

## DEVELOPMENT AND IMPLEMENTATION OF ELECTRONIC DEVICES FOR THE STRESS DETECTION IN ACADEMIC CONTEXTS

### DESARROLLO E IMPLEMENTACIÓN DE DISPOSITIVOS ELECTRÓNICOS PARA LA DETECCIÓN DEL ESTRÉS EN CONTEXTOS ACADÉMICOS

**PhD. Cristhian Manuel Durán Acevedo, MSc. Jeniffer Katherine Carrillo Gómez,  
Ing. Camilo Andrés Albarracín Rojas.**

**Universidad de Pamplona.**  
Grupo de investigación GISM.

Ciudadela Universitaria. Pamplona, Norte de Santander, Colombia.

E-mail: {cmduran, jeniffer.carrillo, camilo.albarracin}@unipamplona.edu.co

**Abstract:** This article shows the development and implementation of an electronic nose (E-nose) for the detection of volatile organic compounds (VOCs) emitted by the skin, a surface electromyography (EMG) system, in addition to the application of portable devices for the measurement of galvanic skin response (GSR), and heart rate variability (HRV). For the processing and analysis of the data of each system, algorithms developed in Python were implemented. Methods of Linear Discriminant Analysis (LDA) and Vector Support Classification Machines (SVM) were applied to classify the measurements, where 90% of success was obtained with the E-nose, with the GSR signal it was possible to classify 100% of success, with the EMG signal a 90% of success and with the HRV signal an 88% of success was obtained.

**Keywords:** Electronic smell, Galvanic Skin response, Heart rate variability, Electromyography, Stress detection.

**Resumen:** El presente artículo muestra el desarrollo e implementación un olfato electrónico (E-nose) para la detección de compuestos orgánicos volátiles (COV's) emitidos por la piel, un sistema de electromiografía de superficie (EMG), además de la aplicación de dispositivos portátiles para la medición de la respuesta galvánica de la piel (GSR), y la variabilidad de la frecuencia cardíaca (HRV). Para el procesamiento y análisis de los datos de cada sistema se implementaron algoritmos desarrollados en Python. Se aplicaron métodos de Análisis Lineal Discriminante (LDA) y Maquinas de Soporte Vectorial Clasificación (SVM) para la clasificación de las medidas, donde un 90% de acierto fue obtenido con la E-nose, con la señal GSR se logró clasificar el 100% de acierto, con la señal EMG un 90% de acierto y con la señal HRV se obtuvo un 88% de acierto.

**Palabras clave:** Electronic smell, Respuesta galvánica de la piel, Variabilidad de la frecuencia cardíaca, Electromiografía, Detección de estrés.

## 1. INTRODUCCIÓN

El estrés académico es una reacción que tienen los estudiantes frente a las diversas exigencias y

demandas generadas durante su paso por la universidad (Schneiderman, 2005). Está influenciado por todos los factores educativos o estímulos del ambiente académico que presionan

de algún modo a los estudiantes, lo que genera un ambiente físico desagradable en el aula de clase, provocando así que el estudiante vea su entorno educativo como una amenaza, un reto, generando una alteración de respuesta del individuo a nivel cognitivo, fisiológico, psicológico y efectos conductuales (Mendoza, 2007).

Actualmente debido a la pandemia del COVID-19 las universidades alrededor del mundo han comenzado a impartir el método de enseñanza de manera virtual generando así retos y adaptaciones en los estudiantes. En consecuencia a esta metodología, se han generado emociones en los estudiantes como ansiedad, depresión, estrés, que puede conducir a efectos desfavorables en el aprendizaje y la salud psicológica de los estudiantes (Huckins, 2020), pues cada estudiante asume la responsabilidad de su proceso de formación. Además, frente a una posible falta de explicación del docente, exceso de trabajos, falta de materiales y herramientas como computador, internet, entre otros, aumentan en el estudiante la probabilidad de bajo rendimiento y desarrollo de altos niveles de estrés (Sahu 2020).

La aplicación de cuestionarios psicométricos se usan tradicionalmente para la detección de estrés y ansiedad (Abu 2020), con ayuda de estos, los profesionales de la salud mental evalúan algunos aspectos psicológicos de una persona como su personalidad y habilidades, aunque con su aplicación se consiguen buenos resultados, una de las desventajas de este método es que los encuestados pueden proporcionar respuestas que intenten minimizar sus atributos negativos y maximizar los positivos, además tienden a ser inexactos o engañosos si no se interpretan de la manera correcta, algunos test tienden a tener respuestas fijas donde muchas veces deben escoger una respuesta que no encaja con su personalidad (Rodríguez. 2020).

