

Algoritmo para el procesamiento de sensores de presión utilizados en la detección de la postura humana en reposo

Algorithm for processing pressure sensors used in detecting human resting posture

Edgar Alfaro Hernández¹, Alejandro Alonso Sánchez¹, Marco Uriel Illescas Flores¹, Piotr Enriquevitch López Chernyshov¹, José Julián Rodríguez Gutiérrez¹, Eduardo Arath Zúñiga Bermúdez¹, Luis Armando Ibarra Manzano², Mario Alberto Ibarra Manzano³

¹ División de Ingenierías del Campus Irapuato-Salamanca, Universidad de Guanajuato

² Escuela de Nivel Medio Superior de San Luis de la Paz, Colegio del Nivel Medio Superior, Universidad de Guanajuato

³ Departamento de Ingeniería Electrónica, División de Ingenierías del Campus Irapuato-Salamanca, Universidad de Guanajuato

{e.alfarohernandez, a.alonsosanchez, mu.illescascasflores, pe.lopezchernyshov, jj.rodriguez.gutierrez, ea.zunigabermudez, luis.ibarra, ibarram}@ugto.mx

Resumen

La identificación precisa de la postura mientras se está acostado es de suma importancia, especialmente en individuos mayores o aquellos con parálisis de la columna vertebral. Esto cobra aún más relevancia cuando se considera que mantener la misma posición durante largos períodos puede resultar en lesiones por presión. Los métodos clínicos actuales emplean interfaces con sensores de presión para detectar los puntos de presión, los cuales se utilizan para generar representaciones visuales de la distribución de la presión ejercida sobre el cuerpo. Sin embargo, aunque este enfoque permite identificar puntos de presión en el dispositivo, no logra detectar de manera precisa los puntos específicos en el cuerpo del individuo. Por ello, resulta crucial desarrollar métodos que permitan identificar la postura del paciente al estar acostado, lo que facilitaría correlacionar los puntos de presión con cada parte del cuerpo y, de esta forma, detectar posibles áreas de presión prolongada que podrían ocasionar lesiones.

Palabras clave: Sensores de presión; Distribución de presión; Postura; Lesiones por presión.

Introducción

En el ámbito de la salud, la detección precisa de la postura humana durante el reposo es un aspecto crucial, especialmente en poblaciones vulnerables como personas mayores y pacientes con parálisis de la columna vertebral. La inmovilidad prolongada en una misma posición puede dar lugar a la formación de úlceras por presión, lesiones que afectan la calidad de vida y pueden complicar el estado de salud general del paciente (Hayat et al., s/f). La prevención de estas lesiones es una prioridad en el cuidado de pacientes inmovilizados y en la gerontología, haciendo necesario el desarrollo de tecnologías que permitan un monitoreo constante y preciso de la postura corporal (Hayat et al., s/f).

Tradicionalmente, los métodos clínicos para detectar puntos de presión en el cuerpo han dependido de interfaces con sensores de presión. Estos dispositivos miden la distribución de la presión ejercida por el cuerpo sobre una superficie, como una cama o silla, y generan mapas de presión que ayudan a identificar áreas de riesgo para la formación de úlceras. Sin embargo, estos métodos suelen ser limitados en su capacidad para correlacionar los datos de presión con las partes específicas del cuerpo del individuo (Stern & Roshan Fekr, 2023). Este desafío plantea la necesidad de un enfoque más preciso y detallado para la detección de la postura humana en reposo.

La investigación propuesta se basa en el desarrollo de un algoritmo innovador que utiliza datos de sensores de presión para identificar con precisión la postura de una persona mientras está acostada. El objetivo es correlacionar los puntos de presión detectados con las partes específicas del cuerpo, permitiendo así una identificación temprana de áreas de presión prolongada y potencialmente peligrosas. Este enfoque no solo contribuirá a la prevención de úlceras por presión, sino que también mejorará el confort y la calidad de vida de los pacientes (Chen et al., 2024).



Figura 1. Representación de un sistema de detección de postura mediante sensores de presión.

