

Jornadas de Automática

Bioseñales en entornos laborales y su aplicación en primeros intervinientes

Vera-Ortega, P.^{a,*}, Vázquez-Martín, R.^a, Mandow, A.^a, García-Cerezo, A.^a

^aGrupo de Robótica y Mecatrónica, Instituto Universitario de Investigación en Ingeniería Mecatrónica y Sistemas Ciberfísicos, Universidad de Málaga, 29071 Málaga, España.

To cite this article: Vera-Ortega, P., Vázquez-Martín, R., Mandow, A., García-Cerezo, A. 2024. Biosignals in work environments and their application in first responders. *Jornadas de Automática*, 45. <https://doi.org/10.17979/ja-cea.2024.45.10841>

Resumen

La medición de señales psicofisiológicas de trabajadores en el desempeño de sus tareas es útil para detectar estados psicofisiológicos que les impidan desarrollar adecuadamente su labor y pongan en peligro su integridad física. Para una detección efectiva de estos estados es necesario una selección adecuada de las bioseñales a monitorizar, acorde a la labor realizada, y un procesamiento correcto de las mismas. También es necesario establecer una verdad fundamental que permita el desarrollo de algoritmos de aprendizaje automático efectivos. Este artículo revisa las bioseñales y herramientas de procesamiento y predicción utilizadas en la detección de estados psicofisiológicos peligrosos para los trabajadores y expone una aplicación de monitorización de las bioseñales con primeros intervinientes durante ejercicios de alta fidelidad.

Palabras clave: Aprendizaje automático, Filtrado y suavizado, Análisis e interpretación de bioseñales, Procesamiento de señales, Control y apoyo a las decisiones, Seguridad.

Biosignals in work environments and their application in first responders

Abstract

Psychophysiological signal measurements from workers are useful for detecting psychophysiological states that prevent them from carrying out their work properly and endanger their physical integrity. For an effective detection of these states, an adequate selection of the biosignals to be monitored, according to the work performed, and their correct processing is necessary. It is also necessary to establish a ground truth that allows the development of effective machine learning algorithms. This article reviews the biosignals, and processing and prediction tools used in the detection of psychophysiological states dangerous to workers and presents an application of biosignal monitoring with first responders during high-fidelity exercises.

Keywords: Machine Learning, Filtering and smoothing, Bio-signals analysis and interpretation, Signal processing, Decision support and control, Security.

1. Introducción

El sistema nervioso simpático (SNS) de una persona reacciona ante estímulos que percibe como potencialmente peligrosos liberando hormonas en el torrente sanguíneo, preparando al cuerpo para afrontar dicha amenaza. Los niveles hormonales se mantienen altos hasta que el sistema nervioso parasimpático (SNP) se activa al cesar la amenaza (Tonacci et al., 2019). A esta reacción se la denomina estrés y es considera-

da positiva si permite superar con éxito el estímulo (eustrés). En cambio, si el estímulo es demasiado intenso o duradero, el estrés se torna negativo (distrés). Ante el distrés, se produce un deterioro en la toma de decisiones, la conciencia situacional y el rendimiento de las personas (Healey and Picard, 2005).

El menoscabo de estos factores en entornos VUCA (Giau-me et al., 2024) o durante la conducción (Halim and Rehan, 2020), unido a la fatiga física, pone en serio peligro la vida de los profesionales que actúan en estos escenarios. Es por

ello que la monitorización de la salud física y mental a través de las bioseñales es relevante para estos trabajadores (Grothe et al., 2023). La dificultad de la monitorización de las bioseñales estriba en realizar los experimentos en entornos realistas, no controlados y fuera de laboratorio, adaptándose a las necesidades de los trabajadores (Batistatos et al., 2022).

Este trabajo revisa el uso de las bioseñales en los entornos laborales en 41 artículos, y presenta al final una aplicación de la recopilación de bioseñales durante ejercicios de alta fidelidad realizados por primeros intervinientes (PI). Tras esta introducción, la Sección 2 presenta las bioseñales monitorizadas y su procesamiento. A continuación, la Sección 3 analiza los cuestionarios empleados para identificar los estados psicofisiológicos sufridos por los trabajadores. La Sección 4 expone los algoritmos, sus protocolos de validación y las métricas utilizados para la detección de estados psicofisiológicos de los trabajadores. Seguidamente, la Sección 5 muestra la monitorización de las bioseñales de PI durante varios ejercicios de alta fidelidad. Por último, la Sección 6 presenta los trabajos futuros y conclusiones de este artículo.

2. Bioseñales psicofisiológicas

Las bioseñales se emplean para la detección de estados fisiológicos y psicológicos. En el caso de usarse para ambos tipos de estados, se habla de aspecto psicofisiológico. La localización más común de los sensores que miden cada bioseñal se representa en la Figura 1.