En una revisión de la bibliografía se encontraron estudios para la detección de estrés a partir de la respuesta fisiológica del paciente, entre las señales más usadas están: las características del ECG como la variabilidad de la frecuencia cardiaca (HRV) (Chen et al. 2020), electroencefalograma (EEG) (Imperatori et al. 2020), actividad electro dérmica (GSR) (Liu 2018), electromiograma (EMG)(Sriramprakash, 2017), la respiración (Machado 2018), el diámetro de la pupila (Torres 2015). El cortisol en los biofluidos y los COV's emitidos por la piel parecen ser marcadores prácticos y útiles para la detección de eventos de estrés emocional.(Zamkah 2020)(Martin. 2016). Sin embargo, a la fecha no existen estudios de la

aplicación de dispositivos electrónicos para la medición de los parámetros relacionados con el estrés en entornos académicos.

En este artículo se presenta una aproximación para la detección de estrés académico en los estudiantes de Ingeniería de la Universidad de Pamplona (Colombia), implementando una E-nose basada en la metodología de detección de COV's, esta es una técnica no invasiva y se ha utilizado ampliamente en el campo de la salud para la detección de enfermedades y trastornos (Hsieh 2018)(Sethi 2013), la respuesta fisiológica provocada en el cuerpo ante un evento percibido como amenazante conlleva a la generación de olores corporales que pueden tener una forma distintiva, lo que indica que pueden existir roles olfativos de COV's relacionados con las emociones humanas (de Groot et al. 2012). El segundo método se fundamenta en la actividad electro dérmica en los dedos de las manos, para ello se implementó un sensor Grove 1.2 GSR de la compañía "Seeed Studio" para medir la conductancia eléctrica de la piel, estos dos métodos están basados en la sudoración emocional, este comportamiento se produce cuando ocurre una reacción frente a un estímulo emotivo, en este caso el estrés, provocando de esta forma una sudoración en toda la superficie de la piel pero que se concentra en palmas de las manos, plantas de los pies, frente y axilas (Machado 2012)

Para el tercer método se implementó el módulo ADS1298ECG-FG de la compañía "Texas Instruments" para la adquisición de señales ECG y a partir de estas conseguir la señal de variabilidad de la frecuencia cardiaca (HRV), esta refleja la actividad del sistema nervioso autónomo sobre la función cardiaca. Como cuarto método se propone la actividad eléctrica del musculo trapecio superior, este ha sido usado como musculo predictor de estrés (Maleki 2020). Para adquirir y procesar las señales EMG se desarrolló un electro miógrafo controlado desde una tarjeta Raspberry pi 3B+. Para el procesamiento de los datos se usaron algoritmos de reconocimiento de patrones implementando el software libre: Python versión 3.8 con la librería "Scikit learn" versión 0.23 (Buitinck et al. 2013). Como técnica de validación se aplicó el inventario SISCO de estrés académico que ha sido implementado en diferentes estudios que respaldan su aplicabilidad en el ámbito académico.(Carranza 2017) Se consideraron el estado de estrés del estudiante, en el que un conjunto de medidas fue adquirido durante la presentación de un examen virtual, y así mismo para el estado de no-estrés el conjunto de medidas se adquirió en un estado de relajación una vez pasada la fecha del examen.

## 2. MATERIALES Y MÉTODOS

### 2.1 Protocolo de medida y selección de los participantes:

Para investigación participaron un grupo de 25 estudiantes de la facultad de ingenierías y arquitectura de la Universidad de Pamplona, Colombia, de manera voluntaria los cuales voluntariamente accedieron a participar en el estudio. En la Tabla 1 se muestra la cantidad de muestras tomadas por cada dispositivo, la edad y el estado del estudiante.

Del grupo de estudiantes 7 fueron mujeres y 18 fueron hombres en edades comprendidas entre los 18 y 30 años, cada uno informo estar sano, no ser fumador, no tener un diagnóstico de ningún trastorno psicológico y no padecer enfermedades de base.

