



Universidad Católica de Santa María

**Facultad de Ciencias e Ingenierías Físicas y Formales
Escuela Profesional de Ingeniería de Sistemas**

**Modelo de Machine Learning para el monitoreo de actividad motora gruesa
en niños con Síndrome de Down para determinar su desempeño físico en
entornos educativos de Arequipa, Perú**

Tesis presentada por:

Oviedo Villanueva, Hector Daniel

ORCID: 0009-0009-6438-246X

Suarez Fernandez, Sergio Paolo

ORCID: 0009-0007-9542-2239

para optar el Título Profesional de Ingeniero de Sistemas

Asesor (a):

Mg. Santillana Valdivia, Mario Cesar

ORCID: 0009-0009-8472-6055

Arequipa – Perú

2026

UNIVERSIDAD CATÓLICA DE SANTA MARÍA

INGENIERIA DE SISTEMAS

TITULACIÓN CON TESIS

DICTAMEN APROBACIÓN DE BORRADOR

Arequipa, 04 de Marzo del 2026

Dictamen: 014766-C-EPIS-2026

Visto el borrador del expediente 014766, presentado por:

2020803011 - SUAREZ FERNANDEZ SERGIO PAOLO

2020892671 - OVIEDO VILLANUEVA HECTOR DANIEL

Titulado:

MODELO DE MACHINE LEARNING PARA EL MONITOREO DE ACTIVIDAD MOTORA GRUESA EN NIÑOS CON SÍNDROME DE DOWN PARA DETERMINAR SU DESEMPEÑO FÍSICO EN ENTORNOS EDUCATIVOS DE AREQUIPA, PERÚ

Nuestro dictamen es:

APROBADO

Título Profesional/Título de Segunda Especialidad/Grado Académico a optar:

INGENIERO DE SISTEMAS

**29643112 - GUEVARA PUENTE DE LA VEGA KARIM
DICTAMINADOR**



**29601217 - ROSAS PAREDES KARINA
DICTAMINADOR**



**29612305 - SULLA TORRES JOSE ALFREDO
DICTAMINADOR**



MODELO DE MACHINE LEARNING PARA EL MONITOREO DE ACTIVIDAD MOTORA GRUESA EN NIÑOS CON SÍNDROME DE DOWN PARA DETERMINAR SU DESEMPEÑO FÍSICO EN ENTORNOS EDUCATIVOS DE AREQUIPA, PERÚ

INFORME DE ORIGINALIDAD

11%

INDICE DE SIMILITUD

10%

FUENTES DE INTERNET

5%

PUBLICACIONES

5%

TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	Submitted to Universidad Católica de Santa María	2%
	Trabajo del estudiante	
2	repositorio.ucsm.edu.pe	1%
	Fuente de Internet	
3	repositorio.ucv.edu.pe	<1%
	Fuente de Internet	
4	hdl.handle.net	<1%
	Fuente de Internet	
5	ebuah.uah.es	<1%
	Fuente de Internet	
6	www.coursehero.com	<1%
	Fuente de Internet	
7	Submitted to Universidad Internacional de la Rioja	<1%
	Trabajo del estudiante	

Dedicatoria

Quiero dedicar esta tesis a mi madre Silvia, la mujer más valiente que conozco. Por haber enfrentado la vida con una fuerza inquebrantable, tomando cada desafío de nuestro camino como propio y enseñándome a nunca rendirme, incluso cuando todo parecía estar en contra al principio de la carrera. Gracias, mamá, por tu amor constante, tu apoyo sin medida y por ser mi refugio y mi impulso. Este logro es enteramente fruto de tu coraje y de cada día en que decidiste salir adelante conmigo, por y para nosotros. También dedico esta meta alcanzada a mis tíos y tías, cuyo ejemplo de esfuerzo y superación me ha dejado siempre la vara muy alta. Ustedes han sido mi norte y mi guía; he crecido queriendo igualar y superar sus logros como una forma de honrar sus vidas. Por enseñarme con su propio ejemplo que los límites existen solo para ser superados. Por último, quiero agradecer a mis mejores amigos, con quienes compartí cursos. Las risas y el ánimo mutuo que siempre nos dimos fue fundamental para enfrentar los retos y llegar hasta aquí. Para mí, los amigos son la familia que uno elige, y me siento muy agradecido de haber contado con ustedes en esta etapa tan importante de mi vida.

Hector Daniel Oviedo Villanueva

Dedico esta tesis a Jesucristo, mi Dios y Salvador, quien nunca me abandonó en mis momentos más difíciles, fue y será siempre mi mayor soporte, el cual me ha dado todo lo bueno que poseo y la victoria cuando parecía imposible; a Patricia, mi madre, quien con su amor y sacrificio me dio siempre lo mejor de ella, me enseñó valores, a nunca rendirme y ser un buen hombre; a Julio César, mi padre, quien siempre me enseñó disciplina, orden y carácter, incentivó y sembró en mí esta pasión por la tecnología; a Edith, Nora y José, mis abuelos, quienes me aman


tanto, me brindaron sus sabios consejos y me dieron su apoyo incondicional siempre, en especial a Edith, quien siempre veló por mí e hizo posible que yo pueda llegar hasta donde estoy; finalmente, a mis tíos, quienes siempre estuvieron para mí y me dieron todo su cariño. Quiero agradecerles a todos los mencionados, pues forman parte de lo que soy y por ellos he logrado mis metas.

Sergio Paolo Suarez Fernandez



Agradecimientos

Agradecemos a la Universidad Católica de Santa María, en la cual adquirimos los conocimientos y valores profesionales para desempeñarnos al más alto nivel en esta profesión; a Cáritas Arequipa, quienes nos abrieron las puertas de su Institución y proporcionaron todas las facilidades para que esta investigación pueda ser concretada. Queremos también dar especial agradecimiento a Dios y a los miembros de nuestras familias. Asimismo, expresamos nuestra sincera gratitud a la Dra. Eveling Castro, a la Dra. Karina Rosas, a la Dra. Karim Guevara y al Dr. José Sullá por su valioso apoyo al compartir sus conocimientos en el curso de Investigación y por su constante feedback para el desarrollo de esta tesis.



RESUMEN

Los niños con Síndrome de Down suelen presentar un desarrollo motor grueso reducido, lo que afecta su rendimiento en actividades físicas. En el contexto escolar, la evaluación del desempeño suele basarse en la observación del docente, susceptible a sesgos; por ello, algunos estudiantes progresan mientras otros no alcanzan mejoras. Ante esta situación, el objetivo fue desarrollar un modelo de monitoreo basado en visión computacional que permita clasificar de forma objetiva, rápida y automatizada a estudiantes con síndrome de Down según su nivel de rendimiento (alto, moderado o bajo), facilitando la adaptación de las actividades a sus necesidades. La presente investigación fue de tipo aplicada, con un enfoque cuantitativo, con niveles descriptivo y correlacional, y un diseño cuasi experimental. El desarrollo del modelo siguió la metodología CRISP-DM. Para el entrenamiento y validación, durante 4 meses se trabajó con una muestra de 23 niños de 8 escuelas pertenecientes a Cáritas Arequipa; se emplearon como herramientas principales Google Meet, reuniones presenciales, Microsoft Excel, registros de actividades y cámaras Canon. El modelo utilizó el modelo BlazePose (MediaPipe) para la extracción de landmarks y el algoritmo Random Forest Classifier para la clasificación. Tras su aplicación, se evidenció una mejora del desempeño físico de los niños en cuatro ejercicios: 43.5% mejoró en Gatear, 34.8% en Lanzamiento de Pelota, 34.8% en Pararse y Sentarse en una Silla y 13% en Salto en dos pies. Asimismo, los modelos alcanzaron exactitudes del 97.23% (Gatear), 95.3% (Salto en dos pies), 95.1% (Lanzamiento de Pelota) y 90.37% (Pararse y Sentarse en una Silla). En conclusión, el modelo propuesto resultó efectivo para evaluar y clasificar objetivamente la motricidad gruesa, contribuyendo a la mejora del desarrollo físico en niños con Síndrome de Down.

Palabras Clave. Síndrome de Down, Visión Computacional, Machine Learning.

ABSTRACT

Children with Down syndrome often exhibit reduced gross motor development, which affects their performance in physical activities. In the school setting, performance assessment is usually based on teacher observation, which is susceptible to bias; therefore, some students progress while others do not improve. Given this situation, the objective was to develop a computer vision-based monitoring model that allows for the objective, rapid, and automated classification of students with Down syndrome according to their performance level (high, moderate, or low), facilitating the adaptation of activities to their needs. This applied research employed a quantitative approach, with descriptive and correlational levels, and a quasi-experimental design. The model was developed following the CRISP-DM methodology. For training and validation, a sample of 23 children from eight schools belonging to Caritas Arequipa was used for four months. The main tools used were Google Meet, in-person meetings, Microsoft Excel, activity logs, and Canon cameras. The model used the BlazePose (MediaPipe) model for landmark extraction and the Random Forest Classifier algorithm for classification. After its application, an improvement in performance was observed in four exercises: 43.5% in Crawling, 34.8% in Ball Throwing, 34.8% in Chair Standing and Sitting, and 13% in Two-Legged Hopping. Furthermore, the models achieved accuracies of 97.23% (Crawling), 95.3% (Two-Legged Hopping), 95.1% (Ball Throwing), and 90.37% (Chair Standing and Sitting). In conclusion, the proposed model proved effective in objectively evaluating and classifying gross motor skills, contributing to the improvement of physical development in children with Down syndrome.

Keywords. Down Syndrome, Computer Vision, Machine Learning.

Índice general

Dedicatoria

Agradecimientos

RESUMEN

ABSTRACT

INTRODUCCIÓN.....1

CAPÍTULO I.....3

PLANTEAMIENTO DE LA INVESTIGACIÓN.....4

1.1. Planteamiento del problema.....4

1.2. Objetivos de la Investigación.....6

1.2.1. Objetivo General.....6

1.2.2. Objetivos Específicos.....6

1.3. Preguntas de Investigación.....7

1.4. Hipótesis, Variables e Indicadores.....7

1.4.1. Hipótesis.....7

1.4.2. Variables de Investigación.....8

1.4.3. Indicadores.....8

1.5. Línea y Sublínea de Investigación.....8

1.6. Palabras Clave.....8

1.7. Solución Propuesta.....9

1.7.1. Justificación e Importancia.....	9
1.7.2. Descripción de la Solución.....	11
1.7.3. Aporte	12
1.7.4. Matriz de Consistencia.....	13
CAPÍTULO II.....	17
FUNDAMENTOS TEÓRICOS	18
2.1. Antecedentes de Investigación.....	18
2.2. Estado del Arte.....	21
2.3. Bases Teóricas de la Investigación	27
2.3.1. Síndrome de Down.....	27
2.3.2. Motricidad gruesa.....	27
2.3.3. Inteligencia Artificial.....	28
2.3.4. Visión Computacional	28
2.3.5. Open CV	29
CAPÍTULO III	30
MARCO METODOLÓGICO	31
3.1. Alcances y Limitaciones.....	31
3.2. Tipo y Nivel de Investigación.....	32
3.3. Universo, Población y Muestra	33
3.3.1. Universo.....	33

3.3.2. Población.....	33
3.3.3. Muestra.....	33
3.4. Métodos, Técnicas e Instrumentos de Recolección de Datos.....	35
3.4.1. Metodología de Desarrollo.....	35
3.4.2. Técnicas de recolección de datos.....	36
3.4.2.1. Entrevistas.....	36
3.4.2.2. Observación.....	36
3.4.2.3. Captura de imágenes.....	36
3.4.3. Instrumentos de recolección de datos.....	36
3.4.3.1. Google Meet.....	36
3.4.3.2. Reuniones Presenciales.....	37
3.4.3.3. Microsoft Excel.....	37
3.4.3.4. Registros de actividades.....	37
3.4.3.5. Cámaras Canon.....	37
3.4.4. Técnicas de procesamiento de datos.....	38
3.4.4.1. Procesamiento de postura y reconocimiento de movimiento.....	38
3.4.4.2. Algoritmo de Machine Learning.....	38
3.4.4.3. Análisis de Componentes Principales (PCA).....	38
3.4.4.4. Técnicas de evaluación y validación del modelo.....	39
3.4.5. Herramientas para el procesamiento de datos.....	39

3.4.5.1. Open CV	39
3.4.5.2. MediaPipe.....	39
3.4.5.3. Random Forest Classifier.....	40
CAPÍTULO IV	41
DESARROLLO DE LA PROPUESTA DE INVESTIGACIÓN	42
4.1. Selección de Ejercicios Físicos.....	42
4.2. Acceso a la Población Objetivo	43
4.2.1. Contacto con la Institución	43
4.2.2. Visitas a las Escuelas	44
4.2.2.1. Primera Visita	44
4.2.2.2. Segunda Visita.....	44
4.3. Desarrollo en Visión Computacional.....	45
4.3.1. Generación del Conjunto de Datos	45
4.3.1.1. Configuración del Equipo de Grabación de Videos Preliminares.....	45
4.3.1.2. Procedimiento para la Grabación de Videos (Dataset)	46
4.3.2. Implementación	52
4.3.2.1. Entorno de Desarrollo.....	53
4.3.2.1.1. Preparación Previa a la Codificación	53
4.3.2.1.2. Guías de Nomenclatura	55
4.3.2.2. Fase 1: Comprensión del Negocio y Arquitectura	56

4.3.2.2.1. Recursos	59
4.3.2.2.2. Restricciones	59
4.3.2.2.3. Definición de la Arquitectura técnica (Pipeline del sistema).....	59
4.3.2.3. Fase 2: Comprensión de los Datos.....	62
4.3.2.3.1. Extracción de Características	62
4.3.2.3.2. Análisis Exploratorio y Selección de Articulaciones.....	63
4.3.2.4. Fase 3: Preparación de los Datos.....	64
4.3.2.4.1. Pre-procesamiento y Limpieza.....	64
4.3.2.4.2. Generación de Etiquetas de Desempeño	65
4.3.2.4.3. Reducción de Dimensionalidad.....	67
4.3.2.5. Fase 4: Modelado.....	68
4.3.2.5.1. Diseño Experimental.....	68
4.3.2.5.2. Selección de algoritmos.....	69
4.3.2.5.3. Resultados Experimentales Comparativos	70
4.3.2.5.4. Discusión y Selección del Modelo Final.....	71
4.3.2.5.5. Configuración del Modelo Final.....	72
4.3.2.5.6. Arquitectura del Sistema.....	72
4.3.2.6. Fase 5: Evaluación	74
4.3.2.6.1. Protocolo de Validación y Definición de Métricas.....	75
4.3.2.6.2. Sentarse y pararse de una silla.....	78

4.3.2.6.3.	Lanzamiento de pelota.....	81
4.3.2.6.4.	Gatear.....	84
4.3.2.6.5.	Salto en dos pies.....	87
4.3.2.7.	Fase 6: Despliegue.....	90
4.3.2.7.1.	Proceso de Predicción con el Modelo Entrenado.....	90
4.3.2.7.2.	Generación de Reportes y Retroalimentación.....	91
4.3.2.7.3.	Validación en Entorno Real.....	92
CAPÍTULO V		93
ANÁLISIS Y VALIDACIÓN DE RESULTADOS		94
5.1.	Resultados.....	94
5.1.1.	Resultados en Visión Computacional.....	94
5.1.1.1.	Sentarse y pararse de una silla.....	94
5.1.1.1.1.	Resultados Promedio Obtenidos en Exactitud.....	95
5.1.1.1.2.	Métricas por Clase.....	95
5.1.1.1.3.	Promedios Globales.....	95
5.1.1.1.4.	Interpretación de Resultados en las Métricas.....	96
5.1.1.1.5.	Análisis Integral.....	100
5.1.1.2.	Lanzamiento de pelota.....	101
5.1.1.2.1.	Resultados Promedio Obtenidos en Exactitud.....	101
5.1.1.2.2.	Métricas por Clase.....	102


5.1.1.2.3.	Promedios Globales.....	102
5.1.1.2.4.	Interpretación de Resultados en las Métricas.....	102
5.1.1.2.5.	Análisis Integral	107
5.1.1.3.	Gatear	108
5.1.1.3.1.	Resultados Promedio Obtenidos en Exactitud	108
5.1.1.3.2.	Métricas por Clase	108
5.1.1.3.3.	Promedios Globales.....	108
5.1.1.3.4.	Interpretación de Resultados en las Métricas.....	109
5.1.1.3.5.	Análisis Integral	113
5.1.1.4.	Salto en dos pies.....	114
5.1.1.4.1.	Resultados Promedio Obtenidos en Exactitud	114
5.1.1.4.2.	Métricas por Clase	114
5.1.1.4.3.	Promedios Globales.....	115
5.1.1.4.4.	Interpretación de Resultados en las Métricas.....	115
5.1.1.4.5.	Análisis Integral	120
5.1.2.	Resultados del Desempeño Físico de los Niños	121
5.1.2.1.	Análisis del Desempeño.....	121
5.1.2.2.	Impacto Educativo.....	126
5.1.2.2.1.	Diseño del estudio de validación	127
5.1.2.2.2.	Instrumentos de medición de mejora	132

5.1.2.2.3.	Comparación de Resultados.....	134
5.1.2.2.4.	Análisis del Progreso en el Desempeño Físico.....	136
5.2.	Discusión.....	140
5.2.1.	Principales Hallazgos	140
5.2.1.1.	Software.....	140
5.2.1.2.	Hardware.....	141
5.2.2.	Fortalezas y Limitaciones	142
5.2.2.1.	Software.....	142
5.2.2.1.1.	Fortalezas.....	142
5.2.2.1.2.	Limitaciones.....	144
5.2.2.2.	Hardware.....	145
5.2.2.2.1.	Fortalezas.....	145
5.2.2.2.2.	Limitaciones.....	146
5.2.2.3.	Tamaño de la Muestra.....	147
5.2.2.3.1.	Fortalezas.....	147
5.2.2.3.2.	Limitaciones.....	147
5.2.2.4.	Calidad de Video.....	148
5.2.2.4.1.	Fortalezas.....	148
5.2.2.4.2.	Limitaciones.....	148
5.2.2.5.	Variabilidad entre Participantes.....	149

5.2.2.5.1. Fortalezas.....	149
5.2.2.5.2. Limitaciones.....	149
5.2.3. Comparación con trabajos previos.....	150
5.2.4. Análisis de Costos del Proyecto.....	151
5.2.4.1. Recursos Humanos.....	151
5.2.4.2. Equipamiento y Tecnología.....	152
5.2.4.3. Materiales y Recursos Educativos.....	153
5.2.4.4. Implementación en Campo.....	154
5.2.5. Trabajos Futuros.....	155
5.3. Validación de la Hipótesis.....	156
Conclusiones.....	158
Recomendaciones.....	161
Trabajos Futuros.....	163
REFERENCIAS.....	164
APÉNDICES.....	171
6.1. Plan de Trabajo.....	171
6.2. Documento de Consentimiento Informado.....	174
6.3. Documento Excel para la toma de datos.....	177
6.4. Guía Técnica del Modelo.....	177
6.4.1. Instalación del Modelo.....	177

6.4.1.1.	Prerrequisitos.....	178
6.4.1.2.	Pasos para la Instalación.....	178
6.4.2.	Uso del Modelo.....	179
6.4.2.1.	Entrenamiento de modelos.....	179
6.4.2.2.	Evaluación de video.....	180
6.4.2.3.	Ejecución de pruebas.....	181
6.4.3.	Estructura del Proyecto.....	181
6.4.4.	Documentación del Módulo.....	182
6.4.4.1.	Pipeline de entrenamiento.....	182
6.4.4.2.	Pipeline de evaluación.....	183
6.4.5.	Pruebas.....	183
6.4.6.	Métricas de rendimiento.....	183
6.4.7.	Solución de problemas.....	184
6.4.7.1.	Problemas comunes.....	184
6.5.	Guía para Grabación de Videos.....	184
6.5.1.	Entorno de Grabación.....	185
6.5.1.1.	Iluminación.....	185
6.5.1.2.	Fondo.....	185
6.5.2.	Cámara y Video.....	186
6.5.2.1.	Especificaciones de Cámara.....	186

6.5.2.2. Estabilidad de la Cámara.....	186
6.5.2.3. Calidad de Video.....	186
6.5.2.4. Posición y Márgenes.....	187
6.5.2.5. Duración y Contenido.....	187
6.6. Cartas y Memorandos.....	188



Índice de figuras

Figura 2.1 Ejercicio donde se emplea la Motricidad Gruesa	27
Figura 2.2 Ramas de la Visión Computacional	28
Figura 2.3 Librería Open CV	29
Figura 4.1 Niña se para y se sienta en la silla	48
Figura 4.2 Silla de madera.....	48
Figura 4.3 Niña realiza lanzamiento de pelota.....	49
Figura 4.4 Pelotas de algodón.....	49
Figura 4.5 Recipiente de plástico.....	50
Figura 4.6 Niño gatea hacia un cono.....	50
Figura 4.7 Cono.....	51
Figura 4.8 Niña realiza saltos en dos pies.....	51
Figura 4.9 Hula-hulas y escalera de tela	52
Figura 4.10 Versión de Python en la cual se basa el entorno virtual.....	53
Figura 4.11 Configuración del intérprete de Python.....	53
Figura 4.12 Instalación de librerías.....	54
Figura 4.13 Arquitectura de archivos.....	55
Figura 4.14 Esquema del Modelo	58
Figura 4.15 Modelo pre-entrenado.....	59
Figura 4.16 Flujo de transformación de datos.....	61
Figura 4.17 Arquitectura del Sistema.....	74
Figura 4.18 Matriz de Confusión del ejercicio Sentarse y pararse de una silla	78
Figura 4.19 Resultados de evaluación del ejercicio Sentarse y pararse de una silla.....	80

Figura 4.20 Matriz de Confusión del ejercicio Lanzamiento de Pelota.....81

Figura 4.21 Resultados de evaluación del ejercicio Lanzamiento de Pelota.....83

Figura 4.22 Matriz de Confusión del ejercicio Gatear.....84

Figura 4.23 Resultados de evaluación del ejercicio Gatear.....86


Figura 4.24 Matriz de Confusión del ejercicio Saltos en 2 pies.....87

Figura 4.25 Resultados de evaluación del ejercicio Saltos en 2 pies.....89

Figura 4.26 Resultados de desempeño.....91

Figura 5.1 Exactitud de los Modelos correspondientes a cada ejercicio.....120

Figura 5.2 Estructura de Archivos del Proyecto.....181



Índice de tablas

Tabla 1.1 Matriz de Consistencia.....	13
Tabla 1.2 Matriz de Consistencia.....	14
Tabla 1.3 Matriz de Consistencia.....	15
Tabla 1.4 Matriz de Operacionalización de Variables.....	16
Tabla 4.1 Especificaciones de cámaras Canon.....	45
Tabla 4.2 Comparación de Desempeño de Algoritmos de Clasificación.....	70
Tabla 5.1 Exactitud del modelo en Sentarse y pararse de una silla.....	95
Tabla 5.2 Resultados de las métricas por clase en Sentarse y pararse de una silla.....	95
Tabla 5.3 Exactitud del modelo en Lanzamiento de Pelota.....	101
Tabla 5.4 Resultados de las métricas por clase en Lanzamiento de Pelota.....	102
Tabla 5.5 Exactitud del modelo en Gatear.....	108
Tabla 5.6 Resultados de las métricas por clase en Gatear.....	108
Tabla 5.7 Exactitud del modelo en Saltos en 2 Pies.....	114
Tabla 5.8 Resultados de las métricas por clase en Saltos en 2 Pies.....	114
Tabla 5.9 Resultados de los niños antes del uso del Modelo.....	122
Tabla 5.10 Cantidad de niños según nivel de desempeño alcanzado en los ejercicios.....	123
Tabla 5.11 Porcentaje de niños según nivel de desempeño alcanzado en los ejercicios.....	123
Tabla 5.12 Resultados de los niños después del uso del Modelo.....	124
Tabla 5.13 Cantidad de niños según nivel de desempeño alcanzado en los ejercicios.....	125
Tabla 5.14 Porcentaje de niños según nivel de desempeño alcanzado en los ejercicios.....	126
Tabla 5.15 Distribución de Fotogramas por clase en Salto en 2 pies.....	130
Tabla 5.16 Distribución de Fotogramas por clase en Lanzamiento de Pelota.....	131

Tabla 5.17 Distribución de Fotogramas por clase en Gatear.....	131
Tabla 5.18 Distribución de Fotogramas por clase en Sentarse y Pararse de una Silla	131
Tabla 5.19 Características del modelo como instrumento.....	133
Tabla 5.20 Características de las encuestas como instrumento	133
Tabla 5.21 Comparación antes y después en el nivel Alto	134
Tabla 5.22 Comparación antes y después en el nivel Moderado.....	135
Tabla 5.23 Comparación antes y después en el nivel Bajo.....	136
Tabla 5.24 Cantidad de niños que mantuvieron el mismo nivel de desempeño en Salto en 2 pies	137
Tabla 5.25 Cantidad de niños que progresaron o retrocedieron en su desempeño en Salto en 2 pies.....	137
Tabla 5.26 Cantidad de niños que mantuvieron el mismo nivel de desempeño en Lanzamiento de Pelota.....	137
Tabla 5.27 Cantidad de niños que progresaron o retrocedieron su desempeño en Lanzamiento de pelota.....	138
Tabla 5.28 Cantidad de niños que mantuvieron el mismo nivel de desempeño en Gatear.....	138
Tabla 5.29 Cantidad de niños que progresaron o retrocedieron en su desempeño en Gatear.....	138
Tabla 5.30 Cantidad de niños que mantuvieron el mismo desempeño en Pararse y sentarse en una silla	139
Tabla 5.31 Cantidad de niños con progreso o retroceso de desempeño en Pararse y sentarse en una silla.....	139
Tabla 5.32 Costos estimados en Recursos Humanos para este proyecto en general	152
Tabla 5.33 Costos en Recursos Humanos para los autores de esta investigación	152
Tabla 5.34 Costos estimados en Equipamiento y Tecnología para este proyecto en general.....	153

Tabla 5.35 Costos en Equipamiento y Tecnología para los autores de esta investigación.....153

Tabla 5.36 Costos estimados en Materiales y Recursos Educativos para este proyecto en general
.....154


Tabla 5.37 Costos en Materiales y Recursos Educativos para los autores de esta investigación 154

Tabla 5.38 Costos estimados de Implementación en Campo para este proyecto en general.....154

Tabla 5.39 Costos de Implementación en Campo para los autores de esta investigación.....155

Tabla 5.40 Contraste de la hipótesis con los resultados obtenidos.....157

Tabla 5.41 Hoja de cálculo para la toma de datos177



Lista de Códigos

Código 4.1: Script de análisis de varianza acumulada para determinar número óptimo de componentes.....	68
Código 4.2: Visualización de la Matriz de Confusión con Heatmap	77
Código 4.3: Evaluación del Desempeño del Modelo mediante Métricas de Clasificación.....	77
Código 4.4: Evaluación de desempeño mediante predicción en videos usando el Modelo Preentrenado.....	90
Código 5.1: Comandos para clonar el repositorio de GitHub.....	178
Código 5.2: Comandos para la creación del entorno virtual	178
Código 5.3: Comando para activar el entorno virtual en Windows	178
Código 5.4: Comando para activar entorno virtual en macOS o Linux	179
Código 5.5: Comandos para realizar la instalación de dependencias.....	179
Código 5.6: Comandos para el entrenamiento de los modelos	179
Código 5.7: Comandos para evaluar los próximos videos con el modelo ya entrenado.....	180
Código 5.8: Comandos para ejecutar pruebas.....	181
Código 5.9: Código para la canalización del entrenamiento.....	182
Código 5.10: Código para manejar el procesamiento de video y extracción de keypoints.....	182
Código 5.11: Código de las principales funciones de predicción y evaluación.....	183
Código 5.12: Comando para ejecutar el conjunto de pruebas.....	183
Código 5.13: Comando para realizar la instalación de MediaPipe	184

INTRODUCCIÓN

Según el Consejo Nacional para la Integración de las Personas con Discapacidad (CONADIS) entre el 2000 y 2024, en el Perú existen 25,113 personas que han sido diagnosticadas con síndrome de Down, de los cuales el 53,2% son hombres y el 46,8% son mujeres, correspondiendo a 13,355 hombres y 11,758 mujeres (CONADIS, 2022). La ciudad de Arequipa no es ajena a esta situación, ya que existe un aproximado de 1014 personas que la padecen, 554 hombres y 460 mujeres (CONADIS, 2024), los cuales enfrentan problemas de desarrollo muscular bajo y escasa energía, lo que provoca que se retrase la fase de desarrollo sensorio-motriz (Isralowitz et al., 2023).

A pesar de estas cifras, la educación actual en el país carece de propuestas tecnológicas innovadoras enfocadas en mejorar las deficiencias físicas que enfrentan los niños con síndrome de Down. Esta carencia se debe tanto a la limitada inversión en investigación como al desconocimiento de los educadores sobre el verdadero nivel de desempeño físico de estos niños, lo cual impacta negativamente en su capacidad para participar de manera activa en actividades físicas recreativas.

Aun cuando el uso de la inteligencia artificial en la educación regular ha ido en aumento, no se han encontrado registros de su aplicación en la educación especializada para niños con síndrome de Down, especialmente en lo que respecta al desarrollo de su motricidad gruesa. En este contexto esta investigación busca evaluar el impacto que la inteligencia artificial, mediante la visión computacional, podría tener en el desarrollo de la motricidad gruesa en niños con síndrome de Down. Específicamente, se pretende diseñar un modelo que capture los movimientos de los niños en determinadas actividades físicas, y posteriormente permita analizar este contenido

identificando las fallas de ejecución de estos, para clasificarlos en función del desempeño obtenido. Aunque la adaptación personalizada de las actividades para cada niño luego de la evaluación con el modelo es una aplicación valiosa que surge de esta investigación, dicha adaptación escapa al alcance del proyecto actual.

La presente investigación se organiza de la siguiente manera:

En el Capítulo 1 se expone el planteamiento del problema junto con el objetivo general y los objetivos específicos, las preguntas de investigación, y la delimitación del estudio. Asimismo, se justifica la importancia del trabajo y se describe de manera conceptual la solución propuesta.

En el Capítulo 2 se expone una revisión detallada del Estado del Arte, también se ofrecen las bases teóricas que abordan las terminologías relevantes en profundidad.

En el Capítulo 3 se presenta el marco metodológico, detallando los alcances y limitaciones de la investigación, su tipo y nivel. Además, se describe la población y muestra, junto con los métodos, técnicas e instrumentos empleados.

El Capítulo 4 está orientado al desarrollo de la propuesta y la presentación de los resultados obtenidos.

Por último, el Capítulo 5 incluye el análisis y validación de los resultados, seguido de las conclusiones, recomendaciones y posibles líneas de investigación futura.



CAPÍTULO I

PLANTEAMIENTO DE LA INVESTIGACIÓN

1.1. Planteamiento del problema

El Síndrome de Down es una alteración definida por la existencia de una copia adicional del cromosoma 21. Pues, los niños que la padecen tienen un mayor riesgo de poseer diversas anomalías innatas, esto hasta en un 60%. Además, en general, los que padecen el síndrome de Down son susceptibles a muchas comorbilidades (Alsulami et al., 2024).

Según el Consejo Nacional para la Integración de las Personas con Discapacidad (CONADIS) entre el 2000 y 2024, se obtuvo que en el Perú existen 25,113 personas que han sido diagnosticadas con Síndrome de Down, de los cuales el 53,2% son hombres y el 46,8% son mujeres, correspondiendo a 13,355 hombres y 11,758 mujeres (CONADIS, 2022). La ciudad de Arequipa no es ajena a esta situación, ya que existe un aproximado de 1014 personas que la padecen, 554 hombres y 460 mujeres (CONADIS, 2024), los cuales enfrentan problemas de desarrollo muscular bajo y escasa energía, lo que provoca que se retrase la fase de desarrollo sensorio-motriz (Isralowitz et al., 2023).

Pese a estos números, en la educación actual del país, no se contemplan propuestas tecnológicas innovadoras especializadas que ayuden al desarrollo motor de estos niños, siendo una de las causas la falta de inversión en investigación en esta población, además del desconocimiento por parte de los educadores sobre el verdadero nivel de desempeño de estos niños, lo que puede afectar significativamente su capacidad para participar activamente en actividades físicas recreacionales.

Si bien los niños con Síndrome de Down tienen habilidad en el procesamiento visual-espacial, enfrentan complicaciones en su desarrollo motor. Esto puede provocar que disminuya su

motivación para participar en actividades físicas, lo cual además puede llegar a impactar de manera negativa su desarrollo físico y su capacidad para poder interactuar con el entorno (Isralowitz et al., 2023).

No obstante, en la actualidad la inteligencia artificial ha sido adoptada y utilizada especialmente en las instituciones educativas regulares, en diversas formas. Inicialmente tomó la forma de computadoras, luego pasó a ser sistemas educativos inteligentes online y, finalmente, a robots basados en la web que utilizan sistemas informáticos integrados, entre otras tecnologías como chatbots para realizar tareas y funciones de forma independiente o dependiente. Al utilizar estas plataformas, los profesores pueden realizar diversas funciones administrativas, como revisar y calificar el trabajo de los estudiantes de manera más eficiente y mejorar la calidad de las actividades de aprendizaje (Chen et al., 2020). Sin embargo, a pesar del creciente uso de la IA en la educación regular no se han encontrado registros de aplicaciones de esta en la educación especializada en niños con Síndrome de Down particularmente orientada al desarrollo motriz grueso de estos.

Dado el actual panorama, resulta relevante mencionar el proyecto desarrollado por estudiantes de la Universidad Católica de Santa María en 2023, uno de los pocos ejemplos que guarda una estrecha relación con el tema que aborda la presente investigación, el cual evalúa la actividad física de estudiantes universitarios a través de un prototipo de Visión Computacional similar al que se propone en el presente documento. Esto permitió establecer una línea base de actividad física de los universitarios de Arequipa sin ninguna discapacidad (Sulla-Torres et al., 2023). En contraste, un objetivo de la presente investigación, así como su aporte es lograr una mayor precisión por parte del Modelo sin la necesidad de utilizar cámaras especiales ni costosas, tales como las cámaras Azure Kinect.

A partir de ello, esta investigación propone evaluar cómo la inteligencia artificial, a través de la visión computacional, puede impactar en el desarrollo de las actividades físicas de los niños con Síndrome de Down, enfocándose específicamente en la motricidad gruesa. El objetivo principal de esta investigación es desarrollar un modelo capaz de clasificar el desempeño en distintas actividades, identificando patrones que podrían ser útiles en futuras aplicaciones educativas. Sin embargo, aunque la idea de adaptar las actividades a las necesidades específicas de cada niño es interesante, esto queda fuera del alcance de este proyecto. No obstante, los resultados del prototipo sirven como una herramienta para que los educadores, mediante su conocimiento en educación para niños con habilidades diferentes, puedan realizar estas adaptaciones en función de las necesidades individuales de cada niño.

1.2. Objetivos de la Investigación

1.2.1. Objetivo General

Implementar un modelo de Machine Learning para el monitoreo de movimientos utilizando técnicas de visión computacional, para identificar patrones de motricidad en los niños con Síndrome de Down, con el fin de clasificarlos en función de su desempeño.

1.2.2. Objetivos Específicos

1. Analizar datos de movimiento de niños con Síndrome de Down en entornos educativos de Arequipa, Perú para identificar patrones y necesidades específicas.
2. Implementar algoritmos de análisis de datos existentes para identificar patrones de movimiento y comportamientos relevantes para la participación en actividades educativas.

3. Determinar el nivel de desempeño de los niños en las actividades planteadas y clasificarlos según 3 criterios: alto, moderado, bajo.
4. Validar la efectividad del Modelo a través de su aplicación por docentes en la evaluación del desempeño físico de niños con Síndrome de Down.

1.3. Preguntas de Investigación

1. ¿Cuáles son los patrones de movimiento y necesidades específicas en las actividades físicas de los niños con Síndrome de Down?
2. ¿Qué algoritmos son más efectivos para identificar y analizar patrones de movimientos en niños con Síndrome de Down?
3. ¿Cuál es el método más efectivo para clasificar el nivel de desempeño de los niños con Síndrome de Down en actividades físicas?
4. ¿En qué medida el Modelo mejora la evaluación del desempeño físico de niños con Síndrome de Down por parte de los docentes?

1.4. Hipótesis, Variables e Indicadores

1.4.1. Hipótesis

Mediante la implementación del modelo de monitoreo de movimientos utilizando técnicas de visión computacional, será posible identificar patrones en la motricidad gruesa de niños con Síndrome de Down y, en consecuencia, clasificarlos en niveles de desempeño (alto, moderado o bajo) según el desempeño de sus movimientos.

1.4.2. Variables de Investigación

- **Variable Dependiente:** Nivel de desempeño (alto, moderado o bajo), mejora en la evaluación de los niños.
- **Variable Independiente:** Modelo de monitoreo de movimientos mediante técnicas de visión computacional.

1.4.3. Indicadores

- **Indicadores Variable Dependiente**
 - Porcentaje de niños que logran una mejora en su rendimiento físico
 - Brechas en el rendimiento físico entre los niños
- **Indicadores Variable Independiente**
 - Precisión
 - Recall
 - F1-Score
 - Soporte
 - Exactitud

1.5. Línea y Sublínea de Investigación

1. Línea de Investigación: inteligencia artificial
2. Sublínea de Investigación: visión computacional

1.6. Palabras Clave

Síndrome de Down, Visión Computacional, Machine Learning.

1.7. Solución Propuesta

1.7.1. Justificación e Importancia

La educación física especializada para niños con Síndrome de Down enfrenta un desafío a la hora de evaluar de manera objetiva los avances de cada niño. Las evaluaciones tradicionales suelen ser subjetivas y pueden no detectar pequeños progresos, lo que limita la capacidad de adaptar las intervenciones a las necesidades individuales, por lo que es común que algunos niños consigan avances físicos significativos y algunos otros queden rezagados (Ortiz Távora & Reynosa Navarro, 2021). Se ha demostrado que la actividad física en las personas con Síndrome de Down mejora su autonomía, salud física, salud mental y su inclusión social; pues, mediante un programa de actividad física se ha logrado mejorar habilidades motoras muy importantes, tales como la flexibilidad, velocidad y fuerza. Incluso, se puede prevenir problemas de salud muy comunes en personas con Síndrome de Down, como la obesidad y las enfermedades cardiovasculares (Benavides Pando et al., 2023); además, los juegos y actividades tradicionales logran mejorar las habilidades motoras gruesas, la integración social y la autoestima de los niños con Síndrome de Down (Sailema Torres et al., 2017). En este sentido, una intervención adaptada en particular a las necesidades de los niños con Síndrome de Down puede mejorar significativamente sus habilidades motoras gruesas al emplear tecnologías como la Realidad Virtual, que resultaría más atractiva para los niños y fomentaría su participación en las actividades de educación física (Gómez Álvarez et al., 2018); una alternativa para ello puede ser el uso de la visión computacional, mediante la cual se podría lograr una exactitud y objetividad aún mayores que los métodos tradicionales; pues, al contar con esta tecnología, esta se puede llegar a extrapolar o importar a una aplicación amigable para que los docentes y especialistas puedan emplearla en sus actividades físicas y evaluaciones diarias (Sulla-Torres et al., 2023). Al aplicar esta tecnología, podría ser posible monitorear con

precisión las articulaciones corporales y, de esta manera, obtener información detallada sobre el movimiento de la persona. La capacidad de poder monitorear y analizar el movimiento de cada articulación del cuerpo con una alta precisión, permite crear soluciones más eficaces y específicas según las necesidades de cada individuo para mejorar su motricidad (Posner et al., 2023).