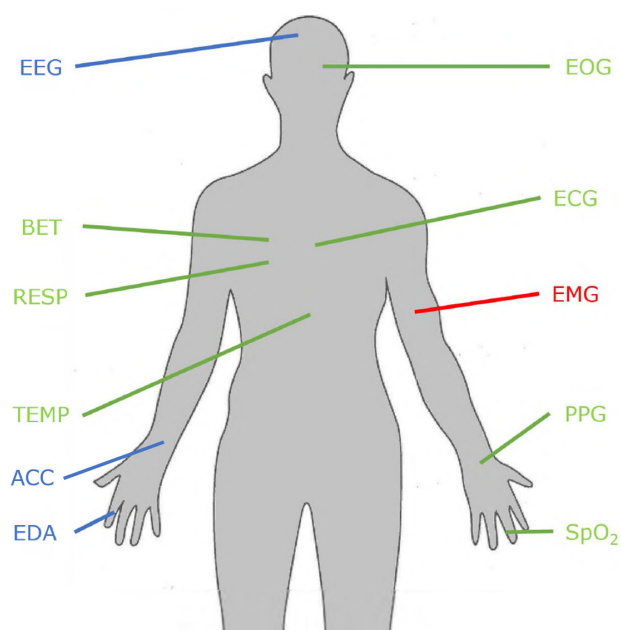


Figura 1: Localización más común de los sensores de las bioseñales. En rojo, señales relacionadas únicamente con el aspecto fisiológico. En azul, señales relacionadas únicamente con el aspecto psicofisiológico. En verde, señales relacionadas con el aspecto psicofisiológico.

Tanto corazón como pulmones están conectados al SNS y al SNP, partes del sistema nervioso autónomo (SNA) (Setz et al., 2010). La frecuencia cardíaca (FC) y su variabilidad (VFC) se han empleado para la detección de estados psicofisiológicos en ambas vertientes. La monitorización de estas dos variables se realiza a través del uso de electrocardiograma

(ECG), que representa la actividad eléctrica del corazón (Wagner et al., 2021), o de la fotopleletismografía (PPG), que mediante el reflejo de un haz de luz sobre los vasos sanguíneos es capaz de detectar el volumen de sangre por cada pulsación (Kang and Kim, 2022). En el aspecto fisiológico, permiten controlar las constantes vitales del corazón para detectar posibles irregularidades en el ritmo cardíaco o, incluso, un paro cardíaco. Desde el punto de vista de la psicología, cambios en las características de la VFC se relacionan con la reacción del cuerpo humano al estrés. De igual manera, la respiración (RESP) se ha empleado también indistintamente en el aspecto fisiológico (posibles paradas respiratorias) como en el psicológico (frecuencia respiratoria inusualmente alta) (Paletta et al., 2022). Además, la temperatura corporal (TEMP) en sus dos vertientes, la temperatura de la piel (TP) y la temperatura interna (TI), se ha empleado tanto para la detección de la fatiga física, por su incremento al realizar esfuerzo físico, como para la detección de estrés, por su relación con el incremento de la actividad metabólica del cuerpo ante un estresor percibido. La TP se mide por medio de termómetros de contacto o infrarrojos (Vavrinsky et al., 2021), mientras que la TI emplea cápsulas ingeridas previamente (Bustos et al., 2023).

En el plano psicológico, la actividad electrodérmica (EDA) ha sido empleada para el estudio del estrés en el entorno laboral. La EDA está formada por dos componentes, el nivel de conductancia de la piel (NCP), que varía lentamente y es señal de la activación psicofisiológica, y la respuesta de la conductancia de la piel (RCP), que reacciona rápidamente ante estímulos. La EDA se relaciona con la actividad del SNS, puesto que las glándulas sudoríparas están únicamente conectadas a esta parte del SNA. La liberación de hormonas como respuesta a un estresor se traduce en una activación de estas glándulas, provocando un cambio en la conductividad de la piel debido a la sudoración (van Dooren et al., 2012).

Otros autores han empleado bioseñales alternativas, como la electromiografía (EMG), que muestra la actividad eléctrica de los músculos, pero que necesita de un sensor por cada músculo que se desee estudiar (Toral et al., 2022); la electroencefalografía (EEG), que detecta la actividad eléctrica del cerebro, pero fuera de entornos controlados sin interferencias electromagnéticas es difícil obtener resultados satisfactorios (Hu and Lodewijks, 2020); la electrooculografía (EOG) estudia el movimiento del ojo para detectar parámetros psicofisiológicos, pero requiere de cámaras que interfieren en el campo de visión o en la labor de los sujetos de estudio (Gabbi et al., 2024); la pulsioximetría (SpO_2) (Rodríguez-Arce et al., 2020), la bioimpedancia eléctrica torácica (BET) (Mohino-Herranz et al., 2020) o la aceleración (ACC) (Menghini et al., 2019). La Tabla 1 recoge la frecuencia de uso de las bioseñales en los artículos revisados en este trabajo.

