

ANÁLISIS DE MOVIMIENTO MEDIANTE TEXTIL INTELIGENTE.

Delgado-Oleas, G^{1,2}, Avellar, L³, Stefano-Filho, C⁴, Frizzera, A³, Leal-Junior, A³, Rocon, E¹.

¹Centro de Automática y Robótica (CAR), CSIC-UPM, Madrid, España. gabriel.delgado@csic.es

²Escuela de Ingeniería Electrónica, Universidad del Azuay, Cuenca-Ecuador.

³Programa de Posgrado en Ingeniería Eléctrica, Universidade Federal do Espírito Santo (UFES).

⁴Grupo de Neurofísica, Instituto de Física “Gleb Wataghin”, Universidad de Campinas, Campinas, Brasil.

Resumen

Este artículo presenta el desarrollo de un textil inteligente (smart garment) portátil dotado de 30 sensores de fibra óptica multiplexados que, a través de algoritmos de Inteligencia Artificial (IA), es capaz de clasificar de actividades de múltiples sujetos. Se evalúan seis actividades diarias: de pie, sentado, en cuclillas, brazos arriba y abajo, caminar y correr. El clasificador utilizado es el de k vecinos más cercanos y los resultados de 10 ensayos de todos los voluntarios presentaron una precisión de 94,00 (0,14)%. La cadencia y la frecuencia respiratoria se estimaron y compararon con los datos de una unidad de medición inercial ubicada en la parte posterior de la prenda. El error más alto fue del 2,22 %. El enfoque propuesto presentó la viabilidad para el reconocimiento de actividad y la extracción de parámetros relacionados con el movimiento, en el ámbito de los desarrollos en Healthcare 4.0.

Palabras clave: healthcare, textil inteligente, análisis de movimiento.

1 INTRODUCCIÓN (12 pts, negrita)

Smart Healthcare es una aplicación Internet of Things (IoT) que tiene como objetivo mejorar la calidad de vida cotidiana en los humanos [1]. Los dispositivos con sensores se emplean para recopilar datos médicos y signos vitales de los pacientes para monitorear las condiciones de salud, rastrear el progreso e indicar anomalías [2]. Además, la monitorización remota de la salud con alta velocidad y ejecución inteligente se puede lograr aumentando el número de dispositivos y utilizando algoritmos de Inteligencia Artificial (IA) [3], obteniendo un mayor potencial para tomar decisiones inteligentes en la vida real, [1,4].

Las actividades motoras y la condición fisiológica son información importante para el control de la salud del individuo. Entre los parámetros relacionados con la marcha, la monitorización de la cadencia puede proporcionar información valiosa sobre la marcha y las actividades del usuario, donde las desviaciones en la cadencia pueden estar relacionadas con la fatiga del paciente o, en algunos casos, puede estar relacionado con deterioro físico e incluso cognitivo, [5].

La frecuencia respiratoria (FR) es un parámetro fisiológico que corresponde al número de ciclos respiratorios por minuto (inhalación y exhalación). El monitoreo continuo de la frecuencia respiratoria puede ayudar a detectar enfermedades pulmonares en su etapa temprana o ayudar a evaluar el nivel de acondicionamiento físico y la fatiga del movimiento [6].

Entre los dispositivos vestibles, se encuentran los textiles inteligentes y los cinturones torácicos basados en tecnologías electrónicas y ópticas, que proporcionan la estimación de la frecuencia respiratoria a partir de vibraciones o desplazamientos torácicos [7]. Sin embargo, tales sensores no solo incluyen otra prenda o accesorio adicional al que ya está usando el paciente, sino que también tienen desviaciones en la medición dependiendo de la posición de los sensores y son sensibles a los movimientos de los usuarios, [7]. Dichos inconvenientes se mitigan utilizando una prenda inteligente, donde existe la integración de todos los sensores en un solo accesorio de ropa, que también puede detectar la frecuencia respiratoria en diferentes regiones bajo movimientos dinámicos del usuario.

