del proyecto se adaptó y construyó el modelo de la Figura 3.1, en base a [89], también se especifica los documentos generados de la etapa 3, en base a [90].




Figura 3.1: Metodología para el Prototipado de un Sistema de Monitoreo y Clasificación de Postura en Sedestación en Tiempo Real SIS-MC-PSTR.

3.2. Identificación y Selección de Posturas

Para la identificación de las posturas, según la bibliografía revisada y en acompañamiento de un profesional de fisioterapia, se establecieron los lineamientos base para la clasificación de las posturas. Partiendo del concepto de la postura correcta, se identificaron las principales falencias en las posiciones que adoptan las personas al trabajar frente a un computador. Para esclarecer este proceso se utilizó el método OWAS, con algunas adaptaciones al caso de un individuo en sedestación frente al computador [2].

Debido a que es poco probable que la persona levante sus brazos completos por encima del nivel de hombros, solo se considera la flexión de codos como movimiento de los brazos, ver Figura 2.9. El monitoreo es específico para sedestación, así que el movimiento de las piernas se reduce a la extensión de piernas, ver Figura 2.11. Se desprecia la carga de trabajo, a pesar

de que el gasto energético de las configuraciones musculoesqueléticas es distinto en cada postura [3, 69], no está contemplado en esta tesis analizar su biomecánica.

Después de aclaradas las consideraciones sobre la aplicación del método de clasificación de posturas OWAS, se presentan en la Tabla 3.1 los códigos de las posiciones para cada una de las secciones del cuerpo.

Tabla 3.1: Códigos de posiciones para las secciones del cuerpo de una persona en sedestación frente a un computador. Basado en la metodología OWAS

Códigos de Posiciones por Sección del Cuerpo		
Sección	Código	Posición
Espalda	E1	Erguida
	E2	Inclinada hacia adelante
	E3	Inclinada hacia atrás
	E4	Girada o Inclinada hacia un lado
Brazos	B1	Ambas manos por debajo de los hombros
	B2	Una o ambas manos por encima del nivel del hombro
	B3	Una o ambas manos soportando la cabeza
Piernas	P1	Sentado con pies plantados
	P2	Sentado con piernas o pies cruzados o extendidos

Una vez establecidos los parámetros, se procedió a completar la Tabla 3.2, que recopila las diferentes conductas corporales de una persona en sedestación mientras trabaja frente al computador. En este análisis no se incluye distinciones por la ergonomía o falta de ella en los espacios de trabajo. Apoyado en la observación del comportamiento del voluntario del caso de estudio mientras trabajaba frente su ordenador y recomendaciones del especialista en fisioterapia, se consideraron 13 posturas diferentes siguiendo la Tabla de la metodología OWAS basada en la Figura 2.4. Estas posturas fueron elegidas debido a que son las posiciones naturales más repetitivas o que se adoptan por mayor cantidad de tiempo.

Tabla 3.2: Descripción de las posturas más comunes en sedestación frente a un computador.

Evaluación de Posturas						
Piernas	Brazos	E1	E2	E3	E4	Espalda
		1	1	1	1	Uso de Fuerza
P1	B1	x	x	x		
	B2	x				
	B3		x		x	
P2	B1	x	x	x	x	
	B2					
	B3	x	x		x	

Continuando con la metodología OWAS, a cada postura se le asignó una categoría de fase de trabajo; se establecieron tres etapas globales de actividad laboral:

- 01: Visualización de datos;
- 02: Digitación;
- 03: Concentración.

La Tabla 3.3 presenta el resultado de las posturas y fases de trabajo frente a un computador. En cada columna se muestra el número que identifica la postura de espalda, brazos y piernas según la Tabla 3.1, por ejemplo el código 1 – 1 – 2 se refiere a espalda erguida, ambos manos por de bajo del nivel de los hombros y sentado con los pies plantados. Esta información brinda un mayor entendimiento del contexto para el caso de estudio y los requerimientos.

Tabla 3.3: Recopilación de las posturas en sedestación frente a un computador y fases de trabajo.

Posturas Identificadas por códigos				
Espalda	Brazos	Piernas	Uso de Fuerza	Fase de Trabajo
1	1	1	1	0 2
1	1	2	1	0 2
1	2	1	1	0 1
1	3	2	1	0 3
2	1	1	1	0 2
2	1	1	1	0 3
2	1	2	1	0 2
2	3	1	1	0 3
2	3	2	1	0 3
3	1	1	1	0 2
3	1	2	1	0 2
4	1	2	1	0 1
4	3	1	1	0 3
4	3	2	1	0 1

Partiendo de la Tabla 3.3, se buscaron las principales variables de observación. Se determina que la posición de la espalda es una variable influyente para diferenciar las posturas. En la Tabla 3.4, se definen las categorías de clasificación de posturas en sedestación para el desarrollo del prototipo.

Tabla 3.4: Clasificación de posturas en sedestación frente a un computador. Basado en la metodología OWAS

Clasificación de posturas para el desarrollo del prototipo	
A	Postura Correcta
B	Inclinación hacia adelante
C	Inclinación hacia atrás
D	Sostener Cabeza
E	Inclinación lateral

3.2.1. Detalle de las Posturas

Se debe considerar que el uso de la metodología OWAS permite analizar las posturas estáticas del trabajador, mas no los rangos de movimiento de articulaciones o puntos clave del cuerpo. Es necesario, para el desarrollo del SIS-MC-PSTR, definir con mayor detalle los “límites” de cada postura en la Tabla 3.4.

Se utiliza la metodología REBA para delimitar las características de cada postura. El método permite calificar las posturas del trabajador dependiendo del ángulo del torso, cuello, piernas, brazos y antebrazos [2]. Adaptamos este método a las necesidades del prototipo y basándonos en los ángulos de confort de Wisner [69]. Además se utilizaron las Figuras 2.5 y 2.6 como guías.

En la Tabla 3.5 se detallan los rangos de movimiento del tronco acorde los ángulos de confort, donde el código 1 representa la posición adecuada. Ver Figura 3.2 B. Para mayor detalle ver Figuras 2.5 y 2.10.

Tabla 3.5: Codificación de los rangos de movimiento para los ángulos articulares del Tronco en sedestación frente a un computador.

Descripción Ángulos Articulares del Tronco	
Código	Rango de movimiento
1	0° a 10° extensión y 0° a 20° flexión
2	> 20° flexión
3	< 10° extensión
Si adicional existe inclinación lateral 5°	
4	0° a 10° extensión y 0° a 20° flexión
5	> 20° flexión
6	< 10° extensión

La Tabla 3.6 presenta la descripción del rango de movimiento del cuello, no hay distinción de clase en caso de existir giro de la cabeza. No se considera la extensión del cuello debido a que no es una postura frecuente según la observación. Ver Figura 3.2 A, para mayor detalle ver Figuras 2.5 y 2.9.

Tabla 3.6: Codificación de los rangos de movimiento para los ángulos articulares del Cuello en sedestación frente a un computador.

Descripción Ángulos Articulares del Cuello	
Código	Rango de movimiento
1	0° a 20° flexión
2	> 20° flexión
Si adicional existe inclinación lateral 5°	
3	0° a 20° flexión
4	> 20° flexión




Figura 3.2: Ángulos considerados para el cuello y torso.

En la Tabla 3.7 se describe el movimiento de las piernas. Se consideran solamente dos posiciones, donde el código 1 representa la posición adecuada. Para mayor detalle ver Figuras 2.5 y 2.11.

Tabla 3.7: Codificación de los rangos de movimiento para los ángulos articulares de las piernas en sedestación frente a un computador.

Descripción Ángulos Articulares de Piernas	
Código	Rango de movimiento
1	90° a 110° paralelo al suelo
2	Apoyo unilateral o extendidas

La Tabla 3.8 detalla el rango de movimiento de los brazos, en concreto la extensión y flexión del hombro acorde los ángulos de confort. Donde el código 1 representa la posición adecuada. Ver Figura 3.3 A, para mayor detalle ver Figuras 2.6 y 2.9.

Tabla 3.8: Codificación de los rangos de movimiento para los ángulos articulares de los brazos en sedestación frente a un computador.

Descripción Ángulos Articulares de Brazos	
Código	Rango de movimiento
1	0° a 10° extensión y 0° a 35° flexión
2	< 10° extensión
3	> 35° flexión

Finalmente, la Tabla 3.9 presenta el rango de movimiento de los antebrazos, en específico el codo, acorde los ángulos de confort. Donde el código 1 representa la posición adecuada. Ver Figura 3.2 B, para mayor detalle ver Figuras 2.6 y 2.9.

Tabla 3.9: Codificación de los rangos de movimiento para los ángulos articulares de los antebrazos en sedestación frente a un computador.

Descripción Ángulos Articulares de Antebrazos	
Código	Rango de movimiento
1	80° a 120° extensión y 0° a 35° flexión
2	> 80° extensión




Figura 3.3: Ángulos considerados para el brazo y antebrazo.

Una vez detallados los rangos de movimiento de los puntos clave del cuerpo, con ayuda de la Tabla 3.3, definimos para cada clasificación los posibles movimientos de tronco, cuello, piernas, brazos y antebrazos. El objetivo de este procedimiento es crear una guía para generar un conjunto de entrenamiento para el prototipo. Como resultado, se construye la Tabla 3.10. En esta tabla se especifican todas las composiciones de las cinco posturas, por ejemplo, en D (Sostener la cabeza) la posición de la espalda puede ser 1, 2, o 3, que representan erguida, inclinada hacia adelante, o inclinada hacia atrás respectivamente. Referirse a las Tablas 3.5 - 3.9 para identificar los ángulos de cada sección del cuerpo.

Tabla 3.10: Clasificación de las posturas posibles por clase y ángulos articulares en sedestación frente a un computador. Basado en la metodología OWAS y REBA

Clasificación de posturas por clase y ángulos articulares						
COD	Postura	Código de ángulos por Sección del cuerpo				
		Tronco	Cuello	Piernas	Brazos	Antebrazos
A	Postura Correcta	1	1	1	1	1
B	Inclinación hacia adelante	2	1; 2	1; 2	1; 2	1; 2
C	Inclinación hacia atrás	3	1; 2	1; 2	1; 3	1; 2
D	Sostener Cabeza	1; 2; 3	1; 2	1; 2	3	2
E	Inclinación lateral	4	1; 2	1	1; 2	1; 2
		5	1; 2	1; 2	1; 2	1; 2
		6	1; 2	1; 2	1; 3	1; 2

3.3. Selección de Tecnologías de Skeleton Tracking y Recursos

El prototipo está orientado hacia el uso de sensores ópticos y de profundidad, para ello se realizó una búsqueda comparativa del mercado para establecer las opciones más convenientes que permitan la viabilidad del proyecto. Así mismo, se realizó una búsqueda para la elección del Software Development Kit (SDK) que permita la gestión del sensor, esta sección presenta un resumen del proceso.

3.3.1. Evaluación de cámaras con sensores de profundidad

La Tabla 3.11 presenta un comparativo de las especificaciones y precios de cámaras de profundidad que cumplen con los requerimientos del proyecto. Existen estudios comparativos de estos dispositivos [93–95], por cuestiones de viabilidad y rango de visión se eligió la cámara Orbbec Astra Pro, ver Figura 3.4



Figura 3.4: Cámara de profundidad Orbbec Astra Pro, seleccionada para el seguimiento de esqueleto.

