Evaluación de redes neuronales recurrentes LSTM en la predicción de fatiga muscular

Fabio A. Escobar G, Johan Y. Coral M.

Resumen - Este trabajo está centrado en la predicción de fatiga muscular, existen varias definiciones para este fenómeno, generalmente se define como reducción de rango de movimiento articular, otras definiciones la sustentan bajo el criterio de la pérdida de fuerza al realizar una actividad generada por el músculo esquelético, además, el fenómeno se presenta en toda actividad física sin importar si la persona presenta una patología asociada, es decir, está presente en personas sanas y enfermas.

También el efecto de la fatiga muscular se ve reflejado en diversas actividades cotidianas que realizan las personas, las principales son: terapia de rehabilitación, ejercicio de alto rendimiento, tareas repetitivas, entre otras. El objetivo planteado en la investigación está encaminado a determinar el grado o porcentaje de precisión en la predicción de fatiga cuando se usa algoritmos de inteligencia artificial, tales como las redes LSTM, también en este trabajo se establece una metodología para la adquisición de señales electromiograficas las cuales tiene asociada a ellas el efecto de la fatiga.

La fatiga muscular tiene su efecto negativo en el contexto del trabajo, por lo tanto, una adecuada predicción en el momento que su efecto se hace visible permite tomar acciones que contrarreste este fenómeno, también visto desde la posición de la relación que existe entre máquina y operario se puede ejecutar acciones que protejan la vida de la persona y adicional mejorar utilidad en los procesos productivos.

Esto justifica la propuesta de investigación sobre la "Evaluación de redes neuronales recurrentes LSTM en la predicción de fatiga muscular.

Índice de Términos – Bioseñal, EMG, fatiga muscular, LSTM, sistema muscular y esqueletico, RNA, RNN.

I. INTRODUCCION

Esta última década del siglo XXI se ha convertido en escenario de grandes cambios rápidos y profundos en el campo científico y técnico reflejando la tarea, el reto, el desafío y el compromiso de todo aquél que se encause por el camino del saber desde el campo de la ingeniería electrónica, puesto que hoy es urgente dar soluciones originales ante los nuevos problemas que exigen respuestas inmediatas a las necesidades y demandas de programadores, innovadores y desarrolladores a lo largo y ancho de la sociedad del conocimiento, es de decir, una sociedad tecnológica que a cada instante implementa alternativas de mejoramiento en la calidad de vida haciéndola más rápida, eficiente y eficaz como se lo evidenciará en la presente tesis sobre la implementación de redes neuronales recurrentes LSTM en la predicción de fatiga muscular.

Desde décadas atrás la inteligencia artificial ha venido revolucionando la industria tecnológica y sus algoritmos, los sistemas de control, la medicina y en general todo proceso que involucra análisis de datos. Dentro de estos algoritmos se encuentran las redes neuronales recurrentes que usan memoria de corto y largo plazo denominadas LSTM, estas se han diseñado para evaluar series de datos donde el pasado es importante para presentar una evaluación futura. Dado que la electromiografía son series de datos temporales e independientes de un sujeto a otro, dentro de la señal mioelectricas se encuentra inmersas características de fatiga que a simple vista puede no ser perceptible, por otro lado, la fatiga muscular es un gran problema en la fisioterapia y también en actividades donde involucre el movimiento de articulaciones. Por lo tanto, en este trabajo se evalúa el grado de precisión que tiene una red LSTM en la predicción de fatiga, se inicia estableciendo una metodología que permita obtener el conjunto de datos para su posterior análisis, luego se implementa la red LSTM utilizando librerías de Python y finalmente se presenta los resultados obtenidos, en estos se puede evidenciar que el error máximo está cercano a 10%.

Para mayor comprensión del lector este trabajo de tesis está estructurado en cinco partes: en primer lugar encontrará unos aspectos científico-técnicos que hacen referencia a los elementos de identificación del mismo; en el segundo momento está reflejado el marco teórico: contextual, legal, tecnológico y conceptual relacionado con los aportes bibliográficos en coherencia con lo soportado y requerido para este trabajo de investigación recalcando algunas generalidades de la Evaluación de redes neuronales recurrentes LSTM en la predicción de fatiga muscular y su efecto negativo en el contexto del trabajo; en el tercero, relacionado con el diseño metodológico donde se relaciona el tipo de investigación, el método inductivo resaltando que se parte de premisas ya conocidas para llegar a demostrar en la conclusión la regularidad en los efectos que produce la fatiga y así permitir tomar acciones que contrarresten este fenómeno y propendan por mejorar la utilidad en los procesos productivos, especialmente en el caso de la relación que existe entre

Documento recibido el 12 de agosto de 2022. Este trabajo fue apoyado en parte por Ing. Esp. Oscar Rodríguez. Asesor técnico.

PROHIBIDA SU COPIA

máquina y operario; también en esta parte se hace alusión al enfoque cuantitativo utilizando la recolección y el análisis de datos o de la información recabada en el muestreo de la población observada objeto de este trabajo de investigación; en el cuarto momento se procede al análisis de la información recabada y los resultados arrojados como insumos para llegar a obtener una conclusiones concretas acerca de la efectividad de la evaluación de las redes neuronales recurrentes LSTM en la predicción de fatiga muscular y, finalmente, se cierra con unas conclusiones generales y recomendaciones, además de su respectiva bibliografía.

II. ANTECEDENTES (ESTADO DEL ARTE)

A. Técnica para obtención de información de actividad eléctrica muscular

Esencialmente la fatiga muscular es la dificultad más prevalente, algunos autores la definen como el cansancio del músculo, otros la definen como la pérdida de fuerza a lo largo del tiempo ’(Yousif y cols., 2019). La fatiga muscular puede llegar a causar lesiones las cuales pueden tardar varias semanas en recuperarse (Elshafei y Shihab, 2021), 2017), además limita la ROM.

Ahora bien, la fatiga muscular se ha estudiado desde el dominio subjetivo, relacionando la percepción que experimenta la persona sobre el nivel de fatiga, en la actualidad se usa cuestionarios y escalas como lo es la de Borg (Williams, 2017). Entre los métodos más objetivos van

desde los invasivos, como evaluación del lácteo sanguíneo (Bublitz y cols., 2016), hasta los no invasivos, a este grupo pertenece la electromiografía, frecuencia cardíaca, mecanomiografia, ultrasonografía.

