

ANÁLISIS DEL NÚMERO DE SENSORES PARA LA CLASIFICACIÓN POSTURAL EN SEDESTACIÓN

Patrick Vermander, Nerea Perez, Janire Otamendi, Asier Brull Mesanza, Aitziber Mancisidor, Itziar Cabanes {patrick.vermander, nereza.perezo, janire.otamendi, asier.brull, aitziber.mancisidor, itziar.cabanes}@ehu.eus

Departamento de Ingeniería de Sistemas y Automática,
Escuela de Ingeniería de Bilbao, UPV/EHU

Resumen

La clasificación postural es fundamental de cara a realizar un correcto seguimiento del estado postural en personas mayores. Este seguimiento, además de aportar información continuada a los especialistas sanitarios, puede servir para prevenir trastornos musculoesqueléticos. En este trabajo, se presenta el análisis del número de sensores de un dispositivo de monitorización postural portable compuesto por 16 sensores FSR. Con ello, se busca reducir el coste computacional a la hora de realizar la clasificación, simplificando el modelo y aumentando la autonomía. Para ello, se aplica una metodología basada en dos pasos: 1) Calcular el orden de relevancia de los sensores, mediante Random Forest y ReliefF. 2) Seguir un proceso iterativo de entrenamiento para dos modelos de clasificación basados en SVM y KNN. En cada iteración se aumenta en uno el número de sensores introducidos como entrada, estudiando cómo afecta este número en el desempeño final de los modelos. Los resultados demuestran que un número de 5 sensores es suficiente para lograr porcentajes de acierto superiores al 90 %.

Palabras clave: Monitorización postural; Machine Learning; Optimización; Sensores FSR.

1. INTRODUCCIÓN

Actualmente en el mundo, la población mayor de 65 años supera los 727 millones de personas y se prevé que este número se duplique en los próximos 30 años [6]. La cada vez mayor esperanza de vida, junto con la baja tasa de natalidad, van a provocar que España sea uno de los países más envejecidos del mundo [9].

El impacto del envejecimiento está ligado a un aumento de las actitudes sedentarias, empobreciendo la calidad de vida de estas personas [11]. Una de las consecuencias implícitas del envejecimiento es la pérdida de movilidad y autonomía. Esto, conjuntamente con el debilitamiento muscular propio de la edad provoca la adopción de posturas incorrectas en sedestación [8].

Entre las principales consecuencias de adoptar posturas incorrectas se encuentra la aparición de trastornos musculoesqueléticos como lumbalgia o ciática, entre otros [16, 26]. Llevar a cabo una temprana monitorización postural evita la adopción de posturas inadecuadas. Esto es de vital importancia para evitar que, a las consecuencias propias de la vejez, se le sumen daños físicos adicionales.

Actualmente, la monitorización postural se lleva a cabo mediante el uso de escalas o cuestionarios [5]. Estas escalas permiten conocer el estado postural del anciano en el momento en el que se realizan. Sin embargo, estos cuestionarios, además de tener un carácter subjetivo, solo muestran el estado postural en el momento en el que se realizan. Con la intención de realizar una monitorización continuada en el tiempo, se han desarrollado dispositivos basados en tres tipos de sensores: vestibles, visión y presión.

Los sensores vestibles se colocan sobre el cuerpo o ropa de la persona, monitorizando la posición de la columna. Entre estos sensores destaca el uso de unidades de medición inercial [10, 19]. Estos sensores permiten recopilar datos de forma sencilla y bajo coste pero pueden suponer molestias para el usuario al ir colocados sobre las propias personas.

Para ello, algunos trabajos proponen hacer uso de sistemas de visión, que al estar ubicados sobre el entorno no son tan intrusivos [1, 21, 24]. Estos sensores eliminan la incomodidad intrínseca de los sensores vestibles, pero tienen un rango de acción limitado. Además, pueden presentar problemas de privacidad, especialmente en una población sensible como la de la tercera edad.

En último lugar, los sensores de presión permiten combinar las ventajas de los dos grupos de sensores anteriores. Al estar colocados sobre la superficie de apoyo, no son incómodos para el usuario, y tienen cierta portabilidad. Existen en la actualidad mallas comerciales [14, 20] compuestas por un número elevado de sensores. Estas mallas, pese a tener gran resolución y abarcar toda la superficie de apoyo, tienen un elevado coste y un tiempo de uso limitado. Además, al tratarse de soluciones cerradas, el acceso a los datos es restringido. Es



Figura 1: Módulos que componen el dispositivo de monitorización: 1- Dispositivo sensor con distribución de sensores. 2- Módulo de adquisición de datos. 3- Interfaz gráfica.

por eso, que otros trabajos proponen hacer uso de sensores de fuerza FSR ubicados en puntos discretos.