Tabla 3.11: Comparativo de la selección de Cámaras de profundidad 3D

Comparativo Cámaras de Profundidad 3D			
Especificación	Orbbec Astra Pro	Orbbec Astra S	Intel Real-Sense D415
Rango	0.6m -8m	0.4m - 2m	.5 m to 3 m
FOV	60 °H x 49.5 °V x 73 °D	60 °H x 49.5 °V x 73 °D	65 °Hx40 °V
Resolución de profundidad	640x480 @30fps	640x480 @30fps	1280x720 @90fps
Resolución de imagen RGB	1920 x 1080 @30fps	640x480 @30fps	1920 x 1080 @30fps
Alimentación	USB 2.0	USB 2.0	USB-C 3.1 Gen 1
S.O Compatibles	Android / Linux / Windows7/8/10		
Precio	\$149.99*	\$149.99*	\$272*
*Precio aplica para Estados Unidos, no se consideran gastos de importación			

3.3.2. Evaluación de frameworks para cámaras de profundidad 3D

Existe varios frameworks que permiten la gestión de las cámaras de profundidad, la búsqueda se dirigió con los siguientes requerimientos: compatibilidad con la cámara Orbbec Astra Pro y el sistema operativo Windows 10/11, seguimiento para posturas en sedestación y, que ofrezca opciones de escalabilidad para futuros trabajos. Las opciones seleccionadas fueron Orbbec Body Tracking SDK y NuiTrack AI. Se descartó el SDK de Orbbec debido a que no entrega la información suficiente de sus requerimientos o funcionalidades [96]. La opción que se encontró más conveniente para el proyecto es el SDK NuiTrack AI, la arquitectura se adjunta en el Anexo ???. Este framework, según su página[88], ofrece:

- Procesamiento de datos RGB+3D;
- Seguimiento esquelético de cuerpo completo, en total 19 articulaciones para cada persona (ver Tabla 3.12), seguimiento de rostro con detección de edad y emoción;
- Plataformas de hardware: x64, x86, ARMv7, ARMv8;
- Lenguajes de desarrollo: C++, C#, Python, Unity, Unreal.

Tabla 3.12: Detalle de los 19 puntos clave y articulaciones del seguimiento de esqueleto de Nuitrack

Puntos de Detección de Nuitrack		
Puntos Clave	Lado Derecho	Lado Izquierdo
Cabeza	Hombro	Hombro
Cuello	Codo	Codo
Torso	Muñeca	Muñeca
Cintura	Mano	Mano
Clavículas	Cadera	Cadera
	Rodilla	Rodilla
	Tobillo	Tobillo

La empresa especifica que no hay requisitos estrictos para el rendimiento del hardware con Nuitrack, debido a que el uso de RAM es inferior a 200 MB. Añade que, para los procesadores de escritorio, se requiere soporte para el conjunto de instrucciones AVX. Para el desarrollo del prototipo se cuenta con una computadora con las siguientes especificaciones:

- Procesador: AMD Ryzen 5 3500U con Radeon Vega Mobile Gfx 2.10 GHz;
- RAM: 8.00 GB;
- Disco 480 GB SSD;
- Sistema Operativo: Windows 11 Pro.

Además, se adquirió un trípode para el soporte de la cámara con las siguientes características:

- Altura máxima - 1570 mm y Altura mínima - 560 mm;
- Soporte para cámara fotográfica y video con cabezal de tres cabezas.

En la Figura 3.5 se presenta el esquema final de los componentes principales adquiridos para el desarrollo del prototipo.

Software de Captura y Clasificación de Posturas en Sedestación




Figura 3.5: Esquema de los componentes de hardware y software para el prototipo de seguimiento de postura en sedestación.

3.4. Software de captura de postura en sedestación

En la anterior Sección se definieron los componentes de software y hardware que se utilizan para el prototipo, Figura 3.5. En este apartado se presentan las pruebas para determinar la ubicación de la cámara, el funcionamiento del programa de captura, y la creación del conjunto de datos.

En las primeras pruebas existieron problemas de funcionamiento de la cámara, se determinó que fue debido a que la capacidad de procesamiento de la máquina disponible resultó insuficiente para poner en marcha todas las características del SDK Nitrack. Este problema se solucionó reduciendo la resolución de profundidad a un ciclo de 28 frames por segundo y desactivando el modo RGB de la cámara.

El software permite ajustar la resolución de profundidad según sea necesario, para computadores con menor procesamiento esta característica resulta útil para aliviar la carga computacional. Para este estudio se utiliza el máximo posible, debido a que es un prototipo y es de interés considerar el mayor número de capturas para la etapa de clasificación en tiempo real.

3.4.1. Ubicación de la cámara

El programa de captura de posturas tiene como finalidad crear un *data* para el entrenamiento en la siguiente etapa. Para que los datos adquiridos sean de utilidad, se ha realizado una serie de pruebas que permitan definir el escenario para la toma de datos. Se toma en consideración las recomendaciones dadas por el sitio del SDK Nuitrack [97]:

- Condiciones de iluminación, se recomienda que el área no tenga luz solar directa en el campo de visión del sensor.
- Asegurarse de que la persona tenga suficiente espacio para moverse sin tocar las paredes a los lados y en la parte posterior de la habitación. Debe haber al menos una distancia de 40 centímetros de las paredes y el techo.
- El sensor debe colocarse mirando directamente hacia adelante y paralelo al suelo
- Evitar la ropa oscura, esto puede afectar el seguimiento
- Se recomienda que la altura óptima para ubicar el sensor es entre $0.8m$ a $1.2m$ y una distancia mínima desde el sensor de $D = 1.5m$.

El fabricante no menciona si la ubicación de la cámara se considera para una persona sentada, por este motivo, se realizaron unas pruebas para definir un rango adecuado. La Figura 3.6 muestra la vista de la cámara ubicada a la altura y distancia recomendada.




Figura 3.6: Prueba de visualización de la cámara ubicada a $1.7m$ y $85cm$ de altura.

Se adecuó un escenario controlado (ver Figura 3.7) que facilite las pruebas de ubicación de la cámara con el trípode. La toma de datos conlleva un tiempo considerable, por lo que se simplificó el mobiliario según la disponibilidad del espacio y el tiempo del voluntario. El banco se encuentra ubicado a más de $40cm$ de la pared. Se ha preferido un banco, es decir sin espaldar ni soportes laterales, para que no interrumpa la visualización, la prioridad del entrenamiento será capturar claramente las ubicaciones de cada punto. Se adicionó un panel negro de fondo para crear mayor contraste con la ropa del voluntario, además de una guía en el suelo con marcas cada $10cm$. Las mediciones son tomadas desde el límite frontal del banco hasta el centro del trípode como se muestra en la Figura 3.7.




Figura 3.7: Escenario para pruebas de ubicación de cámara y captura de datos.

En la Figura 3.9 se muestra una serie de capturas vistas con la cámara desde diferentes distancias y alturas. En base a las pruebas, se determina que la distancia mínima entre el banco y la cámara es de $D = 2.40m$ y el rango de altura puede ser de $A_t = 0.6m$ a $A_t = 0.75m$ (medidos desde el suelo a la base de la cámara). La Figura 3.8 presenta capturas del seguimiento de las articulaciones, cabeza y cuello de la persona con las distancias anteriormente definidas.




Figura 3.8: Pruebas de ubicación de cámara a diferentes distancias y altura, con seguimiento de esqueleto.




Figura 3.9: Pruebas de ubicación de cámara a diferentes distancias y altura.

Una vez establecida la distancia y altura de la cámara, se realizan pruebas desde diferentes ángulos. Esta consideración se realizó debido a que desde la vista frontal el mobiliario representa un obstáculo para el correcto funcionamiento de la cámara. En este caso, se ubica a la persona lateralmente y la cámara se desplaza angularmente de $\alpha = 10^\circ$ a $\alpha = 80^\circ$ (desde la vertical del escenario x a la vertical del banco y), medido desde el borde del banco como se muestra en la Figura 3.10.




Figura 3.10: Escenario para pruebas de ubicación de la cámara a diferentes distancias y altura.




Figura 3.11: Pruebas de ubicación de cámara a diferentes ángulos a una distancia $D = 250\text{cm}$ y una altura $A_t = 60\text{cm}$.

La Figura 3.11 presenta las capturas vistas desde la cámara a diferentes ángulos, el objetivo

es ubicar la cámara de tal forma que permita capturar la cintura escapular y preferiblemente ambas piernas y brazos. Según las fotografías, los ángulos de $\alpha = 10^\circ$ a $\alpha = 40^\circ$ no permiten registrar el lado izquierdo de la persona. Esto se ve reflejado en la Figura 3.12, donde se realizaron pruebas con el sensor de profundidad a una altura $A_t = 60\text{cm}$ y $A_t = 70\text{cm}$ para los diferentes ángulos. El seguimiento del cuerpo permite registrar los puntos de los hombros, pero presenta dificultad en capturar los puntos de las piernas.




Figura 3.12: Pruebas de ubicación de cámara de $\alpha = 10^\circ$ a $\alpha = 40^\circ$, a una distancia de $D = 250\text{cm}$ y alturas de $A_t = 0.6\text{cm}$ y $A_t = 0.7\text{cm}$ con seguimiento de esqueleto.

En el siguiente grupo de fotografías de la Figura 3.11, los ángulos de $\alpha = 50^\circ$ a $\alpha = 80^\circ$ permiten registrar el lado izquierdo de un individuo, como se ve en la Figura 3.13, donde se realizaron pruebas con el sensor de profundidad a una altura $A_t = 60\text{cm}$ y $A_t = 70\text{cm}$ para los diferentes ángulos. El seguimiento del cuerpo registra los puntos de los hombros y piernas, pero presenta dificultad para capturar el punto de la cadera izquierda. Con estas pruebas definimos un rango de $\alpha = 50^\circ$ a $\alpha = 80^\circ$ para ubicar la cámara en la toma de datos. Se debe tener en cuenta que en un escenario real la posición del mobiliario determinará el mejor ángulo de vista para el sensor.




Figura 3.13: Pruebas de ubicación de cámara de $\alpha = 40^\circ$ a $\alpha = 80^\circ$, a una distancia de $D = 250\text{ cm}$ y alturas de $A_t = 0.6\text{ cm}$ y $A_t = 0.7\text{ cm}$ con seguimiento de esqueleto.

Recapitulando, los parámetros de ubicación de la cámara de profundidad para el monitoreo de postura de un individuo en sedestación se presentan en la Tabla 3.13.

Tabla 3.13: Parámetros de ubicación de la cámara Orbbec Astra Pro + trípode para la captura de un individuo en sedestación.

Parámetros de ubicación para la cámara	
Altura desde el suelo a la base	$A_t = 60\text{ cm}$ a $A_t = 75\text{ cm}$
Distancia desde el banco	$> D = 250\text{ cm}$
Ángulo de ubicación	$\alpha = 40^\circ$ a $\alpha = 80^\circ$

3.4.2. Programa de captura

Para el uso de la cámara de profundidad Orbbec Astra Pro es necesario instalar el controlador (dependiendo del sistema operativo del computador) que se encuentra en la página oficial de Orbbec [98]. El SDK Nitrack AI requiere de licenciamiento, el procedimiento de adquisición y activación se encuentran en su sitio de compra. Nitrack ofrece librerías para C++, C#, Python, Unity y Unreal. Este prototipo se ha desarrollado con Python 3.9.12. El procedimiento

Tabla 3.15: Detalle de los ángulos de inclinación considerados en el plano (x,y) para el programa de captura

Programa de Captura - Ángulos de inclinación VISTA LATERAL (x,y)	
Código	Detalle
A1	Cabeza (P1) - Cuello(P2)
A2	Cuello (P2) - Torso (P3)
A3	Torso (P3) - Cintura (P4)
A4	Cintura (P4) - Cadera (P12) - Rodilla (P14)
A5	Hombro (P6) - Codo (P8) - Muñeca (P10)

de instalación de los componentes y librerías necesarias se muestran en el Anexo ??.

Como se revisó anteriormente en este capítulo, en la Tabla 3.12, el middleware NuiTrack permite la extracción de 19 puntos y articulaciones. Según las pruebas realizadas en las Figuras 3.12 y 3.13 el reconocimiento de las piernas en sedestación presenta inestabilidad, sobre todo en los puntos de los tobillos. Por esta razón no se toman en cuenta para el cálculo de los ángulos posturales. También se descartan los puntos de las manos debido a que su posición no es considerada una variable en la Tabla 3.10.

Los puntos considerados para el cálculo de los ángulos que describen la postura de un individuo en sedestación, se detallan en la Tabla 3.14. Estos puntos se extraen a través del SDK NuiTrack como coordenadas reales en x,y,z para ser almacenados en variables. Con esta información se calculan los ángulos proyectados en el plano (x,y) y las proyecciones de los ángulos en el plano (z,y). En la Tabla 3.15 se especifican los diferentes ángulos de inclinación de las proyecciones en el plano (x, y), Figura 3.14. Y en la Tabla 3.16 se describen los ángulos de inclinación de las proyecciones en el plano (z,y), Figura 3.15. Los ángulos calculados en las ecuaciones 3.1 a 3.10 son almacenados en un archivo .csv para cada postura capturada.

