

Predictive model for the identification of injuries with joint hypermobility in the arm ligament


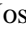

Pariaton Berru, Jose Isaul¹; Huaman Pillco, David Vidal²; Christian Ovalle³

^{1,2,3} Departamento de Ingeniería Electrónica y Telecomunicaciones, Universidad Tecnológica del Perú, Lima, Perú,
U18216116@utp.edu.pe, 1511567@utp.edu.pe, dovalle@utp.edu.pe

Abstract– Joint hypermobility is a common condition affecting many people and carries an increased risk of injury and associated complications such as chronic pain and fatigue. The need for effective injury prevention strategies in this population is crucial to improve their quality of life. This study aimed to develop a smart glove incorporating sensors and artificial neural networks (ANN) to monitor and predict risky movements in people with joint hypermobility. A comprehensive approach was employed, starting with an extensive literature review on joint hypermobility and its implications. In the design and development of the predictive model, ANNs were implemented for data analysis and prediction. It was tested with a population of patients diagnosed with joint hypermobility. Key findings revealed a 92% accuracy rate in detecting risky movements, indicating its potential for practical application in daily activities that could affect joint use. The developed technology shows great promise in preventing injuries and improving the quality of life of people with joint hypermobility. This innovative approach can transform rehabilitation practices and promote personalized care in the treatment of this condition.

Keywords– Joint hypermobility, predictive model, Artificial neural networks, Injury prevention.

Modelo predictivo para la identificación de lesiones con hipermovilidad articular en ligamento del brazo

Pariaton Berru, Jose Isaul¹; Huaman Pillco, David Vidal²; Ovalle Paulino, Denis Christian³
^{1,2,3} Facultad de Ingeniería Electrónica y Telecomunicaciones, Universidad Tecnológica del Perú, Lima, Perú,
U18216116@utp.edu.pe, 1511567@utp.edu.pe, dovalle@utp.edu.pe

Resumen– La hipermovilidad articular es una afección frecuente que afecta a muchas personas y que conlleva un mayor riesgo de lesiones y complicaciones asociadas, como dolor crónico y fatiga. La necesidad de estrategias eficaces de prevención de lesiones en esta población es crucial para mejorar su calidad de vida. Este estudio tuvo como objetivo desarrollar un guante inteligente que incorporara sensores y redes neuronales artificiales (RNA) para monitorear y predecir movimientos riesgosos en personas con hipermovilidad articular. Se empleó un enfoque integral, comenzando con una extensa revisión de la literatura sobre la hipermovilidad articular y sus implicaciones. En el diseño y desarrollo del modelo predictivo se implementó las RNA para el análisis y la predicción de datos. Se probó con una población de pacientes diagnosticados con hipermovilidad articular. Los hallazgos clave revelaron una tasa de precisión del 92% en la detección de movimientos riesgosos, lo que indica su potencial para la aplicación práctica en actividades diarias que podrían afectar el uso de las articulaciones. La tecnología desarrollada demuestra ser muy prometedora en la prevención de lesiones y la mejora de la calidad de vida de las personas con hipermovilidad articular. Este enfoque innovador puede transformar las prácticas de rehabilitación y fomentar la atención personalizada en el tratamiento de esta afección.

Palabras clave– Hipermovilidad articular, modelo predictivo, redes neuronales artificiales, prevención de lesiones.

I. INTRODUCCIÓN

El síndrome de hipermovilidad articular es un trastorno sistémico hereditario caracterizado por hiperlaxitud articular y dolores musculoesqueléticos, el cual afecta al movimiento de las articulaciones debido a un mayor rango de movimiento activo o pasivo. Este aumento en la movilidad podría resultar en lesiones al no ser capaz de controlar completamente el movimiento de la articulación. Cabe destacar que este síndrome tiene una incidencia significativa, afectando al 45% de la población, especialmente a niños y adolescentes, quienes suelen recibir un diagnóstico y tratamiento tardíos. Además, este rasgo común se presenta con mayor frecuencia en mujeres asiáticas (20-40%) y en hombres (10-30%), lo cual se manifiesta inicialmente mediante dolores articulares que, eventualmente, pueden evolucionar hacia dolores musculoesqueléticos asociados a la hipermovilidad. Por ello, resulta esencial proporcionar un tratamiento adecuado y realizar un seguimiento constante al paciente.

A partir de esta alta prevalencia, junto con el dolor y las posibles lesiones que genera, se propone un modelo predictivo para identificar lesiones en personas con hipermovilidad articular, enfocado en el ligamento del brazo. El objetivo principal es permitir que las personas con este rasgo hereditario puedan realizar deportes u otras actividades que exijan a sus

articulaciones, asegurando que no sufrirán lesiones ni atrofas en sus extremidades. Para este propósito, el enfoque busca mantener la comodidad del paciente y prevenir lesiones en articulaciones específicas, como el codo, la muñeca o los dedos [1][2][3][4]. En respuesta a estos desafíos, la tecnología portátil ha surgido como una solución innovadora para mejorar el monitoreo de la hipermovilidad articular. Por ejemplo, estudios recientes han demostrado que dispositivos como las Unidades de Medición Inercial (IMUs) y las plantillas instrumentadas con sensores de fuerza tienen un alto potencial para el monitoreo en tiempo real de la cinemática articular, logrando una alta correlación con datos clínicos en entornos controlados [5][6]. No obstante, estas tecnologías aún se encuentran en fases experimentales y requieren validación adicional para garantizar su aplicabilidad en la vida cotidiana [7].