Algunos autores proponen colocar estos sensores siguiendo un esquema de matriz, cubriendo la mayor superficie posible [2, 13]. Otros trabajos, por el contrario, se centran en la colocación de distribución de sensores para monitorizar puntos relevantes del cuerpo, haciendo una selección más exhaustiva de la ubicación de los mismos. Estos trabajos se centran en colocar sensores únicamente en el respaldo [15], únicamente en el asiento [3, 4], o en ambos [12, 18].

Por lo tanto, se observa que la distribución de los sensores en la bibliografía es variada y diversa. Es por ello, que en un trabajo anterior de los autores se propuso localizar aquellos puntos relevantes en los cuales situar los sensores FSR [25]. Esta localización fue escogida teniendo en cuenta las variaciones en la fuerza entre las diferentes posturas a monitorizar con respecto a la postura correcta, detectando aquellos puntos más significativos para la monitorización postural continua.

Además de la realización de una monitorización postural continua, la detección de las posturas adoptadas por el usuario es de gran importancia de cara a realizar un correcto seguimiento del estado postural. Facilitar a un especialista sanitario el registro de posturas adoptadas por una persona a lo largo del día, puede ayudarle a personalizar el tratamiento adecuado.

Tal como se ha comentado, la selección de los puntos relevantes anterior fue realizada para una monitorización continua. No obstante, se ha observado que para realizar una clasificación postural quizás no es necesario utilizar todos los sensores integrados en el dispositivo. Reducir el número de

sensores, permitiría simplificar el proceso de clasificación además de aumentar la autonomía del dispositivo de monitorización. Es por ello que, de cara a hacer más eficiente el dispositivo de monitorización, en este trabajo se presenta la optimización del número de sensores de dicho dispositivo. Para ello, se presenta el proceso seguido para reducir al mínimo el número de sensores utilizados, manteniendo buenos resultados en la clasificación de posturas. Para ello, se analizan los sensores de mayor relevancia utilizando las técnicas Random Forest y ReliefF, y se comprueba el peso de cada uno de ellos en la clasificación postural.

El resto del artículo se organiza de la siguiente manera. En la Sección 2 se presenta el dispositivo de monitorización a optimizar, así como la base de datos utilizada para tal fin. En la Sección 3, se analiza la relevancia de los sensores para la clasificación postural y se presenta el proceso llevado a cabo para optimizar el dispositivo. En la Sección 4 se validan los resultados. Por último, en la Sección 5 se extraen las conclusiones más relevantes.

2. DISPOSITIVO DE MONITORIZACIÓN POSTURAL

El sistema de monitorización postural desarrollado está compuesto por tres módulos. Un primer módulo consistente en un dispositivo sensor compuesto por 16 sensores FSR dispuestos en el respaldo y asiento de una silla de tal forma que permita la monitorización de espalda y muslos. Esta distribución de sensores se seleccionó en base a un estudio previo realizado por los autores [25], permitiendo medir la fuerza en puntos relevantes para la monitorización postural. Un segundo módulo de adquisición de datos basado en Arduino que per-

mite transmitir los datos de forma inalámbrica y en tiempo real a un ordenador remoto. Y por último, un bloque consistente en una interfaz gráfica alojada en dicho ordenador que permite visualizar las mediciones en tiempo real, así como históricos previamente guardados. El conjunto está alimentado por una batería externa que le da una autonomía superior a 24 horas. La distribución de sensores así como el conjuntos de los bloques está representado en la Figura 1.

De los tres bloques anteriormente descritos, se busca la optimización del primero de ellos con el fin de simplificar la posterior clasificación postural. Es decir, se busca reducir al mínimo el número de sensores necesarios para reducir el coste computacional en la clasificación postural. Las posturas a clasificar se han seleccionado por ser las más comunes en personas de la tercera edad con cierta limitación en el movimiento, en base a la experiencia de personal sanitario. Estas posturas vienen representadas y enumeradas en la Figura 2.