Tabla 3.14: Detalle de los 15 puntos clave y articulaciones del seguimiento de esqueleto utilizando NuiTrack para el prototipo de monitoreo en sedestación

Puntos de Detección del Prototipo					
Puntos Clave		Lado Derecho		Lado Izquierdo	
P1	Cabeza	P6	Hombro	P7	Hombro
P2	Cuello	P8	Codo	P9	Codo
P3	Torso	P10	Muñeca	P11	Muñeca
P4	Cintura	P12	Cadera	P13	Cadera
P5	Clavículas	P14	Rodilla	P15	Rodilla

Tabla 3.16: Detalle de los ángulos de inclinación considerados en el plano (z,y) para el programa de captura

Programa de Captura - Ángulos de inclinación VISTA FRONTAL (z,y)	
Código	Detalle
A6	Cabeza (P1) - Torso (P3)
A7	Torso (P3) - Cintura (P4)
A8	Hombro (P6) - Codo Derecha (P8)
A9	Hombro (P7) - Codo Izquierda (P9)
A10	Cadera Derecha (P12) - Cintura (P4) - Cadera Izquierda (P13)




Figura 3.14: Ángulos considerados para la descripción de la postura en el plano (x,y).




Figura 3.15: Ángulos considerados para la descripción de la postura en el plano (z,y).

Para la Figura 3.14 las ecuaciones (3.1) a (3.5) se utilizan para el cálculo de los ángulos, A1 Cabeza (P1) - Cuello(P2). Figura 3.14 A.

$$A1 = 90^\circ - \arctan\left(\frac{P1_y - P2_y}{P1_x - P2_x}\right) \quad (3.1)$$

A2 Cuello (P2) - Torso (P3). Figura 3.14 A.

$$A2 = 90^\circ - \arctan\left(\frac{P2_y - P3_y}{P2_x - P3_x}\right) \quad (3.2)$$

A3 Torso (P3) - Cintura (P4) . Figura 3.14 B.

$$A3 = 90^\circ - \arctan\left(\frac{P3_y - P4_y}{P3_x - P4_x}\right) \quad (3.3)$$

A4 Cintura (P4) - Cadera (P12) - Rodilla (P14). Figura 3.14 C.

$$A4 = \arctan\left(\frac{P4_y - P12_y}{P4_x - P12_x}\right) - \arctan\left(\frac{P14_y - P12_y}{P14_x - P12_x}\right) \quad (3.4)$$

A5 Hombro (P6) - Codo (P8) - Muñeca (P10). Figura 3.14 D.

$$A5 = \arctan\left(\frac{P6_y - P8_y}{P6_x - P8_x}\right) - \arctan\left(\frac{P10_y - P8_y}{P10_x - P8_x}\right) \quad (3.5)$$

Para la Figura 3.15 las ecuaciones 3.6 - 3.10 se utilizan para el cálculo de los ángulos, A6 Cabeza (P1) - Torso (P3). Figura 3.15 A.

$$A6 = 90^\circ - \arctan\left(\frac{P1_y - P3_y}{P1_z - P3_z}\right) \quad (3.6)$$

A7 Torso (P3) - Cintura (P4). Figura 3.15 A.

$$A7 = 90^\circ - \arctan\left(\frac{P3_y - P4_y}{P3_z - P4_z}\right) \quad (3.7)$$

A8 Hombro (P6) - Codo Derecha (P8). Figura 3.15 B.

$$A8 = 90^\circ - \arctan\left(\frac{P6_y - P8_y}{P8_z - P8_z}\right) \quad (3.8)$$

A9 Hombro (P7) - Codo Izquierda (P9). Figura 3.15 B.

$$A9 = 90^\circ - \arctan\left(\frac{P7_y - P9_y}{P7_z - P9_z}\right) \quad (3.9)$$

A10 Cadera Dererecha (P12) - Cintura (P4) - Cadera Izquierda (P13). Figura 3.15 C.

$$A10 = 360^\circ - \arctan\left(\frac{P12_y - P13_y}{P12_z - P13_z}\right) \quad (3.10)$$

Los datos se almacenaron en un archivo .csv para el entrenamiento del sistema.

3.4.3. Creación del conjunto de datos

Para la creación del conjunto de datos, las capturas de ST se realizan variando la ubicación de la cámara tomando las consideraciones de la Tabla 3.13. Además, se añade un punto de observación de manera paralela al individuo, como se muestra en la Figura 3.16, con la finalidad de dirigir la toma de datos. Se utiliza la aplicación *ON 2D Measure* [99] para medir los ángulos de cuello, tronco y antebrazo. Estos datos permiten al observador clasificar las posturas basados en la Tabla 3.10. La Figura 3.17 presenta un ejemplo del uso de esta aplicación para cada clase de postura.

Siguiendo este procedimiento, se realizó la captura del conjunto de datos en el escenario de la Figura 3.16, teniendo como guía la clasificación de posturas de la Tabla 3.10. El programa permite guardar los ángulos calculados de cada postura en categorías mientras se realiza la observación. Para guardar una entrada se presionan las teclas A, B, C, D, o E según corresponda la clasificación. Se recopilaban alrededor de 400 entradas, procurando tener cantidades iguales de datos de cada categoría. El programa se muestra en el Anexo ??.

Es importante recalcar




Figura 3.16: Escenario para la captura del conjunto de datos, con un punto de observación que permite medir los ángulos de un individuo, cámara ubicada a una distancia $D = 250cm$, $A_t = 60cm$ de altura y ángulo $\alpha = 70^\circ$.




Figura 3.17: Medición de ángulos corporales de la postura con *ON 2D Measure* para dirigir la captura del conjunto de datos, en un escenario controlado.

3.5. Programa de Entrenamiento y Clasificación en tiempo real

La etapa de entrenamiento se desarrolla con técnicas de aprendizaje supervisado. Se aplican tres métodos individualmente, para comparar su desempeño posteriormente. El programa (Anexo ??), emplea las librerías de ML y DL de Python, Keras para Recurrent Neural Networks (RNN), y Scikit-learn para Random Forest Classifier (RFC) y Gradient Boosting Classifier (GBC). El tamaño del conjunto de datos para el entrenamiento, después del post-procesamiento, es de 352 capturas, cada una descrita por 10 ángulos.

3.5.1. Red Neuronal Recurrente

En esta etapa, el programa importa el archivo .csv con los datos angulares de cada postura y la categoría a la que pertenecen. Se realiza una limpieza de datos, en caso de que existan valores nulos. El conjunto de datos se divide para el entrenamiento un 80 % y para pruebas el 20 %, además se balancean los datos para utilizar el mismo número de entradas para cada categoría. En la Figura 3.18 se presenta un esquema resumen del proceso seguido para la elaboración de la red neuronal recurrente.




Figura 3.18: Esquema del procedimiento de elaboración de la Red Neuronal Recurrente.

Para la estructura de la red neuronal se utiliza el modelo secuencial, la primera capa tiene una densidad de 500 neuronas, con activación Rectified Linear Activation Function (ReLU) y la dimensión de las entradas corresponde al número de ángulos capturados por imagen, en este caso 10. La segunda y tercera capa tienen una densidad de 100 y 50 perceptrones respectivamente, con activación ReLU. Una de las recomendaciones para evitar el overfitting, es no utilizar capas ocultas en exceso, debido a que el modelo podría memorizar las posibles salidas, en vez de ser flexible y adecuar las activaciones a las entradas nuevas.

La capa de salida tiene una densidad correspondiente al número de clases de posturas definidas, en este caso 5 y utiliza el modelo de activación simoigdal. Una vez establecida la arquitectura (Figura 3.19) de la red se compila y se define la precisión como métrica de eva-

luación del modelo. Finalmente, se entrena la red con 150 epochs, con un resultado de 92 % de precisión, el modelo y los pesos se guardan en dos archivos json.

Layer (type)	Output Shape	Param #
dense (Dense)	(None, 500)	5500
dense_1 (Dense)	(None, 100)	50100
dense_2 (Dense)	(None, 50)	5050
dense_3 (Dense)	(None, 5)	255

Figura 3.19: Arquitectura de la Red Neuronal Recurrente.

La función de activación ReLu aplica una transformación no lineal, activa la neurona solo si el input está por encima de cero, siguiendo la ecuación 3.11.

$$\text{ReLU}(x) = \max(x, 0) \quad (3.11)$$

La función sigmoide transforma valores en el rango de $(-inf, +inf)$ a valores en el rango $(0, 1)$.

$$\text{sigmoid}(x) = \frac{1}{1 + \exp(-x)} \quad (3.12)$$

3.5.2. Gradient Boosting Classifier

Para el modelo GBC en Python se utiliza la librería de Scikit learn, primero se importan y depuran los datos del archivo .csv que contiene los ángulos calculados. Se reparten los datos para el entrenamiento el 80 % y para la validación el 20 %. Antes de probar el GBC, se realiza un test con el DTC y se comprueba la eficacia del modelo. En la Tabla 3.17 se presentan los resultados de precisión con el modelo de árbol cuando el parámetro profundidad máxima se cambia de 1 a 9, la precisión límite que se obtiene es de 90 %, este valor será la línea base para comparar el GBC. En la Figura 3.20 se presenta un esquema resumen del proceso seguido para la elaboración del GBC.




Figura 3.20: Esquema del procedimiento de elaboración para el GBC .

Tabla 3.17: Precisión obtenida con el clasificador por árbol de decisión para diferentes profundidades.

Profundidad máxima	1	2	3	4	5	6	7	8	9
Accuracy	0.41	0.53	0.75	0.84	0.84	0.85	0.9	0.9	0.9

Los parámetros importantes del modelo GBC para definir son: número de estimadores (árboles creados), tasa de aprendizaje y profundidad máxima. Para ello se crea una “grilla” de entrenamiento variando los valores de los parámetros, se utiliza todo el conjunto de datos [100]. De este proceso se obtuvo los valores de la Tabla 3.18. El modelo entrenado obtuvo una precisión del 95.56 %, que supera el valor obtenido con el DTC. Finalmente se realiza un volcado de datos de la memoria para guardar el modelo entrenado.

Tabla 3.18: Parámetros para el GBC para una precisión del 95 %.

Parámetro	Valor
learning_rate	0.1
max_depth	5
n_estimators	500
subsample	0.8

3.5.3. Random Forest Classifier

De manera similar que los anteriores modelos, se importan y depuran los datos de los ángulos calculados, se utiliza un 80 % de los datos para entrenar el modelo y 20 % para pruebas. Los

parámetros del modelo RFC más notables son: número de estimadores (árboles creados), máximo de muestras, que controla el tamaño de las muestras con la que se construye cada árbol, y profundidad máxima. En la Figura 3.20 se presenta un esquema resumen del proceso seguido para la elaboración del RFC.




Figura 3.21: Esquema del procedimiento de elaboración para el RFC .

Para definir los mejores valores crea una “grilla” de entrenamiento variando los valores de los parámetros [101]. De este proceso se obtuvo los valores de la Tabla 3.14. El modelo entrenado obtuvo una precisión del 93.48 %, que supera el valor obtenido con el DTC. Finalmente se realiza un volcado de datos de la memoria para generar un archivo del modelo entrenado.

Tabla 3.19: Parámetros para el RFC para una precisión del 93 %.

Parámetro	Valor
max_sample	100
max_depth	5
n_estimators	100
random_state	15

3.5.4. Clasificación en tiempo real

Este programa se puede definir como la unión del programa de detección y entrenamiento, ver Anexo ???. Primero se importan los archivos generados de los 3 modelos de entrenamiento RNN, GBC y RFC para crear los modelos predictivos. Segundo, se inicializan los componentes de seguimiento de esqueleto para extraer las coordenadas de los puntos de la Tabla 3.14 y calcular los ángulos, Tablas 3.15 y 3.16. El vector de los 10 ángulos calculados ingresa a la red neuronal y los clasificadores, y estos entregan su predicción. Al mismo tiempo el programa muestra por pantalla el seguimiento del esqueleto de la persona y lanza en pantalla el resultado de cada uno de los clasificadores, Figura 3.22.