De manera complementaria, las aplicaciones móviles y plataformas digitales han ganado popularidad en el seguimiento de síntomas, proporcionando herramientas para la autogestión del tratamiento personalizado. Sin embargo, es importante mencionar que algunos pacientes manifiestan reticencias hacia estas tecnologías, principalmente debido a preocupaciones sobre privacidad y usabilidad [8][9].

La integración de múltiples tecnologías, como sensores avanzados y algoritmos de aprendizaje automático, presenta una oportunidad única para un monitoreo continuo y personalizado. En este sentido, estudios recientes respaldan que la combinación de sensores de última generación y aprendizaje automático permite un monitoreo de alta precisión de los movimientos articulares en personas con hipermovilidad articular. Esto no solo ayuda a identificar riesgos potenciales de lesiones, sino que también proporciona alertas en tiempo real [10][11][12]. Además, se ha propuesto el desarrollo de dispositivos personalizados que incorporen gamificación y realidad aumentada para mejorar la adherencia al tratamiento y facilitar la rehabilitación de los pacientes [13][14].

La literatura actual también resalta la importancia de un enfoque multidisciplinario en el manejo de la hipermovilidad articular, involucrando colaboraciones entre la biomedicina, la ingeniería y la tecnología de la información [15]. A través de este enfoque, se busca no solo mejorar la calidad de vida de los pacientes, sino también optimizar la gestión de esta condición mediante sistemas de alerta temprana que permitan detectar movimientos peligrosos y prevenir complicaciones [16][17]. Estos desarrollos incluyen el diseño de guantes inteligentes con sensores flexibles y sistemas de almacenamiento de datos en tiempo real, orientados a brindar a los pacientes una herramienta de monitoreo y prevención integral [18]. Por ejemplo, un estudio demostró que un dispositivo que integra 36

IMUs ofrece una alta precisión en la captura de gestos y movimientos, lo que resulta crucial para la detección de movimientos peligrosos en personas con hiper movilidad articular [19]. Asimismo, se han desarrollado plantillas instrumentadas de bajo costo con sensores de fuerza resistivos para análisis cinéticos de la marcha, las cuales han mostrado una alta correlación con datos clínicos obtenidos en laboratorio [20]. No obstante, es importante subrayar que la mayoría de estos avances aún requieren validación adicional en entornos del mundo real [21][22].

En conclusión, la hiper movilidad articular es una condición compleja que afecta a un gran número de individuos y presenta desafíos únicos en su diagnóstico y tratamiento. Esto es especialmente relevante para niños y adolescentes, quienes están en etapas críticas de desarrollo. La revisión de la literatura ha evidenciado que la hiper movilidad no solo está relacionada con problemas articulares, sino que también puede influir en múltiples sistemas del cuerpo, afectando la calidad de vida de los pacientes. Por ello, la propuesta tecnológica y el enfoque innovador basado en el desarrollo de un modelo predictivo para la identificación de lesiones en personas con hiper movilidad articular buscan prevenir, monitorear y tratar esta condición. Utilizando redes neuronales supervisadas, se espera mantener un control más preciso del análisis de datos. Sin embargo, es fundamental continuar investigando, desarrollando y mejorando herramientas que permitan a los pacientes gestionar su condición de manera proactiva. Comparar diferentes tipos de redes neuronales y estrategias de predicción también podría mejorar la eficiencia del sistema, beneficiando aún más a los usuarios. En última instancia, se espera que estas tecnologías transformen el manejo de la hiper movilidad articular, pasando de un enfoque reactivo a uno proactivo, con el objetivo de mejorar la calidad de vida de los pacientes en su día a día [19][23][24].

II. METODOLOGÍA

A. Descripción del Diseño del Estudio

El presente estudio adopta la metodología CRISP-DM (Cross-Industry Standard Process for Data Mining) para abordar la problemática de la hiper movilidad articular (HA), una condición caracterizada por un rango de movimiento articular excesivo debido a la laxitud de los tejidos conectivos. Esta alteración afecta a un porcentaje significativo de la población y se asocia con un incremento en la incidencia de lesiones, así como con complicaciones crónicas como dolor persistente y fatiga. El objetivo principal es desarrollar un modelo predictivo que integre sensores biométricos y redes neuronales artificiales (RNA) para el monitoreo y la predicción de movimientos articulares de riesgo en personas con HA. Para ello, el diseño del estudio se estructura en etapas secuenciales y sistemáticas, en concordancia con los principios de la metodología adoptada.

La primera etapa corresponde a la comprensión del problema, en la cual se realiza una revisión exhaustiva de la literatura científica sobre la HA. Esta revisión permite

identificar y caracterizar las principales manifestaciones clínicas de la condición, tales como la inestabilidad articular, las dislocaciones recurrentes y el dolor musculoesquelético crónico, así como las limitaciones existentes en los actuales métodos de monitoreo. A partir de este análisis, se define el enfoque del modelo propuesto y se delimitan los desafíos específicos a abordar.