Para realizar la optimización, se hace uso de una base de datos de las posturas anteriormente indicadas, recogidas mediante el dispositivo de monitorización postural. Esta base de datos se ha obtenido de un total de 35 sujetos sanos a los cuales se les ha pedido que reprodujeran cada una de ellas durante un periodo de 30 segundos. Además, cada uno de ellos ha repetido las posturas en dos ocasiones.

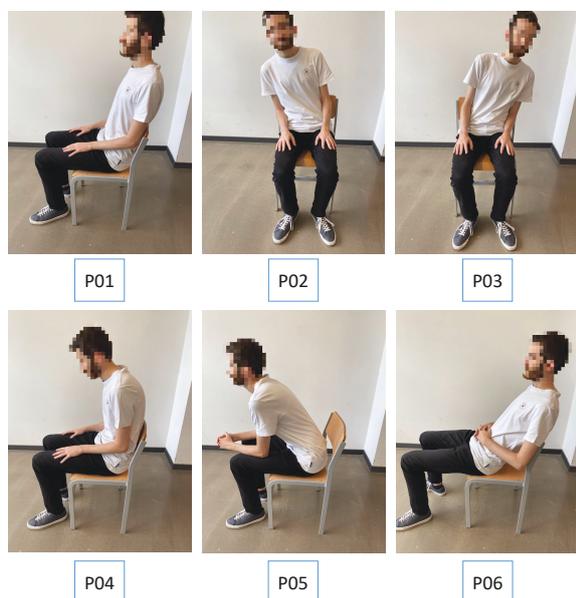


Figura 2: Posturas a clasificar. P01 - Sedestación neutral, P02 - Inclinación lateral hacia la derecha, P03 - Inclinación lateral hacia la izquierda, P04 - Hiperlordosis, P05 - Inclinación hacia atrás, P06 - Deslizamiento sobre el asiento.

3. ANÁLISIS DE LA IMPORTANCIA RELATIVA DE LOS SENSORES DEL DISPOSITIVO DE MONITORIZACIÓN

En esta sección se explica la metodología llevada a cabo para optimizar al mínimo el número de sensores del dispositivo de monitorización (Figura 3). Esta metodología está dividida en dos pasos: 1- Calcular la relevancia relativa de los sensores para clasificar las posturas seleccionadas. 2- Proceso iterativo de entrenamiento de dos modelos de clasificación para estudiar cómo el número de sensores afecta en el desempeño de éstos.

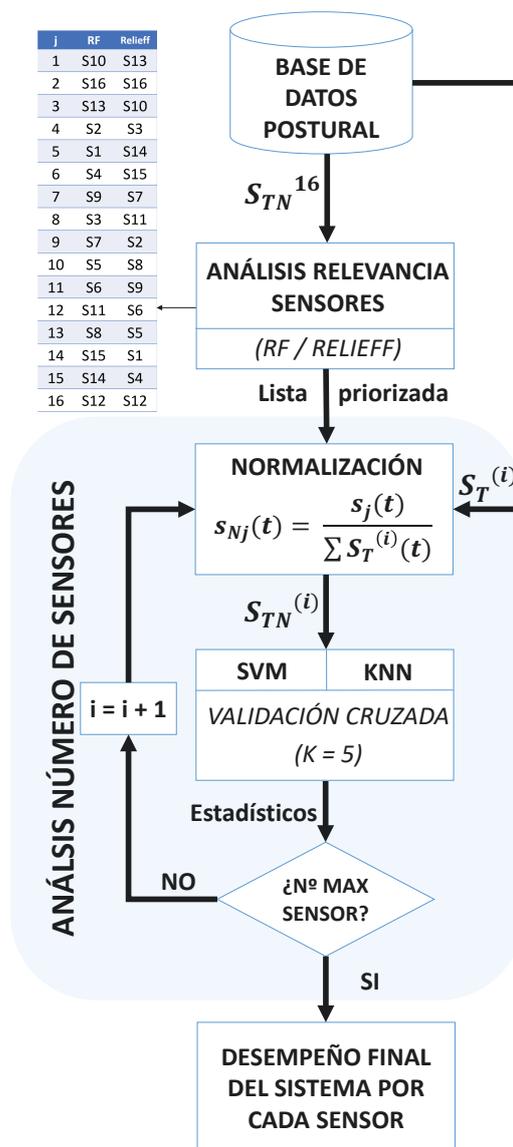


Figura 3: Esquema de la metodología seguida para la optimización del número de sensores del dispositivo de monitorización postural, manteniendo un alto porcentaje de acierto en clasificación postural.

