

Reconocimiento de Gestos de la Mano en Tiempo Real Usando Leap Motion Controller y Machine Learning

CReal-Time Hand Gesture Recognition Using the Leap Motion Controller and Machine Learning

Nogales Rubén Jhon

Escuela Politécnica Nacional / ruben.nogales@epn.edu.ec
Universidad Técnica de Ambato / re.nogales@uta.edu.ec

Quito - Ecuador
Ambato - Ecuador

Benalcázar Marco

Escuela Politécnica Nacional / marco.benalcazar@epn.edu.ec
Quito - Ecuador

Versión electrónica

<https://investigacion.utmachala.edu.ec/proceedings/index.php/utmach/issue/view/3>

RESUMEN

Actualmente, el reconocimiento de gestos se presenta como un problema de extracción de características y reconocimiento de patrones, en el cual se etiqueta un movimiento como perteneciente a una clase determinada. La respuesta de un sistema de reconocimiento de gestos puede aplicarse a diferentes problemas en diferentes campos, como la medicina, la docencia, la robótica, etc. Existen diferentes modelos propuestos en la literatura científica que intentan resolver el problema del reconocimiento del gesto de la mano. Estos trabajos no satisfacen la demanda de procesamiento en tiempo real y alta precisión de reconocimiento, simultáneamente. En este contexto, el presente trabajo propone desarrollar un nuevo modelo para el reconocimiento de gestos con la mano utilizando información infrarroja, adquirida con el Leap Motion Controller, y también utilizando técnicas de aprendizaje automático. El modelo propuesto pretende reconocer 5 gestos estáticos y 4 dinámicos de la mano en tiempo real y con gran precisión, de forma simultánea. La metodología que se utilizará para desarrollar este trabajo se compone de dos fases: el entrenamiento y la prueba: en la primera fase, diseñaremos, clasificaremos, validaremos preliminarmente y sintonizaremos el modelo propuesto. En la segunda fase, probaremos el modelo propuesto estimando su precisión de reconocimiento y el tiempo de procesamiento.

Palabras clave: Reconocimiento de gestos, aprendizaje de máquina automático, leap motion controller.

ABSTRACT

Currently, gesture recognition is presented as a problem of feature extraction and pattern recognition, in which we label a movement as belonging to a given class. The response of a gesture recognition system can be applied for different problems in different fields, such as medicine, teaching, robotics etc. There are different models proposed in the scientific literature that try to solve the problem of hand gesture recognition. These works do not meet the demand for real-time processing and high recognition accuracy, simultaneously. In this context, the present work proposes to develop a new model for the recognition of hand gestures using infrared information, acquired with the Leap Motion Controller, and also using machine learning techniques. The proposed model is intended to recognize 5 static and 4 dynamic gestures of the hand in real time and with high accuracy, simultaneously. The methodology that will be used for developing this work is composed of two phases, the training and testing: In the first phase, we will design, classify, preliminary validation and tune the proposed model. In the second phase, we will test the proposed model by estimating its accuracy of recognition and time of processing.

Keywords: Gesture recognition, machine learning, leap motion controller:

Introducción

Los gestos son considerados como una expresión natural del cuerpo humano para comunicarse con otros seres humanos. (Chaudhary, n.d.; Mcintosh & Group, 2017) En este sentido, un gesto de la mano es considerado como un movimiento de la mano que pretende expresar alguna información. Hay dos categorías de gestos que pueden ser determinadas:

Gestos estáticos.- Consiste en una posición bien definida de la mano en un momento dado.
Gestos dinámicos.- Es una secuencia de movimientos en un lapso de tiempo.

En este contexto, el reconocimiento de los gestos de la mano no es un problema trivial, este consiste en determinar un gesto de salida de un conjunto de gestos predefinidos, además, consiste en determinar el instante de tiempo cuando el gesto fue ejecutado. (Benalcázar, Motoche, Zea, Member, Andrés, et al., 2017).

