

ESTUDIO COMPARATIVO DE CLASIFICADORES PARA EL RECONOCIMIENTO DE EXPRESIONES FACIALES

A COMPARATIVE STUDY OF CLASSIFIERS FOR FACIAL EXPRESSION RECOGNITION

Julieta Domínguez Soberanes

Universidad Panamericana Aguascalientes, México
jdominguez@up.edu.mx

Víctor Manuel Álvarez Pato

Universidad Panamericana Aguascalientes, México
valvarez@up.edu.mx

Claudia Nallely Sánchez Gómez

Universidad Panamericana Aguascalientes, México
cnsanchez@up.edu.mx

José Sebastián Gutiérrez Calderón

Universidad Panamericana Aguascalientes, México
jsgutierrez@up.edu.mx

Ramiro Velázquez Guerrero

Universidad Panamericana Aguascalientes, México
rvelazquez@up.edu.mx

Recepción: 21/octubre/2019

Aceptación: 23/noviembre/2019

Resumen

De acuerdo con el Sistema de Codificación de Acciones Faciales (FACS) de Paul Ekman, las expresiones faciales se originan por la activación de distintos conjuntos de músculos del rostro. En la última década, se han reportado numerosos estudios que intentan reconocer automáticamente emociones en el rostro a partir de expresiones faciales. Sin embargo, para lograr una precisión aceptable, los algoritmos propuestos necesitan entrenamiento específico y en la mayoría de los casos, su ejecución computacional llega a requerir mucho tiempo. En este trabajo presentamos un algoritmo para clasificar expresiones faciales en alguna de las ocho categorías básicas de Paul Ekman: enojo, desprecio, disgusto, miedo, alegría, tristeza, sorpresa y neutral. Utilizando la base de datos de Cohn-Kanade, se han elaborado algoritmos de detección y alineamiento facial mismos que permiten

obtener 68 conjuntos de coordenadas correspondientes a puntos específicos del rostro. Dichas coordenadas se han alimentado a distintos clasificadores con el objetivo de comparar su desempeño. Los resultados indican que el clasificador con mejor desempeño es el Perceptrón Multicapa con una precisión del 89%.

Palabras Claves: Clasificadores, detección de puntos de interés, perceptrón multicapa, reconocimiento de expresiones faciales, técnicas de aprendizaje supervisado.

Abstract

According to Paul Ekman's Facial Action Coding System (FACS), facial expressions can be reduced to sets of movements of different facial muscles. During the last decade, a number of studies have attempted to recognize automatically emotions from facial expressions. However, in order to achieve an acceptable precision, the proposed algorithms need specific training and are computationally burdensome. In this paper, we propose an algorithm to classify facial expressions in one of the eight basic categories of Paul Elkman: anger, sadness, happiness, contempt, disgust, surprise, fear and neutral. Using the Cohn-Kanade dataset, we have elaborated face detection and alignment algorithms that allow obtaining a set of 68 face landmarks. Such landmarks are then used to train and test different classifiers. After comparing the results, the multilayer perceptron approach exhibited the best average accuracy (89%).

Keywords: *classifiers, detection of interest points, facial expression recognition, multilayer perceptron, supervised learning.*

1. Introducción

En la última década, se ha presenciado un creciente interés por mejorar aspectos de la interacción entre humanos y computadoras. Se argumenta que las expresiones faciales desempeñan un papel esencial en las interacciones sociales humanas pues forman parte importante de nuestra comunicación emocional. Es tal el impacto de las expresiones faciales en la comunicación presencial (cara a cara) que se estima que éstas constituyen el 55% del efecto que tiene un mensaje

mientras que el tono de voz y el lenguaje constituyen el 38% y 7%, respectivamente [Mehrabian, 1968].

Las expresiones faciales son universales y guardan poca relación con las diferencias interculturales. A principios de los 70s, el psicólogo Paul Ekman desarrolló el FACS (Sistema de Codificación de Acciones Faciales por sus siglas en inglés), el cual permite interpretar las emociones de una persona a partir de sus expresiones faciales, descritas como una combinación de movimientos musculares aislados conocidos como AUs (Action Units o unidades de acción) [Donato, 1999]. Por ejemplo, una característica común en un rostro que expresa felicidad es la sonrisa, misma que resulta de la activación del músculo zigomático mayor, clasificado por FACS como AU 12.