En la literatura la técnica más utilizada para la detección de fatiga es la electromiografía, esta usa electrodos para detectar los impulsos eléctricos generados por los músculos, otro método frecuente es la mecanomiografia que usa generalmente acelerómetros para detectar las vibraciones mecánicas del músculo, en trabajos relacionados con la MMG se ha usado dispositivos convencionales como los teléfonos inteligentes(Karvekar, Abdollahi, y Rashedi, 2021).

Las señales EMG son no estacionarias y presentan dificultad para detectar la fatiga, además presentan cambios entre personas, diversos trabajos han enfocado sus esfuerzos para resolver este problema, han combinado características en el dominio de tiempo y frecuencia, usando transformada Strockewel (Karvekar y cols., 2021), otro enfoque propuesto por (Li, Li, y Shu, 2020), es obtener señales de músculos agonistas y sinérgicos con lo cual mejora notablemente la precisión.

También se han realizado trabajos en los cuales usa características de señales MMG y EMG para mejorar la precisión.

Por otro lado, la inteligencia artificial está revolucionando diferentes áreas, su diversidad de aplicaciones han penetrado las especialidades médicas, su principal función está en el diagnóstico y seguimiento de patologías individualizando al usuario. La visión general es que estos sistemas llegaron para quedarse. Diversos investigadores han evaluado la fatiga muscular utilizando algoritmos de inteligencia artificial, Zhang et al. (2021), aborda la clasificación de la fatiga muscular usando señales electromiografías, obtenidas de un conjunto de personas que están divididas en dos grupos, combinando características en el dominio del tiempo y frecuencia, siguiendo esta línea Moniri et al. (2021), centra la atención en los músculos del tronco, sigue utilizando señales EMG, y el análisis se realiza en el dominio del tiempo. Otros autores proponen usar algoritmos monofractales y multifractales para clasificar señales EMG que contienen fatiga, como resultados están por encima del 80% en precisión.

III. PROPUESTA

A. Músculo esquelético

El cuerpo humano tiene más de 600 músculos esqueléticos que tienen como función mover las articulaciones (ver Fig. 1.), cada uno de estos tiene definido una función en específico, es decir, para mover una determinada estructura ósea, la fibra motora activa específicamente un músculo con lo cual se produce el movimiento.

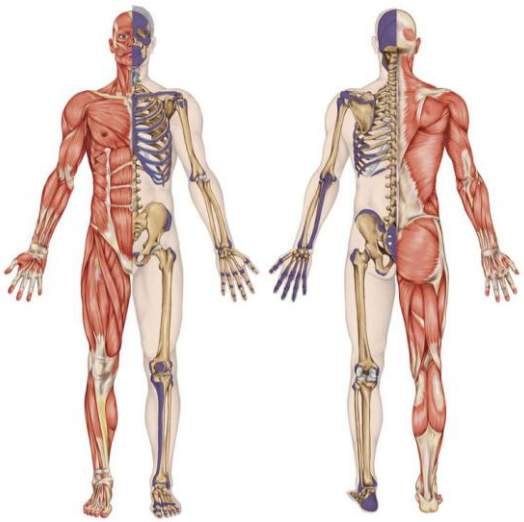

Fig. 1. Músculos esqueléticos del cuerpo humano.

Teniendo en cuenta que esta investigación está en una etapa preliminar para futuros estudios acerca de la interfaz hombre-máquina, se elige trabajar en los miembros superiores ya que estos están compuestos por varias articulaciones formadas por estructuras óseas; una de las principales es el movimiento de brazo que a su vez realiza flexión del codo, este es uno de los movimientos más comunes que un operario realiza dentro del proceso de producción. Ahora bien, para que el brazo sea

PROHIBIDA SU COPIA

flexionado se tiene que estimular el músculo llamado bíceps (ver Fig. 2.), este movimiento se realiza en el eje positivo del cuadrante, tomando como referencia el plano cartesiano.

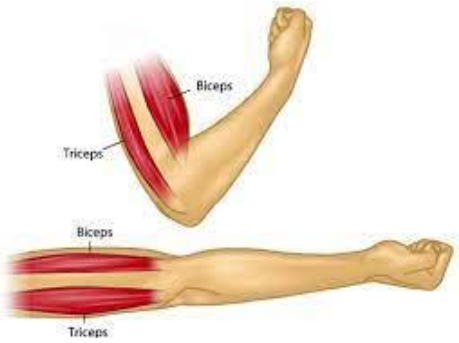

Fig. 2. Músculos del brazo llamados bíceps.

B. Ejercicio físico

La tarea de mover el brazo se denomina ejercicio, dentro de este se puede encontrar tres tipos: isométricos, isotónicos e isocinéticos. Los isométricos se caracterizan por no presentar desplazamiento articular, el músculo permanece estático, pero si ejerce una fuerza la cual se ve reflejada en mantener en una posición la articulación. Por otro lado, los isotónicos está centrada su característica principal en que hay desplazamiento de la articulación, generalmente se realizan en dos fases, la primera es excéntrica y la segunda concéntrica. Finalmente, los isocinéticos que son ejercicios que se realizan en contra del movimiento.

Cada uno de estos ejercicios físicos representa una determinada acción para el fenómeno de la fatiga sea perceptible, para evitar errores de lectura de las variables y por usarse un método de fatiga subjetivo y en la revisión de la literatura consultada menciona que en ejercicios isométricos la fatiga muscular tiene su efecto en un corto plazo, por lo tanto, para esta investigación se trabaja con ejercicios isométricos.

C. Fatiga muscular

Podemos definir este fenómeno en base al proyecto como el mecanismo de defensa que tiene nuestro sistema musculo-esqueletico ante el agotamiento extremo de las fibras musculares en la realización de actividad física; produciendo perdida en la capacidad de mantener un nivel de fuerza en una contracción sostenida o varias de manera intermitente, acompañada de la reducción del rango de movimiento articular. Por lo tanto, esto genera un cambio en la actividad eléctrica muscular.