3.1. ANÁLISIS DE LA RELEVANCIA DE LOS SENSORES

Es de esperar, que a la hora de reducir el número de sensores del dispositivo de monitorización, haya que seleccionar aquellos que más aporten a la diferenciación entre posturas. Por ello, en primer lugar, se lleva a cabo la ordenación de los sensores en función de la relevancia que tiene cada uno de ellos. Para ello, se han utilizado dos técnicas de aprendizaje automático que permiten obtener la importancia relativa de los elementos de entrada en el modelo, en este caso los sensores S_T ¹⁶. Como información de entrada a estas técnicas se usa el valor de la fuerza normalizada de los sensores en cada instante de tiempo, junto con la etiqueta de la postura a la que corresponden. Estas técnicas, para ser exactos son, ReliefF [23] y Random Forest (RF) [7].

Para el cálculo de la importancia relativa de los sensores del dispositivo de monitorización postural, se ha utilizado el método ReliefF seleccionando como número de vecinos 5 y el Random Forest, con un total de 5000 árboles y una estrategia basada en selección de muestra con reemplazo.

En base a estos métodos se han obtenido los pesos que representan la relevancia de cada uno de los sensores. Estos pesos se reflejan ordenados de mayor a menor en función de la relevancia j , junto con el sensor al que corresponden en la Tabla 1, formando dos listas priorizadas. De cara a una posible comparativa, así como para facilitar la comprensión de los mismos, se pasan estos a valores relativos en términos porcentuales (Figura 4).

En los resultados obtenidos se puede apreciar como los tres sensores ubicados en la parte superior del respaldo (S10, S13 y S16) destacan por encima del resto. De la misma forma, el sensor S12 situado en la zona lumbar se sitúa en la zona inferior de la tabla.

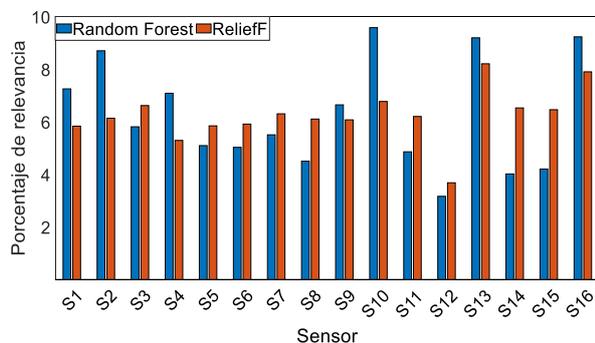


Figura 4: Porcentaje de relevancia de los sensores en la clasificación obtenida mediante Random Forest y ReliefF para el conjunto global de posturas.

Sin embargo, en la zona central de la tabla existe

Tabla 1: Sensores del dispositivo de monitorización ordenadas de mayor a menor relevancia en función de los resultados obtenidos con las técnicas de aprendizaje automático Random Forest y ReliefF.

| j | Random Forest | | ReliefF | |
|----|---------------|--------|---------|--------|
| | Sensor | Peso | Sensor | Peso |
| 1 | S10 | 1,9507 | S13 | 0,1729 |
| 2 | S16 | 1,8797 | S16 | 0,1665 |
| 3 | S13 | 1,8722 | S10 | 0,1427 |
| 4 | S2 | 1,7719 | S3 | 0,1394 |
| 5 | S1 | 1,4771 | S14 | 0,1375 |
| 6 | S4 | 1,4430 | S15 | 0,1361 |
| 7 | S9 | 1,3534 | S7 | 0,1328 |
| 8 | S3 | 1,1838 | S11 | 0,1307 |
| 9 | S7 | 1,1215 | S2 | 0,1293 |
| 10 | S5 | 1,0381 | S8 | 0,1286 |
| 11 | S6 | 1,0246 | S9 | 0,1280 |
| 12 | S11 | 0,9901 | S6 | 0,1246 |
| 13 | S8 | 0,9173 | S5 | 0,1232 |
| 14 | S15 | 0,8568 | S1 | 0,1230 |
| 15 | S14 | 0,8187 | S4 | 0,1115 |
| 16 | S12 | 0,6455 | S12 | 0,0776 |

una discrepancia en el orden de los sensores según el método utilizado. El motivo de esta diferencia es el criterio de cada uno de estos métodos para seleccionar qué es relevante. El Random Forest da mayor relevancia a los sensores que diferencian una postura al recibir mayor fuerza que en el resto. Por el contrario, el método ReliefF da mayor importancia a los sensores que dejan de medir con respecto al resto de posturas. Cada uno con su criterio, el orden de los sensores es coherente para ambos métodos por separado. A priori no se puede saber cual de los órdenes representa mejor la relevancia de los sensores, por lo que ambos se estudian en el siguiente paso de la metodología.