Usando el sistema FACS de Ekman, es posible diseñar sistemas de reconocimiento automático de expresiones faciales (RAEF). El RAEF es un tema que ha cobrado interés entre investigadores en el área de visión por computadora pues sus campos de aplicación abarcan el e-learning [Krithika, 2016], la seguridad [Butalia, 2012], el diagnóstico de desórdenes psiquiátricos [Hamm, 2011], las preferencias de consumidores [Álvarez, 2018a] y la detección de fatiga en operadores [Zhang, 2011], por citar algunos ejemplos.

Un sistema de RAEF se compone básicamente de 5 módulos (figura 1). Una etapa de pre-procesamiento de imágenes donde generalmente se remueve ruido, se realiza los detalles y se adecua la iluminación. Una segunda etapa es la detección de la presencia de un rostro para en una tercera etapa detectar los componentes faciales principales (nariz, ojos, boca, cejas, etc.). En una cuarta etapa se extraen características de los componentes faciales. Las técnicas más populares para este propósito han sido los filtros de Gabor [Abhishree, 2015], Patrones Binarios Locales (LBP) [Ahonen, 2004], Análisis de Componentes Principales (PCA) [Paul, 2012], Análisis de Componentes Independientes (ICA) [Bartlett, 2002] y Gradientes Locales [Tong, 2014]. Una revisión detallada de los aspectos técnicos de estos métodos de extracción de características puede encontrarse en [Pissaloux, 2013]. La quinta etapa de clasificación ordena las características extraídas en la etapa previa para determinar finalmente la expresión facial. Algunos métodos de

clasificación que han obtenido buenos resultados son las redes neuronales [Kar, 2017], Máquinas de Soporte Vectorial (SVM) [Tsai, 2017], Redes Bayesianas [Nefian, 2002], filtros Gaussianos [Wang, 2012] y Modelos Ocultos de Markov (HMM) [Corcoran, 2011]. Un resumen de los detalles técnicos de los clasificadores mencionados puede encontrarse en [Sánchez, 2017].

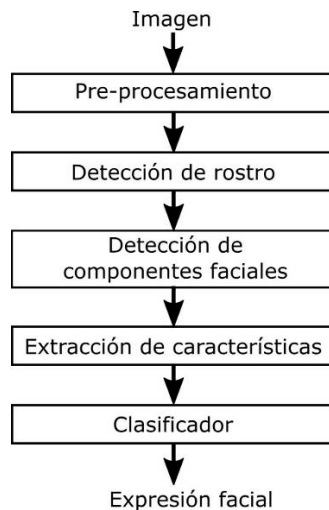


Figura 1 Diagrama de bloques de un sistema RAEF.

Este artículo se concentra precisamente en la quinta etapa del sistema RAEF presentando un estudio comparativo de los desempeños de distintos clasificadores y complementa nuestra investigación de las cuatro etapas previas ya reportadas en [Álvarez, 2018b]. El estudio comparativo contempla los clasificadores: Redes Bayesianas Simples (naive Bayes), Máquina de Soporte Vectorial (SVG), Árbol de Decisiones, Bosque Aleatorio (Random Forest), AdaBoost y el Perceptrón Multicapa.

2. Métodos

Para comparar el desempeño de los distintos clasificadores, se seleccionó la base de datos de Cohn-Kanade [Lucey, 2010], debido a que contiene imágenes de caras etiquetadas de acuerdo a las emociones básicas propuestas por Ekman. De izquierda a derecha: neutral, alegría, sorpresa, enojo, miedo, disgusto y tristeza (figura 2).




Figura 2 Ejemplo de expresiones faciales de la base de datos Cohn-Kanade.

Para cada imagen del conjunto, se aplicó un procedimiento de detección de rostros basado en el Histograma de Gradientes Orientados (HOG) y un algoritmo para detección de puntos de interés, concretamente, el de alineación facial con árboles de regresión [Kazemi, 2014], que devuelve las coordenadas de 68 puntos de interés para cada rostro. Ambos fueron implementados en Dlib, una librería de código abierto para C++ [King, 2009]. Después de someterse a un proceso de normalización para escala y rotación, estos conjuntos de coordenadas se utilizaron como entradas para entrenar y probar distintos algoritmos de clasificación:

- Redes Bayesianas Simples.
- Máquina de Soporte Vectorial.
- Árbol de Decisiones.
- Bosque Aleatorio, AdaBoost.
- Perceptrón Multicapa.