IV. RESULTADOS

A. Procedimiento para obtención de bioseñal en pacientes

Población Objetivo

El desarrollo de este trabajo se ubica en la ciudad de Pasto, departamento de Nariño.

El estudio está centrado en una población de 10 sujetos sanos, con una proporción de igualdad entre mujeres y hombres. El rango de edad es de 18 a 40 años, como criterio de exclusión es que la persona sufra alguna patología relacionada con el sistema músculo-esquelético.
Las variables sexo, color de piel, lugar de nacimiento, zona de residencia, grupo étnico “NO SON OBJETO DE ESTUDIO”, por lo tanto, se incluyeron en el estudio diferentes personas sin importar las variables mencionadas.

Una vez fijada la población objetivo con la cual se dará inicios a este proyecto de investigación, se debe tener en cuenta el marco legal, para evitar posteriores conflictos jurídicos. Por lo tanto la resolución 8430 de 1993 es la que rige en el proceso investigativo a fin.

Según el Art 4. Res. 8430 DE 1993: La investigación para la salud comprende el desarrollo de acciones que contribuyan. Al estudio de las técnicas y métodos que se recomienden empleen para la prestación de servicios de salud pilar de sustento del presente trabajo de investigación. Los autores declaran: Se garantiza el criterio del respeto a su dignidad y la protección de sus derechos y su bienestar según el art. 5 Res.8430 de 1993.

Según el Art. 9 – 11 Res. 8430 de 1993 se considera que el proyecto es una investigación en humanos SIN RIESGO ya que en ningún caso con los procedimientos y/o protocolos el sujeto de investigación sufrirá algún daño como consecuencia inmediata o tardía del estudio. La investigación se llevar a cabo en individuos en pleno uso de sus facultades físicas y mentales, por tanto, no será necesaria la intervención de terceros profesionales o testigos de buena fe (salvo en el caso en donde el individuo manifieste no saber o tener dificultades para leer), más allá de los científicos expertos involucrados en esta propuesta.

Protocolos

Teniendo en cuenta la información encontrada en diferentes artículos científicos relacionados con esta investigación, y con los criterios y técnicas ya definidos se procede a plantear el protocolo para la adquisición de datos. Cabe mencionar que con cada paciente se realizan 10 sesiones en diferentes días.

- Se sustenta a la persona cuál es el objetivo y justificación de la investigación.
- Se pregunta si sufre alguna patología relacionada con los músculos o si ha tenido algún malestar gripal en las últimas 72 horas.
- La persona debe firmar el consentimiento informado.
- Se procede a limpiar con alcohol la zona de ubicación del paciente y de los electrodos superficiales.
- Se colocan los electrodos y la instrumentación a utilizar.

PROHIBIDA SU COPIA

- Se ubica el paciente en una silla.
- Se hace una prueba rápida, para detectar que la señal esté adecuada.
- El brazo debe estar a 90 grados con el antebrazo para iniciar la prueba.
- Mantenga la posición que se le indique durante el mayor tiempo posible.
- Con el fin de que la fatiga se manifieste rápido, se le pide que en su mano tome una pesa de 1 Kilogramo.
- Se da inicio a la prueba.
- Se le manifiesta que debe presionar el pulsador inmediatamente cuando sienta cansancio en el bíceps.
- Cuando la persona baja el brazo se detiene la toma de datos.
- Se espera 10 minutos y se procede a realizar nuevamente la prueba, esto se hace tres veces.
- Finaliza la prueba, desconectando todos los elementos que se ubican en la persona.

B. Desarrollo de hardware, software para obtención y análisis de señales electromiograficas

El hardware usado en este trabajo es la tarjeta de electromiografía MyoWare modelo AT-04-001 (ver Fig. 3.) desarrollada por la empresa Advancer Technologies. Este dispositivo está construido con amplificadores de instrumentación y permite la selección del tipo de señales que se quiere adquirir, es decir, la señal puede estar filtrada y rectificada o por el contrario es una señal completa. La tarjeta fue conectada a la entrada análoga del Arduino Mega 2560, adicional se conectó un pulsador con el fin de determinar el inicio de fatiga muscular.

Fig. 3. Módulo EMG Myoware.

En cuanto al software usado para almacenar la información proveniente de la placa Arduino se usa un script desarrollado en Python, la recepción de los datos se hace por medio del puerto COM y son almacenados en un archivo con extensión *.xlxs.

C. Análisis de datos

La siguiente (Fig. 4.), muestra la señal de electromiografía captada por la tarjeta usada en este trabajo. Se puede observar que hay cambios que oscilan entre 150 y -150 también es evidente que la señal es cambiante en el tiempo. Esta señal es un intervalo de tiempo, las señales adquiridas presentan mayor duración en el tiempo, se almacenan de forma individual por cada sesión y paciente.

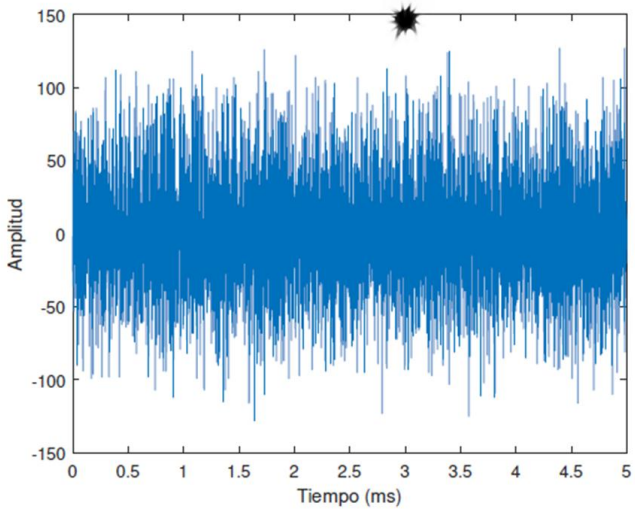

Fig. 4. Señal eléctrica muscular EMG tipo RAW.