Figura 3.22: Captura del programa de detección y clasificación de postura en tiempo real. En la esquina superior izquierda se observa la predicción de los 3 métodos.

4. Aplicaciones

4.1. Validación

Esta sección describe las aplicaciones del prototipo de clasificación en tiempo real de las posturas en sedestación, se presenta la validación y un caso de estudio guiado por un fisioterapeuta.

4.1.1. Validación en condiciones controladas

Para la validación interna del prototipo, se realizaron pruebas con un voluntario en el escenario de la Figura 3.16. Utilizando la aplicación de medición de ángulos *ON 2D Measure*, se guió al individuo para simular las posturas de la Tabla 3.10. En las Figuras 4.1 a 4.5 se muestran ejemplos del procedimiento para cada clase de postura, las tomas se realizan desde diferentes ángulos acorde a los parámetros de ubicación de la cámara establecidos en la Tabla 3.13.




Figura 4.1: Clasificación de la postura A en un escenario controlado, con el uso de la aplicación ON 2D Measure.




Figura 4.2: Clasificación de la postura B en un escenario controlado, con el uso de la aplicación ON 2D Measure.




Figura 4.3: Clasificación de la postura C en un escenario controlado, con el uso de la aplicación ON 2D Measure.




Figura 4.4: Clasificación de la postura D en un escenario controlado, con el uso de la aplicación ON 2D Measure.




Figura 4.5: Clasificación de la postura E en un escenario controlado, con el uso de la aplicación ON 2D Measure.

En el análisis del rendimiento del prototipo se tomaron 125 capturas, para evitar sesgos se escogieron 25 capturas de cada postura de la Tabla 3.10. Todos los métodos clasifican la misma postura al mismo tiempo. Estos resultados se basan en el criterio desde el punto de observación, en la Tabla 4.1 se presentan los porcentajes de detección correcta de cada método. Siendo Gradient Boosting el clasificador que mejor desempeño tuvo con un 78 %, clasificando correctamente 97 de las 125 tomas. Con 76 % le sigue la Red Neuronal Recurrente. El método que peor resultado tuvo es el clasificador Random Forest con un 70 % de detecciones correctas. Para entender a mayor profundidad estos resultados, se describe a continuación el desempeño de cada método.

Tabla 4.1: Porcentaje de detección correcta e incorrecta de los métodos de clasificación con el set de validación

Método	Detección Correcta		Detección Incorrecta	
	Fracción	Porcentaje	Fracción	Porcentaje
RNN	95/125	76 %	30/125	24 %
RFC	88/125	70 %	37/125	30 %
GBC	97/125	78 %	28/125	22 %

4.1.2. Red Neuronal Recurrente

La Tabla 4.2 presenta la matriz de confusión de los resultados del método por RNN, para una mejor visualización en la Figura 4.6 se tiene la matriz normalizada. Donde claramente la mejor detección se logra para la categoría C (inclinación hacia atrás). En la Tabla 4.3 se pueden encontrar los valores de sensibilidad para cada una de las clasificaciones, siendo C la postura mejor detectada y con menor tasa de falsos negativos. Al igual que la clasificación D (manos en la cabeza) que una sensibilidad del 84 % y un 16 % de falsos negativos. Las clases A (postura correcta) y E (inclinación lateral) presenta desempeños muy similares, siendo la especificidad menor para A, es decir la razón de verdaderos negativos. La categoría con menor desempeño en B (inclinación hacia adelante), que alcanza un 64 % de sensibilidad y un 36 % de falsos negativos.

Tabla 4.2: Matriz de confusión del resultado de la clasificación con RNN.

RNN		PRONÓSTICO					
		A	B	C	D	E	TOTAL
REAL	A	18	3	3	0	1	25
	B	3	16	1	3	2	25
	C	1	0	22	1	1	25
	D	0	1	3	20	1	25
	E	2	2	0	3	18	25
	TOTAL	24	22	29	27	23	125




Figura 4.6: Gráfica de la matriz de confusión para el método de clasificación con RNN.

Tabla 4.3: Parámetros de evaluación de la matriz de confusión de la clasificación con RNN para cada clase.

RNN	A		B		C	
	Fracción	%	Fracción	%	Fracción	%
Sensibilidad	18/25	72.0 %	16/25	64.0 %	22/25	88.0 %
Especificidad	94/100	94.0 %	95/100	95.0 %	93/100	93.0 %
Tasa de falsos positivos	6/100	6.0 %	5/100	5.0 %	7/100	7.0 %
Tasa de falsos negativos	7/25	28.0 %	9/25	36.0 %	3/25	12.0 %

RNN	D		E	
	Fracción	%	Fracción	%
Sensibilidad	21/25	84.0 %	18/25	72.0 %
Especificidad	93/100	93.0 %	95/100	95.0 %
Tasa de falsos positivos	7/100	7.0 %	5/100	5.0 %
Tasa de falsos negativos	4/25	16.0 %	7/25	28.0 %

4.1.3. Clasificador Random Forest

Para el caso de RFC en la Tabla 4.4 presenta la matriz de confusión de los resultados, igualmente en la Figura 4.7 se tiene la matriz normalizada para visualizar de mejor manera estos resultados. La categoría C (inclinación hacia atrás) tiene el mayor número de capturas identificadas correctamente.

Tabla 4.4: Matriz de confusión del resultado de la clasificación con RFC.

RFC		PRONÓSTICO					TOTAL
		A	B	C	D	E	
REAL	A	17	4	2	0	2	25
	B	3	18	0	3	1	25
	C	4	0	20	1	0	25
	D	0	0	2	16	7	25
	E	2	2	0	5	16	25
TOTAL		26	24	24	25	26	125




Figura 4.7: Gráfica de la matriz de confusión para el método de clasificación con RFC.

Además, en la Tabla 4.5 se tienen los valores de sensibilidad para cada una de las clasificaciones, siendo C la postura mejor detectada y con menor tasa de falsos negativos. En este caso las posturas D (manos en la cabeza) y E (inclinación lateral) tienen un desempeño similar en cuanto la sensibilidad, es decir, no están siendo correctamente detectados. Pero este método logra clasificar con un 72 % de sensibilidad la clase B (Inclinación hacia adelante), y una tasa de falsos positivos del solo 6 %. El método tiene dificultad para clasificar las posturas A, B y C.

Tabla 4.5: Parámetros de evaluación de la matriz de confusión de la clasificación con RFC para cada clase.

RFC	A		B		C	
	Fracción	%	Fracción	%	Fracción	%
Sensibilidad	17/25	68.0 %	18/25	72.0 %	20/25	80.0 %
Especificidad	91/100	91.0 %	94/100	94.0 %	96/100	96.0 %
Tasa de falsos positivos	9/100	9.0 %	6/100	6.0 %	4/100	4.0 %
Tasa de falsos negativos	8/25	32.0 %	7/25	28.0 %	5/25	20.0 %

RFC	D		E	
	Fracción	%	Fracción	%
Sensibilidad	16/25	64.0 %	16/25	64.0 %
Especificidad	91/100	91.0 %	90/100	90.0 %
Tasa de falsos positivos	9/100	9.0 %	10/100	10.0 %
Tasa de falsos negativos	9/25	36.0 %	9/25	36.0 %

4.1.4. Clasificador Gradient Boosting

En el resumen general de los métodos de la Tabla 4.1 de GBC obtuvo el mejor desempeño. En la Tabla 4.7 se presenta la matriz de confusión de los resultados, y en la Figura 4.8 se tiene la matriz normalizada para facilitar la visualización de los resultados. La categoría A (Postura correcta) tiene el mayor número de capturas identificadas correctamente. En la Tabla 4.6 se tienen los valores de sensibilidad para cada una de las clasificaciones, siendo A la postura mejor detectada, y con una tasa baja de falsos positivos. En este caso las posturas E (inclinación lateral), D (manos en la cabeza) y B (Inclinación hacia adelante) tienen los desempeños más bajos, pero el caso de B es superior a los anteriores modelos. Logra clasificar B con un 72 % de sensibilidad y una tasa de falsos positivos de solo el 6 %. Las categorías C y D presentan un buen desempeño, ambas con un 80 % de sensibilidad.

Tabla 4.6: Matriz de confusión del resultado de la clasificación con GBC.

RFC		PRONÓSTICO					TOTAL
		A	B	C	D	E	
REAL	A	21	1	1	0	2	25
	B	5	19	0	1	0	25
	C	0	0	20	2	3	25
	D	0	0	3	20	2	25
	E	1	2	3	2	17	25
TOTAL		27	22	27	25	24	125




Figura 4.8: Gráfica de la matriz de confusión para el método de clasificación con GBC.

Tabla 4.7: Parámetros de evaluación de la matriz de confusión de la clasificación con Gradient Boosting para cada clase.

GBC	A		B		C	
	Fracción	%	Fracción	%	Fracción	%
Sensibilidad	21/25	84.0 %	19/25	76.0 %	20/25	80.0 %
Especificidad	94/100	94.0 %	97/100	97.0 %	93/100	93.0 %
Tasa de falsos positivos	6/100	6.0 %	3/100	3.0 %	7/100	7.0 %
Tasa de falsos negativos	4/25	16.0 %	6/25	24.0 %	5/25	20.0 %

GBC	D		E	
	Fracción	%	Fracción	%
Sensibilidad	20/25	80.0 %	17/25	68.0 %
Especificidad	95/100	95.0 %	93/100	93.0 %
Tasa de falsos positivos	5/100	5.0 %	7/100	7.0 %
Tasa de falsos negativos	5/25	20.0 %	8/25	32.0 %

4.1.5. Comparaciones

En esta subsección se presenta la relación de falsos positivos entre las categorías a mayor detalle para cada método de clasificación, para esta finalidad las Figuras 4.9, 4.10 y 4.11 presentan las partes simétricas y asimétricas normalizadas de las matrices de confusión de los métodos RNN, RFC y GBC respectivamente. Estas gráficas permiten visualizar, por ejemplo,

si es que hay falsos positivos de una categoría, con la cual otra categoría está siendo incorrectamente clasificada.

En el caso de la RNN, existe mayor confusión entre las categorías A-C, B-D, C-D y D-E. También se puede observar que las categorías C y D son las que mayor cantidad de falsos positivos presentan, pero claramente existe un sesgo hacia C. La clasificación RFC, presenta mas confusión entre las clases B-D, es decir que cuando realmente era B, se clasificó como D. También entre las clases D-E, en otras palabras, varias veces clasificó como E cuando realmente era D.

En el caso de la clasificación GBC el mayor problema se encuentra entre las clases A y B, no existe una inclinación hacia una clase u otra, es decir que se han clasificado incorrectamente el mismo número de veces de A a B y de B a A.




Figura 4.9: Gráfica de la parte asimétrica y simétrica de matriz de confusión para el método de clasificación con Red Neuronal Recurrente.




Figura 4.10: Gráfica de la parte asimétrica y simétrica de matriz de confusión para el método de clasificación con *Random Forest*.




Figura 4.11: Gráfica de la parte asimétrica y simétrica de matriz de confusión para el método de clasificación con *Gradient Boosting*.

Tabla 4.8: Ejemplo del proceso de clasificación en tiempo real, se presentan los ángulos y los resultados de los clasificadores.

Ángulo	Captura 1	Captura 2	Captura 3	Captura 4	Captura 5	Captura 6
A1	6.247	-0.502	0.375	12.019	13.535	13.337
A2	-2.514	-9.062	-8.029	-2.546	-5.037	-3.229
A3	-8.173	-8.110	-8.201	-5.845	-6.790	-7.474
A4	103.970	103.619	101.927	100.099	75.490	102.460
A5	53.708	53.295	49.868	79.353	17.118	37.059
A6	-3.002	-2.591	-8.137	-6.821	-6.040	-6.385
A7	9.741	10.052	9.176	13.985	12.298	16.045
A8	14.355	14.403	16.293	13.877	74.872	34.189
A9	-27.582	-16.556	-24.450	-18.448	-6.337	-21.800
A10	307.856	307.139	306.359	350.897	319.837	330.748
Clasificación						
RNN	A	A	C	B	D	B
RFC	A	C	A	D	D	B
GBC	A	C	A	B	D	B

En la Tabla 4.8 se presentan algunas capturas de los ángulos corporales y la designación de los clasificadores. Se escogieron intencionalmente para analizar los resultados expuestos anteriormente. En la captura 1, los 3 métodos clasificaron correctamente, si se revisa la captura 2 y la captura 3 se visualiza que el método RNN clasificó incorrectamente. Cuando era C indicó A y viceversa, comparando los ángulos con la captura 1 se puede observar que los ángulos están en un límite comprensible para que exista un error de clasificación.