El resultado de un sistema de reconocimiento de gestos es ampliamente utilizado en campos como: la comunicación por medio del lenguaje en señas, (Das, Jakulin, & Nigel, 2016; Zhou Ren, Jingjing Meng, & Junsong Yuan, 2011) la interacción humano-máquina (Dominio, Donadeo, Marin, Zanuttigh, & Cortelazzo, 2013; Zhou Ren et al., 2011), la interacción humano-máquina, realidad virtual entre otros. Mediante la revisión de la literatura científica, se puede determinar que para el reconocimiento y clasificación de gestos de la mano, existen varios modelos que clasifican gestos estáticos y dinámicos. La arquitectura de estos modelos esta basada en la adquisición de información infrarroja, imágenes de profundidad e imágenes a color RGB (Czuszynski, Ruminski, & Wtorek, 2017; Dominio et al., 2013; Dqj et al., 2014; Jais, Mahayuddin, & Arshad, 2015; Jangyodsuk, Conly, & Athitsos, 2014; Park, Ryu, Chang, & Park, 2014).

En este sentido, el reconocimieto de los gestos de la mano en tiempo real es un problema desafiante para los investigadores (Doan, Vu, & Tran, 2015; Dqj et al., 2014; Lu, Tong, & Chu, 2016; Plouffe & Cretu, 2016) debido a las limitaciones de hardware y tiempo de procesamiento. Para que un sistema de clasificación sea considerado que trabaja en tiempo real, debería devolver una respuesta en menos de 300 ms después de que finalice la ejecución del gesto (Benalcázar, Motoche, Zea, Member, & Andrés, 2017). Se determina también que los trabajos encontrados en la literatura científica no satisfacen la demanda de procesamiento en tiempo real y alta precisión de reconocimiento, simultáneamente.

Por lo expuesto anteriormente, el presente trabajo propone el desarrollo de modelos de reconocimiento de gestos de la mano basados en información infrarroja y técnicas de aprendizaje automático. La información infrarroja será adquirida utilizando el dispositivo Leap Motion. Este dispositivo contiene dos cámaras de visión profunda y tres LED infrarrojos, como se muestra en la figura 1. Además, el Leap Motion es un dispositivo especializado para reportar las posiciones y orientaciones espaciales de la mano, es portátil y tiene un bajo costo. El Leap Motion tiene un campo de acción para rastrear la mano de 150 grados de ancho y 60 cm de alto. Con este radio de operación, nos permite detectar la posición espacial (x,y,z) de cada mano, misma que representa un gesto (Clark & Moodley, 2016).




Figura 1. Estructura de Leap Motion Controller.

En este trabajo, proponemos el uso de algoritmos de aprendizaje automático que pueden inferir la clase resultante a partir de los datos obtenidos del Leap Motion. Usaremos aprendizaje automático debido a que desarrollar un modelo matemático para describir el problema para inferir una solución óptima es un problema muy complejo. En la figura 2, presentamos un esquema de aplicaciones de reconocimiento de gestos de la mano.




Figura 2. Esquema general para un sistema de reconocimiento de gestos manuales y sus usos

Un sistema de reconocimiento de gestos de la mano puede dividirse en 5 etapas: adquisición de datos, preprocesamiento, extracción de características, clasificación y postprocesamiento. El presente trabajo se estructura de la siguiente manera: En la sección 1, se presenta la introducción. En la sección 2, repasamos brevemente algunas de las obras que tratan el problema del reconocimiento de gestos con las manos. En la sección 3, presentamos el problema que abordaremos en este trabajo. En las secciones 4 y 5, respectivamente, presentamos la investigación propuesta y la metodología. En la sección 6, presentamos la pregunta de investigación que guía la investigación. En la sección 7, presentamos los objetivos que se lograrán en el desarrollo de la investigación. Para finalizar, el trabajo presenta las conclusiones en la sección 8.