Como se puede apreciar en la Figura 4. Los valores se encuentran al lado positivo y negativo, esto dificulta el cálculo de la amplitud. Para solucionar este inconveniente y como se ha reportado en la literatura que analiza la estadística lo más conveniente para estos casos es evaluar la media cuadrática, esto permite encontrar el valor central de la señal para ello se usa la ecuación (1).

$$RMS = \sqrt{\frac{1}{N}\sum_{n=1}^{N}|x_n|^2} \quad (1)$$

Dónde:

N: número de muestras
Xn: son los enésimos datos

El uso de la ecuación se hace mediante la función “rms” de MatLab, el código está descrito en el Anexo 2. La señal se divide en ventanas de 200 muestras a las cuales se les hace el cálculo, en otras palabras, el valor de N = 200 y la salida es el valor RMS. Este cálculo se hace a lo largo de la señal, el resultado del código se puede ver en la Figura 5.

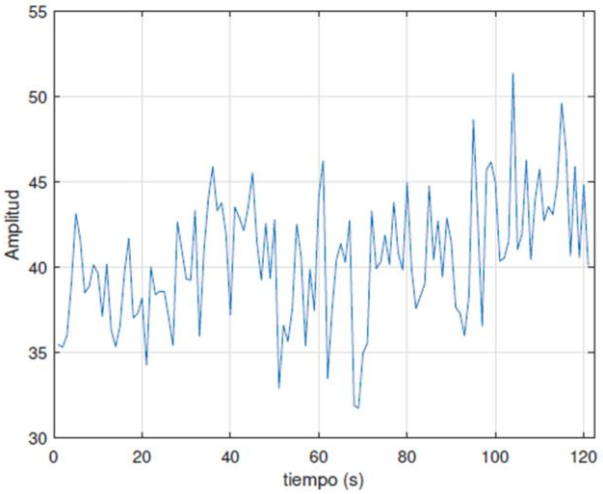

Fig. 5. RMS de señal EMG.

El uso del código presentado en la sección A.2 permite analizar la evolución de la señal EMG; se elige al azar el registro de un paciente para evaluar el comportamiento de la señal. En la Figura 6. Se puede observar el comportamiento de la amplitud a través del tiempo. En términos generales se evidencia que hay un punto donde la amplitud de la señal tiene un mayor nivel, aproximadamente a los 100 segundos la amplitud empieza a crecer con mayor rapidez.

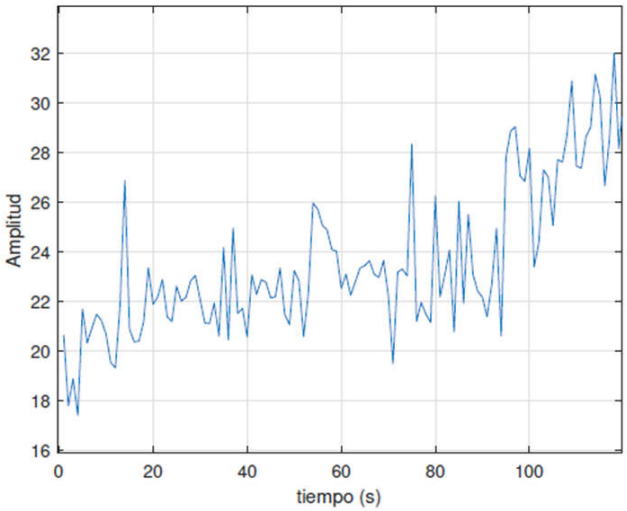

Fig. 6. Amplitud de le señal EMG.

Por otro lado, evaluando el vector que contiene la información del pulso que indica el momento en que inicia a sentir que el músculo se fatigada, cabe recordar que este es un indicador subjetivo que accionado por el paciente. La Figura 7. Muestra el pulso generado por el paciente, para el análisis se realizó el muestreo espaciado con igual número de muestras que se usa en el cálculo del **rms** con esto se puede hacer el cruce de señales que permita evaluar otro tipo de características.

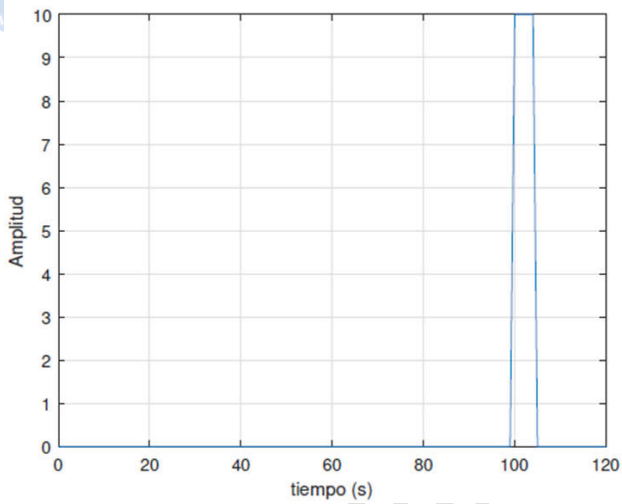

Fig. 7. Señal del pulso eléctrico emitida por el pulsador.

Al realizar la superposición de las Figuras 6 y 7 se observa que el incremento del nivel de señal empieza en el momento que el usuario indica sentir fatiga, se puede inferir que en este momento es donde inicia la presencia del fenómeno de fatiga ver Figura 8.

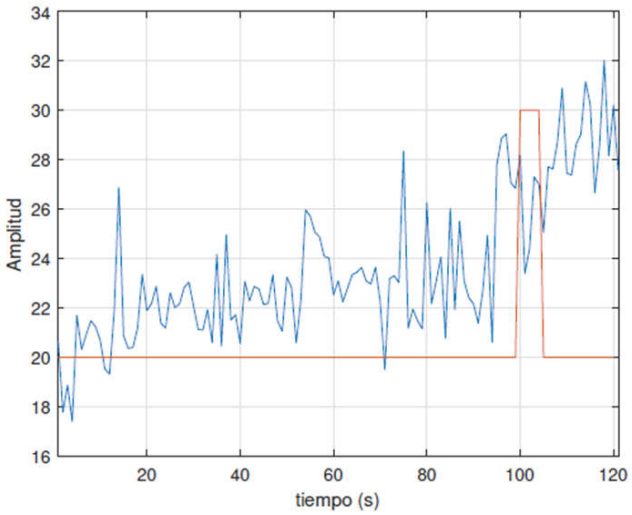

Fig. 8. Superposición de señal de pulso y rms.