Para el desarrollo y validación de este algoritmo, se utilizará la base de datos disponible en PhysioNet, una fuente reconocida en el ámbito de la investigación biomédica. La base de datos de PhysioNet contiene registros de presión obtenidos de diferentes poblaciones, incluidos pacientes con diversas condiciones médicas, lo que proporciona un conjunto de datos robusto para la investigación y el desarrollo de nuevas tecnologías (Baran Pouyan et al., 2018; Stern & Roshan Fekr, 2023).

Investigaciones recientes han demostrado la viabilidad de utilizar datos de presión para la detección de la postura y el monitoreo de pacientes. Por ejemplo, (Pouyan et al., 2017) desarrollaron un sistema que emplea sensores de presión integrados en colchones para monitorear cambios posturales y prevenir la formación de úlceras por presión en pacientes hospitalizados. De manera similar, (Pouyan et al., 2017) exploraron el uso de matrices de sensores de presión para evaluar la postura en personas mayores, destacando la importancia de la precisión en la detección para reducir riesgos de lesiones. Estas investigaciones subrayan la importancia de continuar avanzando en este campo, desarrollando algoritmos que mejoren la precisión y la utilidad clínica de los sistemas de detección de postura.

En este contexto, el presente artículo describe el desarrollo de un nuevo algoritmo de procesamiento de datos de sensores de presión. Este algoritmo está diseñado para procesar de manera precisa la postura de una persona, utilizando métodos avanzados de análisis de datos. Además, se discuten los beneficios potenciales de esta tecnología, no solo en la prevención de lesiones por presión, sino también en su aplicación en la rehabilitación y el monitoreo de la salud general de los pacientes.

En resumen, la detección precisa de la postura humana en reposo es esencial para mejorar la calidad de vida de las personas mayores y de aquellos con movilidad reducida. La investigación aquí presentada busca abordar esta necesidad mediante el desarrollo de un algoritmo que aprovecha datos de sensores de presión, con el objetivo final de prevenir lesiones y mejorar el bienestar de los pacientes. Las referencias a estudios previos y el uso de la base de datos de PhysioNet refuerzan la validez y relevancia de este enfoque en el contexto actual de la investigación biomédica (“Synthetic Data Generation”, 2023).

Metodología

Base de datos

El desarrollo y uso de tecnologías avanzadas como los sensores de presión ha demostrado ser eficaz para mapear la distribución de presión en diferentes posturas de descanso. El Pressure Map Dataset for In-bed Posture Classification, desarrollado por un equipo de investigadores de la Universidad de Texas en Dallas, es un recurso significativo que proporciona datos detallados de presión en diversas posturas de descanso, facilitando la investigación y el desarrollo de algoritmos para la identificación de posturas y la detección de áreas de riesgo (Baran Pouyan et al., 2018), (Pouyan et al., 2017).

La base de datos consiste en dos configuraciones experimentales. La primera configuración utilizó el sensor Vista Medical FSA SoftFlez 2048, equipado con un tapete de 32 x 64 puntos de presión, un rango de presión de 0 a 1,000 y una frecuencia de muestreo de 1 muestra por segundo. Este experimento incluyó a 13 participantes, cuyas edades, alturas y pesos se detallan en la Tabla 1. Cada participante fue registrado durante aproximadamente 2 minutos (120 imágenes) en cada una de las 8 posturas estándar y 9 estados adicionales, sumando un total de 17 posturas (ver Tabla 2).

La segunda configuración utilizó el sensor Vista Medical BodiTrak BT3510, que tiene un tapete de 27 x 64 puntos de presión, un rango de 0 a 500 y la misma frecuencia de muestreo que el primer experimento. Ocho participantes, descritos en la Tabla 3 en cuanto a edad, altura y peso, fueron registrados en 29 diferentes conjuntos de 3 posturas, como se indica en la Tabla 4. Además, en este experimento se registraron datos en dos tipos de colchones: uno de esponja y otro de aire.