Aunque de una única bioseñal se pueden obtener múltiples características que permitan la identificación de estados psicofisiológicos, en el 76,74 % de los trabajos recogidos en esta revisión se han empleado dos o más bioseñales.

Otro factor importante en el uso de varias bioseñales ha sido la popularización de dispositivos portátiles con capacidad de medición de múltiples bioseñales, o la combinación de varios de estos dispositivos (Pratas et al., 2023), mejorando la robustez del sistema de detección de estados psicofisiológicos al poder correlacionar distintas señales (Schmidt et al., 2018).

Tabla 1: Frecuencia de uso de bioseñales en los artículos revisados.

Bioseñal	Número de veces usada
EDA	31
ECG	27
PPG	12
RESP	10
TEMP	10
EMG	7
EEG	6
ACC	5
EOG	3
BET	1
SpO ₂	1

Las bioseñales adquiridas por los dispositivos están sujetas a ruidos y artefactos provocados por interferencias electromagnéticas, movimiento o mal acople de los dispositivos de medición de las señales. Para eliminar de estos elementos no deseados es necesario filtrar las señales dentro de un rango de frecuencias determinado para cada bioseñal, evitando la pérdida de información de la bioseñal (Batista et al., 2019).

Los filtros más empleados en los trabajos revisados han sido los de tipo Butterworth (Daviaux et al., 2020), de respuesta finita al impulso (Kutt et al., 2018), y de media o mediana (Nkurikiyeyezu et al., 2020). Además, también se han empleado otras alternativas como el filtro de Savitzky-Golay (Koo et al., 2018), el filtro analógico (Mizuno et al., 2011) o el filtro elíptico (Das et al., 2018).

Las señales cuentan con una serie de características que son extraídas de los datos captados por los sensores. Algunas de las más utilizadas son comunes a los distintos tipos de bioseñales y pertenecientes al dominio del tiempo: media, desviación típica, mínimo y máximo (Schmidt et al., 2019).

Algunas características son específicas de una bioseñal concreta. En las señales ECG y PPG, es fundamental identificar los picos R característicos de la contracción ventricular del corazón (Pan and Tompkins, 1985). Esta identificación permite estudiar la VFC con características del dominio temporal como la media cuadrática de las diferencias sucesivas entre los intervalos R-R y el porcentaje del número de intervalos R-R adyacentes que difieren más de un determinado tiempo (normalmente 50 milisegundos). Dentro del dominio de la frecuencia se diferencia entre la potencia espectral de la VFC en altas y bajas frecuencias, como muestra de la actividad del SNP o del SNS, respectivamente. También se usan parámetros no lineales como el diagrama de Poincaré (Malik et al., 1996).

3. Cuestionarios

Para obtener una verdad fundamental que relacione las bioseñales recopiladas con los estados psicofisiológicos experimentados por los sujetos de estudio es necesario establecer un procedimiento en el cual se plasme dicha información. Para ello, se han usado cuestionarios especializados en la detección de ansiedad (STAI (Bhoja et al., 2020)), estrés (SAM (Koldijk et al., 2014)) o carga de trabajo (NASA-TLX (Gutiérrez et al., 2023)). Estos cuestionarios pueden dar como opciones de respuesta puntuaciones numéricas (Kyriakou et al., 2019), texto descriptivo de los estados, escalas Likert que combinen las dos

anteriores (Choi et al., 2012) o dibujos descriptivos del estado psicofisiológico del sujeto (Liu et al., 2019).

4. Aprendizaje automático

Tras la extracción de las características de las bioseñales, la correlación entre estas características y los estados psicofisiológicos que puedan causar situaciones de peligro para los trabajadores se ha realizado por medio de algoritmos de aprendizaje automático.

Entre los algoritmos más empleados en los trabajos revisados se encuentran los de bosque aleatorio (Hosseini et al., 2022), árbol de decisión (Koldijk et al., 2018), potenciación del gradiente (Pinto et al., 2023), análisis lineal discriminante (Pakarinen et al., 2019), k-vecinos más cercanos (Han et al., 2020), máquinas de vectores de soporte (McDuff et al., 2014) o las aproximaciones bayesianas (Sun et al., 2012).

En menor medida, se han empleado redes de aprendizaje profundo, como el perceptrón multicapa (Arsalan et al., 2019), las redes neuronales prealimentadas (Filippini et al., 2022) o las redes de creencia profunda (Torku et al., 2022).