Obras relacionadas

En (Dqj et al., 2014), Se propone un método de reconocimiento de gestos dinámicos basados en vectores de soporte (SVM por sus siglas en Inglés). El dispositivo utilizado para la extracción de datos es el Leap Motion Controller. Este dispositivo devuelve las posiciones espaciales de la mano como $P_i(x_i, y_i, z_i)$. También se propone una nueva metodología para la extracción de características. La metodología propuesta está basada en la variación de amplitud del ángulo de orientación. Se basa en la metodología propuesta y el orden de aparición de las características. Los gestos probados consisten en los 10 números árabigos del 0 al 9 con 160 muestras para cada gesto. Reporta una precisión de reconocimiento de 90.75%, no reporta la velocidad de reconocimiento.

In (Lu et al., 2016) los autores proponen un vector de características novedoso para la representación de gestos dinámicos utilizando el Leap Motion. El vector de características está compuesto por la dirección de la palma, el vector normal, la posición de la punta de los dedos y la posición del centro de la palma. El sistema de clasificación reporta una precisión de reconocimiento de 89.5%. Este valor resulta del promedio de la precisión de reconocimiento de 6 pruebas. La evaluación se realiza en 12 gestos del lenguaje de señas americanos, donde cada gesto se representa con 60 cuadros por segundo en dos conjuntos de datos. Los conjuntos de datos para entrenamiento fueron construidos por 10 personas, y cada gesto se repite tres veces.

En (Plouffe & Cretu, 2016) el autor presenta el reconocimiento de los gestos estáticos y dinámicos de la mano en tiempo real utilizando el sensor Kinect. Se utiliza el algoritmo de k-curvature. Este algoritmo consiste en la detección de la punta del dedo en el contorno de la mano. Se reporta una tasa de precisión de reconocimiento del 92.4%. También propone una adaptación del algoritmo Dynamic Time Warping no solo como una herramienta de validación sino también como un selector de gestos candidato. Los datos de entrada para esta solución son imágenes en bruto que se adquieren de cámaras de profundidad. Este trabajo no reporta el número de muestras para entrenamiento. Este trabajo tienen un conjunto de 45 gestos estáticos y dinámicos, y de éstos únicamente 9 gestos son probados. El documento menciona que funciona en tiempo real pero informa tiempos entre 2.6 y 2.9 s.

En (Czuszynski et al., 2017) los autores presentan una comparación entre los métodos basados en distribuciones Gaussianas y Redes Neuronales Artificiales (ANN por sus siglas en Inglés) para el reconocimiento de gestos de la mano. Utiliza sensores ópticos lineales patentados como dispositivo móvil. También presenta dos tipos de enfoques de clasificación, el primero se refiere al tipo de intensidad de luz reflejada con la mano cerca del sensor. El segundo se refiere al reconocimiento cuando dos de los dedos permanecen juntos. El reconocimiento se realizan en 3 gestos, presentando una precisión de reconocimiento de 81.19% para los métodos basados en distribuciones Gaussianas con cadenas ocultas de Markov (HMM por sus siglas en Inglés). La clasificación con redes neuronales artificiales presenta el 90.02% de precisión. Este trabajo no presenta la velocidad de reconocimiento.

En (Jangyodsuk et al., 2014) los autores presentan el reconocimiento de gestos en lenguaje de señas americano utilizando imágenes de profundidad y color proporcionadas por el sensor Kinect. Los algoritmos de clasificación para este trabajo son los siguientes: Algoritmo de Distorsión de Tiempo Dinámico y el Gradiente Orientado de Histograma. Para este trabajo, estos algoritmos están basados en la forma de la mano. El trabajo está realizado con 10 gestos obteniendo una precisión del 82%. Finalmente, los autores de este documento proponen un método de alineación de imágenes en color y en profundidad, mejorando la precisión en un 8%. El reconocimiento se realiza en 1113 signos.

En (Kumari, Garg, & Aulakh, 2014) los autores presentan un enfoque para la reducción del tamaño del conjunto de datos basado en una neurona con puntas inteligentes. En este algoritmo, la extracción de características se realiza para mejorar la precisión del reconocimiento utilizando el algoritmo de clasificación y análisis de componentes principales (PCA por sus siglas en Inglés). Para este trabajo, el conjunto de datos se obtiene de videos. En estos videos, el movimiento de la mano es reconocido como un gesto por el análisis de dirección. Este trabajo se realizó con un conjunto de 20 muestras.

