



RECONOCIMIENTO E IDENTIFICACIÓN DE CONDICIÓN MÉDICA UTILIZANDO HERRAMIENTAS CAD, EMPLEADO EN DOS CASOS DE APLICACIÓN DURANTE LA EXPERIENCIA EN NEXO GLOBAL VALLE 2021-22

Manuel Alejandro Henao Ramirez

Estudiante del programa de Ingeniería Mecatrónica
Universidad Autónoma de Occidente



El conocimiento es de todos

Minciencias



Enlazando el futuro de los jóvenes Vallecaucanos

DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

Grupo de Investigación Flexi Lab – Wu Group
Tutoría a cargo de la Dr. Yuehwern Yih
Universidad de Purdue

DEPARTAMENTO DE DEPARTAMENTO DE AUTOMÁTICA Y ELECTRÓNICA

Grupo de Investigación Diseño de Experiencias
Tutoría a cargo del Dr. Diego Martínez Castro
Universidad Autónoma de Occidente

Ministerio de Ciencia Tecnología e Innovación
Gobernación del Valle del Cauca
Instituto Financiero para el Desarrollo del Valle del Cauca INFIVALLE
Universidad Santiago de Cali

Pasantía Internacional “Nexo Global Valle del Cauca”
Santiago de Cali, Colombia
30 de marzo de 2022

COMITÉ EDITORIAL DE LA UNIVERSIDAD SANTIAGO DE CALI

Carlos Andrés Pérez Galindo
Rector
Claudia Liliana Zúñiga Cañón
Directora General de Investigaciones
Edward Javier Ordóñez
Editor

DISEÑO Y DIAGRAMACIÓN

Juan Diego Tovar Cardenas
librosusc@usc.edu.co



El conocimiento es de todos

Minciencias

RECONOCIMIENTO E IDENTIFICACIÓN DE CONDICIÓN MÉDICA UTILIZANDO HERRAMIENTAS CAD, EMPLEADO EN DOS CASOS DE APLICACIÓN DURANTE LA EXPERIENCIA EN NEXO GLOBAL VALLE 2021-22

Recognition and identification of medical conditions using CAD tools, used in two application cases during the Nexo Global Valley 2021-22 experience

Manuel Alejandro Henao Ramirez

Estudiante del programa de Ingeniería Mecatrónica

Universidad Autónoma de Occidente

 manuel.henao9913@gmail.com

Resumen. El diagnóstico asistido por ordenador (CAD) es el conjunto de tecnologías que desarrollan conceptos aplicados de inteligencia artificial (IA), visión computacional y procesamiento de datos clínicos. Su principal aplicación es la identificación de anomalías en el cuerpo humano antes de un análisis realizado por un profesional. Se trata de un enfoque revolucionario para el diagnóstico médico debido los beneficios presentados en la experiencia del paciente, la eficacia de la respuesta temporal para el diagnóstico, así como la adaptabilidad en diferentes tipos de aplicaciones. El presente trabajo, describe la experiencia en una pasantía internacional en la cual se trabajaron con dos desarrollos de “wearables” (sensores vestibles) en donde se identificaron, diseñaron y evaluaron soluciones a partir del análisis que las herramientas CAD permiten emplear sobre las variables de interés, con el fin de ser una herramienta de apoyo en el proceso de diagnóstico médico. En primer lugar, se realizará una contextualización del trabajo realizado, atravesando por los principales resultados obtenidos, dificultades presentadas, finalizando con una reflexión de los desafíos a futuro que desde ambos desarrollos se establecen.

Palabras clave: *diagnóstico asistido por computadora (CAD), aprendizaje profundo, salud, wearables.*

Abstract. Computer-aided diagnosis (CAD) is the set of technologies that develop applied concepts of artificial intelligence (AI), computer vision and clinical data processing. Their main application is the identification of anomalies in the human body prior to analysis by a professional. It is a revolutionary approach to medical diagnosis due to the benefits presented in the patient experience, the efficiency of the time response for diagnosis, as well as the adaptability in different types of applications. This paper describes the experience in an international internship in which two developments of wearables devices were worked on, where solutions were identified, designed and evaluated based on the analysis that CAD tools allow to use on the variables of interest, in order to be a support tool in the medical diagnostic process. Firstly, a brief background of the work carried out will be presented, going through the main results obtained, difficulties encountered, ending with a reflection on the future challenges that are established from both developments.