Para estos algoritmos de aprendizaje supervisado es necesario establecer una serie de protocolos de validación a la hora de realizar su entrenamiento con datos previamente etiquetados, empleándose usualmente la validación cruzada, en la que se divide el conjunto de datos en varios grupos, dejando uno de ellos para validar el entrenamiento realizado con el resto de los grupos y repitiéndose normalmente dicho proceso hasta que todos los grupos han servido para validar el entrenamiento realizado con el resto de grupos. Un caso particular de validación cruzada es la conocida por sus siglas en inglés como LOSO (Leave-One-Subject-Out), dejando uno de los sujetos de estudio fuera del entrenamiento y usándose para evaluar el algoritmo entrenado (Bobade and Vani, 2020).

Para la evaluación de los diversos algoritmos y redes empleadas en la detección de estados psicofisiológicos se han empleado una serie de métricas, representadas en las ecuaciones (1), (2), (3) y (4). En estas ecuaciones se han tenido en cuenta los verdaderos positivos (VP), los verdaderos negativos (VN), los falsos positivos (FP) y los falsos negativos (FN):

- Exactitud: Número de VP y VN sobre el total de muestras.

$$Exactitud = \frac{(VP + VN)}{(VP + FP + VN + FN)} \quad (1)$$

- Precisión: Número de VP sobre el total de positivos (tanto VP como VN).

$$Precisión = \frac{VP}{(VP + FP)} \quad (2)$$

- Sensibilidad: Número de VP sobre el total de VP y FN.

$$Sensibilidad = \frac{VP}{(VP + FN)} \quad (3)$$

- Puntuación F1: Compromiso entre la precisión (2) y la sensibilidad (3), siendo 1 la mejor puntuación y 0 la peor.

$$Puntuación F_1 = 2 \cdot \frac{Precisión \cdot Sensibilidad}{(Precisión + Sensibilidad)} \quad (4)$$

A pesar de la variedad de algoritmos de aprendizaje automático y aprendizaje profundo existentes, en los distintos trabajos revisados en este artículo no existe un tipo concreto que presente mejores métricas que los demás.

5. Monitorización de bioseñales en primeros intervinientes durante ejercicios de alta fidelidad

Una aplicación de la recopilación de bioseñales en entornos laborales es la que ha sido llevada a cabo durante varias ediciones de las Jornadas Internacionales de la Universidad de Málaga sobre Seguridad, Emergencias y Catástrofes (JEMERG), organizadas anualmente por la Cátedra de Seguridad, Emergencias y Catástrofes. En estas Jornadas participan PI, término que agrupa a los profesionales que acuden en primer lugar ante una emergencia (Policía, Bomberos y servicios médicos, entre otros). A lo largo de las ediciones de los años 2021, 2022 y 2023 se han realizado ejercicios de alta fidelidad de localización y rescate de víctimas atrapadas en un vehículo siniestrado, extinción de incendios (Figura 2(a)) y rescate vertical de víctimas atrapadas tras un corrimiento de tierras (Figura 2(b)) (Vera-Ortega et al., 2023).



Figura 2: Intervenciones monitorizadas durante las JEMERG: en (a), extinción de incendio y en (b), rescate de víctima atrapada.

Durante estos ejercicios se utilizó el dispositivo BITalino Core BT de la empresa Plux (PLUX, 2020). Se recopilaban las señales ECG, EDA y RESP en todas las ediciones, además de EEG en la edición de 2022, de un total de ocho bomberos participantes en los ejercicios. La evolución a lo largo de las tres ediciones de las JEMERG ha permitido solucionar errores de sujeción de los electrodos y de conexión entre dispositivos, aumentando la duración de las grabaciones, de diez minutos inicialmente a algo más de dos horas en la última edición, según lo recogido en la Tabla 2.

Tabla 2: Duración de las grabaciones y bioseñales registradas de los PI durante las distintas ediciones de las JEMERG.

Edición	Duración	Bioseñales
2021	10 min 35 s	ECG, EDA, RESP
2022	7 min 44 s	ECG, EDA, EEG, RESP
2023	2 h 5 min 58 s	ECG, EDA, RESP

Estas grabaciones han sido sometidas a procesos de filtrado de las señales y extracción de las características. La Figura 3 presenta cinco segundos de señal ECG grabada durante

las JEMERG-22 y su posterior procesamiento para detectar los picos R de dicha señal y algunas de sus características.




Figura 3: Procesamiento de señal ECG grabada durante las JEMERG-22. En (a), señal original, y en (b), señal tras filtrado mediante filtro Butterworth de orden 3 y paso banda entre 5 y 60 Hz, detección de picos R según el algoritmo de (Pan and Tompkins, 1985) y cálculo de la distancia media, máxima y mínima entre picos R consecutivos en esa misma ventana de tiempo.