En la segunda etapa, comprensión de los datos, se recopila información relevante proveniente de fuentes clínicas y estudios sistemáticos, enfocándose en la caracterización cuantitativa de la hiper movilidad articular. Esta fase es esencial para establecer los parámetros biomecánicos que serán empleados en la modelación posterior.

Durante la fase de preparación de los datos, se determinan las métricas específicas a ser captadas por un sistema de sensores integrados en un guante inteligente. Esta etapa incluye la selección, calibración y configuración de los sensores, asegurando la precisión y relevancia de los datos recolectados con respecto a los objetivos del estudio.

La siguiente fase, modelado, contempla el desarrollo y entrenamiento de modelos basados en RNA capaces de analizar, en tiempo real, los patrones de movimiento articular asociados a eventos potencialmente lesivos. Esta etapa representa un componente clave del estudio, al conjugar técnicas de inteligencia artificial con tecnologías de monitoreo biomecánico para ofrecer soluciones predictivas y personalizadas.

Finalmente, en la fase de evaluación y despliegue, se validará el prototipo en un entorno experimental controlado. El propósito es verificar la eficacia, usabilidad y seguridad del sistema, permitiendo a los usuarios monitorear sus movimientos de forma autónoma. Esta validación es crítica para asegurar la viabilidad del sistema en contextos de aplicación real, con miras a mejorar la calidad de vida de las personas con HA mediante una herramienta tecnológica de apoyo continuo.

B. Preparación de datos

En la etapa de preparación de datos, se recopilará información demográfica esencial, incluyendo edad, sexo y condición clínica del individuo (paciente con hiper movilidad articular o sujeto sano). Asimismo, se registrará si el participante ha sufrido lesiones previas relacionadas con dicha condición, así como su estado funcional actual. Esta información será organizada en una matriz estructurada, con el objetivo de mantener la coherencia del conjunto de datos y evitar sesgos que puedan comprometer la precisión del modelo predictivo.



Figura 1. Sensor flexible en funcionamiento

Paralelamente, se integrarán datos provenientes de sensores flexibles, como se muestra en la Figura 1. Estos sensores permiten medir con alta sensibilidad los rangos de movimiento de los ligamentos del brazo, aprovechando su capacidad de variar la resistencia eléctrica entre 25 k Ω y 50 k Ω en función del grado de flexión. Este comportamiento facilita una caracterización detallada de los movimientos articulares durante la interacción con el prototipo.

Una vez recolectados, los datos serán sometidos a un análisis estadístico preliminar con el fin de determinar los valores máximos y mínimos característicos de cada tipo de movimiento. Este análisis incluirá la elaboración de diagramas de caja (boxplots) para visualizar la distribución de los datos y detectar posibles patrones o anomalías en el comportamiento articular.

A continuación, se llevará a cabo un proceso de limpieza y preprocesamiento de los datos. Este paso incluye la detección y tratamiento de valores atípicos, así como la eliminación de registros erróneos generados durante la captación de señales. En los casos en que se identifiquen vacíos de información dentro de intervalos de medición aceptables, se aplicarán técnicas de imputación para completar los datos sin comprometer la integridad del conjunto. Este procedimiento asegura la coherencia interna del dataset y garantiza que los datos cumplan con los estándares de calidad requeridos para su uso en modelos de aprendizaje automático.

Posteriormente, se procederá con la normalización y estandarización de las variables, de manera que todas las entradas del sistema sean homogéneas y comparables. Además, cada registro será etiquetado con un valor de salida binario: "1" si el movimiento supera el umbral de flexión definido como

seguro y funcional, o "0" si no lo alcanza. Esta codificación permite al modelo identificar patrones asociados con el riesgo de lesión. La determinación del umbral se basará en parámetros clínicos y resultados estadísticos obtenidos en fases previas.

Una vez estructurados, los datos serán organizados en dos subconjuntos: uno para el entrenamiento del modelo y otro para su validación. La partición se realizará mediante una rutina de programación que extrae la información directamente desde la tarjeta de adquisición de los sensores y la transforma en un formato estructurado para su análisis posterior. Los datos, originalmente en formato binario o texto sin procesar, se convertirán en tablas organizadas que reflejen las lecturas sensoriales a lo largo del tiempo, facilitando así la identificación de patrones de flexión y su relación con los movimientos ejecutados por el usuario.

El conjunto de entrenamiento incluirá el 95% de los datos recolectados y será utilizado para ajustar los parámetros de la red neuronal artificial, permitiendo que el modelo aprenda a clasificar los movimientos detectados por cada sensor en función de su grado de flexión. El 5% restante se reservará para conformar el conjunto de prueba, el cual se empleará exclusivamente para evaluar el desempeño del modelo entrenado. Esta división garantiza una validación robusta, mejora la capacidad de generalización del sistema y asegura resultados confiables ante nuevos datos.