*Tabla 1. Información de la cantidad de muestras y etiquetado de los pacientes.*


| Etiqueta | Edad | Semestre | Muestras en estado relajado |     |     |     | Muestras en estado estresado |     |     |     |
|----------|------|----------|-----------------------------|-----|-----|-----|------------------------------|-----|-----|-----|
|          |      |          | E-nose                      | GSR | HRV | EMG | E-nose                       | GSR | HRV | EMG |
| A        | 22   | 8        | 3                           | 1   | 2   | 2   | 4                            | 1   | 2   | 2   |
| B        | 25   | 4        | 3                           | 1   | 2   | 2   | 3                            | 1   | 2   | 2   |
| C        | 19   | 5        | 3                           | 1   | 2   | 2   | 3                            | 1   | 2   | 2   |
| D        | 18   | 1        | 4                           | 1   | 2   | 2   | 4                            | 1   | 2   | 2   |
| E        | 25   | 10       | 4                           | 1   | 2   | 2   | 6                            | 1   | 2   | 2   |
| F        | 24   | 10       | 3                           | 1   | 2   | 2   | 4                            | 1   | 2   | 2   |
| G        | 23   | 9        | 4                           | 1   | 2   | 2   | 4                            | 1   | 2   | 2   |
| H        | 21   | 7        | 5                           | 1   | 2   | 2   | 4                            | 1   | 2   | 2   |
| I        | 20   | 7        | 5                           | 1   | 2   | 2   | 4                            | 1   | 2   | 2   |
| J        | 24   | 9        | 6                           | 1   | 2   | 2   | 4                            | 1   | 2   | 2   |
| K        | 27   | 10       | 3                           | 1   | 2   | 2   | 4                            | 1   | 2   | 2   |
| L        | 21   | 9        | 4                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| M        | 26   | 5        | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| N        | 24   | 7        | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| O        | 23   | 6        | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| P        | 24   | 10       | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| Q        | 23   | 10       | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| R        | 23   | 5        | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| S        | 30   | 10       | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| T        | 24   | 9        | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| U        | 23   | 10       | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| V        | 23   | 7        | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| W        | 24   | 9        | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| X        | 20   | 8        | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |
| Y        | 22   | 9        | 5                           | 1   | 2   | 2   | 5                            | 1   | 2   | 2   |

Durante la toma de las mediciones a todos los participantes se les indico evitar el consumo de

bebidas alcohólicas, medicamentos, consumir alimentos con olor (por ejemplo: ajo, cebolla) y hacer ejercicio excesivo; así como evitar la aplicación o uso de productos cosméticos, etc. Para las mediciones en estado de estrés las muestras fueron recolectadas mientras los estudiantes presentaban un examen de forma virtual; en cambio para el estado de relajación las muestras fueron recolectadas después de que el estudiante finalizara la presentación de los exámenes de cada una de las asignaturas matriculadas en el semestre académico comprendido entre los meses de Marzo - Junio 2020. Las mediciones fisiológicas fueron adquiridas en el lugar de residencia de cada estudiante, siguiendo las medidas de seguridad necesarias como el uso de overol, tapabocas y guantes desechables.

### 2.2 Respuesta galvánica de la piel.

La respuesta galvánica de la piel (GSR) es la señal obtenida a partir de la variación en la resistencia eléctrica de la piel, la cual se ve afectada por la transpiración. La sudoración está regulada por el Sistema Nervioso Autónomo (SNA), específicamente en la rama simpática (SNS), cuando esta es demasiado estimulada, la actividad de la glándula sudorípara aumenta, y a su vez aumenta la conductancia de la piel, y viceversa. Gracias a este comportamiento, la conductancia de la piel puede ser una medida de las respuestas del Sistema Nervioso Simpático (Anon n.d.). Para la adquisición de la señal GSR se ubicaron los electrodos del dispositivo en la mano no dominante del paciente sobre el dedo índice y el dedo medio como se presenta en la Fig.1, durante un tiempo de medida de 5 minutos.



*Fig. 1. Sensor GSR, a) ubicación de los electrodos, b) Tarjeta electrónica y electrodos.*

### 2.3 Sistema de olfato electrónico.

#### 2.3.1 Diseño.

Los componentes del sistema de olfato electrónico se presentan en la fig 2, en a) se muestra matriz de sensores de gases, para la medición de la señal de cada sensor se acopló una tarjeta Arduino Astar 32U4, esta cuenta con capacidad de 8 entradas analógicas y una resolución de 10 Bits. En b) se presenta la cámara de medida, esta fue construida en acero

inoxidable con un volumen muerto de 20 ml, provista de un empaque el cual proporciona hermeticidad y portabilidad.




Fig. 2. Sistema de olfato electrónico para la medición de compuestos orgánicos volátiles.

Se seleccionaron 8 sensores químico-resistivos comerciales (ver Tabla 2). Cada uno de los sensores tiene diferente sensibilidad y tipo de gas a detectar, esto con el fin de poder adquirir la mayor cantidad de información desde el espectro de los compuestos volátiles, los cuales son medidos durante el proceso de absorción y desorción de los analitos.

Tabla 2 Sensores químico-resistivos E-nose.

| Nº | Referencia del sensor | Uso específico                        |
|----|-----------------------|---------------------------------------|
| 1  | MQ2                   | Propano, Metano, Alcohol,             |
| 2  | MQ3                   | Alcohol, Bencina, CO, CH <sub>4</sub> |
| 3  | MQ4                   | Metano, Gas Natural                   |
| 4  | MQ5                   | Gas Natural, GLP                      |
| 5  | MQ9                   | CO, Gas inflamable                    |
| 6  | MQ138                 | Tolueno, Acetona, Etanol              |
| 7  | TGS825                | Sulfuro de Hidrogeno                  |
| 8  | TGS832                | Clorofluorocarbonos                   |

Se diseñó un software para visualización de la respuesta de los sensores de gas en tiempo real, así como seleccionar la ruta para almacenar las señales medidas en formato .txt, además de permitir establecer los tiempos de captura de datos y de limpieza de la cámara de medida (Ver fig. 3).