3.2. ANÁLISIS DEL NÚMERO DE SENSORES

En base a las dos listas priorizadas de sensores obtenidas en el apartado anterior (Tabla 1), en este punto se pasa a estudiar cómo afectan éstas en el rendimiento de los clasificadores posturales.

Para ello, se tienen en cuenta dos modelos de clasificación. Por una parte K vecinos más cercanos (KNN) [22] y por otro las máquinas de soporte vectorial (SVM) [17]. Estos modelos se han entrenado usando Matlab, que entre sus funciones incluye la optimización de hiperparámetros de los mismos. Con ambos modelos se sigue la metodología representada en la Figura 3.

Para el análisis del número necesario de sensores del dispositivo se sigue un proceso iterativo dividido en dos pasos: normalización y entrenamiento del clasificador. Se comienza haciendo uso del sensor más relevante y por cada iteración, este número se incrementa en uno, siguiendo el orden de la lista definida en la Tabla 1.

Para cada iteración, se comienza con un primer paso de normalización de los sensores utilizados. La normalización de los datos se ha realizado calculando el porcentaje de fuerza que mide un sensor en un instante t , con respecto a la fuerza total medida por los sensores de la lista de la iteración i , en ese instante. La normalización llevada a cabo se recoge en la siguiente ecuación:

$$s_{Nj}(t) = \frac{s_j(t)}{\sum S_T^{(i)}(t)} \quad (1)$$

Siendo $s_{Nj}(t)$ el valor normalizado del sensor con prioridad j , $s_j(t)$ el valor medido por el sensor con prioridad j , y $S_T^{(i)}(t)$ el conjunto de los sensores utilizados en la iteración i .

De esta forma, los datos quedan normalizados y escalados en valores comprendidos entre 0 y 1. En cada una de las iteraciones se recalcula el valor de los sensores normalizados de la lista, dado que el número de sensores que la conforman aumenta. Los valores normalizados de los sensores en cada iteración se utilizan como entrada a los modelos de clasificación KNN y SVM.

Este proceso se lleva a cabo con los datos de las posturas obtenidas en la Sección 2. Para garantizar que los resultados no dependen de la división de los datos de entrenamiento y test, se ha realizado una validación cruzada de 5 iteraciones. Por ello, en cada iteración y con un número de sensores determinado, se seleccionan 28 sujetos diferentes para entrenar el modelo y el resto para validar los resultados. Esta división del conjunto de entrenamiento y validación se realiza de forma aleatoria.

A modo de resumen, se tienen dos bucles. Un primer bucle que recorre cada uno de los sensores ordenados en el apartado anterior, y un segundo bucle interior que permite realizar la validación cruzada al ir cambiando entre sujetos de entrenamiento y validación. El proceso termina cuando se alcanza la última iteración ($i = 16$) y por tanto se ha estudiado la lista formada por la totalidad de los sensores.

Para validar los resultados, se ha repetido este mismo proceso de forma inversa. Es decir, se ha comenzado entrenando el modelo con el sensor menos relevante ($j = 16$), en la siguiente interacción con los dos menos relevantes, y así sucesivamente. Es de esperar, que si la relevancia de los sensores

se ha ordenado correctamente en el punto anterior, en esta segunda repetición, se necesite un mayor número de sensores para alcanzar buenos resultados.

4. VALIDACIÓN

En este apartado se pasa a describir los resultados obtenidos siguiendo la metodología descrita en la Sección 3.2. Mediante esta validación, se quiere comprobar si el hecho de reducir los sensores siguiendo el orden establecido, afecta en el rendimiento de la clasificación.

Para ello, en este apartado se discuten los resultados de los ordenes obtenidos tanto con el método ReliefF como con el orden propuesto por Random Forest, utilizando los dos modelos de clasificación mencionados. Para ello, en la Figura 5 se representa la media del porcentaje de acierto obtenido en la validación cruzada en función del número de sensores de entrada utilizados.