En consecuencia, surge la necesidad de mejorar la educación física especializada para este grupo de niños con habilidades diferentes. Para poder lograrlo, se desarrolló un modelo de Machine Learning entrenado para monitorear y detectar el desempeño de los niños, lo cual podría ofrecer una solución prometedora al brindar una evaluación más precisa y objetiva, permitiendo identificar patrones en la motricidad gruesa y clasificar a los niños en función de su desempeño. Esta información valiosa puede ser utilizada por los docentes para diseñar programas de ejercicio personalizados que les permitan adaptar la evaluación y el aprendizaje a las necesidades específicas de cada niño; no obstante, cabe resaltar que en la presente propuesta, solamente se desarrollará el modelo de Machine Learning; pues, la adaptación de la evaluación y el aprendizaje respecto a las necesidades específicas de cada niño, escapa al alcance del proyecto y queda en manos de los docentes realizarlo con los resultados que obtenga al usar el modelo.

Adicionalmente, la presente investigación contribuye con los principios establecidos en la Ley N° 29973 – Ley General de la Persona con Discapacidad, promulgada por el Congreso de la República del Perú, la cual establece la necesidad de promover la inclusión plena y efectiva de las personas con discapacidad en los ámbitos educativo y tecnológico (Ministerio de la Mujer y Poblaciones Vulnerables, 2019).

1.7.2. Descripción de la Solución

Para abordar este desafío, se propone el desarrollo de una herramienta tecnológica para el monitoreo y evaluación de las actividades físicas en niños con Síndrome de Down. Esta herramienta está basada en visión computacional, permite analizar y extraer información valiosa de las imágenes capturadas, lo cual se podrá realizar por medio de las cámaras, que se instalarán en un pequeño escenario donde los niños realizarán juegos o actividades físicas, y dichas cámaras captarán las imágenes en 3D desde diferentes ángulos; además con la librería utilizada descrita más adelante en la presente investigación, se tiene la capacidad de identificar el sujeto en cuestión y los movimientos que este realiza en el espacio capturado, de esta forma se va armando un dataset de videos los cuales se procesan y se extraen coordenadas y metadatos para evaluarlos con mayor precisión y establecer parámetros para su análisis. De esta manera, se puede brindar una retroalimentación más precisa del sujeto. Este Modelo de visión computacional, puede aportar una mayor facilidad para la evaluación del progreso de los niños por parte de los docentes, mientras que por parte de los niños podría significar una mayor motivación para participar en actividades físicas que mejoren su motricidad gruesa particularmente, además de generar una mayor confianza en sí mismos. Algunas extensiones de la investigación pueden considerar la integración con plataformas educativas, el desarrollo de módulos para otras áreas de desarrollo (cognitivo, lingüístico, social) y la adaptación a otros grupos poblacionales con otras discapacidades, mientras que los posibles inconvenientes detectados serían el costo de desarrollo e implementación. Finalmente, es importante precisar que en la presente investigación no se abarca el desarrollo de ninguna interfaz de usuario (UI) ni aplicativo, aspectos que podrían abordarse en trabajos futuros; pues, solamente se abarca el desarrollo del Modelo de visión computacional; del mismo modo, no se contempla la capacitación de los docentes sobre el uso del modelo ni su instalación; sin embargo,

en esta investigación se incluyó una guía detallada sobre la instalación del modelo e indicaciones en relación a cómo deben realizarse las grabaciones de manera correcta para que este modelo pueda retornar el mejor resultado posible.

1.7.3. Aporte

La presente investigación tiene el potencial de aportar significativamente al campo de la Ingeniería de Sistemas a través del desarrollo de un modelo de visión computacional innovador enfocado a la evaluación de la motricidad gruesa humana. La implementación de algoritmos de aprendizaje profundo y la integración de hardware y software podrían permitir crear una herramienta precisa y eficiente para el análisis de movimientos. A nivel educativo, este trabajo contribuye al área de la educación física, al mejorar el desarrollo integral de niños con Síndrome de Down apoyándolos en su desarrollo motriz, además contribuye al área de la salud porque tiene el potencial de mejorar la calidad de vida y salud física de niños con Síndrome de Down. Un aporte a la educación para niños con habilidades diferentes, de manera que serán los docentes quienes reciban un resultado por parte de esta herramienta para una evaluación más objetiva y precisa del desempeño físico de estos niños. Asimismo, genera nuevo conocimiento sobre el uso de las TIC en la educación física de niños con discapacidades, y tiene el potencial de ser replicada en otros contextos y poblaciones. Finalmente, esta investigación contribuye al cumplimiento de los objetivos de inclusión educativa establecidos en la Ley N° 29973 – Ley General de la Persona con Discapacidad (Ministerio de la Mujer y Poblaciones Vulnerables, 2019).

1.7.4. Matriz de Consistencia

Tabla 1.1

Matriz de Consistencia

Elementos	Objetivos Específicos	Preguntas de Investigación	Hipótesis	Variables	Metodología
Título	Modelo de Machine Learning para el monitoreo de actividad motora gruesa en niños con Síndrome de Down para determinar su desempeño físico en entornos educativos de Arequipa, Perú				
Objetivo General	Implementar un modelo de Machine Learning para el monitoreo de movimientos utilizando técnicas de Visión Computacional, para identificar patrones de motricidad en los niños con Síndrome de Down, con el fin de clasificarlos en función de su desempeño.		Mediante la implementación del modelo de monitoreo de movimientos utilizando técnicas de visión computacional, será posible identificar patrones en la motricidad gruesa de niños con síndrome de Down y, en consecuencia, clasificarlos en niveles de desempeño (alto, moderado o bajo) según la precisión de sus movimientos.	Independiente: Modelo de monitoreo de movimientos mediante técnicas de visión computacional. Dependiente: Nivel de desempeño (alto, moderado o bajo), mejora en la evaluación de los niños.	

Tabla 1.2

Matriz de Consistencia

Elementos	Objetivos Específicos	Preguntas de Investigación	Hipótesis	Variables	Metodología
Objetivo Específico 1	Analizar datos de movimiento de niños con síndrome de Down en entornos educativos de Arequipa, Perú para identificar patrones y necesidades específicas.	¿Cuáles son los patrones de movimiento y necesidades específicas en las actividades físicas de los niños con Síndrome de Down?		Variables de movimiento: Coordenadas cinemáticas de landmarks corporales (99 valores x, y, z por frame mediante MediaPipe y BlazePose).	Recolección y análisis de datos de movimiento en tiempo real utilizando cámaras Canon.
Objetivo Específico 2	Implementar algoritmos de análisis de datos existentes para identificar patrones de movimiento y comportamientos relevantes para la participación en actividades educativas.	¿Qué algoritmos son más efectivos para identificar y analizar patrones de movimientos en niños con Síndrome de Down?		Algoritmos de análisis de datos: Algoritmos de clasificación supervisada: Random Forest, PCA, métricas biomecánicas por ejercicio.	Desarrollo y prueba de algoritmos de análisis de datos utilizando datos recolectados.
Objetivo Específico 3	Determinar el nivel de desempeño de los niños en las actividades planteadas y clasificarlos según 3 criterios: alto, moderado, bajo.	¿Cuál es el método más efectivo para clasificar el nivel de desempeño de los niños con Síndrome de Down en actividades físicas?		Clasificación del desempeño: Nivel de desempeño motor: Alto (1), Moderado (2), Bajo (3), evaluado con Accuracy, Precision, Recall, F1-score.	Desarrollo de un método de clasificación basado en datos de movimiento y una matriz de calificación.

Tabla 1.3*Matriz de Consistencia*

Elementos	Objetivos Específicos	Preguntas de Investigación	Hipótesis	Variables	Metodología
Objetivo Específico 4	Validar la efectividad del Modelo a través de su aplicación por docentes en la evaluación del desempeño físico de niños con Síndrome de Down.	¿En qué medida el Modelo mejora la evaluación del desempeño físico de niños con Síndrome de Down por parte de los docentes?		Efectividad del modelo: precisión en la evaluación, satisfacción del docente, mejora en el desempeño físico.	Instalación de las cámaras, preparación del escenario para la grabación de los videos, recolección del feedback de los docentes y análisis de resultados.

Tabla 1.4

Matriz de Operacionalización de Variables

Tipo de Variable	Variable	Dimensiones	Indicadores	Instrumento
Independiente	Modelo de monitoreo de movimientos mediante técnicas de visión computacional	Visión computacional	Precisión Recall F1-Score Soporte Exactitud	Datasets, Librerías de Python, Algoritmos de Clasificación.
Dependiente	Nivel de desempeño (alto, moderado, bajo)	Clasificación en función del nivel (alto, moderado, bajo)	Porcentaje de niños que logran una mejora en su rendimiento físico.	Observación directa y registros de actividades en hojas de cálculo.
	Mejora en la evaluación de los niños	Desarrollo motor grueso	Brechas en el rendimiento físico entre los niños.	Pruebas físicas estandarizadas registradas en hojas de cálculo.
Interviniente	Entorno educativo	Calidad de las instalaciones	Condiciones del entorno físico (espacio, recursos disponibles).	Inspección y evaluación de las instalaciones educativas en reportes de evaluación.
		Actitud de los docentes	Nivel de aceptación y resistencia hacia la nueva tecnología.	Encuestas en Google Forms y entrevistas con docentes.
Inesperada	Funcionamiento del Modelo	Problemas técnicos	Frecuencia y tipo de fallos técnicos.	Registros de incidencias técnicas, informes de mantenimiento registrados en reportes de mantenimiento.



CAPÍTULO II

FUNDAMENTOS TEÓRICOS

2.1. Antecedentes de Investigación

Un estudio hecho en Canadá por Svendsen (2007) explora el uso de la visión por computadora para analizar el movimiento humano, con especial enfoque en los cambios de peso en personas con síndrome de Down. Con el objetivo de mejorar el monitoreo de la rehabilitación motora, se proponen nuevos conceptos y algoritmos para el análisis del movimiento, como la caja delimitadora curva y las imágenes de historial de movimiento. Estos métodos se evalúan en experimentos con personas con síndrome de Down, demostrando ser precisos y confiables para analizar el movimiento humano. Los resultados sugieren que la visión por computadora es una herramienta valiosa para este campo, y los avances presentados en este estudio podrían integrarse en herramientas existentes para mejorar su precisión y funcionalidad, aportando información útil para evaluar el progreso y motivar a las personas con síndrome de Down en su rehabilitación motora, lo cual brinda amplias posibilidades de mejorar los algoritmos utilizados y adaptarlos a las herramientas actuales.

En el estudio de Lange et al. (2012), se presenta JewelMine, un sistema de rehabilitación basado en juegos que utiliza la cámara de profundidad Kinect de Microsoft. Este sistema está diseñado específicamente para la rehabilitación del equilibrio y de las extremidades superiores, y consiste en una serie de ejercicios que animan a los usuarios a salir de su base de apoyo. El juego permite una personalización según el nivel de habilidad del paciente, garantizando un desafío adecuado durante todo el proceso de rehabilitación. Además, se han implementado herramientas sofisticadas de análisis post-sesión que cuantifican el rango de movimiento y comparan estos datos con sesiones previas, permitiendo un seguimiento detallado del progreso del paciente. Este sistema

se encuentra actualmente en evaluación en varios ensayos clínicos tanto en Estados Unidos como en otros países.

Recientemente en China Mo et al. (2016) en su tesis introducen un modelo de visión por computadora basado en aprendizaje profundo para el reconocimiento de la actividad física humana a partir de datos del esqueleto corporal, obtenidos mediante el sensor Microsoft Kinect. La muestra utilizada en este estudio consistió en 7 sujetos con Síndrome de Down. Estos participaron en un juego de realidad virtual que constaba de movimientos de desplazamiento lateral de peso para navegar por obstáculos. Todas las actividades se llevaron a cabo en una posición de pie con los pies estacionarios, frente a una cámara que capturaba una vista frontal de los movimientos realizados. La metodología utilizada en la investigación incluye la creación de una base de datos de siete secuencias de video, cada una con una duración de 2 minutos y 7 segundos, filmadas a una resolución de 480 x 720 píxeles y el desarrollo de algoritmos para analizar los movimientos corporales completos de los sujetos, centrándose en la segmentación temporal de actividades humanas cíclicas y en la detección de cambios en ángulos formados por partes del cuerpo (como el torso, la pierna superior y la pierna inferior). Los resultados experimentales demuestran la eficacia del modelo propuesto, alcanzando una tasa de exactitud del 81,8% en el reconocimiento de doce tipos de actividades físicas. Estos resultados evidencian el potencial de las redes neuronales convolucionales para el aprendizaje supervisado en el contexto del RAH, particularmente para el reconocimiento de la actividad física humana. El desarrollo de los algoritmos para analizar los movimientos corporales completos de los sujetos empleado en este estudio puede ser utilizado y mejorado para esta investigación, orientándolo a las necesidades especiales de la muestra elegida.

Posteriormente, en la investigación realizada por Sailema Torres et al. (2017), se investigó el impacto de juegos tradicionales ecuatorianos en la motricidad de 85 niños con SD de entre 5 y 15 años. La intervención, que consistió en 72 sesiones de 40 minutos durante seis meses, se centró en la mejora de destrezas locomotrices, no locomotrices y de proyección. Los resultados mostraron un incremento significativo en la independencia del desplazamiento (41.17 puntos porcentuales, $p=0.000$), habilidades no locomotrices (27.05 puntos porcentuales, $p=0.003$), y habilidades de proyección (32.55 puntos porcentuales, $p=0.000$), concluyendo que las actividades lúdicas tradicionales son efectivas para la estimulación motriz e intelectual en esta población.

Más adelante, Siebra & Siebra (2018) en su estudio, emplean herramientas computacionales aplicadas en concreto al análisis de habilidades motoras en niños con síndrome de Down; además, se emplearon tres grupos de trabajo: el primero, compara características motoras entre individuos con síndrome de Down y otros grupos; el segundo, determina características motoras específicas de individuos con síndrome de Down y el tercero, se enfoca solamente en intervenciones.

Por otro lado, el proyecto de Martínez José (2018), hace uso de un algoritmo de comparación de posturas que evalúa en tiempo real las posiciones articulares del usuario, capturadas con el Kinect, y las compara con posturas predefinidas en el sistema. Además, se implementa el algoritmo de reconocimiento de posturas humanas en tiempo real de Shotton et al., que segmenta y detecta las articulaciones clave, permitiendo corregir las posturas durante los ejercicios. Ambos estudios destacan el uso de algoritmos de procesamiento de movimiento humano y visión artificial para mejorar la precisión y efectividad en tareas físicas, tanto en la interacción robótica como en la corrección de posturas en ejercicios físicos.

Finalmente, en el estudio realizado por Gómez Álvarez et al. (2018), se determinó el efecto de una intervención basada en realidad virtual sobre el desarrollo motor y el control postural en niños con síndrome de Down. Se realizó un estudio cuasi experimental con un enfoque cuantitativo, donde 16 niños con el síndrome de Down fueron asignados aleatoriamente a un grupo experimental que utilizó la Wii Balance Board (GWBB) y un grupo control. La intervención, llevada a cabo dos veces por semana durante cinco semanas, mostró resultados significativos en la mejora del control postural y habilidades motoras, especialmente en el subtest de manipulación del Test TGMD-2 en el grupo GWBB ($p < 0,01$), sugiriendo que este tipo de intervención puede ser eficaz para mejorar ciertas habilidades motoras en esta población.

2.2. Estado del Arte

A partir de la revisión sistemática de estudios previos existentes identificados en la fase exploratoria sobre el uso de visión computacional en la educación, y particularmente en el desarrollo motriz grueso en niños con síndrome de Down, se encontraron fuentes científicas, de investigaciones con diferentes variables y perspectivas teóricas, orientadas a caracterizar el desarrollo motor y determinar el impacto de la visión computacional en esta área.

Las investigaciones realizadas por Benavides Pando et al. (2023), Wang et al. (2023) y Agbolade et al. (2020), presentan una coincidencia en la aplicación de la visión computacional con diversas herramientas computacionales en personas que padecen el síndrome de Down. En el primer estudio, el cual fue realizado por Benavides Pando et al. (2023), se evaluó el impacto de un programa de actividad física en 26 jóvenes con síndrome de Down, con edades entre 12 y 27 años. Se implementó un programa de 20 sesiones de 45 minutos cada una, evaluando las capacidades físicas antes y después mediante la batería Eurofit. Los resultados mostraron mejoras significativas

en fuerza abdominal ($p=.002$), potencia en miembros inferiores ($p=.021$), flexibilidad ($p<.001$), y velocidad en extremidades superiores e inferiores ($p=.010$ y $p<.001$, respectivamente). Estos hallazgos sugieren que un programa de actividad física bien diseñado puede mejorar las capacidades físicas de los jóvenes con síndrome de Down, contribuyendo a su bienestar general. Además, Wang et al. (2023) en su estudio, presenta un sistema llamado "Down-Syndrome-Detector", basado en la arquitectura de Swin Transformer, el cual usa visión computacional como parte fundamental de su enfoque, está diseñado para detectar el síndrome de Down a partir de micrografías de metafase mediante un enfoque automatizado de visión por computadora. El sistema incluye módulos de segmentación, alineación y clasificación de cromosomas, y se beneficia del aprendizaje por transferencia para así poder optimizar su precisión con conjuntos de datos limitados. Los resultados de las pruebas en varios conjuntos de datos públicos y privados demuestran una alta precisión en la detección de células con trisomía 21, lo que sugiere su potencial para mejorar la eficiencia y reducir la carga manual en la detección clínica de este síndrome; en adición a esto, en el estudio de Agbolade et al. (2020), se realiza el reconocimiento facial en personas con síndrome de Down usando técnicas de visión por computadora. El estudio analiza los desafíos y avances en el reconocimiento de características dismórficas faciales específicas de personas con Síndrome de Down mediante el uso de algoritmos de aprendizaje automático y redes neuronales. Este artículo destaca cómo las técnicas modernas de procesamiento de imágenes pueden mejorar la detección y el diagnóstico precoz de este síndrome, abordando los retos de variaciones de postura, iluminación y expresiones faciales. Además, explora varios métodos de extracción de características faciales, como los basados en redes neuronales y descriptores geométricos, y su eficacia para identificar el síndrome de Down en diversas poblaciones.

Por otra parte, en los estudios de Hōrak (2019), Cai et al. (2021), Khanal et al. (2022), Luo et al. (2023) coinciden en el monitoreo de actividad física y rendimiento motor en personas sin discapacidades. Primero, en el estudio de Hōrak (2019), se destaca mucho la importancia de monitorear la actividad física de los niños y adolescentes, lo cual es crucial para poder desarrollar intervenciones efectivas que promuevan hábitos físicamente activos; en adición, sugiere el uso de algoritmos de Deep Learning y visión computacional para el análisis en tiempo real del comportamiento humano, como el reconocimiento de acciones. Además, en el estudio de Cai et al. (2021), se investigó el impacto de la ubicación del Kinect SDK en la precisión de la medición de parámetros cinemáticos durante la realización de una tarea funcional típica de las extremidades superiores, como la tarea de beber. Se evaluaron veintiún posiciones Kinect con diferentes distancias y orientaciones, comparando los ángulos articulares obtenidos con un sistema de captura de movimiento 3D, considerado el estándar de oro. Los resultados indican que la orientación del sensor tiene un impacto significativo en la precisión de la medición, mientras que la distancia no alcanzó significado estadístico. Las recomendaciones incluyen la colocación del sensor en el lado contralateral del sujeto con una orientación de aproximadamente 30° a 45° para tareas que involucren extremidades superiores, evitando la oclusión corporal en posiciones de máxima extensión. En adición, Khanal et al. (2022) en su estudio, proporciona una revisión de las técnicas de visión computacional para el monitoreo de ejercicios físicos; sin embargo, este se centra en técnicas que no emplean el contacto físico. Finalmente, en la investigación de Luo et al. (2023) se evalúa el rendimiento motor de las extremidades superiores en niños empleando Kinect v2, una versión anterior de Microsoft Kinect; además, se propone un algoritmo de optimización que se usa para recoger las coordenadas de la cámara como método de calibración. Según indican, la

calibración angular de la abducción articular, la protracción y rotación externa del hombro; como resultado, el error relativo del ángulo medido se redujo al 2,5% y el error del ángulo medido a 2°.

Los estudios realizados por Albert et al. (2020), Cerfoglio et al. (2022), Brambilla et al. (2023), Królikowska et al. (2023), Lo Priore (2023), Posner et al. (2023), Sulla-Torres et al. (2023) evalúan la fiabilidad y utilidad del sensor Azure Kinect, lo cual sirvió como una referencia para poder medir y analizar el movimiento humano en general. Primero, en el estudio realizado por Albert et al. (2020), se evaluó la precisión del Azure Kinect en comparación con su predecesor, Kinect v2, y un sistema de captura de movimiento Vicon, considerado como el estándar de oro. El estudio incluyó a cinco adultos jóvenes sanos que caminaron en una cinta a diferentes velocidades, permitiendo una comparación detallada de los parámetros espacio-temporales de la marcha, como la longitud de paso, tiempo de paso, y ancho de paso. Los resultados mostraron que el Azure Kinect ofrece una precisión significativamente mayor en la estimación de parámetros espaciales en comparación con Kinect v2, especialmente en la medición de la longitud y el ancho del paso. En adición, en la investigación realizada por Cerfoglio et al. (2022), se explora el uso de la cámara Kinect de Microsoft, un sensor óptico 3D que ha demostrado ser una herramienta no invasiva y precisa para evaluar la marcha en pacientes post-accidente cerebrovascular. Este estudio revisa las metodologías y resultados de investigaciones previas, destacando tanto la validación de mediciones basadas en Kinect frente a sistemas optoelectrónicos de referencia, como la caracterización de los patrones de marcha en esta población específica. Por parte de Brambilla et al. (2023), en su estudio se demuestra que un sensor de bajo costo y no invasivo como Azure Kinect, puede ser usado para poder medir y evaluar el rendimiento del movimiento. Otro estudio que evalúa el Microsoft Azure Kinect es el realizado por Królikowska et al. (2023), en el cual se mide la fiabilidad de esta herramienta, para así poder medir el rango de movimiento que pueda

tener la muñeca y el antebrazo en personas sanas; pues, se realizaron mediciones en 28 hombres y 28 mujeres en un total de tres sesiones diferentes, los resultados mostraron una alta fiabilidad, lo cual sugiere que el Azure Kinect es muy útil para la evaluación y rehabilitación clínica de la mano. También, Lo Priore (2023) proporciona en su artículo una base sólida acerca del uso de Exergames y tecnologías de seguimiento de movimiento, entre los que se menciona al Azure Kinect, para la rehabilitación motora en el hogar. Además, en la investigación de Posner et al. (2023), se presenta un conjunto de datos de seguimiento corporal capturado mediante dos dispositivos Azure Kinect, que proporciona 315 secuencias de caminatas de 15 participantes. Las secuencias incluyen siete acciones de caminata y tres trayectorias predefinidas, sumando 21 secuencias por participante. Los datos, capturados y procesados utilizando el SDK de Azure Kinect y herramientas oficiales de Microsoft, incluyen posiciones y orientaciones de 32 articulaciones, permitiendo la duplicación efectiva de la velocidad de cuadros mediante la intercalación de las capturas. Este conjunto de datos está diseñado para entrenar redes neuronales en la predicción del movimiento humano y para probar algoritmos de reconocimiento de acciones. Finalmente, Sulla-Torres et al. (2023) en su estudio, se evalúa la actividad física de estudiantes universitarios empleando un prototipo de Visión computacional con Azure Kinect. Este último estudio destaca la precisión y objetividad de la visión computacional mediante las cámaras Azure Kinect frente a otros métodos tradicionales.

En adición, en un estudio reciente Moreira Sanchez & Vasquez Arriaga (2022) examinan los algoritmos utilizados en sistemas de visión artificial aplicados a la corrección de posturas y el control de dispositivos robóticos. En este proyecto se emplean algoritmos de cálculo de ángulos articulares para replicar los movimientos humanos en un brazo robótico. El sistema utiliza las librerías SimpleOpenNI y OpenCV para capturar las coordenadas de las articulaciones detectadas por el Kinect, y a partir de estas, un algoritmo calcula los vectores y ángulos necesarios para

controlar los servomotores del brazo robótico. El protocolo MQTT facilita la comunicación entre la estación emisora y la receptora, asegurando la precisión del movimiento en tiempo real.

Finalmente, las investigaciones de Sangkarit & Tapanya (2024) y Shi et al. (2024) coinciden en evaluar cómo los factores externos pueden llegar a influir en el desarrollo de las habilidades motoras gruesas en niños. Primeramente, en el estudio realizado por Sangkarit & Tapanya (2024) se investiga el impacto que tienen los contenedores en el desarrollo de las habilidades motoras gruesas en bebés prematuros, los cuales se encuentran entre 8 y 13 meses de edad, etapa en la cual empiezan a caminar; además, se realizó una evaluación mensual de los percentiles de motricidad de estos bebés empleando la Escala de motricidad de Alberta, y se logró identificar factores que afectan positivamente en su desarrollo motor, tales como el tamaño del contenedor y la superficie blanda del piso. En el otro estudio, realizado por Shi et al. (2024) se investigan los efectos de un programa de Rugby de bandera en las habilidades motoras gruesas y la aptitud física de niños preescolares, de 5 a 6 años, el cual tiene una duración de 12 semanas. Se realizó la comparación de un grupo de niños que participó en dicho programa, con otro que siguió una currícula regular de educación física; los resultados arrojaron que los niños que participaron en el programa de Rugby de bandera lograron mejorar significativamente en varias de sus habilidades motoras gruesas y, además en su aptitud física en general, con diferencias de acuerdo al género en algunas de las pruebas. Este estudio sugiere que este tipo de programas suelen ser más efectivos que los currículos tradicionales para que los niños pequeños puedan lograr un desarrollo en sus habilidades motoras gruesas.

2.3. Bases Teóricas de la Investigación

2.3.1. Síndrome de Down

También conocido como Trisomía 21, es una alteración en la que una persona posee 1 cromosoma extra o solamente una parte de un cromosoma. Dicha copia extra modifica la manera en que se forman y desarrollan el cerebro y cuerpo de la persona. Además, los cromosomas son diminutos envoltorios en los cuales se encuentran sus genes y estos, poseen el ADN, que es información cuya función es controlar el aspecto y funcionamiento del cuerpo (MedlinePlus, 2024). Esta condición afecta el control motor selectivo, generando así una inestabilidad y deficiencia al momento de ejecutar movimientos motores (Lopes et al., 2021).

2.3.2. Motricidad gruesa

Son las habilidades motoras que implican el uso de los músculos grandes del cuerpo para poder realizar movimientos coordinados y amplios, tales como correr, saltar, etc (Sangkarit & Tapanya, 2024). La etapa preescolar es un periodo en el cual se produce el mayor pico para su desarrollo, además muchas habilidades motoras gruesas se desarrollan con gran variabilidad hasta los 8 años (Shi et al., 2024).

Figura 2.1

Ejercicio donde se emplea la Motricidad Gruesa



Nota. Esta figura muestra dos niños realizando el ejercicio de salto en dos pies.

2.3.3. Inteligencia Artificial

Es aquella rama de la informática que se encarga del desarrollo de computadoras que puedan llegar a imitar características parecidas a las humanas, tales como el aprendizaje, razonamiento, toma de decisiones e incluso la resolución de problemas (Saad Alotaibi et al., 2024).


2.3.4. Visión Computacional

Es aquel campo de estudio que se enfoca en cómo las computadoras logran obtener una percepción de gran nivel a partir de imágenes y videos digitales, lo cual puede ayudar a poder tomar mejores decisiones en el mundo real (Heidari et al., 2024).

Además, las técnicas de visión computacional son cada vez más populares, pues en los últimos años han ayudado a superar muchas limitaciones y a mejorar la eficiencia del control de calidad (Ullah et al., 2024).

Figura 2.2

Ramas de la Visión Computacional



Nota. Esta figura muestra las ramas de la Visión Computacional.

2.3.5. Open CV

Es una biblioteca informática de código abierto con funciones de programación dirigida de manera específica a la visión computacional en tiempo real. En adición, esta es una plataforma de código abierto y gratis, cuya interfaz principal está hecha en el lenguaje de programación c++ (Aswin Kumer et al., 2020).

Figura 2.3

Librería Open CV



Nota. Esta figura muestra cómo es la detección de objetos mediante la Librería OpenCV de Python.



CAPÍTULO III

MARCO METODOLÓGICO

3.1. Alcances y Limitaciones

Para poder realizar la definición del alcance y limitaciones de esta investigación, se tomó en cuenta lo siguiente:

El proyecto es viable tanto a nivel tecnológico como a nivel metodológico, ya que se cuenta con la disponibilidad de dispositivos de monitoreo, las cámaras Canon, cámaras de teléfonos móviles, entre otros. Sin embargo, hay diversos retos técnicos que pueden llegar a perjudicar la precisión y la integridad de los datos necesarios en esta investigación, desde ruido visual en los videos, formato de estos, hasta la aceptación de los niños, docentes e incluso padres de familia sobre este modelo de visión computacional.

Este modelo se probó en 8 instituciones educativas para niños con habilidades diferentes pertenecientes a Cáritas Diocesana del Arzobispado de Arequipa, ubicadas en Arequipa, Perú; las cuales cuentan con 25 niños que padecen el Síndrome de Down matriculados en estas, de los cuales solamente participaron 23. De esta manera, se realizó una recopilación de datos muy representativa de este contexto geográfico. Las pruebas fueron realizadas en entornos controlados dentro de las instituciones educativas, y con supervisión de los docentes, para de esta manera poder ratificar la precisión y fiabilidad de los datos.

El periodo de monitoreo se planificó para un periodo aproximado de cuatro meses, lo cual facilitó la observación del desempeño físico de los niños en las distintas actividades propuestas. Sin embargo, un periodo de monitoreo de cuatro meses puede que no sea suficiente para poder apreciar cambios a largo plazo en el desempeño motor grueso de los niños con Síndrome de Down.

El desarrollo de la investigación no requirió un presupuesto económico significativo, ya que la Universidad Católica de Santa María facilitó el acceso al equipamiento necesario, como las cámaras Canon y los trípodes utilizados durante la fase de grabación de videos, eliminando la necesidad de adquirir equipos de forma independiente. En cuanto al entorno de desarrollo, se hizo uso exclusivo de software libre y de código abierto, entre ellos Python, MediaPipe, OpenCV y Scikit-learn, lo que permitió reducir los costos de licenciamiento y garantizar un acceso libre y reproducible al entorno de trabajo. Este apoyo institucional y el uso de herramientas tecnológicas accesibles resultaron fundamentales para la viabilidad técnica y metodológica del proyecto, asegurando su ejecución eficiente sin comprometer la calidad de los resultados.

3.2. Tipo y Nivel de Investigación

Esta investigación sigue una metodología de investigación del tipo aplicada con un enfoque cuantitativo; además, cuenta con los niveles descriptivo y correlativo con un diseño cuasi experimental. Pues, se enfoca en aplicar de manera práctica los conocimientos y tecnologías existentes, en este caso utilizadas para desarrollar e implementar un Modelo de Machine Learning para el monitoreo de la actividad motora gruesa en los niños con el síndrome de Down.

Además, se recopilaron datos numéricos sobre el desempeño motor de los niños para identificar patrones y realizar clasificaciones objetivas, brindando de esta manera un panorama claro del desempeño que muestren los niños en las pruebas físicas propuestas por sus docentes. En adición, la investigación intenta describir las características y patrones de movimiento en la actividad motora gruesa de los niños con Síndrome de Down y analizar las relaciones entre diferentes variables que influyen en su desempeño motor. Finalmente, se optó por un diseño cuasiexperimental para evaluar la efectividad del modelo de monitoreo en un entorno educativo

real sin la necesidad de asignación aleatoria de los participantes, lo cual es más práctico y ético en este contexto.

3.3. Universo, Población y Muestra

3.3.1. Universo

El universo de esta investigación está conformado por todas las personas diagnosticadas con el Síndrome de Down en Perú, estimándose en 25 113 casos (CONADIS, 2022).

3.3.2. Población

En cuanto a la población, en esta investigación se considera exclusivamente los 1014 casos de personas con Síndrome de Down (554 hombres y 460 mujeres) en la ciudad de Arequipa hasta 2024 (CONADIS, 2024).

3.3.3. Muestra

La muestra de esta investigación consistirá en un subconjunto representativo de 23 niños con Síndrome de Down en un rango de edad entre 4 a 10 años, pertenecientes a 8 de los centros educativos afiliados por convenio a la Institución Cáritas Diocesana del Arzobispado de Arequipa (Cáritas Arequipa). Los centros educativos cuyos niños participarán son:

- C.E.B.E. Nuestra Señora de la Consolación
- C.E.B.E. María de los Remedios
- C.E.B.E. María de la Esperanza
- C.E.B.E. Santa Ana
- C.E.B.E. Nuestra Señora del Perpetuo Socorro
- C.E.B.E. Señor de los Milagros

- C.E.B.E. San Martín de Porres
- C.E.B.E. Nuestra Señora de la Candelaria

Se utiliza un muestreo estratificado no probabilístico a conveniencia. Se seleccionaron los participantes en función de su disponibilidad y el consentimiento de los padres y docentes. Para calcular la muestra, se empleó la fórmula del tipo cuantitativo para una población finita, la cual está definida por Aguilar-Barojas (2005) y se detalla a continuación:

Fórmula:

$$n = \frac{N * Z^2 * S^2}{d^2 * (N - 1) + Z^2 * S^2}$$

Donde:

n = tamaño de la muestra

N = tamaño de la población

Z = valor de Z crítico, nivel de confianza del 95%

S = varianza de la población en el estudio

d = nivel de precisión, margen de error

Aplicación:

$$n = \frac{1014 * (1,96)^2 * (0,5)^2}{(0,10)^2 * (1014 - 1) + (1,96)^2 * (0,5)^2}$$

$$n = \frac{1014 * 3,8416^2 * 0,25^2}{0,01 * 1013 + 3,8416 * 0,25}$$

$$n = \frac{975,3124}{10,13 + 0,9604} \approx \frac{975,3124}{11,0904} \approx 87,96$$

$$n \approx 88$$

El tamaño de la muestra recomendado es de 88 personas para una población de 1014 individuos con Síndrome de Down, con un margen de error del 10%. Este enfoque asegura una representación adecuada y respeta las limitaciones prácticas y éticas de este proyecto; sin embargo, se trabajó con una muestra de 23 niños, la cual es la cantidad total de participantes que se ha logrado acceder dentro de los centros educativos afiliados a Cáritas Arequipa; dicha cantidad será suficiente y manejable para realizar un análisis preliminar. La selección final dependió del acceso permitido por las instituciones educativas y los permisos otorgados por los padres de familia y docentes. Este enfoque garantiza que la muestra proporcione datos significativos, permitiendo obtener resultados válidos y confiables en el contexto de esta investigación.

3.4. Métodos, Técnicas e Instrumentos de Recolección de Datos

3.4.1. Metodología de Desarrollo

Para el desarrollo del modelo se optó por emplear CRISP-DM, proceso para proyectos de Ciencia de Datos, el cual es el más adecuado para estructurar el desarrollo e implementación de un modelo basado en visión computacional y Machine Learning que clasifica el desempeño físico de los niños con Síndrome de Down a partir de videos de ejercicios.

En la implementación se utilizó el modelo pre entrenado BlazePose de MediaPipe (Visión Computacional) para la extracción de puntos clave; sin embargo, para la clasificación de desempeño en función del ejercicio evaluado se hace uso de un modelo sin entrenar, es aquí donde se estructura la implementación en base a las etapas que proporciona esta metodología, desde la limpieza y generación de un data set, hasta las pruebas de precisión, para esto se vio por conveniente utilizar el algoritmo Random Forest Classifier, que es un algoritmo de Machine Learning supervisado.

3.4.2. Técnicas de recolección de datos

Para la recolección de datos, se utilizaron diversas técnicas que aseguren la obtención de información completa y precisa, tal como se detalla en los apéndices.

3.4.2.1. Entrevistas

Se realizaron entrevistas estructuradas con padres y educadores para recopilar permisos y datos de los sujetos de la muestra. Para esto se desarrolló un plan de trabajo con el cual se asistió a los centros educativos acorde a las fechas establecidas, el cual se muestra en el Apéndice 1.

También se elaboraron los documentos de permisos y consentimientos informados dirigidos a los padres o apoderados de los menores para la participación de estos niños en la investigación, tal como se muestra en los Apéndices.

3.4.2.2. Observación

Evaluación directa de las actividades físicas con la supervisión de los docentes.

3.4.2.3. Captura de imágenes

Captura de imágenes, videos, y metadatos en formatos estándares, para evaluar la precisión del modelo de clasificación de movimientos.

3.4.3. Instrumentos de recolección de datos

3.4.3.1. Google Meet

Esta herramienta se utilizó para realizar reuniones de manera virtual con los padres de familia o apoderados, directoras y docentes; con el fin de coordinar las fechas de visita, disponibilidad, discutir avances y aclarar dudas sin necesidad de hacerlo presencialmente.

3.4.3.2. Reuniones Presenciales

Estas reuniones se hicieron para poder interactuar de manera directa con los docentes y directoras de cada centro educativo, con el fin de informar en qué consiste la investigación, recolectar los datos y permisos necesarios. Además, en estas reuniones se realizaron las grabaciones en video de las actividades físicas realizadas por los niños con Síndrome de Down, así como la obtención de opiniones y retroalimentación en tiempo real.

3.4.3.3. Microsoft Excel

Estas hojas de cálculo de Excel se usaron para almacenar la información y datos relevantes de los niños con síndrome de Down, tales como su nombre completo, edad, otra(s) discapacidad(es) como se muestra en el Apéndice 6.3.

3.4.3.4. Registros de actividades

Estos registros permitieron documentar cada actividad realizada en el proyecto, tales como las fechas de las visitas, sesiones, captura de datos, observaciones y cualquier incidencia.

3.4.3.5. Cámaras Canon

Estas herramientas, acompañadas por sus respectivos trípodes, se utilizaron para armar un pequeño set en los lugares donde se realizaron las grabaciones de las actividades físicas realizadas por los niños con Síndrome de Down en cada sesión; además, estas cámaras poseen una alta resolución y calidad de video. Cabe recalcar que la grabación de los videos preliminares para el entrenamiento del modelo fue realizada con esta cámara.

3.4.4. Técnicas de procesamiento de datos

3.4.4.1. Procesamiento de postura y reconocimiento de movimiento

El procesamiento de imágenes y la extracción de características visuales (modelo pre entrenado) son fundamentales para evaluar el rendimiento en los ejercicios. Se aplicaron técnicas de detección de posturas que permiten extraer las posiciones clave de las articulaciones del cuerpo humano en las imágenes o secuencias de video. Para este fin, se utiliza el modelo pre entrenado BlazePose de MediaPipe y OpenCV, que permiten detectar y analizar la postura corporal y graficar las coordenadas de cada extremidad en cada frame del video.