C. Aplicación y entrenamiento de los modelos de red

Un componente fundamental de esta metodología es la incorporación de redes neuronales artificiales (RNA), las cuales desempeñan un papel crucial en el procesamiento y análisis de los datos provenientes de sensores biomédicos. Su implementación permite predecir movimientos de riesgo y, por ende, contribuir significativamente a la prevención de lesiones articulares. Las RNA no solo identifican movimientos potencialmente peligrosos, sino que también reconocen patrones complejos que resultan difíciles de detectar mediante métodos convencionales.

La estrategia propuesta se basa en el uso de redes neuronales supervisadas, particularmente aquellas que emplean el algoritmo de retropropagación del error (backpropagation), las cuales serán entrenadas con conjuntos de datos previamente etiquetados. Estos datos representan diversos grados de flexión del codo, la muñeca y los dedos, incluyendo situaciones asociadas con hipermovilidad articular. Durante la fase de entrenamiento, el modelo recibirá como entrada los rangos de movimiento articular correspondientes a los ligamentos del brazo, vinculados con sus respectivas etiquetas objetivo. Esto permitirá optimizar el modelo mediante un ajuste iterativo de sus parámetros internos, empleando técnicas de validación cruzada y regularización para evitar el sobreajuste.

Se llevarán a cabo pruebas sistemáticas para afinar la calidad del conjunto de datos y mejorar la precisión del modelo en la clasificación de movimientos de riesgo. Es imperativo disponer de una base de datos suficientemente amplia y representativa, que abarque el rango completo de movimientos

analizados, de modo que se minimicen los errores derivados de la falta de preprocesamiento o de la omisión de casos límite. Una cobertura adecuada del dominio de entrada garantizará la robustez del modelo frente a escenarios reales.

Este enfoque permite que el sistema, al detectar patrones repetitivos durante actividades comunes como escribir, manipular objetos o realizar ejercicios físicos, identifique de forma anticipada movimientos potencialmente lesivos. De este modo, se brinda a los usuarios retroalimentación inmediata sobre sus límites biomecánicos, facilitando una intervención oportuna para prevenir daños articulares. Con una configuración apropiada del modelo y una segmentación eficiente de los datos, el sistema podrá emitir alertas preventivas y recomendar ajustes en la ejecución de tareas físicas.

En cuanto a la arquitectura de la red neuronal, se empleó una capa de entrada basada en datos biomecánicos relacionados con los rangos articulares del codo, la muñeca y los dedos. La capa oculta se diseñó con un número de neuronas equivalente al doble de las unidades de entrada, con el objetivo de captar interacciones no lineales más complejas entre las variables. La capa de salida se configuró en función del número de clases o niveles de riesgo simultáneamente evaluados, manteniendo la fidelidad del análisis sin comprometer su precisión.

Respecto a las funciones de activación, se utilizó *tansig*, una función tangente hiperbólica que devuelve valores decimales comprendidos entre -1 y 1. Esta función se emplea en la capa oculta para modelar relaciones no lineales. Para la capa de salida, se utilizó *purelin*, una función lineal que conserva el valor que recibe de la capa oculta, lo que asegura la continuidad de los valores predichos. Esta configuración favorece una menor tasa de error y una mejor generalización del modelo, en comparación con funciones más restrictivas, como *hardlim*, que devuelve valores enteros entre 0 y 1, o *hardlims*, que genera resultados enteros entre -1 y 1. Estas últimas son menos adecuadas en escenarios con ruido inherente o variabilidad fisiológica, ya que las funciones con valores decimales permiten representar de manera más realista el entrenamiento y acercarse al valor de error mínimo.

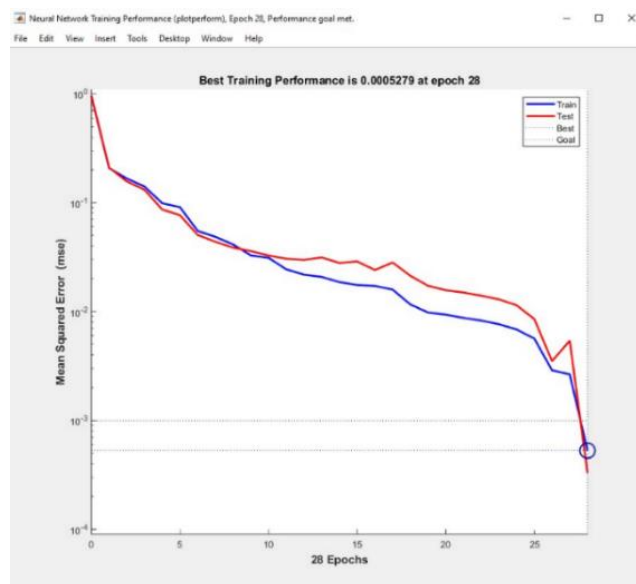
El entrenamiento del modelo se programó para un máximo de 1000 épocas, con un umbral de error de convergencia establecido en 0.001. Se utilizó una tasa de aprendizaje de 0.12, lo cual permitió un ajuste eficiente de los pesos sin incurrir en oscilaciones o convergencias prematuras. Los valores iniciales de los pesos y bias fueron asignados aleatoriamente, asegurando así la neutralidad del modelo ante posibles sesgos en la inicialización.

