

Tipo de artículo: Artículo original

Identificar las piezas dentarias mediante procesamiento digital de imágenes y Deep Learning

Identify dental pieces through digital image processing and Deep Learning

Alfonso A. Guijarro-Rodríguez^{1*} , <https://orcid.org/0000-0001-6046-426X>

Juan A. Quinde-Bayas² , <https://orcid.org/0000-0002-3142-889X>

María I. Galarza-Soledispa³ , <https://orcid.org/0000-0001-8358-7596>

Mirella C. Ortiz-Zambrano⁴ , <https://orcid.org/000-0001-9290-4194>

¹ Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil. Correo electrónico: alfonso.guijarror@ug.edu.ec

² Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil.

³ Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil.

⁴ Facultad de Ciencias Matemáticas y Físicas, Universidad de Guayaquil.

* Autor para correspondencia: alfonso.guijarror@ug.edu.ec

Resumen

Contexto: Los profesionales de la salud oral requieren un amplio estudio para identificar la anatomía de las piezas dentarias con su respectiva morfología, para esto se preparó un modelo computacional basado en inteligencia artificial (IA) que crea una interfaz gráfica y permite al usuario identificar cada pieza dental. Método: Para realizar el caracterizado de la estructura morfológica de una pieza dental, se emplearon técnicas experimentales de Procesamiento Digital de Imágenes (PDI); es decir, llevar su anatomía dental; color, tamaño y forma a representaciones computacionales. Para lo cual, se preparó un banco de imágenes de piezas dentales, que fueron obtenidas tanto en la clínica de la Facultad Piloto de Odontología e internet. El modelo se basó en Redes Neuronales Convolucionales (RNC) y pasó por fases propias del PDI Resultados: El algoritmo fue desarrollado en Matlab, y los resultados sometidos a validación de expertos, luego del entrenamiento, las pruebas revelaron una precisión del 94.49% para detección de dientes, mientras que para las muelas la efectividad fue de un 87,5% en la detección individual. Conclusiones: El trabajo sugiere que la cantidad de imágenes etiquetadas contribuye a mejorar la precisión de los resultados siempre que sean de alta resolución, además queda claro que existe influencia entre el espectro visible y no visible de las imágenes para el reconocimiento de las piezas dentarias.

Palabras clave: Algoritmo, Detección, Imágenes, Pieza dental, Segmentación.

Abstract

Context: Oral health professionals require extensive study to identify the anatomy of the teeth with their respective morphology, for this a computational model based on artificial intelligence (AI) was prepared that creates a graphical interface and allows the user to identify each tooth. Method: To characterize the morphological structure of a dental piece, experimental techniques of Digital Image Processing (DIP) were used; that is, bring your dental anatomy; color, size, and shape to computer representations. For which, a bank of images of dental pieces was prepared, which were obtained both in the clinic of the Pilot School of Dentistry and the Internet. The model was based on Convolutional Neural Networks (CNN) and went through phases typical of the PDI Results: The algorithm was developed in Matlab, and the results were submitted to validation by experts. After training, the tests revealed an accuracy of 94.49% for detection of teeth, while for molars the effectiveness was 87.5% in detection. individual. Conclusions: The work suggests that the number of labeled images contributes to improving the accuracy of



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional**
(CC BY 4.0)

the results as long as they are of high resolution, it is also clear that there is an influence between the visible and non-visible spectrum of the images for the recognition of dental pieces.

Keywords: *Algorithm, Detection, Images, Tooth, Segmentation*

Recibido: 11/07/2022

Aceptado: 30/09/2022

En línea: 01/10/2022

Introducción

La visión artificial en los últimos años ha tenido un gran impacto en el campo científico (Infaimon, 2010) su evolución tecnológica y sus aplicaciones han sido de gran interés en el campo de la industria (Zion, 2012), finanzas, medicina, agricultura, entre otras (Aperador-Chaparro, Bautista-ruiz, & Mejía, 2013). Esto ha provocado cambios significativos en la forma de analizar los datos, lo cual ha incidido para que en las empresas inviertan en equipamiento local o arquitecturas en nube para realizar un óptimo procesamiento de la información.

El reconocimiento de objetos tiene como tarea solucionar problemas asociados a identificar las estructuras anatómicas de las piezas dentarias con su respectiva morfología, para lo cual la tecnología presenta metodologías experimentales como el PDI y otras alternativas como las técnicas de la desviación de la mediana, redes neuronales artificiales, redes neuronales convolucionales, Deep Learning, entre otras, para crear modelos de reconocimiento de piezas dentarias.