En el caso de la captura 4, el método RFC falló la clasificación, indicando D cuando era B. Si se comparan los ángulos con las capturas 5 y 6, la captura 4 se asemeja más a B. En este caso existe un error de clasificación, el cual se podría mejorar incrementando el tamaño del conjunto de datos o con mayor precisión al momento de capturar las posturas que limiten con

otras.

Finalmente, se presenta la Tabla 4.9 de coincidencias, aquí se ha resumido las veces que los métodos de clasificación han coincidido para cada clase. En la primera columna se tiene la combinación de los métodos RNN, RFC y GBC o ninguno vs las clases A, B, C, D y E. Por ejemplo, de 25 casos para la postura E (inclinación lateral) existieron 3 ocasiones en la que ningún método clasificó correctamente.

Para la clase B, de 25 casos hubo 8 ocasiones en que los 3 métodos clasificaron bien, tomando como ejemplo, la combinación de RFC y GBC en 5 ocasiones coincidieron en su clasificación a B. Si se conocen cuantas de las 5 veces la clasificación fue correcta, es posible aumentar la sensibilidad de la detección general, mediante la ponderación de los valores obtenidos para cada clasificación.

Tabla 4.9: Matriz de coincidencias de las combinaciones los métodos de clasificación para cada clase.

matriz de coincidencias					
Métodos	A	B	C	D	E
RNN, RFC, GBC	11	8	14	8	11
RNN y RFC	1	3	3	3	1
RNN y GBC	5	4	3	6	3
RFC y GBC	4	5	3	3	3
RNN	1	1	2	3	3
RFC	1	2	0	1	1
GBC	1	2	0	1	0
Ninguno	1	0	0	0	3

4.1.6. Validación en escenario real

Para evaluar el rendimiento del SIS-MC-PSTR el prototipo se adecuó en una oficina de trabajo, la cámara de profundidad se coloca a una distancia $d = 240cm$ de la silla, a una altura $A_t = 80cm$ y en un ángulo $\alpha = 45^\circ$, ver Figura 4.12. Además se utilizó una cámara en un ángulo de $\beta = 10^\circ$ para tomar fotografías de cada una de las posturas capturadas.

El monitoreo se realizó por 2 horas diarias por 5 días laborales, mientras el voluntario realizaba sus tareas frente al computador. La franja horaria en la que se tomaron las capturas fue de 15:00 a 18:00 para captar las últimas horas de la jornada laboral del voluntario, en las cuales podría encontrarse menos conciente del monitoreo. Las tomas se limitaron a 2 horas debido a que fue el tiempo permitido para ingresar al lugar.

El tiempo de muestreo se adecuó a 1 captura por minuto debido a que es una actividad poco dinámica, consiguiendo 120 capturas por días, en total se obtuvieron 600 capturas. En el post-procesamiento se eliminaron las capturas en las que el individuo estaba en estados diferentes a la sedestación. También se eliminaron las capturas en las que se registró una pérdida del seguimiento del esqueleto, esto esta relacionado a que el color de la ropa del paciente era oscura. En total el set de datos fue de 407 capturas, en la tabla 4.10 se presentan cuantas capturas se obtuvieron en cada uno de los 5 días.

En este caso, se contó con el especialista en fisioterapia para la clasificación de las imágenes.



Figura 4.12: Colocación del prototipo en el lugar de trabajo del individuo .

Para lograr un nivel de confianza del 95 % en la validación, el tamaño de la muestra fue de 293 fotografías. Las mismas que fueron seleccionadas aleatoriamente con el programa de la página [102], el resultado de la aleatorización se presenta en el Anexo ??.

Tabla 4.10: Porcentaje de datos tomados para la validación del prototipos en un escenario real.

Día	Muéstras de imágenes	Porcentaje del total	Porcentaje de muestreo	Número de imágenes por estrato
1	90	22 %	65 %	65
2	73	18 %	53 %	53
3	88	22 %	65 %	64
4	73	18 %	53 %	53
5	82	20 %	59 %	58

Se presentó al fisioterapeuta las fotografías tomadas desde el punto de observación para que realice la clasificación en base su criterio. La Figura 4.13 presenta el resultado del monitoreo en función del porcentaje del tiempo de cada día en que el paciente estuvo en cada una de las posturas, según el análisis del especialista y los clasificadores. La clasificación del fisioterapeuta determinó que el voluntario estuvo el 77 % del tiempo capturado en la postura B (inclinación hacia adelante). El SIS-MC-PSTR coincide que B es la postura mas recurrente, la Tabla 4.11 presenta el resultado de la clasificación de los tres métodos para cada postura.




Figura 4.13: Porcentaje del tiempo de cada día en cada una de las posturas, según la clasificación del especialista y las clasificaciones de los métodos RNN, RFC y GBC.

Tabla 4.11: Porcentaje del tiempo que el paciente adoptó las diferentes posturas, según el análisis del especialista y los clasificadores RNN, RFC y GBC.

Resumen								
Postura	Fisioterapeuta		RNN		RFC		GBC	
	Fracción	%	Fracción	%	Fracción	%	Fracción	%
A	37/293	13 %	57/293	19 %	47/293	16 %	79/293	27 %
B	227/293	77 %	167/293	57 %	181/293	62 %	176/293	60 %
C	8/293	3 %	18/293	6 %	9/293	3 %	8/293	3 %
D	9/293	3 %	29/293	10 %	39/293	13 %	17/293	6 %
E	13/293	4 %	24/293	8 %	19/293	6 %	15/293	5 %

Para ampliar el estudio del desempeño de cada uno de los clasificadores se presentan las Tablas de confusión y los parámetros. En el caso de RNN, Tabla 4.12 y 4.13, la postura A obtuvo un 56 % de sensibilidad. En conjunto con la matriz de confusión se observa que existe un conflicto entre las posturas A y B, debido a que en 25 ocasiones B fue detectado como A.

Tabla 4.12: matriz de confusión de la clasificación con RNN, validación en escenario real.

RNN		PRONÓSTICO					
		A	B	C	D	E	TOTAL
REAL	A	21	13	1	0	2	37
	B	25	153	11	23	13	225
	C	0	2	6	0	0	8
	D	1	2	0	6	0	9
	E	1	2	0	0	11	14
	TOTAL	48	172	18	29	26	293

Tabla 4.13: Parámetros de evaluación de la matriz de confusión de la clasificación con RNN, validación en escenario real

RNN	A		B		C	
	Fracción	%	Fracción	%	Fracción	%
Sensibilidad	21/37	56.8 %	153/225	68.0 %	6/8	75.0 %
Especificidad	229/256	89.5 %	49/68	72.1 %	273/285	95.8 %
Tasa de falsos positivos	27/256	10.5 %	19/68	27.9 %	12/285	4.2 %
Tasa de falsos negativos	16/37	43.2 %	72/225	32.0 %	2/8	25.0 %

RNN	D		E	
	Fracción	%	Fracción	%
Sensibilidad	6/9	66.7 %	11/14	78.6 %
Especificidad	261/284	91.9 %	264/279	94.6 %
Tasa de falsos positivos	23/284	8.1 %	15/279	5.4 %
Tasa de falsos negativos	3/9	33.3 %	3/14	21.4 %

A continuación, los resultados del método por RFC se presentan en las Tablas 4.14 y 4.15. En este caso la sensibilidad para la categoría B es de 68 %, los errores de detección están mayoritariamente asociados a las categorías A y D.

Tabla 4.14: Matriz de confusión de la clasificación con RFC, validación en escenario real.

RFC		PRONÓSTICO					
		A	B	C	D	E	TOTAL
REAL	A	19	13	0	3	2	37
	B	27	155	4	32	7	225
	C	0	2	5	0	1	8
	D	0	3	0	5	1	9
	E	0	5	0	0	9	14
	TOTAL	46	178	9	40	20	293

Tabla 4.15: Parámetros de evaluación de la matriz de confusión de la clasificación con RFC, validación en escenario real

RFC	A		B		C	
	Fracción	%	Fracción	%	Fracción	%
Sensibilidad	19/37	51.4 %	155/225	68.9 %	5/8	62.5 %
Especificidad	229/256	89.5 %	45/68	66.2 %	281/285	98.6 %
Tasa de falsos positivos	27/256	10.5 %	23/68	33.8 %	4/285	1.4 %
Tasa de falsos negativos	18/37	48.6 %	70/225	31.1 %	3/8	37.5 %

RFC	D		E	
	Fracción	%	Fracción	%
Sensibilidad	5/9	55.6 %	9/14	64.3 %
Especificidad	249/284	87.7 %	268/279	96.1 %
Tasa de falsos positivos	35/284	12.3 %	11/279	3.9 %
Tasa de falsos negativos	4/9	44.4 %	5/14	35.7 %

En el caso del clasificador Gradient Boosting la sensibilidad obtenida para la postura B es del 72 %. Al igual que los métodos anteriores, el clasificador presenta mayor dificultad en diferenciar las posturas A y B, Tablas 4.16 y 4.17,

Tabla 4.16: Matriz de confusión de la clasificación con GBC, validación en escenario real.

GBC		PRONÓSTICO					
		A	B	C	D	E	TOTAL
REAL	A	23	14	0	0	0	37
	B	46	162	2	9	6	225
	C	1	0	6	1	0	8
	D	1	2	0	6	0	9
	E	1	3	0	1	9	14
	TOTAL	72	181	8	17	15	293

Tabla 4.17: Parámetros de evaluación de la matriz de confusión del GBC, validación en escenario real

GBC	A		B		C	
	Fracción	%	Fracción	%	Fracción	%
Sensibilidad	23/37	62.2 %	162/225	72.0 %	6/8	75.0 %
Especificidad	207/256	80.9 %	49/68	72.1 %	283/285	99.3 %
Tasa de falsos positivos	49/256	19.1 %	19/68	27.9 %	2/285	0.7 %
Tasa de falsos negativos	14/37	37.8 %	63/225	28.0 %	2/8	25.0 %

GBC	D		E	
	Fracción	%	Fracción	%
Sensibilidad	6/9	66.7 %	9/14	64.3 %
Especificidad	273/284	96.1 %	273/279	97.8 %
Tasa de falsos positivos	11/284	3.9 %	6/279	2.2 %
Tasa de falsos negativos	3/9	33.3 %	5/14	35.7 %

Finalmente, se presenta en la Tabla 4.18 una comparación de los resultados según el porcentaje de detecciones correctas para cada clasificador en pruebas de laboratorio y el escenario del caso de esturio. Siendo GBC el método con mejor desempeño con un 75 % de éxito en pruebas en condiciones controladas y 67 % en el escenario real.

Tabla 4.18: Comparación del rendimiento del prototipo en un escenario real vs pruebas de laboratorio, en función del porcentaje de aciertos.

Método	Escenario Real		Laboratorio	
	Fracción	Porcentaje	Fracción	Porcentaje
RNN	197/293	67 %	94/125	76 %
RFC	193/293	66 %	88/125	70 %
GBC	206/293	70 %	95/125	78 %

4.2. Caso de Estudio

Para el caso de estudio se contó con el apoyo de un voluntario que accedió a que esta información obtenida fuera presentada en el presente documento.

El voluntario trabaja como Ingeniero en sistemas y en el campo académico como docente e investigador. El tiempo de trabajo sentado frente a un computador es de 6 a 8 horas diarias (no seguidas), según su estimación. Su actividad física es media. En su jornada laboral realiza trabajo de oficina, visualización de datos y redacción. Se realizó una evaluación en el ámbito de la fisioterapia al voluntario, ver Figuras 4.14 y 4.15. Es preciso indicar que en esta sesión no se realizó ningún tratamiento ni intervención de fisioterapia. Con la evaluación se identificaron los siguientes elementos:

- Acortamiento en Músculo Esternocleidomastoideo (ECOM) bilateral
- Disminución de la fuerza en los músculos profundos cervicales
- Puntos dolorosos negativos en músculos subnucales derecho e izquierdo
- Puntos dolorosos negativos en músculos trapecio derecho e izquierdo
- Puntos dolorosos positivo en músculo escaleno
- Puntos dolorosos positivos en músculos esplenio de cabeza y cuello
- Con limitación en la inclinación lateral izquierda del cuello



Figura 4.14: Pre-diagnóstico del paciente para caso de estudio .