La tabla 1 resume ventajas y limitaciones de los clasificadores. Posteriormente se replicó el proceso, pero con un conjunto de entradas ligeramente distintas; en lugar de utilizar las coordenadas de cada punto de interés. Se sustrajeron las coordenadas correspondientes a un rostro etiquetado como neutral de coordenadas asociadas a los rostros con otras emociones. Por ejemplo, en figura 3 se muestra un individuo con emociones de alegría y neutral, así como la diferencia entre sus coordenadas. Para pruebas, se utilizaron las implementaciones de las técnicas de clasificación de la librería scikit-learn de Python [Pedregosa, 2011] con los parámetros originales. Para la Máquina de Soporte Vectorial se utilizó un kernel Gaussiano con valor de $C=1.0$. Para el Bosque Aleatorio se utilizaron 10 árboles de decisión tomando a Gini como medida de impureza y la entropía como ganancia de información. Para AdaBoost se utilizaron 50 árboles de decisión como clasificadores base.

Tabla 1 Características de los clasificadores considerados.

Redes Bayesianas Simples	Ventajas	<ul style="list-style-type: none"> • Generalmente, son fáciles de construir y de entender. • Las inducciones de estos clasificadores son rápidas, requiriendo normalmente solo un paso para hacerlo. • Es muy robusto considerando atributos irrelevantes. • Toma evidencia de muchos atributos para la predicción final.
	Desventajas	<ul style="list-style-type: none"> • Si dos variables están relacionadas de forma poco evidente, existe una dependencia entre ellas y puede que el modelo no tenga esta relación en cuenta. • En un sistema con un gran número de variables, puede ser difícil asegurar su consistencia. • Presenta numerosas fuentes de error; por ejemplo en la discretización de variables, ruido, valores perdidos en la base de datos, etc.
Máquinas de Soporte Vectorial	Ventajas	<ul style="list-style-type: none"> • El entrenamiento es fácil. • No hay óptimo local, como en las redes neuronales. • Se escalan relativamente bien para datos en espacios dimensionales altos. • El compromiso entre la complejidad del clasificador y el error puede ser controlado explícitamente.
	Desventajas	<ul style="list-style-type: none"> • Se necesita una buena función kernel, es decir, se necesitan metodologías eficientes para sintonizar los parámetros de inicialización de la máquina de soporte vectorial.
Árboles de decisión	Ventajas	<ul style="list-style-type: none"> • Fácil de entender e interpretar. • Requiere poca preparación de los datos. • Robusto: Se desempeña bien incluso si sus suposiciones se demuestran no siempre verdaderas. • Funciona bien con grandes conjuntos de datos.
	Desventajas	<ul style="list-style-type: none"> • Toma de decisiones locales, la decisión no es necesariamente globalmente óptima • El árbol puede no generalizar bien los datos de entrenamiento. • Presenta conceptos difíciles de aprender y necesita de otros algoritmos de aprendizaje como la programación lógica inductiva.
Bosque Aleatorio	Ventajas	<ul style="list-style-type: none"> • Existen muy pocas suposiciones y por lo tanto la preparación de los datos es mínima. • Puede manejar hasta miles de variables de entrada e identificar las más significativas. Método de reducción de dimensionalidad. • Una de las salidas del modelo es la importancia de variables. • Incorpora métodos efectivos para estimar valores faltantes.
	Desventajas	<ul style="list-style-type: none"> • Pérdida de interpretación. • Bueno para clasificación, no tanto para regresión. Las predicciones no son de naturaleza continua. • En regresión, no puede predecir más allá del rango de valores del conjunto de entrenamiento. • Poco control en lo que hace el modelo (modelo caja negra para modeladores estadísticos)
AdaBoost	Ventajas	<ul style="list-style-type: none"> • Simple de implementar. • Desarrolla la selección de características resultando en un clasificador simple. • Generalización aceptable
	Desventajas	<ul style="list-style-type: none"> • Solución sub-óptima • Sensible a datos ruidosos y valores atípicos.
Perceptrón multicapa	Ventajas	<ul style="list-style-type: none"> • Generalización. Al ser una red neuronal, el perceptrón multicapa es capaz de generalización, es decir, de clasificar parámetros desconocidos dentro de parámetros conocidos. Entradas ruidosas o incompletas serán clasificadas. • Tolerante a fallos: Las redes neuronales continúan trabajando aun en la presencia de fallos. El aprendizaje después de un fallo es rápido
	Desventajas	<ul style="list-style-type: none"> • No extrapola bien, es decir, si la red se entrena mal o de manera insuficiente, las salidas pueden ser imprecisas. • La existencia de mínimos locales en la función de error dificulta considerablemente el entrenamiento. • No hay garantía en los resultados.