Y para las pruebas utiliza un conjunto de 10 muestras. Este trabajo obtuvo una precisión del 90%. En (Doan et al., 2015) los autores proponen un conjunto de gestos de los cuales los patrones cíclicos son extraídos durante el movimiento de la mano. Los movimientos son capturados por cámaras del sensor Kinect en formato de video. Estos datos son procesados por el algoritmo del vecino más cercano (K-NN por sus siglas en Inglés) y el Dynamic Time Warping, lo que resulta en un 95% de precisión de reconocimiento con un tiempo de cálculo aproximado de 167 ms / cuadro + 16 ms. La evaluación se realiza en 5 gestos dinámicos.

En (Vo, Huynh, Nguyen, & Meunier, 2016) presenta el reconocimiento del lenguaje de señas vietnamita a través de una secuencia de imágenes proporcionadas por el sensor Kinect. Los cuadros capturados alimentan un sistema de segmentación que extrae la región de la mano. Estas imágenes se clasifican con SVM en tiempo real. Este artículo presenta una precisión de clasificación del 91%, con el parámetro $k = 2$. Del mismo modo, el valor de k varía con el parámetro $k = 3$, obtiene un valor de precisión del 98,54%, también se evidencia si el parámetro aumenta a $k = 5$ el valor de precisión disminuye a 94.19%. k es el valor de las características de trama consecutivas. No menciona el tiempo para el reconocimiento.

En (Hisham & Hamouda, 2017), presenta una interfaz para la comunicación entre personas con discapacidad auditiva y personas normales que no están familiarizadas con el lenguaje de señas árabe. Esta comunicación es hecha a través de un sistema de reconocimiento de gestos de la mano usando el Controlador Leap Motion. Para éste sistema de reconocimiento de gestos se usan algoritmos como: SVM, K-NN, ANN y dynamic time warping. El modelo está probado en 38 gestos estáticos y 20 gestos dinámicos. Reporta valores de clasificación para ANN 96.10% para gestos estáticos, 95.20% para gestos dinámicos, igualmente 99.0% - 98.30% con K-NN, y 96.50% - 94.20% para SVM. No reporta valores para el tiempo de clasificación.

Problema

La revisión de la literatura presentada en la sección previa claramente muestra que hay varios modelos propuestos para el reconocimiento de gestos de la mano. Estos modelos están basados en diferentes algoritmos existentes o basados en nuevos algoritmos propuestos. Adicionalmente, estos modelos reconocen gestos estáticos y dinámicos. A pesar de las características anteriores, los modelos propuestos en la literatura científica no satisfacen la demanda de alta precisión de reconocimiento y procesamiento en tiempo real simultáneamente.

Investigación propuesta

El presente trabajo propone el desarrollo de nuevos modelos para el reconocimiento de los gestos de la mano basada en información infrarroja usando el dispositivo Leap Motion y algoritmos de aprendizaje automático. Estos modelos podrían trabajar en tiempo real con una alta precisión de reconocimiento. Para probar el modelo, proponemos el uso de 5 gestos estáticos como se muestra en la figura 3, y 4 gestos dinámicos como se presenta en la figura 4. Los gestos estáticos son mano abierta, mano cerrada, pellizco, onda hacia dentro y onda hacia afuera. Los gestos dinámicos son círculo, deslizar, toque de pantalla y toque de tecla.




Figura 3. gesto estático recuperado con la cámara de profundidad del Controlador Leap Motion.
a)mano cerrada b) mano abierta c) pellizco d) onda hacia adentro d) onda hacia afuera



Figura 4. Gestos dinámicos a) círculo b) deslizar c) toque de pantalla d) toque de tecla

Para este trabajo, proponemos el uso de información infrarroja y algoritmos de aprendizaje automático como variables independientes. La información infrarroja se dividirá en tres subvariables: tipo de entrada para el sistema de reconocimiento, distancia entre el centro de la palma y el sensor, y frecuencia de muestreo. Los indicadores para medir la primera subvariable son la posición espacial y la dirección de cada nudillo como se presenta en la figura 5. Adicionalmente, la imagen de profundidad y el conjunto de marcos de imagen para cada gesto se utilizarán como indicadores de la primera subvariable.