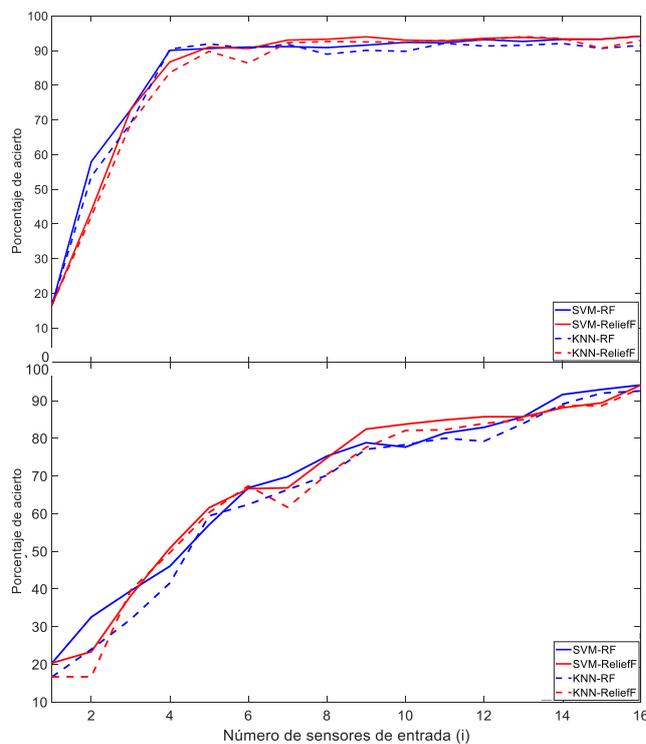


Figura 5: Porcentajes de acierto de los clasificadores SVM y KNN en función del número de sensores utilizados. Arriba: Sensores ordenados de mayor a menor relevancia. Abajo: Sensores ordenados de menor a mayor relevancia.

En azul se representa el orden obtenido mediante Random Forest, mientras que en rojo se representa el orden obtenido mediante ReliefF. Además, se diferencian los resultados obtenidos mediante SVM (línea continua) y KNN (línea de puntos).

En la gráfica superior se representan los sensores ordenados en base a ir utilizando la lista de sensores ordenados de mayor a menor relevancia. Tal y como se puede apreciar, con los 4 sensores más relevantes para el caso de RF y 5 sensores para Relief se obtienen porcentajes de acierto superiores al 90%. A partir de ese punto, la tasa de acierto se estabiliza, siendo invariable independientemente de aumentar el número de sensores. A raíz de los resultados, los sensores más relevantes con ambos métodos son los ubicados en la zona superior del respaldo (sensores S10, S13 y S16). Se trata, de hecho, de la zona donde más varía la fuerza entre una postura y otra.

El comportamiento de las gráficas es similar independientemente de la lista de prioridad utilizada. Esto demuestra que ambos métodos de cálculo de relevancia son eficientes, y que el criterio utilizado por cada uno de ellos, pese a ser diferente, es válido.

Por otro lado, en la gráfica inferior, se representan los mismos resultados, cambiando el orden de relevancia de los sensores, de menor a mayor. Esto se realiza para comprobar si solamente con el hecho de reducir los sensores se obtienen buenos resultados o si además, la selección de éstos es importante. En este segundo caso, para superar el porcentaje de acierto de 90% se necesita un número mínimo de 15 sensores. Por tanto, se puede concluir que seguir el orden relevancia marcado para los sensores es imprescindible para optimizar correctamente el número de sensores utilizados.

De esta forma, se puede concluir que, con un número significativamente menor de sensores utilizados, se pueden obtener tasas de acierto altas. Para ello, es necesario tener en cuenta el orden de relevancia de cada uno de estos sensores a la hora de clasificar las posturas. Por otro lado, el método de cálculo de relevancia utilizado, pese a seguir criterios diferentes, es igual de eficaz. Muestra de ello es que el desempeño del clasificador es similar independientemente del orden utilizado.

5. CONCLUSIONES

Actualmente, existe una gran variedad de distribución de sensores de presión para monitorización postural. En su mayoría, estos se ubican en forma de malla, buscando cubrir la mayor superficie posible. Para la clasificación postural, este tipo de distribución puede llegar a no ser eficiente, al utilizar un número excesivo de sensores.

En este trabajo se ha presentado una metodología de optimización de los dispositivos de monitorización postural basados en sensores de presión. Esta metodología se ha implementado y validado en el

dispositivo de monitorización postural presentado anteriormente por los autores [25], compuesto inicialmente por 16 sensores FSR, distribuidos entre el asiento y respaldo.