Keywords: *computer-aided diagnosis (CAD), deep learning, healthcare, wearables.*

INTRODUCCIÓN

El cuidado de la salud al igual que todos los sectores productivos está experimentando grandes cambios en el status quo de las entidades de la salud debido a la llamada cuarta revolución industrial también, conocida como la revolución de los datos. Esto en gran medida ya que, gracias a la abundancia en los datos biomédicos o datos clínicos, se ha permitido modificar el paradigma del autocuidado y la interacción doctor-paciente (Miotto et al., 2018). En este campo, la extracción de características y obtención de conocimiento a partir de datos clínicos tales como imágenes médicas, historias clínicas y señales biológicas, representa un reto clave en la transformación de este sector, un ejemplo de lo anterior, es el enfoque que se busca dar con los sistemas predictivos de autocuidado con la medicina de precisión, la cual busca garantizar un tratamiento indicado, en el tiempo indicado a partir del análisis oportuno de los datos clínicos del paciente (Collins & Varmus, 2015).

El diagnóstico asistido por ordenador (CAD) permite una interacción interdisciplinaria entre las ciencias de la salud y las ciencias computacionales, ofreciendo una herramienta de apoyo en los procesos de toma de decisiones, testeo y diagnóstico por parte del profesional de la salud en tareas clínicas, operacionales y epidemiológicas (Luxton, 2016) (Shaw et al., 2019).

Debido a la compleja dinámica del cuerpo humano, es importante implementar algoritmos adaptativos para las aplicaciones impredecibles y cambiantes en el área de la salud. Por ello, este enfoque es muy revolucionario, debido a que se pueden manejar grandes volúmenes de datos, reduciendo el sesgo por posibles errores humanos, permitiendo ofrecer toma de decisiones objetivas, eficientes y oportunas, capaces de poder salvar una vida al considerar una aproximación proactiva frente al diagnóstico y posterior tratamiento de enfermedades.

Como se mencionó, existen múltiples fuentes de datos biomédicos que varían en el tipo de dato a procesar, las aplicaciones de las herramientas CAD más relevantes giran en torno al procesamiento de imágenes médicas tales como resonancias magnéticas, ecografías, radiografías y tomografías computarizadas (Fenoll, 2010). Así mismo, se presenta el análisis de los registros de historias clínicas digitales, en las cuales se incluye información estructurada como no estructurada; la primera involucra información como diagnósticos, medicaciones, exámenes de laboratorio, entre otras, mientras que la no estructurada se refiere a notas médicas libres. Por último, se presentan los datos obtenidos por “wearables” también conocidos como sensores vestibles

en los cuales predominan la adquisición de señales fisiológicas (Greene et al., 2016) con diferentes principios de funcionamiento que evalúan principalmente la actividad o respuesta cerebral, cardíaca, muscular, en la piel, en la sangre y el análisis automático de expresión facial.

Ahora bien, una vez descrita la relevancia y beneficios de las herramientas CAD en el sector salud, se procederá a describir los dos casos de aplicación los cuales están relacionados con desarrollos de wearables en estados diferentes de desarrollo en colaboración con dos grupos de investigación de la universidad de Purdue.

Por un lado, veinticinco voluntarios fueron sometidos a pruebas en diez diferentes escenarios de conducción, tales como estar en una densidad de tráfico baja y alta, también conduciendo en carreteras rectas y curvas, mientras realizaban tareas secundarias (memoria y cálculos matemáticos). Para cada escenario se adquirieron señales cardiovasculares similares a las de la fotopletoxiografía (PPG) utilizando un desarrollo de nanosensores vestibles por parte del grupo de investigación con el fin de estimar el estado de carga mental de los sujetos. El objetivo consistió en establecer la correlación entre las cargas mentales y los parámetros fisiológicos adquiridos por la señal PPG de la frecuencia cardíaca (HR) y la variabilidad de la frecuencia cardíaca (HRV) mediante algoritmos de IA.

El estrés se ha convertido en una de las causas con mayor incidencia en muchas enfermedades de la sociedad moderna, este se puede entender como un factor físico, químico o emocional que provoca tensión corporal o mental y que puede ser un factor de causalidad de enfermedades (Can et al., 2019). Según el Instituto Americano del estrés, USA tiene gastos superiores a 300.000 millones de dólares por año debido a enfermedades causadas por estrés (World Health Organization, 2020).