Fig. 3 Interfaz gráfica para la E-nose.

### 2.3.2 Protocolo de medida.

Para la medición de COV's el paciente entra en contacto con un embudo metálico ubicado en la frente del paciente como se muestra en la Fig 4, con ayuda de válvulas se evita o permite el paso de los COV's emitidos por el paciente y

contenidos en el embudo hacia la matriz de sensores de gas, el embudo es mantenido por el sujeto durante cinco minutos ejerciendo presión para evitar la pérdida de COV's.



Fig. 4. Ubicación del embudo para la medición de compuestos orgánicos volátiles.

Luego de 3 minutos desde la ubicación del embudo en el paciente, se activa la bomba de vacío para purgar la cámara de gases con aire ambiente. Este proceso ayuda a limpiar el circuito de las tuberías y la cámara de sensores de gas. Después de dos minutos de purgado se permite el paso de los compuestos volátiles a la cámara de medida para la adquisición de las señales durante 2 minutos. Finalizados estos dos minutos se limpia la cámara de medida con aire ambiente para expulsar los compuestos que hubieran quedado en el sistema de medición.

### 2.4 Diseño del electro miógrafo.

Al circuito de adquisición se le implementaron filtros tipo Butterworth de segundo orden con estructura de fuente de tensión controlada por tensión para adquirir la señal EMG lo más limpia posible, un filtro pasa altas de 30Hz para eliminar la componente DC inducida en la señal, un filtro pasa bajas de 450 Hz y un filtro rechaza banda de 60Hz para eliminar el ruido de red, además cuenta con fuente de alimentación simétrica que permite alimentarlo con baterías o con un adaptador entre 15-22V DC (Ver fig. 5).




Fig. 5. Vistas del PCB para EMG.

Se usaron electrodos desechables marca "LifeCare", con sensor de Ag/AgCl con gel sólido y conexión de broche, estos son electrodos hipo alérgicos, cuentan con una excelente conductividad y fuerte adhesión. Se ubicaron en el paciente según las pautas de la norma SENIAM como se muestra en la fig. 6 y se



usaron cables blindados para evitar el ruido inducido por interferencias electromagnéticas.



Fig. 6. Ubicación de los electrodos.

Para la adquisición de las señales EMG y GSR se diseñó la interfaz gráfica presentada en la fig. 7, esta permite crear la carpeta en la que se guardan los datos, seleccionar que señal se va a adquirir y visualizar la señal adquirida, así como modificar el tiempo de muestreo y duración de la medición.




Fig. 7. Interfaz gráfica para la adquisición de GSR y EMG.

## 2.5 Variabilidad de la frecuencia cardiaca (HRV).

### 2.5.1 Adquisición señal ECG.

Se implementó el módulo ADS1298 para la adquisición de la señal electrocardiográfica, este cuenta con su propio software que permite visualizar, filtrar, y guardar las señales adquiridas, así como presentar la ilustración del espectro en frecuencia de las señales adquiridas. Además, el módulo cuenta con resolución de 24 bits y frecuencia de muestreo de 500 muestras por segundo. En la fig. 8 se presenta un ejemplo de una señal medida.




Fig. 8. Señal ECG adquirida.

### 2.5.2 Extracción señal HRV.

La señal HRV ha servido como indicador de la respuesta del sistema nervioso autónomo frente a una perturbación emocional, así como enfermedades psiquiátricas, además se ha demostrado que permite predecir la respuesta autónoma del estrés emocional agudo en entornos reales (Dikecligil and Mujica-parodi 2010). Para su extracción a partir de la señal ECG

desarrolló un algoritmo en Python para determinar la distancia que hay entre los picos R apoyándose en la derivada de la señal ECG, cada distancia es guardada y en conjunto estas son las que representan la señal HRV, en la fig. 9 se presentan las gráficas de cada etapa del algoritmo, en donde a) es la señal ECG adquirida, b) es su derivada, en c) se presentan los picos R detectados y en d) se muestra la señal HRV en donde la amplitud representa el tiempo entre puntos R y el eje horizontal representa la cantidad de puntos R extraídos de la señal ECG.

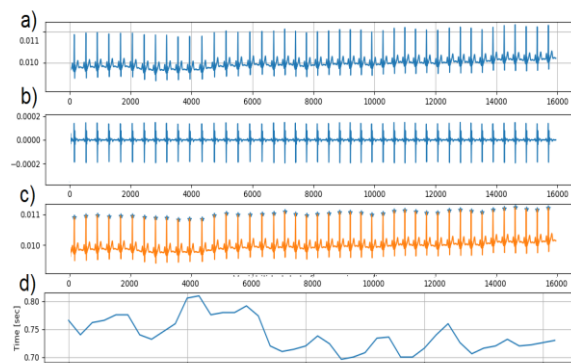


Fig. 9. Extracción de la señal HRV.