Gracias a los resultados de una encuesta respondida por los miembros del Consorcio de Bomberos de la Diputación Provincial de Málaga, se conocieron los requisitos ergonómicos de estos PI, pasando de una configuración inicial de medición de la señal EDA en la base del dedo pulgar a la colocación sobre el omoplato izquierdo, y eliminando del conjunto de sensores los de la señal EEG. Para facilitar la colocación de los sensores, disminuir el tiempo de preparación de los PI y mejorar el agarre de los electrodos al cuerpo, en la edición de 2023 se integraron los sensores en una camiseta deportiva. Además, para obtener una verdad fundamental sobre el estado psicofisiológico de los intervinientes monitorizados durante los ejercicios se ha desarrollado un cuestionario en el que recoger sus impresiones, previa firma de un consentimiento informado.

La recopilación de estas bioseñales busca crear una base de datos que permita, tras el procesamiento de las señales, entrenar algoritmos de aprendizaje automático que detecten en tiempo real niveles de estrés y fatiga que interfieran en la labor desarrollada por los PI. Esto permitirá poder retirar a tiempo del escenario de actuación al interviniente afectado antes de que sufra algún tipo de percance, entorpecza a sus compañeros o perjudique el desarrollo de las operaciones.

6. Conclusiones

En los artículos revisados durante este trabajo, las bioseñales han demostrado su importancia en la detección de factores de riesgo en el puesto de trabajo relacionados con el estado psicofisiológico de los trabajadores.

Durante este artículo, se han descrito las bioseñales más empleadas en los trabajos revisados. En la selección y recopilación de estas bioseñales deben tenerse en cuenta los estados que se desean detectar y las características de la labor desarrollada por los trabajadores, que deben ser contrastadas con una verdad fundamental, recogidas en forma de cuestionarios. Además, es necesario realizar un correcto procesamiento de las bioseñales, que elimine el ruido y los artefactos presentes en las grabaciones. La correcta selección de las características resulta en una mejora en la eficiencia del entrenamiento de los algoritmos de aprendizaje automático que permiten la detección de los estados psicofísicos peligrosos para los trabajadores en su entorno laboral, sin que haya un tipo de algoritmo concreto que destaque sobre los demás en cuanto a resultados.

Por último, este artículo ha presentado una aplicación de monitorización de señales ECG, EDA, RESP y EEG de bomberos durante ejercicios de alta fidelidad desarrollados en las JEMERG. A lo largo las tres ediciones de las JEMERG en las que han sido monitorizadas las bioseñales de los bomberos se han aplicado técnicas de mejora de la adquisición de las bioseñales, junto con mejoras en la ergonomía, en la conexión de los equipos utilizados y en la obtención de la verdad fundamental del estado psicofisiológico de los PI a través de cuestionarios. La recopilación de estas bioseñales y su posterior procesamiento permitirán el entrenamiento de algoritmos de detección del estrés y la fatiga física en el exigente entorno de trabajo de los PI.

Agradecimientos

Este trabajo ha sido parcialmente financiado por el Ministerio de Ciencia, Innovación y Universidades, Gobierno de España, proyectos RTI2018-093421-B-I00 y PID2021-122944OB-I00.

Los autores quieren agradecer también la colaboración de la Cátedra de Seguridad, Emergencias y Catástrofes de la Universidad de Málaga, dirigida por Jesús Miranda Páez, por la organización de los ejercicios y el contacto con el consorcio de Bomberos de la Diputación Provincial de Málaga. Además, agradecemos la colaboración de los miembros del Real Cuerpo de Bomberos de Málaga y del Cuerpo de Bomberos de Benalmádena durante la realización de los ejercicios en las JEMERG.