3.4.4.2. Algoritmo de Machine Learning

Se emplearon técnicas de aprendizaje automático para entrenar un modelo capaz de clasificar el rendimiento (alto, moderado, bajo) basado en las características extraídas de las posturas. El algoritmo utilizado en este caso es Random Forest Classifier, el cual fue elegido debido a que tiene una capacidad para poder manejar datos multidimensionales complejos de movimiento e identificar de manera automática las métricas discriminativas para distintas tareas motoras con una alta precisión, además de poder generar medidas continuas de desempeño; en adición, su arquitectura de varios árboles de decisión logra prevenir el desajuste y detecta correlaciones complejas entre métricas de movimiento, lo cual brinda las características necesarias para el desarrollo de este modelo (Kuhner et al., 2017).

3.4.4.3. Análisis de Componentes Principales (PCA)

Para reducir la dimensionalidad de los datos y mejorar los tiempos de entrenamiento, se empleó el algoritmo Análisis de Componentes Principales (PCA) que es una técnica de reducción

de dimensionalidad que transforma un conjunto de características originales en un nuevo conjunto de variables no correlacionadas, llamadas componentes principales, que explican la mayor parte de la varianza en los datos. Al aplicar PCA, se pueden reducir las dimensiones sin perder información relevante, lo que contribuye a mejorar la capacidad de generalización del modelo y reducir el tiempo de procesamiento.

3.4.4.4. Técnicas de evaluación y validación del modelo

Para garantizar la robustez y precisión del modelo, se utilizan técnicas de validación cruzada y división de datos en conjunto de entrenamiento y prueba. El 80% de los datos se emplean para el entrenamiento del modelo, mientras que el 20% restante se reserva para la evaluación de su desempeño. Durante este proceso, se utilizan métricas como la Precisión, el Recall, el F1-score y la Exactitud para evaluar la calidad de las predicciones del modelo.

3.4.5. Herramientas para el procesamiento de datos

3.4.5.1. Open CV

Librería de Python para el procesamiento automático de videos; además, se encarga de tareas tales como el análisis de movimiento, segmentación de imágenes y la detección de patrones específicos en los datos visuales.

3.4.5.2. MediaPipe

Framework para la detección de poses y puntos clave del cuerpo humano a partir de los videos grabados; además transforma los datos del video en información bien estructurada, es decir, coordenadas de puntos clave del cuerpo, que luego se pueden analizar para poder evaluar los movimientos.

3.4.5.3. Random Forest Classifier

Algoritmo de aprendizaje automático que se emplea para clasificar y predecir resultados basados en los datos procesados; pues, clasifica los movimientos de los niños con Síndrome de Down para así determinar patrones y evaluar su desempeño motriz.





CAPÍTULO IV

DESARROLLO DE LA PROPUESTA DE INVESTIGACIÓN

En el presente capítulo se procede con el detalle de los pasos a seguir para la selección de los ejercicios físicos que se realizaron, el acceso a la población objetivo, el desarrollo en visión computacional y la creación del conjunto de datos de los videos de niños con Síndrome de Down realizando actividades físicas empleando su motricidad gruesa, lo cual es de vital importancia para poder desarrollar, entrenar y probar el modelo de monitoreo.

4.1. Selección de Ejercicios Físicos

Para tener claro cuáles son los ejercicios que debían ejecutar los niños con Síndrome de Down empleando su motricidad gruesa, se realizó la consulta de ello a la Dra. Rossana Gómez Campos, especialista chilena en actividad física, quien sugirió que realizar entre 3 a 4 ejercicios sería suficiente para evaluar a los niños con Síndrome de Down, también sugirió que sean niños de entre 4 a 10 años de edad. Los ejercicios recomendados específicamente para niños con Síndrome de Down fueron los siguientes:

- Sentarse y pararse de una silla
- Lanzamiento de pelota
- Gatear
- Saltos en 2 pies

En adición, sugirió que se usen los siguientes equipos para las pruebas: Cámaras Canon, Nodos y Antropometría; de los cuales se empleó solamente las Cámaras Canon.

4.2. Acceso a la Población Objetivo

Para poder realizar el desarrollo de esta propuesta, fue de vital importancia tener el acceso a los niños con Síndrome de Down, en las respectivas instituciones educativas donde se encuentran matriculados, durante el horario de clases, bajo la supervisión de al menos un docente que los apoye y asista en el desarrollo de dichas actividades. Para ello, se investigó cuáles son las instituciones educativas a las que asisten niños con Síndrome de Down en la ciudad de Arequipa; luego, se seleccionó a la institución Cáritas Diocesana del Arzobispado de Arequipa, la cual posee diversas escuelas afiliadas para niños con habilidades diferentes.

4.2.1. Contacto con la Institución

Para realizar el contacto con la institución Cáritas Arequipa se siguió un procedimiento formal, el cual se detalla a continuación:

Primero, se realizó un contacto vía llamada telefónica al número que se encuentra en su página web; posteriormente, se agendó una cita con la Sra. coordinadora de Cáritas Arequipa, con el propósito de explicarle de manera detallada la propuesta, y solicitarle el acceso a las escuelas afiliadas que cuenten con niños con Síndrome de Down inscritos en estas, las cuales se indicó que son 8 en total y cuentan con 25 niños con Síndrome de Down matriculados, de los cuales se tuvo acceso para evaluar a 23 que asistieron en ambas visitas; luego, se agendó una segunda cita para la presentación de los responsables de la investigación a las directoras de cada escuela, explicarles la propuesta y se les proporcionó los consentimientos informados escritos que deben ser entregados a los padres de familia o apoderados de cada niño para ser llenados y firmados; además, indicaron la cantidad y edades de niños con Síndrome de Down que tienen inscritos en sus escuelas respectivamente; finalmente, la coordinadora entregó los memorandos dirigidos a las directoras de

cada escuela con su respectiva copia de cada uno, los cuales se indicó deben ser llevados el día de la visita a cada escuela, además de redactar un plan de trabajo y adjuntarlo a dicho memorando.

4.2.2. Visitas a las Escuelas

4.2.2.1. Primera Visita

Tras establecer el contacto con la institución Cáritas Arequipa, se procedió con la primera visita a las escuelas, durante esta visita se entregaron los memorandos a las directoras y se presentó el plan de trabajo correspondiente; asimismo, se efectuaron las primeras grabaciones, captura de imágenes y datos con las cámaras Canon realizando las actividades físicas definidas previamente, los cuales sirvieron para el entrenamiento y desarrollo del modelo; y se pidió la copia del memorando firmado por cada directora respectivamente.

4.2.2.2. Segunda Visita

En la segunda visita, con el modelo ya desarrollado y entrenado, en esta oportunidad con las cámaras de sus teléfonos celulares, los propios docentes fueron quienes grabaron los videos de los niños con Síndrome de Down ejecutando las mismas actividades físicas de la primera visita, para luego cargarlos al modelo; en función a los resultados obtenidos en una primera ronda de ejercicios, los docentes adaptaron la ejecución, y aplicaron correcciones en la técnica de los ejercicios a los niños y se hizo una segunda ronda de grabaciones donde se pudo validar la mejora del rendimiento físico de estos. En ambas visitas no se logró contar con los 25 niños en total, debido a que 2 niños no asistieron a sus colegios en la segunda visita; por lo tanto, no se les pudo evaluar ni corroborar su mejora en el desempeño físico, y no se les consideró en la evaluación; sin embargo, los otros 23 niños sí asistieron a sus colegios en ambas visitas, es así que se utilizó el mismo grupo de niños para dicha evaluación.

4.3. Desarrollo en Visión Computacional

4.3.1. Generación del Conjunto de Datos

4.3.1.1. Configuración del Equipo de Grabación de Videos Preliminares

La generación del conjunto de datos inició con la configuración del equipo destinado a la captura de videos preliminares, el cual incluye dos cámaras Canon y dos trípodes. Este equipo se empleó para obtener grabaciones en alta resolución, las cuales conformaron el conjunto de datos (dataset) utilizado en el entrenamiento y prueba del modelo de visión computacional; en adición, los niños fueron grabados realizando el ejercicio de frente y de costado por las 2 cámaras Canon de manera simultánea, es decir una grabó desde un ángulo y la otra cámara desde el otro. Posteriormente, la validación del modelo se realizó mediante grabaciones adicionales realizadas por los docentes empleando las cámaras de sus teléfonos celulares, lo que permitió evaluar el desempeño del modelo en condiciones reales de uso.

Tabla 4.1

Especificaciones de cámaras Canon

Especificación	Descripción
Montura de lente	Canon EF
Zoom Óptico	Lente 18 – 55 IS II lens
Formato de Cámara	APS-C (1.6x Crop Factor)
Sensor de Imagen	Tipo: CMOS 22,3 x 14,9 mm Píxeles Efectivos: 24,10 mpx Píxeles Reales: 25,80 mpx
Velocidad de Obturador	3 fps
Resolución Máxima	1920 x 1080 px
Calidad de Video	Full HD
Procesador	DIGIC 8

Nota. En esta tabla se detallan las especificaciones de las cámaras Canon empleadas para la grabación de los videos preliminares.

4.3.1.2. Procedimiento para la Grabación de Videos (Dataset)

El proceso de captura de imágenes de las actividades físicas de los niños con Síndrome de Down ha sido planificado de forma estratégica, teniendo en cuenta los horarios y fechas en las que dichos niños acuden a las escuelas afiliadas a Cáritas Arequipa, es por ello que se armó un cronograma de visitas para cada escuela.

1. Planificación de la Grabación de Videos

Definición de las fechas de la primera y segunda visita para recolección de datos.

a) Cronograma de Primera Visita

- **Semana 1 (24 - 25 de septiembre de 2024):**
 - C.E.B.E. Nuestra Señora de la Consolación: 24 septiembre
 - C.E.B.E. María de los Remedios: 25 septiembre
- **Semana 2 (2 - 3 de octubre de 2024):**
 - C.E.B.E. María de la Esperanza: 2 octubre
 - C.E.B.E. Santa Ana: 3 octubre
- **Semana 3 (9 - 10 de octubre de 2024):**
 - C.E.B.E. Nuestra Señora del Perpetuo Socorro: 9 octubre
 - C.E.B.E. Señor de los Milagros: 10 octubre
- **Semana 4 (16 - 17 de octubre de 2024):**
 - C.E.B.E. San Martin de Porres: 16 octubre
 - C.E.B.E. Nuestra Señora de la Candelaria: 17 octubre

b) Cronograma de Segunda Visita

- **Semana 5 (29 - 30 de octubre de 2024):**
 - C.E.B.E. Nuestra Señora de la Consolación: 29 octubre

- C.E.B.E. María de los Remedios: 30 octubre
- **Semana 6 (6 - 7 de noviembre de 2024):**
 - C.E.B.E. María de la Esperanza: 6 noviembre
 - C.E.B.E. Santa Ana: 7 noviembre
- **Semana 7 (13 - 14 de noviembre de 2024):**
 - C.E.B.E. Nuestra Señora del Perpetuo Socorro: 13 noviembre
 - C.E.B.E. Señor de los Milagros: 14 noviembre
- **Semana 8 (20 - 21 de noviembre de 2024):**
 - C.E.B.E. San Martin de Porres: 20 noviembre
 - C.E.B.E. Nuestra Señora de la Candelaria: 21 noviembre

2. Conjunto de Datos de Entrenamiento

El propósito de este proceso fue grabar videos preliminares de los niños con Síndrome de Down realizando actividades físicas que permitan entrenar el modelo, los cuales fueron grabados mediante las cámaras Canon. Las actividades físicas que realizaron fueron las siguientes:

a) Ejercicio 1: Sentarse y pararse de una silla.

Este ejercicio consiste en colocar una silla, donde el niño procede a sentarse en ella y, luego a pararse de esta misma.

Figura 4.1

Niña se para y se sienta en la silla



Pararse



Sentarse

Nota. Esta figura muestra como una niña con síndrome de Down se sienta y luego se para de una silla de madera.

Figura 4.2

Silla de madera



Nota. Esta figura muestra el único instrumento que se utilizó para este ejercicio, el cual fue una silla de madera.

b) Ejercicio 2: Lanzamiento de Pelota.

Este ejercicio consiste en colocar un recipiente o baúl, en donde los niños lanzarán una pelota de plástico o algodón.

Figura 4.3

Niña realiza lanzamiento de pelota



Nota. Esta figura muestra como una niña con síndrome de Down realiza el lanzamiento de una pelota de plástico.

Figura 4.4

Pelotas de algodón



Nota. Esta figura muestra uno de los instrumentos que se utilizó para este ejercicio, el cual fue una pelota de algodón.

Figura 4.5

Recipiente de plástico



Nota. Esta figura muestra otro de los instrumentos que se utilizó para este ejercicio, el cual fue un recipiente o baúl.

c) **Ejercicio 3:** Gatear.

Este ejercicio consiste en colocar un cono o punto de llegada al cual los niños deben llegar gateando y luego deberán regresar al punto de partida de igual manera.

Figura 4.6

Niño gatea hacia un cono



Nota. Esta figura muestra como un niño con síndrome de Down se desplaza gateando hacia un cono, el cual es el punto de llegada.

Figura 4.7

Cono



Nota. Esta figura muestra el único instrumento que se utilizó para este ejercicio, el cual fue un cono.

d) Ejercicio 4: Saltos en dos pies.

Este ejercicio consiste en colocar hula-hulas en línea recta o una escalera de tela en el piso donde los niños deben saltar dentro con los dos pies juntos.

Figura 4.8


Niña realiza saltos en dos pies



Nota. Esta figura muestra como una niña con síndrome de Down realiza saltos con los dos pies juntos dentro de una escalera de tela colocada en el piso.

Figura 4.9

Hula-hulas y escalera de tela



Hula-hulas



Escalera de tela

Nota. Esta figura muestra los instrumentos que se utilizaron para este ejercicio, los cuales son mínimo 4 hula-hulas o una escalera de tela.

4.3.2. Implementación

Cada fase del proyecto, desde la comprensión del negocio hasta el despliegue (CRISP-DM), ha sido detallada con fragmentos del código original a manera de ilustración que refleja cómo se resolvieron los problemas y se implementaron las soluciones. Se utilizó un enfoque modular y escalable en la arquitectura del entorno que facilita el mantenimiento y la futura expansión del modelo, permitiendo la incorporación de nuevos ejercicios y mejoras en el análisis del desempeño.


4.3.2.1. Entorno de Desarrollo

4.3.2.1.1. Preparación Previa a la Codificación

Se definió Visual Studio Code Versión: 1.89.0 (Universal) como entorno de desarrollo, en este mismo se configuró un entorno virtual basado en Python 3.9.6 para la instalación de las librerías y dependencias necesarias.

Figura 4.10

Versión de Python en la cual se basa el entorno virtual

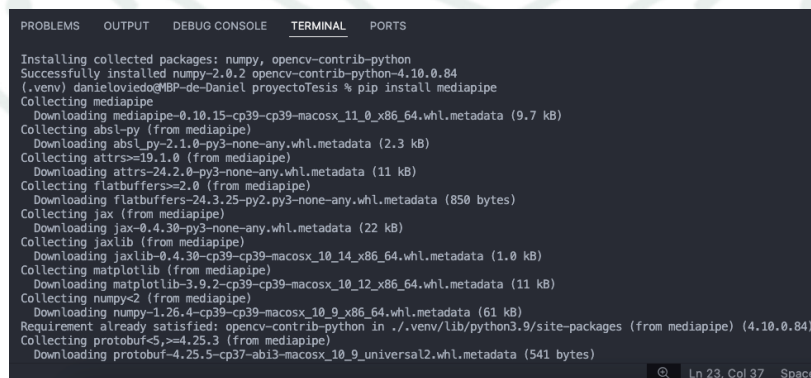


Nota. Esta figura muestra la versión 3.9.6 de Python que debe ser elegida para el entorno virtual.

Se configuró un intérprete de Python dentro del entorno virtual (.venv); se eligió la versión 3.9.6 debido a que esta tiene compatibilidad con la librería principal del proyecto.

Figura 4.11

Configuración del intérprete de Python



Nota. Esta figura muestra la configuración del intérprete de Python dentro del entorno virtual en la terminal.

Posteriormente, se instalaron las respectivas librerías, las cuales se mencionan a continuación:

- **MediaPipe:** Para detectar puntos clave del cuerpo (landmarks).
- **OpenCV-contrib-python:** Para manejar video e imágenes.
- **Scikit-learn:** Para entrenar y usar modelos de machine learning.
- **Pandas:** Para manipular datos estructurados (landmarks y etiquetas).
- **NumPy:** Para operaciones numéricas y manipulación de arrays multidimensionales.
- **Joblib:** Para serialización y carga de modelos entrenados (.pkl).
- **Matplotlib:** Para generar gráficos y matrices de confusión.
- **Seaborn:** Para visualizaciones estadísticas avanzadas.
- **pytest memory-profiler logging:** Para manejar metadatos del Modelo para la fase de testing.

Figura 4.12

Instalación de librerías

```
Downloading importlib_metadata-8.5.0-py3-none-any.whl (26 kB)
Downloading importlib_resources-6.4.5-py3-none-any.whl (36 kB)
Downloading kiwisolver-1.4.7-cp39-cp39-macosx_10_9_x86_64.whl (65 kB)
Downloading ml_dtypes-0.5.0-cp39-cp39-macosx_10_9_universal2.whl (732 kB)
732.2/732.2 kB 6.9 MB/s eta 0:00:00
Downloading packaging-24.1-py3-none-any.whl (53 kB)
Downloading pillow-10.4.0-cp39-cp39-macosx_10_10_x86_64.whl (3.5 MB)
3.5/3.5 MB 5.5 MB/s eta 0:00:00
Downloading pyparsing-3.1.4-py3-none-any.whl (104 kB)
Downloading python_dateutil-2.9.0.post0-py2.py3-none-any.whl (229 kB)
Downloading scipy-1.13.1-cp39-cp39-macosx_10_9_x86_64.whl (39.4 MB)
39.4/39.4 MB 5.3 MB/s eta 0:00:00
Downloading opt_einsum-3.4.0-py3-none-any.whl (71 kB)
Downloading six-1.16.0-py2.py3-none-any.whl (11 kB)
Downloading zipp-3.20.2-py3-none-any.whl (9.2 kB)
Downloading pycparser-2.22-py3-none-any.whl (117 kB)
Installing collected packages: flatbuffers, zipp, six, pyparsing, pycparser, protobuf, pillow, packaging, opt-einsum, numpy, kiwisolver, python-dateutil, ml-dtypes, importlib-resources, importlib-metadata, contourpy, CFFI, sounddevice, matplotlib, jaxlib, jax, mediapipe
Attempting uninstall: numpy
Found existing installation: numpy 2.0.2
Uninstalling numpy-2.0.2:
Successfully uninstalled numpy-2.0.2
```

Nota. Esta figura muestra la instalación de las respectivas librerías en la terminal.

Una vez completa la instalación y configuración inicial del entorno virtual en el cual se desarrollará el código, la arquitectura de archivos queda de la siguiente manera:

Figura 4.13

Arquitectura de archivos

```
projectoTesis/
├── src/
│   ├── training/ # Model training pipeline
│   │   ├── main_training.py
│   │   ├── process_videos.py
│   │   ├── pca_reduction.py
│   │   ├── train_model.py
│   │   ├── compare_models.py
│   │   └── label_data_*.py
│   └── evaluation/ # Model evaluation pipeline
│       ├── main_evaluation.py
│       └── predict_performance.py
├── data/
│   ├── raw/ # Input video files organized by exercise
│   │   ├── crawl/ # Crawl exercise videos
│   │   ├── jump/ # Jump exercise videos
│   │   ├── sit/ # Sit exercise videos
│   │   └── throw/ # Throw exercise videos
│   ├── processed/ # Processed landmark data
│   ├── models/ # Trained model files (.pkl)
│   ├── results/ # Evaluation and comparison results
│   └── confusion_matrices/ # Confusion matrix visualizations
```

Nota. Arquitectura de archivos del entorno virtual en Visual Studio Code.

- **Lenguaje:** Se utilizó el lenguaje Python en su versión 3.9.6, ya que es el que mejor se adapta a los proyectos desarrollados con OpenCV y MediaPipe, y por su flexibilidad.
- **Estilo de Código:** Se adoptó PEP 8 (Guía de estilo de Python) como estándar principal, el cual usa 4 espacios por nivel de indentación, nombres de variables y funciones en snake_case, nombres de clases en CamelCase, y comentarios claros y concisos usando comentarios de línea o bloque cuando resulta necesario.

4.3.2.1.2. Guías de Nomenclatura

Se separó la lógica del entrenamiento del modelo de la evaluación con el modelo ya entrenado, el módulo de entrenamiento contiene los scripts correctamente automatizados y

conectados, con los cuales se toma como entrada el dataset de videos previamente limpiados para analizarlos y entrenar al modelo de clasificación; mientras que, el módulo de evaluación consume el modelo generado y entrenado para evaluar un nuevo video.

- **Nombres de Variables:**

- Se usó nombres descriptivos para variables que representen datos importantes como frame, landmarks, motion_detected, etc.
- Para las variables temporales o de uso general, se usaron convenciones como temp_frame, counter, threshold, x_coord, y_coord, etc.
- Se utilizó “frame” para referirse a cuadros capturados por la cámara.

- **Nombres de Funciones:**

- Para funciones que interactúan con MediaPipe, se usó el prefijo “mp_” para distinguirlas; por ejemplo, “mp_drawing()”.

- **Nombres de Clases:**

- Se utilizan nombres de clases en CamelCase que representen conceptos de alto nivel; por ejemplo, DrawingSpec, VideoCapture y LandmarkAnalyzer.

4.3.2.2. Fase 1: Comprensión del Negocio y Arquitectura

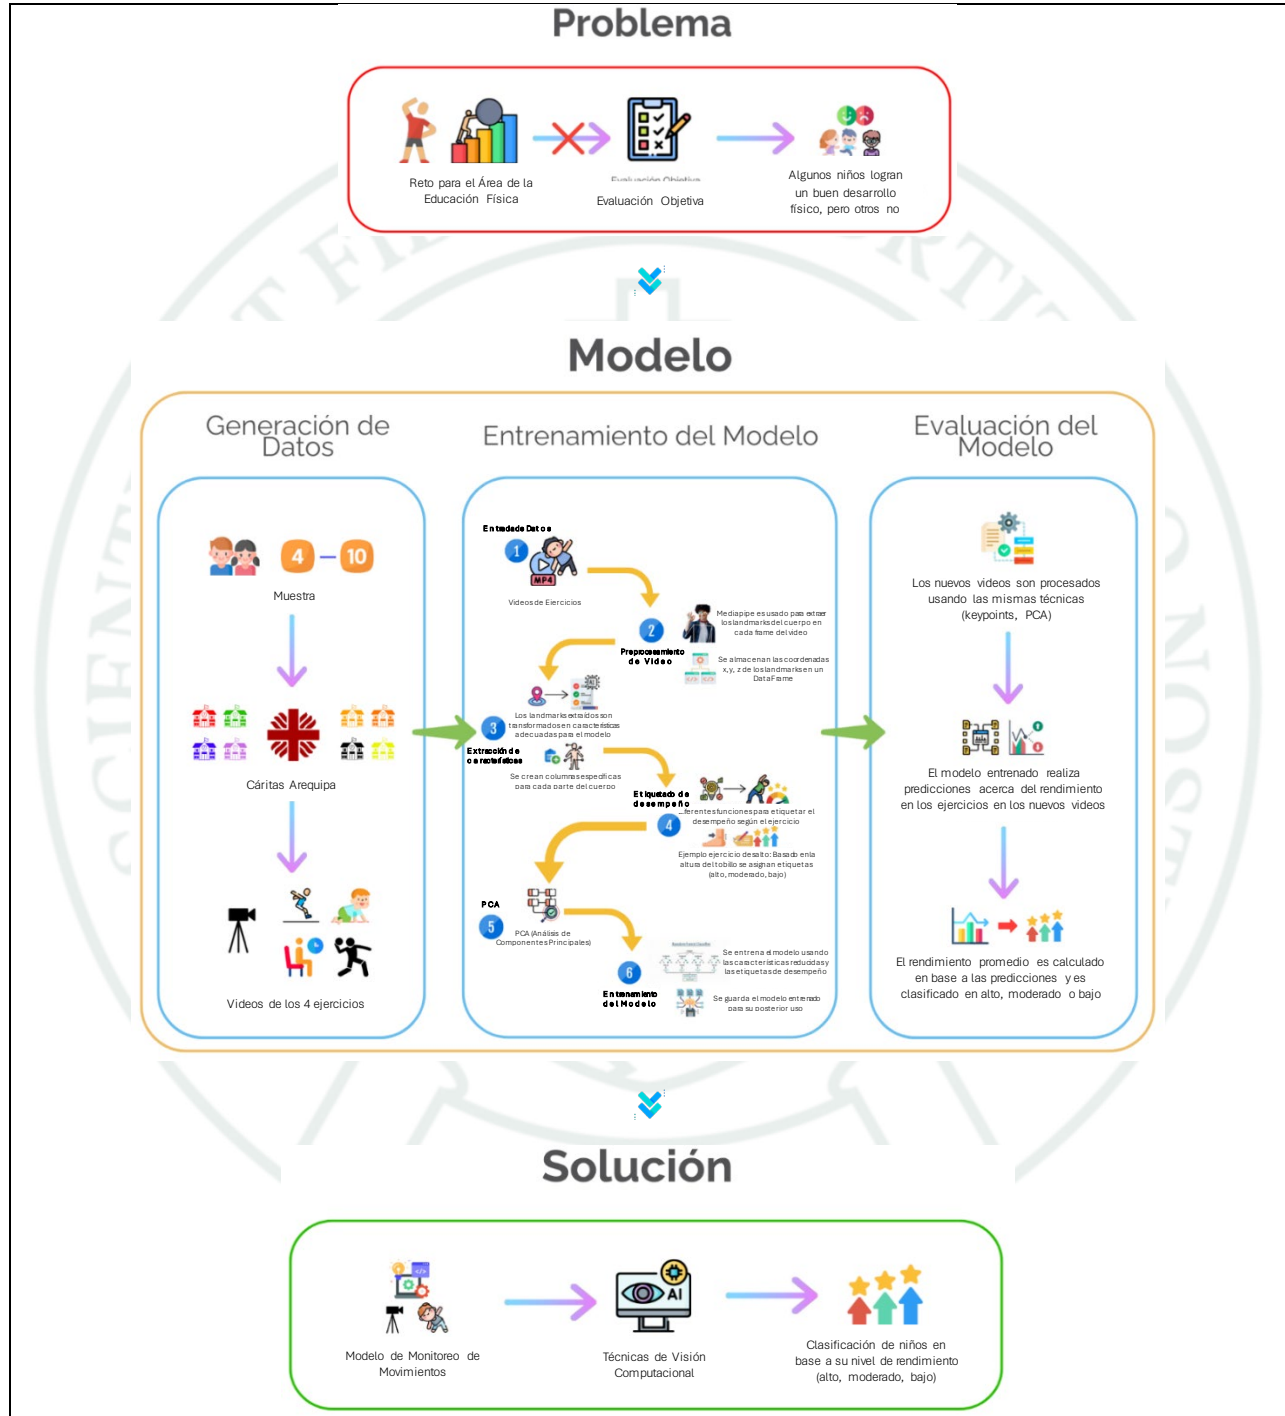
La fase inicial del proyecto se centró en identificar y definir la problemática existente en la educación física para personas con habilidades diferentes. Se determinó que la evaluación motora tradicional en niños con Síndrome de Down depende en gran medida de la observación directa del docente, lo cual introduce un sesgo subjetivo inherente y dificulta la medición precisa del progreso físico a lo largo del tiempo; en respuesta a ello, se establecieron los siguientes objetivos técnicos y de negocio:

- **Objetivo de Negocio:** Proveer a los docentes de una herramienta de soporte a la decisión que cuantifique objetivamente la calidad del movimiento, permitiendo adaptar las terapias físicas a las necesidades individuales de cada estudiante.
- **Objetivo de Minería de Datos:** Traducir el problema educativo a un problema de clasificación supervisada. El sistema debe ser capaz de ingerir datos no estructurados en este caso videos en formato .mp4 y asignar una categoría discreta de desempeño (Alto, Moderado, Bajo). Esta clasificación se fundamenta en patrones cinemáticos predefinidos mediante algoritmos heurísticos, los cuales digitalizan los criterios de evaluación biomecánica establecidos por los especialistas.

Para abordar este desafío computacional, se definió una arquitectura de software que integra visión computacional para la extracción de características y aprendizaje automático para la inferencia, estructurada a través de un flujo de procesamiento secuencial.

Figura 4.14

Esquema del Modelo



Nota. Esta figura muestra un esquema de la necesidad que se aborda en esta investigación, la metodología utilizada para el modelo de IA y la solución que se plantea en respuesta a la necesidad.

4.3.2.2.1. Recursos


Se utilizó un modelo pre-entrenado de la librería MediaPipe para detectar y extraer puntos clave del cuerpo humano en cada frame del video, representando la estructura corporal en coordenadas espaciales (x, y, z).

Figura 4.15

Modelo pre-entrenado



Salto en 2 pies



Sentarse y pararse de una silla

Nota. Estas figuras muestran frames de los videos con los cuales el modelo ha sido pre-entrenado con MediaPipe, de esta manera se detectan y extraen los keypoints.

4.3.2.2.2. Restricciones

- Las posibles limitaciones del hardware al procesar videos en tiempo real.
- La calidad de los datos puede verse afectada por la posición de las cámaras y las oclusiones en los movimientos de los sujetos.

4.3.2.2.3. Definición de la Arquitectura técnica (Pipeline del sistema)

Como estrategia para alcanzar los objetivos planteados bajo las restricciones identificadas, se diseñó una arquitectura de procesamiento secuencial. El modelo de Machine Learning es entrenado mediante un proceso de aprendizaje supervisado orientado a evaluar el rendimiento

motor a partir de patrones de movimiento específicos. El flujo técnico funciona de la siguiente manera: durante el entrenamiento, el modelo utiliza el modelo de estimación de postura corporal BlazePose integrado en MediaPipe para procesar cada video de los ejercicios, descomponiendo cada archivo en frames individuales. En esta etapa, se extrae un mapa topológico de 33 puntos clave (landmarks) que representan las articulaciones del cuerpo humano. Cada frame es transformado en un vector numérico que contiene las coordenadas espaciales (x, y, z) de cada articulación. Estas coordenadas se almacenan en archivos CSV que reúnen la secuencia temporal completa de movimientos del niño. Para garantizar la objetividad, cada tipo de ejercicio cuenta con un algoritmo de evaluación propio especializado basado en métricas biomecánicas descritas previamente por especialistas:


- **Salto en 2 pies:** Analiza la variación vertical inversa de los tobillos (coordenadas Y) para estimar la altura máxima alcanzada y la simetría en el aterrizaje.
- **Gatear:** Evalúa la coordinación motora mediante la correlación del movimiento diagonal entre extremidades opuestas (mano-rodilla) y la estabilidad del centro de gravedad en la cadera.
- **Lanzamiento de Pelota:** Verifica el cumplimiento de la cadena cinética correcta, asegurando la secuencia de activación proximal-distal (tronco - hombro - codo - muñeca).
- **Sentarse y Pararse de una Silla:** Mide el control postural a través de la alineación vertical de la columna y la velocidad de aceleración de la cadera durante las fases de ascenso y descenso.

Finalmente, en la etapa de etiquetado, estos criterios permiten clasificar el rendimiento en tres clases (alto, moderado o bajo). Esta clasificación se realiza mediante el cálculo de percentiles

estadísticos sobre la distribución de datos de la muestra, generando así las etiquetas de referencia necesarias para el entrenamiento supervisado del modelo. La Figura 4.16 ilustra el pipeline técnico del sistema, detallando el flujo de transformación de datos a través de los componentes de software implementados.

Figura 4.16

Flujo de transformación de datos



Nota. El diagrama utiliza carriles (swimlanes) para distinguir entre los artefactos de datos (columna izquierda, en azul) y la lógica de procesamiento (columna derecha, en verde).

4.3.2.3. Fase 2: Comprensión de los Datos

La fase de comprensión de datos se fundamentó en la captura y análisis de videos de ejercicios motores realizados por la muestra de estudio. Para garantizar la relevancia clínica de los datos, el diseño de los ejercicios (gateo, lanzamiento, salto y sentadilla) fue validado previamente por especialistas en desarrollo físico para niños con habilidades diferentes. Los videos crudos, capturados en formato .mp4 a 30 FPS, constituyen la entrada no estructurada del sistema, la cual debe ser transformada en datos numéricos estructurados para su procesamiento computacional.

4.3.2.3.1. Extracción de Características

Para la digitalización del movimiento humano, se implementó un pipeline de extracción de características basado en la librería MediaPipe Holistic usando el modelo BlazePose. A diferencia de enfoques que requieren marcadores físicos, esta solución utiliza visión computacional para inferir la geometría corporal en tiempo real. Técnicamente, el proceso de extracción se configuró de la siguiente manera:

- **Modelo de Postura:** Se hizo uso del modelo BlazePose para esto se instanció la solución `mp_holistic.Holistic` con el parámetro `model_complexity=1`, optimizando el balance entre precisión y velocidad de inferencia para hardware estándar.
- **Topología de Landmarks:** El modelo detecta y rastrea 33 puntos clave (landmarks) corporales, que cubren desde las articulaciones faciales hasta los pies.
- **Espacio Vectorial:** Para cada frame del video, el sistema extrae las coordenadas espaciales (x, y, z) de cada uno de los 33 puntos. Esto resulta en la transformación de cada imagen en un vector de características unidimensional de 99 valores (33 puntos x 3 coordenadas), eliminando la información de píxeles y conservando únicamente la información biomecánica.

El script de procesamiento (process_videos.py) itera sobre cada video del dataset, generando una matriz de datos donde cada fila representa un instante de tiempo (t) y cada columna una coordenada específica de una articulación (ej. left_knee_x, right_ankle_y), estructura necesaria para el entrenamiento de los algoritmos de Machine Learning.

4.3.2.3.2. Análisis Exploratorio y Selección de Articulaciones

Dada la alta dimensionalidad del vector inicial (99 características), se realizó un análisis exploratorio para identificar qué subconjunto de articulaciones aportaba información significativa para evaluar la calidad de ejecución de cada ejercicio específico.

Basado en la cinética de cada movimiento, se aislaron los siguientes nodos críticos para el análisis:

- **Salto en 2 Pies:** El análisis se centró en la variación vertical (eje Y) de los tobillos permitiendo medir la altura relativa del salto y la simetría en el aterrizaje.
- **Gatear:** Se priorizó el seguimiento de las extremidades contralaterales para evaluar la coordinación cruzada. Las articulaciones clave fueron las muñecas y las rodillas, además de las caderas para medir la estabilidad.
- **Lanzamiento de Pelota:** Se analizó la cadena cinética superior, monitoreando la secuencia de activación de hombros, codos y muñecas para verificar el patrón de movimiento "próximo-distal".
- **Sentarse y Pararse de una Silla:** Se evaluó el control postural mediante la alineación del tronco, utilizando los puntos de hombros y caderas para calcular la verticalidad de la columna y la velocidad de descenso.

Esta selección estratégica de características permite que el modelo enfoque su capacidad de procesamiento en los aspectos biomecánicos relevantes, descartando ruido introducido por movimientos involuntarios de articulaciones no involucradas (como movimientos faciales o de dedos).

4.3.2.4. Fase 3: Preparación de los Datos

En esta fase, los datos crudos extraídos (vectores de 99 dimensiones) fueron sometidos a un proceso de refinamiento para garantizar la calidad del entrenamiento. Este proceso incluyó la limpieza de ruido, la generación algorítmica de etiquetas de desempeño y la reducción de dimensionalidad estadística.

4.3.2.4.1. Pre-procesamiento y Limpieza

Para garantizar que los modelos reciban datos consistentes y libres de ruido, se aplicó un tratamiento de errores de detección y se estandarizó la generación de vectores mediante tres procesos secuenciales:

- **Segmentación Temporal:** Se eliminaron manualmente los fragmentos de video iniciales y finales donde no existía ejecución de la actividad (tiempo muerto) o donde se presentaban oclusiones por la intervención de los docentes.
- **Imputación de Datos:** Durante la extracción con el modelo de MediaPipe, se identificaron frames con valores nulos (NaN) debido a movimientos rápidos u oclusiones parciales transitorias. Para tratar estos errores sin perder información valiosa, se aplicó una técnica de interpolación lineal temporal. Este método matemático asume la continuidad cinemática del movimiento humano; es decir, dado que una articulación no puede teletransportarse de un punto A a un punto B

en una fracción de segundo, el algoritmo reconstruye la trayectoria perdida calculando los valores intermedios entre el último frame válido conocido y el siguiente.

- **Normalización:** Para mitigar las variaciones causadas por la distancia de la cámara respecto al sujeto, las coordenadas (x, y, z) fueron normalizadas en relación con el marco delimitador del cuerpo, haciendo que el modelo sea invariante a la escala del niño o la posición de la cámara.
- **Construcción del Vector:** Finalmente, para generar un vector de características unidimensional por cada instante de tiempo. Cada frame se transformó en un vector $v \in \mathbb{R}^{99}$ resultante de la concatenación de las 3 coordenadas de los 33 puntos clave. Este vector estructurado constituye la entrada final para los algoritmos de clasificación.

4.3.2.4.2. Generación de Etiquetas de Desempeño

Se desarrolló un sistema de etiquetado automatizado. Esta clasificación se fundamenta en patrones cinemáticos predefinidos mediante algoritmos heurísticos, los cuales digitalizan los criterios de evaluación biomecánica establecidos por los especialistas en desarrollo físico.

A diferencia del etiquetado manual, donde el criterio del evaluador puede variar por factores como la fatiga o la percepción visual, la implementación de scripts garantiza una estandarización absoluta. El sistema traduce las instrucciones cualitativas de los expertos (ej. "el niño debe mantener la espalda recta") en reglas lógicas programadas en Python que analizan la geometría de los landmarks. Esto asegura que cada repetición sea juzgada bajo la misma "rúbrica computacional" inmutable.

A continuación, se detalla la lógica algorítmica implementada para cada ejercicio:

- **Salto en 2 pies:** El algoritmo para evaluar el salto centra su análisis en los Landmarks 27 y 28 (Tobillos). La métrica crítica es la altura máxima alcanzada durante el vuelo. El sistema calcula el promedio de la posición vertical (eje Y) de ambos tobillos frame a frame. Dado que en visión computacional el eje Y es invertido, un menor valor numérico indica mayor elevación física. Se establecieron umbrales dinámicos basados en los terciles de la distribución de datos de la muestra, clasificando automáticamente como "Alto Desempeño" a aquellas ejecuciones en el tercil superior de elevación.
- **Gatear:** Para este ejercicio se buscó digitalizar el criterio clínico de "patrón cruzado". El algoritmo monitorea la sincronía entre las extremidades opuestas, específicamente comparando el movimiento de las Muñecas (Landmarks 15/16) con las Rodillas contrarias (Landmarks 26/25). El script verifica que cuando una mano avanza, la rodilla opuesta lo haga simultáneamente. Adicionalmente, se analiza la estabilidad del centro de gravedad monitoreando la variación de altura en las Caderas (Landmarks 23/24); una menor oscilación vertical se traduce en una mayor puntuación de estabilidad.
- **Lanzamiento de Pelota:** Para este ejercicio, el modelo verifica el cumplimiento de la cadena cinética abierta. Se rastrean los Hombros (Landmarks 11/12), Codos (13/14) y Muñecas (15/16) del brazo ejecutor. El algoritmo calcula la velocidad angular de cada articulación y valida temporalmente que los picos de aceleración ocurran en el orden biomecánico eficiente: primero el tronco, seguido por el hombro, luego el codo y finalmente la muñeca. Si la secuencia se altera (ej. mover

la muñeca antes que el hombro), el sistema penaliza la clasificación, ya que indica una técnica deficiente que no aprovecha la transferencia de fuerza.