Figura 4.15: Pre-diagnóstico del paciente para caso de estudio.

Luego, se planificó el monitoreo de la postura del paciente dentro de los límites de su espacio de trabajo, ver Figura 4.16. Se adecuaron la cámara de profundidad a una distancia $d = 240\text{cm}$ del voluntario, una altura $A_t = 75\text{cm}$ y en un ángulo $\alpha = 60^\circ$ y no se realizó ningún cambio para mejorar la ergonomía del lugar. El tiempo de muestreo se adecuó a 1 captura por minuto debido a que es una actividad poco dinámica. El monitoreo se hizo por 10 horas, mientras realizaba sus tareas frente al computador, priorizando las últimas horas de la jornada laboral.



Figura 4.16: Escenario: lugar de trabajo del voluntario para caso de estudio.

En total se obtuvieron 600 capturas, en el post-procesamiento se eliminaron las tomas en las que el individuo se encontraba levantado o en otra actividad. También se eliminaron las

capturas en las que se registró una pérdida del seguimiento del esqueleto para evitar datos erróneos.

La predicción del SIS-MC-PSTR fue que el paciente pasó más del 55 % del tiempo, para todos los clasificadores, en la posición B (inclinación hacia adelante). Entre el 19 % y 27 % en la postura correcta A, y el 18 % a 26 % del tiempo restante en las posturas C, D y E. Después del tiempo de monitoreo, el especialista realizó un diagnóstico final del paciente con las siguientes observaciones:

- Persiste acortamiento en ECOM bilateral
- Disminución de la fuerza en los músculos profundos cervicales
- Apareció un punto doloroso positivos en músculos subnucales derecho y en el músculos trapecio derecho e izquierdo
- Puntos dolorosos positivos en músculo masetero bilateral
- Puntos dolorosos positivos en músculos esplenio de cabeza y cuello
- Ligera variación en los ángulos de limitación en la inclinación lateral izquierda del cuello

La información obtenida por el SIS-MC-PSTR del monitoreo del paciente se entregó al fisioterapeuta. La observación de las imágenes y la evaluación previa y posterior el especialista en fisioterapia contó con información objetiva para recomendar al paciente la forma de adecuar ergonómicamente el espacio de trabajo y mejorar la postura, Figura 4.17. Además se recomendó la activación de músculos profundos cervicales para mejorar la estabilidad del cuello. Disminuir la sobrecarga en la zona lumbar por mantener la postura de inclinación anterior constante, Figura 4.18. Resulta importante aclarar que no existió intervención fisioterapéutica entre la primera y la segunda evaluación. Solamente se realizó la evaluación del puesto de trabajo.




Figura 4.17: Diagnóstico final del paciente para caso de estudio, recomendaciones del especialista para adecuar el lugar de trabajo ergonómicamente.



Figura 4.18: Diagnóstico final del paciente para caso de estudio, indicaciones para ejercicios.

5. Conclusiones y recomendaciones

Este capítulo final, la sección 5.1 presenta las conclusiones del trabajo de titulación con base al análisis correspondiente de los resultados obtenidos en el capítulo 4 y teniendo en consideración los objetivos planteados en el capítulo 1. En el apartado 5.2 se presentan algunas recomendaciones importantes. Finalmente, en la sección 5.3 se describen aquellas propuestas respecto a formas de ampliar la investigación a futuro.

5.1. Conclusiones

- La inserción de la tecnología en la sociedad ha provocado cambios acelerados en el ámbito laboral, incrementando el número de personas que adoptan el teletrabajo, además, se debe tener presente al personal administrativo, docentes y oficinistas cuyo trabajo demanda estar varias horas frente a un computador. La falta de ergonomía en los espacios de trabajo puede causar problemas a nivel musculoesquelético, y puede tener un impacto negativo en la productividad y la calidad de vida de las personas. Es importante que las empresas y los individuos tomen medidas para mejorar la ergonomía en los espacios de trabajo para prevenir problemas de salud y aumentar la eficiencia y el bienestar de los trabajadores. Mediante el desarrollo de este trabajo fue posible elaborar un prototipo para monitorear la postura en sedestación de un individuo en su espacio de trabajo. Mediante la guía de un profesional en fisioterapia, la conducta postural se definió en 5 clases como se muestra en la Tabla 3.10. Y con métodos de Inteligencia Artificial (IA) y DL se logró la detección y clasificación en tiempo real de las posturas definidas.
- En la revisión teórica de soluciones existentes en el seguimiento de postura, se encontraron diferentes métodos y tecnologías, basado en esta revisión y con el análisis del mercado se encontró conveniente inclinarse hacia las opciones de visión artificial. La cámara con sensor de profundidad elegida fue la Orbecc Astra Pro, para el desarrollo del sistema se utilizaron las librerías del SDK NuiTrack para Python 3.9.12 y las librerías Scikit-learn y Keras para la clasificación de las posturas.
- El software de captura de posturas permitió generar un set de datos de las coordenadas espaciales de las posiciones de cabeza, cuello y articulaciones para un total de 15 puntos. Las coordenadas permitieron calcular las proyecciones de los ángulos corporales en el plano $x - y$ como se indica en la Tabla 3.15 y en el plano $y - z$ de la Tabla 3.16, dando un total de 10 ángulos por captura.
- En la toma creación del data set, para procurar continuidad en la adquisición de datos, se establecieron los lineamientos de la ubicación de la cámara respecto al escenario y un punto de observación para dirigir las posturas del individuo.
- Los métodos de clasificación elegidos fueron RNN, RFC y GBC, los mismos que fueron entrenados con el set de datos de los ángulos corporales generado y puestos a prueba en un escenario controlado y en un escenario real para un caso de estudio de fisioterapia, siguiendo las pautas establecidas para la ubicación de la cámara respecto a la persona monitoreada.
- Los métodos de clasificación fueron evaluados por separado, mediante sus matrices de confusión y parámetros de confiabilidad para determinar las falencias de cada uno, tanto en las pruebas de laboratorio en un escenario controlado y, en el caso de estudio en compañía de un fisioterapeuta. En las pruebas de laboratorio los métodos alcanzaron un

75 % RNN, 69 % el RFC y 76 % el GBC de aciertos en un set de 125 capturas, Tabla 4.18. Y siendo C (Inclinación hacia atrás) la postura mejor detectada por los 3 métodos.

- En la validación en un escenario real, se monitoreó a un individuo por 5 días, 2 horas diarias, mientras trabaja frente su computador, se le pidió al fisioterapeuta que clasificara las posturas del paciente según la Tabla 3.10 basado en fotografías del paciente. Debido a que el especialista solo contaba con un ángulo de visión es posible que existan imprecisiones en la clasificación de alguna captura.
- En las pruebas en un escenario real los métodos alcanzaron un 67 % RNN, 66 % el RFC y 70 % el GBC de aciertos en un set de 293 capturas, 4.18.
- Los resultados del caso de estudio, determinaron que el individuo permaneció menos del 27 % del tiempo monitoreado en la postura correcta, la mayor parte del tiempo el individuo se posicionó inclinado hacia adelante, y el resto del tiempo en las posturas C, D y E. Los tres modelos coinciden e indicaron que el paciente estuvo inclinado hacia adelante.
- El caso de estudio permitió obtener información útil para el especialista, que le ayudó a comprender mejor el caso del paciente mientras realiza sus actividades laborales. Debido a que se conoce que la postura dominante que adopta al trabajar es inclinarse hacia adelante, le permitió tomar decisiones más informadas sobre el tratamiento que debe seguir. Además, el uso del prototipo puede ser útil para evaluar la efectividad del tratamiento e intervención ergonómica. En resumen, el prototipo es una herramienta valiosa para la evaluación ergonómica y de fisioterapia, ya que le permite tener una visión del contexto del paciente sin estar de manera presencial y por largos periodos observándolo.
- El proyecto logró cumplir tanto el objetivo general como los objetivos específicos, la implementación de un prototipo de seguimiento y clasificación en tiempo real de posturas en sedestación, con enfoque en el monitoreo de trabajo frente ordenadores por periodos largos, y aplicarlo en un caso de fisioterapia.
- El prototipo se ve afectado principalmente por las limitaciones de la cámara, es necesario que las condiciones del ambiente en el que se prueba el prototipo favorezcan la detección del esqueleto. El entrenamiento se ha realizado con un solo participante y desde determinados ángulos, es preciso crear un set mayor variando las condiciones.

5.2. Perspectivas

A continuación se listan algunas perspectivas que se pueden tomar en torno este trabajo.

- Implementar el código en otro ordenador de características superiores al utilizado, que permitan probar todas las funciones del SDK Nuitrack. Por ejemplo, utilizar el sensor Red Green Blue (RGB) y la detección de objetos para incrementar los parámetros de análisis.
- Ampliar la clasificación de las posturas, el programa fue desarrollado de forma dinámica, lo que permite incrementar el número de clases. Esto permitiría entregar mayor información de utilidad a los especialistas en fisioterapia.
- Realizar más casos de estudio para obtener resultados estadísticamente más significativos. Muestras más grandes de estudios sumados al seguimiento de pacientes por parte de especialistas en fisioterapia, permitirá obtener resultados y conclusiones más representativas.

- Posibilidad de reevaluación de varios pacientes utilizando el prototipo elaborado luego de las intervenciones ergonómicas y aplicación de la Fisioterapia fundamentada en las observaciones.
- Entrenar un sistema con Inteligencia Artificial (IA) con los resultados de los clasificadores implementados en este trabajo. Se puede aprovechar los puntos fuertes de cada método para incrementar el rendimiento de la detección.

5.3. Trabajos futuros

- Adaptar el sistema a un ordenador monoplaca que permita la autonomía del prototipo y mayor adaptabilidad a los entornos de los pacientes.
- Implementar una interfaz gráfica para los usuarios, tanto para el profesional de salud como para el paciente. Además, que presente los resultados de manera efectiva según los requerimientos de la fisioterapia.
- Implementar un sistema de envío y adquisición de datos desde el prototipo hacia una base de datos relacional, que almacene la información de diferentes pacientes, primando la privacidad y seguridad de los mismos.