Referencias

- Arsalan, A., Majid, M., Anwar, S. M., Bagci, U., 2019. Classification of perceived human stress using physiological signals. In: 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 1247–1250.
DOI: 10.1109/EMBC.2019.8856377
- Batista, D., da Silva, H. P., Fred, A., Moreira, C., Reis, M., Ferreira, H. A., 2019. Benchmarking of the BITalino biomedical toolkit against an established gold standard. *Healthcare Technology Letters* 6 (2), 32 – 36.
DOI: 10.1049/htl.2018.5037
- Batistatos, M. C., Kourtis, M.-A., Xilouris, G. K., Santorinaios, D., Oikonomakis, A., Kourtis, A., 2022. A technological framework for leveraging first responders' efficiency and safety. In: 2022 Panhellenic Conference on Electronics & Telecommunications (PACET), pp. 1–6.
DOI: 10.1109/PACET56979.2022.9976349
- Bhoja, R., Guttman, O. T., Fox, A. A., Melikman, E., Kosemund, M., Ginchich, K. J., 2020. Psychophysiological stress indicators of heart rate variability and electrodermal activity with application in healthcare simulation research. *Simulation in Healthcare* 15 (1), 39 – 45.
DOI: 10.1097/SIH.0000000000000402
- Bobade, P., Vani, M., 2020. Stress detection with machine learning and deep learning using multimodal physiological data. In: 2020 Second International Conference on Inventive Research in Computing Applications (ICIRCA), pp. 51–57.
DOI: 10.1109/ICIRCA48905.2020.9183244
- Bustos, D., Cardoso, F., Rios, M., Vaz, M., Guedes, J., Torres Costa, J., Santos Baptista, J., Fernandes, R. J., 2023. Machine learning approach to model physical fatigue during incremental exercise among firefighters. *Sensors* 23 (1).
DOI: 10.3390/s23010194
- Choi, J., Ahmed, B., Gutierrez-Osuna, R., 2012. Development and evaluation of an ambulatory stress monitor based on wearable sensors. *IEEE Transactions on Information Technology in Biomedicine* 16 (2), 279 – 286.
DOI: 10.1109/TITB.2011.2169804
- Das, D., Datta, S., Bhattacharjee, T., Choudhury, A. D., Pal, A., 2018. Eliminating individual bias to improve stress detection from multimodal physiological data. *Conference proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference 2018*, 5753 – 5758.
DOI: 10.1109/EMBC.2018.8513680
- Daviaux, Y., Bonhomme, E., Ivers, H., de Sevin, E., Micoulaud-Franchi, J.-A., Bioulac, S., Morin, C. M., Philip, P., Altena, E., 2020. Event-related electrodermal response to stress: results from a realistic driving simulator scenario. *Human Factors* 62 (1), 138 – 151.
DOI: 10.1177/0018720819842779
- Filippini, C., Di Crosta, A., Palumbo, R., Perpetuini, D., Cardone, D., Ceccato, I., Di Domenico, A., Merla, A., 2022. Automated affective computing based on bio-signals analysis and deep learning approach. *Sensors* 22 (5).
DOI: 10.3390/s22051789
- Gabbi, M., Cornia, L., Villani, V., Sabattini, L., 2024. Understanding fatigue through biosignals: a comprehensive dataset. In: *Proceedings of the 2024 ACM/IEEE International Conference on Human-Robot Interaction. Association for Computing Machinery, New York, NY, USA*, p. 901–905.
DOI: 10.1145/3610977.3637485
- Giaume, L., Le Roy, B., Daniel, Y., Lauga Cami, H., Jost, D., Travers, S., Trousselard, M., 2024. Psychological, cognitive, and physiological impact of hazards casualties' trainings on first responders: the example of a chemical and radiological training. an exploratory study. *Frontiers in Psychology* 15.
DOI: 10.3389/fpsyg.2024.1336701
- Grothe, J., Tucker, S., Blake, A., Achutan, C., Medcalf, S., Suwondo, T., Fruhling, A., Yoder, A., 2023. Exploring first responders' use and perceptions on continuous health and environmental monitoring. *International Journal of Environmental Research and Public Health* 20 (6).
DOI: 10.3390/ijerph20064787
- Gutiérrez, A., Blanco, P., Ruiz, V., Chatzigeorgiou, C., Oregui, X., Álvarez, M., Navarro, S., Feidakis, M., Azpiroz, I., Izquierdo, G., Larraga-García, B., Kasnesis, P., Olaiola, I. G., Álvarez, F., 2023. Biosignals monitoring of first responders for cognitive load estimation in real-time operation. *Applied Sciences* 13 (13).
DOI: 10.3390/app13137368
- Halim, Z., Rehan, M., 2020. On identification of driving-induced stress using electroencephalogram signals: a framework based on wearable safety-critical scheme and machine learning. *Information Fusion* 53, 66 – 79.
DOI: 10.1016/j.inffus.2019.06.006
- Han, H. J., Labbaf, S., Borelli, J. L., Dutt, N., Rahmani, A. M., 2020. Objective stress monitoring based on wearable sensors in everyday settings. *Journal of Medical Engineering and Technology* 44 (4), 177 – 189.
DOI: 10.1080/03091902.2020.1759707
- Healey, J. A., Picard, R. W., 2005. Detecting stress during real-world driving tasks using physiological sensors. *IEEE Transactions on Intelligent Transportation Systems* 6 (2), 156 – 166.
DOI: 10.1109/TITS.2005.848368
- Hosseini, S., Gottumukkala, R., Katragadda, S., Bhupatiraju, R. T., Ashkar,