- **Sentarse y Pararse de una Silla:** En este ejercicio se mide el control postural y la fuerza excéntrica. El algoritmo traza un vector entre los Hombros (Landmarks 11/12) y las Caderas (23/24) para medir la alineación del tronco; si el ángulo de este vector se desvía significativamente de la vertical, se detecta una mala postura. Simultáneamente, se calcula la aceleración de bajada de la cadera. Si la aceleración supera un umbral seguro, el sistema lo interpreta como una "caída" sobre la silla por falta de control muscular, asignando una etiqueta de bajo desempeño.

4.3.2.4.3. Reducción de Dimensionalidad

El vector original de 99 características presenta una alta colinealidad biomecánica (dependencia entre articulaciones adyacentes), lo cual introduce redundancia y aumenta el riesgo de sobreajuste en el modelo de clasificación.

Para mitigar esto, se aplicó la técnica de Análisis de Componentes Principales (PCA), transformando el espacio vectorial original a un subespacio latente de menor dimensión:

- **Configuración:** Se implementó un umbral dinámico de varianza, configurando $n_components=0.95$ en el objeto PCA de scikit-learn. Este parámetro instruye al algoritmo a seleccionar automáticamente el número mínimo de componentes necesarios para retener el 95% de la varianza explicada.
- **Justificación de Varianza:** Al aplicar este umbral, el número de componentes seleccionados varía según la complejidad biomecánica de cada ejercicio: Salto (5 componentes), Gateo (6 componentes), Sentarse (8 componentes) y Lanzamiento

(8 componentes). Esto confirma que el salto, al depender de una métrica principal (altura del tobillo), concentra su varianza en menos dimensiones, mientras que ejercicios con patrones multiarticulares complejos requieren mayor representación dimensional. En todos los casos, se retiene el 95% de la información relevante del movimiento.

```
from sklearn.decomposition import PCA
# Carga csv labeled
df = pd.read_csv(input_csv)
landmark_cols = [c for c in df.columns if c.endswith(('_x', '_y', '_z'))]
X = df[landmark_cols]

# Se configura con umbral de varianza en lugar de número fijo
pca = PCA(n_components=0.95)
X_reduced = pca.fit_transform(X)

# sklearn determina automáticamente cuántos componentes necesita
n_components = X_reduced.shape[1]
```

Código 4.1: Script de análisis de varianza acumulada para determinar número óptimo de componentes.

4.3.2.5. Fase 4: Modelado

En esta fase se construyeron y evaluaron modelos predictivos capaces de clasificar el desempeño motor a partir de los vectores de características reducidos (PCA). El proceso se orientó a identificar el algoritmo que mejor generalizara los patrones biomecánicos no lineales inherentes al movimiento humano.

4.3.2.5.1. Diseño Experimental

Para garantizar la validez estadística de los resultados, se aplicó un protocolo de división de datos. El dataset procesado se segregó aleatoriamente en dos subconjuntos:

- **Conjunto de Entrenamiento (80%):** Utilizado para el ajuste de los pesos y reglas de los modelos.
- **Conjunto de Prueba (20%):** Reservado exclusivamente para la evaluación final, simulando el comportamiento del modelo frente a datos desconocidos (nuevos estudiantes).

Se utilizó la semilla aleatoria `random_state=42` para garantizar la reproducibilidad de los experimentos en todas las ejecuciones.

4.3.2.5.2. Selección de algoritmos

Se seleccionaron cinco algoritmos de aprendizaje supervisado que representan diferentes familias de modelado, con el objetivo de contrastar su eficacia en la clasificación de patrones cinemáticos:

- **Random Forest (Ensamble):** Seleccionado por su capacidad para manejar relaciones no lineales y su robustez frente al ruido (varianza) mediante el promedio de múltiples árboles de decisión.
- **XGBoost (Boosting):** Incluido por su eficiencia en la optimización de gradientes, útil para detectar patrones sutiles en los datos.
- **Support Vector Machine (SVM):** Evaluado por su eficacia en espacios de alta dimensionalidad mediante el uso de kernels no lineales (RBF).
- **Regresión Logística (Lineal):** Utilizado como línea base para determinar si los datos son linealmente separables.

- **K-Nearest Neighbors (KNN):** Evaluado por su enfoque basado en similitud geométrica, intuitivo para comparar posturas corporales cercanas en el espacio vectorial.

4.3.2.5.3. Resultados Experimentales Comparativos

En lugar de evaluar cada modelo de forma aislada, se realizó una ejecución comparativa unificada bajo las mismas condiciones de pre-procesamiento.

La Tabla 4.2 consolida las métricas de desempeño obtenidas por cada algoritmo sobre el conjunto de prueba y detalla la Exactitud Global (Accuracy), desglosa la Precisión (P) y el Recall (R) para cada clase de desempeño (Alto, Moderado, Bajo).

Tabla 4.2

Comparación de Desempeño de Algoritmos de Clasificación

Algoritmo	Exactitud (Accuracy)	Clase 1 (P/R)	Clase 2 (P/R)	Clase 3 (P/R)	Comportamiento
Random Forest	95.55%	0.96 / 0.96	0.93 / 0.93	0.97 / 0.97	Equilibrado y robusto en todas las clases.
Regresión Logística	95.79%	0.97 / 0.97	0.93 / 0.94	0.97 / 0.96	Alta precisión, pero dependiente de linealidad.
SVM (RBF)	94.80%	0.96 / 0.97	0.94 / 0.90	0.94 / 0.98	Dificultad leve en clases intermedias.
K-NN	94.17%	0.97 / 0.95	0.91 / 0.92	0.95 / 0.96	Sensible a la dispersión de datos.
XGBoost	93.48%	0.96 / 0.95	0.90 / 0.91	0.94 / 0.96	Menor rendimiento en este dataset específico.

Nota. P = Precisión, R = Recall (Sensibilidad). Los valores están expresados en escala de 0 a 1. Se resalta en negrita el balance del modelo seleccionado y muestra caídas de rendimiento en modelos competidores.

Los resultados muestran una alta competitividad entre los modelos, donde todos superan el umbral del 93%, lo que valida la calidad de los datos de entrada generados en la fase anterior.

4.3.2.5.4. **Discusión y Selección del Modelo Final**

El análisis detallado de la tabla anterior revela patrones críticos que justifican la selección del modelo, más allá de la exactitud global:

- **Estabilidad en la Clase "Moderado":** La clase "Moderado" es la más difícil de clasificar, ya que representa el punto medio de la transición biomecánica.
 - XGBoost mostró su debilidad aquí, cayendo a una precisión de 0.90.
 - SVM, aunque preciso, tuvo una caída notable en el Recall de esta clase (0.90), lo que significa que "perdió" o no detectó el 10% de los casos moderados reales.
 - Random Forest y Regresión Logística mantuvieron un desempeño robusto (>0.93) en esta zona crítica.
- **Comparativa Final - Random Forest vs. Regresión Logística:** Si bien la Regresión Logística obtuvo una ventaja marginal en exactitud global (+0.24%), se seleccionó Random Forest como el modelo final. Esta decisión técnica prioriza la robustez estructural sobre la precisión numérica pura:
 - **Equilibrio P/R:** Random Forest muestra una simetría perfecta entre Precisión y Recall en la clase "Alto" (0.96/0.96) y "Bajo" (0.97/0.97). Esto indica que el modelo no tiene sesgo hacia falsos positivos ni falsos negativos.
 - **Justificación Biomecánica:** Los modelos lineales como Regresión Logística asumen que el cambio de "Bajo" a "Alto" rendimiento sigue una progresión constante. Sin embargo, en motricidad, pequeños fallos técnicos pueden degradar el rendimiento de forma no lineal. Random Forest, al trabajar con

múltiples árboles de decisión, segmenta mejor estas fronteras de decisión complejas, haciéndolo más confiable para futuros datos que podrían no ser linealmente separables.

4.3.2.5.5. Configuración del Modelo Final

Definido el algoritmo, se procedió al ajuste final de hiperparámetros para el despliegue en producción. El modelo fue instanciado con la siguiente configuración en el script `train_model.py`:

- **n_estimators = 100**: Cantidad de árboles para estabilizar la predicción.
- **criterion = 'gini'**: Para optimizar la pureza de los nodos.
- **class_weight = 'balanced'**: Para asegurar que el modelo preste igual atención a los casos de bajo y alto desempeño.

El modelo resultante fue serializado en formato `.pkl`, quedando listo para su integración en el módulo de evaluación.

4.3.2.5.6. Arquitectura del Sistema

El sistema se divide en dos módulos con funciones distintas: el Módulo de Entrenamiento y el Módulo de Evaluación. Ambos replican la etapa inicial completamente denominada Capa de Procesamiento de Video, encargada de extraer y estandarizar la información de movimiento corporal a partir de cualquier video de entrada.

Esta etapa cumple una función fundamental: extraer frame por frame los landmarks del sujeto, asegurar la consistencia de los datos mediante de interpolación lineal, y aplicar una normalización corporal de datos para asegurar que siempre se evalúen cantidades comparables entre sujetos, esto genera un conjunto de 99 dimensiones por frame, que representan la posición

normalizada de los 33 puntos corporales detectados. Ambos módulos parten de esta misma representación para realizar sus funciones respectivas.

A partir de este punto, los módulos trabajan de forma diferente:

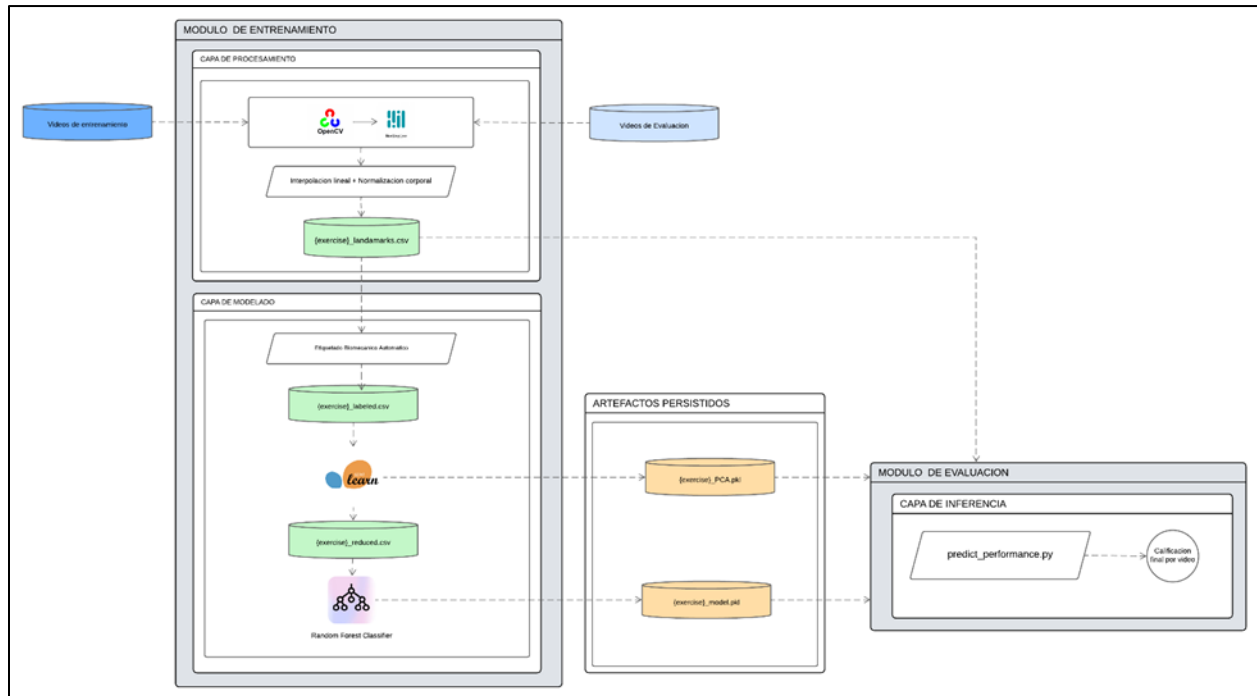
El Módulo de Entrenamiento se encarga de construir los modelos que el sistema usará para clasificar. Recibe los datos procesados, les asigna una etiqueta de rendimiento (Alto, Moderado o Bajo) según los criterios biomecánicos definidos para cada ejercicio, reduce la cantidad de variables mediante PCA y entrena el clasificador Random Forest. Como resultado, genera dos archivos: el modelo PCA ajustado (pca.pkl) y el modelo de clasificación entrenado (model.pkl), que quedan guardados para ser usados posteriormente.

El Módulo de Evaluación se encarga de aplicar lo que el sistema ya aprendió sobre videos nuevos. Recibe los mismos 99 valores por frame generados por la etapa de procesamiento de videos, carga los dos archivos guardados durante el entrenamiento y los utiliza para producir una calificación final por video.

De esta manera, la etapa de extracción y normalización de movimiento es la misma para ambos módulos, lo que garantiza que el sistema evalúe videos nuevos bajo exactamente las mismas condiciones en que fue entrenado.

Figura 4.17

Arquitectura del Sistema



4.3.2.6. Fase 5: Evaluación

El objetivo principal de esta fase consistió en validar la robustez y la capacidad de generalización del modelo final. Para ello, se sometió al algoritmo entrenado a un proceso de inferencia utilizando exclusivamente el subconjunto de prueba (correspondiente al 20% de los datos originales), el cual se mantuvo aislado durante toda la etapa de entrenamiento. Esta división de datos es crítica para simular un escenario de producción real, de esta manera, nos aseguramos de que los resultados reflejen la capacidad real del sistema para operar con información nueva, descartando que el modelo simplemente haya memorizado los ejemplos de entrenamiento.

4.3.2.6.1. Protocolo de Validación y Definición de Métricas

Para cuantificar objetivamente el desempeño, no basta con medir la exactitud global. Se seleccionaron indicadores específicos que responden a las necesidades del contexto educativo, los cuales se detallan a continuación:

1. Precisión (Precision)

Esta métrica penaliza cualquier falso positivo; pues, en el ámbito de la Educación, la precisión es muy importante cuando las consecuencias de cualquier falso positivo pueden llegar a impactar negativamente, como lo es en este caso (Du et al., 2023).

Proporción de verdaderos positivos (TP) entre todas las predicciones positivas (TP + FP, falsos positivos).

Fórmula:

$$\textit{precision} = \frac{TP}{TP + FP}$$

2. Sensibilidad (Recall)

Detecta la mayor cantidad de movimientos (objetivos) correctos de los niños con SD, y penaliza los falsos negativos; es decir, objetivos que no fueron detectados (Du et al., 2023).

Proporción de verdaderos positivos (TP) entre todas las instancias que pertenecen a la clase real (TP + FN, falsos negativos).

Fórmula:

$$\textit{sensibilidad} = \frac{TP}{TP + FN}$$

3. F1-Score

Detecta de manera correcta los movimientos de los niños con Síndrome de Down, pues sirve de balance entre la Precisión y Recall, ya que mediante el promedio armónico brinda una evaluación combinada de las tasas de verdaderos positivos y las de falsos negativos en una única métrica, logrando así que el modelo no optimice una sola dimensión (Du et al., 2023).

Fórmula:

$$F1 - Score = 2 * \frac{presicion * sensibilidad}{presicion + sensibilidad}$$

4. Soporte (Support)

Representa la cantidad de muestras verdaderas para cada clase y, además permite contextualizar las demás métricas de evaluación; pues, permite poder validar si es que se cuenta con los suficientes datos para que el resto de las métricas mencionadas sean más confiables estadísticamente.

5. Exactitud (Accuracy)

Es una métrica estándar para poder evaluar modelos de visión computacional, pues mide cuantas predicciones se acertaron del total de predicciones realizadas; logrando así evaluar las habilidades motoras y desempeño físico de niños con habilidades diferentes (Donnelly et al., 2023).

Fórmula:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Para obtener estos datos el modelo utiliza una Matriz de Confusión, que organiza sus predicciones en categorías: verdaderos positivos (TP), verdaderos negativos (TN), falsos positivos (FP) y falsos negativos (FN). A partir de esta matriz se calculan las métricas clave como la precisión, el recall y el F1-score.

Se configuró de la siguiente manera:

```
# Generate confusion matrix
cm = confusion_matrix(y_test, y_pred)

# Display model performance results
print(f"Model: {model_name}")
print(f"Accuracy: {accuracy:.4f}")
print("Classification Report:\n", report)

# Create and save confusion matrix visualization
create_confusion_matrix_plot(cm, exercise_name, model_name)

# Save trained model for later use in evaluation
model_path = f"data/models/{exercise_name}_model.pkl"
joblib.dump(model, model_path)
print(f"Model saved to: {model_path}")
```

Código 4.2: Visualización de la Matriz de Confusión con Heatmap

Para mostrar esta tabla en tiempo real se utilizó:

```
from sklearn.metrics import accuracy_score, classification_report,
confusion_matrix
```

Código 4.3: Evaluación del Desempeño del Modelo mediante Métricas de Clasificación

- **Estructura de la Matriz:**
 - Las filas representan las clases reales de los datos de prueba (Eje Y).
 - Las columnas representan las clases predichas por el modelo (Eje X).
 - Cada celda muestra el número de instancias que pertenecen a una combinación de clase verdadera y clase predicha.


Para la evaluación de precisión y desempeño, se empleó el conjunto de prueba para realizar la evaluación del Modelo. A continuación, se muestran las matrices de confusión y los resultados obtenidos de la evaluación de precisión y desempeño respectivamente por cada uno de los ejercicios: sentarse y pararse de una silla, lanzamiento de pelota, gatear, y saltos en dos pies.

4.3.2.6.2. Sentarse y pararse de una silla

- **Matriz de Confusión:**

Figura 4.18

Matriz de Confusión del ejercicio Sentarse y pararse de una silla



Nota. Esta figura muestra la Matriz de Confusión del ejercicio Sentarse y Pararse de una Silla, que ha sido generada con el conjunto de datos, en la cual se pueden apreciar los valores verdaderos y los valores de la predicción.

Los resultados por Clase son los siguientes:

➤ **Valor Real: Bajo Rendimiento**

- El Modelo identificó de manera correcta 235 casos de bajo rendimiento.
- El Modelo clasificó 13 casos como rendimiento moderado cuando en realidad era bajo.
- El Modelo clasificó 2 casos como alto rendimiento cuando en realidad era bajo.

➤ **Valor Real: Rendimiento Moderado**

- El Modelo clasificó 7 casos como bajo rendimiento cuando en realidad era moderado.
- El Modelo identificó de manera correcta 241 casos de rendimiento moderado.
- El Modelo clasificó 21 casos como alto rendimiento cuando en realidad era moderado.

➤ **Valor Real: Alto Rendimiento**

- El Modelo clasificó 2 casos como bajo rendimiento cuando en realidad era alto.
- El Modelo clasificó 29 casos como rendimiento moderado cuando en realidad era alto.
- El Modelo identificó de manera correcta 217 casos de rendimiento alto.

- **Resultados Obtenidos:**

Figura 4.19

Resultados de evaluación del ejercicio Sentarse y pararse de una silla

```

Model: RandomForest
Accuracy: 0.9035
Classification Report:
      precision    recall  f1-score   support

     1       0.96     0.94     0.95     250
     2       0.85     0.90     0.87     269
     3       0.90     0.88     0.89     248

 accuracy          0.90     0.90     0.90     767
 macro avg         0.91     0.90     0.90     767
 weighted avg      0.90     0.90     0.90     767

Matriz de confusión guardada en: data/results/confusion_matrices\sit_RandomForest_confusion_matrix.png
Model saved to: data/models/sit_model.pkl

```

Nota. En esta figura se muestran los resultados de la evaluación de precisión y desempeño del modelo para el ejercicio Sentarse y pararse de una silla.

- **Análisis integral:**


Este ejercicio presentó el mayor desafío biomecánico, alcanzando una exactitud global del 90.37%. Al analizar las métricas detalladas, observamos que la Precisión para detectar el 'Alto Rendimiento' es elevada (96%), lo que indica que cuando el sistema califica una buena postura, es muy confiable. Sin embargo, el F1-Score desciende ligeramente en la clase 'Moderado' (0.87), reflejando cierta dificultad para trazar una línea divisoria clara entre un movimiento fluido y uno ligeramente brusco. A pesar de esta sutil dificultad, el modelo mantiene una Sensibilidad (Recall) del 88-90% para identificar casos que requieren corrección.

4.3.2.6.3. Lanzamiento de pelota

- Matriz de Confusión:

Figura 4.20

Matriz de Confusión del ejercicio Lanzamiento de Pelota



Nota. Esta figura muestra la Matriz de Confusión del ejercicio Lanzamiento de Pelota, que ha sido generada con el conjunto de datos, en la cual se pueden apreciar los valores verdaderos y los valores de la predicción.

Los resultados por Clase son los siguientes:

➤ **Valor Real: Bajo Rendimiento**

- El Modelo identificó de manera correcta 2276 casos de bajo rendimiento.
- El Modelo clasificó 42 casos como rendimiento moderado cuando en realidad era bajo.
- El Modelo clasificó 33 casos como alto rendimiento cuando realmente era bajo.

➤ **Valor Real: Rendimiento Moderado**

- El Modelo clasificó 101 casos como bajo rendimiento cuando en realidad era moderado.
- El Modelo identificó de manera correcta 2244 casos de rendimiento moderado.
- El Modelo clasificó 89 casos como alto rendimiento cuando en realidad era moderado.

➤ **Valor Real: Alto Rendimiento**

- El Modelo clasificó 10 casos como bajo rendimiento cuando en realidad era alto.
- El Modelo clasificó 77 casos como rendimiento moderado cuando en realidad era alto.
- El Modelo identificó de manera correcta 2234 casos de rendimiento alto.

- **Resultados Obtenidos:**

Figura 4.21

Resultados de evaluación del ejercicio Lanzamiento de Pelota

```
Model: RandomForest
Accuracy: 0.9505
Classification Report:
      precision    recall  f1-score   support

     1       0.95       0.97       0.96       2351
     2       0.95       0.92       0.94       2434
     3       0.95       0.96       0.96       2321

 accuracy                   0.95       7106
 macro avg       0.95       0.95       0.95       7106
 weighted avg    0.95       0.95       0.95       7106

Matriz de confusión guardada en: data/results/confusion_matrices\throw_RandomForest_confusion_matrix.png
Model saved to: data/models/throw_model.pkl
```

Nota. En esta figura se muestran los resultados de la evaluación de precisión y desempeño del modelo para el ejercicio Lanzamiento de Pelota.

- **Análisis integral:**

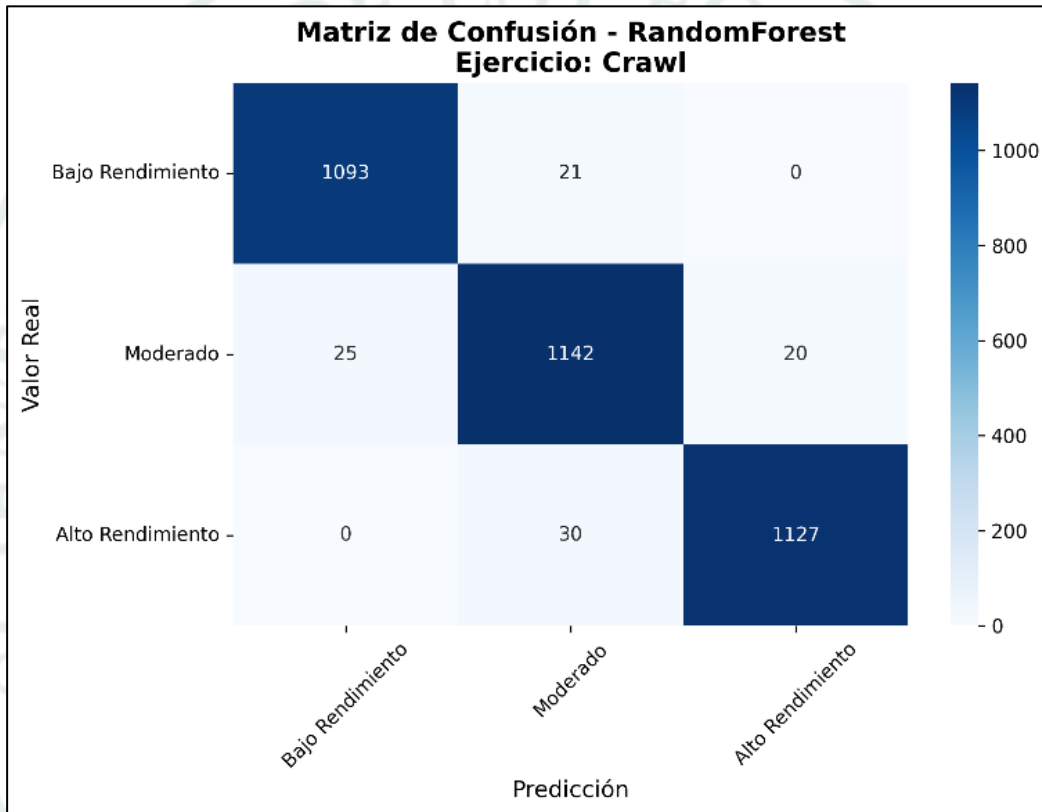
El modelo alcanzó una exactitud global del 95.1%, cifra respaldada por un sólido equilibrio entre Precisión (95%) y Sensibilidad (Recall) promedio del 95%. Destaca especialmente su capacidad para identificar el 'Alto Rendimiento' (con un Recall del 97%), lo cual confirma que las reglas programadas para la secuencia de movimiento (tronco-hombro-codo) actúan como un filtro muy efectivo para validar la técnica correcta. Por otro lado, la matriz muestra una ligera dispersión entre los niveles 'Bajo' y 'Moderado'; esto sugiere que, aunque el modelo distingue perfectamente una buena ejecución, la diferencia entre un lanzamiento deficiente y uno regular puede ser sutil, dependiendo a veces de pequeños grados de amplitud en el movimiento del brazo.

4.3.2.6.4. Gatear

- Matriz de Confusión:

Figura 4.22

Matriz de Confusión del ejercicio Gatear



Nota. Esta figura muestra la Matriz de Confusión del ejercicio Gatear, que ha sido generada con el conjunto de datos, en la cual se pueden apreciar los valores verdaderos y los de la predicción.

Los resultados por Clase son los siguientes:

➤ **Valor Real: Bajo Rendimiento**

- El Modelo identificó de manera correcta 1093 casos de bajo rendimiento.
- El Modelo clasificó 21 casos como rendimiento moderado cuando en realidad era bajo.
- El Modelo clasificó 0 casos como alto rendimiento cuando en realidad era bajo.

➤ **Valor Real: Rendimiento Moderado**

- El Modelo clasificó 25 casos como bajo rendimiento cuando en realidad era moderado.
- El Modelo identificó de manera correcta 1142 casos de rendimiento moderado.
- El Modelo clasificó 20 casos como alto rendimiento cuando en realidad era moderado.

➤ **Valor Real: Alto Rendimiento**

- El Modelo clasificó 0 casos como bajo rendimiento cuando en realidad era alto.
- El Modelo clasificó 30 casos como rendimiento moderado cuando en realidad era alto.
- El Modelo identificó de manera correcta 1127 casos de rendimiento alto.

- **Resultados Obtenidos:**

Figura 4.23

Resultados de evaluación del ejercicio Gatear

```
Model: RandomForest
Accuracy: 0.9722
Classification Report:
      precision    recall  f1-score   support

     1         0.98     0.98     0.98     1114
     2         0.96     0.96     0.96     1187
     3         0.98     0.97     0.98     1157

 accuracy          0.97          0.97          0.97          3458
 macro avg         0.97         0.97         0.97          3458
 weighted avg      0.97         0.97         0.97          3458

Matriz de confusión guardada en: data/results/confusion_matrices\crawl_RandomForest_confusion_matrix.png
Model saved to: data/models/crawl_model.pkl
```

Nota. En esta figura se muestran los resultados de la evaluación de precisión y desempeño del modelo para el ejercicio Gatear.

- **Análisis integral:**


Este ejercicio obtuvo el rendimiento más alto del estudio con una exactitud del 97.23% y un F1-Score casi perfecto de 0.98 para las clases extremas. Esto valida la robustez de los algoritmos de coordinación cruzada: el patrón de movimiento de cuatro apoyos es muy distintivo, permitiendo que el sistema alcance una Precisión del 98% en la detección de 'Bajo Rendimiento'. La ausencia de confusión significativa entre clases indica que la señal extraída por MediaPipe (sincronía muñeca-rodilla) es limpia y determinante para la clasificación.

4.3.2.6.5. Saltos en dos pies

- Matriz de Confusión:

Figura 4.24

Matriz de Confusión del ejercicio Saltos en 2 pies



Nota. Esta figura muestra la Matriz de Confusión del ejercicio Saltos en 2 Pies, que ha sido generada con el conjunto de datos, en la cual se pueden apreciar los valores verdaderos y los valores de la predicción.

Los resultados por Clase son los siguientes:

➤ **Valor Real: Bajo Rendimiento**

- El Modelo identificó de manera correcta 532 casos de bajo rendimiento.
- El Modelo clasificó 17 casos como rendimiento moderado cuando en realidad era bajo.
- El Modelo clasificó 0 casos como alto rendimiento cuando en realidad era bajo.

➤ **Valor Real: Rendimiento Moderado**

- El Modelo clasificó 17 casos como bajo rendimiento cuando en realidad era moderado.
- El Modelo identificó de manera correcta 563 casos de rendimiento moderado.
- El Modelo clasificó 31 casos como alto rendimiento cuando en realidad era moderado.

➤ **Valor Real: Alto Rendimiento**

- El Modelo clasificó 0 casos como bajo rendimiento cuando en realidad era alto.
- El Modelo clasificó 18 casos como rendimiento moderado cuando en realidad era alto.
- El Modelo identificó de manera correcta 558 casos de rendimiento alto.

- **Resultados Obtenidos:**

Figura 4.25

Resultados de evaluación del ejercicio Saltos en 2 pies

```
Training and evaluating model...
Model: RandomForest
Accuracy: 0.9522
Classification Report:
      precision    recall  f1-score   support

     1         0.97     0.97     0.97         549
     2         0.94     0.92     0.93         611
     3         0.95     0.97     0.96         576

 accuracy          0.95         1736
 macro avg         0.95     0.95     0.95         1736
 weighted avg      0.95     0.95     0.95         1736

Matriz de confusión guardada en: data/results/confusion_matrices\jump_RandomForest_confusion_matrix.png
Model saved to: data/models/jump_model.pkl
```

Nota. En esta figura se muestran los resultados de la evaluación de precisión y desempeño del modelo para el ejercicio Saltos en 2 pies.

- **Análisis integral:**

El modelo alcanzó una exactitud del 95.3%, Es crucial resaltar que la Precisión para la clase 'Bajo Rendimiento' es del 95%, lo que garantiza que los niños con dificultades motoras sean identificados correctamente para recibir apoyo. Además, la matriz muestra cero errores cruzados severos (ningún salto 'Bajo' fue clasificado como 'Alto'), confirmando que el uso de la posición normalizada de los tobillos es un predictor robusto y objetivo de la potencia de salto.

4.3.2.7. Fase 6: Despliegue

En la etapa final del ciclo CRISP-DM, se integraron los modelos entrenados y validados dentro de un módulo de evaluación funcional. El objetivo fue habilitar la evaluación de nuevos videos en un módulo de producción, permitiendo a los docentes obtener retroalimentación automatizada sin necesidad de reentrenar el modelo.

4.3.2.7.1. Proceso de Predicción con el Modelo Entrenado

El despliegue se basa en la carga de los artefactos serializados (.pkl) generados en la fase de modelado. A diferencia de la etapa de entrenamiento, el pipeline de predicción está optimizado para la velocidad de respuesta.

El proceso técnico, está implementado en el script “predict_performance.py”, se siguieron los siguientes pasos para cada nuevo video ingresado por el docente:

- **Carga de Artefactos:** Se deserializa el modelo específico del ejercicio (ej. throw_model.pkl) y la matriz de transformación PCA correspondiente.
- **Procesamiento en Tiempo Real:** Se extraen los landmarks frame a frame utilizando la misma configuración de MediaPipe que en el entrenamiento.
- **Proyección y Predicción:** Los nuevos vectores de características son proyectados al espacio reducido (PCA) y clasificados por Random Forest.

```
def main_evaluation():
    video_file = os.path.join(base_path, f'data/raw/throw/throw_009.mp4')
    model_file = os.path.join(base_path, f'data/models/throw_model.pkl')
    pca_components = 10
    predict_performance(video_file, model_file, pca_components)
```

Código 4.4: Evaluación de desempeño mediante predicción en videos usando el Modelo

Preentrenado

4.3.2.7.2. Generación de Reportes y Retroalimentación

El modelo no solo clasifica el video en su totalidad, sino que proporciona una granularidad frame por frame. Esto permite identificar momentos exactos donde la técnica del niño falla o mejora.

Como se evidencia en la Figura 4.25, el sistema genera un log de salida que detalla la clasificación instantánea y calcula una métrica consolidada:

- **Promedio de Desempeño:** Un valor numérico (1.0 - 3.0) que permite al docente ver el progreso del niño, incluso si no cambia de categoría.
- **Clasificación General:** La etiqueta final (Alto/Moderado/Bajo) basada en la moda o promedio ponderado de la ejecución completa.

Figura 4.26

Resultados de desempeño


```
Frame 686: Desempeño Bajo
Frame 687: Desempeño Bajo
Frame 688: Desempeño Bajo
Frame 689: Desempeño Bajo
Frame 690: Desempeño Bajo
Frame 691: Desempeño Bajo
Frame 692: Desempeño Bajo
Frame 693: Desempeño Bajo
Frame 694: Desempeño Bajo
Frame 695: Desempeño Bajo

Promedio de desempeño: 2.02
Desempeño general del ejercicio: Moderado
```

Nota. En esta figura se puede apreciar los resultados de los últimos frames del video, el promedio de desempeño y el desempeño general del ejercicio.

4.3.2.7.3. Validación en Entorno Real

Se verificó la viabilidad técnica del modelo para operar en cualquier equipamiento disponible en instituciones educativas. Las pruebas, realizadas mediante la ejecución de los scripts de evaluación en computadoras portátiles estándar (procesador i5 con 8GB de RAM), demostraron que la combinación de Random Forest y PCA permite procesar los videos de manera fluida y con baja latencia. Este resultado confirma que la solución propuesta es computacionalmente ligera, ya que no requiere hardware de aceleración gráfica (GPU) dedicado. Esto valida la idoneidad del modelo para ser implementado en futuros desarrollos de software educativo sin exigir inversiones costosas en infraestructura tecnológica por parte de las escuelas de Cáritas Arequipa.





CAPÍTULO V

ANÁLISIS Y VALIDACIÓN DE RESULTADOS

En el presente capítulo, se procede con el análisis y validación de los resultados obtenidos del modelo desarrollado para el monitoreo de actividad motora gruesa en niños con Síndrome de Down. Primero, se realiza la exposición de los métodos de validación empleados para evaluar la precisión del modelo por medio de los indicadores descritos en la tabla 1.3. Luego, se muestran los resultados en el desempeño físico de los niños antes y después del uso del modelo. Finalmente, se realiza la discusión sobre los principales hallazgos en esta investigación, las fortalezas y limitaciones identificadas, la discusión con el Estado del Arte, el análisis de costos del proyecto y los trabajos futuros.

5.1. Resultados

5.1.1. Resultados en Visión Computacional

Tal como se detalla en el capítulo 4.1, se evaluaron 4 ejercicios realizados por 23 niños con Síndrome de Down pertenecientes a 8 escuelas para niños con habilidades diferentes afiliadas a Cáritas Arequipa, en un rango de edades entre 4 a 10 años. El modelo BlazePose de MediaPipe demostró una capacidad robusta para la extracción y seguimiento de los keypoints anatómicos durante la ejecución de los 4 ejercicios mencionados en el Capítulo 4.1. En cuanto a los resultados obtenidos por los modelos de cada ejercicio respectivamente, y teniendo en cuenta las métricas clave (Precisión, Sensibilidad, F1-Score, Soporte y Exactitud), se pudo interpretar lo siguiente:

5.1.1.1. Sentarse y pararse de una silla

En este ejercicio, el modelo (sit_model) mostró ser altamente eficaz para identificar niños con un desempeño bajo en el ejercicio Sentarse y pararse de una silla, los cuales son precisamente quienes más requieren una intervención prioritaria por parte de sus docentes. Además, este

ejercicio presentó la exactitud promedio más baja de esta investigación (90.37%) comparado con Gatear (97.23%), Lanzamiento de pelota (95.1%) y Salto en 2 pies (95.3%); esto se debe a que existe una mayor complejidad, pues los niños realizan el ejercicio de diversas formas, tales como el impulso con sus manos, rotación lateral, inclinación de la columna, entre otros.

5.1.1.1.1. Resultados Promedio Obtenidos en Exactitud

Tabla 5.1

Exactitud del modelo en Sentarse y pararse de una silla

Métrica	Valor
Exactitud (Accuracy)	90.37%

5.1.1.1.2. Métricas por Clase

Tabla 5.2

Resultados de las métricas por clase en Sentarse y pararse de una silla

Clase	Precisión	Sensibilidad	F1-Score	Soporte
1 (Alto)	0.96 (96%)	0.94 (94%)	0.95 (95%)	250
2 (Moderado)	0.85 (85%)	0.90 (90%)	0.87 (87%)	269
3 (Bajo)	0.90 (90%)	0.88 (88%)	0.89 (89%)	248

5.1.1.1.3. Promedios Globales

- **Macro avg:** Precisión 0.91 (91%), Recall 0.90 (90%), F1-Score 0.90 (90%)
- **Weighted avg:** Precisión 0.90 (90%), Recall 0.90 (90%), F1-Score 0.90 (90%)
- **Soporte total:** 767 frames

5.1.1.1.4. Interpretación de Resultados en las Métricas

- **Precisión (Precision):**

- **Clase 1 - Alto (96%):** Esta es la clase con la precisión más alta del ejercicio y es comparable con las mejores métricas del ejercicio Gatear; en adición, de cada 100 predicciones en Alto, 96 son correctas; además, solo 4% resultaron ser falsos positivos, es decir niños con rendimiento Moderado o Bajo que fueron clasificados de manera errónea como Alto. Pese a la complejidad del ejercicio, los casos con desempeño alto presentaron al menos una alineación del tronco casi perfecta verticalmente con una ligera desviación, una aceleración de descenso controlada y transición fluida sin pausas o varios intentos.
- **Clase 2 - Moderado (85%):** Esta es la precisión más baja de toda la investigación, pues de un total de 100 predicciones solamente 85 son correctas; además, 15% resultaron ser falsos positivos, los cuales se dividen entre los casos de rendimiento Alto que tuvieron una inclinación de tronco puntual, y los casos de rendimiento Bajo que lograron un descenso controlado pero con mala postura. Esta precisión se debe a que un caso puede tener una buena alineación de columna pero un descenso rápido (moderado o bajo), mientras que otro caso puede tener una alineación imperfecta pero un control muscular adecuado (moderado o alto); pues, el modelo combina ambas variables, pero cuando están separadas resulta ser difuso, entonces Random Forest puede calificar Moderado cuando hay esa incertidumbre.