El estrés se presenta en dos formas principales: agudo y crónico. En la primera, se relaciona con presiones y demandas que provienen de situaciones pasadas o futuras en un corto plazo. Por otro lado, las crónicas hacen alusión a las presiones o demandas de larga duración (Greene et al., 2016). En ambas situaciones, el estrés se manifiesta tanto psicológicamente como fisiológicamente.

El foco del presente trabajo giró entorno en analizar las cargas mentales a partir del comportamiento de una de las variables fisiológicas medidas que tienen los usuarios al experimentar diferentes condiciones de conducción.

Uno de los factores predominantes en el estudio de cargas mentales involucra la actividad del corazón, este órgano vital bombea



sangre alrededor del todo el cuerpo con un ritmo en particular. Dicho ritmo es medido mediante los latidos por minuto del corazón o también conocido como ritmo cardíaco (HR). Factores como la edad, género y enfermedades, alteran el desempeño de como el corazón opera y por consiguiente su ritmo (Antelmi, 2004). La variación del tiempo entre latidos del corazón es conocido como un fenómeno fisiológico llamado variabilidad de ritmo cardíaco (HRV) (Londhe & Atulkar, 2019).

La reacción de estrés es percibida por el cuerpo una vez que detecta una posible amenaza. Independientemente de ser real o imaginaria, los mecanismos defensivos del cuerpo inician un proceso automático y rápido llamado reacción de “lucha o huida” o respuesta de estrés para protegerse (Can et al., 2019). Tanto el ritmo cardíaco como su variabilidad, son reguladas por un mecanismo neuro-cardíaco conocido como el sistema nervioso autónomo (ANS) este está compuesto por dos módulos, el sistema nervioso simpático (SNS) y el sistema nervioso parasimpático (PNS).

El primero, dentro de estas situaciones provee un incremento de suministro de sangre en el cuerpo incrementando el HR, mientras que el segundo, una vez desaparece la situación de estrés, regula el organismo disminuyendo el HR. Cuando la variabilidad de ritmo cardíaco (HRV) se combina con otros métodos de detección de estrés, establecen marcadores fisiológicos y físicos asociados al estrés en un individuo (Munla et al., 2015).

Con esto presente, la variable analizada correspondió al cambio de presión y volumen en sangre mediante la fotopletoangiografía (PPG) esta, es una técnica óptica no invasiva y de bajo costo que detecta cambios de volumen sanguíneo mediante un pulso óptico generado por un emisor de luz infrarroja con un fotodetector situado muy cerca que actúa como el receptor de la luz reflejada (Elgendi, 2020). Así mismo, este método en comparativa con otros métodos de detección de estrés, es altamente utilizable en wearables debido a su alta precisión, bajo costo, bajo mantenimiento y por emplear métodos no intrusivos (Greene et al., 2016).

Respecto al segundo desarrollo, el agua es un elemento esencial para la vida incluyendo el correcto funcionamiento corporal donde la relación de las células con el medio permite que haya un equilibrio hídrico y en el caso de haber una pérdida de significativa de estas sustancias, los mismos órganos o estímulos como la necesidad de ingerir líquidos permiten la regulación de este hecho. Sin embargo, para los adultos mayores este proceso no funciona de igual forma que en los jóvenes, debido a que la sensación de sed y la capacidad de concentración urinaria suele disminuir con la edad. Como consecuencia, la deshidratación por

pérdida de agua en adultos mayores se asocia con un aumento de mortalidad y discapacidad (Hooper et al., 2016).

Teniendo en cuenta lo anterior, desde una etapa previa se está realizando el desarrollo de un pañal inteligente para evaluar el estado de deshidratación en adultos mayores a partir del esfuerzo de iones presente en la orina, el objetivo consistió en establecer los niveles de deshidratación en adultos mayores mediante algoritmos de IA con el fin de monitorear el estado de la persona. En primer lugar, se ahondará en un marco teórico relevante para el análisis de las variables de interés, posteriormente, se describirá un esbozo de los resultados obtenidos, finalizando por un proceso de reflexión y conclusiones de las dificultades presentadas y desafíos a futuro para cada desarrollo.