## 2.6 Métodos de procesamiento.

### 2.6.1 LDA (Análisis discriminante lineal).

Es un algoritmo estadístico apropiado para la selección de variables independientes que permiten diferenciar grupos y la cantidad de estas variables que es necesaria para conseguir la mejor clasificación posible. Además de que puede cuantificar su poder de discriminación con relación a la pertenencia de un objeto a un grupo. (Gyamfi et al. 2019)

### 2.6.2 KNN (K Nearest Neighbor).

El principio de funcionamiento de este algoritmo es que, si la mayoría de las k muestras son más similares al primer punto de consulta de la función a la que pertenece una determinada categoría, entonces la respuesta es que el punto de consulta pertenece a dicha categoría, la similitud entre las muestras se puede medir por la distancia en las características. Un conjunto de datos debe contener las etiquetas y deben indicarse al comienzo del algoritmo. (Kuang and Zhao 2009)

### 2.6.3 SVM (Support vector machine).

El algoritmo establece una superficie de decisión para dos o más clases distintas en un conjunto de datos de entrada, los datos son mapeados por medio de un kernel lineal u otro tipo de kernel a un espacio dimensional más alto en el que se

busca la máxima separación entre las clases. (Gustavo A 2005)

### 2.7 implementación del inventario SISCO.

Es un inventario conformado por 31 ítems que permiten determinar si el encuestado es candidato para contestar el inventario, además de identificar el nivel de intensidad del estrés académico y la frecuencia en que las demandas del entorno se consideran como estímulos estresores, determina la frecuencia con que se presentan reacciones a dicho estímulo e identifica la importancia del uso de estrategias de afrontamiento. (Macías 2007)

## 3. RESULTADOS

### 3.1 Respuestas con el GSR.

Las respuestas obtenidas del sensor GSR se muestran en la fig. 10, son dos medidas del mismo paciente, pero en diferentes condiciones: durante estado de relajación a) y durante estado estresado b). Como se aprecia en las figuras, la variable medida del sensor esta en voltios, ambas señales se adquirieron durante 5 minutos con una frecuencia de muestreo de 10 muestras por segundo, se aprecia una diferencia significativa entre las dos respuestas lo que permite obtener una clara clasificación de las medidas.




Fig. 10. Respuesta galvánica de la piel (GSR).

### 3.2 Procesamiento de datos con GSR.

Para estandarizar los datos del conjunto de medidas de la señal GSR adquiridas se implementó la función “StandardScaler” antes de la ejecución del algoritmo de análisis discriminante lineal. En la Fig 11(a) se muestra el gráfico de dispersión de las medidas realizado a partir de los factores resultantes del algoritmo LDA, se aprecia que el algoritmo clasifica correctamente los datos de ambas clases del conjunto de medidas. Adicionalmente se implementó el algoritmo SVM, en el cual se usaron como datos de entrenamiento y prueba los factores del LDA, el algoritmo fue implementado con kernel lineal y empleando el método de validación cruzada *k-fold* con  $k=5$ . Para conseguir una representación gráfica de la

respuesta del algoritmo, se graficó la distancia al hiperplano de cada muestra con respecto a cada medida (Ver fig. 11(b)).




Fig. 11. Respuesta gráfica algoritmos GSR.

### 3.3 Respuestas con la E-nose.

En la fig. 12 se presenta la respuesta de cada uno de los sensores de la E-nose, las señales de los sensores de gases muestran que estos responden adecuadamente a los compuestos orgánicos volátiles emitidos por la piel, la medida a) corresponde a una medición tomada a un paciente en estado de relajación y la medida b) ilustran el comportamiento de los sensores en una muestra tomada al mismo paciente durante la presentación de un examen parcial que correspondiente al estado de estrés, se muestra que la variable medida de los sensores está en voltios, con la amplitud del conjunto de señales se puede determinar el estado del paciente. Así mismo, el eje horizontal representa el tiempo de adquisición de la señal.

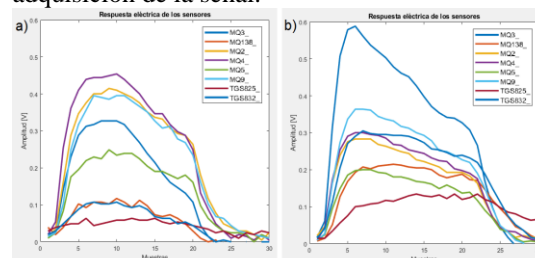


Fig. 12. Respuesta de los sensores de gas: a) muestra en estado de relajación, b) muestra en estado de estrés.