D. Comparación del comportamiento de señal en pacientes

Las señales electromiograficas difieren entre pacientes, es decir, el paciente A presenta un nivel de amplitud mayor que el paciente B. Ahora bien, el tiempo en que aparece el fenómeno de fatiga no está estandarizado ocurre al igual que el nivel de amplitud de la señal, en pacientes puede ser más tardío que en otros y su evolución también es diferente. La figura muestra las señales de dos pacientes, a simple vista se puede inferir que uno de ellos presenta niveles de amplitud menores y el incremento del nivel de la señal se hace en diferente tiempo.

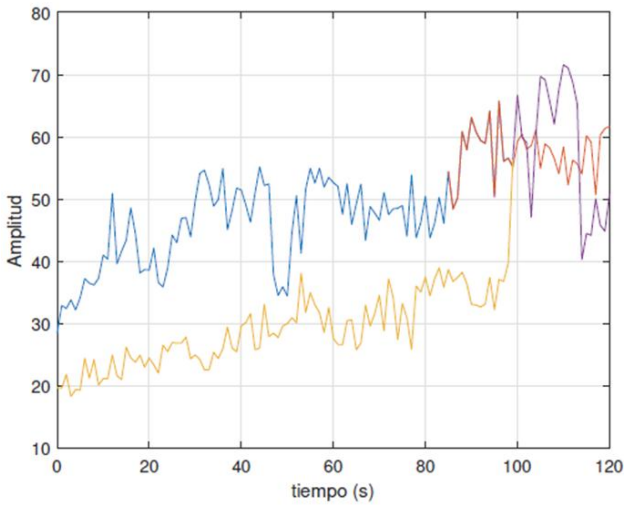

Fig. 9. Comparación de señales rms entre paciente A y B.

E. Generación del dataset

En la sección anterior se analizaron los datos desde el punto de vista individual por cada paciente. En esta sección se integra los datos de las sesiones y los pacientes, para ello se procede a dividir los datos en dos conjuntos, el primero contiene los datos de la señal no fatigada y el segundo de la señal fatigada. El siguiente paso es normalizar los datos con esto se asegura que la información está en una única escala. En la anterior figura se observa que los datos están sin normalizar, esta información es normalizada y se obtiene datos como se muestran en la Figura 10. Aquí se observa que las dos señales coinciden con su escala.

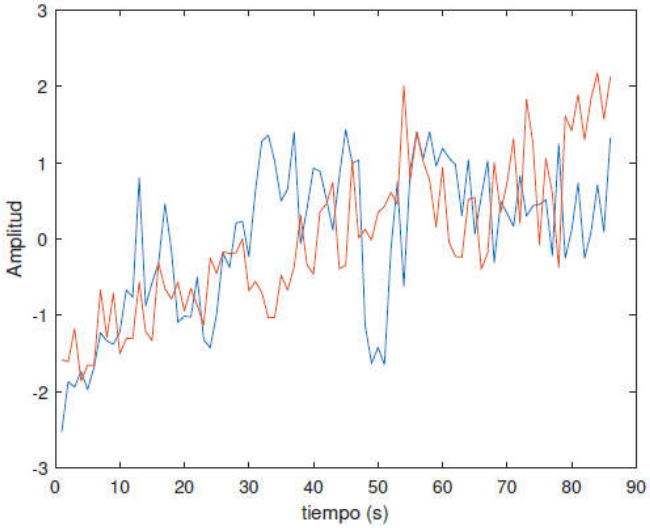

Fig. 10. Señales escaladas y normalizadas.

En la sección anterior se analizaron los datos desde el punto de vista individual por cada paciente. En esta sección se integra los datos de las sesiones y los pacientes, para ello se procede a dividir los datos en dos conjuntos, el primero contiene los datos de la señal no fatigada y el segundo de la señal fatigada.

El siguiente paso es normalizar los datos con esto se asegura que la información está en una única escala. En la figura se observa que los datos están sin normalizar, esta información es normalizada y se obtiene datos como se muestran en la figura anterior, aquí se observa que las dos señales coinciden con su escala.

Recordando que la información fue obtenida de 10 personas en diferentes sesiones, se tiene datos aislados, entonces, el objetivo final es consolidar la información en un solo archivo que permita generar una señal única. Para este proceso se va a seguir un método de ventanas con una determinada longitud, es decir, se extraen los primeros datos de un paciente y se almacenan en un vector luego se selecciona otro paciente y se extrae la muestra y se une con la muestra anterior, este proceso se repite hasta terminar los datos de todos los pacientes. Esta metodología se aplica a los dos conjuntos fatigados y no fatigados.

F. Creación de la red neuronal LSTM

Las LSTM's tienen una alta sensibilidad a los datos a escala en entrada, más aún cuando las funciones de activación son la tangente hiperbólica o la función sigmoidea. Debido a esto es necesario realizar el escalado de los datos. En este trabajo se realiza todo el proceso en el software Python.

La red neuronal LSTM se modela con ayuda de la librería Keras que es especializada para la construcción de redes neuronales de diversos tipos. Se configura un modelo secuencial, la capa de entrada está diseñada para que reciba información unitaria, en las capas ocultas se configura 10 bloques LSTM y finalmente se usa la función de activación sigmoidea que está configurada por defecto. En la compilación de modelo se especifica que la función de optimización es el descenso del gradiente estocástico, para la pérdida de datos se usa el error cuadrático medio, además, se usa 100 épocas y bloque de 1. En la Figura 11. Se puede observar el resumen de la red neuronal.

```
Model: "sequential_34"
_________________________________________________________________
 Layer (type)                 Output Shape              Param #
=================================================================
 lstm_30 (LSTM)               (None, 10)                480

 dense_42 (Dense)             (None, 10)                110

=================================================================
Total params: 590
Trainable params: 590
Non-trainable params: 0
_________________________________________________________________
```

Fig. 11. Resume de la red neuronal de tipo LSTM.

G. Entrenamiento de la red neuronal

Para el entrenamiento de la red neuronal LSTM se dividió el dataset en aproximadamente el 70% de los datos para entrenamiento y el 30% de datos de evaluación.