Figura 3 Localización de puntos de interés en dos expresiones del mismo individuo.

La base de datos de Cohn-Kanade no contiene imágenes explícitamente etiquetadas como neutrales, pero dado que están agrupadas como secuencias de imágenes que van desde una expresión neutral a un pico de expresión de otras emociones, se tomó la primera imagen de cada grupo y se obtuvieron 380 expresiones neutrales, 57 de las cuales fueron elegidas arbitrariamente para entrenar los clasificadores con una etiqueta adicional llamada “neutral” y de las demás, una por cada persona incluida en la base de datos se utilizó como referencia para la sustracción de coordenadas. Después se aplicó el mismo grupo de clasificadores a los 68 pares de restas por rostro y se obtuvieron mejores resultados para casi todos ellos. De nuevo, el Perceptrón Multicapa obtuvo la mejor puntuación. A partir de estos resultados, se utilizó Matlab para entrenar una red neuronal [Santillana, 2010] con distintas configuraciones y se obtuvo el mejor desempeño con una red de una sola capa oculta y 10 neuronas.

Se utilizaron dos procesos para analizar los datos:

- Las coordenadas de los 68 puntos (figura 3).
- Las distancias entre dichos puntos y los correspondientes a una imagen de la misma persona, pero con una expresión neutral.

3. Resultados

Las imágenes utilizadas se tomaron de [Lucey, 2010]. El conjunto de datos se compone de 380 imágenes, de las cuales 45, 18, 59, 25, 69, 28, 83 y 53 de ellas

corresponden a las expresiones de enojo, desprecio, disgusto, miedo, alegría, tristeza, sorpresa y neutral, respectivamente. Se utilizaron varias técnicas de aprendizaje supervisado para identificar cuál aportaba los mejores resultados. Se realizaron 100 experimentos escogiendo de forma aleatoria las imágenes para cada uno de ellos, el 70% de las 380 imágenes para entrenamiento de los algoritmos y 30% para verificación de los mismos, de manera que se lograra una aleatoriedad acorde a los clasificadores. Los resultados que se muestran son el promedio de los datos obtenidos en los 100 experimentos.

Para medir el desempeño de un clasificador se utiliza comúnmente la precisión y la razón de error balanceado (BER). La precisión indica cuántas de las imágenes han sido clasificadas correctamente y se define en la ecuación 1.

$$Precision(y, \hat{y}) = \frac{100}{n} \sum_{i=1}^n \delta(y_i == \hat{y}_i) \quad (1)$$

Donde y , \hat{y} son las etiquetas reales y las obtenidas para el conjunto de prueba, respectivamente; n es el número de muestras en el conjunto y δ es una función cuyo valor es 1 si el parámetro es verdadero y 0 en caso contrario.

Por su parte, BER proporciona el promedio de error en clasificación por clase y ayuda a analizar el error aun cuando los datos no están balanceados. BER se define en la ecuación 2.

$$ER(y, \hat{y}) = \frac{100}{n_c} \sum_{k=1}^{n_c} \frac{fn_k}{n_k} \quad (2)$$

Donde y , \hat{y} tienen el mismo significado que en la ecuación (1), n_c es el número de clases, fn_k es el número de falsos negativos para la clase k y n_k es el número de muestras en el conjunto de la clase k .