- **Clase 3 - Bajo (90%):** Esta clase logró una precisión intermedia, pues de cada 100 predicciones en Bajo, 90 son correctas; en adición, solo el 10% resultaron ser falsos positivos, es decir casos de nivel Moderado o Alto clasificados como Bajo; finalmente, esta precisión no es más alta debido a que se mostró un desempeño variable, pues esto se dio en 2 casos, el primer caso donde puede sentarse en la silla con una inclinación excesiva, la cual muestra que claramente es un desempeño bajo, y el otro caso donde hay un descenso más controlado y una inclinación moderada, entonces es por ese motivo que el modelo clasificó el segundo caso como Bajo en base a los patrones con los cuales fue entrenado, cuando realmente es Moderado o Bajo.

La precisión en las clases 1 y 3 resultó ser alta; sin embargo, en la clase 2, es decir los casos clasificados como Moderado, se logró una precisión baja por lo que se recomienda que para estos casos se realice una evaluación manual por parte del docente para validar estos resultados.

- **Sensibilidad (Recall):**

- **Clase 1 - Alto (94%):** De 250 frames realmente Altos en total, el modelo logró detectar 235 de manera correcta; en adición, solo 15 frames no fueron detectados como Alto cuando realmente lo eran, esto ocurrió porque en fotogramas críticos, la cadera quedó parcialmente oculta, lo que provocó un salto en el cálculo de la aceleración lo cual el modelo interpretó como un descenso descontrolado.
- **Clase 2 - Moderado (90%):** De 269 frames realmente Moderados, el modelo pudo detectar 242 de forma correcta; en adición, solo 27 frames de nivel Moderado no fueron detectados, esto indica que el modelo resultó ser

conservador, pues prefirió clasificar los casos ambiguos como Moderados en vez de clasificarlos como Altos o Bajos cuando en realidad no lo eran.

- **Clase 3 - Bajo (88%):** Esta es la sensibilidad más baja del ejercicio, pues de los 248 frames realmente Bajos, se detectaron 218 de manera correcta; en adición, solo 30 frames no fueron clasificados como Bajo cuando realmente lo eran, esto indicó que aproximadamente el 12% de los niños con rendimiento Bajo no fueron detectados como tal.

La sensibilidad del 88% en la clase Bajo, sugirió que el modelo ha requerido ciertos ajustes de umbrales, pues se debió reducir el umbral de aceleración segura para así capturar más casos de descenso rápido; además, se debió incrementar la penalización por desviación del vector de tronco, y también considerar características adicionales como el número de intentos para pararse o el uso de las manos.

- **F1-Score:**

- **Clase 1 - Alto (95%):** En esta clase se pudo apreciar un excelente balance entre la precisión (96%) y la sensibilidad (94%); en adición, este es el F1-Score más alto del ejercicio, lo cual confirma que el modelo es altamente confiable para poder identificar niveles de alto desempeño más que los otros 2 niveles; finalmente, no hay un sesgo significativo, pues la diferencia entre la precisión y sensibilidad es apenas de un 2%.
- **Clase 2 - Moderado (87%):** En esta clase se presentó el F1-Score más bajo del ejercicio, pues hay un desbalance entre la precisión (85%) y la sensibilidad (90%), lo cual generó un F1-Score menor que en la clase Alto; en adición, ello

refleja que esta clase predice de más el nivel Moderado, ya que posee una alta sensibilidad pero baja precisión.

- **Clase 3 - Bajo (89%):** Esta clase posee un F1-Score intermedio, pues hay un balance entre una precisión aceptable (90%) y una sensibilidad mejorable (88%); sin embargo, hay un margen de mejora para poder incrementar la detección de casos con nivel Bajo sin comprometer la precisión.

La métrica de F1-Score en este ejercicio presenta mucha variabilidad, ya que se pudo apreciar una brecha de 8% entre Alto y Moderado (clase 1 y clase 2), lo cual confirma que el ejercicio de Sentarse y Pararse de una Silla presentó una dificultad asimétrica, pues el modelo resultó ser más efectivo al detectar un gran desempeño, que uno medio o bajo.

- **Soporte (Support):**

- Clase 1 - Alto: 250 frames (32.6%)
- Clase 2 - Moderado: 269 frames (35.1%)
- Clase 3 - Bajo: 248 frames (32.3%)
- **Total: 767 frames de soporte**

Tal como se puede apreciar, el dataset de soporte está muy bien balanceado con una diferencia de solamente 21 frames (2.7%); además, este balance casi perfecto es estadísticamente favorable porque garantiza que Random Forest tuvo la oportunidad de aprender los patrones biomecánicos de cada nivel de desempeño, lo cual evitó sesgos que pudieran favorecer la predicción de alguna de las 3 clases, es por ello que las métricas de Precisión, Sensibilidad y F1-Score son directamente comparables entre clases sin la necesidad de ser ponderadas.

- **Exactitud (Accuracy):**

En base a la matriz mostrada en la figura 4.17, se puede apreciar que para el ejercicio Sentarse y Pararse de una Silla, el Modelo es muy eficiente identificando el bajo rendimiento ($235/250 = 94\%$ de exactitud); por otra parte, cuenta con un buen desempeño para el rendimiento moderado ($241/269 = 89.6\%$ de exactitud). Además, tiene un poco de dificultad para poder distinguir entre el rendimiento moderado o bajo con el alto ($217/248 = 87.5\%$ de exactitud). Como se puede observar, hay un patrón descendente en la exactitud, lo cual muestra que el modelo tiene mayor dificultad para distinguir entre las categorías inferiores de rendimiento, lo cual se explica por la convergencia de patrones biomecánicos en niños con mejor desempeño. Además, este ejercicio presenta la exactitud más baja de esta investigación, lo cual fue debido a que el modelo mide 2 variables complejas en este ejercicio; la primera es el control de la postura, es decir la alineación del tronco, en la cual se trazó un vector entre hombros (landmarks 11/12) y caderas (landmarks 23/24), y se midió la desviación del vector respecto a la vertical, pues una desviación significativa indicó una mala postura y como resultado se le penalizó en la clasificación; la segunda es la fuerza excéntrica, es decir el control del descenso al sentarse, en la cual se calculó la aceleración de bajada de la cadera, pues una aceleración excesiva al momento de sentarse indicó una falta de control muscular, por lo tanto se le asignó un bajo desempeño.

5.1.1.1.5. Análisis Integral

En este ejercicio, tal como se puede apreciar, Random Forest alcanzó una exactitud del 90.37%, la cual resultó ser la más baja de esta investigación, pues existieron desafíos por parte del modelo en cuanto al control de la postura y la fuerza excéntrica; los cuales incluyen una alineación del tronco y control del descenso independientes, es decir una buena postura pero un descenso rápido o bien una mala postura pero un descenso más controlado; además, cuando el ángulo de la

rodilla fue aproximadamente de 90° y las caderas quedaron parcialmente o totalmente ocultas, se redujo la detección de los landmarks 23/24; en adición, el descenso rápido provocó un desenfoque que degradó el seguimiento frame a frame; finalmente, cuando se usaron estrategias diversas como impulsarse con las manos, rotación lateral o varios intentos al pararse, los cuales el modelo debe clasificar en los 3 niveles. Sin embargo, el modelo mostró ser excelente al identificar casos de alto desempeño con una Precisión del 96%, Sensibilidad del 94%, F1-Score del 95% en la clase Alto, además de contar con un dataset balanceado.

5.1.1.2. Lanzamiento de pelota

En este ejercicio, el modelo (`throw_model`) mostró ser muy eficiente para identificar que niños requieren una intervención por parte de sus docentes, y altamente eficaz en reconocer que niños cuentan con un mejor desarrollo motor grueso. Además, Lanzamiento de pelota posee la segunda mejor exactitud en promedio (95.1%) después del ejercicio Gatear (97.23%), pues ambos comparten ciertas características que los favorecen en la clasificación, como movimientos con secuencias temporales definidas y métricas angulares robustas (tanto el ángulo del codo como los ángulos cruzados brazo-pierna son descriptores geométricos invariantes que Mediapipe logra capturar con alta precisión).

5.1.1.2.1. Resultados Promedio Obtenidos en Exactitud

Tabla 5.3

Exactitud del modelo en Lanzamiento de Pelota

Métrica	Valor
Exactitud (Accuracy)	95.1%

5.1.1.2.2. Métricas por Clase

Tabla 5.4

Resultados de las métricas por clase en Lanzamiento de Pelota

Clase	Precisión	Sensibilidad	F1-Score	Soporte
1 (Alto)	0.95 (95%)	0.97 (97%)	0.96 (96%)	2351
2 (Moderado)	0.95 (95%)	0.92 (92%)	0.94 (94%)	2434
3 (Bajo)	0.95 (95%)	0.96 (96%)	0.96 (96%)	2321

5.1.1.2.3. Promedios Globales

- **Macro avg:** Precisión 0.95 (95%), Recall 0.95 (95%), F1-Score 0.95 (95%)
- **Weighted avg:** Precisión 0.95 (95%), Recall 0.95 (95%), F1-Score 0.95 (95%)
- **Soporte total:** 7106 frames

5.1.1.2.4. Interpretación de Resultados en las Métricas

- **Precisión (Precision):**
 - **Clase 1 - Alto (95%):** En esta clase, de cada 100 predicciones Altas, 95 fueron correctas; en adición, solo 5 de estas 100 resultaron ser falsos positivos, es decir casos de rendimiento Moderado o Bajo clasificados como Alto; además, la alta precisión en esta clase se debió a que el modelo generó un espacio de características con separación simétrica, pues los casos que fueron clasificados como Alto realizaron una secuencia correcta de tronco, hombro, codo y muñeca, esto agregado a velocidades angulares altas.
 - **Clase 2 - Moderado (95%):** En esta clase, al igual que en la clase Alto, de cada 100 predicciones Moderadas, 95 resultaron ser correctas; en adición, solo 5 de estas fueron falsos positivos, es decir confusiones al clasificar casos que

realmente eran Altos o Bajos pero que se les clasificó como Moderado; además, la precisión en esta clase se vio asociada con una secuencia correcta pero también con velocidades reducidas, o secuencias con ligeras alteraciones.

- **Clase 3 - Bajo (95%):** En esta clase, de igual manera que en las clases Alto y Moderado, de cada 100 predicciones Bajas, 95 fueron correctas; en adición, solamente 5 de estas resultaron ser falsos positivos, es decir casos de rendimiento Moderado o Alto clasificados como Bajo; además, la precisión de esta clase tuvo relación con una secuencia alterada, es decir la muñeca se mueve antes que el hombro, lo cual es incorrecto, pues primero se debe acelerar el hombro, luego el codo y finalmente la muñeca.

Tal como se puede apreciar, en este ejercicio las 3 clases alcanzaron la misma Precisión (95%), lo cual quiere decir que alcanzó una simetría perfecta que confirma que el modelo resultó ser más robusto al detectar la cadena cinética (tronco, hombro, codo, muñeca) de este ejercicio, a comparación del control de postura y la fuerza excéntrica (ejercicio Sentarse y pararse de una silla); además, la precisión alcanzada por las 3 clases mostró que el modelo prácticamente no tiene ningún sesgo, pues no sobreestima el desempeño en casi ningún caso, ni lo subestima; finalmente, esto muestra que un docente puede confiar en el modelo cuando ese muestre como resultado cualquiera de los 3 niveles de desempeño (alto, moderado o bajo) de manera igual, pues los 3 tienen prácticamente la misma probabilidad de ser correctos.

- **Sensibilidad (Recall):**

- **Clase 1 - Alto (97%):** Esta clase presentó la sensibilidad más alta del ejercicio, pues de los 2351 frames de nivel Alto realmente, se detectó 2280 de manera correcta; en adición, solamente 71 frames de nivel Alto no fueron detectados

como Alto. Se presentó este alto porcentaje de Sensibilidad en esta clase debido a que existió una secuencia temporal adecuada, es decir los fotogramas muestran un orden correcto en casi todos los casos, velocidades angulares en el percentil 80-100 y una rotación visible del tronco antes del movimiento del brazo; estas características son muy distintivas, es por ello que Random Forest rara vez confunde un lanzamiento de nivel alto con las otras 2 clases.

- **Clase 2 - Moderado (92%):** Esta clase logró la sensibilidad más baja del ejercicio, pues de los 2434 frames de nivel Moderado realmente, se logró detectar 2239 correctamente; en adición, solo 195 frames que realmente eran Moderado, fueron clasificados de manera errónea, los cuales se dividieron entre los casos clasificados como Alto y los casos clasificados como Bajo; esto se dio porque cuando un caso realizó una secuencia correcta no presentó velocidad intermedia, o bien si presentó una velocidad adecuada, pero una secuencia con algunas alteraciones, o también otro caso pudo realizar ambos correctamente pero presentó una extensión incompleta del codo.
- **Clase - Bajo (96%):** Esta clase logró una sensibilidad intermedia respecto a las clases 1 y 2, pues de los 2321 frames realmente de nivel Bajo, se detectaron 2228 de manera correcta; en adición, solamente 93 frames no fueron detectados como Bajo; finalmente, la sensibilidad es alta en esta clase debido a que los lanzamientos de un nivel Bajo presentaron una cadena cinética incorrecta, tales como una secuencia invertida donde la muñeca se mueve antes que el codo o el hombro, o bien donde hubo una ausencia de rotación del tronco, o también cuando hubo un movimiento lento y simultáneo de todas las articulaciones.

Como se puede apreciar, en este ejercicio las características biomecánicas son fácilmente detectables por el modelo, es por ello que presentaron una alta sensibilidad en los niveles Alto y Bajo.

- **F1-Score:**

- **Clase 1 - Alto (96%):** Esta clase presentó un equilibrio excelente entre la Precisión (95%) y la Sensibilidad (97%); en adición, logró el mismo F1-Score que la clase Bajo; finalmente, presenta un sesgo ligero en cuanto a la Alta sensibilidad, pues detecta más casos de nivel Alto de los que logra predecir.
- **Clase 2 - Moderado (94%):** Esta clase presentó el F1-Score más bajo del ejercicio; sin embargo, este también fue alto al igual que en las clases 1 y 3; en adición, refleja un ligero desbalance entre la Precisión (95%) y Sensibilidad (92%); además, esto indica que hay un buen margen de mejora en la detección de casos Moderados sin comprometer la Precisión.
- **Clase 3 - Bajo (96%):** Esta clase presentó un F1-Score idéntico al de la clase 1; en adición, presenta un balance muy bueno entre la Precisión (95%) y la Sensibilidad (96%); finalmente, esto confirma que el modelo es altamente efectivo tanto al identificar casos de rendimiento Alto, como casos de nivel Bajo que presentan dificultades en su rendimiento físico.

Tal como se puede apreciar, los valores entre el 94% y 96% en esta métrica resultaron ser muy consistentes, pues la brecha de solo 2 puntos porcentuales entre Alto y Bajo con Moderado fue mucho menor que en el ejercicio de Sentarse y Pararse de una Silla (brecha de 8 puntos), lo cual confirma que en este ejercicio donde se empleó la cadena cinética (tronco, hombro, codo, muñeca) el modelo logró clasificaciones más equilibradas y confiables para las 3 clases.

- **Soporte (Support):**
 - Clase 1 - Alto: 2351 frames (33.1%)
 - Clase 2 - Moderado: 2434 frames (34.3%)
 - Clase 3 - Bajo: 2321 frames (32.7%)
 - **Total: 7106 frames de soporte**

En esta métrica, tal como se puede apreciar, en este ejercicio se contó con un dataset muy bien balanceado con una diferencia mínima de solo 113 frames; además, en comparación con otros ejercicios presentó el mejor balance con la mínima diferencia porcentual de frames con los que contó cada clase; en adición, presentó una gran confiabilidad estadística con entre 2300 y 2400 frames por clase; finalmente, si este modelo se aplicara en una nueva muestra de niños realizando este ejercicio, se lograría un resultado en la exactitud muy similar (95.1%).

- **Exactitud (Accuracy):**

En base a la matriz mostrada en la figura 4.19, se puede apreciar que para el ejercicio Lanzamiento de Pelota, el Modelo es bastante eficiente identificando el bajo rendimiento ($2276/2351 = 96.8\%$ de exactitud); por otra parte, cuenta con un buen desempeño para el rendimiento moderado ($2244/2434 = 92.2\%$ de exactitud); además, es muy eficiente para poder distinguir entre el rendimiento moderado o bajo con el alto ($2234/2321 = 96.3\%$ de exactitud). Esta exactitud mostró que de 7106 frames, Random Forest logró clasificar 6797 frames de manera correcta, pero falló en 309; en adición, en este ejercicio se logró una exactitud muy alta debido a que el modelo logró capturar la cadena cinética (tronco, hombro, codo, muñeca) de forma correcta, la cual incluye el rastreo de hombros (landmarks 11/12), codos (landmarks 13/14) y muñecas (15/16), además calcula la velocidad angular de cada articulación involucrada en el ejercicio frame a frame, en adición valida que los picos de aceleración ocurran en el orden biomecánico correcto:

primero, la rotación del tronco; segundo, la aceleración del hombro; tercero, la extensión del codo; y cuarto, la proyección de la muñeca. Como se puede observar, al igual que en el ejercicio de Salto, los niveles bajo y alto son los más sencillos de clasificar por parte del modelo, en comparación con el nivel moderado.

5.1.1.2.5. Análisis Integral

Random Forest Classifier logró un 95.1% de exactitud promedio entre las 3 clases (alto, moderado, bajo), esto fue posible gracias a: primero, la transferencia eficiente de fuerza en el lanzamiento, la cual requirió una secuencia proximal distal en la cadena cinética abierta (tronco, hombro, codo, muñeca), pues este principio es universal y no depende las características individuales; segundo, contó con variables objetivas y cuantificables, las cuales son la velocidad angular medible frame a frame por medio de la derivada de ángulos articulares, el orden temporal de picos el cual se pudo verificar mediante la detección de máximos locales en curvas de aceleración y no hay una ambigüedad interpretativa, pues o la secuencia es correcta o no lo es; tercero, el modelo resultó ser robusto a oclusión parcial, incluso si la muñeca se oculta por momentos la secuencia hombro - codo puede verificarse, pues el algoritmo no falla del todo ante la pérdida de un landmark; cuarto, no presenta variación en cuanto a la fuerza absoluta, pues un niño que realizó un lanzamiento con poca fuerza pero con secuencia correcta pudo lograr clasificarse como Alto, debido a su técnica correcta, esto evita el sesgo contra niños que presenten menor fuerza.

5.1.1.3. Gatear

En este ejercicio, el modelo (crawl_model) resultó ser altamente confiable, pues con el 97.23% de exactitud promedio, este ejercicio puede usarse como evaluación primaria en diversos programas de evaluación para niños con discapacidades, pues la probabilidad de falsos positivos o negativos es mínima.

5.1.1.3.1. Resultados Promedio Obtenidos en Exactitud

Tabla 5.5

Exactitud del modelo en Gatear

Métrica	Valor
Exactitud (Accuracy)	97.23%

5.1.1.3.2. Métricas por Clase

Tabla 5.6

Resultados de las métricas por clase en Gatear

Clase	Precisión	Sensibilidad	F1-Score	Soporte
1 (Alto)	0.98 (98%)	0.98 (98%)	0.98 (98%)	1114
2 (Moderado)	0.96 (96%)	0.96 (96%)	0.96 (96%)	1187
3 (Bajo)	0.98 (98%)	0.97 (97%)	0.98 (98%)	1157

5.1.1.3.3. Promedios Globales

- **Macro avg:** Precisión 0.97 (97%), Recall 0.97 (97%), F1-Score 0.97 (97%)
- **Weighted avg:** Precisión 0.97 (97%), Recall 0.97 (97%), F1-Score 0.97 (97%)
- **Soporte total:** 3458 frames

5.1.1.3.4. Interpretación de Resultados en las Métricas

- **Precisión (Precision):**

- **Clase 1 - Alto (98%):** De cada 100 predicciones en Alto, 98 son correctas; además, solo el 2% resultaron ser falsos positivos, lo cual proviene de niños que lograron un patrón cruzado casi perfecto, pero que ocasionalmente pierden la sincronía por 1-2 ciclos. El algoritmo, al promediar sobre toda la secuencia, puede clasificarlos como "Alto" cuando en realidad son "Moderado-superior"; finalmente, de los 1114 frames reales de clase Alto, el modelo predijo correctamente un aproximado de 1092 como Alto.
- **Clase 2 - Moderado (96%):** De cada 100 predicciones en Moderado, 96 son correctas; además, el 4% fueron falsos positivos debido a las confusiones en Alto o Bajo, pues en Alto los niños lograron una excelente estabilidad (caderas estables) pero un patrón cruzado imperfecto, y en bajo los niños consiguen un patrón cruzado ocasional pero poca estabilidad; en adición, de los 1187 frames reales de clase Moderado, aproximadamente 1140 fueron clasificados correctamente; finalmente, esta es la precisión más baja de las tres clases, reflejando que la clase Moderado recibe confusiones bidireccionales.
- **Clase 3 - Bajo (98%):** De cada 100 predicciones en Bajo, 98 son correctas; además, solo el 2% son falsos positivos, los cuales ocurrieron cuando un niño "Moderado-inferior" tiene un día particularmente malo y ejecuta con desempeño atípicamente bajo; finalmente, la precisión resultó ser igual a la de la clase Alto (98%), lo cual indicó que los extremos (alto y moderado) son más fáciles de identificar que el rango medio (moderado).

La alta precisión en los niveles Alto y Bajo (98%) evita sobreestimaciones o subestimaciones severas del desempeño del niño; en contraste, la precisión de 96% en el nivel moderado sigue siendo excelente y además refleja la naturaleza de ser la clase intermedia.

- **Sensibilidad (Recall):**

- **Clase 1 - Alto (98%):** De los 1114 frames que fueron realmente Alto, el modelo detectó 1092 de manera correcta; además, solamente 22 frames que eran de nivel Alto no fueron detectados; finalmente, no hubo confusiones entre los niveles Alto y Bajo, lo cual indicó que el modelo logro distinguir con alta eficiencia los extremos.
- **Clase 2 - Moderado (96%):** De los 1187 frames que realmente eran Moderado, el modelo pudo detectar 1140 de manera correcta; además, un aproximado de 47 frames fueron confundidos con Alto o Bajo; finalmente, esta clase muestra la misma sensibilidad que la Precisión (96%), lo cual indicó un balance adecuado.
- **Clase 3 - Bajo (97%):** De los 1157 frames realmente de nivel Bajo, el modelo logró detectar 1122 de forma correcta; además, solamente 35 frames de un nivel realmente Bajo no fueron detectados; finalmente, la sensibilidad resultó ser ligeramente inferior a la precisión, lo que indicó que hay más falsos negativos que falsos positivos en esta clase.

La sensibilidad resultó ser muy importante, pues la alta sensibilidad en la clase Bajo (97%) garantiza que de cada 100 niños, 97 sean detectados de manera correcta, minimizando así un riesgo de subestimar su nivel de desempeño.

- **F1-Score:**

- **Clase 1 - Alto (98%):** En esta clase se puede apreciar que existió un balance adecuado entre la Precisión (98%) y la Sensibilidad (98%), pues el algoritmo de patrón cruzado y estabilidad indica claramente un alto desempeño y por lo tanto, RandomForest no necesita decidir entre minimizar falsos positivos contra falsos negativos: ambos son mínimos naturalmente; además, esto indicó que el modelo es tan efectivo para evitar falsos positivos como para detectar verdaderos positivos.
- **Clase 2 - Moderado (96%):** Al igual que en la clase 1, esta clase presentó un balance adecuado, pues tanto Precisión, Sensibilidad y F1-Score cuentan con un 96%; además, aunque es el F1-Score más bajo de este ejercicio, sigue siendo muy efectivo; finalmente, con ello se pudo apreciar que no hay sesgo hacia la sobreestimación ni subestimación del desempeño físico del niño.
- **Clase 3 - Bajo (98%):** Esta clase presenta un F1-Score similar al de la clase Alto; sin embargo, existió una ligera diferencia entre la Precisión (98%) y Sensibilidad (97%), esto no afecta de manera significativa al F1-Score, y además la ausencia del patrón cruzado es un indicador que compensa la variabilidad en estabilidad; finalmente. Esto confirmó que el modelo es robusto para poder identificar casos de desempeño Bajo.

Los valores entre el 96% y 98% son muy altos, lo cual indicó que Random Forest no presenta gran cantidad de sesgos sistemáticos en ninguna clase.

- **Soporte (Support):**

- Clase 1 - Alto: 1114 frames (32.2%)
- Clase 2 - Moderado: 1187 frames (34.3%)
- Clase 3 - Bajo: 1157 frames (33.5%)
- **Total: 3458 frames de soporte**

El balance adecuado fue posible gracias a que se contó con un algoritmo objetivo de clasificación, pues a diferencia de clasificación manual subjetiva, el algoritmo de patrón cruzado y estabilidad generó umbrales cuantitativos que distribuyen los casos de forma más equitativa. Además, no hubo sesgo de aprendizaje, pues Random Forest tuvo entre 1100 a 1200 frames de ejemplo de cada patrón (cruzado perfecto, intermitente, ausente), lo cual le permitió aprender los 3 niveles de desempeño casi con igual profundidad; en adición, ya que se contó con más de 1100 frames de soporte por clase, los intervalos de confianza fueron muy estrechos, lo cual indicó que si se aplica el modelo en una nueva muestra de niños, se lograrían resultados muy parecidos.

- **Exactitud (Accuracy):**

En base a la matriz mostrada en la figura 4.21, se puede apreciar que para el ejercicio Gatear, el Modelo es muy eficiente identificando el bajo rendimiento ($1093/1114 = 98.1\%$ de exactitud); por otra parte, cuenta con un excelente desempeño para el rendimiento moderado ($1142/1187 = 96.2\%$ de exactitud). Además, es muy eficiente para poder distinguir entre el rendimiento moderado o bajo con el alto ($1127/1157 = 97.4\%$ de exactitud). Tal como se puede observar, este es el ejercicio que presenta la mayor exactitud promedio de los 4 (97.23% de exactitud), lo cual indica que de 3458 frames totales en este ejercicio, Random Forest Classifier logró clasificar 3386 frames de manera correcta, pero falló en 72; esto significa que por cada evaluación de 100 niños el modelo acertará en 98 clasificaciones, y en cada 2 de 100 se requerirá

una revisión manual. En adición, el modelo (crawl_model) logró un alto porcentaje de Exactitud debido a que captura dos características biomecánicas críticas que son altamente discriminativas; la primera es el Patrón Cruzado (sincronía de extremidades opuestas), pues el modelo monitorea específicamente muñecas (Landmarks 15/16) vs rodillas contrarias (Landmarks 26/25) y verifica que cuando la mano derecha avanza, la rodilla izquierda lo haga simultáneamente y viceversa; la segunda es la Estabilidad del Centro de Gravedad (oscilación vertical de caderas), pues el modelo analiza Caderas (Landmarks 23/24) frame a frame y una menor variación en el eje Y (altura), la cual indica una mayor estabilidad y por lo tanto, una mayor puntuación. Esta es la exactitud más alta entre todos los ejercicios evaluados en esta investigación, lo cual confirma que Gatear es el ejercicio más sencillo de clasificar automáticamente.

5.1.1.3.5. Análisis Integral

Tal como se puede apreciar, el dataset de frames de soporte está correctamente balanceado, con diferencias mínimas entre clases (73 frames - 2.1% del total). En cuanto a las implicaciones del balance, las métricas son directamente comparables entre las clases sin la necesidad de una ponderación; además, no hay sesgo de muestreo favoreciendo significativamente a ninguna de las 3 clases. El modelo contó con oportunidades equivalentes para poder aprender patrones de cada nivel de desempeño. En adición, al contar con soporte de 1100 a 1200 frames por clase, las métricas cuentan con una alta confiabilidad estadística, pues los intervalos de confianza resultaron muy estrechos (más o menos 1-2%), lo cual mostró que estos resultados pueden ser generalizados a nuevos datos. Los factores que explican el gran desempeño del modelo (crawl_model) en el ejercicio Gatear son los siguientes; primero, dicho modelo cuenta con un patrón motor cíclico y predecible, pues este ejercicio alterna las extremidades de manera regular, generando así características temporales consistentes que RandomForest puede capturar mediante variables de

secuencia; segundo, el modelo BlazePose de Mediapipe logra detectar rodillas, codos, caderas y muñecas sin oclusión significativa durante todo el ciclo de Gatear; finalmente, este modelo es robusto a variaciones individuales, pues al analizar secuencias completas frame a frame y promediarlas, el algoritmo tolera fluctuaciones momentáneas, por ejemplo un solo ciclo descoordinado en medio de 10 coordenados no penaliza excesivamente.

5.1.1.4. Saltos en dos pies

En este ejercicio, la alta exactitud promedio (95.3%) lograda por modelo (jump_model) logra validar que la altura de los tobillos es un descriptor robusto para este ejercicio en específico, pues a diferencia de otras métricas más complejas (ángulos de rodilla, velocidad de salto, etc), esta característica simple captura de manera eficaz el rendimiento de los niños en saltos verticales en 2 pies.

5.1.1.4.1. Resultados Promedio Obtenidos en Exactitud

Tabla 5.7

Exactitud del modelo en Saltos en 2 Pies

Métrica	Valor
Exactitud (Accuracy)	95.3%

5.1.1.4.2. Métricas por Clase

Tabla 5.8

Resultados de las métricas por clase en Saltos en 2 Pies

Clase	Precisión	Sensibilidad	F1-Score	Soporte
1 (Alto)	0.97 (97%)	0.97 (97%)	0.97 (97%)	549
2 (Moderado)	0.94 (94%)	0.92 (92%)	0.93 (93%)	611
3 (Bajo)	0.95 (95%)	0.97 (97%)	0.96 (96%)	576

5.1.1.4.3. Promedios Globales

- **Macro avg:** Precisión 0.95 (95%), Recall 0.95 (95%), F1-Score 0.95 (95%)
- **Weighted avg:** Precisión 0.95 (95%), Recall 0.95 (95%), F1-Score 0.95 (95%)
- **Soporte total:** 1736 frames

5.1.1.4.4. Interpretación de Resultados en las Métricas

- **Precisión (Precision):**
 - **Clase 1 - Alto (97%):** Esta clase presentó la precisión más alta del ejercicio, pues de cada 100 predicciones en total clasificadas como Alto, 97 son correctas; en adición, solo 3% resultaron ser falsos positivos, es decir casos de nivel Moderado o Bajo clasificados como Alto; además, la precisión resultó ser alta en la clase 1 debido a que los niños en el tercil superior de elevación tienen ciertas características inequívocas, tales como una altura de vuelo claramente superior al umbral, una separación entre el tercil superior y el medio resultó importante para minimizar las confusiones, y un despliegue en el que ambos tobillos alcanzan una altura similar en el mismo frame.
 - **Clase 2 - Moderado (94%):** Esta clase mostró una precisión intermedia, pues de cada 100 predicciones clasificadas como Moderado, 94 son correctas; en adición, el 6% fueron falsos positivos, es decir confusiones bidireccionales con las clases Alto y Bajo; además, la precisión en esta clase resultó ser la más baja del ejercicio debido a que esta clase recibe confusiones con ambos extremos Alto y Bajo, pues con Alto correspondió a los casos que tuvieron un salto bajo para su capacidad, y con Bajo correspondió a los casos que tuvieron un salto muy bueno para su nivel real.

- **Clase 3 - Bajo (95%):** Esta clase presentó una precisión ligeramente superior a la clase Moderado, pues de cada 100 predicciones, 95 fueron hechas correctamente; en adición, el 5% resultaron ser falsos positivos, es decir casos que presentaron realmente un nivel Moderado o Alto y fueron clasificados como Bajo; además, la precisión en esta clase 3, de igual manera que en la clase 1, resultó ser alta debido a que el tercil inferior tuvo una clara separación del medio, e incluso casos con altura de salto mínima resultaron ser fácilmente identificables.

Tal como se puede apreciar, la precisión en este ejercicio resultó ser más alta en los extremos (alto y bajo) que en el medio (moderado); esto resultó ser propio de una clasificación basada en una variable continua cuantitativa (altura), pues los extremos son naturalmente más sencillos de distinguir que el medio. Además, a comparación del Lanzamiento de pelota que mostró una precisión idéntica en las 3 clases porque usa múltiples variables, este ejercicio solamente usa la altura, generando así un patrón de extremos más precisos.

- **Sensibilidad (Recall):**

- **Clase 1 - Alto (97%):** Esta clase presentó la sensibilidad más alta del ejercicio junto con la clase Bajo, igualando la precisión, pues de los 549 frames, se logró detectar 532 de manera correcta; en adición, solo 17 frames que realmente fueron de nivel Alto no se detectaron; además, el modelo presentó un balance muy bueno, pues logró la misma precisión y sensibilidad, lo cual indica que el modelo no cuenta con sesgo para la clase Alto, ya que no predice de más ni de menos.

- **Clase 2 - Moderado (92%):** Esta clase mostró la sensibilidad más baja del ejercicio, pues de los 611 frames que realmente fueron de nivel Moderado, se detectaron 562 de manera correcta; en adición, solamente 49 frames fueron clasificados erróneamente, los cuales se dividieron entre casos Moderados clasificados como Alto y otros clasificados como Bajo. En esta clase existió una mayor precisión que sensibilidad, lo cual indicó que el modelo predijo de menos el nivel Moderado, pues no detectó el 8% de casos que realmente fueron Moderado, pero cuando predijo Moderado acertó en el 92% de esos casos.
- **Clase 3 - Bajo (97%):** Esta clase presentó la sensibilidad más alta del ejercicio igualando a la mostrada por la clase Alto, pues de 576 frames se logró detectar 559 de manera correcta; en adición, solamente 17 frames no fueron detectados como Bajo; además, la sensibilidad es alta en esta clase debido a que los casos en el tercil inferior de salto presentan una altura de salto mínima o inexistente, o bien solo levantan las puntas de los pies, es así que MediaPipe detecta que los tobillos (landmarks 27/28) apenas cambian su coordenada Y.

Tal como se puede apreciar, la sensibilidad en este ejercicio resultó ser muy alta en los extremos Alto y Bajo; además, el modelo mostró ser más eficiente al detectar el bajo desempeño en este ejercicio, comparado con el ejercicio Pararse y sentarse en una silla, en el cual se empleó el control postural y la fuerza excéntrica.

- **F1-Score:**

- **Clase 1 - Alto (97%):** Esta clase presentó el F1-Score más alto del ejercicio, pues mostró un balance perfecto entre la Precisión y la Sensibilidad, es por ello que prácticamente no existió sesgo direccional alguno; en adición, este ejercicio

presentó el segundo F1-Score más alto de esta investigación, solo por detrás del ejercicio Gatear (98%).

- **Clase 2 - Moderado (93%):** Esta clase mostró el F1-Score más bajo del ejercicio, pues refleja un ligero desbalance entre la Precisión (94%) y Sensibilidad (92%), lo cual indicó que la detección de casos en el nivel moderado es correcta pero mejorable; en adición, presentó un F1-Score idéntico al de la clase 2 del ejercicio Lanzamiento de pelota.
- **Clase 3 - Bajo (96%):** Esta clase mostró un F1-Score intermedio entre las clases 1 y 2, el cual sigue siendo alto; sin embargo, refleja un ligero desbalance entre Precisión (95%) y Sensibilidad (97%), es así que presentó un ligero sesgo hacia una alta Sensibilidad, pues detecta más casos de nivel Bajo de los que predice, pese a ello es favorable, pues es mejor detectar un caso de más que perder uno real.

Tal como se puede apreciar, los valores entre el 93% y 97% de F1-Score en este ejercicio resultaron ser consistentes, pues la brecha de 4 puntos porcentuales entre la clase Alto y Moderado es menor que en el ejercicio Sentarse y pararse de una silla, la cual fue una brecha de 8%.

- **Soporte (Support):**
 - Clase 1 - Alto: 549 frames (31.6%)
 - Clase 2 - Moderado: 611 frames (35.2%)
 - Clase 3 - Bajo: 576 frames (33.2%)
 - **Total: 1736 frames de soporte**

Como se puede observar, el dataset se encontró bien balanceado, con diferencias mínimas por clase, pues existió apenas una diferencia de 62 frames (3.6% del dataset) de un total de 1736. Además, se contó con entre 550 a 610 frames por clase, donde los intervalos de confianza son estrechos; en adición, estos resultados demostraron que si se aplica el modelo en una nueva muestra se deberían obtener resultados similares en la exactitud.

- **Exactitud (Accuracy):**

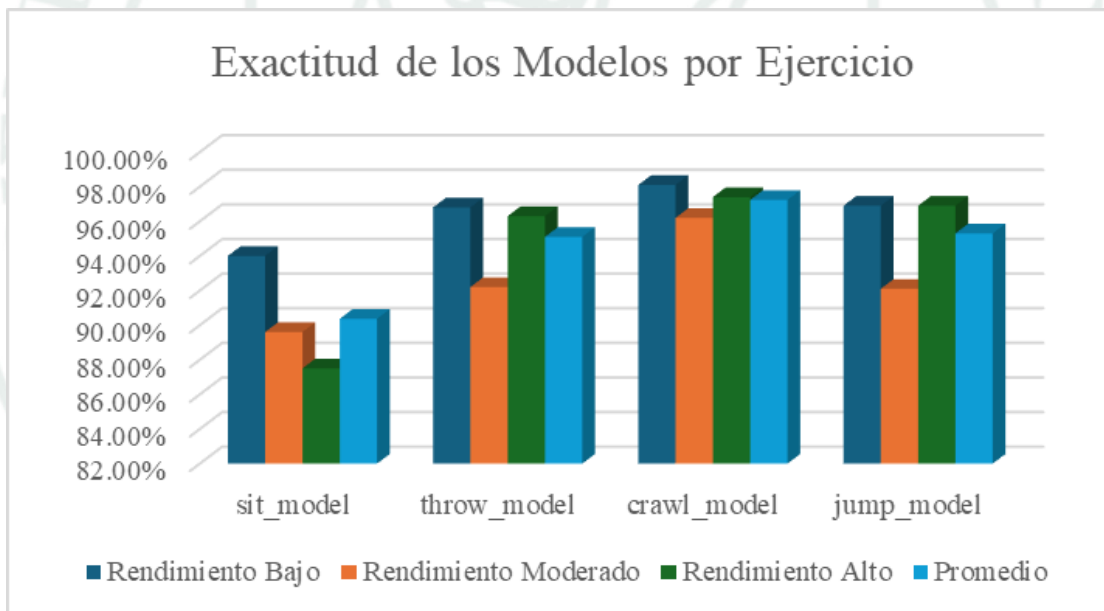
En base a la matriz mostrada en la figura 4.23, se puede apreciar que para el ejercicio Saltos en 2 Pies, el modelo es muy eficiente identificando el bajo rendimiento ($532/549 = 96.9\%$ de exactitud); por otra parte, cuenta con un buen desempeño para el rendimiento moderado ($563/611 = 92.1\%$ de exactitud); finalmente, es muy eficiente para poder distinguir entre el rendimiento moderado o bajo con el alto ($558/576 = 96.9\%$ de exactitud). Aquí se puede observar que los niveles de rendimiento alto y bajo son mucho más sencillos de clasificar por parte del modelo que el nivel moderado. En este ejercicio se logró esta exactitud debido a que el ejercicio de Saltos en 2 pies se basa en la altura máxima durante el salto, pues el modelo centra su análisis en los landmarks 27 y 28 (tobillos), calcula el promedio de la posición vertical (eje Y) de ambos tobillos frame a frame (en visión computacional el eje Y es invertido, es decir a menos valor numérico, mayor elevación física hay y viceversa), y las ejecuciones que logren el tercil superior de elevación se les clasifica como Alto desempeño. Finalmente, esta métrica resultó ser medida de forma efectiva porque la altura de vuelo es una variable física medible sin ambigüedad de interpretación, es decir no depende de una interpretación subjetiva como una buena postura o mucha coordinación de partes del cuerpo.