Tabla 1. Distribución de los 13 participantes en edad, peso y altura para el experimento 1 con el sensor Vista Medical FSA SoftFlez 2048

Número	Edad	Altura (Kg)	Peso (Kg)
1	19	175	87
2	23	183	85
3	23	183	100
4	24	177	70
5	24	172	66
6	26	169	83
7	27	179	96
8	27	186	63
9	30	174	74
10	30	174	79
11	30	176	91
12	33	170	78
13	34	174	74

Tabla 2. Distribución de las 8 posturas estándar y 9 estados para el experimento 1 con el sensor Vista Medical FSA SoftFlez 2048

Índice	Postura	Inclinación de la cama	Giro del cuerpo
1	Supino	0	0
2	Derecha	0	0
3	Izquierda	0	0
4	Derecha	0	30
5	Derecha	0	60
6	Izquierda	0	30
7	Izquierda	0	60
8	Supino	0	0
9	Supino	0	0
10	Supino	0	0
11	Supino	0	0
12	Supino	0	0
13	Feto derecho	0	0
14	Feto izquierdo	0	0
15	Supino	30	0
16	Supino	45	0
17	Supino	60	0

Tabla 3. Distribución de los 8 participantes en edad, peso y altura para el experimento 2 con el sensor Vista Medical BodiTrak BT3510

Número	Edad	Altura (Kg)	Peso (Kg)
1	19	175	87
2	23	183	85
3	23	183	100
4	24	172	66
5	27	179	96
6	27	186	63
7	30	174	74
8	30	174	79

Tabla 4. Distribución de los 29 diferentes estados en 3 posturas para el experimento 1 con el sensor Vista Medical BodiTrak BT3510

Índice	Postura	Inclinación de la cama	Giro del cuerpo
B1	Supino	0	0
B2	Supino	0	0
B3	Supino	0	0
B4	Supino	0	0
B5	Supino	0	0
B6	Supino	0	0
B7	Supino	0	0
B8	Supino	0	0
B9	Supino	0	0
B10	Supino	0	0
C1	Derecha	0	0
C2	Derecha	0	0
C3	Derecha	0	0
D1	Izquierda	0	0
D2	Izquierda	0	0
D3	Izquierda	0	0
E1	Derecha	0	20
E2	Derecha	0	40
E3	Izquierda	0	20
E4	Izquierda	0	40
E5	Derecha	0	20
E6	Izquierda	0	20
F1	Supino	0	0
F2	Supino	10	0
F3	Supino	20	0
F4	Supino	30	0
F5	Supino	40	0
F6	Supino	50	0
F7	Supino	60	0

La base de datos incluye dos archivos CSV que contienen información sobre los participantes y las posturas de cada uno de los dos experimentos. Para procesar, analizar y visualizar estos datos, se desarrolló una interfaz de usuario (GUI) en MATLAB que automatiza estos procesos. La Figura 1 muestra el diagrama general de la GUI, que recibe como entradas el tipo de experimento y los dos archivos CSV de configuración, además de los datos de los sensores de presión. Esta interfaz permite visualizar los datos brutos de los sensores para cada participante y postura específica. Durante el proceso de adquisición, pueden surgir datos atípicos que sean inferiores a 0 o superiores a 1,000 en el primer experimento y a 500 en el segundo. Estos datos atípicos pueden ajustarse utilizando seis diferentes filtros, descritos a continuación:

1. Filtro de media (k_1).
2. Filtro de mediana (k_2).
3. Filtro cúbico de ventana cuadrada de 3×3 (k_3).
4. Filtro cúbico de ventana de suma de 5×5 (k_4).
5. Filtro cúbico de ventana en cruz de 5×5 (k_5).
6. Filtro híbrido de ventana de 5×5 (k_6).