La integración de sensores con la ropa, los llamados textiles inteligentes, es una solución atractiva para superar estos inconvenientes. Los textiles inteligentes presentan las ventajas de la compacidad de los sensores y una mayor transparencia entre el sensor y el usuario, lo que conduce al monitoreo de la actividad natural sin inhibir el movimiento del usuario, [8]. Además, los textiles inteligentes se manipulan fácilmente.

Los Sensores de Fibra Óptica (SFO) tienen características atractivas para la tecnología textil inteligente, que incluyen capacidad de multiplexación, peso ligero y tamaño compacto. Además, los SFO no son susceptibles a las descargas eléctricas y son inmunes a las interferencias electromagnéticas, [9].

El uso de una solución integrada y totalmente portátil como la que se propone en este trabajo proporciona beneficios para aplicaciones de atención médica remota, debido a la posibilidad de monitorear a los pacientes en diferentes actividades de su vida diaria utilizando sistemas portátiles que no restringen su patrón natural de movimientos, [6].

2 METODOLOGÍA

El sistema propuesto comprende dos secciones, la primera una prenda inteligente fotónica utilizando estructuras compuestas de sensores basadas en tecnología de fibra óptica (Smart Garment), la segunda sección se basa en un algoritmo de clasificación de “Machine Learning” k vecinos más cercanos (kNN), que permite la monitorización simultánea de diferentes parámetros relacionados con la salud.

2.1 PRENDA INTELIGENTE.

La prenda inteligente SmartGarment (Figura 1) consta de 30 sensores SFO basados en variaciones de intensidad distribuidos en cuatro fibras e integrados en un tejido. Con el fin de obtener una distribución uniforme de los sensores en la prenda inteligente, se colocan sensores adyacentes con una distancia de 10 cm entre ellos para evaluar la posibilidad de identificar y clasificar actividades usando estos arreglos de sensores.




Figura 1. Descripción general de SmartGarment.

En este caso, la tensión aplicada sobre la fibra óptica conduce a una variación en la potencia óptica transmitida. Este fenómeno permite inferir el estrés o deformación en el sensor de fibra óptica a través de la variación de potencia óptica. Además, el sensor fue construido con un acoplamiento lateral entre el diodo emisor de luz (LED) y la fibra óptica con una sección lateral (exponiendo su núcleo al LED) usando resina de poliuretano transparente en el medio. Por lo tanto, una carga transversal (tensión o deformación) también da como resultado una variación de la distancia entre el LED y la fibra óptica, lo que también conduce a una variación de la potencia óptica. Para el multiplexado de los sensores se utilizó la técnica propuesta en trabajos previos, [10], donde existe una activación secuencial de cada LED en la que solo se activa un LED a la vez durante 1 ms. La detección de potencia óptica está sincronizada con la activación del LED.

La comunicación de datos se realiza por Bluetooth y toda la electrónica del sistema se alimenta con una batería, lo que da como resultado un sistema totalmente portátil. La frecuencia de adquisición del sistema es de 100 Hz, lo que reduce los problemas de adquisición de datos inestables y discontinuos. A esta tasa de muestreo, el algoritmo de clasificación es

capaz de clasificar la actividad incluso cuando hay una reducción menor de las muestras. Además, el sistema cuenta con una tarjeta microSD para el almacenamiento de datos para análisis a posteriori.

2.2 ALGORITMO DE CLASIFICACIÓN.

Se usó un algoritmo de clasificación kNN debido a su menor costo computacional, además de que presenta una alta precisión en la clasificación del movimiento, lo que conduce a un equilibrio entre la precisión y el costo computacional adecuado para sistemas totalmente integrados [11].

La clasificación se realiza a través del algoritmo de aprendizaje automático, donde las entradas del algoritmo son la variación de potencia óptica normalizada de cada sensor, ya que la técnica de multiplexación conduce a una interferencia insignificante entre los sensores.