REFLEXIÓN

Desde el enfoque del diagnóstico asistido por computadora se presenta una breve explicación de las arquitecturas de algoritmos de aprendizaje automático más empleadas en este campo (Miotto et al., 2018):

- Redes Neuronales Convolucionales (CNN): La arquitectura básica de la CNN consiste en una capa convolucional (operaciones de sumas y multiplicaciones aplicadas a una imagen) y de agrupación, opcionalmente seguida de una capa totalmente conectada para la predicción supervisada. En la práctica, las CNN están compuestas generalmente por más de 10 capas convolucionales y de agrupación para modelar mejor el espacio de entrada y realizar la extracción automática de características de bajo nivel a alto nivel. Las aplicaciones más exitosas las CNN se obtienen en visión computacional y extracción de características especialmente en datos de dos dimensiones (imágenes, videos, etc.)
- Redes Neuronales Recurrentes (RNN): Las RNN son útiles para procesar secuencias de datos. Estas, están compuestas por una red que realiza la misma tarea para cada elemento de una secuencia, y cada valor de salida depende de los cálculos anteriores. En la formulación original, las RNN estaban limitadas a mirar hacia atrás sólo unos pocos pasos debido a los problemas del desvanecimiento del gradiente. Las redes de memoria a largo plazo (LSTM) (Hochreiter & Schmidhuber, 1997) y unidades recurrentes cerradas (GRU) (Cho et al., 2014) abordan este problema modelando el estado oculto con celdas que deciden qué mantener en la memoria (y qué suprimir) teniendo en cuenta el estado anterior de la memoria, la memoria actual y el valor de entrada. Estas variantes son

eficientes a la hora de capturar dependencias a largo plazo y han dado excelentes resultados en aplicaciones secuencias de tiempo y de procesamiento del lenguaje natural (NLP)

- Autoencoders (AE): Es un modelo de aprendizaje no supervisado en el que el valor objetivo es igual a la entrada, es decir, no tiene determinado el resultado que se va a obtener tras el aprendizaje o en otros términos la salida no está definida con anterioridad. Los AE están compuestos por un decodificador que transforma la entrada en una representación latente (representación comprimida de los datos), y por un decodificador, que reconstruye la entrada a partir de esta representación. Los AE se entrenan para minimizar el error de reconstrucción (filtrado de datos, remoción de ruido). Al restringir la dimensión de la representación latente para que sea diferente de la entrada (y, por consiguiente, de la salida), es posible descubrir patrones relevantes en los datos. Las AE se utilizan generalmente para el aprendizaje de la representación y a menudo se regularizan añadiendo ruido a los datos originales.

Como bien se mencionó anteriormente, el desarrollo de la experiencia en Nexo Global Valle 2021-2022 estuvo compuesta de dos casos de aplicación con el propósito de aplicar herramientas CAD, cada uno en etapas diferentes de desarrollo, por un lado, en la relación entre estrés y las variables fisiológicas anteriormente presentadas, el aporte giró en torno a la primera etapa de procesamiento que se deben realizar en variables biológicas el cual está relacionado con remoción de artefactos o ruidos eléctricos y detección de eventos (Karagiannis et al., 2011). Esto con el fin de estimar las variables de ritmo cardíaco (HR) y su variabilidad (HRV). Este proceso estuvo enfocado en la etapa de pre procesamiento de las señales de fotopleto-mografía de los 25 usuarios que fueron participantes de un experimento previo por parte del grupo de investigación del Dr. Wenzhou Wu de la universidad de Purdue. El objetivo era identificar, evaluar e implementar un algoritmo que permitiera realizar la clasificación y cálculo de los parámetros mencionados de forma automática, siendo esta etapa el principal insumo para posteriores desarrollos que estén relacionados con la correlación de estas variables con cargas mentales.

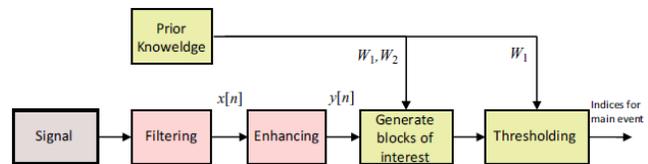
Por otro lado, se desarrolló una metodología que buscaba identificar, evaluar y posteriormente implementar pruebas sobre el pañal inteligente tomando como referencia el desarrollo de sensores basados en papel (Singh et al., 2018) que actualmente está desarrollando el grupo de investigación del Dr. Ramsés Martínez de la universidad de Purdue. Esto con el fin de garantizar calidad

en la recolección de datos para proponer en desarrollos posteriores un modelo de clasificación del estado de deshidratación de personas mayores empleando herramientas que desde el CAD se proponen.