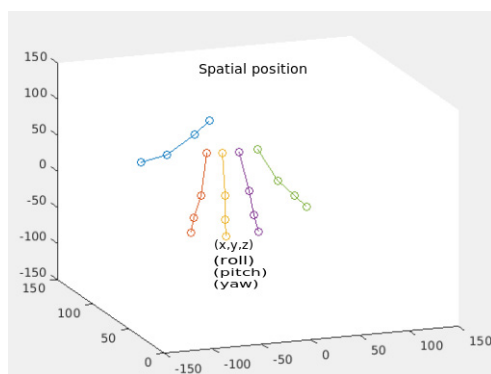


Figura 5. Información espacial (x,y,z) de los nudillos y el centro de la palma de la mano

El indicador para medir la segunda subvariable es la distancia en centímetros entre el centro de la palma y la superficie superior del Leap Motion. El indicador para la tercera subvariable será el número de muestras para cada nudillo de la mano o el número de imágenes de profundidad durante cuatro segundos. Para medir esta variable independiente es necesario considerar que el sensor tiene un rango de operación de 150 grados y 60 cm en los ejes y como se muestra en la figura 6.




Figura 6. Rango de operación del Controlador Leap Motion

En cuanto a la variable de aprendizaje automático, se dividen en las siguientes subvariables: preprocesamiento, extracción de características, clasificación y postprocesamiento. El preprocesamiento es un conjunto de algoritmos que se utilizan para mejorar los datos adquiridos. Para la extracción de características, proponemos probar diferentes métodos en el dominio de la frecuencia, el dominio del tiempo y el dominio de la frecuencia y el tiempo. Con respecto al tipo de algoritmos de clasificación, utilizaremos los algoritmos paramétricos y no paramétricos. Finalmente, utilizaremos el filtro de reglas como algoritmo de postprocesamiento.

METODOLOGIA

En esta sección, describimos la metodología que será usada para ejecutar la investigación propuesta. Esta metodología consta de dos fases: entrenamiento y pruebas. En esta sección, también describiremos los resultados que queremos obtener.

A. Entrenamiento

En esta fase, se presenta el diseño, entrenamiento, validación preliminar y puesta a punto el modelo de reconocimiento. A continuación se describe cada uno de los pasos que componen la fase de entrenamiento.

Diseño: Este paso consiste en diseñar la arquitectura del sistema de reconocimiento de gestos, estos son: adquisición de datos, preprocesamiento, extracción de características, clasificación y post-procesamiento. De éstos cinco módulos talvez los más importantes son adquisición de datos, preprocesamiento, extracción de características.

Adquisición de datos: Para este paso se obtienen los datos del Leap Motion que posteriormente alimentará al módulo de preprocesamiento. Para este trabajo, consideraremos dos tipos de datos: imágenes de profundidad y la orientación y posiciones espaciales de la mano. Para nuestro estudio usaremos los siguientes parámetros.

- Posición de la palma de la mano y velocidad
- Dirección y vector normal.

Este conjunto de datos en un tiempo definido representa un gesto como se ve en figura 7.



Figura 7. Seguimiento posicional

Un segundo conjunto de datos serán las imágenes de profundidad. Estas imágenes serán capturadas por dos cámaras de profundidad incluidas en el Controador Leap Motion. Este dispositivo mantiene los últimos 60 cuadros en memoria. De este modo, cinco repeticiones serán recolectadas de cada gesto para alimentar nuestro sistema de reconocimiento de gestos de la mano.

Con todos estos procesos, esperamos que este grupo de datos tenga una buena representación de reconocimiento de gestos como se ve en la figura 8.



Figura 8. Posición y orientación de la palma y dedos de la mano.