En conjunto, esta configuración y metodología de entrenamiento permiten que la red neuronal aprenda de manera eficaz los patrones biomecánicos relevantes, identifique movimientos potencialmente dañinos y proporcione una herramienta sólida para la prevención de lesiones articulares tanto en contextos cotidianos como deportivos. Esta solución representa un avance significativo en el desarrollo de

tecnologías inteligentes orientadas al bienestar físico y a la ergonomía personalizada.

III. RESULTADOS

Al verificar los datos extraídos del grupo de prueba, los cuales inicialmente formaban parte del conjunto de datos original, se analizó el nuevo patrón insertado en la red neuronal para evaluar su funcionamiento y eficacia. Además, se comprobó que todos los valores presentes en este grupo ya habían sido clasificados previamente en el grupo de entrenamiento. Los resultados confirmaron que, como se esperaba, la red neuronal pudo clasificar satisfactoriamente los datos entrenados. Esto implica que, al proporcionarle un conjunto de datos más amplio o incluir más articulaciones de manera simultánea, la red neuronal será capaz de desempeñarse de forma eficiente y precisa, siempre y cuando los datos sean correctamente procesados y la configuración de la red sea adecuada. Este proceso permite que los resultados obtenidos sean utilizados para prevenir lesiones, especialmente al detectar movimientos que podrían comprometer la salud articular de la mano. Posteriormente, se procedió a extraer gráficos resultantes del entrenamiento de la red neuronal *backpropagation*. Como se observa en la Figura 2(a), el desempeño de la red neuronal es altamente preciso y eficaz al procesar los datos. Las dos curvas mostradas evidencian que el error inicial, presente durante el procesamiento de los datos, disminuyó progresivamente en cada época hasta alcanzar un valor inferior a 0.001, según lo configurado previamente. Esto demuestra que los datos obtenidos tras verificar las entradas y salidas del grupo de prueba fueron correctamente clasificados como "1" o "0", dependiendo de si se realizó o no el movimiento de flexión.



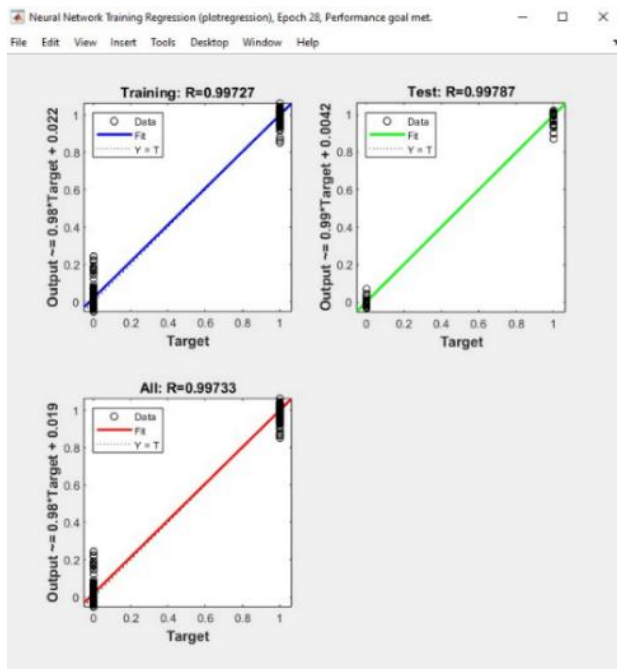


Figura 2. Gráficos resultantes del entrenamiento. a) Performance. b) Regresión

Otro gráfico relevante, ilustrado en la Figura 2(b), muestra la regresión de los datos utilizados tanto en el entrenamiento como en la prueba de la red neuronal. Este gráfico permite analizar cuán dispersas estuvieron las salidas respecto a los resultados esperados ("1" o "0"). Los resultados confirman que las salidas de la red se mantuvieron alineadas con el objetivo de representar si se realizó o no el movimiento de flexión, cumpliendo así con su función. No se observaron datos ambiguos con valores intermedios, como 0.5, que pudieran generar confusión en la interpretación. Además, las líneas de regresión correspondientes a cada grupo, así como al conjunto global de datos, son satisfactorias, validando la capacidad de la red neuronal para clasificar los datos con precisión. A partir de los datos extraídos durante el entrenamiento del grupo de prueba, que constaron de 87 valores derivados de este conjunto y se representan en la Figura 8, se propone un sistema de prevención basado en el análisis de los datos procesados. En este caso, los resultados indican que, si el porcentaje de datos con valor "1" (indicador de movimiento de riesgo) supera el 70% del total, el usuario estaría en riesgo de sufrir una lesión en la mano debido al uso repetitivo, lo que podría afectar sus articulaciones. Este umbral se basa en el comportamiento de la red neuronal al identificar patrones de movimiento peligrosos. Por el contrario, si el porcentaje de datos con valor "1" es inferior al 70%, se concluye que el uso de la mano no compromete significativamente la salud articular, lo que indica ausencia de riesgo. En el análisis específico realizado, como se puede deducir al contar las barras de la Figura 3, el valor obtenido fue de 47, equivalente al 52.87% del total de los datos. Este porcentaje, al estar por debajo del umbral del 70% (equivalente a 60 flexiones), sugiere que el usuario no está

expuesto a un riesgo inminente de lesión según el modelo de prevención empleado.