Con el proyecto del Dr. Wu, se identificó un algoritmo basado en conocimiento previo, ampliamente utilizado en aplicaciones sobre señales biológicas conocido como algoritmo de medias móviles relacionadas con dos eventos (TERMA) (Elgendi, 2016) (Elgendi, 2020). Este detecta el valor máximo de la señal de fotopleto-mografía dado por la componente la señal sistólica en su valor máximo el cual en condiciones normales tiene correlación con el ritmo cardíaco y su valor máximo está en fase con la onda R en la señal electrocardiográfica (ECG) lo cual, permite estimar el valor de ritmo cardíaco (HR) y su variabilidad (HRV).

Este algoritmo como se puede apreciar en la Figura 1 consta de seis etapas: la primera consta de un filtrado para remoción de ruido eléctrico y componentes no pertenecientes a la señal de PPG (Liang et al., 2018), posteriormente una elevación de la señal al cuadrado, incrementando los componentes de alta frecuencia. Con esto presente, se generan unos bloques de interés basados en el tiempo de duración aproximada del evento (w_1) y duración aproximada de un ciclo o latido del corazón (w_2), con estas consideraciones se genera una umbralización permitiendo diferenciar los picos verdaderos de los picos asociados al ruido eléctrico.

Figura 1. Algoritmo TERMA.



Nota: Diagrama de flujo del algoritmo de medias móviles relacionadas con dos eventos (TERMA) algoritmo para detectar el evento principal en una señal biológica cuasi periódica.

Durante la etapa de implementación y validación, (Makowski et al., 2021) se identificó que el algoritmo no generalizaba la detección de eventos en todos los sets de datos. Debido a esto, se evaluará el desarrollo de un procesamiento digital de señales más riguroso, permitiendo modificar parámetros con el fin de ajustar su eficiencia en todo el set de datos de manera personalizada por cada actividad realizada por el usuario.

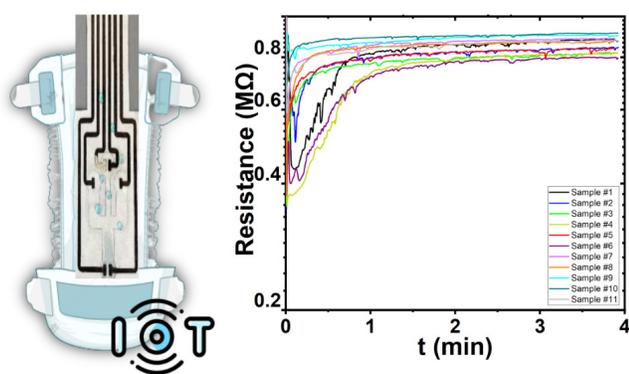
Por otro lado, con el proyecto del Dr. Martínez se desarrollaron múltiples pruebas de confiabilidad sobre el desarrollo del sensor para medir esfuerzo iónico de la orina. Esta variable medida a



partir de la conductividad eléctrica de la muestra de orina. Para ello, se incurrió en múltiples pruebas de confiabilidad evaluando materiales y métodos de manufactura siguiendo lineamientos de desarrollo de sensores wearables en base de papel para aplicaciones biológicas (Ahmed et al., 2016) (Singh et al., 2018).

Debido a que el desarrollo está próximo a una publicación, no se puede ahondar en detalles asociados al proceso de manufactura del sensor, no obstante, en la Figura 2 se puede evidenciar una ilustración del sensor sobre el pañal y los datos recolectados de concentración de iones en la orina.

Figura 2. Ilustración desarrollo pañal inteligente.



Nota: Pañal inteligente inalámbrico desarrollado por investigadores de la Universidad de Purdue y el Instituto Tecnológico de California y conductividad de muestras de orina para estado de deshidratación de adultos mayores.

Desde las herramientas CAD se evaluará la posibilidad de analizar estos datos a partir del enfoque de aprendizaje automático. Esto mediante el uso de un algoritmo que procese secuencias de tiempo, considerando lo anterior, las arquitecturas que se ajustan para esta tarea son las redes neuronales recurrentes (RNN), redes de memoria a largo plazo (LSTM) y unidades recurrentes cerradas (GRU). Este análisis se espera realizar en futuros trabajos una vez la etapa de recolección de los datos por parte del sensor esté finalizada.

CONCLUSIONES

La tendencia dada en la actualidad por la cuarta revolución industrial de procesar datos y brindar un valor agregado ha representado un crecimiento en el área de desarrollo de los dispositivos wearables.