Pre-procesamiento: El valor de la posición espacial $P_i (x_i, y_i, z_i)$ y orientación obtenida del Leap Motion ya son preprocesadas. De este modo, este tipo de datos no necesita ser preprocesados. Sin embargo, las imágenes de profundidad estarán sujetas a procesos que incluyen las siguientes opciones: reducción de ruido, transformación a escala gris, binarización, segmentación, mejora y estandarización.

Para la reducción de ruido usaremos filtros promedio o filtros Gaussianos. La segmentación incluye las siguientes opciones: segmentación basada en discontinuidad y similitud.

Extracción de características: En este trabajo usaremos la posición de la palma, velocidad y orientación.

Respecto a los datos de los dedos, utilizaremos la posición de la punta, vector de velocidad y dirección. La representación numérica de estos valores es un gesto y el cambio de estos valores medido con una distancia métrica representa un gesto diferente. Estos datos serán guardados en una hyper matriz que alimentará el sistema de clasificación.

Del mismo modo, para la extracción de características de una imagen de profundidad usaremos la identificación del contorno de la mano con una aplicación de filtro de pasa altos. Los tipos de algoritmos de extracción de características serán aplicados en los siguientes dominios: frecuencia, tiempo y frecuencia-tiempo.

Clasificación: La clasificación es: dado un conjunto de datos de entrada y un algoritmo de aprendizaje automático se obtiene un modelo. Este modelo tratará de identificar un valor de salida llamado etiqueta o clase basada en todos estos datos antes presentados. En este trabajo, nuestro conjunto de datos se dividen en 80% para entrenamiento y 20% para la validación preliminar. Del mismo modo usaremos algoritmos paramétricos y no paramétricos para la construcción de modelos.

Algoritmos paramétricos: Los algoritmos de aprendizaje paramétrico sesgan su aprendizaje a una función bien definida. En este sentido, los algoritmos tienen un tamaño de parámetro bien definido, independientemente del tamaño del conjunto de datos.

Para este trabajo usaremos los siguientes algoritmos:

- Naive Bayes
- Redes neuronales artificiales

Proponemos estos algoritmos porque son fáciles de entender e interpretar. Además, estos algoritmos no requieren una gran cantidad de datos y convergen rápidamente. **Algoritmos no paramétricos:** Los algoritmos no paramétricos no vinculan fuertemente su aprendizaje a una función. Esto deja libre al modelo para aprender cualquier distribución de datos de entrada. Para este trabajo, usaremos la siguiente clasificación de algoritmos:

- K-vecinos mas cercanos
- Árboles de decisión
- Máquinas de vectores de soporte

Estos algoritmos son muy útiles debido a su gran capacidad de adaptación a diferentes distribuciones. En este sentido, el resultado obtenido usando algoritmos no paramétricos puede ser mejor que el resultado obtenido por los algoritmos paramétricos. Los algoritmos no paramétricos requieren un gran número de datos de entrenamiento para estimar la función. Debido al número de parámetros que este necesita, este proceso puede ser más lento que los algoritmos paramétricos.

Validación preliminar: Con el modelo obtenido y con el 20% de datos, procedemos a evaluar el desempeño inicial del modelo basado en la exactitud y la velocidad de reconocimiento.

Ajuste de modelo: En este paso, validamos el resultado del modelo preliminar. Si el resultado obtenido no satisface los requerimientos de velocidad y exactitud de reconocimiento, procederemos a optimizar el diseño del modelo. Finalmente obtendremos un nuevo modelo que satisfaga los requerimientos en tiempo de procesamiento y alta exactitud de reconocimiento.

B. Modelo de pruebas

Test: Con el modelo ajustado, daremos un nuevo conjunto de datos de gestos de la mano, y observaremos los valores de exactitud y velocidad de reconocimiento obtenidos. Estos son los valores que se reportarán como resultado de la investigación.

Pregunta de investigación

La pregunta de investigación que proponemos para este trabajo es: Cuál es la estructura de los modelos basados en información infrarroja y aprendizaje automático para el reconocimiento de gestos de la mano que trabajen en tiempo real y posea una alta exactitud de clasificación?