### 3.4 Procesamiento de datos con la E-nose.

Tras estandarizar los datos se implementó el algoritmo LDA al conjunto de datos de las señales medidas de todos los pacientes, donde en la Fig 13 a) se presenta la gráfica de la respuesta del PCA con puntos verdes el estado de relajación y los de color rojo representan las muestras que se tomaron en estado de estrés, en b) se muestra el gráfico 3D.

Además, se implementó el algoritmo *k* vecinos mas cercanos ajustando los parámetros:  $k=5$  y el correspondiente a distancia euclidiana. Para el entrenamiento y prueba del algoritmo se usaron los scores resultantes del algoritmo PCA. Se

consiguió la representación gráfica de la respuesta del algoritmo en la que se distingue la frontera de decisión del algoritmo (ver fig 13c.), la ejecución del algoritmo se llevó a cabo con el método de validación cruzada  $k$ -folds con  $k=5$ , consiguiendo una precisión del 90%.

Los scores resultantes del PCA se emplearon como datos de entrenamiento y prueba para el algoritmo SVM con con parámetros de kernel lineal y con el método de validación cruzada  $k$ -folds con  $k=5$ . En la fig 13(d) se muestra la gráfica de la distancia al hiperplano de cada muestra con respecto al número de muestras como se presenta en la figura. Con este modelo se consiguió una precisión del 90% en la clasificación del conjunto de datos.

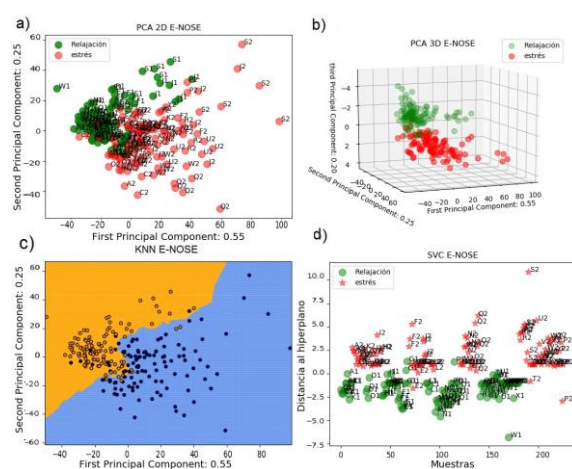


Fig. 13. Representación gráfica de los algoritmos de clasificación E-nose.

### 3.5 Respuestas con el EMG.

En la fig. 14 se presenta la señal EMG adquirida del musculo trapecio superior al ejecutar un movimiento voluntario del hombro, en a) se muestra la señal sin filtrar y con componente DC inducida, en b) se presenta la señal filtrada. Por cada estudiante se adquirieron 5 muestras, 2 en estado de relajación, 2 en estado de estrés y una realizando un movimiento voluntario.




Fig. 14. Señal EMG: a) Sin filtrar, b) señal filtrada.

### 3.6 Procesamiento de datos con EMG.

Para el procesamiento del conjunto de datos de EMG se extrajeron características de la señal

como: valor absoluto medio, cambios de signo de pendiente, varianza, log detector, cambio de amplitud promedio, diferencia de valor de varianza entre otras. Al conjunto de características se les aplicó el algoritmo LDA, la respuesta del algoritmo se presenta en la fig. 15, se implementó el algoritmo de máquinas de soporte vectorial con kernel lineal usando como datos de entrenamiento las características extraídas a cada señal y usando el método de validación cruzada  $k$ -folds con  $k=5$ , se consiguió una precisión del 90% en el conjunto de características.




Fig. 15. LDA 2D del conjunto de datos EMG.

### 3.7 Respuestas con HRV.

En la fig. 16 se presentan las señales adquiridas de: a) la señal ECG en estado de relajación con todos los picos R identificados y marcados con color azul, en b) la señal HRV extraída de a) en la que la amplitud de la señal representa el tiempo entre intervalos R, para el estado de estrés en c) se muestra la señal ECG adquirida y en d) la señal HRV extraída de la señal ECG mostrada en c), se evidencia que en estado de estrés el ritmo cardiaco aumenta provocando que la señal HRV disminuya en amplitud en comparación con la señal HRV extraída de la señal ECG medida en estado de relajación.

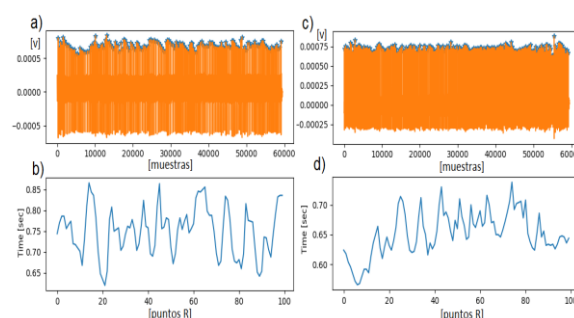


Fig. 16. Señales ECG y HRV.