Para la detección, selección y manipulación de las piezas dentarias, se aplicó un algoritmo que reconozca los objetos sin afectar la postura en la que esté localizada, haciendo uso del espacio de colores y tratando de reducir la influencia de las sombras y brillos que aparecen en las fotografías, evitando el ruido de la información, para esto las imágenes capturadas son sometidas a algoritmos de Deep learning que son más rápidos y detectan homogéneamente los puntos de interés (Atoche, Magaña, & Sandoval, 2015).

Cintas, Delrieux, Bianchi, & Defossé (2012) consideran que el procesamiento de imágenes aplicado al reconocimiento de la posición de vértebras mediante Redes Neuronales permite encontrar un método no supervisado de reconocimiento, el cual identifica objetos, acciones o características, para describir el contenido, y en general automatizar las tareas cognitivas que usualmente requieren supervisión humana. El desarrollo de esta investigación se centra especialmente en la clasificación de vértebras mediante Redes Neuronales. Aunque el enfoque es referido a vértebras su estructura y alcance permiten establecer las bases para el reconocimiento de las estructuras anatómicas de las piezas dentarias con su respectiva morfología a través de algoritmos no supervisados.

Rai & Andree (2016) comentan que la detección temprana y caracterización de las lesiones de caries son muy importantes porque el procedimiento de restauración podría reducirse. Si se detecta en una etapa temprana, los



profesionales de la salud oral pueden implementar medidas para revertir y controlar las caries, usando técnicas tratadas en pacientes con necesidad de atención preventiva, es decir, detección de caries en placas radiográficas a partir del uso del reconocimiento de patrones en imágenes. Lo cual, sirve de base para la detección de las estructuras anatómicas de las piezas dentarias sean estas muelas o dientes.

(Peláez, Vaccaro, & Guijarro, 2015) presentan un trabajo para explorar la posibilidad de establecer, si a través del PDI, elementos como: el área, la composición, la distribución espacial, el tamaño, el contorno, la superficie de los agregados, entre otros, tienen influencia en las propiedades de resistencia del hormigón, de manera que se puede categorizar a partir de dichas características. Trabajo que sirvió de base para seguir el modelo en fases con los ajustes respectivos que permitan identificar las piezas dentales con clasificadores basados en Deep Learning.

Finalmente este trabajo centra su estudio en identificar las piezas dentarias, sin importar su ubicación haciendo uso de un modelo computacional que utiliza técnicas de PDI con algoritmos no supervisados para reconocer y detectar las piezas dentarias en un adulto en la dentición permanente con mayor exactitud y precisión. Para ello el trabajo se ha organizado en forma clásica, la sección de materiales y métodos presenta diferentes técnicas para mejorar la calidad de una imagen, el algoritmo para la construcción del detector RGB, técnicas de segmentación sobre las piezas dentarias, Redes Neuronales Artificiales (RNA), un clasificador que usa el algoritmo de Adaboost, ejecutado desde el software Matlab, la sección de resultados muestra el nivel de exactitud y presión para el reconocimiento de muelas y dientes, y finalmente las conclusiones y recomendaciones derivadas de este trabajo.

Materiales y métodos

Este trabajo utiliza el PDI para identificar las piezas dentarias con su morfología, siguiendo las fases del método experimental, captura, pre-procesado, segmentación, extracción de características y clasificación o reconocimiento (Peláez, Vaccaro, & Guijarro, 2015). Mientras que las otras técnicas analizan la imagen para mejorar la calidad y segmentar el área de interés. Considerando que una imagen se compone del espacio de color RGB, este se ajusta para cumplir el requisito de mostrar tasas muy bajas de tiempos de ejecución. Para entender mejor este modelo, se va a caracterizar una imagen como una matriz de $H \times W$ píxeles. En una imagen RGB, cada uno de estos píxeles será el resultado de la suma aditiva del mismo píxel de otras tres sub-imágenes (sub-matrices) que representa cada uno de los componentes. Es común encontrar estos componentes representados por su luminosidad, de tal forma que, a mayor brillo de la imagen, mayor será la contribución de ese componente en ese punto en particular.

En los últimos años, se aprecia un creciente interés en desarrollar nuevas técnicas que permitan establecer diagnósticos médicos, apoyado en tecnologías de la información, concretamente en la detección temprana de



enfermedades para aplicar los respectivos tratamientos, por ejemplo el autor refiere un trabajo que presenta un 80% de éxito en sus resultados, para la clasificación de caries (Guijarro-Rodríguez, y otros, 2019). El trabajo en mención permitió utilizar un banco de imágenes para el reconocimiento de caries y también permite realizar bancos de imágenes derivados para otros estudios sobre las enfermedades que presenta la cavidad bucal, siendo la identificación de las piezas dentarias un punto de interés en este trabajo, la figura 1, muestra un esquema para la detección de objetos desde el plano RGB.