Los kernels utilizados para estos filtros se muestran en las Ecuaciones 1 y 2. Los datos pueden ser procesados utilizando cualquiera de estos filtros, y adicionalmente, se empleó un método de interpolación bicúbica para mejorar la visualización de los datos. Cada una de las opciones de filtrado e interpolación son independientes, permitiendo su activación o desactivación en cualquier momento

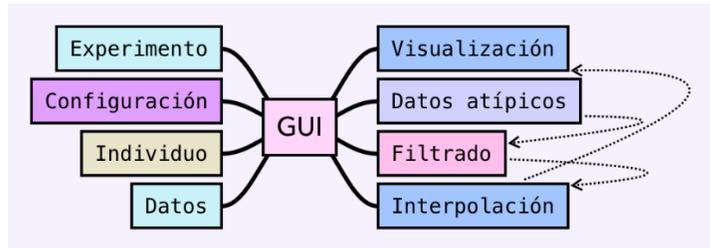


Figura 1. Diagrama general de interfaz de usuario y su procesamiento y visualización de datos.

$$k_3 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & -1/4 & 1/2 & -1/4 & 0 \\ 0 & 1/2 & 0 & 1/2 & 0 \\ 0 & -1/4 & 1/2 & -1/4 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad k_4 = \begin{bmatrix} 0 & 0 & -1/12 & 0 & 0 \\ 0 & 0 & 1/3 & 0 & 0 \\ -1/12 & 1/3 & 0 & 1/3 & -1/12 \\ 0 & 0 & 1/3 & 0 & 0 \\ 0 & 0 & -1/12 & 0 & 0 \end{bmatrix} \quad (1)$$

$$k_5 = \begin{bmatrix} -1/12 & 0 & 0 & 0 & -1/12 \\ 0 & 1/3 & 0 & 1/3 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 1/3 & 0 & 1/3 & 0 \\ -1/12 & 0 & 0 & 0 & -1/12 \end{bmatrix} \quad k_6 = \begin{bmatrix} -1/24 & 0 & -1/24 & 0 & -1/24 \\ 0 & 1/6 & 1/6 & 1/6 & 0 \\ -1/24 & 1/6 & 0 & 1/6 & -1/24 \\ 0 & 1/6 & 1/6 & 1/6 & 0 \\ -1/24 & 0 & -1/24 & 0 & -1/24 \end{bmatrix} \quad (2)$$

Resultados

La Figura 2 ilustra la GUI diseñada para analizar las posturas medidas mediante los sensores de presión. Inicialmente, el usuario debe seleccionar el experimento que desea analizar, especificando desde qué sensor se adquirieron los datos y bajo qué protocolo. Una vez seleccionado el experimento, la GUI muestra en tablas la información de los participantes y las posturas disponibles.

Para el primer experimento, se activa un control deslizante que permite navegar a través de la secuencia de imágenes. En el caso del segundo experimento, adicionalmente se puede elegir el tipo de colchón que se desea visualizar. Al lado derecho de la imagen de los sensores de presión, se muestra una referencia de colores para la gráfica. Si existen valores atípicos en los datos, es posible aplicar cualquiera de los seis filtros mencionados anteriormente o, si se desea mejorar aún más la imagen, aplicar una interpolación bicúbica.

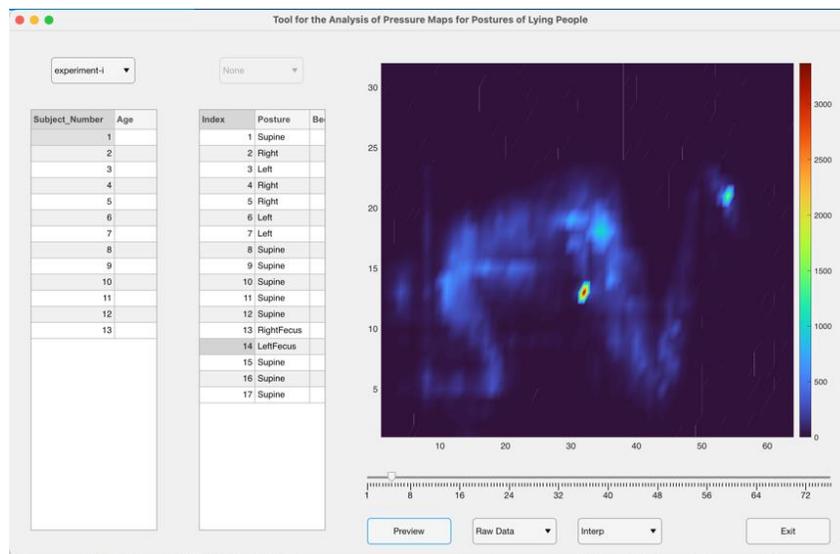


Figura 2. Imagen de la interfaz de usuario diseñada para procesar, analizar y visualizar los datos desde los sensores de presión.