### 3.8 Procesamiento de datos con HRV.

Al conjunto de datos conformado con las señales HRV extraídas de las medidas ECG se les aplicó el algoritmo SVM con parámetros de kernel lineal, el equivalente a distancia euclidiana y haciendo uso del método de validación cruzada  $k$ -folds con  $k=5$  consiguiendo una precisión del 88% en la clasificación de las medidas, en la fig.

17 se presenta la gráfica de la respuesta del algoritmo, las estrellas rojas corresponden a cada señal en estado de estrés y los puntos verdes representan las muestras en estado de relajación.




Fig. 17. Representación gráfica de la respuesta del algoritmo SVM.

### 3.9 Análisis con el método estadístico SISCO.

Según los resultados del análisis psicológico las demandas del entorno que con mayor frecuencia son percibidas como estímulos estresores en la población de estudio fueron: Evaluaciones de los profesores, temor a equivocarse en las respuestas y sobrecarga académica. Entre las estrategias de afrontamiento las más valoradas por los pacientes encuestados están: la elaboración de un plan y defender sus ideas sin dañar a otros. En la fig. 18 se muestra el porcentaje de estudiantes que según la puntuación que obtuvieron en el inventario fue identificado con un nivel de estrés de este instrumento.




Fig. 18. Nivel de estrés en la población de estudio.

## 4. RECONOCIMIENTO

Nuestra más sincera gratitud a todos los estudiantes que voluntariamente accedieron a participar en esta investigación, a la psicóloga Sandra Padilla por su asesoría en la aplicación del inventario SISCO y al grupo de investigación GISM de la Universidad de Pamplona.

## 5. CONCLUSIONES

Con los métodos implementados fue posible determinar de manera no invasiva el estado (estresado o relajado) en el que se encontraba el paciente al momento de realizar las mediciones. Por medio de las señales fisiológicas adquiridas con estos sistemas fue posible determinar el nivel de estrés en una situación y entorno real en el

que el estudiante terminaba la presentación de un examen, logrando obtener resultados que permitieron una buena discriminación y clasificación de cada conjunto de datos. Con la metodología de análisis de la E-nose se pudo detectar el estado del paciente logrando un porcentaje en la exactitud de la clasificación del 91% usando el algoritmo SVM. Aunque se obtuvieron buenos resultados, sería importante comparar el funcionamiento de la E-nose con técnicas clásicas de análisis de gases como la cromatografía de gases - espectrometría de masas con el objetivo de validar de forma adecuada el protocolo de muestreo y el método de adquisición de las medidas. A partir de las señales adquiridas de la respuesta galvánica de la piel de cada estudiante se consiguió un porcentaje de discriminación y clasificación del 100%, con la señal de variabilidad de la frecuencia cardíaca el 88% de clasificación y con el conjunto de datos de electromiografía el 90%, demostrando que este tipo de dispositivos aún sigue siendo una herramienta de gran aplicabilidad en el estudio del comportamiento psicológico de la persona. Sin embargo, es importante seguir investigando y caracterizando cada uno de las señales generadas por los sensores.

## REFERENCIAS

- Abu, Manuel R. 2020. "Psicometría Del Estrés." (March).
- Anon. n.d. "Respuesta Galvánica de La Piel (GSR) - Brainsigns." Retrieved February 17, 2020 (<https://www.brainsigns.com/es/science/s2/technologies/gsr>).
- Buitinck, Lars, Gilles Louppe, Mathieu Blondel, Olivier Grisel, Vlad Niculae, Peter Arnaud Joly, Brian Holt, and Gaël Varoquaux. 2013. "API Design for Machine Learning Software: Experiences from the Scikit-Learn Project." 1–15.
- Carranza, Lourdes del Pilar Ancajima. 2017. "Propiedades Psicométricas Del Inventario SISCO Del Estrés Académico En Universitarios de La Ciudad de Trujillo." Universidad Cesar Vallejo.
- Chen, Yingyue, Liping Zhang, Bei Zhang, and Chang'an A. Zhan. 2020. "Short-Term HRV in Young Adults for Momentary Assessment of Acute Mental Stress." *Biomedical Signal Processing and Control* 57:101746.
- Dikecligil, Gülce N. and Lilianne R. Mujica-parodi. 2010. "Ambulatory and Challenge-Associated Heart Rate Variability Measures Predict Cardiac Responses to Real-World Acute Emotional Stress." *BPS* 67(12):1185–90.
- de Groot, Jasper H. B., Monique A. M. Smeets,