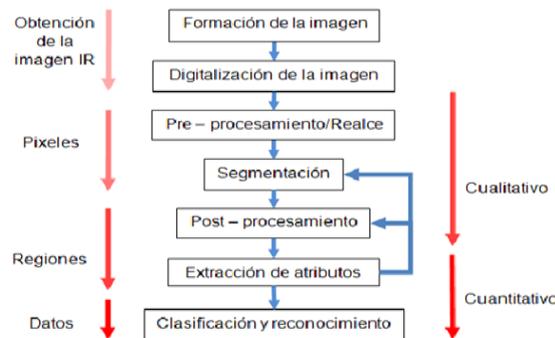


Figura 1. Proceso de detección de objeto.

Técnicas de Procesamiento de imágenes

Transformada De Watershed

Es una técnica de procesamiento morfológica por medio de ella se puede llevar a cabo la segmentación de imagen, basada en regiones, el mismo que se adapta a las diferentes muestras de imágenes a tal punto que es capaz de distinguir elementos complejos que generalmente no pueden ser procesados correctamente mediante algoritmos comunes (González, Rodríguez, & Orozco, 2017) como se muestra en la Figura 2(a).

Transformada Canny

Es una técnica de segmentación, para la detección de bordes que existen dentro de una representación gráfica. Este algoritmo es reconocido como el más destacado en los métodos de detección de bordes, se debe a la utilidad de máscaras de convolución por lo que está basado en la primera derivada (Valverde, 2007). El algoritmo cuenta con las siguientes fases: obtener el gradiente, supresión no máxima, histéresis de umbral y cerrar los bordes que hayan quedado abiertos por el ruido, tal como se muestra en la figura 2 (b).

Transformada Sobel



Es una técnica de segmentación, que se aplica dentro del PDI, esta técnica nos facilita el cálculo de la intensidad y la gradiente de la ilustración adquirida por medio de cada pixel, se compone de la imagen, de esta manera facilita la obtención de bordes para mostrar los cambios bruscos que se pueden haber efectuado, además de presentar la dirección de forma horizontal y vertical tal como se muestra en la Figura 2 (c). (Gálvez, 2014).

Transformada De K-Means

Este es un método que se lo conoce como algoritmo de Lloyd en el campo de la informática, consiste en clasificar un conjunto de elementos en base a propiedades de estos de forma iterativa. El algoritmo fue creado por Stuart Lloyd en el año 1957, fue creado como una técnica para modulación por impulsos codificados (López & Luna, 2014). Este método es utilizado para llevar a cabo la transformación de segmentación de imagen como se muestra en la Figura 2(d).