Bibliografía

- [1] R. J. Stanborough, "The truth about blue light and eye health," Jan 2022. [En línea]. Disponible: <https://www.healthline.com/health/what-is-blue-light#risks-and-side-effects>
- [2] M. Villar, "Posturas De Trabajo," *Instituto Nacional de Seguridad e Higiene en el Trabajo (INSHT)*, p. 54, 2015. [En línea]. Disponible: <http://www.insht.es/InshtWeb/Contenidos/Documentacion/FICHASDEPUBLICACIONES/ENCATALOGO/ERGONOMIA/Posturasdetrabajo.pdf>
- [3] J. A. Diego-Mas, "Bio-mec." [En línea]. Disponible: <https://www.ergonautas.upv.es/metodos/biomecanica/biomecanica-ayuda.php>
- [4] C. Cánovas, "Análisis de los ajustes ergonómicos, el puesto de trabajo en una muestra de estudiantes de ingeniería informática," *Revista de Fisioterapia*, vol. 6, num. 1, pp. 19–29, 2007. [En línea]. Disponible: <http://repositorio.ucam.edu/handle/10952/392>
- [5] S. Magallón, "Desgloce de a cámara Microsoft Kinect," pp. 33–76, 2010.
- [6] 3DiVi, "Nuitrack-sdk/overview.md at master · 3divi/nuitrack-sdk." [En línea]. Disponible: <https://github.com/3DiVi/nuitrack-sdk/blob/master/doc/Overview.md>
- [7] J. Guerrero, "Redes recurrentes," pp. 1–53, 2020.
- [8] C. Oropeza, "Capítulo 3: Redes Neuronales Recurrentes," pp. 15–25, 2007. [En línea]. Disponible: http://catarina.udlap.mx/u_dl_a/tales/documentos/lem/oropeza_c.ca/
- [9] J. Orellana, "Arboles de decision y random forest." [En línea]. Disponible: <https://bookdown.org/content/2031/ensambladores-random-forest-parte-i.html#random-forest>
- [10] "Algoritmo k-nearest neighbour." [En línea]. Disponible: <https://www.ibm.com/topics/knn>
- [11] A. Navlani, "Sklearn random forest classifiers in python tutorial," May 2018. [En línea]. Disponible: <https://www.datacamp.com/tutorial/random-forests-classifier-python>
- [12] D. S. Team, "Gradient boosting – what you need to know - machine learning," Dec 2020. [En línea]. Disponible: <https://datascience.eu/machine-learning/gradient-boosting-what-you-need-to-know/>
- [13] INEC, "Tecnologías de la información y comunicación," 2022. [En línea]. Disponible: <https://www.ecuadorencifras.gob.ec/tecnologias-de-la-informacion-y-comunicacion-tic/>
- [14] M. Guaña y E. Alvear, "Caracterización del consumidor digital ecuatoriano," *Revista publicando*, vol. 2, num. 5, pp. 226–242, 2015.
- [15] C. Infante y R. Benavides, "Uso y abuso de dispositivos móviles y su rol en el desarrollo de trastornos del sueño en adolescentes," *Alerta, Revista científica del Instituto Nacional de Salud*, vol. 5, num. 1, pp. 50–56, 2022.
- [16] M. Ramírez y L. Restrepo, "Archivos de Medicina alteraciones orgánicas y funcionales ocasionadas por el uso excesivo de pantallas de visualización de datos," *Universidad de Manizales*, vol. 15, num. 2, pp. 326–340, 2015.
- [17] M. Alderete y L. Gutiérrez, "ICT and productivity in service industries in Colombia," *Lecturas de Economía*, vol. 77, num. 77, pp. 163–188, 2012.

- [18] A. Belzunegui-Eraso y A. Erro-Garcés, "Teleworking in the context of the Covid-19 crisis," *Sustainability (Switzerland)*, vol. 12, num. 9, pp. 1–18, 2020.
- [19] V. Carpio-Fernández, C. García-Linares, T. Cerezo-Rusillo, y P. F. Casanova-Arias, "Covid-19: uso y abuso de internet y teléfono móvil en estudiantes universitarios." *Revista INFAD de Psicología. International Journal of Developmental and Educational Psychology*, vol. 2, num. 1, p. 107–116, ago. 2021.
- [20] A. R. Kayis, B. Satıcı, M. E. Deniz, S. A. Satıcı, y M. D. Griffiths, "Fear of COVID-19, loneliness, smartphone addiction, and mental wellbeing among the Turkish general population: a serial mediation model," *Behaviour and Information Technology*, vol. 41, num. 11, pp. 2484–2496, 2021. [En línea]. Disponible: <https://doi.org/10.1080/0144929X.2021.1933181>
- [21] G. Serra, L. Lo Scalzo, M. Giuffrè, P. Ferrara, y G. Corsello, "Smartphone use and addiction during the coronavirus disease 2019 (COVID-19) pandemic: cohort study on 184 Italian children and adolescents," *Italian Journal of Pediatrics*, vol. 47, num. 1, pp. 1–10, 2021.
- [22] A. Mantilla y J. I. Martínez, "Innovación y Tecnología en Fisioterapia Futuras herramientas de intervención," *Movimiento Científico*, vol. 11, num. 1, pp. 37–43, 2017.
- [23] J. D. Mas y J. Alcaide, "Using Kinect sensor in observational methods for assessing postures at work. *Applied Ergonomics*," 2014.
- [24] L. Bridgeman, M. Volino, J. Y. Guillemaut, y A. Hilton, "Multi-person 3D pose estimation and tracking in sports," *IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops*, vol. 2019-June, pp. 2487–2496, 2019.
- [25] J. A. Medina, "Experiencia investigativa de los fundamentos para la virtualización de las asignaturas de estudios generales en la formación universitaria," 2021.
- [26] C. Becerra y L. Reyes, "Teletrabajo , impactos en la salud del talento humano en época de pandemia Teleworking , impacts on the health of human talent in times of pandemic," *Revista Colombiana de Salud Ocupacional*, vol. 11, num. 2, pp. 1–8, 2021.
- [27] D. Gomes de Arruda, "Ergonomía en docente universitario durante la pandemia generada por la covid-19," p. 6, 2021.
- [28] K. Xu, Y. Fujita, Y. Lu, S. Honda, M. Shiomi, T. Arie, S. Akita, y K. Takei, "A Wearable Body Condition Sensor System with Wireless Feedback Alarm Functions," *Advanced Materials*, vol. 33, num. 18, 2021.
- [29] R. Cedeño, "Análisis de la marcha a través de machine learning para la clasificación de alteraciones óseas y musculares," Querétaro, 2021.
- [30] A. Abrami, S. Gunzler, C. Kilbane, R. Ostrand, B. Ho, y G. Cecchi, "Automated computer vision assessment of hypomimia in parkinson disease: Proof-of-principle pilot study," *Journal of Medical Internet Research*, vol. 23, num. 2, pp. 1–11, 2021.
- [31] A. Lunin y C. H. Glock, "Systematic review of Kinect-based solutions for physical risk assessment in manual materials handling in industrial and laboratory environments," *Computers and Industrial Engineering*, vol. 162, p. 107660, 2021.
- [32] S. Almasi, H. Ahmadi, F. Asadi, L. Shahmoradi, G. Arji, M. Alizadeh, y H. Kolivand, "Kinect-Based Rehabilitation Systems for Stroke Patients: A Scoping Review," *BioMed Research International*, vol. 2022, 2022.

- [33] M. Antico, N. Balletti, A. Ciccotelli, M. Ciccotelli, G. Laudato, A. Lazich, M. Notarantonio, R. Oliveto, S. Ricciardi, S. Scalabrino, y J. Simeone, "2Vita-B Physical: An Intelligent Home Rehabilitation System Based on Microsoft Azure Kinect," *Frontiers in Human Dynamics*, vol. 3, num. September, pp. 1–15, 2021.
- [34] W. Min, H. Cui, Q. Han, y F. Zou, "A scene recognition and semantic analysis approach to unhealthy sitting posture detection during screen-reading," *Sensors (Switzerland)*, vol. 18, num. 9, 2018.
- [35] E. Lopez, J. De la Calleja, H. Escalante, J. Alanís, P. Vázquez, y M. Morales, "Modelo Para La Detección Automática De La Actividad Humana: "Correr" Usando Redes Neuronales," *Pistas Educativas*, vol. 1, num. 141, pp. 43–44, 2021.
- [36] A. S. Acharya, P. Gandhi, S. Karkera, N. Ghagare, y S. Deshmukh, *Posture Monitoring and Back Pain Relief Using ATmega328, Android and Unity*. Springer Singapore, 2019, vol. 65. [En línea]. Disponible: http://dx.doi.org/10.1007/978-981-13-3765-9_16
- [37] R. Gupta, S. H. Gupta, A. Agarwal, P. Choudhary, N. Bansal, y S. Sen, "A Wearable Multisensor Posture Detection System," *Proceedings of the International Conference on Intelligent Computing and Control Systems, ICICCS 2020*, num. Icccs, pp. 818–822, 2020.
- [38] F. Hu, P. He, S. Xu, Y. Li, y C. Zhang, "FingerTrak: Continuous 3D Hand Pose Tracking by Deep Learning Hand Silhouettes Captured by Miniature Thermal Cameras onWrist," *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, vol. 4, num. 2, 2020.
- [39] M. El Amine Elforaici, I. Chaaraoui, W. Bouachir, Y. Ouakrim, y N. Mezghani, "Posture recognition using an rgb-d camera: exploring 3d body modeling and deep learning approaches," *2018 IEEE Life Sciences Conference, LSC 2018*, pp. 69–72, 2018.
- [40] A. D. Călin y A. Coroiu, "Interchangeability of kinect and orbbec sensors for gesture recognition," *Proceedings - 2018 IEEE 14th International Conference on Intelligent Computer Communication and Processing, ICCP 2018*, pp. 309–315, 2018.
- [41] M. A. R. Ahad, M. Ahmed, A. Das Antar, Y. Makihara, y Y. Yagi, "Action recognition using kinematics posture feature on 3D skeleton joint locations," *Pattern Recognition Letters*, vol. 145, pp. 216–224, 2021. [En línea]. Disponible: <https://doi.org/10.1016/j.patrec.2021.02.013>
- [42] P. Ren, D. Yao, M. Jahanshahi, P. A. Valdes-Sosa, J. F. Bosch Bayard, L. Dong, J. Chen, L. Mao, D. Ma, M. A. Sanchez, D. M. Morejon, y M. L. Bringas, "Multivariate Analysis of Joint Motion Data by Kinect: Application to Parkinson's Disease," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 28, num. 1, pp. 181–190, 2020.
- [43] V. Silva, F. Soares, J. S. Esteves, y G. Vercelli, "Human action recognition using an image-based temporal and spatial representation," *International Congress on Ultra Modern Telecommunications and Control Systems and Workshops*, vol. 2020-October, pp. 41–46, 2020.
- [44] C.-F. Juang y W.-E. Ni, "Human posture classification using interpretable 3-d fuzzy body voxel features and hierarchical fuzzy classifiers," *IEEE Transactions on Fuzzy Systems*, vol. 30, num. 12, p. 5405 – 5418, 2022, cited by: 1.
- [45] A. K. Shackelford, S. Member, C. H. Davis, y S. Member, "Hierarchical Fuzzy Classification Approach for High-Resolution Multispectral Data," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 41, num. 9, pp. 1920–1932, 2003.

- [46] D. Reynolds, "Gaussian Mixture Models," *Encyclopedia of Biometrics*, num. 2, pp. 827–832, 2015.
- [47] Q. Tao y J. Wang, "A New Fuzzy Support Vector Machine Based on the Weighted Margin," *Neural Processing Letters*, vol. 20, num. 3, pp. 139–150, 2004.
- [48] INEC, "Registro Estadístico de Recursos y Actividades de Salud 2006-2018," *Instituto Ecuatoriano de Estadísticas y Censos*, 2020.
- [49] J. B. Robles y J. Iglesias Ortiz, "Relación Entre Posturas Ergonómicas Inadecuadas Y La Aparición De Trastornos Musculo Esqueléticos En Los Trabajadores De Las Áreas Administrativas Que Utilizan Pantalla De Visualización De Datos, En Una Empresa De La Ciudad De Quito En El Año 2015," *Revista de Ciencias de Seguridad y Defensa*, num. 2, pp. 1–24, 2019.
- [50] G. Cañarte, "Trastornos musculoesqueléticos en personal administrativo," vol. 3974800, 2019.
- [51] O. Amft, "How wearable computing is shaping digital health," *IEEE Pervasive Computing*, vol. 17, num. 1, pp. 92–98, 2018.
- [52] H. Dhillon, "Current concepts in sports injury rehabilitation," *Indian Journal of Orthopaedics*, vol. 51, num. 5, p. 529 – 536, 2017, cited by: 27; All Open Access, Green Open Access. [En línea]. Disponible: https://www.scopus.com/inward/record.uri?eid=2-s2.0-85029313247&doi=10.4103%2fortho.IJOrtho_226_17&partnerID=40&md5=c654dfdd51b67e2b442bafbf8bf84169
- [53] Q. Wang, R. Lee, S. Hunter, y S. Chan, "The effectiveness of internet-based telerehabilitation among patients after total joint arthroplasty: An integrative review," *International Journal of Nursing Studies*, vol. 115, p. 103845, 2021. [En línea]. Disponible: <https://doi.org/10.1016/j.ijnurstu.2020.103845>
- [54] S. Kumar, A. Kumar, M. Kumar, A. Kumar, R. Arora, y R. Sehrawat, "Feasibility of telemedicine in maintaining follow-up of orthopaedic patients and their satisfaction: A preliminary study," *Journal of Clinical Orthopaedics and Trauma*, vol. 11, pp. S704–S710, 2020. [En línea]. Disponible: <https://doi.org/10.1016/j.jcot.2020.07.026>
- [55] G. Maresca, M. G. Maggio, R. De Luca, A. Manuli, P. Tonin, L. Pignolo, y R. S. Calabrò, "Tele-Neuro-Rehabilitation in Italy: State of the Art and Future Perspectives," *Frontiers in Neurology*, vol. 11, num. September, pp. 1–12, 2020.
- [56] E. Le Toullec, P. Piette, P. Gallien, E. Leblong, B. Fraudet, y F. Terrade, "Influence of the covid19 health crisis on the perception of tele-education in the french physiotherapist population, a qualitative study;," *Kinesithérapie*, vol. 22, num. 248-249, p. 6 – 13, 2022, cited by: 0; All Open Access, Bronze Open Access. [En línea]. Disponible: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85119300983\&doi=10.1016%2fj.kine.2021.09.011\&partnerID=40&md5=c9b0da8453291fff8d00cd9b12121383>
- [57] M. Taverne, "Efectos de las pantallas sobre la visión humana : posibles daños irreparables y consecuencias psico-fisiológicas," *Academia*, num. 23, pp. 1–6, 2020.
- [58] A. Arias Díaz, N. Bernal Reyes, y L. Camacho Rangel, "Effect of the electronic devices over the visual system," *Revista Mexicana de Oftalmología*, vol. 91, num. 2, pp. 103–106, 2017.