La tabla 2 presenta la comparación entre distintos clasificadores junto con sus medidas de precisión y BER. Note que el Perceptrón Multicapa alimentado con las restas de coordenadas obtuvo los mejores resultados.

Mientras mayor sea el porcentaje que aparece en la diagonal de la matriz, mejor es el clasificador. En este caso puede verse que la clasificación es aceptable. Sin embargo, los mejores resultados corresponden a las expresiones de disgusto,

alegría, sorpresa y neutral. Los valores más grandes fuera de la diagonal (0.35 y 0.27) indican que las expresiones: neutral, tristeza y desprecio se confunden entre ellas con facilidad.

Tabla 2 Resultados de la clasificación de expresiones faciales.

Clasificador	68 puntos		Distancias	
	Precisión	BER	Precisión	BER
Redes Bayesianas Simples	52.13	54.79	82.05	22.53
SVM	58.97	57.86	38.46	75.50
Árbol de Decisiones	52.99	57.56	76.92	30.09
Bosque Aleatorio	59.83	52.52	82.05	23.66
AdaBoost	36.75	76.42	38.46	73.72
Perceptrón Multicapa	67.52	46.74	88.03	17.99

La tabla 3 muestra la matriz de confusión entre las distintas expresiones utilizando el Perceptrón Multicapa y las restas de coordenadas. Cada línea de la matriz representa las etiquetas asignadas a las imágenes de prueba, mientras que las columnas representan el porcentaje (en un rango entre 0 y 1) de las imágenes que fueron marcadas con la etiqueta correspondiente a la columna.

Tabla 3 Matriz de confusión – Perceptrón Multicapa.

	Enojo	Desprecio	Disgusto	Miedo	Alegría	Tristeza	Sorpresa	Neutral
Enojo	0.87	0.02	0.04	0.01	0.00	0.03	0.00	0.04
Desprecio	0.00	0.73	0.00	0.03	0.00	0.03	0.00	0.06
Disgusto	0.03	0.00	0.97	0.00	0.00	0.00	0.00	0.00
Miedo	0.01	0.01	0.00	0.84	0.02	0.02	0.00	0.02
Alegría	0.00	0.00	0.00	0.01	1.00	0.00	0.00	0.00
Tristeza	0.04	0.03	0.00	0.01	0.00	0.78	0.00	0.07
Sorpresa	0.00	0.04	0.00	0.01	0.00	0.02	0.98	0.00
Neutral	0.01	0.01	0.00	0.00	0.00	0.05	0.00	0.96

El Perceptrón Multicapa ha sido exitosamente integrado a nuestro sistema RAEF [Álvarez, 2018a]. Algunos de los resultados se muestran en la figura 4, donde se observan cuatro diferentes emociones: a) neutral, b) miedo, c) disgusto y d) alegría.

4. Discusión

Otros algoritmos de clasificación de expresiones no requieren partir de una imagen base considerada como neutral. Esto puede resultar una desventaja en la

mayor parte de las circunstancias en las que comúnmente se busca aplicar el análisis facial, sin embargo, en un ambiente controlado como en el que se planea aplicar el algoritmo (un laboratorio), no resulta complicado obtener la imagen neutral, mientras que esta técnica ofrece una mayor facilidad de clasificación.