Las clases c1 (de pie), c2 (sentado), c3 (cuclillas), c4 (brazos arriba y abajo), c5 (caminar), c6 (correr), serán las salidas del sistema. La clase c3 (en cuclillas) representa la actividad en cuclillas, que implica una flexión/extensión de rodilla y una flexión/extensión de cadera. Por otro lado, la clase c4 representa los brazos arriba-abajo, lo que implica una gran flexión/extensión de hombros y una rotación longitudinal corta.

El conjunto de datos de kNN se permutó aleatoriamente y se dividió en entrenamiento (70 %) y prueba (30 %). Los datos de entrenamiento fueron los datos base para clasificar los datos de prueba, es decir, cada nueva muestra se comparó con todos los datos de entrenamiento. Por lo tanto, la etiqueta predominante de las k muestras más cercanas se definió como la etiqueta de esta nueva muestra, y esto se aplicó a todos los datos de prueba. Como métrica de distancia se utilizó la distancia euclídea.

Las precisiones de 10 ensayos aleatorios para todos los conjuntos de datos de voluntarios son superiores al 90 %. Las diferentes precisiones de clasificación pueden estar relacionadas con los movimientos realizados por cada voluntario durante las actividades del protocolo, ya que cada persona realiza los movimientos de una manera particular. La Figura 2 muestra la matriz de confusión de la clasificación kNN para todo el conjunto de datos, incluidos todos los voluntarios. En la diagonal de cada matriz se encuentra el porcentaje de las muestras clasificadas correctamente.

Tabla 1. Parámetros estimados de los sensores IMU (referencia) y SmartGarment: errores entre las medidas obtenidas de los dos sistemas.

Voluntario	IMU			SmartGarment			Errores		
	Cadencia (steps/min)		FR (c/min)	Cadencia (steps/min)		FR (c/min)	Cadencia (%)		FR (%)
	Caminando	Corriendo	De pie	Caminando	Corriendo	De pie	Caminando	Corriendo	De pie
1	71.96	143.94	13.19	71.96	143.94	13.20	0	0	0.08
2	79.14	155.92	13.79	77.38	156.54	13.90	2.22	0.40	0.80
3	68.36	125.94	13.79	68.60	126.64	14.04	0.35	0.56	1.81
4	73.16	146.34	14.39	72.12	145.98	14.60	1.42	0.27	1.46




Figura 2. Matriz de confusión de la clasificación

Para estimar la cadencia, se analizaron las respuestas de los sensores durante las actividades de caminar y correr. Se incorporó una unidad de medida inercial (IMU) en la parte superior trasera de la prenda como sistema de referencia para la comparación con la prenda inteligente propuesta, y se compararon los datos de “yaw” obtenidos de la IMU con la prenda inteligente fotónica (sensor 8, ya que esta El sensor está ubicado en el lateral del cuerpo y presenta una gran variación en la respuesta al caminar y correr).

Al aplicar la FFT a la respuesta temporal de los datos de yaw y del sensor 8, ambos resultados presentaron picos de frecuencia de 35.98 ciclos/min y 71.97 ciclos/min. Estas frecuencias corresponden a ciclos de zancada por minuto, lo que lleva a duplicar el valor de los ciclos de pasos por minuto, ya que una zancada consta de dos pasos. Así, analizando los resultados de FFT, la cadencia estimada es de 71,96 pasos/min (caminar) y 143,94 pasos/min (correr), no presentando error entre los resultados de los sensores fotónicos de prendas inteligentes y la IMU.

