

CLASIFICACIÓN DE POSTURAS MEDIANTE USO DE REDES NEURONALES Y DISPOSITIVO IOT

Juan Manuel Montes-Sánchez^{1,2}, Francisco Luna-Perejón^{1,2}, Lourdes Durán-López^{1,2,3}, Alberto Vazquez-Baeza¹, Isabel Beasley-Bohórquez⁴, José L. Sevillano-Ramos^{1,2,3}

¹Dpto. Arquitectura y Tecnología de Computadores, Universidad de Sevilla

²Grupo de investigación RTC, Universidad de Sevilla

³Research Institute of Computer Engineering, Universidad de Sevilla

⁴Escuela Universitaria de Osuna, Universidad de Sevilla

E-mail de correspondencia: juanmanuelmontes@us.es

RESUMEN

El tiempo que la población pasa sentada ha aumentado en las últimas décadas debido al incremento del uso del ordenador personal. Paralelamente, también han aumentado las dolencias musculoesqueléticas. Gran parte de estas son consecuencia directa de pasar largos periodos sentados en posturas estáticas. En este trabajo se ha desarrollado un sistema IoT de monitorización de la postura, consistente en un asiento equipado con 6 sensores de fuerza resistivos (FSR). La información de los sensores es clasificada por una red neuronal entrenada mediante técnicas de aprendizaje automático para diferenciar entre 7 posturas; 6 de ellas consideradas de mayor riesgo de causar dolencia. Se han recogido datos de 12 participantes y se han evaluado diferentes modelos de red neuronal en busca de la mayor efectividad de la red. El mejor modelo obtenido tiene una precisión media del 81% y consiste en dos capas ocultas de 128 neuronas cada una. Este resultado demuestra posible la distinción entre las posturas estudiadas con un uso mínimo de sensores, lo cual implica menor complejidad y coste que otros estudios similares.

1. INTRODUCCIÓN

El aumento del uso del ordenador personal en las últimas décadas se relaciona con un incremento de las dolencias musculoesqueléticas causadas por pasar largos periodos sentado (Wu, He, Li, Wang, & Wang, 2012). El creciente desarrollo del llamado aprendizaje automático ha motivado la aparición de sistemas de clasificación postural que intentan dar solución a este problema, aunque la mayoría son de difícil implementación debido a su alto coste y complejidad. En este estudio se ha desarrollado un sistema de clasificación de bajo coste y se ha evaluado su eficiencia.

2. MATERIALES Y MÉTODOS

En este apartado se describen el sistema hardware y software, así como la creación del set de datos usado y detalles de los modelos de red neuronal empleados.

2.1 Dispositivo Internet of Things (IoT)

Para realizar este estudio se ha diseñado y fabricado un dispositivo hardware compuesto de tres partes principales:

- Asiento sensor: consiste en 6 sensores resistivos de fuerza (FSR) cubiertos por un cojín. Los sensores van conectados a una placa electrónica de fabricación y diseño propios.
- Unidad de control: consta de una placa de desarrollo STM32 NUCLEO-F411RE a la que se han conectado las señales de la placa de sensores a su entrada del convertor analógico-digital y a la que se ha provisto de comunicación bluetooth. Recibe las señales de los sensores y envía las lecturas de forma inalámbrica a la aplicación.
- Aplicación software: dispone de interfaz gráfica que informa al usuario de su postura y muestra los valores de presión en el asiento en forma de mapa de calor.

2.2 Set de datos

Utilizando el dispositivo de medición, se han recogido los datos de los sensores para 7 posturas diferentes (figura 1). Un total de 12 voluntarios participaron en la recogida de datos, 4 mujeres y 8 hombres de diversa estatura, peso y edad. Para cada usuario se registró cada postura en dos ocasiones mantenida 15 segundos a una frecuencia de 8Hz.

Figura 1. Posturas clasificadas. Las dos últimas tienen variación izquierda-derecha.



Fuente: (Zemp *et al.*, 2016).

Todos estos datos recogidos fueron normalizados para su uso como entrada de la red neuronal que se describe en el siguiente apartado. El 85% de los datos se usó para entrenamiento y el restante 15% para evaluación.

2.3 Red Neuronal de clasificación

Para realizar la clasificación de las posturas en función de los sensores se crearon diversos modelos de red neuronal, variando su número de capas ocultas y neuronas. Para el diseño, entrenamiento y evaluación de las redes se han usado las herramientas TensorFlow y Keras. La precisión de las redes se ha medido con la fórmula 1 (Sokolova & Lapalme, 2009).