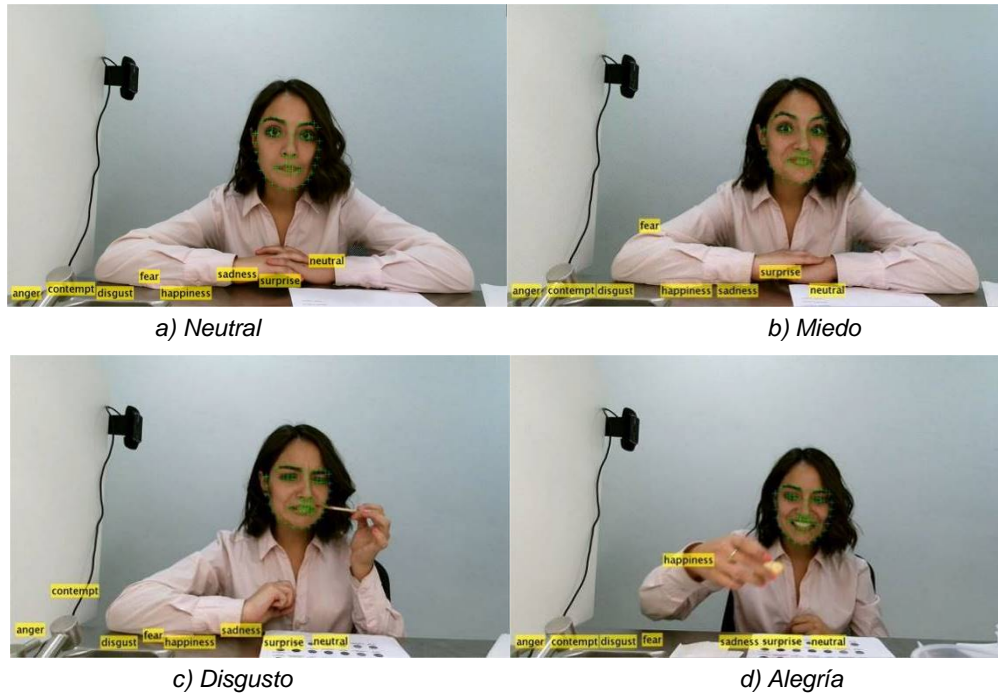


Figura 4 Resultados del clasificador Perceptrón Multicapa en el sistema RAEF.

Algunos problemas de clasificación fueron obviados al utilizar conjuntos de puntos de interés como entrada para los algoritmos, ya que analizar imágenes completas requiere más tiempo de procesamiento. Sin embargo, el ignorar características particulares de cada rostro (mismas que aprovechan otros algoritmos) puede dejar de lado información relevante para las expresiones faciales: líneas, arrugas, cambios de color, etc.

5. Conclusiones

La utilización de puntos de interés para clasificar expresiones faciales tiene el potencial de arrojar buenos resultados. Sustraer a cada expresión las coordenadas de la referencia neutral mejora considerablemente los resultados.

Una vez que las imágenes han sido pre-procesadas, es posible emplear varios clasificadores distintos para agruparlas. Las expresiones más fáciles de reconocer son: disgusto, alegría, sorpresa y neutral. Sin embargo, desprecio y tristeza se confunden fácilmente con neutral.

El algoritmo seleccionado funciona bien con vistas frontales de rostros, pero el reconocimiento de emociones falla con facilidad cuando las caras cambian de posición. Como perspectivas de trabajo futuro se planea abordar este tema.

6. Bibliografía y Referencias

- [1] Abhishree, T.M., Latha, J., Manikantan, K. & Ramachandran, S. Face recognition using Gabor filter based feature extraction with anisotropic diffusion as a pre-processing technique, *Procedia Computer Science*, Vol. 45, 312-321, 2015.
- [2] Ahonen, T., Hadid, A. & Pietikäinen M. Face recognition with Local Binary Patterns. In: Pajdla T., Matas J. (eds), *Lecture Notes in Computer Science*, Vol. 3021, Springer, Berlin, Heidelberg, 2004.
- [3] Álvarez, V.M., Domínguez-Soberanes, J., Sánchez, C., Gutiérrez, S., López, B., Quiroz, R., Mendoza, D., Buendía, H. & Velázquez, R. Consumer acceptances through facial expressions of encapsulated flavors based on a nanotechnology approach, 2018 *Nanotechnology for Instrumentation and Measurement (NANOIM)*, Mexico City, Mexico, 2018, pp. 1-5.
- [4] Álvarez, V.M., Velázquez, R., Gutiérrez, S. & Enríquez-Zarate, J. A method for facial emotion recognition based on interest points, 2018 *International Conference on Research in Intelligent and Computing in Engineering (RICE)*, San Salvador, 2018, pp. 1-4.
- [5] Bartlett, M.S., Movellan, J.R. & Sejnowski, T.J. Face recognition by independent component analysis. *IEEE Transactions on Neural Networks*, Vol. 13, 1450-1464, 2012.
- [6] Butalia, M.A., Ingle, M. & Kulkarni, P. Facial expression recognition for security. *International Journal of Modern Engineering Research*, No. 2, 1449-1453, 2012.