- Z., Borst, C. W., Cochran, K., 2022. A multimodal sensor dataset for continuous stress detection of nurses in a hospital. *Scientific Data* 9 (1). DOI: 10.1038/s41597-022-01361-y
- Hu, X., Lodewijks, G., 2020. Detecting fatigue in car drivers and aircraft pilots by using non-invasive measures: the value of differentiation of sleepiness and mental fatigue. *Journal of Safety Research* 72, 173 – 187. DOI: 10.1016/j.jsr.2019.12.015
- Kang, D.-H., Kim, D.-H., 2022. 1D convolutional autoencoder-based PPG and GSR signals for real-time emotion classification. *IEEE Access* 10, 91332 – 91345. DOI: 10.1109/ACCESS.2022.3201342
- Koldijk, S., Neerinx, M. A., Kraaij, W., 2018. Detecting work stress in offices by combining unobtrusive sensors. *IEEE Transactions on Affective Computing* 9 (2), 227 – 239. DOI: 10.1109/TAFCC.2016.2610975
- Koldijk, S., Sappelli, M., Verberne, S., Neerinx, M. A., Kraaij, W., 2014. The SWELL knowledge work dataset for stress and user modeling research. In: *Proceedings of the 16th International Conference on Multimodal Interaction*. Association for Computing Machinery, New York, NY, USA, p. 291–298. DOI: 10.1145/2663204.2663257
- Koo, H. R., Lee, J.-W., Lee, J. H., 2018. Garment function module to reduce motion artifacts in heart-activity-sensing clothing based on a magnetic-induced conductivity sensing method. *Textile Research Journal* 88 (19), 2190 – 2205. DOI: 10.1177/0040517517716909
- Kutt, K., Binek, W., Misiak, P., Nalepa, G. J., Bobek, S., 2018. Towards the development of sensor platform for processing physiological data from wearable sensors. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 10842 LNAI, 168 – 178. DOI: 10.1007/978-3-319-91262-2_16
- Kyriakou, K., Resch, B., Sagl, G., Petutschnig, A., Werner, C., Niederseer, D., Liedlgruber, M., Wilhelm, F., Osborne, T., Pykett, J., 2019. Detecting moments of stress from measurements of wearable physiological sensors. *Sensors* 19 (17). DOI: 10.3390/s19173805
- Liu, J. J. W., Reed, M., Vickers, K., 2019. Reframing the individual stress response: balancing our knowledge of stress to improve responsiveness to stressors. *Stress and Health* 35 (5), 607 – 616. DOI: 10.1002/smi.2893
- Malik, M., Camm, A., Bigger Jr., J., Breithardt, G., Cerutti, S., Cohen, R., Coumel, P., Fallen, E., Kennedy, H., Kleiger, R., Lombardi, F., Malliani, A., Moss, A., Rottman, J., Schmidt, G., Schwartz, P., Singer, D., 1996. Heart rate variability. standards of measurement, physiological interpretation, and clinical use. *European Heart Journal* 17 (3), 354 – 381. DOI: 10.1093/oxfordjournals.eurheartj.a014868
- McDuff, D., Gontarek, S., Picard, R., 2014. Remote measurement of cognitive stress via heart rate variability. In: *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. pp. 2957–2960. DOI: 10.1109/EMBC.2014.6944243
- Menghini, L., Gianfranchi, E., Cellini, N., Patron, E., Tagliabue, M., Sarlo, M., 2019. Stressing the accuracy: wrist-worn wearable sensor validation over different conditions. *Psychophysiology* 56 (11). DOI: 10.1111/psyp.13441
- Mizuno, K., Tanaka, M., Yamaguti, K., Kajimoto, O., Kuratsune, H., Watanabe, Y., 2011. Mental fatigue caused by prolonged cognitive load associated with sympathetic hyperactivity. *Behavioral and Brain Functions* 7. DOI: 10.1186/1744-9081-7-17
- Mohino-Herranz, I., Gil-Pita, R., García-Gómez, J., Rosa-Zurera, M., Seoane, F., 2020. A wrapper feature selection algorithm: an emotional assessment using physiological recordings from wearable sensors. *Sensors* 20 (1). DOI: 10.3390/s20010309
- Nkurikiyeyezu, K., Yokokubo, A., Lopez, G., 2020. Effect of person-specific biometrics in improving generic stress predictive models. *Sensors and Materials* 32 (2), 703 – 722. DOI: 10.18494/SAM.2020.2650
- Pakarinen, T., Pietilä, J., Nieminen, H., 2019. Prediction of self-perceived stress and arousal based on electrodermal activity. In: *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. pp. 2191–2195. DOI: 10.1109/EMBC.2019.8857621
- Paletta, L., Pszeida, M., Schneeberger, M., Dini, A., Reim, L., Kallus, K. W., 2022. Cognitive-emotional stress and risk stratification of situational awareness in immersive first responder training. In: *2022 IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)*. pp. 1–4. DOI: 10.1109/BHI56158.2022.9926805