Fórmula 1. Precisión de la red neuronal

$$\text{Precisión} = \sum_c \frac{TP_c + TN_c}{TP_c + TN_c + FP_c + FN_c}, c \in \text{clases}$$

3. RESULTADOS Y DISCUSIÓN

En la **tabla 1** se recoge la precisión media de cada variación del modelo de red estudiada. Se obtuvieron los mejores resultados con una configuración de 128 neuronas y 2 capas ocultas, siendo la precisión media del 81%.

Tabla 1. Precisión media de las distintas redes evaluadas.

N.º de Capas Ocultas	N.º de neuronas						
	128	16	32	64	128	256	512
1	48.15%	70.69%	67.21%	74.03%	63.47%	73.14%	72.05%
2	63.26%	76.15%	65.29%	71.05%	81.00%	73.65%	74.68%
3	63.61%	69.07%	73.08%	75.74%	73.26%	73.44%	72.46%
4	63.29%	67.21%	68.13%	73.30%	74.97%	76.86%	79.10%

Fuente: elaboración propia.

Figura 2. Matriz de confusión de la red neuronal seleccionada.

	1	2	3	4	5	6	7	
1	173 5.10%	6 0.18%	180 5.31%	95 2.80%	43 1.27%	4 0.12%	0 0.0%	501 34.53% 65.47%
2	0 0.0%	505 14.90%	0 0.0%	1 0.03%	0 0.0%	0 0.0%	0 0.0%	506 99.80% 0.20%
3	2 0.06%	4 0.12%	442 13.04%	11 0.32%	70 2.07%	0 0.0%	0 0.0%	529 83.55% 16.45%
4	0 0.0%	0 0.0%	126 3.72%	336 9.91%	2 0.06%	0 0.0%	0 0.0%	464 72.41% 27.59%
5	0 0.0%	0 0.0%	4 0.12%	0 0.0%	435 12.84%	1 0.03%	0 0.0%	440 98.86% 1.14%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.03%	526 15.52%	0 0.0%	527 99.81% 0.19%
7	94 2.77%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	328 9.68%	422 77.73% 22.27%
	269 64.31% 35.69%	515 98.06% 1.94%	752 58.78% 41.22%	443 75.85% 24.15%	551 78.95% 21.05%	531 99.06% 0.94%	328 100% 0.00%	3389 81.00% 19.00%
	1	2	3	4	5	6	7	

Fuente: elaboración propia.

Para esta configuración, además, se muestran los resultados de clasificación de posturas en la **figura 2**, que se corresponde con la matriz de confusión del modelo. Se observa que el modelo predice erróneamente casi la mitad de las muestras correspondientes con la postura 1 como postura 3.

Este problema se encuentra también en estudios similares que obtienen una precisión similar en su clasificación (Zemp *et al.*, 2016), con la diferencia de que el número de sensores que se han usado en este trabajo es mucho menor y todos están localizados en el asiento en lugar de repartidos por toda la silla (menor complejidad del sistema).

4. CONCLUSIONES

Este estudio logra el objetivo de igualar o mejorar sistemas más complejos de clasificación postural con un dispositivo de poco consumo y coste y un modelo de red neuronal de baja complejidad que alcanza una precisión media del 81% de acierto. Hay además margen de mejora para corregir los problemas de clasificación pre-

sentes ampliando el set de datos o recolocando los sensores en configuraciones que den mayor efectividad.

AGRADECIMIENTOS

A la Cátedra Telefónica de la Universidad de Sevilla y a la Fundación Telefónica por aportar fondos para esta investigación, así como al grupo de investigación RTC por proporcionar recursos.

REFERENCIAS BIBLIOGRÁFICAS

- Sokolova, M., & Lapalme, G.** (2009). A systematic analysis of performance measures for classification tasks. *Information Processing and Management*, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Wu, S., He, L., Li, J., Wang, J., & Wang, S.** (2012). Visual display terminal use increases the prevalence and risk of work-related musculoskeletal disorders among chinese office workers: A cross-sectional study. *Journal of Occupational Health*, 54(1), 34–43. <https://doi.org/10.1539/joh.11-0119-OA>
- Zemp, R., Tanadini, M., Plüss, S., Schnüriger, K., Singh, N. B., Taylor, W. R., & Lorenzetti, S.** (2016). Application of Machine Learning Approaches for Classifying Sitting Posture Based on Force and Acceleration Sensors. *BioMed Research International*, 2016. <https://doi.org/10.1155/2016/5978489>