En muchas ocasiones se subestima el potencial que tiene un programa computacional para brindar respuestas eficientes y pre-

cisas, y más aún en el área de la salud donde se pueden presentar mayores dificultades a comparación de otras áreas. A pesar de esto, hasta ahora no es posible reemplazar al profesional de la salud en el campo de diagnóstico ya que el algoritmo puede presentar posibles errores o sesgos al no identificar eficazmente los patrones que describen la enfermedad con precisión. Sin embargo, con los diferentes resultados (Miotto et al., 2018) se han demostrado que los algoritmos de aprendizaje automático juegan un papel fundamental para disminuir el error humano y agilizar el análisis de datos y de esta forma optimizar el tiempo de análisis del experto contando como una opinión de revisión y así garantizar un tratamiento indicado, en el tiempo indicado.

El aprendizaje profundo puede modificar el paradigma de la atención sanitaria, ya que, considerando la gran cantidad de datos suministrados por los registros de pacientes, se puede estimar una única representación holística del paciente para apoyar eficazmente a los médicos en sus actividades diarias.

Múltiples desafíos surgen con este enfoque, ya que se presenta una complejidad dada por la alta variedad en la naturaleza de los datos, limitaciones de acceso a datos de personas, esto se ve evidenciado con los requerimientos que exige el protocolo IRB para tratar datos reales de personas o el IACUC en caso de animales. Este tipo de protocolos afecta directamente este enfoque, debido a que desde los algoritmos de aprendizaje profundo la efectividad y robustez se incrementan debido a la cantidad de datos médicos que se suministren.

Otro desafío que enfrentan, es incorporar habilidades propias de los expertos de la salud tales como la experiencia en el análisis de este tipo de datos y la interpretabilidad de los mismos.

En esta experiencia trabajando con dos desarrollos de sensores wearables, se evidenció uno de los principales desafíos que estas tecnologías enfrentan. Dicho desafío corresponde a garantizar una recolección de buena calidad de datos. A diferencia de otros campos de aplicación donde los datos generalmente están limpios y bien estructurados, en el sector de la salud los datos son muy heterogéneos, ambiguos, ruidosos e incompletos. Bajo estas condiciones, emplear análisis de aprendizaje automático puede traducirse en obtener gran cantidad de redundancias y sesgos en los resultados dados en el entrenamiento. Esta etapa de recolección, se considera la más crítica en esta área, en gran medida por las limitaciones en hardware y consumo energético que tienen estos dispositivos.

No obstante, de manera personal me gustaría reconocer de primera mano el logro obtenido en los dos campos de aplicación

en los cuales se desarrolló la experiencia, esto en gran medida ya que el enfoque de aplicar herramientas CAD no estaba contemplado en ninguno de los dos proyectos. Con lo anterior, se presentaron las bases de los beneficios que estas herramientas pueden representar para analizar los datos obtenidos por ambos grupos de investigación.

Así mismo, reconocer esta experiencia de Nexo Global Valle del Cauca 2021-2022 como una etapa de crecimiento personal y profesional la cual me permitió reconocer oportunidades dentro del campo de la investigación, donde las dinámicas de trabajo son diferentes. Como visión profesional, considero que hoy en día un profesional debe ser proactivo con su proceso de aprendizaje para mantenerse actualizado con los desarrollos que se están realizando día a día, sobretodo en áreas relacionadas con desarrollos tecnológicos. En este sentido desde la investigación se aportan muchas actitudes que promueven este comportamiento. Dichas actitudes las quiero implementar ejerciendo mi profesión. Así mismo, fue desafiante y enriquecedor interactuar con grupos de investigación interdisciplinarios y desde mis habilidades como ingeniero mecatrónico identificar oportunidades de mejora aportando en los desarrollos que estos grupos se encuentran realizando ofreciendo un valor agregado.