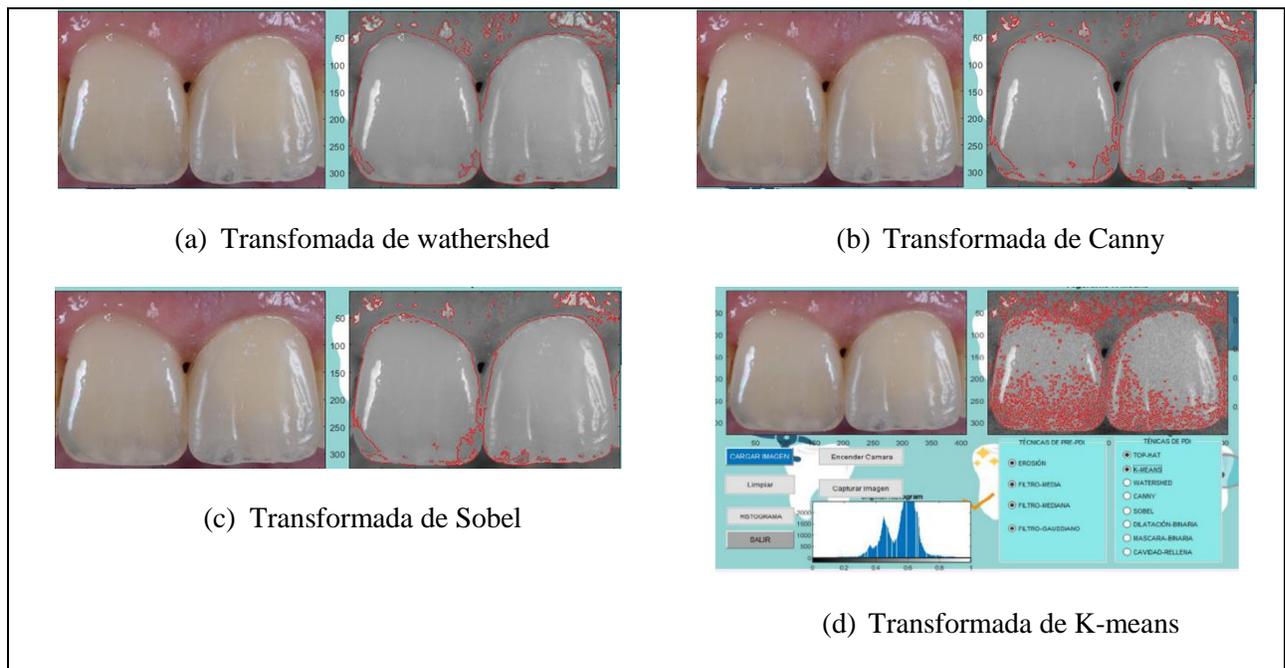


Figura 2. Técnicas de Procesamiento de imágenes.

Las Redes Neuronales Artificiales (RNA) pueden poseer varias entradas, varias capas y esas capas varias neuronas, la experiencia las neuronas van reforzando ciertos enlaces para ir aprendiendo o entrenando, permitiendo buscar la combinación de ciertos parámetros entre ellos la raíz de la pieza dentaria, el contorno, de tal manera que se adaptan a



un determinado problema, con las características adquirida se comienza a entrenar por capas como se muestra en la Figura 3.

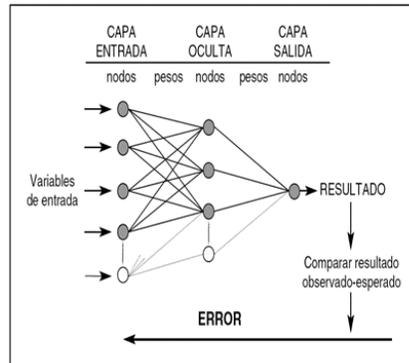


Figura 3. Redes Neuronales por capas.

Una vez detectada las características, el algoritmo de RNA irá comparando con el clasificador de capas, el cual está basado en una cascada de clasificadores binarios entrenados mediante el algoritmo de Adaboost descrito a continuación.

Dadas las imágenes de ejemplo $(x_1, y_1), \dots, (x_n, y_n)$ donde $Y_i = 0, 1$ para los ejemplos negativos y positivos respectivamente,

- Inicializamos los pesos $W_{1,i} = \frac{1}{2}m, \frac{1}{2}n$. para $Y_i = 0, 1$ donde m y n son el número de negativos y positivos respectivamente.

- Para $t=1, \dots, T$

1. Normalizar los pesos, $W_{t,i} \leftarrow W_{t,i} / \sum_{j=1}^n W_{t,i}$ De manera que W_t es una distribución de probabilidad.
2. Para cada característica, j , entrenar un clasificador h_j que está restringido a usar una sola característica. El error es evaluado con respecto a

$$W_t, E_t = \sum_i^j W_i |h_i(x_i) - y_i|$$

3. Escoger el clasificador, h_j , con el menor error E_t .
4. Se actualiza los pesos:

$$W_{t+1,i} = W_{t,i} \beta_t^{1-e_i}$$

Donde $e_i = 0$ si el ejemplo x , se ha clasificado correctamente, $e_i = 1$ en caso contrario, y $\beta_t = \frac{E_t}{1-E_t}$

- El clasificador final es:



$$h(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{otherwise} \end{cases}$$

donde $\alpha_t = \log \frac{1}{\beta_t}$

Matlab

Herramienta de ámbito matemático, que incorpora un IDE de desarrollo integrado, cuenta con un lenguaje de programación que permite trabajar con algoritmos, matrices, entre otros, en este trabajo permitió ejecutar y entrenar la red neuronal artificial desde su versión R2016a. A nivel de procesamiento de imagen se trabajó con **Image Processing Toolbox**, herramienta que facilitó un conjunto de aplicaciones para realizar, procesamiento, segmentación, mejoras, supresión de ruido, análisis, visualización y desarrollo de algoritmos para trabajar con imágenes. Una vez obtenido el clasificador, entrenamos la red neuronal y a través del comando **nntraintool** se presenta la ventana de entrenamiento, que posee una capa de entrada, una neurona en la capa de salida, 3 iteraciones tal como se muestra en la Figura 4.