- [7] Corcoran, P. & Iancu, C. Hidden Markov Models in automatic face recognition - A review, *Reviews, Refinements and New Ideas in Face Recognition*, IntechOpen, 2011.
- [8] Donato, G., Bartlett, M.S., Hager, J.C., Ekman, P. & Sejnowski, T.J. Classifying facial actions, *Transactions on Pattern Analysis and Machine Intelligence*, Vol. 21, No. 10, 974–989, 1999.
- [9] Hamm, J., Kohler, C.G., Gur, R.C. & Verma, R. Automated Facial Action Coding System for dynamic analysis of facial expressions in neuropsychiatric disorders, *Journal of Neuroscience Methods*, 237-256, 2011.
- [10] Kar, N.B., Babu, K.S. & Jena, S.K. Face expression recognition using histograms of oriented gradients with reduced features, *Advances in Intelligent Systems and Computing*, Vol. 460, 209-219, 2017.
- [11] Kazemi, V. & Sullivan, J. One millisecond face alignment with an ensemble of regression trees, *IEEE Conference on Computer Vision and Pattern Recognition*, Columbus, Ohio, 1867-1874, 2014.
- [12] King, D.E. Dlib-ml: A Machine Learning Toolkit, *Journal of Machine Learning Research*, vol. 10, 1755-1758, 2009.
- [13] Krithika, L.B. & Lakshmi, P.G., Student Emotion Recognition System (SERS) for e-learning Improvement based on learner concentration metric, *Procedia Computer Science*, 85, pp. 767-776, 2016.
- [14] Lucey, P., Cohn, J. F., Kanade, T., Saragih, J., Ambadar, Z. & Matthews, I. The Extended Cohn-Kanade Dataset (CK+): A complete dataset for action unit and emotion-specified expression, *IEEE Computer Society Conference on Computer Vision and Pattern Recognition - Workshops*, San Francisco, 94-101, 2010.
- [15] Mehrabian, A. Communication without words. *Psychology Today*, Vol. 2, No. 4, 53-56, 1968.
- [16] Pissaloux, E., Maybank, S. & Velázquez, R. On Image Matching and Feature Tracking for Embedded Systems: A State of the Art. In: A. Chatterjee, H. Nobahari & P. Siarry (Eds.), *Advances in Heuristic Signal Processing and Applications*, Springer-Verlag (Berlin-Heidelberg), 2013, pp. 357-380.

- [17] Paul, L.C. & Sumam, A.A. Face recognition using Principal Component Analysis Method, *International Journal of Advanced Research in Computer Engineering & Technology*, Vol. 1, No. 9, 135-139, 2012.
- [18] Nefian, A.V. Embedded Bayesian networks for face recognition, *IEEE International Conference on Multimedia and Expo*, 133-136, 2002.
- [19] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O. & Vanderplas, J. Scikit-learn: Machine learning in Python. *Journal of machine learning research*, 2011.
- [20] Sánchez, C., Rivera, M. & Velázquez, R. Robust multiband image segmentation method based on user clues, *2017 IEEE 37th Central America and Panama Convention (CONCAPAN XXXVII)*, Managua, 2017, pp. 1-6.
- [21] Santillana, A., Delgado-Mata, C., & Velázquez, R., Training a single-layer perceptron for an approximate edge detection on a digital image, *2011 International Conference on Technologies and Applications of Artificial Intelligence*, Taiwan, pp. 189-193, 2011.
- [22] Tong, Y., Chen, R. & Cheng, Y. Facial expression recognition algorithm using lgc based on horizontal and diagonal prior principle. *Optik-International Journal for Light and Electron Optics* Vol. 125, 4186-4189, 2014.
- [23] Tsai, H.H. & Chang, Y.C. Facial expression recognition using a combination of multiple facial features and support vector machine, *Soft Computing*, 1-17, 2017.
- [24] Wang, S., Li, W., Wang, Y., Jiang, Y., Jiang, S. & Zhao, R. An improved difference of gaussian filter in face recognition, *Journal of Multimedia*, 6, 429-433, 2012.
- [25] Zhang, Z. & Zhang, J. A new real-time eye tracking for driver fatigue detection. *ITS Telecommunications Proceedings*, 8-11, 2011.