- [59] Z. Mendieta, “Efectos adversos en el desarrollo visual y cognitivo en niños menores de 3 años relacionados con el tiempo excesivo de uso de pantallas digitales,” *Bajo la modalidad de grado monografía de compilación, Universidad de la salle*, pp. 1–39, 2017.
- [60] S. Thomée, A. Härenstam, y M. Hagberg, “Computer use and stress, sleep disturbances, and symptoms of depression among young adults - a prospective cohort study,” *BMC Psychiatry*, vol. 12, 2012.
- [61] S. Thom, *ICT use and mental health in young adults*, 2013. [En línea]. Disponible: <http://doi.acm.org/10.1145/2517351.2517359>
- [62] “Musculoskeletal health.” [En línea]. Disponible: <https://www.who.int/news-room/fact-sheets/detail/musculoskeletal-conditions>
- [63] M. Delgado, “Trastornos musculoesqueléticos asociados al tiempo incrementado que el radiólogo pasa delante de una pantalla de ordenador en hospitales públicos y privados de Lambayeque,” Ph.D. dissertation, Universidad Nacional Pedro Ruiz, 2021.
- [64] Y. Hodelín, “Riesgos sobre tiempo prolongado frente a un ordenador.” [En línea]. Disponible: <https://revinfcientifica.sld.cu/index.php/ric/article/view/149>
- [65] J. A. Diego-Mas, “Owas,” 2015. [En línea]. Disponible: <https://www.ergonautas.upv.es/metodos/owas/owas-ayuda.php>
- [66] C. Lins y A. Hein, “Classification of body postures using smart workwear,” *BMC Musculoskeletal Disorders*, vol. 23, num. 1, 2022, cited by: 0; All Open Access, Gold Open Access, Green Open Access.
- [67] J. A. Diego-Mas, “Reba,” 2015. [En línea]. Disponible: <https://www.ergonautas.upv.es/metodos/reba/reba-ayuda.php>
- [68] *Fundamentos de enfermería: conceptos, proceso y práctica*, 8ésima ed., ser. Serie Enfermería. Madrid: Pearson Prentice Hall, 2008.
- [69] L. C. Marchan, “Anatomía Funcional 3,” *Isp*, vol. 1, p. 42, 2011. [En línea]. Disponible: http://3tecprevriesgos2010.files.wordpress.com/2011/09/anatomia-biomecanica-antropometria_2.pdf%5Chttp://3tecprevriesgos2010.files.wordpress.com/2011/09/anatomia-biomecanica-antropometria_3.pdf
- [70] L. L. Gómez Echeverry, A. M. Jaramillo Henao, M. A. Ruiz Molina, S. M. Velásquez Restrepo, C. A. Páramo Velásquez, y G. J. Silva Bolívar, “Human motion capture and analysis systems: a systematic review/Sistemas de captura y análisis de movimiento cinemático humano: una revisión sistemática,” *Prospectiva*, vol. 16, num. 2, pp. 24–34, 2018.
- [71] M. D. Bravo, R. C. Rengifo, y R. W. Agredo, “Comparación de dos Sistemas de Captura de Movimiento por medio de las Trayectorias Articulares de Marcha,” *Revista Mexicana de Ingeniería Biomedica*, vol. 37, num. 2, pp. 149–160, 2016.
- [72] S. J. Lee, Y. Motai, y H. Choi, “Tracking human motion with multichannel interacting multiple model,” *IEEE Transactions on Industrial Informatics*, vol. 9, num. 3, pp. 1751–1763, 2013.
- [73] P. J. Noonan, J. M. Anton-Rodriguez, T. F. Cootes, W. A. Hallett, y R. Hinz, “Multiple target marker tracking for real-time, accurate, and robust rigid body motion tracking of the head for brain pet,” in *2013 IEEE Nuclear Science Symposium and Medical Imaging Conference (2013 NSS/MIC)*, 2013, pp. 1–6.

- [74] Z. Cao, G. Hidalgo, T. Simon, S. E. Wei, y Y. Sheikh, "OpenPose: Realtime Multi-Person 2D Pose Estimation Using Part Affinity Fields," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 43, num. 1, pp. 172–186, 2021.
- [75] I. Culjak, D. Abram, T. Pribanic, H. Dzapo, y M. Cifrek, "A brief introduction to opencv," in *2012 Proceedings of the 35th International Convention MIPRO*, 2012, pp. 1725–1730.
- [76] V. Morocho, E. Colina-Morles, S. Bautista, A. Mora, y M. Falconí, "Analysis of thermographic patterns using open cv: Case study: A clinker kiln," in *ICINCO 2015 - 12th International Conference on Informatics in Control, Automation and Robotics, Proceedings*, ser. ICINCO 2015 - 12th International Conference on Informatics in Control, Automation and Robotics, Proceedings, J. Filipe, J. Filipe, K. Madani, O. Gusikhin, y J. Sasiadek, Eds. SciTePress, 2015, pp. 479–484, 12th International Conference on Informatics in Control, Automation and Robotics, ICINCO 2015 ; Conference date: 21-07-2015 Through 23-07-2015.
- [77] R. Medina, S. Bautista, A. Zeas-Puga, y V. Morocho, "Aplicación de técnicas de visión por computador para apoyo al diagnóstico de la pisada: Fotopodómetro digital," *Maskana*, vol. 8, p. 93–101, nov. 2017. [En línea]. Disponible: <https://publicaciones.ucuenca.edu.ec/ojs/index.php/maskana/article/view/1454>
- [78] S. He, "A Sitting Posture Surveillance System Based on Kinect," *Journal of Physics: Conference Series*, vol. 1026, num. 1, 2018.
- [79] "Astra series-orbbec 3d." [En línea]. Disponible: <https://orbbec3d.com/index/Product/info.html?cate=38&id=36>
- [80] Tesych, "Cámara de profundidad de azure kinect dk," Dec 2022. [En línea]. Disponible: <https://learn.microsoft.com/es-es/azure/kinect-dk/depth-camera>
- [81] R. Horaud, "A short tutorial on three-dimensional cameras," *Slides*, 2013. [En línea]. Disponible: <https://team.inria.fr/perception/team-members/radu-patrice-horaud/>
- [82] S. H. Yoo, H. Geng, T. L. Chiu, S. K. Yu, D. C. Cho, J. Heo, M. S. Choi, I. H. Choi, C. Cung Van, N. V. Nhung, B. J. Min, y H. Lee, "Deep Learning-Based Decision-Tree Classifier for COVID-19 Diagnosis From Chest X-ray Imaging," *Frontiers in Medicine*, vol. 7, 2020.
- [83] S. Tangirala, "Evaluating the impact of GINI index and information gain on classification using decision tree classifier algorithm," *International Journal of Advanced Computer Science and Applications*, vol. 11, num. 2, pp. 612–619, 2020.
- [84] D. M. Blanco-Murillo, A. García-Domínguez, C. E. Galván-Tejada, y J. M. Celaya-Padilla, "Comparación del nivel de precisión de los clasificadores Support Vector Machines, k Nearest Neighbors, Random Forests, Extra Trees y Gradient Boosting en el reconocimiento de actividades infantiles utilizando sonido ambiental," *Research in Computing Science*, vol. 147, num. 5, pp. 281–290, 2018.
- [85] M. Pal, "Random forest classifier for remote sensing classification," *International Journal of Remote Sensing*, vol. 26, num. 1, pp. 217–222, 2005.
- [86] J. Hoare, "Gradient boosting classifier explained," Aug 2022. [En línea]. Disponible: <https://www.displayr.com/gradient-boosting-the-coolest-kid-on-the-machine-learning-block/>
- [87] "Gradient boosting classifier con python." [En línea]. Disponible: https://www.cienciadedatos.net/documentos/py09_gradient_boosting_python.html

- [88] 3DiVi, “3divi/nuitrack-sdk: Nuitrack™ 3d tracking middleware developed by 3divi inc.” [En línea]. Disponible: <https://github.com/3DiVi/nuitrack-sdk>
- [89] T. Gorschek, P. Garre, S. Larsson, y C. Wohlin, “A model for technology transfer in practice,” *IEEE Software*, vol. 23, num. 6, pp. 88–95, 2006.
- [90] M. Goudswaard, C. Snider, J. Gopsill, D. Jones, M. Harvey, y B. Hicks, “The prototyping fungibility framework,” *Procedia CIRP*, vol. 100, pp. 271–276, 2021. [En línea]. Disponible: <https://doi.org/10.1016/j.procir.2021.05.066>
- [91] D. Tole, “Como establecer una metodología efectiva para el proceso de transición de prototipos tangibles a producto mínimo viable en el departamento del meta,” Ph.D. dissertation, Universidad Santo Tomás, 2020.
- [92] C. A. Hansen, L. S. Jensen, A. G. Özkil, y N. M. Martins Pacheco, “FOSTERING PROTOTYPING MINDSETS in NOVICE DESIGNERS with the PROTOTYPING PLANNER,” *Proceedings of the Design Society: DESIGN Conference*, vol. 1, pp. 1725–1734, 2020.
- [93] V. Gutta, E. D. Lemaire, N. Baddour, y P. Fallavollita, “A Comparison of Depth Sensors for 3D Object Surface Reconstruction,” *CMBES Proceedings*, vol. 42, num. August, pp. 4–7, 2019.
- [94] A. D. C. A. Coroiu y A. Coroiu, “Interchangeability of kinect and orbbec sensors for gesture recognition,” in *2018 IEEE 14th International Conference on Intelligent Computer Communication and Processing (ICCP)*, 2018, pp. 309–315.
- [95] X. Xu y R. W. McGorry, “The validity of the first and second generation microsoft kinect™ for identifying joint center locations during static postures,” *Applied Ergonomics*, vol. 49, pp. 47–54, 2015.
- [96] “Body tracking sdk-orbbec 3d.” [En línea]. Disponible: <https://orbbec3d.com/index/Product/info.html?cate=38&id=38>
- [97] 3DiVi, “3divi/nuitrack: Sdknuitrack sdk general preparations.” [En línea]. Disponible: https://github.com/3DiVi/nuitrack-sdk/blob/master/doc/General_preparations.md#player-environment
- [98] “Download sdk-orbbec 3d.” [En línea]. Disponible: <https://orbbec3d.com/index/download.html>
- [99] PotatotreeSoft, “On 2d-camerameasure - apps en google play.” [En línea]. Disponible: https://play.google.com/store/apps/details?id=com.potatotree.on2dcamerameasure&hl=es_419&gl=US&pli=1
- [100] F. Pedregosa, “Sklearn.ensemble.gradientboostingclassifier.” [En línea]. Disponible: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.GradientBoostingClassifier.html>
- [101] —, “Sklearn.ensemble.randomforestclassifier.” [En línea]. Disponible: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>
- [102] “Research randomizer.” [En línea]. Disponible: <https://randomizer.org/>