Para estimar la frecuencia respiratoria (FR), se analizaron las respuestas de los sensores durante la prueba de pie. El voluntario estaba en posición vertical y no realizó ningún movimiento para reducir

la influencia de los artefactos. Se aplicó un filtro de paso de banda entre 0.3 y 0.7 Hz para atenuar los ruidos externos. Los datos de “pitch” obtenidos por la IMU se compararon con la prenda inteligente (sensor 17, ya que este sensor está posicionado en la mitad del cuerpo y presenta una alta variación durante la tarea de respiración). Al aplicar la FFT sobre la respuesta temporal del sensor 17 y los datos de “pitch”, los resultados presentaron picos de 13,20 y 13,19 ciclos/min, respectivamente, que conducen a las frecuencias respiratorias estimadas de 26,40 y 26,38 ciclos en 2 minutos, como se presenta en la Fig. 9 Las tasas de respiración estimadas de IMU y los datos de prendas inteligentes fotónicas presentan una alta correlación (0,08% de error relativo). La Tabla 1 muestra la cadencia estimada y la frecuencia respiratoria de todos los voluntarios. Los errores entre los parámetros estimados por el SmartGarment y por la IMU ocurren debido a la sensibilidad cruzada de los sensores POF, mientras que la IMU es un sensor 3D y la extracción de parámetros involucra datos de una sola dimensión, lo que reduce la interferencia de los datos de otros ejes, disminuyendo el ruido en el análisis FFT.

3 CONCLUSIONES

En este artículo, se describe la definición y desarrollo de una prenda inteligente basada en 30 sensores SFO multiplexados para la identificación de actividad y la extracción de parámetros relacionados con el movimiento. El sistema incluye un sistema de sensores casi distribuidos, es decir, un sistema con varios puntos de medición a lo largo de los SFO y comunicación inalámbrica, lo que conduce a un sistema totalmente portátil optimizado para aplicaciones de IoT. Se propone un protocolo de reconocimiento de actividad humana para evaluar la capacidad de identificar la actividad motora humana utilizando el SmartGarment. Seis tareas de la vida diaria fueron realizadas por 4 voluntarios durante 2 minutos.

Se utilizó el clasificador kNN debido a su sencilla implementación y alto rendimiento de clasificación. Este enfoque de clasificación se repitió y los resultados de 10 ensayos presentaron una precisión de clasificación del 94,00 (0,14) % entre los voluntarios.

Los parámetros de cadencia y frecuencia respiratoria se validaron mediante el uso de una IMU colocada en la región superior de la espalda. La cadencia fue evaluada durante las actividades de marcha y carrera y presentó errores de 1,00 (1,01)% y 0,31 (0,24)%, respectivamente, cuando se compara con la cadencia estimada por los datos de la IMU. El parámetro de frecuencia respiratoria se evaluó durante la actividad de pie en la que no hay movimiento y los sensores fotónicos de la prenda inteligente presentaron un error de 1,04 (0,76)% del resultado de la IMU. La baja media y desviación estándar de los errores indican una buena precisión y repetibilidad del sistema para medir los diferentes parámetros. Además, el sistema propuesto demostró ser una opción factible para extraer diferentes tipos de parámetros biomédicos utilizando una prenda ligera instrumentada que puede emplearse en las actividades diarias sin perturbar el movimiento del usuario. Por lo tanto, el enfoque propuesto es una opción optimizada para aplicaciones de atención médica remota para identificar actividades y extraer diferentes parámetros utilizando componentes compactos y de bajo costo integrados en una vestimenta habitual. Los trabajos futuros incluyen la aplicación de todo el sistema en un monitoreo de atención médica en tiempo real para ser utilizado en una evaluación clínica.

Agradecimientos

Este trabajo pertenece al proyecto Discover2Walk “Desarrollo de una plataforma robótica para ayudar a niños con Parálisis Cerebral a descubrir cómo caminar”, financiado por el Ministerio de Ciencia e Innovación (Ref. PID2019-105110RB-C31).

English summary

SMART GARMENT FOR MOVEMENT ANALYSIS

Abstract

This paper presents the development of a wearable smart garment equipped with 30 multiplexed fiber optic sensors that, through Artificial Intelligence (AI) algorithms, can classify multiple subjects' activities. Six daily activities are evaluated: standing, sitting, squatting, arms up and down, walking, and running. The classifier used is k-nearest neighbors, and results from 10 trials of all volunteers showed an accuracy of 94.00 (0.14)%. Cadence and respiratory rate were estimated and compared with data from an inertial measurement unit located on the back of the garment. The highest error was 2.22%. The proposed approach presented feasibility for activity recognition and extraction of motion-related parameters in the scope of Healthcare 4.0 developments.