- Annemarie Kaldewaij, Maarten J. A. Duijndam, and Gün R. Semin. 2012. "Chemosignals Communicate Human Emotions." *Psychological Science* 23(11):1417–24.
- Gustavo A, Betancourt. 2005. "LAS MÁQUINAS DE SOPORTE VECTORIAL (SVMs)." *Scientia et Technica* (27):67–72.
- Gyamfi, Kojo Sarfo, James Brusey, Andrew Hunt, and Elena Gaura. 2019. "A Dynamic Linear Model for Heteroscedastic LDA under Class Imbalance." *Neurocomputing* 343:65–75.
- Hsieh, Yun Chun and Da Jeng Yao. 2018. "Intelligent Gas-Sensing Systems and Their Applications." *Journal of Micromechanics and Microengineering* 28(9).
- Huckins, Jeremy F., Alex W. daSilva, Weichen Wang, Elin Hedlund, Courtney Rogers,... 2020. "Mental Health and Behavior of College Students During the Early Phases of the COVID-19 Pandemic: Longitudinal Smartphone and Ecological Momentary Assessment Study." *Journal of Medical Internet Research* 22(6):e20185.
- Imperatori, Claudio, Francesco Saverio Bersani, Greta Cicerale, Alberto Carrara, and Benedetto Farina. 2020. "Neurophysiological Correlates of Religious Coping to Stress: A Preliminary EEG Power Spectra Investigation." *Neuroscience Letters* 728(March):134956.
- Kuang, Quansheng and Lei Zhao. 2009. "A Practical GPU Based KNN Algorithm." *International Symposium on Computer Science and Computational Technology (ISCST)* 7(3):151–55.
- Liu, Yun and Siqing Du. 2018. "Psychological Stress Level Detection Based on Electrodermal Activity." *Behavioural Brain Research* 341(November 2017):50–53.
- Machado-Moreira, Christiano A. and Nigel A. S. Taylor. 2012. "Psychological Sweating from Glabrous and Nonglabrous Skin Surfaces under Thermoneutral Conditions." *Psychophysiology* 49(3):369–74.
- Machado Fernández, José Raúl and Lesya Anishchenko. 2018. "Mental Stress Detection Using Bioradar Respiratory Signals." *Biomedical Signal Processing and Control* 43:244–49.
- Macías, Arturo Barrazas. 2007. "El Inventario SISCO Del Estrés Académico." *Investigación Educativa Duranguense* (7):89–93.
- Martin, H. J., M. A. Turner, S. Bandelow, L. Edwards, Svetlana Riazanskaia, and C. L. P. Thomas. 2016. "Volatile Organic Compound Markers of Psychological Stress in Skin: A Pilot Study." *Journal of Breath Research* 10(4):46012.
- Mendoza, Leticia, Eva Cabrera Ortega, Dinorah González Quevedo, Rubí Martínez and Rosalinda Saucedo Hernández. 2007. "El Estrés Académico Incidencia Del Sistema de Enseñanza y Función Moduladora de Las Variables Psicosociales En La Salud, El Bienestar y El Rendimiento de Los Estudiantes Universitarios." *Revista de Enfermería. Vol. 4.*
- Pourmohammadi, Sara and Ali Maleki. 2020. "Stress Detection Using ECG and EMG Signals: A Comprehensive Study." *Computer Methods and Programs in Biomedicine* 193.
- Rodríguez-Arce, Jorge, Liliana Lara-Flores, Otniel Portillo-Rodríguez, and Rigoberto Martínez-Méndez. 2020. "Towards an Anxiety and Stress Recognition System for Academic Environments Based on Physiological Features." *Computer Methods and Programs in Biomedicine* 190.
- Sahu, Pradeep. 2020. "Closure of Universities Due to Coronavirus Disease 2019 (COVID-19): Impact on Education and Mental Health of Students and Academic Staff." *Cureus* 2019(4):4–9.
- Schneiderman, Neil, Gail Ironson, and Scott D. Siegel. 2005. "Stress and Health: Psychological, Behavioral, and Biological Determinants." *Annual Review of Clinical Psychology* 1(1):607–28.
- Sethi, Shneh, Ranjan Nanda, and Trinad Chakraborty. 2013. "Clinical Application of Volatile Organic Compound Analysis for Detecting Infectious Diseases." *Clinical Microbiology Reviews* 26(3):462–75.
- Sriramprakash, S., Vadana D. Prasanna, and O. V. Raman. Murthy. 2017. "Stress Detection in Working People." *Procedia Computer Science* 115:359–66.
- Torres-Salomao, L. A., M. Mahfouf, and Emad El-Samahy. 2015. "Pupil Diameter Size Marker for Incremental Mental Stress Detection." *2015 17th International Conference on E-Health Networking, Application and Services, HealthCom 2015* 286–91.
- Zamkah, Abdulaziz, Terence Hui, Simon Andrews, Nilanjan Dey, Fuqian Shi, and R. Simon Sherratt. 2020. "Identification of Suitable Biomarkers for Stress and Emotion Detection for Future Personal Affective Wearable Sensors." *Biosensors* 10(4).