5.1.1.4.5. Análisis Integral

En este ejercicio, el modelo alcanzó una exactitud promedio de 95.3% debido a que la altura de vuelo (salto) es una variable biomecánica objetiva que no requiere de otras variables como la postura, entre otras; en adición, el modelo aprovechó el eje Y invertido para poder identificar la altura máxima la cual es equivalente al valor Y mínimo, esto resultó ser técnicamente correcto y robusto; además, al promediar la altura de ambos tobillos, se redujo el ruido de detección individual y se verificó el despliegue bilateral si solamente un tobillo se eleva mucho.

Figura 5.1

Exactitud de los Modelos correspondientes a cada ejercicio



Nota. En esta figura se pueden apreciar los resultados de la precisión de los 4 Modelos correspondientes a los ejercicios en base al rendimiento alto, moderado, bajo; en adición, también se muestra el promedio de Exactitud por cada modelo.

5.1.2. Resultados del Desempeño Físico de los Niños

5.1.2.1. Análisis del Desempeño

Los 23 niños con síndrome de Down fueron grabados en video realizando los 4 ejercicios físicos que se mencionan en el capítulo 4.1 con las cámaras Canon.

Posteriormente, se cargaron los videos al modelo y, en base a los resultados mostrados por el mismo, los docentes mediante sus conocimientos sobre actividad física y niños con Síndrome de Down adaptaron las actividades físicas en base a las necesidades específicas de estos mismos, de acuerdo con el desempeño físico que ellos mostraron.

A continuación, se detalla estadísticamente el progreso del desempeño físico de cada niño desde la primera prueba antes de emplear el modelo, hasta la última prueba luego del uso del modelo por parte de los docentes:

1. Resultados de pruebas físicas antes del uso del Modelo

Tal como se detalla en el capítulo 4.3.1.2, en primera instancia se realizó las visitas iniciales a los colegios para capturar los videos de los niños con síndrome de Down realizando las actividades físicas mencionadas en el capítulo 4.1, dichos videos se emplearon para el entrenamiento del modelo.

Cada niño es representado por un id, de igual manera cada ejercicio y cada número representa el nivel de desempeño de los niños en cada uno de estos, tal como se puede apreciar en la tabla 5.9, los resultados fueron los siguientes:

Tabla 5.9

Resultados de los niños antes del uso del Modelo

ID_Estudiante	Jump_1	Throw_1	Crawl_1	Sit_1
001	3	3	2	2
002	2	3	3	3
003	3	3	1	2
004	2	3	3	3
005	3	3	3	3
006	3	2	3	3
007	3	3	3	3
008	3	3	3	3
009	3	3	2	2
010	2	1	1	2
011	3	3	2	3
012	3	2	2	3
013	3	3	3	2
014	2	3	2	3
015	3	3	3	3
016	3	3	3	2
017	2	1	2	1
018	3	3	3	3
019	2	3	1	3
020	2	2	2	2
021	1	2	2	1
022	3	3	3	3
023	2	1	1	1

Donde:

1 = Alto

2 = Moderado

3 = Bajo

Antes del uso del modelo por parte de los docentes, en cuanto a la cantidad de niños que logró cada nivel de desempeño (alto, moderado, bajo), como se puede apreciar en la tabla 5.10 y la tabla 5.11, tenemos las siguientes estadísticas:

Tabla 5.10*Cantidad de niños según nivel de desempeño alcanzado en los ejercicios*

Ejercicio	Alto (1)	Moderado (2)	Bajo (3)
Salto en 2 pies	1	8	14
Lanzamiento de pelota	3	4	16
Gatear	4	8	11
Sentarse y pararse de una silla	3	7	13

Nota. En esta tabla se puede apreciar la cantidad de niños clasificados por el nivel de desempeño que obtuvieron por cada ejercicio físico que completaron: salto en dos pies, lanzamiento de pelota, gatear, pararse y sentarse de la silla; donde alto = 1, moderado = 2 y bajo = 3.

Tabla 5.11*Porcentaje de niños según nivel de desempeño alcanzado en los ejercicios*

Ejercicio	Alto (1)	Moderado (2)	Bajo (3)
Salto en 2 pies	4%	35%	61%
Lanzamiento de pelota	13%	17%	70%
Gatear	17%	35%	48%
Sentarse y pararse de una silla	13%	30%	57%

Nota. En esta tabla se pueden apreciar el porcentaje de niños que consiguieron un nivel de desempeño en cada ejercicio físico; pues, los niños en su mayoría, tienen un desempeño bajo en los 4 ejercicios, y son muy pocos los que tienen un desempeño alto; además, en cuanto a complejidad tenemos que Salto en 2 pies resulta ser el ejercicio donde más complicaciones tienen los niños con síndrome de Down al momento de realizarlos correctamente; por otra parte, el ejercicio Gatear resulta ser el más sencillo para los niños.

2. Resultados de pruebas físicas después del uso del Modelo

Luego de tener el modelo desarrollado, se realizó las segundas visitas a los colegios para la validación del modelo. En este caso, los videos no fueron grabados por las cámaras Canon, sino por las cámaras de los teléfonos móviles de los docentes, quienes luego de haber grabado el video, lo subieron al modelo; posteriormente, dicho modelo les mostró el resultado de cada una de las pruebas físicas realizadas por los niños.

Tabla 5.12

Resultados de los niños después del uso del Modelo

ID Estudiante	Jump 2	Throw 2	Crawl 2	Sit 2
001	3	2	2	2
002	2	3	2	3
003	2	2	1	1
004	2	2	1	2
005	3	3	3	2
006	3	2	3	2
007	3	3	3	3
008	3	3	2	2
009	3	3	1	2
010	2	1	1	1
011	3	2	2	2
012	2	1	2	1
013	3	3	3	2
014	1	2	1	3
015	3	3	2	3
016	3	3	2	2
017	2	1	2	1
018	3	3	3	3
019	2	2	1	3
020	2	2	1	1
021	1	1	2	1
022	3	3	2	3
023	2	1	1	1

Donde:

1 = Alto

2 = Moderado

3 = Bajo

En la tabla 5.12 se puede apreciar que cada niño es representado por un id, de igual manera cada ejercicio y cada número representa el nivel de desempeño de los niños en cada uno de estos.

Después del uso del modelo por parte de los docentes, en cuanto a la cantidad de niños que logró cada nivel de desempeño (alto, moderado, bajo), como se puede apreciar en la tabla 5.13 y la tabla 5.14, tenemos las siguientes estadísticas:

Tabla 5.13

Cantidad de niños según nivel de desempeño alcanzado en los ejercicios

Ejercicio	Alto (1)	Moderado (2)	Bajo (3)
Salto en 2 pies	2	9	12
Lanzamiento de pelota	5	8	10
Gatear	8	10	5
Sentarse y pararse de una silla	7	9	7

Nota. En esta tabla se puede apreciar la cantidad de niños clasificados por el nivel de desempeño que obtuvieron por cada ejercicio físico que completaron: salto en dos pies, lanzamiento de pelota, gatear, pararse y sentarse de la silla; donde alto = 1, moderado = 2 y bajo = 3. Dichos resultados fueron obtenidos luego del uso del modelo.

Tabla 5.14

Porcentaje de niños según nivel de desempeño alcanzado en los ejercicios

Ejercicio	Alto (1)	Moderado (2)	Bajo (3)
Salto en 2 pies	9%	39%	52%
Lanzamiento de pelota	22%	35%	43%
Gatear	35%	43%	22%
Sentarse y pararse de una silla	30%	39%	30%

Nota. En esta tabla se pueden apreciar los porcentajes de niños que consiguieron un nivel de desempeño en cada ejercicio físico; pues, con estos resultados se puede apreciar que tras el uso del modelo por parte de los docentes, los niños han presentado una mejoría notable a nivel general en su desempeño en cada actividad, respecto a las primeras pruebas físicas; pues, los docentes al ver el desempeño de cada niño, pudieron adaptar y cambiar las actividades físicas que realizan sus estudiantes con síndrome de Down en base a las necesidades específicas que estos mismos mostraron y nuevamente evaluarlos, de tal manera los niños obtuvieron mejores resultados.

5.1.2.2. Impacto Educativo

Los resultados obtenidos en las primeras pruebas físicas antes del uso del modelo, tal como se puede apreciar en la tabla 5.9 son inferiores a los resultados obtenidos en las pruebas físicas luego del uso de este modelo por parte de los docentes, como se puede apreciar en la tabla 5.12; ya que estos mismos al obtener los resultados de cada prueba por parte del modelo, pudieron ver en qué nivel de desempeño se encontraba cada uno de sus estudiantes con síndrome de Down, y de esta manera adaptaron de manera individual y personalizada las actividades físicas para los niños. A continuación, se detalla el proceso de evaluación, los instrumentos usados para medir las mejoras en el desempeño de los niños, y una comparativa del rendimiento físico antes y después del uso del modelo.

5.1.2.2.1. Diseño del estudio de validación

La evaluación del impacto del modelo a nivel educativo se realizó por medio de un estudio cuasi-experimental de tipo antes-después (pre-test/post-test), empleando la misma muestra, es decir los 23 niños con síndrome de Down, entre las edades de 4 a 10 años, distribuidos en las 8 instituciones educativas afiliadas a Cáritas Arequipa, durante un periodo de intervención de 4 meses.

A continuación, se detalla el procedimiento para el entrenamiento y evaluación del modelo:

1. Recolección de datos de entrenamiento

- Se realizaron las primeras visitas a las 8 instituciones educativas para niños con habilidades diferentes.
- Los videos fueron capturados por los investigadores empleando las cámaras Canon.
- Cada uno de los 23 niños, entre 4 a 10 años, realizó los 4 ejercicios: Saltos en 2 pies, Lanzamiento de Pelota, Gatear, Sentarse y pararse de una silla.

2. Entrenamiento del modelo

- **Entrada de videos de ejercicios:** Archivos de video en formato MP4 que contienen a los niños realizando ejercicios (Salto en dos pies, Gatear, Sentarse y pararse de una silla, Lanzamiento de pelota).
- **Preprocesamiento de videos:** Se utiliza el modelo BlazePose de MediaPipe para extraer puntos clave (landmarks) del cuerpo en cada cuadro del video, y luego se almacena las coordenadas x, y, z de los landmarks en un DataFrame.

- **Extracción de Características:** Los landmarks extraídos son transformados en características adecuadas para el modelo, luego se crean columnas específicas para cada parte del cuerpo (e.g., left_ankle_y, right_ankle_y).
- **Etiquetado de Desempeño:** Se utilizan diferentes funciones para etiquetar el desempeño según el ejercicio, es así que se asignan etiquetas (Alto, Moderado, Bajo).
- **Reducción de Dimensionalidad:** Mediante PCA (Análisis de Componentes Principales), se reduce la dimensionalidad de los datos conservando las características más significativas para facilitar el entrenamiento del modelo.
- **Entrenamiento del Modelo:** Se implementa el algoritmo de aprendizaje supervisado Random Forest Classifier. Este modelo recibe como entrada la matriz de datos reducida (los componentes del PCA, cuya cantidad varía por ejercicio: 5 para Salto, 6 para Gateo, 8 para Sentarse y 8 para Lanzamiento, determinados dinámicamente para retener el 95% de la varianza) y utiliza el 80% del dataset para construir múltiples árboles de decisión que aprenden a asociar los patrones biomecánicos con las etiquetas de desempeño (Alto, Moderado, Bajo). Finalmente, el modelo se valida con el 20% restante de los datos para asegurar su capacidad de generalización.

3. Validación y evaluación del modelo

- Se realizó la segunda visita a las 8 instituciones educativas para niños con habilidades diferentes.
- Los nuevos videos fueron procesados mediante las mismas técnicas (keypoints y PCA).

- El modelo previamente entrenado realizó las predicciones sobre el rendimiento en los ejercicios en los nuevos videos.
- El rendimiento promedio del niño fue calculado en base a las predicciones, para de esta forma ser clasificado en alto, moderado o bajo.
- Los docentes indicaron su grado de satisfacción respecto al modelo y a la mejora del desempeño de los niños con síndrome de Down.

El dataset utilizado para el entrenamiento y validación del modelo está compuesto de videos que fueron capturados en ambas visitas a las 8 instituciones educativas, cuyos videos fueron capturados con objetivos distintos; además, para el entrenamiento se grabó de manera simultánea al niño realizando el ejercicio de frente y de costado, es decir una cámara Canon lo grabó desde un ángulo y la otra cámara desde el otro; por otra parte, los videos para la evaluación fueron capturados por la cámara de los dispositivos móviles de cada docente. La composición del dataset fue la siguiente:

- Participantes: 23 niños con síndrome de Down entre 4 a 10 años de edad
- Ejercicios evaluados: 4 (Salto en 2 pies, Lanzamiento de pelota, Sentarse y pararse de una silla, y Gatear).
- Videos por ejercicio: 92
- Videos totales: 368 en formato MP4
 - Primera visita: 8 videos por niño grabados por cámaras Canon ($8 \times 23 = 184$)
 - Segunda visita: 4 videos antes y 4 videos por cada niño después del uso del modelo, en total fueron 8 videos por niño grabados por los dispositivos móviles de los docentes ($8 \times 23 = 184$)

- Duración por video: mínimo 4 segundos (variable por cada niño).

Por otra parte, el dataset que comprende los videos y los fotogramas (frames) por cada niño, ejercicio y clase que se utilizaron para el entrenamiento y evaluación del modelo, se dividieron de la siguiente manera:

- Videos por cada niño: 16 videos en total
 - 2 videos en la primera visita (para entrenamiento) por ejercicio ($2 \times 4 = 8$)
 - 2 videos en la segunda visita (para evaluación) por ejercicio, 1 antes y 1 después del uso del modelo ($2 \times 4 = 8$)
- Fotogramas (frames) utilizados por cada clase:

Tal como se mencionó en el Capítulo 4.3.2.5.1, se empleó la semilla aleatoria `random_state=42`, para que el dataset procesado se dividiera de manera aleatoria en 2 subconjuntos; uno de entrenamiento, el cual utiliza el 80% de los frames, y otro de prueba, que utiliza el 20% restante.

- Salto en 2 pies:

Tabla 5.15

Distribución de Fotogramas por clase en Salto en 2 pies

Clase	Entrenamiento (80%)	Prueba (20%)	Fotogramas Totales
Bajo (3)	461	115	576
Moderado (2)	489	122	611
Alto (1)	439	110	549
Subtotal	1389	347	1736

- Lanzamiento de pelota:

Tabla 5.16

Distribución de Fotogramas por clase en Lanzamiento de Pelota

Clase	Entrenamiento (80%)	Prueba (20%)	Fotogramas Totales
Bajo (3)	1857	464	2321
Moderado (2)	1947	487	2434
Alto (1)	1881	470	2351
Subtotal	5685	1421	7106

- Gatear:

Tabla 5.17

Distribución de Fotogramas por clase en Gatear

Clase	Entrenamiento (80%)	Prueba (20%)	Fotogramas Totales
Bajo (3)	926	231	1157
Moderado (2)	950	237	1187
Alto (1)	891	223	1114
Subtotal	2767	691	3458

- Sentarse y Pararse de una Silla:

Tabla 5.18

Distribución de Fotogramas por clase en Sentarse y Pararse de una Silla

Clase	Entrenamiento (80%)	Prueba (20%)	Fotogramas Totales
Bajo (3)	198	50	248
Moderado (2)	215	54	269
Alto (1)	200	50	250
Subtotal	614	153	767

Tal como se puede apreciar, los resultados mostraron una distribución adecuada entre las 3 clases (alto, moderado y bajo), pues el desbalance resultó ser mínimo en la suma de frames totales por clase en un mismo ejercicio; sin embargo, en cuanto a la cantidad total de frames por ejercicio, se puede apreciar que hubieron grandes diferencias, pues Lanzamiento de pelota concentró el 54.4% del dataset total (7106 frames), Gatear el 26.5% (3458 frames), Pararse y sentarse en una silla solo el 5.9% (767 frames), y finalmente Salto en 2 pies el 13.3% (1736 frames). Este desbalance ocurrió debido a implicaciones directas en confiabilidad estadística por clase, pues en el caso de Sentarse y pararse en una silla solamente generó conjuntos de prueba muy reducidos a comparación de los demás ejercicios, lo cual produjo intervalos de confianza más amplios que limitan la robustez de conclusiones sobre el desempeño; por el contrario, el ejercicio Lanzamiento de Pelota generó la mayor cantidad de conjuntos de prueba más robustos, lo cual provocó intervalos de confianza más estrechos que contienen una mayor confiabilidad estadística a las métricas reportadas. En adición, estas diferencias no se debieron a la cantidad de videos grabados, pues como se mencionó previamente el total de videos capturados fue 16 por niño, sino que fueron debido a las diferentes tasas de retención durante el filtrado automático por confianza por parte del modelo BlazePose, pues Mediapipe descartó fotogramas donde la confianza de detección de landmarks anatómicos estuvo por debajo del umbral establecido (>0.5), y dicha tasa de descarte varía bastante según las características biomecánicas de cada ejercicio.

5.1.2.2.2. Instrumentos de medición de mejora

Para medir la mejora del desempeño físico de los niños con síndrome de Down se tiene el propio modelo de monitoreo con el cual los docentes pudieron saber el desempeño de sus estudiantes con una mayor precisión y objetividad; otro instrumento son las encuestas realizadas a

los docentes expertos en educación para niños con habilidades diferentes, donde se les consultó sobre su opinión, nivel de satisfacción y si consideraron que el niño ha mejorado en su rendimiento.

➤ Modelo:

Tabla 5.19

Características del modelo como instrumento

Instrumento	Modelo de monitoreo de movimientos	
Componente	Descripción técnica	Función en la evaluación
Entrada	Video digital (formato MP4)	Capturar al niño realizando el ejercicio
Procesamiento	MediaPipe + Random Forest Classifier	Analizar los datos, extraer keypoints y generar un modelo predictivo
Salida Escala	Clasificación (Alto/Moderado/bajo) 3 niveles	Asignar nivel de desempeño 1 = alto, 2 = moderado, 3 = bajo

➤ Encuestas a Docentes:

Tabla 5.20

Características de las encuestas como instrumento

Instrumento	Encuestas a docentes	
Componente	Descripción técnica	Función en la evaluación
Tipo de Instrumento	Cuestionario con preguntas de respuesta simple y preguntas de opción múltiple	Evaluar el impacto percibido y que cambios ha provocado en la práctica de la educación física
Población Objetivo	8 docentes pertenecientes a instituciones educativas de Cáritas Arequipa (una por institución)	Capturar la percepción y satisfacción sobre la utilidad del modelo y la mejora del desempeño físico en sus estudiantes con Síndrome de Down
Momento de Aplicación	Post-intervención (después de usar el modelo y realizar evaluación final con sus estudiantes)	Evaluar la experiencia de uso del modelo
Duración	15-20 minutos	Tiempo suficiente para reflexión por parte de los docentes
Medio	Google Forms y Microsoft Excel	Registrar evaluación

5.1.2.2.3. Comparación de Resultados

A continuación, se muestra una comparativa detallada de los resultados del nivel de desempeño de los niños que lograron una mejora antes del uso del modelo y después del uso de este mismo, de un total de 23 niños como se mencionó previamente.

- Alto Rendimiento:

Tabla 5.21

Comparación antes y después en el nivel Alto

Nivel	Alto (1) - Antes		Alto (1) - Después		Balances	
	Cantidad	%	Cantidad	%	Cantidad	%
Salto en 2 pies	1	4%	2	9%	+1	+5%
Lanzamiento de pelota	3	13%	5	22%	+2	+9%
Gatear	4	17%	8	35%	+4	+18%
Sentarse y pararse de una silla	3	13%	7	30%	+4	+17%

Como se puede apreciar en la tabla 5.21, estos ejercicios muestran diferente sensibilidad a la intervención de los docentes, luego de que estos conozcan el rendimiento del niño por parte del modelo con más precisión. Además, los ejercicios Pararse y Sentarse en una Silla y Gatear fueron aquellos en los que se observó una mejoría más notable, esto según lo que se pudo interpretar, es porque los niños practican constantemente dichos ejercicios durante su vida cotidiana y principalmente en sus aulas durante la jornada escolar, entonces las adaptaciones de los docentes se refuerzan constantemente. En adición, la coordinación diagonal en el gateo y el control postural al sentarse o pararse de una silla, son habilidades de patrón motor que se pueden mejorar con práctica guiada; por lo tanto, no dependen mucho de un buen desarrollo muscular del niño. Por

otra parte, en el ejercicio de Salto en 2 pies los niños no lograron una mejora significativa debido a que los saltos dependen de potencia muscular en el tren inferior, lo cual en niños con síndrome de Down es limitado; además, la fuerza muscular se desarrolla de manera más lenta que la coordinación.

➤ Rendimiento Moderado:

Tabla 5.22

Comparación antes y después en el nivel Moderado

Nivel	Moderado (2) - Antes		Moderado (2) - Después		Balances	
	Cantidad	%	Cantidad	%	Cantidad	%
Salto en 2 pies	8	35%	9	39%	+1	+4%
Lanzamiento de pelota	4	17%	8	35%	+4	+18%
Gatear	8	35%	10	43%	+2	+8%
Sentarse y pararse de una silla	7	30%	9	39%	+2	+9%

Como se puede apreciar en la tabla 5.22, el incremento en el nivel de rendimiento moderado no indica un estancamiento, sino que refleja un progreso, pues una mayor cantidad de niños logra pasar de un rendimiento bajo a uno moderado, que los que alcanzan el nivel alto. Esto resulta ser consistente, ya que las transiciones del nivel bajo al moderado ocurren más rápido que las del nivel moderado al alto. En cuanto al ejercicio de Lanzamiento de pelota, se puede afirmar que las intervenciones docentes fueron más efectivas para que los niños con rendimiento bajo logren uno moderado; sin embargo, un progreso en el rendimiento desde moderado hacia uno alto requiere más tiempo. Por otra parte, en los ejercicios Pararse y Sentarse en una Silla, y Gatear los niños logran una progresión sostenida sin estancamiento. Por otra parte, en el ejercicio de salto, no hubo

una notable mejoría; sin embargo, esto no representa una falla en la intervención, sino que muestra la necesidad de fortalecer el desarrollo de potencia muscular en el tren inferior.

➤ Bajo Rendimiento:

Tabla 5.23

Comparación antes y después en el nivel Bajo

Ejercicio	Bajo (3) - Antes		Bajo (3) - Después		Balances	
	Cantidad	%	Cantidad	%	Cantidad	%
Salto en 2 pies	14	61%	12	52%	"-2"	"-9%"
Lanzamiento de pelota	16	70%	10	43%	"-6"	"-27%"
Gatear	11	48%	5	22%	"-6"	"-26%"
Sentarse y pararse de una silla	13	57%	7	30%	"-6"	"-27%"

Como se puede apreciar en la tabla 5.23, la reducción de la cantidad de niños que tuvieron un rendimiento bajo demuestra el impacto positivo del modelo; puesto que, precisamente es muy importante para cumplir con uno de los objetivos de esta investigación, lo cual es que el número de niños con síndrome de Down con un rendimiento bajo sea cada vez menor. La poca cantidad de niños que lograron mejorar su desempeño en el ejercicio de salto, es decir que continuaron con un rendimiento bajo, muestra que el Salto en 2 pies no es un ejercicio que pueda mejorarse en un corto plazo para la mayoría de los niños con síndrome de Down.

5.1.2.2.4. Análisis del Progreso en el Desempeño Físico

A continuación, se detalla la progresión, retroceso y permanencia en niveles de desempeño (alto, moderado, bajo) en los 4 ejercicios, por parte de los 23 niños con síndrome de Down:

- Salto en 2 pies:

Tabla 5.24

Cantidad de niños que mantuvieron el mismo nivel de desempeño en Salto en 2 pies

Nivel de desempeño	Cantidad	%
Permanecieron en Alto (1-1)	1	4.3%
Permanecieron en Moderado (2-2)	7	30.4%
Permanecieron en Bajo (3-3)	12	52.2%
Total sin progreso	20	87%

Tabla 5.25

Cantidad de niños que progresaron o retrocedieron en su desempeño en Salto en 2 pies

Nivel de desempeño	Cantidad	%
Progresaron de Bajo a Moderado (3-2)	2	8.7%
Progresaron de Moderado a Alto (2-1)	1	4.3%
Progresaron de Bajo a Alto (3-1)	0	0%
Total con progreso	3	13%
Retrocesos	0	0%

- Lanzamiento de pelota:

Tabla 5.26

Cantidad de niños que mantuvieron el mismo nivel de desempeño en Lanzamiento de Pelota

Nivel de desempeño	Cantidad	%
Permanecieron en Alto (1-1)	2	8.7%
Permanecieron en Moderado (2-2)	3	13%
Permanecieron en Bajo (3-3)	10	43.5%
Total sin progreso	15	65.2%

Tabla 5.27*Cantidad de niños que progresaron o retrocedieron su desempeño en Lanzamiento de pelota*

Nivel de desempeño	Cantidad	%
Progresaron de Bajo a Moderado (3-2)	6	26.1%
Progresaron de Moderado a Alto (2-1)	1	4.3%
Progresaron de Bajo a Alto (3-1)	1	4.3%
Total con progreso	8	34.8%
Retrocesos	0	0%

➤ Gatear:

Tabla 5.28*Cantidad de niños que mantuvieron el mismo nivel de desempeño en Gatear*

Nivel de desempeño	Cantidad	%
Permanecieron en Alto (1-1)	4	17.4%
Permanecieron en Moderado (2-2)	4	17.4%
Permanecieron en Bajo (3-3)	5	21.7%
Total sin progreso	13	56.5%

Tabla 5.29*Cantidad de niños que progresaron o retrocedieron en su desempeño en Gatear*

Nivel de desempeño	Cantidad	%
Progresaron de Bajo a Moderado (3-2)	6	26.1%
Progresaron de Moderado a Alto (2-1)	2	8.7%
Progresaron de Bajo a Alto (3-1)	2	8.7%
Total con progreso	10	43.5%
Retrocesos	0	0%

- Pararse y Sentarse en una Silla:

Tabla 5.30

Cantidad de niños que mantuvieron el mismo desempeño en Pararse y sentarse en una silla

Nivel de desempeño	Cantidad	%
Permanecieron en Alto (1-1)	3	13%
Permanecieron en Moderado (2-2)	5	21.7%
Permanecieron en Bajo (3-3)	7	30.4%
Total sin progreso	15	65.2%

Tabla 5.31

Cantidad de niños con progreso o retroceso de desempeño en Pararse y sentarse en una silla

Nivel de desempeño	Cantidad	%
Progresaron de Bajo a Moderado (3-2)	5	21.7%
Progresaron de Moderado a Alto (2-1)	2	8.7%
Progresaron de Bajo a Alto (3-1)	1	4.3%
Total con progreso	8	34.8%
Retrocesos	0	0%

Los hallazgos clave encontrados son que el ejercicio Gatear fue en el que hubo la mayor cantidad de niños que progresaron, pues 10 de 23 mejoraron su rendimiento (43.5%); por el contrario, el ejercicio de Salto en 2 pies fue aquel en el cual los niños tuvieron el menor progreso, pues solo 3 de 23 mejoraron en su rendimiento (13%) y 12 de 23 permanecieron en el nivel bajo (52.2%); además, el ejercicio Gatear fue aquel donde una mayor cantidad de niños lograron el nivel alto y se mantuvieron (17.4%); finalmente, la cantidad de niños que logró progresar desde el nivel bajo hasta el alto fueron 2 en el ejercicio Gatear (8.7%), 1 en el ejercicio de Lanzamiento de

pelota, de igual manera 1 en el ejercicio Sentarse y pararse de una silla, y ninguno en el caso de Salto en 2 pies.

5.2. Discusión

5.2.1. Principales Hallazgos

5.2.1.1. Software

El uso de la visión computacional, rama de la inteligencia artificial, permite un análisis detallado y objetivo de los movimientos del cuerpo humano en general; lo cual contribuye mucho con la evaluación objetiva del desempeño físico de los niños con Síndrome de Down, esto elimina el sesgo de la interpretación y el ojo humano, para así asegurar que la evaluación sea objetiva y lo más precisa posible, pues el modelo demostró tener una alta exactitud alcanzando desde un 97.23% en el ejercicio de Gatear, el cual resultó ser el más alto en esta investigación, y un 90.37% en el ejercicio de Pararse y sentarse en una silla, que resultó ser la exactitud más baja; por lo tanto, como se puede apreciar, el modelo cuenta con más del 90% de exactitud en todos los ejercicios y demostró tener exactitudes variables; sin embargo, dicha variabilidad no representa una falla en el modelo, sino que refleja diferencias en la biomecánica de cada movimiento y es susceptible a la medición automatizada mediante los keypoints.

Como se mencionó previamente, el modelo logró la mayor exactitud en el ejercicio Gatear, lo cual se debe al distintivo biomecánico del patrón contralateral, además este ejercicio presentó una firma geométrica muy robusta, la cual fue la coordinación diagonal, es decir la sincronía entre las manos y rodillas opuestas, dicha relación espacial generó patrones de características (features) con alta varianza entre clases, lo cual logró facilitar que el modelo Random Forest trace fronteras de decisión claras y minimice la confusión; a diferencia del ejercicio Pararse y Sentarse en una

Silla, en el cual el modelo logró la menor exactitud, pues la diferencia entre una postura correcta y una incorrecta dependió de algunas variaciones sutiles en la curvatura de la columna, lo cual resultó ser subjetivo.

El modelo automatiza el proceso de evaluación y monitoreo, para así permitir que los docentes solamente deban cargar el video al modelo, y este mismo les devolverá el resultado sobre el desempeño físico de sus estudiantes (alto, medio, bajo) al cabo de unos pocos minutos. Esto reduce mucho el tiempo y esfuerzo que se requiere para poder evaluar a cada niño. Los docentes expresaron su satisfacción respecto al modelo; además, los docentes no requieren una formación técnica avanzada; es por tal motivo que esto mejora la aceptación del modelo en los entornos educativos, donde los docentes pueden enfocarse en adaptar sus actividades físicas en base a las necesidades físicas específicas de sus estudiantes.

El modelo podría llegar a tener ciertas dificultades para procesar los videos cuando en estos hay nuevos movimientos o situaciones con las que no se entrenó el modelo y que no formaron parte del conjunto de datos inicial. Esto podría provocar algunos errores en la interpretación de los movimientos por parte del modelo, o en todo caso clasificar como un rendimiento bajo.

5.2.1.2. Hardware

1. Equipos

La mínima resolución de video que debe tener la cámara del dispositivo con el cual se grabará el video debe ser de 480p; para que esto no afecte al procesamiento de los videos ni a los resultados que muestre el modelo; por otra parte, se demostró que los resultados por parte del modelo no fueron afectados por el tipo de cámara con la que se capturó los videos, pues el contraste entre los videos grabados con las cámaras Canon en la primera visita con los videos grabados con

la cámara de los dispositivos móviles de los docentes en la segunda visita no representó ningún problema ni diferencia significativa en los resultados proporcionados por el modelo. Mostrando así, que no se requieren equipos de grabación costosos ni especializados para una correcta evaluación por parte del modelo, siempre y cuando los videos cuenten por lo menos con la calidad de 480p como se mencionó previamente.

2. Requerimientos:

Se recomienda que las computadoras en las cuales sea instalado el Modelo cuenten con al menos 8GB de memoria RAM y 10GB de espacio libre mínimo de almacenamiento en la unidad principal; lo cual muestra que no se requieren computadoras costosas, potentes, ni especializadas para que el modelo pueda ser instalado y ejecutado.

5.2.2. Fortalezas y Limitaciones

5.2.2.1. Software

5.2.2.1.1. Fortalezas

1. Visión Computacional

➤ Precisión en el monitoreo:

El uso de la inteligencia artificial y visión computacional permite una evaluación objetiva y más precisa de la motricidad gruesa, disminuyendo así el sesgo de la interpretación y el ojo humano; pues, el modelo consiguió que los niños fueran evaluados con la misma herramienta, independientemente de cualquier rasgo o característica personal. La evidencia más clara de este impacto es que el modelo identificó a 4 niños (17.4%) con un alto rendimiento en el ejercicio Gatear, que los docentes no reconocieron previamente.

➤ **Automatización de clasificación en base al desempeño:**

El análisis automático de los videos reduce el tiempo necesario para evaluar el desempeño físico de los niños y, además puede realizarse de manera continua; pues, la evaluación tradicional por parte de los docentes requiere tiempo, en cambio la evaluación por parte del modelo reduce dicho tiempo a solo 5 minutos en promedio, permitiendo a los docentes realizar una mayor cantidad de evaluaciones en un menor tiempo; además, una mayor frecuencia de evaluaciones permite que se detecte de manera temprana los estancamientos en el rendimiento físico.

2. Mejora en el área de la Educación

Los niños con discapacidades, incluyendo aquellos con síndrome de Down, enfrentan desafíos significativos en las actividades físicas, lo que genera una necesidad educativa específica.

El área de la Educación enfrenta el reto de evaluar objetivamente el rendimiento motor de estos estudiantes, ya que los docentes tradicionalmente carecen de herramientas para realizar evaluaciones cuantitativas y precisas de las actividades físicas.

Este modelo ha demostrado proporcionar resultados objetivos y más precisos del desempeño motor grueso de los niños, permitiendo a los docentes realizar intervenciones más adecuadas y personalizadas basadas en datos específicos del rendimiento de cada estudiante; en adición, la ausencia de casos de niños con algún retroceso en el desempeño valida que las intervenciones no fueron contraproducentes por parte de los docentes especialistas en educación para niños con habilidades diferentes.

5.2.2.1.2. Limitaciones

1. Dependencia de la calidad de los videos

Esta limitación surgió debido a que en algunos casos el reflejo del sol, el posicionamiento de los niños o el docente que está grabando el video del ejercicio, provocaron que el modelo no detecte los movimientos de manera correcta, y de esa forma pueda afectar el resultado final que devuelva el modelo; ello se evidenció en este estudio en el ejercicio de Sentarse y Pararse de una Silla, pues durante la transición del ángulo de la rodilla de 60° a 90° , el tronco del niño oculta temporalmente las caderas (landmarks 23/24) que son necesarias para calcular el vector hombro-caderas; precisamente este fue uno de los motivos por los que este ejercicio obtuvo una baja exactitud, esto demuestra que la calidad de la captura de videos es fundamental.

2. Errores en la interpretación de movimientos complejos

Algunos movimientos complejos o poco definidos fueron complicados de analizar por parte del modelo, lo cual podría generar errores o falta de precisión en los resultados; pues, los niños con Síndrome de Down emplearon estrategias motoras de compensación debido a sus patrones de desarrollo motor atípicos, entonces algunas de estas variaciones biomecánicas fueron malinterpretadas por el modelo, el cual fue entrenado sobre patrones motores estándar; por ejemplo, en el caso del ejercicio Gatear varios niños no lograron mostrar el patrón cruzado normal (mano derecha - rodilla izquierda alternado) el cual el modelo detecta bien, sino un gateo en bloque (ambos brazos simultáneos) o gateo asimétrico (mayor apoyo en el hemicuerpo); entonces, es por ello que el modelo, al no detectar el patrón cruzado esperado, penaliza de manera automática esas ejecuciones.

En algunos casos hubo resultados ambiguos, pues el modelo clasificó de manera incorrecta algún movimiento o simplemente no brindó un análisis detallado si las variaciones de los movimientos fueron muy sutiles; además, la evidencia cuantitativa de esta limitación se mostró en la sensibilidad de la clase Moderado, que fue claramente la más baja de todos los ejercicios, lo cual indicó que entre el 8% y 9% de casos realmente de nivel Moderado fueron clasificados como Alto o Bajo; en adición, en el ejercicio de Salto en 2 pies, un niño con síndrome de Down que saltó con $Y = 385\text{px}$ fue clasificado como Moderado, y el cual mejoró a $Y = 375\text{px}$ en la segunda prueba, cruzó el umbral del tercil superior ($Y = 380$) y por lo tanto fue reclasificado como Alto, a pesar de que la diferencia es de apenas 10px esto se debió posiblemente a una variabilidad normal o una diferencia en motivación para realizar un mejor salto que en su intento previo.

5.2.2.2. Hardware

5.2.2.2.1. Fortalezas

1. Dispositivos de alta calidad para entrenamiento del modelo

El uso de cámaras de una mayor calidad, como las cámaras Canon u otros equipos similares, logró mejorar la precisión de los resultados que retornó el modelo; además, el modelo mostró no requerir de hardware especializado para funcionar ni alcanzar exactitudes más altas, lo cual representa una ventaja y un aporte respecto a alternativas parecidas que existen hoy en día que sí requieren hardware más robusto; en adición, durante la etapa de grabación de videos para el entrenamiento del modelo, en este estudio se utilizó 2 cámaras Canon de gama media con sus respectivos trípodes, las cuales capturaron los videos en una resolución de 1920×1080 píxeles a 30 fps (cuadros por segundo), la evidencia cuantitativa del impacto de la calidad de la cámara en el

entrenamiento del modelo se reflejó en las altas exactitudes logradas, entre 90.37% y 97.23%, y los altos porcentajes en los resultados de las demás métricas (Precisión, Sensibilidad y F1-Score).

2. Bajos Costos

El modelo requiere un bajo costo de mantenimiento; además, a diferencia de otros modelos de evaluación motora que requieren licencias de software anuales, este modelo para ser desarrollado ha requerido de costos muy bajos, tal como se detalla en el Capítulo 5.2.4; además, el costo de implementación es prácticamente nulo, pues mientras se cuente por lo menos con una computadora con características muy comunes y poco exigentes como se mencionó en el Capítulo 5.1.2.1 y un dispositivo móvil con una cámara que por lo menos pueda capturar el movimiento y tenga una nitidez que permita distinguir mínimamente al niño realizando el ejercicio, resultará suficiente para poder implementar este modelo.