Keywords: healthcare, smartgarment, movement analysis.

Referencias

- [1] K. Shafique, B. Khawaja, F. Sabir, ... S. Q.-I., and undefined 2020, “Internet of things (IoT) for next-generation smart systems: A review of current challenges, future trends and prospects for emerging 5G-IoT scenarios,” *ieeexplore.ieee.org*, Accessed: Jun. 27, 2022. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8972389/>.
- [2] G. A. Akpakwu, B. J. Silva, G. P. Hancke, and A. M. Abu-Mahfouz, “A Survey on 5G Networks for the Internet of Things: Communication Technologies and Challenges,” *IEEE Access*, vol. 6, pp. 3619–3647, Dec. 2017, doi: 10.1109/ACCESS.2017.2779844.
- [3] G. Yang *et al.*, “Homecare Robotic Systems for Healthcare 4.0: Visions and Enabling Technologies,” *IEEE J. Biomed. Heal. Informatics*, vol. 24, no. 9, pp. 2535–2549, Sep. 2020, doi: 10.1109/JBHI.2020.2990529.
- [4] J. Chanchaichujit, A. Tan, F. Meng, and S. Eaimkhong, “Optimization, Simulation and Predictive Analytics in Healthcare,” *Healthc. 4.0*, pp. 95–121, 2019, doi: 10.1007/978-981-13-8114-0_5.
- [5] E. Smith, T. Cusack, C. Cunningham, and C. Blake, “The influence of a cognitive dual

- task on the gait parameters of healthy older adults: A systematic review and meta-analysis,” *J. Aging Phys. Act.*, vol. 25, no. 4, pp. 671–686, Oct. 2017, doi: 10.1123/JAPA.2016-0265.
- [6] S. Majumder, T. Mondal, M. J. Deen, S. Evoy, and B. Fidan, “Wearable sensors for remote health monitoring,” *mdpi.com*, doi: 10.3390/s17010130.
- [7] M. Krehel, M. Schmid, R. M. Rossi, L. F. Boesel, G. L. Bona, and L. J. Scherer, “An optical fibre-based sensor for respiratory monitoring,” *Sensors (Switzerland)*, vol. 14, no. 7, pp. 13088–13101, Jul. 2014, doi: 10.3390/S140713088.
- [8] A. Leal-Junior, L. Avellar, A. Frizera, and C. Marques, “Smart textiles for multimodal wearable sensing using highly stretchable multiplexed optical fiber system,” *Sci. Rep.*, vol. 10, no. 1, Dec. 2020, doi: 10.1038/S41598-020-70880-8.
- [9] Y. Koyama, M. Nishiyama, and K. Watanabe, “Smart textile using hetero-core optical fiber for heartbeat and respiration monitoring,” *IEEE Sens. J.*, vol. 18, no. 15, pp. 6175–6180, Aug. 2018, doi: 10.1109/JSEN.2018.2847333.
- [10] A. G. Leal-Junior, C. R. Díaz, C. Marques, M. J. Pontes, and A. Frizera, “Multiplexing technique for quasi-distributed sensors arrays in polymer optical fiber intensity variation-based sensors,” *Opt. Laser Technol.*, vol. 111, pp. 81–88, Apr. 2019, doi: 10.1016/j.optlastec.2018.09.044.
- [11] S. Zhang, X. Li, M. Zong, X. Zhu, and R. Wang, “Efficient kNN classification with different numbers of nearest neighbors,” *IEEE Trans. Neural Networks Learn. Syst.*, vol. 29, no. 5, pp. 1774–1785, May 2018, doi: 10.1109/TNNLS.2017.2673241.

© 2022 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC-SA 4.0 license (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).