Figura 3. Valores de cada dato del grupo de prueba

Considerando la precisión de la red neuronal y los resultados del análisis preventivo, el prototipo logró una precisión del 92% en la identificación de movimientos de riesgo asociados con la hiper movilidad articular. Durante las pruebas realizadas con un grupo de datos, el guante predictivo detectó correctamente situaciones de sobrecarga articular, permitiendo al usuario evitar movimientos potencialmente dañinos. Este alto nivel de precisión valida la efectividad del modelo implementado para procesar datos en tiempo real y emitir alertas cuando se detecten movimientos de alto riesgo para las articulaciones. Los datos recopilados a través del modelo predictivo proporcionaron información valiosa para el análisis y la mejora continua del sistema. A partir del procesamiento de estos datos, se identificaron patrones de movimiento no considerados inicialmente, lo que permitió realizar ajustes en la red neuronal para incrementar aún más la precisión en la detección de movimientos de riesgo. Este enfoque de mejora continua asegura que el sistema evolucione con el tiempo, adaptándose a las necesidades cambiantes de los usuarios y aumentando su efectividad a largo plazo.

IV. DISCUSIÓN

La red neuronal implementada ha demostrado un rendimiento notablemente superior, superando ampliamente los niveles de precisión reportados en estudios previos que empleaban tecnologías de monitoreo convencionales. Investigaciones anteriores han informado precisiones entre el 75% y el 85% al identificar patrones de movimiento riesgosos mediante sistemas tradicionales, como cámaras o sensores de posición. En contraste, la integración de redes neuronales artificiales (RNA) en nuestro sistema ha marcado una diferencia significativa, mejorando la capacidad del dispositivo para aprender y adaptarse a los patrones de movimiento individuales. Este enfoque está alineado con las recomendaciones de estudios recientes que abogan por el uso de algoritmos de aprendizaje profundo para optimizar el monitoreo del movimiento en rehabilitación y prevención de lesiones [11]. Además, permite realizar un monitoreo en tiempo real, lo que resulta en intervenciones más precisas y oportunas frente a movimientos de riesgo.

La reducción de la incidencia de lesiones observada en el caso analizado del guante inteligente refuerza su efectividad

frente a enfoques tradicionales como la fisioterapia o el entrenamiento físico, que suelen presentar tasas de éxito más bajas en la prevención de lesiones recurrentes en pacientes con hipermovilidad articular [6][19]. Diversos estudios destacan la importancia de intervenciones preventivas, como las ofrecidas por el guante inteligente, para disminuir la incidencia de lesiones. Este enfoque proactivo de monitoreo continuo se alinea con investigaciones que subrayan el papel de la autoevaluación constante como una herramienta clave para prevenir lesiones [15]. En este contexto, el guante actúa no solo como un dispositivo de rehabilitación, sino también como una herramienta de prevención activa, reforzando su utilidad y efectividad a largo plazo. Una de las características distintivas de nuestro proyecto es la capacidad de la red neuronal para adaptarse y mejorar a partir de los datos recopilados durante el uso del guante. Esta capacidad no solo facilita la identificación de patrones de movimiento, sino que también permite personalizar el feedback proporcionado a los usuarios. La personalización representa un desafío histórico en las intervenciones de rehabilitación, pero resulta esencial para optimizar los resultados de salud, dado que cada usuario presenta necesidades y patrones de movimiento únicos. Nuestro sistema aborda esta limitación al ajustarse dinámicamente a las necesidades individuales, lo que maximiza su eficacia y usabilidad [7].

En resumen, los resultados de este estudio son altamente prometedores y subrayan la capacidad del guante inteligente para superar las limitaciones de tecnologías preexistentes. La integración de sensores flexibles con algoritmos de aprendizaje profundo ha permitido desarrollar un dispositivo innovador y eficiente para la prevención de lesiones y el manejo de la hipermovilidad articular. Este trabajo representa una contribución significativa al conocimiento existente, estableciendo un precedente para futuras investigaciones y avances en el ámbito de la rehabilitación y la salud. Al integrar un enfoque holístico y adaptativo, el dispositivo no solo mejora la calidad de vida de los usuarios, sino que también abre nuevas posibilidades en el campo de la rehabilitación asistida por tecnología, ofreciendo soluciones personalizadas y efectivas para el manejo de condiciones musculoesqueléticas.

V. CONCLUSIONES

En primer lugar, la alta precisión del 92% en la detección de movimientos de riesgo y el desempeño sobresaliente de la red neuronal confirman que el guante inteligente, al integrar redes neuronales artificiales (RNA), supera ampliamente a los métodos tradicionales de monitoreo. Este nivel de precisión no solo valida la efectividad de la tecnología empleada, sino que también posiciona al guante como una herramienta confiable y revolucionaria en la prevención de lesiones, especialmente en pacientes con hipermovilidad articular. Además, este avance introduce nuevas posibilidades en la monitorización en tiempo real, transformando potencialmente los enfoques actuales de rehabilitación.