Los sensores de presión están dispuestos de manera equidistante para garantizar un funcionamiento óptimo, lo cual resulta en una imagen de origen discretizada, como se ilustra en la Figura 3(a). Mediante la aplicación de la interpolación bicúbica, es posible obtener una representación más precisa de la presión, como se muestra en la Figura 3(b). Este proceso mejora significativamente el análisis de la postura y la identificación de los puntos de presión.

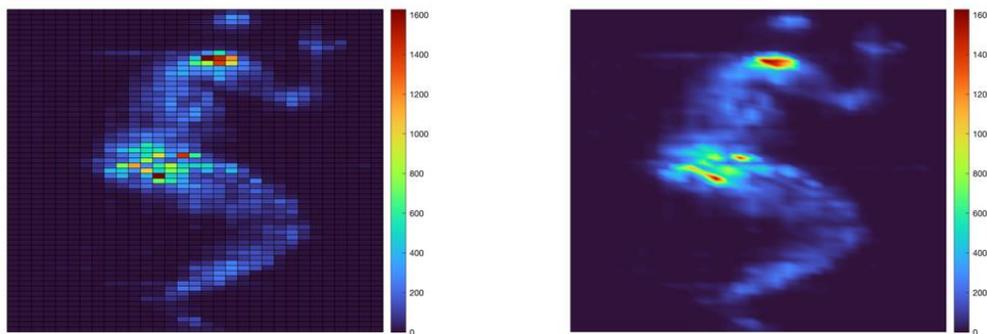


Figura 3. Imágenes obtenidas desde los sensores de presión (a) datos brutos desde el sensor Vista Medical FSA SoftFlez 2048, (b) interpolación bicúbica de los datos brutos del sensor.

La Figura 3 muestra datos atípicos del sensor Vista Medical FSA SoftFlez 2048, identificados por presentar puntos de presión superiores a 1,000, lo cual es incorrecto para este sensor. Para ajustar estos datos, se utilizan los seis filtros mencionados anteriormente, permitiendo la corrección de las anomalías. La Figura 4 ilustra los resultados obtenidos con cada una de las seis opciones de filtrado. A través de esta comparación, se puede observar que cada filtro tiene sus ventajas y desventajas dependiendo de la aplicación; sin embargo, en este análisis, el filtro híbrido demuestra ser especialmente efectivo, logrando una mayor continuidad en las regiones con puntos de presión atípicos y homogeneizando la imagen resultante.

Además del filtro híbrido, los otros filtros utilizados ofrecen diferentes enfoques para manejar los datos atípicos:

1. Filtro de media: Este filtro suaviza la imagen al calcular el promedio de los valores de los píxeles circundantes. Es efectivo para reducir el ruido, pero puede difuminar detalles importantes en áreas con variación significativa de presión.
2. Filtro de mediana: Funciona seleccionando la mediana de los valores en la ventana de filtro. Este método es más robusto contra los valores extremos que el filtro de media y preserva mejor los bordes en la imagen.
3. Filtro cúbico de ventana cuadrada de 3x3: Utiliza una aproximación cúbica para suavizar la imagen, lo que puede ser útil para preservar los detalles mientras se reduce el ruido. Este filtro es adecuado para áreas con cambios sutiles en la presión.
4. Filtro cúbico de ventana de suma de 5x5: Amplía la ventana de análisis, ofreciendo una suavización más intensa. Es útil en casos donde los datos son extremadamente ruidosos y se necesita una gran uniformidad.
5. Filtro cúbico de ventana en cruz de 5x5: Este filtro especializa su acción en patrones específicos dentro de la ventana, ofreciendo una corrección focalizada en áreas cruciales sin afectar el resto de la imagen demasiado.