REFERENCIAS BIBLIOGRÁFICAS

- Ahmed, S., Bui, M.-P. N., & Abbas, A. (2016). Paper-based chemical and biological sensors: Engineering aspects. *Biosensors & Bioelectronics*, 77, 249–263. <https://doi.org/10.1016/j.bios.2015.09.038>
- Antelmi, I. (2004). Influence of age, gender, body mass index, and functional capacity on heart rate variability in a cohort of subjects without heart disease". *The American j. of cardiology*, 93(3), 381–385.
- Can, Y. S., Arnrich, B., & Ersoy, C. (2019). Stress detection in daily life scenarios using smart phones and wearable sensors: A survey. *Journal of Biomedical Informatics*, 92(103139), 103139. <https://doi.org/10.1016/j.jbi.2019.103139>
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv [cs.CL]*. <https://doi.org/10.48550/ARXIV.1406.1078>
- Collins, F. S., & Varmus, H. (2015). A new initiative on precision medicine. *The New England Journal of Medicine*, 372(9), 793–795. <https://doi.org/10.1056/NEJMp1500523>
- Elgendi, M. (2016). TERMA framework for biomedical signal analysis: An economic-inspired approach. *Biosensors*, 6(4), 55. <https://doi.org/10.3390/bios6040055>
- Elgendi, M. (2020). *PPG Signal Analysis: An Introduction Using MATLAB*. CRC Press.
- Fenoll, I. G. (2010). Aportaciones a la Segmentación y Caracterización de Imágenes Médicas 3D. Universidad de Sevilla. <https://docplayer.es/53586479-Aportaciones-a-la-segmentacion-y-caracterizacion-de-imagenes-medicas-3d.html>
- Greene, S., Thapliyal, H., & Caban-Holt, A. (2016). A Survey of Affective Computing for Stress Detection: Evaluating technologies in stress detection for better health. *IEEE consumer electronics magazine*, 5(4), 44–56. <https://doi.org/10.1109/mce.2016.2590178>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hooper, L., Bunn, D. K., Downing, A., Jimoh, F. O., Groves, J., Free, C., Cowap, V., Potter, J. F., Hunter, P. R., & Shepstone, L. (2016). Which frail older people are dehydrated? The UK DRIE study. *The Journals of Gerontology. Series A, Biological Sciences and Medical Sciences*, 71(10), 1341–1347. <https://doi.org/10.1093/gerona/glv205>
- Karagiannis, A., Constantinou, P., & Vouyioukas, D. (2011). Biomedical time series processing and analysis methods: The case of empirical mode decomposition. En *Advanced Biomedical Engineering*. InTech.
- Liang, Y., Elgendi, M., Chen, Z., & Ward, R. (2018). An optimal filter for short photoplethysmogram signals. *Scientific Data*, 5(1), 180076. <https://doi.org/10.1038/sdata.2018.76>
- Londhe, A. N., & Atulkar, M. (2019). Heart rate variability: A methodological survey. 2019 International Conference on Intelligent Sustainable Systems (ICISS).
- Luxton, D. D. (2016). An introduction to artificial intelligence in behavioral and mental health care. En D. D. Luxton (Ed.), *Artificial Intelligence in Behavioral and Mental Health Care* (pp. 1–26). Elsevier.
- Makowski, D., Pham, T., Lau, Z. J., Brammer, J. C., Lespinasse, F., Pham, H., Schölzel, C., & Chen, S. H. A. (2021). NeuroKit2: A Python toolbox for neurophysiological signal processing. *Behavior Research Methods*, 53(4), 1689–1696. <https://doi.org/10.3758/s13428-020-01516-y>



- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities and challenges. *Briefings in Bioinformatics*, 19(6), 1236-1246. <https://doi.org/10.1093/bib/bbx044>
- Munla, N., Khalil, M., Shahin, A., & Mourad, A. (2015). Driver stress level detection using HRV analysis. 2015 International Conference on Advances in Biomedical Engineering (ICABME).
- Shaw, J., Rudzicz, F., Jamieson, T., & Goldfarb, A. (2019). Artificial intelligence and the implementation challenge. *Journal of Medical Internet Research*, 21(7), e13659. <https://doi.org/10.2196/13659>
- Singh, A. T., Lantigua, D., Meka, A., Taing, S., Pandher, M., & Camici-Unal, G. (2018). Paper-based sensors: Emerging themes and applications. *Sensors (Basel, Switzerland)*, 18(9), 2838. <https://doi.org/10.3390/s18092838>
- World Health Organization. (2020). Occupational health: Stress at the workplace. <https://www.who.int/news-room/questions-and-answers/item/occupational-health-stress-at-the-workplace>

Cita recomendada

Henao Ramirez, M. A. (2022). Reconocimiento e identificación de condición médica utilizando herramientas CAD, empleado en dos casos de aplicación durante la experiencia en Nexo Global Valle 2021-22. *Nexo Global. Artículos de reflexión*, pp. 1-9.