Objetivos

En esta sección se presentan los desafíos que con el desarrollo del proyecto se pretenden alcanzar. El principal desafío es desarrollar varios modelos de reconocimiento de gestos de la mano basados en información infrarroja utilizando algoritmos de aprendizaje automático, estos algoritmos serán comparados entre sí en función de la mejor exactitud de clasificación obtenido, y el menor tiempo de procesamiento alcanzado, finalmente, se presentará el modelo con mayor exactitud de reconocimiento alcanzado y menor tiempo de procesamiento reportado.

Con la finalidad alcanzar estos desafíos propuestos, se desarrollarán los modelos utilizando algoritmos de aprendizaje automático paramétricos y no paramétricos, que reconozcan los 5 gestos estáticos y los 4 gestos dinámicos propuestos anteriormente. Estos modelos deberán trabajar en tiempo real y con una alta exactitud.

Finalmente, el mejor modelo obtenido será testeado para validar su respuesta en términos de exactitud y velocidad de procesamiento.

Conclusiones

En este paper, proponemos el desarrollo de varios modelos de reconocimiento de gestos de la mano en tiempo real, basados en datos de profundidad entregados por el Leap Motion y que utilicen algoritmos de Machine Learning. Los datos de profundidad son los datos espaciales, dirección y velocidad de la palma de la mano y de los dedos. Los algoritmos de aprendizaje automático serán: Naive Bayes, ANN, k-NN, árboles de decisión y SVM. Los modelos reconocerán cinco gestos estáticos como: mano abierta, mano cerrada, pellizco, onda hacia dentro y onda hacia afuera. Los gestos dinámicos son: círculo, deslizar, toque de pantalla y toque de tecla.

La base de datos estará estructurada por al menos 25 repeticiones de cada uno de los gestos. Para la validación preliminar del modelo usaremos el 20% del conjunto de datos. Mientras que para el testeo final presentaremos un nuevo conjunto de datos, con un número de muestras igual al número de muestras utilizadas para el entrenamiento. El modelo propuesto será evaluado en base a la exactitud de reconocimiento y la velocidad de procesamiento simultáneamente.

Reconocimiento

Los Autores agradecen a la Escuela Politécnica Nacional por el Programa de Doctorado en Informática y a la Universidad Técnica de Ambato por apoyar constantemente a la capacitación de sus docentes.