'DA SU COPIA

En este trabajo para evaluar el rendimiento de una red neuronal LSTM se hace uso de la gráfica de pérdidas o *loss*. Esta permite evaluar cómo es su evolución de los datos en un modelo. Según la literatura entre más grandes las pérdidas las predicciones van a estar alejadas del valor real. En la Figura se puede observar la evolución de pérdidas a través de las épocas, se evidencia dos señales que corresponden a entrenamiento y test marcados con los colores azul y naranja respectivamente, se infiere que los valores decrecen con una alta tasa hasta la época 5 aproximadamente y luego no presentan cambios significativos. Las pérdidas son de 0.015 y 0.02 para entrenamiento y test respectivamente.

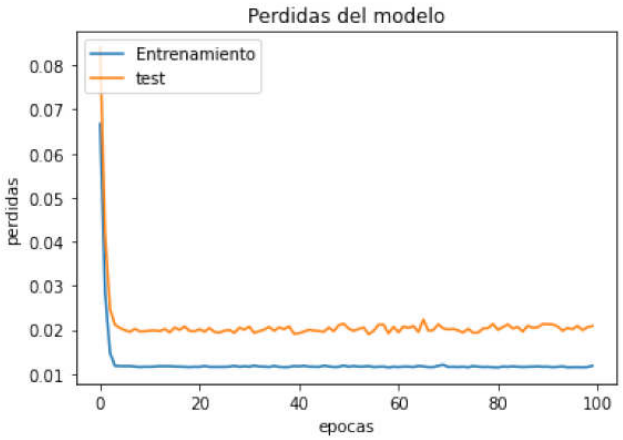

Fig. 12. Grafica de las pérdidas o loss.

H. Métricas para la evaluación de la red neuronal

A lo largo del documento se ha mencionado que el problema que se trabaja en esta investigación está asociado a la predicción, además teniendo en cuenta la descripción planteada en la sección anterior, se usará métricas para regresión.

Dentro de las métricas más usadas está el error medio absoluto, error cuadrático medio y raíz del error cuadrático medio. En esta investigación se usa el error cuadrático medio debido a que este destaca errores grandes entre los pequeños, el cálculo está dado por la Ecuación 2.

$$MSE = \frac{1}{N}\sum_{t=1}^{N} e^2{}_t \qquad (2)$$

Dónde:

N: es el número de observaciones.
E: es el error de cada observación.

I. Evaluación de la red neuronal

En la Figura 13. Muestra dos señales identificadas con el color azul para los datos reales y rojo para predicción, se puede observar que los datos generados por la red neuronal siguen a los datos reales, en algunos instantes se presenta una diferencia que es interpretada como el error entre las dos señales.

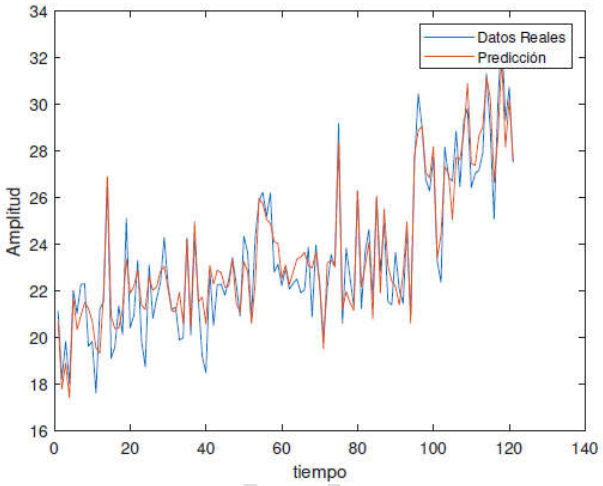

Fig. 13. Grafica de evaluación de la red neuronal LSTM.

La Tabla 2 presenta los errores que se obtuvieron después de evaluar el algoritmo entrenado, la primera fila indica las sesiones que tuvo cada persona, la primera columna se indica la persona numerada de 1 a 10. Se puede observar que el error más grande es del 10% y el mínimo error es de 1%.

Tabla 1.
Porcentaje de error en la predicción de la red neuronal

Persona	S1	S2	S3	S4	S5	S6	S7	S8	S9	S10
1	3	4	1	7	2	2	1	6	6	4
2	1	1	1	3	2	3	5	4	3	4
3	2	2	2	2	3	3	3	1	3	4
4	3	3	3	3	5	3	6	2	5	4
5	2	3	3	2	2	3	8	1	3	1
6	3	3	4	6	5	1	6	2	8	1
7	3	4	3	5	5	2	10	1	7	1
8	3	2	2	3	3	4	5	5	4	3
9	2	2	1	1	7	3	1	5	3	4
10	1	4	7	1	1	1	1	5	2	1

En la Figura 14. Se observa los cuartiles del error, se observa que el error promedio está en 3.4%, presenta un error menor a 8% y mayor a 1%. Estos datos son evaluados en las 10 sesiones de la persona identificada como 1 según la tabla anterior.

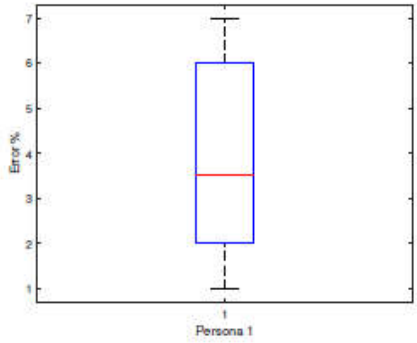

Fig. 14. Error de predicción en la persona 1.

PROHIBIDA SU COPIA

En la Figura 15 se muestra los cuartiles del error, se observa que el error promedio está en 1%, presenta un error menor a 7% y superior a 1%. Estos datos son evaluados en las 10 sesiones de la persona identificada como 10.

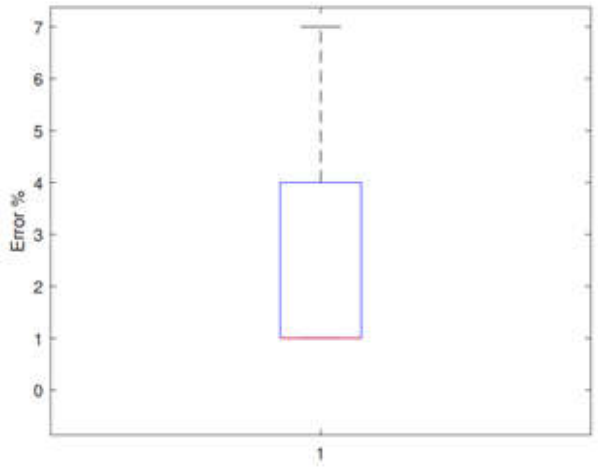

Fig. 15. Error de predicción en la persona 10.