- Pan, J., Tompkins, W. J., 1985. A real-time QRS detection algorithm. *IEEE Transactions on Biomedical Engineering BME-32* (3), 230 – 236. DOI: 10.1109/TBME.1985.325532
- Pinto, R. J., Silva, P. M., Duarte, R. P., Marinho, F. A., Gouveia, A. J., Gonçalves, N. J., Coelho, P. J., Zdravevski, E., Lameski, P., Garcia, N. M., Pires, I. M., 2023. Preliminary study on the identification of diseases by electrocardiography sensors’ data. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* 13919 LNBI, 292 – 304. DOI: 10.1007/978-3-031-34953-9_23
- Pratas, P., Bustos, D., Guedes, J., Mendes, J., Baptista, J. S., Vaz, M., 2023. Physiological monitoring systems for fatigue detection within firefighters: a brief systematic review. *Studies in Systems, Decision and Control* 449, 469 – 486. DOI: 10.1007/978-3-031-12547-8_38
- Rodríguez-Arce, J., Lara-Flores, L., Portillo-Rodríguez, O., Martínez-Méndez, R., 2020. Towards an anxiety and stress recognition system for academic environments based on physiological features. *Computer Methods and Programs in Biomedicine* 190. DOI: 10.1016/j.cmpb.2020.105408
- Schmidt, P., Reiss, A., Dürichen, R., Marberger, C., Van Laerhoven, K., 2018. Introducing WESAD, a multimodal dataset for wearable stress and affect detection. In: *Proceedings of the 20th ACM International Conference on Multimodal Interaction*. Association for Computing Machinery, New York, NY, USA, p. 400–408. DOI: 10.1145/3242969.3242985
- Schmidt, P., Reiss, A., Dürichen, R., Laerhoven, K. V., 2019. Wearable-based affect recognition—a review. *Sensors* 19 (19). DOI: 10.3390/s19194079
- Setz, C., Arnrich, B., Schumm, J., La Marca, R., Tröster, G., Ehlert, U., 2010. Discriminating stress from cognitive load using a wearable EDA device. *IEEE Transactions on Information Technology in Biomedicine* 14 (2), 410 – 417. DOI: 10.1109/TITB.2009.2036164
- Sun, F.-T., Kuo, C., Cheng, H.-T., Buthpitiya, S., Collins, P., Griss, M., 2012. Activity-aware mental stress detection using physiological sensors. *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering, LNICST 76 LNICST*, 211 – 230. DOI: 10.1007/978-3-642-29336-8_12
- Tonacci, A., Billeci, L., Burrai, E., Sansone, F., Conte, R., 2019. Comparative evaluation of the autonomic response to cognitive and sensory stimulations through wearable sensors. *Sensors* 19 (21). DOI: 10.3390/s19214661
- Toral, V., Romero, F. J., Castillo, E., Morales, D. P., Rivadeneyra, A., Salinas-Castillo, A., Parrilla, L., García, A., 2022. A versatile wearable based on reconfigurable hardware for biomedical measurements. *Measurement: Journal of the International Measurement Confederation* 201. DOI: 10.1016/j.measurement.2022.111744
- Torku, A., Chan, A. P., Yung, E. H., Seo, J., 2022. Detecting stressful older adults-environment interactions to improve neighbourhood mobility: a multimodal physiological sensing, machine learning, and risk hotspot analysis-based approach. *Building and Environment* 224. DOI: 10.1016/j.buildenv.2022.109533
- PLUX, 2020. BITalino Core BT datasheet. Available online: <https://support.pluxbiosignals.com/wp-content/uploads/2021/11/bitalino-core-datasheet.pdf>, accessed on May 31, 2024.
- van Dooren, M., de Vries, J.-J., Janssen, J. H., 2012. Emotional sweating across the body: comparing 16 different skin conductance measurement locations. *Physiology and Behavior* 106 (2), 298 – 304. DOI: 10.1016/j.physbeh.2012.01.020
- Vavrinsky, E., Stopjakova, V., Kopani, M., Kosnacova, H., 2021. The concept of advanced multi-sensor monitoring of human stress. *Sensors* 21 (10). DOI: 10.3390/s21103499
- Vera-Ortega, P., Vázquez-Martín, R., Fernandez-Lozano, J., García-Cerezo, A., Mandow, A., 2023. Enabling remote responder bio-signal monitoring in a cooperative human-robot architecture for search and rescue. *Sensors* 23 (1). DOI: 10.3390/s23010049
- Wagner, R. E., da Silva, H. P., Gramann, K., 2021. Validation of a low-cost electrocardiography (ECG) system for psychophysiological research. *Sensors* 21 (13). DOI: 10.3390/s21134485