La metodología propuesta ha consistido en un primer paso de ordenación de la relevancia de cada uno de los sensores iniciales utilizados para clasificar 6 posturas habituales en personas con baja movilidad. Para ello, se utilizan dos técnicas, el Random Forest y Relief para predecir la importancia relativa de los features de entrada.

En base al orden de relevancia de los sensores obtenido mediante estos dos métodos, se ha seguido un proceso iterativo, comenzando con la utilización del sensor más relevante. Para cada iteración se ha realizado una validación cruzada de 5 particiones, entrenando dos modelos de clasificación, uno basado en KNN y otro en SVM. Entre iteraciones, se eleva el número de sensores a utilizar. Se ha realizado el mismo procedimiento, invirtiendo el orden de relevancia de los sensores, del menos relevante, al más relevante.

Por último, hay que recalcar que esta optimización en el número de sensores se ha realizado de cara a tener como aplicación final la clasificación postural. Los resultados muestran como con un número de 4 sensores en el caso del RF y con un número de 5 sensores para Relief se consigue superar el porcentaje de acierto del 90% independientemente del clasificador utilizado. A partir de ahí, el resto de sensores no contribuye en gran medida al desempeño del clasificador. El hecho de reducir el número de sensores permite optimizar el número de sensores del dispositivo para clasificación postural, pero provoca una pérdida de información. Esta información puede ser de gran relevancia para otras aplicaciones como detección de escaras o anomalías.

Agradecimientos

Este trabajo ha sido financiado por: FEDER/Ministerio de Ciencia e Innovación - Agencia Estatal de Investigación/Proyecto PID2020-112667RB-I00 financiado por MCIN/AEI/10.13039/501100011033, la Universidad del País Vasco UPV/EHU (GIU19/045), Gobierno Vasco (Grupos: Ref. IT1726-22 y contratos predoctorales PRE-2021-1-0001 y PRE-2021-1-0214) y Ayuda FPU del Ministerio de Ciencia, Innovación y Universidades (FPU19/04874).

English summary

ANALYSIS OF THE NUMBER OF SENSORS FOR SITTING POSTURE CLASSIFICATION

Abstract

Postural classification is essential for correct monitoring of postural status in the elderly. This monitoring, in addition to providing continuous information to health specialists, can be used to prevent musculoskeletal disorders. In this work, the analysis of the number of sensors of a postural monitoring device composed of 16 FSR sensors is presented. The aim is to reduce the computational cost of classification, simplifying the model and increasing autonomy. To this end, a methodology based on two steps is applied: 1) Calculate the order of relevance of the sensors, using Random Forest and ReliefF. 2) Follow an iterative training process for two classification models based on SVM and KNN. In each iteration the number of sensors introduced as input is increased by one, studying how this number affects the final performance of the models. The results show that a number of 5 sensors is sufficient to achieve hit rates above 90 %.

Keywords: Postural monitoring; Machine Learning; Optimisation; FSR sensors.