En el histograma mostrado en la Figura 16. Permite observar que el error tiene mayor densidad en el 3%, con aportes ligeramente menores se encuentran valores cercanos a éste y con un menor aporte, valores iguales al 10%, esto permite inferir que el error promedio de cada una de las sesiones es del 3%.

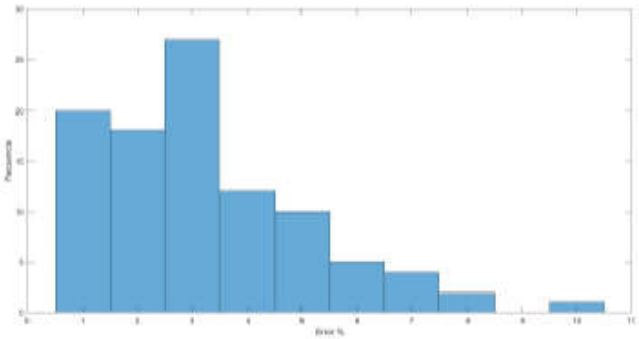

Fig. 16. Histograma del error total.

En la Figura 17. Se observa el diagrama que permite identificar el comportamiento general del error que presenta la red neuronal LSTM en la predicción de fatiga, se observa que hay dos valores atípicos 8 y 10. También se infiere que la mediana está en el 3%, además, se ve que la distribución es simétrica por lo que se puede inferir que la media, mediana y moda son coincidentes.

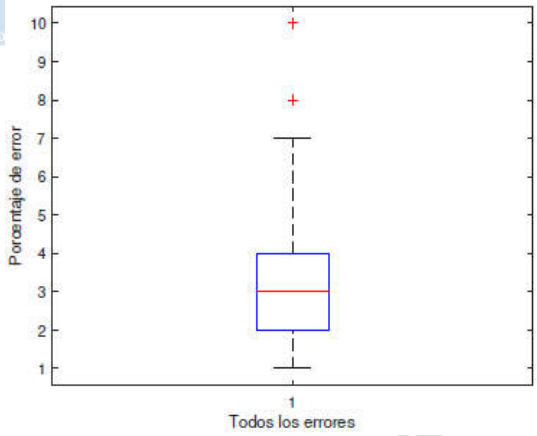

Fig. 17. Predicción de error total.

La red neuronal LSTM implementada en este trabajo presenta errores máximos del 10% lo que se evidencia que los datos podrían diferir el 10% de la señal real, por otro lado, la media está centrada en 3%, es importante mencionar que el valor máximo es un valor atípico. Por lo tanto, se puede evidenciar que la red neuronal planteada permite predecir la fatiga con un buen porcentaje de certeza, en el peor de los casos la salida estará el 10% lejos de la realidad, generalmente esta tendrá errores aproximados del 3%. A lo largo de esta sección se ha evaluado el comportamiento de la red neuronal LSTM en la predicción de fatiga, obteniendo métricas que permiten evaluar cuán cerca está la señal entregada por el predictor versus la señal real. Esta evaluación permite definir que la LSTM propuesta en este trabajo tiene buenos resultados debido a que tiene un desempeño del 97% de acierto contra un 3% de desacierto, también se puede manifestar que esta puede generalizar cualquier señal de electromiografia que se le ingrese a la red, bajo los parámetros establecidos (mencionados en las diferentes sesiones).

La fatiga muscular es un fenómeno que está presente en la actividad muscular y su desarrollo difiere de persona a persona, este se relaciona con la amplitud de la señal de electromiografia que esta se puede catalogar como una señal estocástica, por lo tanto, el valor de la salida depende de varios factores. Por otro lado, el modelo LSTM propuesto en este trabajo presto errores máximos de 10% y promedios del 3% siendo consecuente con la literatura se puede afirmar que el modelo presenta buenos rendimientos. Considerando que la EMG tiene asociado a ella la fatiga y sus características de la señal son no estacionarias el modelo LSTM puede predecir la fatiga muscular con alto grado de confiabilidad en su resultado.

V. CONCLUSIONES Y RECOMENDACIONES

La electromiografía es la técnica más usada para evaluar la fatiga, debido a los niveles de voltaje que están en el orden de los micro voltios es susceptible a ruido. También la elección de la instrumentación es un factor importante, en este trabajo

se usó la tarjeta Myoware junto con la tarjeta arduino Mega. En la mayoría de las muestras que se tomaron los resultados fueron satisfactorios y comparables con la documentación disponible, pero también hubo casos donde la señal no permite evaluar la evolución de la fatiga. Los datos se tomaron a un grupo de 10 personas mayores de edad, ellos asistieron a diferentes sesiones; la data obtenida permitió crear un conjunto de datos el cual se usó para entrenar y evaluar la red neuronal LTMS.

Se estableció el protocolo para la toma de datos en el que interactúa la persona indicando la aparición del fenómeno de la fatiga, este tipo de evaluaciones presentan sesgos en la información. Como una alternativa de mitigar errores sistemáticos se realizó el análisis individual de los datos lo que permitió confrontar los datos obtenidos versus lo reportado en la literatura, es decir, la literatura reporta que la fatiga hace que las señales mioelectricas aumenten su voltaje eléctrico, a través del análisis esta información fue constatada e incluida en un dataset.

En el desarrollo de esta investigación se obtuvo un dataset el cual se usó para entrenar y evaluar una red neuronal LSTM, como resultados se obtuvo un error máximo de 10% y el error mínimo 1%, por lo que se puede concluir que el algoritmo tiene una buena predicción, es importante mencionar que el dataset objeto de estudio usa la percepción subjetiva de la persona para determinar la fatiga.

Para evaluar algoritmos de inteligencia artificial existen varias métricas, la elección de cual usar depende de la aplicación del algoritmo. En este trabajo se usó el error cuadrático medio debido a que permite evaluar qué tan eficiente es la predicción, además, se obtuvieron resultados de error cuadrático de 1.76 y 4.8 para entrenamiento y test respectivamente. También se determina que la red neuronal planteada tiene su mayor aprendizaje en las primeras cinco épocas.