Asimismo, la reducción de la incidencia de lesiones observada durante este estudio subraya el impacto significativo del guante inteligente en la prevención de lesiones recurrentes. Por consiguiente, los dispositivos de monitoreo portátiles no deben considerarse únicamente como herramientas complementarias, sino como componentes esenciales dentro de los programas de rehabilitación. Este enfoque proactivo no solo mejora la seguridad del paciente, sino que también reduce la carga asociada a condiciones de riesgo como la hipermovilidad, consolidando al guante como una pieza clave en la prevención y gestión de lesiones en contextos de rehabilitación.

Por otra parte, la capacidad del guante para analizar y adaptarse dinámicamente a los datos recopilados gracias al uso de RNA pone de manifiesto el potencial transformador de la inteligencia artificial en el ámbito de la salud. En este sentido, la personalización de la atención, al ajustar los tratamientos a las necesidades individuales de cada usuario, permite desarrollar un modelo de rehabilitación más eficiente y flexible. Esto abre la puerta a un futuro prometedor, en el que las tecnologías de aprendizaje continuo no solo optimicen los tratamientos, sino que también impulsen avances significativos en medicina preventiva mediante intervenciones más adaptativas y efectivas.

En conclusión, los hallazgos de este estudio destacan el impacto significativo del guante inteligente en la rehabilitación de personas con hipermovilidad articular, superando las limitaciones de las tecnologías existentes. Al combinar la monitorización en tiempo real con algoritmos avanzados de inteligencia artificial, este dispositivo no solo mejora la prevención de lesiones, sino que también optimiza la rehabilitación activa, ofreciendo un enfoque innovador y personalizado que mejora la calidad de vida de los usuarios y establece un modelo de referencia para el manejo de condiciones musculoesqueléticas.

REFERENCES

- [1] N. L. Greenwood, L. D. Duffell, C. M. Alexander, and A. H. McGregor, "Electromyographic activity of pelvic and lower limb muscles during postural tasks in people with benign joint hypermobility syndrome and non hypermobile people. A pilot study," *Manual Therapy*, vol. 16, no. 6, pp. 623–628, Dec. 2011, doi: 10.1016/J.MATH.2011.07.005.
- [2] M. Castori, "Ehlers-Danlos Syndrome, Hypermobility Type: An Underdiagnosed Hereditary Connective Tissue Disorder with Mucocutaneous, Articular, and Systemic Manifestations," *International Scholarly Research Notices*, vol. 3, no. 1, p. 751768, Jan. 2012, doi: 10.5402/2012/751768.
- [3] L. Remvig, D. V. Jensen, and R. C. Ward, "Epidemiology of general joint hypermobility and basis for the proposed criteria for benign joint hypermobility syndrome: review of the literature.," *The Journal of Rheumatology*, vol. 34, no. 4, 2007.
- [4] M. M. Lamari *et al.*, "Generalized Joint Hypermobility: A Statistical Analysis Identifies Non-Axial Involvement in Most Cases," *Children* 2024, Vol. 11, Page 344, vol. 11, no. 3, p. 344, Mar. 2024, doi: 10.3390/CHILDREN11030344.
- [5] A. M. Howell, T. Kobayashi, H. A. Hayes, K. B. Foreman, and S. J. M. Bamberg, "Kinetic gait analysis using a low-cost insole," *IEEE Transactions on Biomedical Engineering*, vol. 60, no. 12, pp. 3284–3290, 2013, doi: 10.1109/TBME.2013.2250972.
- [6] M. Zens *et al.*, "Novel approach to dynamic knee laxity