El modelo es gratuito para todo aquel que desee adquirirlo; entre ellos, los docentes de los niños con el síndrome de Down, pues este modelo ha sido desarrollado con el fin de ser de código y acceso abierto, es decir gratuito, el cual se encuentra en el repositorio de GitHub mencionado en el Capítulo 6.4.1.2 en los Apéndices.

5.2.2.2. Limitaciones

1. Mala calidad de los dispositivos de captura

En el caso de que la cámara del dispositivo usado para la grabación de los videos sea de una resolución baja, es posible que el modelo no sea capaz de detectar o rastrear adecuada y correctamente los movimientos, por lo cual los resultados se verían afectados; pues, aunque el modelo fue desarrollado para que también pueda ser usado con hardware accesible como se mencionó previamente, es decir cámaras convencionales de los dispositivos móviles, existe un

mínimo de calidad que debe tener la cámara, la cual debe poder capturar al niño de manera que se pueda distinguir las partes de su cuerpo mientras realiza el ejercicio y no se vea borroso.

5.2.2.3. Tamaño de la Muestra

5.2.2.3.1. Fortalezas

La muestra de 23 niños con Síndrome de Down correspondiente a 8 escuelas para niños con habilidades diferentes representa una cantidad mínima adecuada para un estudio piloto de validación como este; en adición, la participación de estas 8 instituciones educativas diferentes ubicadas en diversos distritos de la ciudad de Arequipa, proporcionó una diversidad de contextos socioeducativos que aumentó la validez de los resultados, pues reflejaron condiciones reales de implementación en entornos educativos reales y diferentes.

5.2.2.3.2. Limitaciones

El tamaño de muestra es limitado, teniendo en cuenta el total personas diagnosticadas con Síndrome de Down que se encuentran en la ciudad de Arequipa, los cuales son un total de 1014 casos aproximadamente (CONADIS, 2024), pues este restringe ligeramente la generalización de los resultados a una población más amplia de niños, especialmente teniendo en cuenta la alta variabilidad fenotípica que caracteriza a los niños con síndrome de Down; sin embargo, no se pudo acceder a una mayor población debido a las siguientes razones:

- Cáritas Diocesana del Arzobispado de Arequipa solo cuenta con 8 instituciones educativas afiliadas a esta, de los cuales solamente contaron con 25 niños con síndrome de Down matriculados entre las edades de 4 a 10 años.

- De un aproximado de 1014 niños con síndrome de Down que se encontraron en la ciudad de Arequipa, muchos no se encontraron matriculados ni asistieron a alguna institución educativa para niños con habilidades diferentes.
- Solamente Cáritas Arequipa nos proporcionó el acceso a sus instalaciones e instituciones educativas, por lo cual solo se pudo acceder a esa muestra de 25 niños.
- De los 25 niños con el rango de edad mencionado, matriculados en las instituciones educativas de Cáritas Arequipa, solo 23 de ellos asistieron en ambas visitas, los otros 2 niños no.

5.2.2.4. Calidad de Video

5.2.2.4.1. Fortalezas

El uso de cámaras Canon con una resolución de 1920 x 1080 px a 30 fps para la captura de los videos de los niños realizando los 4 ejercicios, proporcionó una calidad de captura mayor a la de estudios previos, tales como el de (Mo et al., 2016), en el cual se usó una resolución de 480 x 720 px; además, resultó ser suficiente que los videos sean grabados con una cámara de un dispositivo móvil común, la cual permita que los videos sean nítidos y no borrosos, esto validó la viabilidad de implementación sin la necesidad de algún hardware especializado ni costoso que requiera de una fuerte inversión económica por parte de Cáritas Arequipa, ni de otras instituciones similares.

5.2.2.4.2. Limitaciones

La dependencia de condiciones de captura controladas resultó ser una gran limitación en esta investigación; pues, cuando la iluminación fue poco adecuada ya sea por poca luz dentro del aula o la luz del sol, la tasa de exactitud descendió en varios puntos porcentuales. Además, la

detección de landmarks mediante BlazePose de MediaPipe requiere de ciertas condiciones específicas para la grabación de videos, de esta manera se garantiza una correcta clasificación del desempeño por parte del modelo; además, la calidad del video afecta directamente la capacidad del modelo para extraer los puntos clave.

5.2.2.5. Variabilidad entre Participantes

5.2.2.5.1. Fortalezas

Los niños participantes, los cuales padecen el síndrome de Down y, algunos de ellos también padecen el Trastorno del Espectro Autista (TEA) y Retraso Mental (RM), presentaron diversidad clínica y educativa representativa real; pues, el rango de edad que se consideró fue de 4 a 10 años, el cual abarca desde preescolar hasta escolar temprano, periodo en el cual el desarrollo motor tiene mayor impacto neurológico mediante intervenciones de especialistas y docentes; además, la distribución de niños por nivel educativo reflejó integración de niños en diferentes etapas escolares y diferentes edades; por otra parte, hubieron niños que si bien es cierto cursaban cierto año académico, su edad fue mayor, pues la edad física de la gran mayoría de estos niños es superior a su edad mental o cognitiva, lo cual se debe al propio síndrome de Down (Trisomía 21), o bien por TEA o Retraso Mental. En adición, esta diversidad le permitió al modelo poder aprender patrones de diversos casos de niños con el síndrome de Down que padecen también otras discapacidades, se encuentran en diferentes grados académicos y son de diferentes edades.

5.2.2.5.2. Limitaciones

Pese a que la muestra incluyó niños con comorbilidades además del síndrome de Down (TEA y Retraso Mental), resultaron ser solo algunas de otras discapacidades que presentan los niños con síndrome de Down, tales como Cardiopatías Congénitas, Hipotiroidismo, o algún

problema de vista, las cuales en muchos casos pueden llegar a afectar el desempeño motor grueso; en adición, otra limitación presentada es la similitud geográfica y socioeconómica de los 23 niños con síndrome de Down evaluados en la ciudad de Arequipa, la cual puede llegar a limitar la generalización a los niños de otras regiones y departamentos del Perú.

- Rango de Edad: 4 a 10 años
- Distribución por grado académico:
 - Inicial: 9 niños (39.1%)
 - Primaria: 14 niños (60.9%)
- Comorbilidades:
 - Solamente síndrome de Down: 18 niños (78.3%)
 - SD + RM: 3 niños (13%)
 - SD + TEA: 2 niños (8.7%)

5.2.3. Comparación con trabajos previos

Los resultados de la evaluación de los Modelos muestran que se logró un 90.37% de exactitud en el ejercicio de pararse y sentarse en una silla, un 95.1% en el ejercicio de lanzamiento de pelota, un 97.23% en el ejercicio de gatear, y un 95.3% en el ejercicio de salto en 2 pies; además, cada precisión alcanzada por parte del modelo por cada ejercicio en esta investigación resultaron ser superiores a los resultados experimentales en la tesis de Mo et al. (2016), donde su Modelo logró una tasa de exactitud del 81.8%.

Además, en esta misma investigación, como indican Mo et al. (2016), los videos fueron grabados con una resolución de 480 x 720px, mientras que en esta investigación los videos capturados para el entrenamiento del modelo fueron capturados con una resolución máxima de

1920 x 1080 px, es decir una calidad de video Full HD. En adición, el modelo de Lange et al. (2012) se enfoca mayormente en la rehabilitación, pero no proporciona comparaciones directas en cuanto a la precisión en actividades físicas. Además, el uso de Azure Kinect y algoritmos de visión computacional en los estudios de Mo et al. (2016) y Benavides Pando et al. (2023) resultaron útiles para mejorar el modelo y los algoritmos usados en el desarrollo del mismo en esta investigación; en adición, se encontró que Microsoft Kinect, usado en el estudio de Lange et al. (2012), es más robusto para uso en exteriores como patios escolares con sombras que varían, por otra parte, el modelo BlazePose utilizado en esta investigación requiere ambientes interiores con iluminación más controlada. Finalmente, otra ventaja que ofrece esta investigación respecto a los estudios realizados por Albert et al. (2020), Cerfoglio et al. (2022), Brambilla et al. (2023), Królikowska et al. (2023), Lo Priore (2023), Posner et al. (2023) y Sulla-Torres et al. (2023) es que el modelo puede procesar videos grabados por cualquier cámara que tenga mínimo la capacidad de grabar un video nítido; pues tal como se mencionó previamente, uno de los objetivos del Modelo es que este pueda lograr una precisión mayor, sin la necesidad de contar con cámaras especiales ni costosas como las cámaras Azure Kinect.

5.2.4. Análisis de Costos del Proyecto

Para el desarrollo e implementación de este proyecto, se deben tener en cuenta los siguientes costos, los cuales se detallan a continuación:

5.2.4.1. Recursos Humanos

- Los costos estimados requeridos en recursos humanos para aquellos que deseen desarrollar e implementar este proyecto son los siguientes:

Tabla 5.32*Costos estimados en Recursos Humanos para este proyecto en general*

Tiempo	Recurso	Costo Total	Justificación
4 meses	Investigadores	S/. 6 000 – S/. 9 000	Sueldo mensual
4 meses	Profesional en educación especial para niños con discapacidades	S/. 3 000 – S/. 5 000	Sueldo mensual
4 meses	Profesionales en programación y desarrollo de Modelos de Visión Computacional	S/. 8 000 – S/. 12 000	Sueldo mensual

- Los costos requeridos en recursos humanos por parte de los autores de esta investigación en el caso de este proyecto fueron los siguientes:

Tabla 5.33*Costos en Recursos Humanos para los autores de esta investigación*

Tiempo	Recurso	Costo Total	Justificación
4 meses	Investigadores	S/. 0	Los autores fueron los investigadores
4 meses	Profesional en educación especial para niños con discapacidades	S/. 0	Los docentes de Cáritas Arequipa participaron voluntariamente sin realizar ningún cobro por sus servicios
4 meses	Profesionales en programación y desarrollo de Modelos de Visión Computacional	S/. 0	Los autores de esta investigación fueron los desarrolladores del Modelo

5.2.4.2. Equipamiento y Tecnología

- Los costos estimados requeridos en equipamiento y tecnología para aquellos que deseen desarrollar e implementar este proyecto son los siguientes:

Tabla 5.34*Costos estimados en Equipamiento y Tecnología para este proyecto en general*

Cantidad	Recurso	Costo Total	Justificación
2 unidades	Computadora Portátil (Laptop)	S/. 3 000 – S/. 5 000	Registro de datos de los niños, desarrollo del Modelo de Visión Computacional
2 unidades	Cámara de Video (Teléfono o Cámara Profesional)	S/. 1 500 – S/. 2 500	Grabación de videos desde un ángulo frontal y lateral
1 unidad	Licencia de Microsoft Word y Excel	S/. 30	Pago mensual de licencia de software para documentación
-	Editor de código, Python, frameworks y librerías	S/. 0	No se requiere ningún pago, pues son de uso gratuito

- Los costos requeridos en equipamiento y tecnología por parte de los autores de esta investigación en el caso de este proyecto fueron los siguientes:

Tabla 5.35*Costos en Equipamiento y Tecnología para los autores de esta investigación*

Cantidad	Recurso	Costo Total	Justificación
2 unidades	Computadora Portátil (Laptop)	S/. 5 000	Registro de datos de los niños, desarrollo del Modelo de Visión Computacional
2 unidades	Cámara de Video (Teléfono o Cámara Profesional)	S/. 0	La Universidad Católica de Santa María proporcionó cámaras Canon Profesionales
1 unidad	Licencia de Microsoft Word y Excel	S/. 0	La Universidad Católica de Santa María proporcionó la licencia de Microsoft
-	Editor de código, Python, frameworks y librerías	S/. 0	No se requiere ningún pago, pues son de uso gratuito

5.2.4.3. Materiales y Recursos Educativos

- Los costos estimados requeridos en materiales y recursos educativos para aquellos que deseen desarrollar e implementar este proyecto son los siguientes:

Tabla 5.36*Costos estimados en Materiales y Recursos Educativos para este proyecto en general*

Recurso	Costo Total	Justificación
Material deportivo (conos, aros, pelotas, colchonetas, sillas, etc)	≈ S/. 200	Material necesario para que los niños realicen los ejercicios
Material de papelería e impresión	≈ S/. 200	Impresora, fichas de evaluación, consentimientos informados, permisos y documentación

- Los costos requeridos en materiales y recursos educativos por parte de los autores de esta investigación en el caso de este proyecto fueron los siguientes:

Tabla 5.37*Costos en Materiales y Recursos Educativos para los autores de esta investigación*

Recurso	Costo Total	Justificación
Material deportivo (conos, aros, pelotas, colchonetas, sillas, etc)	S/. 0	El material fue proporcionado por las instituciones educativas de cada niño
Material de papelería e impresión	S/. 0	Cáritas Arequipa tuvo la gentileza de redactar e imprimir los permisos

5.2.4.4. Implementación en Campo

- Los costos estimados requeridos de la implementación en campo para aquellos que deseen desarrollar e implementar este proyecto son los siguientes:

Tabla 5.38*Costos estimados de Implementación en Campo para este proyecto en general*

Recurso	Costo Total	Justificación
Transporte a Instituciones Educativas	Varía en base a diversos factores	Movilidad hacia los diferentes centros educativos
Transporte para Gestión de Permisos	Varía en base a diversos factores	Movilidad hacia la entidad o consorcio educativo para gestionar autorización de acceso a las Instituciones Educativas

- Los costos requeridos de la implementación en campo por parte de los autores de esta investigación en el caso de este proyecto fueron los siguientes:

Tabla 5.39

Costos de Implementación en Campo para los autores de esta investigación

Recurso	Costo Total	Justificación
Transporte a Instituciones Educativas	S/. 500	Movilidad hacia los 8 centros educativos de Cáritas Arequipa
Transporte para Gestión de Permisos	S/. 40	Movilidad hacia la entidad o consorcio educativo para gestionar autorización de acceso a las Instituciones Educativas

El costo total estimado de este proyecto en general para otros investigadores es un aproximado entre S/. 21 930 y S/. 33 900; por otra parte, el costo total de este proyecto para los autores de esta investigación fue de S/. 5 540.

5.2.5. Trabajos Futuros

Como trabajos futuros se podría considerar la integración con plataformas educativas ya existentes, el desarrollo de más módulos para otras áreas de desarrollo (como el desarrollo cognitivo, lingüístico, social, en motricidad fina, etc) y la adaptación de este modelo a otros grupos poblacionales en general con otras comorbilidades, como las personas con TDAH, Retraso Mental, Asperger, etc.

5.3. Validación de la Hipótesis

La hipótesis planteada en esta investigación, tal como se detalló en el Capítulo 1.4.1, en la cual se estableció que, mediante la implementación del modelo de monitoreo de movimientos utilizando técnicas de visión computacional, será posible identificar patrones en la motricidad gruesa de niños con Síndrome de Down y, en consecuencia, clasificarlos en niveles de desempeño (alto, moderado o bajo) según el desempeño de sus movimientos. Los resultados obtenidos permitieron contrastar esta hipótesis en lo siguiente:

Respecto a la identificación de los patrones en la motricidad gruesa, el modelo implementado demostró ser capaz de extraer y analizar patrones cinemáticos a través de los landmarks corporales proporcionados por el modelo BlazePose de MediaPipe, permitiendo así distinguir exitosamente los movimientos ejecutados en los 4 ejercicios evaluados.

En cuanto a la clasificación por niveles de desempeño, los modelos entrenados lograron clasificar correctamente a los niños en los niveles Alto, Moderado y Bajo, alcanzando exactitudes del 97.23% en Gatear, 95.3% en Salto en 2 pies, 95.1% en Lanzamiento de pelota, y 90.37% en Sentarse y pararse de una silla. Además, todos los valores superaron el umbral mínimo establecido para el modelo.

Tabla 5.40*Contraste de la hipótesis con los resultados obtenidos*

Componente de la Hipótesis	Evidencia Obtenida	Resultado
Identificar patrones de motricidad gruesa mediante visión computacional	MediaPipe BlazePose extrajo 99 características biomecánicas por frame (33 landmarks × 3 coordenadas) en los 4 ejercicios evaluados, identificando patrones de coordinación, postura y secuencia cinemática	Confirmado
Clasificar en niveles Alto, Moderado o Bajo	El modelo alcanzó exactitudes de 97.23% (Gatear), 95.3% (Salto), 95.1% (Lanzamiento) y 90.37% (Sentarse y pararse), todas superiores al 90%	Confirmado
Aplicable a niños con síndrome de Down	El sistema fue validado con 23 niños con síndrome de Down de 8 instituciones educativas afiliadas a Cáritas Arequipa, entre 4 y 10 años de edad	Confirmado
Utilidad en la evaluación del desempeño	Los docentes mostraron concordancia mayoritaria con las clasificaciones del modelo y reportaron reducción en el tiempo de evaluación tradicional	Confirmado

De tal manera, basándose en la evidencia experimental obtenida, se acepta y confirma la hipótesis de investigación, pues el modelo implementado resultó ser efectivo para identificar patrones de motricidad gruesa en niños con Síndrome de Down y clasificarlos de manera más objetiva según su nivel de desempeño físico.

Conclusiones

- PRIMERO. Fue posible analizar exitosamente los datos de movimiento de 23 niños con Síndrome de Down en entornos educativos de Arequipa, Perú mediante el uso del modelo BlazePose de MediaPipe como técnica de visión computacional, lo cual permitió identificar patrones específicos de actividad motora gruesa. Este análisis demostró la posibilidad y viabilidad de emplear una herramienta tecnológica de bajo costo, como lo es este modelo, para el monitoreo de actividad física en niños con Síndrome de Down en entornos educativos especializados. Sin embargo, varios niños emplearon patrones compensatorios atípicos como el gateo en bloque que el modelo penalizó automáticamente, lo cual evidenció ciertas limitaciones para interpretar variaciones biomecánicas naturales en estos niños.
- SEGUNDO. Se logró identificar patrones de movimiento, niveles de actividad y comportamientos relevantes para la atención y participación en actividades físicas educativas mediante la implementación de algoritmos ya existentes como Mediapipe y Random Forest Classifier, alcanzando exactitudes variadas en los 4 ejercicios, pues en Sentarse y pararse en una silla alcanzó un 90.37%, en Lanzamiento de pelota un 95.1%, en Salto en 2 pies un 95.3%, y en Gatear un 97.23%; esta variación mostró que ejercicios con métricas biomecánicas más objetivas, como la altura de salto y el patrón cruzado, alcanzaron una mayor exactitud que los ejercicios dependientes de variables subjetivas; en adición, la clase Moderado presentó claramente la sensibilidad más baja en los 4 ejercicios, pues el intervalo entre el 87.5% y 96.2% indicó que entre el 8% a 9% de casos realmente de nivel Moderado fueron clasificados como Alto o Bajo debido a la ambigüedad de zonas intermedias entre los terciles; sin embargo, el modelo requiere que los videos no contengan

ruido visual, sean en formato MP4 y sean grabados con una correcta iluminación que permita al modelo detectar las partes del cuerpo de forma adecuada.

- TERCERO. Fue posible determinar el nivel de desempeño de los niños con Síndrome de Down mediante el modelo y clasificarlos de acuerdo a dicho desempeño según 3 criterios: alto, moderado, bajo; proporcionando así una herramienta tecnológica útil y más precisa para una evaluación objetiva de su desempeño físico. Además, la clasificación por terciles generó una distribución balanceada. Asimismo, la comparación de resultados previos y posteriores al uso del modelo mostró que el 43.5% de los niños progresaron en el ejercicio Gatear, un 34.8% en Lanzamiento de pelota y en Sentarse y pararse de una silla, pero solamente un 13% en el Salto en 2 pies, lo cual reveló que una mayor cantidad de niños progresó en su desempeño en ejercicios basados en coordinación motora más que en aquellos que dependen de una potencia muscular del tren inferior. En adición, no se encontraron retrocesos por parte de los niños en su rendimiento físico en ninguno de los 4 ejercicios; no obstante, la muestra de 23 niños usada en esta investigación no incluyó a aquellos que padecen comorbilidades más severas además del Síndrome de Down, tales como cardiopatías congénitas, hipotiroidismo, limitando así la aplicabilidad a casos clínicos más complejos. Por último, esta investigación contribuye alineándose con las políticas inclusivas del sistema educativo peruano y abriendo oportunidades para futuras investigaciones con muestras más amplias, diferentes poblaciones y diversos contextos educativos.

- CUARTO. Mediante encuestas de Google Forms y Excel se logró recopilar el nivel de satisfacción de los docentes y su experiencia con el modelo; además, se realizó la validación de los resultados mostrados por este modelo acerca del desempeño físico de los niños en las actividades físicas, de tal forma que los docentes veían a los niños con Síndrome de Down realizando las actividades físicas, y posteriormente dichos docentes validaban su apreciación con los resultados que mostró el modelo, con los cuales en su mayoría estaban de acuerdo; entonces, dicha concordancia validó la utilidad práctica del modelo, pues además de lograr reducir el tiempo de evaluación tradicional, se logró desarrollar un modelo que permite clasificar a niños con Síndrome de Down en base a su desempeño físico al realizar actividades físicas empleando su motricidad gruesa. Sin embargo, como se mencionó, la muestra de 23 niños (2.3% aproximadamente de los 1014 casos en Arequipa) resultó pequeña y dependió del acceso que se pudo conseguir a los centros educativos de Arequipa, lo que podría limitar la generalización de los resultados de esta investigación a otras poblaciones o contextos geográficos.

Recomendaciones

1. Se sugiere involucrar a los padres de familia o apoderados en el proceso de monitoreo; puesto que, durante el desarrollo de esta investigación, se identificó que la poca comunicación entre los docentes y los padres o apoderados del niño limitó la continuidad de las intervenciones para la mejora de la motricidad gruesa de los niños con Síndrome de Down, pues los padres no recibieron mayor información sobre el desempeño de sus hijos y la forma en la cual pueden apoyar al niño reforzando los ejercicios en casa; es así que sería muy útil incluir reuniones individuales trimestrales con los padres de familia presentando los resultados antes y después del desempeño físico de los niños, brindar sugerencias por parte de los docentes especialistas sobre cómo deben apoyarlos y fomentar el ejercicio físico en casa, y realizando sesiones grupales donde dichos docentes muestren la técnica correcta de los ejercicios.
2. Se recomienda poder evaluar la efectividad y el impacto del modelo a largo plazo; es decir, entre 8 meses a 1 año, periodo en el cual se sugiere realizar evaluaciones periódicas que puedan permitir la medida del impacto de este modelo en el desempeño motriz de los niños con Síndrome de Down y su bienestar físico en general. Estas evaluaciones permitirán hacer ajustes y mejoras al modelo, además de dar una retroalimentación útil a los docentes y padres de familia; en adición, se sugiere que las adaptaciones de los ejercicios en base a las necesidades y características específicas de los niños sean realizadas por especialistas certificados; pues, pese a que el análisis del progreso de los niños mostró que el 43.5% de los niños mejoró en Gatear, un 34.8% en Lanzamiento de Pelota, el mismo porcentaje en Sentarse y Pararse de una Silla, y solamente un 13% en Salto en 2 pies; estos resultados

podrían mejorarse considerablemente si es un especialista certificado quien determina la forma en la cual debe adaptarse la actividad física.

3. Se recomienda siempre tener en cuenta todas las consideraciones éticas y legales que estén relacionadas con la recolección y el almacenamiento de datos, principalmente si se habla de menores de edad, tales como los niños con síndrome de Down entre las edades de 4 a 10 años de edad, y en general con cualquier discapacidad; pues, se debe asegurar que se respeten dichas normas de privacidad manteniendo los datos e imagen de los niños en completo anonimato y que los padres de familia o apoderados estén siempre informados sobre el funcionamiento y propósito de los datos que se recolecten y, además cómo usaran estos datos; para futuros estudios con otras muestras provenientes de distintos contextos geográficos, todo esto debe considerarse antes de capturar datos o videos de estas personas, pues se debe contar con un permiso de la institución educativa y los consentimientos informados respectivamente por cada participante, tal como se realizó en este estudio.

Trabajos Futuros

1. Se maximizará el impacto del modelo en los entornos educativos mediante la integración de este modelo con otras herramientas tecnológicas y plataformas existentes que son usadas en las instituciones educativas, lo cual agilizaría y facilitaría la creación de informes que combinen datos de rendimiento académico, social y motriz de los niños con Síndrome de Down.
2. Aunque este modelo está enfocado a niños que padecen el Síndrome de Down, se considerará la posibilidad de una adaptación de este mismo para niños con otras discapacidades, como los niños con TDAH, Autismo, Asperger, entre otros; de esta forma, se amplía el alcance del modelo y se contribuye aún más en la inclusión educativa.
3. Se incluirá una mayor cantidad de niños con Síndrome de Down, en cuanto a edad y nivel de desarrollo motor, para así poder obtener resultados aún más representativos y generales.
4. Se desarrollarán y validarán métricas más específicas de desempeño motor que consideren también el control motor y la coordinación; además, basado en los datos recogidos, se crearán protocolos de intervención aún más específicos en base a las necesidades de los niños, de esta forma se mejorará aún más las estrategias pedagógicas usadas en las escuelas.
5. Se añadirán más ejercicios sugeridos y validados por especialistas en actividad física para personas con habilidades diferentes, además de los 4 ejercicios evaluados en esta investigación (pararse y sentarse en una silla, saltos en 2 pies, lanzamiento de pelota, gatear).

REFERENCIAS

- Agbolade, O., Nazri, A., Yaakob, R., Ghani, A. A., & Cheah, Y. K. (2020). Down syndrome face recognition: A review. In *Symmetry* (Vol. 12, Number 7). MDPI AG.
<https://doi.org/10.3390/sym12071182>
- Aguilar-Barojas, S. (2005). Fórmulas para el cálculo de la muestra en investigaciones de salud. *Salud En Tabasco*, 7. <http://www.redalyc.org/articulo.oa?id=48711206>
- Albert, J. A., Owolabi, V., Gebel, A., Brahms, C. M., Granacher, U., & Arnrich, B. (2020). Evaluation of the pose tracking performance of the azure kinect and kinect v2 for gait analysis in comparison with a gold standard: A pilot study. *Sensors (Switzerland)*, 20(18), 1–22. <https://doi.org/10.3390/s20185104>
- Alsulami, S., Alghanem, A., AlShuraim, R., Al Sulaiman, K., Abdelwahab, O. A., Aljohani, S., Alkofide, H., AlFaifi, M., Hazwani, T., & Aljuhani, O. (2024). Opioid and benzodiazepine requirements in critically ill post-surgical children with down syndrome: a systematic review and meta-analysis. *BMC Pediatrics*, 24(1). <https://doi.org/10.1186/s12887-024-04971-0>
- Aswin Kumer, S. V., Kanakaraja, P., Areez, S., Patnaik, Y., & Tarun Kumar, P. (2020). An implementation of virtual white board using open CV for virtual classes. *Materials Today: Proceedings*, 46, 4031–4034. <https://doi.org/10.1016/j.matpr.2021.02.544>
- Benavides Pando, E. V., Delgado Valles, C., Ornelas Contreras, M., & Jiménez Lira, C. (2023). *Actividad física en jóvenes con Síndrome de Down Physical activity in people with Down Syndrome*. <https://recyt.fecyt.es/index.php/retos/index>

- Brambilla, C., Marani, R., Romeo, L., Lavit Nicora, M., Storm, F. A., Reni, G., Malosio, M., D’Orazio, T., & Scano, A. (2023). Azure Kinect performance evaluation for human motion and upper limb biomechanical analysis. *Heliyon*, 9(11), e21606.
<https://doi.org/10.1016/J.HELIYON.2023.E21606>
- Cai, L., Liu, D., & Ma, Y. (2021). Placement recommendations for single kinect-based motion capture system in unilateral dynamic motion analysis. *Healthcare (Switzerland)*, 9(8).
<https://doi.org/10.3390/healthcare9081076>
- Cerfoglio, S., Ferraris, C., Vismara, L., Amprimo, G., Priano, L., Pettiti, G., Galli, M., Mauro, A., & Cimolin, V. (2022). Kinect-Based Assessment of Lower Limbs during Gait in Post-Stroke Hemiplegic Patients: A Narrative Review. In *Sensors* (Vol. 22, Number 13). MDPI.
<https://doi.org/10.3390/s22134910>
- Chen, L., Chen, P., & Lin, Z. (2020). Artificial Intelligence in Education: A Review. *IEEE Access*, 8, 75264–75278. <https://doi.org/10.1109/ACCESS.2020.2988510>
- CONADIS. (2022). *Día Mundial del Síndrome de Down - Noticias - Consejo Nacional para la Integración de la Persona con Discapacidad - Plataforma del Estado Peruano*.
<https://www.gob.pe/institucion/conadis/noticias/593360-dia-mundial-del-sindrome-de-down>
- CONADIS. (2024). *POBLACIÓN DIAGNOSTICADA CON SÍNDROME DE DOWN INSCRITA EN EL REGISTRO NACIONAL DE LA PERSONA CON DISCAPACIDAD POR SEXO SEGÚN REGIÓN, 2000-2024 1/*.
<https://sgd.conadisperu.gob.pe:8181/validadorDocumental/inicio/detalle.jsf>
- Donnelly, N., Cunningham, A., Salas, S. M., Bracher-Smith, M., Chawner, S., Stochl, J., Ford, T., Raymond, F. L., Escott-Price, V., & van den Bree, M. B. M. (2023). Identifying the

neurodevelopmental and psychiatric signatures of genomic disorders associated with intellectual disability: a machine learning approach. *Molecular Autism*, 14(1).

<https://doi.org/10.1186/s13229-023-00549-2>

Du, S., Wang, K., & Cao, Z. (2023). BPR-Net: Balancing Precision and Recall for Infrared Small Target Detection. *IEEE Transactions on Geoscience and Remote Sensing*, 61.

<https://doi.org/10.1109/TGRS.2023.3296102>

Gómez Álvarez, N., Venegas Mortecinos, A., Zapata Rodríguez, V., López Fontanilla, M., Maudier Vásquez, M., Pavez-Adasme, G., & Hernández-Mosqueira, C. (2018). Effect of an intervention based on virtual reality on motor development and postural control in children with down syndrome. *Revista Chilena de Pediatría*, 89(6), 747–752.

<https://doi.org/10.4067/S0370-41062018005001202>

Heidari, S., Dinneen, M. J., & Delmas, P. (2024). Quantum Annealing for Computer Vision minimization problems. *Future Generation Computer Systems*, 160, 54–64.

<https://doi.org/10.1016/j.future.2024.05.037>

Hörak, H. (2019). Computer vision-based unobtrusive physical activity monitoring in school by room-level physical activity estimation: A method proposition. *Information (Switzerland)*,

10(9). <https://doi.org/10.3390/info10090269>

Isralowitz, E. B., Sideris, J., Stein Duker, L. I., Baranek, G. T., & Cermak, S. A. (2023).

Comparing sensory processing in children with Down syndrome to a mental age matched sample of children with autism, other developmental disabilities, and typically developing children. *Research in Developmental Disabilities*, 134.

<https://doi.org/10.1016/j.ridd.2022.104421>

- Khanal, S. R., Paulino, D., Sampaio, J., Barroso, J., Reis, A., & Filipe, V. (2022). A Review on Computer Vision Technology for Physical Exercise Monitoring. In *Algorithms* (Vol. 15, Number 12). MDPI. <https://doi.org/10.3390/a15120444>
- Królikowska, A., Maj, A., Dejneka, M., Prill, R., Skotowska-Machaj, A., & Kołcz, A. (2023). Wrist motion assessment using Microsoft Azure Kinect DK: A reliability study in healthy individuals. *Advances in Clinical and Experimental Medicine : Official Organ Wrocław Medical University*, 32(2), 203–209. <https://doi.org/10.17219/ACEM/152884>
- Kuhner, A., Schubert, T., Cenciarini, M., Wiesmeier, I. K., Coenen, V. A., Burgard, W., Weiller, C., & Maurer, C. (2017). Correlations between motor symptoms across different motor tasks, quantified via random forest feature classification in Parkinson's disease. *Frontiers in Neurology*, 8(NOV). <https://doi.org/10.3389/fneur.2017.00607>
- Lange, B., Koenig, S., McConell, E., Chang, C.-Y., Juang, R., Suma, E., Bolas, M., & Rizzo, A. (2012). *Interactive Game-Based Rehabilitation Using the Microsoft Kinect*. IEEE.
- Lo Priore, S. (2023). *Exergames in realtà virtuale e body tracking: riabilitazione motoria per pazienti affetti da malattia di Parkinson e post-Ictus = Body tracking in VR exergames: motor rehabilitation for Parkinson's disease and post-Stroke patients*.
- Lopes, J. B. P., Barbosa, L. C., Parreira, R. B., Duarte, N. D. A. C., Silva, T. D., Monteiro, C. B. D. M., Conway, B., Galli, M., Cimolin, V., & Oliveira, C. (2021). Movement analysis of upper limbs during motor task in down syndrome immediately after TDCS combined with non-immersive virtual reality. *Gait & Posture*, 90, 137–138. <https://doi.org/10.1016/j.gaitpost.2021.09.072>

- Luo, C., Yan, Z., Wu, J., Liu, X., & Li, Y. (2023). Calibration of upper limb joint angle based on Azure Kinect depth camera. *Proceedings - 2023 6th International Conference on Data Science and Information Technology, DSIT 2023*, 103–108.
<https://doi.org/10.1109/DSIT60026.2023.00025>
- Martínez José, J. M. (2018). *"Sistema de Visión Artificial para la Detección y Corrección de Posturas Que para obtener el Título de.*
- MedlinePlus. (2024). *Síndrome de Down*. <https://medlineplus.gov/spanish/downsyndrome.html>
- Ministerio de la Mujer y Poblaciones Vulnerables. (2019). *LEY 29973_ REGLAMENTO_17_07_2023*.
- Mo, L., Li, F., Zhu, Y., & Huang, A. (2016). Human physical activity recognition based on computer vision with deep learning model. *2016 IEEE International Instrumentation and Measurement Technology Conference Proceedings*, 1–6.
<https://doi.org/10.1109/I2MTC.2016.7520541>
- Moreira Sanchez, R. L., & Vasquez Arriaga, C. D. (2022). *DESARROLLO DE UN SISTEMA DE VISIÓN ARTIFICIAL MEDIANTE SENSOR KINECT, ARDUINO Y COMUNICACIÓN WIFI PARA CONTROLAR UN BRAZO ROBÓTICO DE 4GDL*.
- Ortiz Távara, T. M., & Reynosa Navarro, E. (2021). *Inclusión educativa de niños con síndrome Down en educación inicial regular, Perú*.
http://scielo.sld.cu/scielo.php?script=sci_arttext&pid=S0864-21252021000200017

- Posner, C., Sánchez-Mompó, A., Mavromatis, I., & Al-Ani, M. (2023). A dataset of human body tracking of walking actions captured using two Azure Kinect sensors. *Data in Brief*, 49. <https://doi.org/10.1016/j.dib.2023.109334>
- Saad Alotaibi, B., Ibrahim Shema, A., Umar Ibrahim, A., Awad Abuhussain, M., Abdulmalik, H., Aminu Dodo, Y., & Atakara, C. (2024). Assimilation of 3D Printing, Artificial Intelligence (AI) and Internet of Things (IoT) For the Construction of Eco-Friendly Intelligent homes: An Explorative Review. *Heliyon*, e36846. <https://doi.org/10.1016/j.heliyon.2024.e36846>
- Sailema Torres, Á. A., Sailema Torres, M., Amores Guevara, P. del R., Navas Franco, L. E., Mallqui Quisintuña, V. A., & Romero Frómata, E. (2017). *TRADITIONAL GAMES AS MOTOR STIMULATOR IN CHILDREN WITH DOWN SYNDROME*.
- Sangkarit, N., & Tapanya, W. (2024). Factors influencing on gross motor skills in infants: Implications for walking development. *Early Human Development*, 195. <https://doi.org/10.1016/j.earlhumdev.2024.106076>
- Shi, Z., Yang, X., Zhang, X., Zhu, W., Dai, Y., & Li, J. (2024). An empirical study of the flag rugby game programme to promote gross motor skills and physical fitness in 5–6 year old preschool children. *Heliyon*, 10(8). <https://doi.org/10.1016/j.heliyon.2024.e29200>
- Siebra, C. A., & Siebra, H. A. (2018). Using computational support in motor ability analysis of individuals with Down syndrome: Literature review. *Computer Methods and Programs in Biomedicine*, 157, 145–152. <https://doi.org/10.1016/J.CMPB.2018.01.029>
- Sulla-Torres, J., Pamo, B. A. S., & Rodríguez, F. J. C. (2023). Evaluation of Physical Activity by Computer Vision Using Azure Kinect in University Students. *International Conference on*

Electrical, Computer, Communications and Mechatronics Engineering, ICECCME 2023.

<https://doi.org/10.1109/ICECCME57830.2023.10253287>

Svendsen, J. P. (2007). *Analysis of Motor Skills in Subjects with Down's Syndrome using Computer Vision Techniques.*

Ullah, Z., Qi, L., Pires, E. J. S., Reis, A., & Nunes, R. R. (2024). A Systematic Review of Computer Vision Techniques for Quality Control in End-of-Line Visual Inspection of Antenna Parts. In *Computers, Materials and Continua* (Vol. 80, Number 2, pp. 2387–2421). Tech Science Press. <https://doi.org/10.32604/cmc.2024.047572>

Wang, C., Yu, L., Su, J., Mahy, T., Selis, V., Yang, C., & Ma, F. (2023). Down Syndrome detection with Swin Transformer architecture. *Biomedical Signal Processing and Control*, 86. <https://doi.org/10.1016/j.bspc.2023.105199>

APÉNDICES

6.1. Plan de Trabajo

Título del Proyecto: Modelo de Machine Learning para el monitoreo de actividad motora gruesa en niños con síndrome de Down para determinar su desempeño físico en entornos educativos de Arequipa, Perú.

Autores del Proyecto:

- Hector Daniel Oviedo Villanueva
- Sergio Paolo Suarez Fernandez

Fecha de inicio: 12 de septiembre de 2024

Duración del Proyecto en el Colegio: 3 meses (12 de setiembre de 2024 - 20 de diciembre de 2024)

1. Objetivo del Plan de Trabajo en el Colegio

Llevar a cabo la recolección de datos de actividad motora gruesa de los niños con Síndrome de Down a través de la implementación de cámaras Canon y la interacción con los maestros y niños. Se busca capturar los movimientos de los niños durante actividades físicas para su posterior análisis en el desarrollo del software.

2. Actividades del Proyecto en el Colegio

2.1. Fase de Preparación (12 de septiembre - 17 de septiembre de 2024)

- Reunión inicial con el personal del colegio (12 de septiembre de 2024):
 - Presentación del equipo de trabajo y los objetivos del proyecto.
 - Coordinación de fechas y horarios para la instalación del equipo y las sesiones con los niños.
 - Explicación de los procedimientos a los maestros y personal administrativo.
 - Duración: 1 hora.

2.2. Fase de Recolección de Datos (26 de septiembre - 17 de octubre de 2024)

- Definición preliminar de horarios de primera visita para recolección de datos iniciales:
 - **Distribución por semanas:**
 - **Semana 1 (24 - 25 de septiembre de 2024):**
 - C.E.B.E. Nuestra Señora de la Consolación: 24 de septiembre.
 - C.E.B.E. María de los Remedios: 25 de septiembre.