La EMG es la técnica más usada para la evaluación de fatiga muscular.

Las señales de EMG son susceptibles al ruido por su bajo nivel (uV).

La instrumentación de esta técnica es de bajo costo y muy accesible.

El porcentaje de error final muestra que la técnica utilizada es acertada para la cantidad de datos obtenida como entrada (10 personas).

Se puede hacer la hipótesis de que el error más alto obtenido durante el análisis (10%) es obtenido por la baja cantidad de población tomada como datos de entrada.

Se puede determinar que la red neuronal LSTM tiene mayor perdida durante las primeras cinco épocas por que esta se encuentra en una etapa de aprendizaje, esto se debe a que la población es baja. Al aumentar el número de personas, el aprendizaje de la red neuronal se desarrolla en más interacciones.

Al ser datos estocásticos, se dice que el porcentaje en la red neuronal asciende hasta un 10% de error del valor real, en cuanto a que son datos aleatorios que toma el algoritmo para el aprendizaje y su predicción de fatiga muscular.

VI. RECONOCIMIENTOS

A. Agradecimientos de Fabio Escobar

En primer lugar quiero agradecer a mi tutor, quien con sus conocimientos y apoyo me guió a través de cada una de las etapas de este proyecto para alcanzar los resultados que buscaba. Oscar Rodríguez; Ingeniero en electrónica. Sin usted y sus virtudes, su paciencia y constancia este trabajo no lo hubiese logrado tan fácil. Sus consejos fueron siempre útiles cuando no salían de nosotros pensamientos e ideas para alcanzar los resultados y objetivos logrados. Usted formó parte importante de esta historia con sus aportes profesionales que lo caracterizan. Muchas gracias por sus múltiples palabras de aliento, cuando más las necesitamos; por estar allí y sus orientaciones en la parte práctica.

También quiero agradecer a la corporación universitaria Autónoma de Nariño por brindarnos todos los recursos y herramientas que fueron necesarios para llevar a cabo el proceso de investigación. A todos nuestros docentes, quienes tuvieron paciencia, dedicación y perseverancia para compartir su experiencia y su conocimiento preciso e invaluable, quienes formaron con sus palabras sabias la ética y profesionalismo con el que saldremos adelante, a un mundo por descubrir.
En especial, quiero nombrar a un gran hombre quien me dio la oportunidad de ingresar al mundo de conocimientos profesionales, gracias infinitas para el doctor y fundador Tito Jaime Colunge Q.E.P.D. Por abrirme las puertas de su casa, por creer en mí y brindarme la oportunidad de establecer un nuevo objetivo, el título de ingeniero en electrónica. Para con él, sacar adelante a mi familia.

Muchas gracias a toda la familia Colunge por su hospitalidad y sepan que siempre los llevare en mi corazón. Sepan que con orgullo, cada paso que daré y las oportunidades que vendrán, los créditos a ustedes. Por último, quiero agradecer a todos mis compañeros y a mi familia, por apoyarme aun cuando mis ánimos decaían. En especial, quiero hacer mención de mis padres, que siempre estuvieron ahí para darme palabras de apoyo y un abrazo reconfortante para renovar energías. Ustedes han sido siempre el motor que impulsa mis sueños y esperanzas, quienes estuvieron siempre a mi lado en los días y noches más difíciles durante mis horas de estudio. Siempre han sido mis mejores guías de vida. Hoy cuando concluyo mis estudios, les dedico a ustedes este logro amados padres, como

PROHIBIDA SU COPIA

una meta más, conquistada. Orgulloso de haberlos de que la vida los haya unido como mis padres y que en este momento tan importante estén aquí, a mi lado.

Gracias por ser quienes son y por creer en mí. . . Muchas gracias a todos.

B. Agradecimientos de Johan Coral

Expreso mis más grandes agradecimientos a Dios por el regalo maravilloso de la vida, a mis padres por brindarme su apoyo, a mi abuela Lolita como le decimos de cariño por la fortaleza en este proceso de transformación porque, aunque el camino se tornaba pedroso siempre estuvieron presentes para continuar mi proyecto de vida. A mis hijos por ser el motor que me impulsan a avivar el sentido de mi vida y mi razón de ser y existir

VII. REFERENCIAS BIBLIOGRAFICAS

[1] Bublitz, C., Renno, A. C. M., Ramos, R. S., Assis, L., Sellera, C. A. C., Trimer, R. Guizilini, S. (2016). Acute effects of low-level laser therapy irradiation on blood lactate and muscle fatigue perception in hospitalized patients with heart failure—a pilot study. Lasers in medical science, 31(6), 1203 1209

[2] Elshafei, M., y Shihab, E. (2021). Towards detecting biceps muscle fatigue in gym activity using wearables. Sensors, 21(3), 759.

[3] Karvekar, S., Abdollahi, M., y Rashedi, E. (2021). Smartphone-based human fatigue level detection using machine learning approaches. Ergonomics, 64(5), 600–612.

[4] Lehmann, E. L., y Casella, G. (2006). Theory of point estimation. Springer Science & Business Media.

[5] Li, M., Li, J., y Shu, M. (2020). Detection of muscle fatigue by fusion of agonist and synergistic muscle semg signals. En 2020 ieee 33rd international symposium on computer-based medical systems (cbms) (pp. 95–98).

[6] Salas, R. (2004). Redes neuronales artificiales. Universidad de Valparaıso. Departamento de Computación, 1, 1–7.

[7] Williams, N. (2017). The borg rating of perceived exertion (rpe) scale. Occupational Medicine, 67(5), 404–405.

[8] Yousif, H. A., Zakaria, A., Rahim, N. A., Salleh, A. F. B., Mahmood, M., Alfarhan, K. A. Hussain, M. K. (2019). Assessment of muscles fatigue based on surface emg signals using machine learning and statistical approaches: a review. En Iop conference series: materials science and engineering (Vol. 705, p. 012010).

[9] Fuentes de las figuras y tablas: Esta investigación.

PROHIBIDA SU COPIA