Referencias bibliográficas

- Benalcázar, M. E., Motoche, C., Zea, J. A., Member, S., & Andrés, G. (2017). Hand gesture recognition using MYO armband. *Chinese Automation Congress (CAC)*, 2017, 4850–4855.
- Benalcázar, M. E., Motoche, C., Zea, J. A., Member, S., Andrés, G., Anchundia, C. E., ... Pérez, M. (2017). Real-Time Hand Gesture Recognition Using the Myo Armband and Muscle Activity Detection. *2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM)*, 1–6. <https://doi.org/10.1109/ETCM.2017.8247458>
- Chaudhary, A. (n.d.). Ankit Chaudhary.
- Czuszynski, K., Ruminski, J., & Wtorek, J. (2017). Pose classification in the gesture recognition using the linear optical sensor. *Proceedings - 2017 10th International Conference on Human System Interactions, HSI 2017*, 18–24. <https://doi.org/10.1109/HSI.2017.8004989>
- Das, S. R., Jakulin, T. E., & Nigel, K. G. J. (2016). Linear and rotational air gesture detection using optical sensors setup in automotive infotainment system. *International Conference on Communication and Signal Processing, ICCSP 2016*, 1164–1169. <https://doi.org/10.1109/ICCSP.2016.7754335>
- Doan, H. G., Vu, H., & Tran, T. H. (2015). Recognition of hand gestures from cyclic hand movements using spatial-temporal features. *ACM International Conference Proceeding Series*, 03–04–Dece, 260–267. <https://doi.org/10.1145/2833258.2833301>
- Dominio, F., Donadeo, M., Marin, G., Zanuttigh, P., & Cortelazzo, G. M. (2013). Hand Gesture Recognition with Depth Data. *Proceedings of the 4th ACM/IEEE International Workshop on Analysis and Retrieval of Tracked Events and Motion in Imagery Stream*, 9–16. <https://doi.org/10.1145/2510650.2510651>
- Dqj, X., Dl, L. D. R., Xq, H. Q., Lq, X. X., Lw, F., Glvflsolqh, L. V. D., ... Kdqg, D. G. Q. (2014). A Novel Feature Extracting Method for Dynamic Gesture Recognition Based on Support Vector Machine. *Proceedings of the IEEE International Conference on Information and Automation*, (July), 437–441.
- Hisham, B., & Hamouda, A. (2017). Arabic Static and Dynamic Gestures Recognition Using Leap Motion. <https://doi.org/10.3844/jcsp.2017.337.354>
- Jais, H. M., Mahayuddin, Z. R., & Arshad, H. (2015). A Review on Gesture Recognition Using Kinect. *The 5th International Conference on Electrical Engineering and Informatics 2015*, 594–599. <https://doi.org/10.1109/ICEEI.2015.7352569>
- Jangyodsuk, P., Conly, C., & Athitsos, V. (2014). Sign language recognition using dynamic ime warping and hand shape distance based on histogram of oriented gradient features. *Proceedings of the 7th International Conference on PErvasive Technologies Related to Assistive Environments - PETRA '14*, 1–6. <https://doi.org/10.1145/2674396.2674421>
- Kumari, N., Garg, R., & Aulakh, I. K. (2014). A spiking neuron improved PCA model for hand gesture recognition. *ACM International Conference Proceeding Series*, 11–16–Nove. <https://doi.org/10.1145/2677855.2677876>
- Lu, W., Tong, Z., & Chu, J. (2016). Dynamic hand gesture recognition with leap motion controller. *IEEE Signal Processing Letters*, 23(9), 1188–1192. <https://doi.org/10.1109/LSP.2016.2590470>
- Mcintosh, J., & Group, B. I. (2017). SensIR: Detecting Hand Gestures with a Wearable Bracelet using Infrared Transmission and Reflection.
- Park, S., Ryu, M., Chang, J. Y., & Park, J. (2014). A hand posture recognition system utilizing frequency difference of infrared light. *Proceedings of the 20th*

- ACM Symposium on Virtual Reality Software and Technology - VRST '14, 65–68. <https://doi.org/10.1145/2671015.2671114>
- Plouffe, G., & Cretu, A.-M. (2016). Static and Dynamic Hand Gesture Recognition in Depth Data Using Dynamic Time Warping. *IEEE Transactions on Instrumentation and Measurement*, 65(2), 305–316. <https://doi.org/10.1109/TIM.2015.2498560>
- Vo, D.-H., Huynh, H.-H., Nguyen, T.-N., & Meunier, J. (2016). Automatic hand gesture segmentation for recognition of Vietnamese sign language. *Proceedings of the Seventh Symposium on Information and Communication Technology - SoICT '16*, 368–373. <https://doi.org/10.1145/3011077.3011135>
- Zhou Ren, Jingjing Meng, & Junsong Yuan. (2011). Depth camera based hand gesture recognition and its applications in Human-Computer-Interaction. *2011 8th International Conference on Information, Communications & Signal Processing*, 1–5. <https://doi.org/10.1109/ICICS.2011.6173545>

CURRÍCULUM DE LOS AUTORES

	<p>Rubén Eduardo Nogales Portero Ingeniero en Sistemas y Computación. Magister en Redes y Telecomunicaciones. Estudiante de Doctorado de la Escuela Politécnica Nacional. Profesor titular auxiliar 1 de la Universidad Técnica de Ambato. Integrante del grupo de Investigación REWARD. Ambato - Ecuador</p>
	<p>Marco Enrique Benalcázar Palacios Ingeniero en Electrónica y Telecomunicaciones. Doctor en Ingeniería Orientación Electrónica. Profesor titular agregado 3 de la Escuela Politécnica Nacional. Director de Investigación de la Escuela Politécnica Nacional. Investigador en Sistemas Inteligentes. Quito - Ecuador</p>