- **Semana 2 (2 - 3 de octubre de 2024):**
 - C.E.B.E. María de la Esperanza: 2 de octubre.
 - C.E.B.E. Santa Ana: 3 de octubre.
- **Semana 3 (9 - 10 de octubre de 2024):**
 - C.E.B.E. Nuestra Señora del Perpetuo Socorro: 9 de octubre.
 - C.E.B.E. Señor de los Milagros: 10 de octubre.
- **Semana 4 (16 - 17 de octubre de 2024):**
 - C.E.B.E. San Martín de Porres: 16 de octubre.
 - C.E.B.E. Nuestra Señora de la Candelaria: 17 de octubre.
- **Entrevistas:**

Se realizarán entrevistas a las directoras de las escuelas para obtener los permisos necesarios y recopilar los datos relevantes de los niños, los cuales son nombre completo, edad, discapacidad, talla y peso. Cada entrevista tendrá una duración de máximo 30 minutos.
- **Revisión de espacio físico para la instalación de cámaras Canon:**
 - Inspección del área donde se llevarán a cabo las actividades físicas.
 - Verificación de las condiciones de iluminación y espacio.
 - Duración: 2 horas.
- **Instalación de las cámaras Canon:**
 - Colocación y prueba de las cámaras en el área designada del colegio.
 - Configuración técnica y calibración de los dispositivos para asegurar la captura óptima de los movimientos.
 - Duración: 10 minutos.
- Definición preliminar de horarios de segunda visita para validación del modelo:
 - **Distribución por semanas:**
 - **Semana 5 (29 - 30 de octubre de 2024):**
 - C.E.B.E. Nuestra Señora de la Consolación: 29 de octubre.
 - C.E.B.E. María de los Remedios: 30 de octubre.
 - **Semana 6 (6 - 7 de noviembre de 2024):**
 - C.E.B.E. María de la Esperanza: 6 de noviembre.
 - C.E.B.E. Santa Ana: 7 de noviembre.
 - **Semana 7 (13 - 14 de noviembre de 2024):**
 - C.E.B.E. Nuestra Señora del Perpetuo Socorro: 13 de noviembre.
 - C.E.B.E. Señor de los Milagros: 14 de noviembre.
 - **Semana 8 (20 - 21 de noviembre de 2024):**
 - C.E.B.E. San Martín de Porres: 20 de noviembre.
 - C.E.B.E. Nuestra Señora de la Candelaria: 21 de noviembre.

2.3. Interacción y Evaluación con Maestros (2 de diciembre - 5 de diciembre de 2024)

- Reunión de retroalimentación con los maestros:
 - Los maestros proporcionarán sus observaciones sobre el comportamiento de los niños durante las sesiones.
 - Evaluación de la efectividad del modelo en cuanto a la participación y motivación de los niños.
 - Duración: 2 horas.
 - Evaluación final del modelo por los maestros:
 - Recopilación de opiniones sobre la facilidad de uso del modelo y la aplicabilidad de los datos obtenidos para personalizar actividades físicas.
 - Duración: 1 hora.
-

3. Consideraciones Especiales

- **Privacidad y Seguridad:** Todos los datos capturados serán tratados con estricta confidencialidad, garantizando la privacidad de los niños y del personal.
 - **Flexibilidad:** El cronograma y las actividades podrán adaptarse según las necesidades del colegio y la disponibilidad de los niños.
-

4. Resultados Esperados

Al finalizar la etapa de recolección de datos, se espera contar con suficiente material visual y estadístico que permita desarrollar y validar el Modelo de monitoreo de actividad motora para niños con Síndrome de Down, facilitando así la mejora en las actividades físicas y la intervención educativa en este grupo de estudiantes.

6.2. Documento de Consentimiento Informado.

CONSENTIMIENTO INFORMADO PARA PARTICIPAR EN UN ESTUDIO DE INVESTIGACIÓN	
Padres de Familia/Apoderados	
<i>Título del estudio:</i>	Modelo de Machine Learning para el monitoreo de actividad motora gruesa en niños con síndrome de Down para determinar su desempeño físico en entornos educativos de Arequipa, Perú
<i>Investigadores:</i>	Hector Daniel Oviedo Villanueva, Sergio Paolo Suarez Fernandez
<i>Institución:</i>	Universidad Católica de Santa María

Propósito del estudio:

Estamos invitando a su hijo(a) a participar en un estudio donde se desarrollará un modelo de monitoreo de movimientos utilizando técnicas de visión computacional, para identificar patrones de motricidad en los niños con síndrome de Down, con el fin de clasificarlos en función de su desempeño (Alto, moderado, bajo).

El objetivo de este proyecto es la necesidad de mejorar la educación física especializada para este grupo de estudiantes. Para poder lograrlo, se proporcionará a los docentes herramientas tecnológicas, tales como un modelo basado en Visión Computacional, lo cual podría ofrecer una solución prometedora al brindar una evaluación más precisa y objetiva, permitiendo identificar patrones en la motricidad gruesa y clasificar a los niños en función de su desempeño. Esta información valiosa puede ser utilizada por los docentes para diseñar programas de ejercicio personalizados que les permitan adaptar la evaluación y el aprendizaje a las necesidades específicas de cada niño; no obstante, cabe resaltar que en la presente propuesta, solamente se desarrollará el modelo de Visión Computacional; pues, la adaptación de la evaluación y el aprendizaje respecto las necesidades específicas de cada niño, escapa al alcance del proyecto y queda en manos de los docentes realizarlo con los resultados que genere este modelo.

Procedimientos:

Si usted acepta que su hijo participe y su hijo decide participar en este estudio se le realizará lo siguiente:

1. Se tomarán los datos de nombre completo, edad, peso, talla, discapacidad(es).
2. Se le realizarán las grabaciones en su Institución Educativa, donde realizará ejercicios empleando su motricidad gruesa con la ayuda de algún docente, los cuales incluyen pararse y sentarse de la silla, gatear, saltar en dos pies, abdominales y lanzamiento de pelota.
3. Se le tapaná el rostro y garantizamos la privacidad de su imagen y datos personales; por lo tanto, no se difundirán ninguno de estos.

Riesgos:

El monitoreo de sus actividades físicas con las cámaras podría hacer que los niños se sientan incómodos o cohibidos, lo cual podría afectar su desempeño en las pruebas

Existe la posibilidad que los niños sufran caídas accidentales durante estas pruebas; sin embargo, es muy poco probable ya que estas actividades siempre se realizarán con la supervisión y ayuda de al menos un docente.

Beneficios:

Su hijo(a) se beneficiará de una intervención adaptada en particular a sus necesidades específicas, lo cual puede mejorar significativamente sus habilidades motoras gruesas, al emplear tecnologías como la realidad virtual; además, esto puede resultar ser atractivo para su hijo y fomentar su participación en las actividades de educación física al ver un progreso en su desarrollo motor y capacidad física.

CONSENTIMIENTO INFORMADO PARA PARTICIPAR EN UN ESTUDIO DE INVESTIGACIÓN	
Padres de Familia/Apoderados	
<i>Título del estudio:</i>	Modelo de Machine Learning para el monitoreo de actividad motora gruesa en niños con síndrome de Down para determinar su desempeño físico en entornos educativos de Arequipa, Perú
<i>Investigadores:</i>	Hector Daniel Oviedo Villanueva, Sergio Paolo Suarez Fernandez
<i>Institución:</i>	Universidad Católica de Santa María

Costos y compensación

No se deberá pagar nada por la participación de su hijo(a) en el estudio. Igualmente, no recibirá ningún incentivo económico ni de otra índole, ni tendrá que realizar gastos por transporte y/o un refrigerio por el tiempo brindado; puesto que, las pruebas se realizarán en su Institución Educativa correspondiente en horario de clases.

Confidencialidad:

Nosotros guardaremos la información de su hijo(a) con códigos y no con nombres. Si los resultados de este seguimiento son publicados, no se mostrará ninguna información que permita la identificación de su hijo(a) o de otros participantes del estudio.

Uso futuro de la información obtenida

Deseamos conservar las muestras de su hijo(a) almacenándolas hasta culminar la sustentación de nuestro proyecto de tesis. Las muestras serán usadas para entrenar el modelo.

Estas muestras sólo serán identificadas con códigos.

Si usted no desea que las muestras de su hijo(a) permanezcan almacenadas ni utilizadas posteriormente, su hijo(a) aún puede seguir participando del estudio.

Además, la información de los resultados será guardada y usada posteriormente para estudios de investigación beneficiando al mejor conocimiento de esta discapacidad, integrar dicho modelo con plataformas educativas, desarrollar módulos para otras áreas (cognitivo, lingüístico y social) e incluso la adaptación de este modelo a otros grupos poblacionales con necesidades especiales.

Autorizo a tener las grabaciones de mi hijo(a) almacenadas SI () NO ()

Derechos del participante:

Si usted decide que su hijo(a) participe en el estudio, podrá retirarse de éste en cualquier momento, o no participar en una parte del estudio sin daño alguno. Si tiene alguna duda adicional, por favor pregunte al personal del estudio o llame al Dr. José Alfredo Sullá Torres al teléfono 959 950 467.

Si tiene preguntas sobre los aspectos éticos del estudio, o cree que su hijo(a) ha sido tratado injustamente puede contactar a la Sra. Águeda Muñoz del Carpio Toia, presidente del Comité Institucional de Ética de Investigación de la Universidad Católica de Santa María al correo electrónico: comiteeticainvestigacionucsm@gmail.com

CONSENTIMIENTO INFORMADO PARA PARTICIPAR EN UN ESTUDIO DE INVESTIGACIÓN	
Padres de Familia/Apoderados	
<i>Título del estudio:</i>	Modelo de Machine Learning para el monitoreo de actividad motora gruesa en niños con síndrome de Down para determinar su desempeño físico en entornos educativos de Arequipa, Perú
<i>Investigadores:</i>	Hector Daniel Oviedo Villanueva, Sergio Paolo Suarez Fernández
<i>Institución:</i>	Universidad Católica de Santa María

Una copia de este consentimiento informado le será entregada.

DECLARACIÓN Y/O CONSENTIMIENTO

Accepto voluntariamente que mi hijo(a) participe en este estudio, comprendo de las actividades en las que participará si ingresa al estudio, también entiendo que mi hijo(a) puede decidir no participar y que puede retirarse del estudio en cualquier momento.

Nombres y Apellidos Padre/madre/tutor	Firma	Fecha y Hora
Nombres y Apellidos Testigo (si el participante es analfabeto)	Firma	Fecha y Hora
Nombres y Apellidos Investigador 1	Firma	Fecha y Hora
Nombres y Apellidos Investigador 2	Firma	Fecha y Hora

6.3. Documento Excel para la toma de datos

Tabla 5.41

Hoja de cálculo para la toma de datos

2	Código	Edad	Grado	Discapacidad
3	Colegio Nuestra Señora de la consolacion			
4	001	6	4 inicial	Sindrome de Down
5	002	9	2 primaria	Sindrome de Down
6	003	8	2 primaria	Sindrome de Down, TEA
7	004	10	2 primaria	Sindrome de Down
8	Colegio Maria de la Esperanza			
9	005	8	5 inicial	Sindrome de Down, RM leve
10	006	9	2 primaria	Sindrome de Down, RM leve
11	Colegio Santa Ana			
12	007	4	3 inicial	Sindrome de Down
13	008	6	4 inicial	Sindrome de Down
14	009	5	3 inicial	Sindrome de Down
15	010	7	1 primaria	Sindrome de Down
16	011	9	1 primaria	Sindrome de Down
17	012	8	1 primaria	Sindrome de Down
18	Colegio Nuestra Señora del perpetuo socorro			
19	013	4	3 inicial	Sindrome de Down
20	014	5	4 inicial	Sindrome de Down
21	015	8	1 primaria	Sindrome de Down
22	016	8	1 primaria	Sindrome de Down
23	017	6	1 primaria	Sindrome de Down
24	Colegio Señor de los Milagros			
25	018	9	1 primaria	Sindrome de Down
26	019	7	4 inicial	Sindrome de Down
27	Colegio San Martin de Porres			
28	020	9	2 Primaria	Sindrome de Down
29	021	4	4 inicial	Sindrome de Down
30	Colegio Nuestra Señora de La Candelaria			
31	021	8	5 inicial	Sindrome de Down
32	022	7	5 inicial	Sindrome de Down

6.4. Guía Técnica del Modelo

6.4.1. Instalación del Modelo

A continuación, se proporciona una guía detallada para realizar la instalación del Modelo de Visión Computacional en un ordenador.

6.4.1.1. Prerrequisitos

- Python: 3.9.6 o superior
- Git: Para el control de versiones (opcional)
- Memoria: Se recomienda un mínimo de 4 GB de RAM
- Almacenamiento: al menos 2 GB de espacio libre

6.4.1.2. Pasos para la Instalación

Para realizar la instalación del Modelo de manera satisfactoria, se deben seguir los siguientes pasos, y cada comando debe ser ingresado en una terminal:

- Paso 1: Clonar el repositorio

```
git clone https://github.com/HectorDaniell/proyectoTesis.git
cd proyectoTesis
```

Código 5.1: Comandos para clonar el repositorio de GitHub

- Paso 2: Crear un entorno virtual

```
python -m venv .venv
```

Código 5.2: Comandos para la creación del entorno virtual

- Paso 3: Activar el entorno virtual
 - Para Windows:

```
.venv\Scripts\activate
```

Código 5.3: Comando para activar el entorno virtual en Windows

- Para macOS/Linux:

```
source .venv/bin/activate
```

Código 5.4: Comando para activar entorno virtual en macOS o Linux

- Paso 4: Instalar dependencias

```
# Actualizar pip
pip install --upgrade pip

# Instalar dependencias
pip install -r requirements.txt
```

Código 5.5: Comandos para realizar la instalación de dependencias

6.4.2. Uso del Modelo

Para realizar el uso del Modelo de manera correcta, se debe realizar lo siguiente, y cada comando debe ser ingresado en una terminal:

6.4.2.1. Entrenamiento de modelos

- Para entrenar el modelo con el conjunto de datos de vídeo:

```
# Navegar al directorio de entrenamiento
cd src/training

# Ejecutar el pipeline de entrenamiento
python main_training.py
```

Código 5.6: Comandos para el entrenamiento de los modelos

- El proceso de entrenamiento:
 - Procese archivos de video y extraiga puntos de referencia de postura.
 - Etiquete el rendimiento según criterios específicos del ejercicio.
 - Aplicar la reducción de dimensionalidad de PCA.
 - Entrenamiento y evaluación de modelos de aprendizaje automático.
 - Guardar modelos entrenados en data/models/.

6.4.2.2. Evaluación de video

Los videos deben estar en data/raw/{ejercicio}/ en formato MP4.

- Para evaluar nuevos vídeos con el modelo entrenado:

```
# Navegar al directorio de evaluación
cd src/evaluation

# Por defecto entrena el ejercicio configurado en main_training.py (última
línea). Para cambiar el ejercicio, modificar el argumento:
main_training('jump') # o 'crawl', 'sit', 'throw'

# Ejecutar evaluación
python main_evaluation.py
```

Código 5.7: Comandos para evaluar los próximos videos con el modelo ya entrenado

- La evaluación:
 - Procesa el vídeo de entrada.
 - Extrae puntos de referencia de postura.
 - Aplica el mismo preprocesamiento que el entrenamiento.
 - Genera predicciones de rendimiento.
 - Muestra cuadro por cuadro y resultados generales.

6.4.2.3. Ejecución de pruebas

```
# Ejecutar la suite de pruebas completa
python test/test_exercise_modules.py
```

Código 5.8: Comandos para ejecutar pruebas

6.4.3. Estructura del Proyecto

Figura 5.2

Estructura de Archivos del Proyecto

```
projectoTesis/
├── README.md
├── AGENTS.md
├── requirements.txt
├── .gitignore
├── src/
│   ├── training/
│   │   ├── main_training.py
│   │   ├── process_videos.py
│   │   ├── label_data_jump.py
│   │   ├── label_data_crawl.py
│   │   ├── label_data_sit.py
│   │   ├── label_data_throw.py
│   │   ├── pca_reduction.py
│   │   ├── train_model.py
│   │   └── compare_models.py
│   └── evaluation/
│       ├── main_evaluation.py
│       └── predict_performance.py
├── data/
│   ├── raw/
│   │   ├── jump/
│   │   ├── crawl/
│   │   ├── sit/
│   │   └── throw/
│   ├── processed/
│   │   ├── {exercise}_landmarks.csv
│   │   ├── {exercise}_labeled.csv
│   │   ├── {exercise}_reduced.csv
│   │   ├── {exercise}_pca.pkl
│   │   └── models/
│   │       └── {exercise}_model.pkl
│   └── results/
│       ├── model_comparison.csv
│       └── confusion_matrices/
├── docs/
│   └── DOCUMENTATION.md
├── Landmarks/
│   ├── main.py
│   └── extract_landmarks.py
└── test/
    └── test_exercise_modules.py
```

Nota. En esta tabla se puede apreciar la arquitectura de carpetas del proyecto.

6.4.4. Documentación del Módulo

6.4.4.1. Pipeline de entrenamiento

- Orquestador principal para la canalización de entrenamiento. (**main_training.py**)

```
# Entry point: Execute training pipeline for jump exercise
if __name__ == "__main__":
    main_training('jump')

# Function to select appropriate labeling function based on exercise type
def select_labeling_function(exercise_name):
    """
    Select the appropriate performance labeling function based on exercise type.

    Args:
        exercise_name (str): Name of the exercise (jump, crawl, sit, ball
        throwing)

    Returns:
        function: Appropriate labeling function for the exercise

    Raises:
        ValueError: If no labeling function is available for the exercise
    """
```

Código 5.9: Código para la canalización del entrenamiento

- Maneja el procesamiento de video y la extracción de puntos de referencia. (**process_videos.py**)

```
def process_video(video_path, exercise_name, combined_df):
    """
    Extract pose landmarks from video using MediaPipe.

    Args:
        video_path (str): Path to input video
        exercise_name (str): Exercise type
        combined_df (pd.DataFrame): Existing landmark data

    Returns:
        pd.DataFrame: Combined landmark data
    """
```

Código 5.10: Código para manejar el procesamiento de video y extracción de keypoints

6.4.4.2. Pipeline de evaluación

- Principales funciones de predicción y evaluación. (**predict_performance.py**)

```
def predict_performance(video_path, model_path, pca_components):  
    """  
    Complete pipeline for predicting exercise performance.  
    Args:  
        video_path (str): Path to input video  
        model_path (str): Path to trained model  
        pca_components (int): Number of PCA components  
    """
```

Código 5.11: Código de las principales funciones de predicción y evaluación

6.4.5. Pruebas

- El proyecto incluye pruebas exhaustivas, las cuales cubren:
 - Pruebas funcionales: validación de modelos, procesamiento de entrada/salida.
 - Pruebas de rendimiento: velocidad de procesamiento, uso de memoria, análisis de FPS.
 - Pruebas de robustez: manejo de errores, casos extremos.
- El conjunto de pruebas se ejecuta con el siguiente comando en la terminal:

```
python test/test_exercise_modules.py
```

Código 5.12: Comando para ejecutar el conjunto de pruebas

6.4.6. Métricas de rendimiento

- El sistema logra las siguientes métricas de rendimiento:
 - Precisión: >75% en conjuntos de datos de prueba.
 - Velocidad de procesamiento: 15+ FPS en hardware estándar.
 - Uso de memoria: Optimizado para sistemas de 4GB+.

- Ejercicios compatibles: saltar, gatear, sentarse, lanzar pelotas.

6.4.7. Solución de problemas

6.4.7.1. Problemas comunes

- Problemas de instalación de MediaPipe:

```
# Try installing specific version
pip install mediapipe==0.10.5
```

Código 5.13: Comando para realizar la instalación de MediaPipe

- Problemas de memoria:
 - Reducir la resolución de video
 - Procesar videos en lotes más pequeños
 - Aumentar la RAM del sistema
- Problemas de rendimiento:
 - Usar aceleración de GPU si está disponible
 - Reducir los componentes de PCA
 - Optimizar la velocidad de fotogramas de vídeo

6.5. Guía para Grabación de Videos

A continuación, se proporciona una guía detallada con indicaciones y recomendaciones que se deben cumplir para realizar de manera correcta las grabaciones de los ejercicios; pues, una buena calidad de grabación mejora en gran manera la calidad y precisión de los resultados obtenidos.

6.5.1. Entorno de Grabación

6.5.1.1. Iluminación

- Asegurar iluminación uniforme y suficiente en el área de grabación
- Evitar contraluz; es decir, algún objeto entre la cámara y la fuente de luz ya sea el sol o luz artificial.
- Evitar sombras que puedan provocar que se oculte alguna extremidad del niño en la grabación.
- Se recomienda realizar las grabaciones con la luz natural del sol o bien una iluminación artificial constante.
- Evitar grabaciones con iluminación insuficiente o penumbra.
- Evitar cambios bruscos de iluminación durante la grabación de los videos.
- Procurar que no haya ningún reflejo o destello que sature la imagen o no permita distinguir las extremidades del niño.

6.5.1.2. Fondo

- Fondo ideal:
 - De preferencia realizar las grabaciones en entornos con fondos simples y que hagan contraste con la ropa del niño, para así evitar que sus extremidades se confundan con el color del fondo.
 - Evitar fondos con patrones complejos o muchos colores.
 - Mantener el fondo estático en la medida de lo posible.

- Profundidad de campo:
 - Ajustar para que el niño y sus extremidades se vean nítidos.
 - Se puede desenfocar el fondo y resaltar al niño durante la grabación; sin embargo, no es estrictamente necesario.

6.5.2. Cámara y Video

6.5.2.1. Especificaciones de Cámara

- La grabación de los videos puede ser realizada con la cámara de un celular, cámara profesional (tales como las cámaras Canon), o cualquier tipo de cámara que tenga por lo menos una resolución de 480p; sin embargo, se recomienda que sea de al menos 720p.

6.5.2.2. Estabilidad de la Cámara

- Se recomienda usar trípodes o algún soporte que permita que el dispositivo con el cual se realizará la grabación de los videos se mantenga firme y estático.
- En el caso se opte por realizar la grabación sosteniendo el dispositivo con la mano, procurar sostenerlo de manera firme y estable.
- Evitar movimientos bruscos al grabar.

6.5.2.3. Calidad de Video

- Resolución:
 - Mínimo: 480p
 - Recomendado: 720p o superior
- Cuadros por Segundo (Frame Rate o FPS):
 - Mínimo: 24-30 fps

- Recomendado: 30 pfs o superior

6.5.2.4. Posición y Márgenes

- Mantener una distancia adecuada para capturar en video al niño y toda la escena en donde se desarrolla el ejercicio.
- Evitar ángulos que distorsionen la perspectiva.

6.5.2.5. Duración y Contenido

- Duración:
 - Se debe grabar suficiente contenido; es decir, el video del niño realizando el ejercicio debe tener una duración de 4 segundos por lo mínimo.
 - Evitar videos excesivamente largos que capturen material innecesario; por ejemplo, el niño terminando el ejercicio de gateo, luego se pone de pie y empieza a jugar o hacer alguna otra acción que no corresponda al ejercicio que se desea evaluar.
- Contenido relevante:
 - Asegurarse que el niño realizando el ejercicio sea claramente visible.
 - Capturar solo la realización del ejercicio.
 - Evitar grabar solamente una parte del cuerpo del niño.
 - Evitar que otras personas aparezcan en el video, por ejemplo, los docentes queriendo ayudar o mostrar cómo se hace el ejercicio al niño; pues, en el video solamente debe ser grabado el niño realizando el ejercicio propuesto.

6.6. Cartas y Memorandos

A continuación, se proporcionan las cartas, permisos y memorandos firmados, los cuales evidencian y respaldan la autorización de las directoras de cada institución afiliada a Cáritas Arequipa obtenida para la ejecución de la presente investigación. Asimismo, se adjunta la carta emitida por el Vicerrectorado de Investigación de la Universidad Católica de Santa María, mediante la cual se respalda de manera oficial el desarrollo de esta tesis ante las instituciones participantes.





**Universidad Católica
de Santa María**

“IN SCIENTIA ET FIDE ERIT FORTITUDO NOSTRA”
En la ciencia y en la fe esta nuestra fortaleza

Arequipa, 29 de noviembre del 2024

CARTA N°031-VRINV-2024-UCSM

Señor

DIRECTOR DE LA INSTITUCION “CARITAS AREQUIPA”

Presente.-

De mi mayor consideración:

Por medio de la presente, reciba un cordial saludo de la Universidad Católica de Santa María y en especial del Vicerrectorado de Investigación y asimismo hacer de su conocimiento que nuestra casa de estudios está desarrollando el Proyecto Validación y propuesta de una batería de aptitud física para evaluar a niños y adolescentes por medio visión computacional en escolares de la provincia de Arequipa.

Motivo por el cual, invitamos a su distinguida Institución para que puedan ser parte de las evaluaciones que respectan al desarrollo de los proyectos en mención. Así mismo he de indicar que los estudiantes que realizarán su actividad de “Voluntariado” serán:

- Sergio Paolo Suárez Fernández
DNI: 73874060
- Héctor Daniel Oviedo Villanueva
DNI: 70995855

Para efectos de las coordinaciones pertinentes, agradeceré se sirvan contactar con el Dr. José Sulla Torres al correo electrónico jsullato@ucsm.edu.pe o al teléfono 959950467.

Sin otro particular, por la atención que le merezca la presente, hago propicia la oportunidad para renovarle los sentimientos de mi especial consideración.

Atentamente,



DR. MÁXIMO RONDÓN RONDÓN
Vicerrector de Investigación
Universidad Católica de Santa María

MRR/VRINV
gchq.

Cáritas Diocesana de Arequipa

UN CAMINO DE AMOR Y SERVICIO

**“AÑO DEL BICENTENARIO DE LA CONSOLIDACION DE NUESTRA INDEPENDENCIA Y DE LA
CONMEMORACION DE LAS HEROICAS BATALLAS DE JUNIN Y AYACUCHO”**

MEMORANDUM Nº 026 – 2024 - (Nº01)

PARA : Prof. KATYA GRACIELA ESPINOZA CALDERÓN
Directora Encargada por Funciones
CEBE Nuestra Señora de la Consolación – Cáritas – J.D. Hunter

ASUNTO : Recolección de información de actividad motora gruesa de los estudiantes con Síndrome de Down por estudiantes de la “Universidad Católica Santa María” en la modalidad de Voluntariado.

FECHA : 17 de setiembre del 2024

Me es grato saludarla y a la vez comunicarle que los estudiantes del X semestre de la escuela Profesional de Ingeniería de Sistemas, de la UCSM, quienes realizarán la actividad en mención en calidad de voluntariado en el CEBE que usted dirige y cuyos datos detallo a continuación:

- SERGIO PAOLO SUAREZ FERNANDEZ : DNI Nº 73874060 - COD. EST. 2020803011
- HECTOR DANIEL OVIEDO VILLANUEVA : DNI Nº 70995855 - COD. EST. 2020892671

Es oportuno mencionar que la asistencia de los mencionados estudiantes serán los días especificados según cronograma, considerando como fecha de inicio el 12 de setiembre del 2024 y de término el 20 de diciembre del 2024.

Agradeceré a usted brindarles las facilidades del caso.

Atentamente,



Rdo. 24-09-24

Cáritas Diocesana de Arequipa

UN CAMINO DE AMOR Y SERVICIO

"AÑO DEL BICENTENARIO DE LA CONSOLIDACION DE NUESTRA INDEPENDENCIA Y DE LA CONMEMORACION DE LAS HEROICAS BATALLAS DE JUNIN Y AYACUCHO"

MEMORANDUM N° 027 – 2024 - (N°02)

PARA : Prof. GLORIA EDITH QUIROZ GONZALES
Directora Encargada por Funciones
CEBE María de los Remedios – Cáritas – Socabaya

ASUNTO : Recolección de información de actividad motora gruesa de los estudiantes con Síndrome de Down por estudiantes de la "Universidad Católica Santa María" en la modalidad de Voluntariado.

FECHA : 17 de setiembre del 2024

Me es grato saludarla y a la vez comunicarle que los estudiantes del X semestre de la escuela Profesional de Ingeniería de Sistemas, de la UCSM, quienes realizarán la actividad en mención en calidad de voluntariado en el CEBE que usted dirige y cuyos datos detallo a continuación:

- SERGIO PAOLO SUAREZ FERNANDEZ : DNI N° 73874060 - COD. EST. 2020803011
- HECTOR DANIEL OVIEDO VILLANUEVA : DNI N° 70995855 - COD. EST. 2020892671

Es oportuno mencionar que la asistencia de los mencionados estudiantes serán los días especificados según cronograma, considerando como fecha de inicio el 12 de setiembre del 2024 y de término el 20 de diciembre del 2024.

Agradeceré a usted brindarles las facilidades del caso.

Atentamente,



CÁRITAS DIOCESANA DE AREQUIPA

[Signature]
DIRECTOR P.E.E.C.



Cáritas Diocesana de Arequipa

UN CAMINO DE AMOR Y SERVICIO

"AÑO DEL BICENTENARIO DE LA CONSOLIDACION DE NUESTRA INDEPENDENCIA Y DE LA CONMEMORACION DE LAS HEROICAS BATALLAS DE JUNIN Y AYACUCHO"

MEMORANDUM Nº 028 – 2024 - (Nº03)

PARA : Prof. NURY BLANCA MARQUEZ PUMATANCA
Directora Encargada por Funciones
CEBE María de la Esperanza – Cáritas – Characato

ASUNTO : Recolección de información de actividad motora gruesa de los estudiantes con Síndrome de Down por estudiantes de la "Universidad Católica Santa María" en la modalidad de Voluntariado.

FECHA : 17 de setiembre del 2024

Me es grato saludarla y a la vez comunicarle que los estudiantes del X semestre de la escuela Profesional de Ingeniería de Sistemas, de la UCSM, quienes realizarán la actividad en mención en calidad de voluntariado en el CEBE que usted dirige y cuyos datos detallo a continuación:

- SERGIO PAOLO SUAREZ FERNANDEZ : DNI Nº 73874060 - COD. EST. 2020803011
- HECTOR DANIEL OVIEDO VILLANUEVA : DNI Nº 70995855 - COD. EST. 2020892671

Es oportuno mencionar que la asistencia de los mencionados estudiantes serán los días especificados según cronograma, considerando como fecha de inicio el 12 de setiembre del 2024 y de término el 20 de diciembre del 2024.

Agradeceré a usted brindarles las facilidades del caso.

Atentamente,



DIRECTOR P.E.E.C.



Cáritas Diocesana de Arequipa

UN CAMINO DE AMOR Y SERVICIO

“AÑO DEL BICENTENARIO DE LA CONSOLIDACION DE NUESTRA INDEPENDENCIA Y DE LA
CONMEMORACION DE LAS HEROICAS BATALLAS DE JUNIN Y AYACUCHO”

MEMORANDUM N° 029 – 2024 - (N°04)

PARA : Prof. ELVIRA GRACIELA CHAVEZ NUÑEZ
Directora Encargada por Funciones
CEBE Santa Ana – Cáritas – Paucarpata

ASUNTO : Recolección de información de actividad motora gruesa de los estudiantes con
Síndrome de Down por estudiantes de la “Universidad Católica Santa
María” en la modalidad de Voluntariado.

FECHA : 17 de setiembre del 2024

Me es grato saludarla y a la vez comunicarle que los estudiantes del X semestre de la escuela Profesional de Ingeniería de Sistemas, de la UCSM, quienes realizarán la actividad en mención en calidad de voluntariado en el CEBE que usted dirige y cuyos datos detallo a continuación:

- SERGIO PAOLO SUAREZ FERNANDEZ : DNI N° 73874060 - COD. EST. 2020803011
- HECTOR DANIEL OVIEDO VILLANUEVA : DNI N° 70995855 - COD. EST. 2020892671

Es oportuno mencionar que la asistencia de los mencionados estudiantes serán los días especificados según cronograma, considerando como fecha de inicio el 12 de setiembre del 2024 y de término el 20 de diciembre del 2024.

Agradeceré a usted brindarles las facilidades del caso.

Atentamente,



DIRECCIÓN
DIRECTOR P.E.E.C.

Elvira G. Chávez Nuñez
Elvira G. Chávez Nuñez
CEBE "SANTA ANA" - CARIT.
DIRECTORA

03/10/2024

Cáritas Diocesana de Arequipa

UN CAMINO DE AMOR Y SERVICIO

“AÑO DEL BICENTENARIO DE LA CONSOLIDACION DE NUESTRA INDEPENDENCIA Y DE LA CONMEMORACION DE LAS HEROICAS BATALLAS DE JUNIN Y AYACUCHO”

MEMORANDUM Nº 030 – 2024 - (Nº05)

PARA : Prof. MIRIAM ELSIE ARAGON ZEVALLOS
Directora Encargada por Funciones
CEBE Nuestra Señora del Perpetuo Socorro – Cáritas – Miguel Grau

ASUNTO : Recolección de información de actividad motora gruesa de los estudiantes con Síndrome de Down por estudiantes de la “Universidad Católica Santa María” en la modalidad de Voluntariado.

FECHA : 17 de setiembre del 2024

Me es grato saludarla y a la vez comunicarle que los estudiantes del X semestre de la escuela Profesional de Ingeniería de Sistemas, de la UCSM, quienes realizarán la actividad en mención en calidad de voluntariado en el CEBE que usted dirige y cuyos datos detallo a continuación:

- SERGIO PAOLO SUAREZ FERNANDEZ : DNI Nº 73874060 - COD. EST. 2020803011
- HECTOR DANIEL OVIEDO VILLANUEVA : DNI Nº 70995855 - COD. EST. 2020892671

Es oportuno mencionar que la asistencia de los mencionados estudiantes serán los días especificados según cronograma, considerando como fecha de inicio el 12 de setiembre del 2024 y de término el 20 de diciembre del 2024.

Agradeceré a usted brindarles las facilidades del caso.

Atentamente,



DIOCESANA DE AREQUIPA

DIRECTOR P.E.E.C.



Miriam E. Aragón Zevallos
DIRECTORA

Recibido
09-10-2024

Cáritas Diocesana de Arequipa

UN CAMINO DE AMOR Y SERVICIO

"AÑO DEL BICENTENARIO DE LA CONSOLIDACION DE NUESTRA INDEPENDENCIA Y DE LA CONMEMORACION DE LAS HEROICAS BATALLAS DE JUNIN Y AYACUCHO"

MEMORANDUM N° 031 – 2024 - (N°06)

PARA : Prof. LORENA ESTHER ASPILCUETA HURTADO
Directora Encargada por Funciones
CEBE Señor de los Milagros– Cáritas – Mariano Melgar

ASUNTO : Recolección de información de actividad motora gruesa de los estudiantes con Síndrome de Down por estudiantes de la "Universidad Católica Santa María" en la modalidad de Voluntariado.

FECHA : 17 de setiembre del 2024

Me es grato saludarla y a la vez comunicarle que los estudiantes del X semestre de la escuela Profesional de Ingeniería de Sistemas, de la UCSM, quienes realizarán la actividad en mención en calidad de voluntariado en el CEBE que usted dirige y cuyos datos detallo a continuación:

- SERGIO PAOLO SUAREZ FERNANDEZ : DNI N° 73874060 - COD. EST. 2020803011
- HECTOR DANIEL OVIEDO VILLANUEVA : DNI N° 70995855 - COD. EST. 2020892671

Es oportuno mencionar que la asistencia de los mencionados estudiantes serán los días especificados según cronograma, considerando como fecha de inicio el 12 de setiembre del 2024 y de término el 20 de diciembre del 2024.

Agradeceré a usted brindarles las facilidades del caso.

Atentamente,



Cáritas Diocesana de Arequipa

UN CAMINO DE AMOR Y SERVICIO

“AÑO DEL BICENTENARIO DE LA CONSOLIDACION DE NUESTRA INDEPENDENCIA Y DE LA CONMEMORACION DE LAS HEROICAS BATALLAS DE JUNIN Y AYACUCHO”

MEMORANDUM Nº 032- 2024 - (Nº07)

PARA : Prof. RICARDINA MARIA ORTIZ ANCO
Directora Encargada por Funciones
CEBE San Martin de Porres – Cáritas – Miraflores

ASUNTO : Recolección de información de actividad motora gruesa de los estudiantes con Síndrome de Down por estudiantes de la “Universidad Católica Santa María” en la modalidad de Voluntariado.

FECHA : 17 de setiembre del 2024

Me es grato saludarla y a la vez comunicarle que los estudiantes del X semestre de la escuela Profesional de Ingeniería de Sistemas, de la UCSM, quienes realizarán la actividad en mención en calidad de voluntariado en el CEBE que usted dirige y cuyos datos detallo a continuación:

- SERGIO PAOLO SUAREZ FERNANDEZ : DNI Nº 73874060 - COD. EST. 2020803011
- HECTOR DANIEL OVIEDO VILLANUEVA : DNI Nº 70995855 - COD. EST. 2020892671

Es oportuno mencionar que la asistencia de los mencionados estudiantes serán los días especificados según cronograma, considerando como fecha de inicio el 12 de setiembre del 2024 y de término el 20 de diciembre del 2024.

Agradeceré a usted brindarles las facilidades del caso.

Atentamente,



Ricardina Ortiz Anco
Ricardina Ortiz Anco
DIRECTORA
C.M. 1029406555

Recibido 23/10/2024

Cáritas Diocesana de Arequipa

UN CAMINO DE AMOR Y SERVICIO

“AÑO DEL BICENTENARIO DE LA CONSOLIDACION DE NUESTRA INDEPENDENCIA Y DE LA CONMEMORACION DE LAS HEROICAS BATALLAS DE JUNIN Y AYACUCHO”

MEMORANDUM N° 033- 2024 - (N°08)

PARA : Prof. VIANNEY MADELEY PAREDES VERA
Directora Encargada por Funciones
CEBE Nuestra Señora de La Candelaria – Cáritas – Cayma
Celular N° 983771686

ASUNTO : Recolección de información de actividad motora gruesa de los estudiantes con Síndrome de Down por estudiantes de la “Universidad Católica Santa María” en la modalidad de Voluntariado.

FECHA : 17 de setiembre del 2024

Me es grato saludarla y a la vez comunicarle que los estudiantes del X semestre de la escuela Profesional de Ingeniería de Sistemas, de la UCSM, quienes realizarán la actividad en mención en calidad de voluntariado en el CEBE que usted dirige y cuyos datos detallo a continuación:

- SERGIO PAOLO SUAREZ FERNANDEZ : DNI N° 73874060 - COD. EST. 2020803011
- HECTOR DANIEL OVIEDO VILLANUEVA : DNI N° 70995855 - COD. EST. 2020892671

Es oportuno mencionar que la asistencia de los mencionados estudiantes serán los días especificados según cronograma, considerando como fecha de inicio el 12 de setiembre del 2024 y de término el 20 de diciembre del 2024.

Agradeceré a usted brindarles las facilidades del caso.

Atentamente,



Vianney Paredes Vera
DIRECTORA
CM. 1045208910


Recibido
24/10/24


Cesar Ariaga Pacheco
DIRECTOR P.E.E.C.