Referencias

- [1] J. K. Aggarwal and L. Xia. Human activity recognition from 3D data: A review. *Pattern Recognition Letters*, 48:70–80, 2014.
- [2] J. Ahmad, J. Sidén, and H. Andersson. A proposal of implementation of sitting posture monitoring system for wheelchair utilizing machine learning methods. *Sensors*, 21(19):6349, 2021.
- [3] D. E. Arias, E. J. Pino, P. Aqueveque, and D. W. Curtis. Unobtrusive support system for prevention of dangerous health conditions in wheelchair users. *Mobile Information Systems*, 2016, 2016.
- [4] J. Bao, W. Li, J. Li, Y. Ge, and C. Bao. Sitting posture recognition based on data fusion on pressure cushion. *TELKOMNIKA Indonesian Journal of Electrical Engineering*, 11(4):1769–1775, 2013.
- [5] L. Barks, C. Garvan, B. Crane, M. Peterson, L. M. Brown, and G. Powell-Cope. Reliability and criterion-related validity of the seated posture scale. *Rehabilitation Nursing Journal*, 44(4):213–220, 2019.
- [6] J. Bongaarts. United nations department of economic and social affairs, population division world family planning 2020: Highlights, 2020.
- [7] L. Breiman. Random forests. *Machine learning*, 45(1):5–32, 2001.
- [8] S. Chopra, M. Kumar, and S. Sood. Wearable posture detection and alert system. *Proceedings of the 5th International Conference on System Modeling and Advancement in Research Trends, SMART 2016*, pages 130–134, 2017.
- [9] J. I. Conde-Ruiz, C. I. González, et al. El proceso de envejecimiento en españa. *Estudios sobre la economía española.-2021/07*, 2021.
- [10] A. Cristina, F. Geraldo, and A. M. Kuasne. Prototype of Wearable Technology Applied to the Monitoring of the Vertebral Column. *International Journal of Online and Biomedical Engineering*, 16(01):34–50, 2020.
- [11] A. Edjolo, C. Proust-Lima, F. Delva, J.-F. Dartigues, and K. Pérès. Natural history of dependency in the elderly: a 24-year population-based study using a longitudinal item response theory model. *American journal of epidemiology*, 183(4):277–285, 2016.
- [12] T. Fu and A. Macleod. Intellichair: An approach for activity detection and prediction via posture analysis. In *2014 International Conference on Intelligent Environments*, pages 211–213. IEEE, 2014.
- [13] M. H. Jaffery, M. A. Ashraf, A. Almogren, H. M. Asim, J. Arshad, J. Khan, A. U. Rehman, and S. Hussien. Fsr-based smart system for detection of wheelchair sitting postures using machine learning algorithms and techniques. *Journal of Sensors*, 2022, 2022.
- [14] B. S. Kozniowski and J. L. Cezeaux. Wheelchair pressure monitoring alert system for the reduction of the occurrence of pressure sores. *2011 IEEE 37th Annual Northeast Bioengineering Conference, NEBEC 2011*, pages 1–2, 2011.
- [15] R. Kumar, A. Bayliff, D. De, A. Evans, S. K. Das, and M. Makos. Care-Chair: Sedentary Activities and Behavior Assessment with Smart Sensing on Chair Backrest. *2016 IEEE*

- International Conference on Smart Computing, SMARTCOMP 2016*, pages 1–8, 2016.
- [16] A. M. Lis, K. M. Black, H. Korn, and M. Nordin. Association between sitting and occupational lbp. *European Spine Journal*, 16(2):283–298, 2007.
- [17] F. López-Estrada, A. Méndez-López, I. Santos-Ruiz, G. Valencia-Palomo, and E. Escobar-Gómez. Detección de fallas en vehículos aéreos no tripulados mediante señales de orientación y técnicas de aprendizaje de máquina. *Revista Iberoamericana de Automática e Informática Industrial*, 18(3):254–264, 2021.
- [18] C. Ma, W. Li, R. Gravina, and G. Fortino. Posture detection based on smart cushion for wheelchair users. *Sensors (Switzerland)*, 17(4):6–18, 2017.
- [19] S. Ma, W. H. Cho, C. H. Quan, and S. Lee. A sitting posture recognition system based on 3 axis accelerometer. *CIBCB 2016 - Annual IEEE International Conference on Computational Intelligence in Bioinformatics and Computational Biology*, pages 1–3, 2016.
- [20] S. Ostadabbas, M. Baran Pouyan, M. Nourani, and N. Kehtarnavaz. In-bed posture classification and limb identification. *IEEE 2014 Biomedical Circuits and Systems Conference, BioCAS 2014 - Proceedings*, pages 133–136, 2014.
- [21] H. Pazhoumand-Dar. FAME-ADL: a data-driven fuzzy approach for monitoring the ADLs of elderly people using Kinect depth maps. *Journal of Ambient Intelligence and Humanized Computing*, 10(7):2781–2803, 2019.
- [22] L. E. Peterson. K-nearest neighbor. *Scholarpedia*, 4(2):1883, 2009. revision #137311.
- [23] M. Robnik-Šikonja and I. Kononenko. Theoretical and empirical analysis of relieff and rrelieff. *Machine learning*, 53(1):23–69, 2003.
- [24] Z. Saenz-De-Urturi and B. Garcia-Zapirain Soto. Kinect-based virtual game for the elderly that detects incorrect body postures in real time. *Sensors (Switzerland)*, 16(5), 2016.
- [25] P. Vermander, N. Pérez, A. Mancisidor, and I. Cabanes. Dispositivo de monitorización postural para personas de la tercera edad con alto grado de sedentarismo. In *XLII Jornadas de Automática*, pages 75–82. Universidade da Coruña, Servizo de Publicacións, 2021.
- [26] W. J. Yi, O. Sarkar, S. Mathavan, and J. Sanniie. Wearable sensor data fusion for remote health assessment and fall detection. *IEEE International Conference on Electro Information Technology*, pages 303–307, 2014.



© 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>).