- measurement using capacitive strain gauges,” *Knee Surgery, Sports Traumatology, Arthroscopy*, vol. 23, no. 10, pp. 2868–2875, Oct. 2015, doi: 10.1007/S00167-015-3771-9/METRICS.
- [7] J. S. Tan *et al.*, “Predicting Knee Joint Kinematics from Wearable Sensor Data in People with Knee Osteoarthritis and Clinical Considerations for Future Machine Learning Models,” *Sensors* 2022, Vol. 22, Page 446, vol. 22, no. 2, p. 446, Jan. 2022, doi: 10.3390/S22020446.
- [8] G. Arogam, N. Manivannan, and D. Harrison, “Review on Wearable Technology Sensors Used in Consumer Sport Applications,” *Sensors* 2019, Vol. 19, Page 1983, vol. 19, no. 9, p. 1983, Apr. 2019, doi: 10.3390/S19091983.
- [9] D. R. Seshadri *et al.*, “Wearable sensors for monitoring the internal and external workload of the athlete,” *npj Digital Medicine* 2019 2:1, vol. 2, no. 1, pp. 1–18, Jul. 2019, doi: 10.1038/s41746-019-0149-2.
- [10] E. Kay, J. Levick, T. Machingura, and S. Bird, “Sensory Considerations for Emerging Textile Applications,” *Textiles* 2024, Vol. 4, Pages 17-25, vol. 4, no. 1, pp. 17–25, Jan. 2024, doi: 10.3390/TEXTILES4010002.
- [11] A. De Brabandere, J. Emmerzaal, A. Timmermans, I. Jonkers, B. Vanwanseele, and J. Davis, “A Machine Learning Approach to Estimate Hip and Knee Joint Loading Using a Mobile Phone-Embedded IMU,” *Frontiers in Bioengineering and Biotechnology*, vol. 8, p. 509363, Apr. 2020, doi: 10.3389/FBIOE.2020.00320/BIBTEX.
- [12] E. Repnik, U. Puh, N. Goljar, M. Munih, and M. Mihelj, “Using Inertial Measurement Units and Electromyography to Quantify Movement during Action Research Arm Test Execution,” *Sensors* 2018, Vol. 18, Page 2767, vol. 18, no. 9, p. 2767, Aug. 2018, doi: 10.3390/S18092767.
- [13] R. Rodríguez-Romo, M. Orrantia-Vertiz, J. Barragán-Garfias, G. Rojas-García, A. Rodríguez-Álvarez, and N. Carbonell-Bobadilla, “Síndrome de hipermovilidad articular,” *Acta Ortopédica Mexicana*, vol. 34, no. 6, pp. 441–449, 2020, doi: 10.35366/99145.
- [14] X. Suau, M. Alcoverro, A. López-Méndez, J. Ruiz-Hidalgo, and J. R. Casas, “Real-time fingertip localization conditioned on hand gesture classification,” *Image and Vision Computing*, vol. 32, no. 8, pp. 522–532, Aug. 2014, doi: 10.1016/J.IMAVIS.2014.04.015.
- [15] J. K. Kim, K. Lee, and S. G. Hong, “Detection of important features and comparison of datasets for fall detection based on wrist-wearable devices,” *Expert Systems with Applications*, vol. 234, p. 121034, Dec. 2023, doi: 10.1016/J.ESWA.2023.121034.
- [16] M. Gumà *et al.*, “Una estimación de la laxitud articular en la consulta externa,” *Revista Española de Reumatología*, vol. 28, no. 7, pp. 298–300, Aug. 2001, Accessed: Oct. 09, 2024. [Online]. Available: <https://www.elsevier.es/es-revista-revista-espanola-reumatologia-29-articulo-una-estimacion-laxitud-articular-consulta-13020669>
- [17] Z. ; Cai *et al.*, “Device-Free Wireless Sensing for Gesture Recognition Based on Complementary CSI Amplitude and Phase,” *Sensors* 2024, Vol. 24, Page 3414, vol. 24, no. 11, p. 3414, May 2024, doi: 10.3390/S24113414.
- [18] T. Jiralerspong, E. Nakanishi, C. Liu, and J. Ishikawa, “Experimental Study of Real-Time Classification of 17 Voluntary Movements for Multi-Degree Myoelectric Prosthetic Hand,” *Applied Sciences* 2017, Vol. 7, Page 1163, vol. 7, no. 11, p. 1163, Nov. 2017, doi: 10.3390/APP7111163.
- [19] G. S. Lakshmi and H. R., “Calibration of Force Sensitive Resistor used in Force Controlled Grippers,” *International Journal of Engineering Research & Technology*, vol. 9, no. 8, Aug. 2020, doi: 10.17577/IJERTV9IS080129.
- [20] W. Li, M. L. Zhan, Q. Y. Yu, B. Y. Zhang, and Z. R. Zhou, “Quantitative assessment of friction perception for fingertip touching with different roughness surface,” *Biosurface and Biotribology*, vol. 1, no. 4, pp. 278–286, Dec. 2015, doi: 10.1016/J.BSBT.2015.11.004.
- [21] H. Al-Mahafzah, T. AbuKhalil, M. Alksasbeh, and B. Alqaralleh, “Multi-modal palm-print and hand-vein biometric recognition at sensor level fusion,” *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 13, no. 2, pp. 1954–1963, Apr. 2023, doi: 10.11591/ijece.v13i2.pp1954-1963.
- [22] W. Ahmed, M. K. Sattar, W. Shahnawaz, U. Saeed, S. M. Khan, and N. A. Khan, “Wearable Hand-Rehabilitation System with Soft Gloves for Patient with Face Paralysis and Disability,” *Engineering Proceedings 2021, Vol. 12, Page 56*, vol. 12, no. 1, p. 56, Dec. 2021, doi: 10.3390/ENGPROC2021012056.
- [23] S. Elkateb, A. Métwalli, A. Shendy, and A. E. B. Abu-Elanien, “Machine learning and IoT – Based predictive maintenance approach for industrial applications,” *Alexandria Engineering Journal*, vol. 88, pp. 298–309, Feb. 2024, doi: 10.1016/J.AEJ.2023.12.065.
- [24] M. A. Ozdemir, D. H. Kisa, O. Guren, and A. Akan, “Dataset for multi-channel surface electromyography (sEMG) signals of hand gestures,” *Data in Brief*, vol. 41, p. 107921, Apr. 2022, doi: 10.1016/J.DIB.2022.107921.