Cada filtro se selecciona según la necesidad específica del análisis, buscando siempre el equilibrio entre eliminar los datos atípicos y preservar la fidelidad de los datos de presión originales. La elección del filtro adecuado depende del tipo de datos, la magnitud de los atípicos y los requerimientos específicos del análisis. La combinación de estos métodos permite una visualización precisa y ajustada de los datos capturados por los sensores de presión

Conclusiones

Los seis filtros implementados demostraron ser esenciales para corregir datos atípicos en las mediciones de presión del sensor. Especialmente, el filtro híbrido mostró una capacidad superior para homogeneizar la imagen resultante y mejorar la continuidad en las regiones de presión atípica, convirtiéndolo en una opción ideal para aplicaciones donde la precisión es crucial. La elección del filtro más adecuado varía según la naturaleza específica de los datos y el contexto del análisis. Los filtros de media y mediana son efectivos para mitigar el ruido general, mientras que los filtros cúbicos son preferibles para preservar detalles en condiciones de variabilidad sutil.

La integración de estas tecnologías en entornos clínicos no solo mejora la monitorización y cuidado del paciente, sino que también optimiza los recursos sanitarios al facilitar un seguimiento más eficaz y menos invasivo. Estos avances son un paso significativo hacia una atención más personalizada y proactiva, adaptándose a las necesidades individuales de cada paciente y, por ende, mejorando su calidad de vida.

La precisión en la corrección y análisis de los datos de presión tiene implicaciones profundas para la investigación clínica, particularmente en el estudio de las posturas en cama y la prevención de úlceras por presión en pacientes con movilidad reducida. Se recomienda explorar la incorporación de técnicas de aprendizaje automático para automatizar el proceso de selección y aplicación de filtros, lo que podría mejorar la eficiencia y efectividad del análisis de datos en tiempo real.

Futuras investigaciones deberían centrarse en validar estos métodos en un conjunto más amplio de datos y bajo condiciones variadas, para asegurar su robustez y aplicabilidad en diferentes escenarios clínicos.

Bibliografía/Referencias

- Baran Pouyan, M., Birjandtalab, J., Heydarzadeh, M., Ostadabbas, S., Rasoul Yousefi, Farshbaf, M., Nourani, M., & Pompeo, M. (2018). *A Pressure Map Dataset for In-bed Posture Classification (pmd)* [Dataset]. physionet.org. <https://doi.org/10.13026/C2W09K>
- Chen, R. J., Ding, T., Lu, M. Y., Williamson, D. F. K., Jaume, G., Song, A. H., Chen, B., Zhang, A., Shao, D., Shaban, M., Williams, M., Oldenburg, L., Weishaupt, L. L., Wang, J. J., Vaidya, A., Le, L. P., Gerber, G., Sahai, S., Williams, W., & Mahmood, F. (2024). Towards a general-purpose foundation model for computational pathology. *Nature Medicine*, *30*(3), 850–862. <https://doi.org/10.1038/s41591-024-02857-3>
- Hayat, Y., Tariq, M., Hussain, A., Tariq, A., & Rasool, S. (s/f). A Review of Biosensors and Artificial Intelligence in Healthcare and Their Clinical Significance. *International Research Journal of Economics and Management Studies IRJEMS*, *3*(1). Recuperado el 27 de julio de 2024, de <https://irjems.org/irjems-v3i1p126.html>
- Pouyan, M. B., Birjandtalab, J., Heydarzadeh, M., Nourani, M., & Ostadabbas, S. (2017). A pressure map dataset for posture and subject analytics. *2017 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, 65–68. <https://doi.org/10.1109/BHI.2017.7897206>
- Stern, L., & Roshan Fekr, A. (2023). In-Bed Posture Classification Using Deep Neural Network. *Sensors*, *23*(5), Article 5. <https://doi.org/10.3390/s23052430>
- Synthetic data generation: State of the art in health care domain. (2023). *Computer Science Review*, *48*, 100546. <https://doi.org/10.1016/j.cosrev.2023.100546>