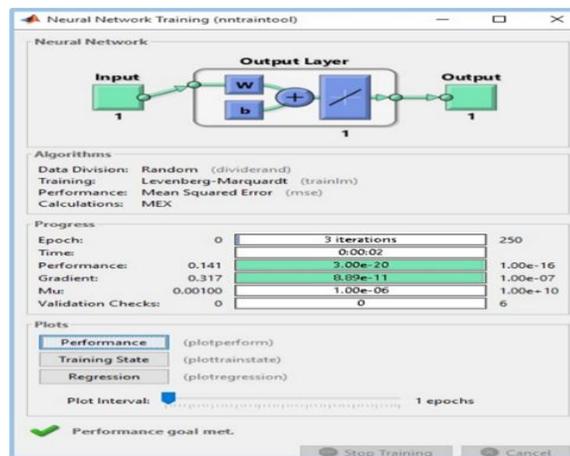


Figura 4. La ejecución de la red neuronal.

Deep Learning

El método de aprendizaje profundo permite que los ordenadores obtener ciertos conocimientos similares a como lo hacen las personas, es decir aprender mediante ejemplos. Por medio de este modelo informático aprende a realizar tareas de clasificación directamente a partir de imágenes, texto o sonido. Los modelos de Deep Learning pueden alcanzar una precisión de vanguardia que en ocasiones supera el rendimiento humano. Los modelos se entrenan mediante un amplio conjunto de datos etiquetados y arquitecturas de redes neuronales que contienen muchas capas (Bendemra, 2018) como se muestra en la Figura 5.



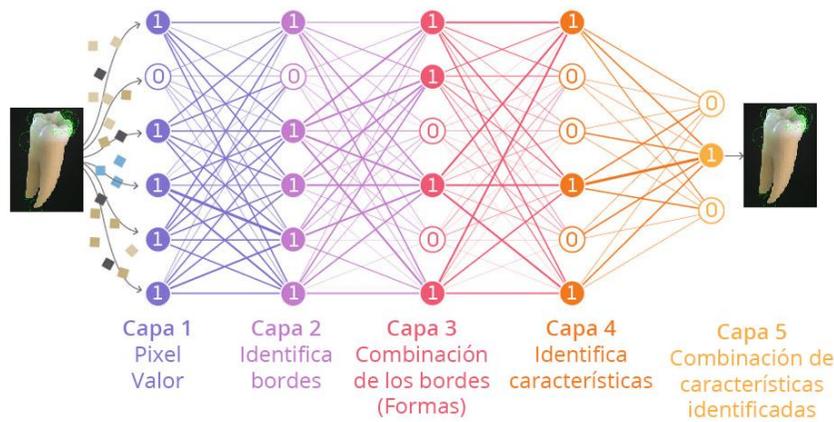


Figura 5. Flujo de trabajo de Deep Learning.

Después de la detección de características, a través de la arquitectura de una red neuronal convolucional, se cambia a clasificación de capa siguiente a la última que es una capa totalmente conectada al fondo competitivo que genera un vector de X dimensiones donde Y es el número de clases que la red podrá predecir. Este vector contiene la probabilidad para cada clase de cualquier imagen siendo clasificada. La capa final de la arquitectura una red neuronal convolución (se muestra en la Figura 6) utiliza una función para proporcionar la salida de clasificación y así poder identificar la pieza dental a través de una imagen y con un profundo aprendizaje se pudo detectar el objeto, se representa el flujo de trabajo para el reconocimiento de la pieza dentaria.

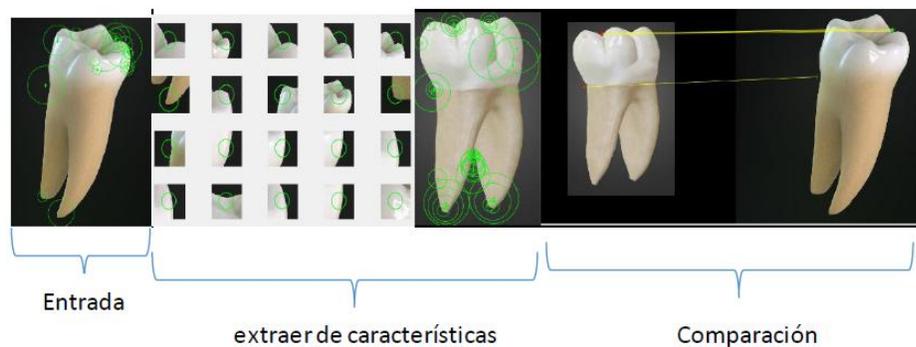


Figura 6. Detección de piezas dentarias.

Otras Herramientas



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional** (CC BY 4.0)

Para preparar la interfaz web de reconocimiento de las piezas dentales, fue necesario recurrir a tecnologías como Cascading Style Sheets (CSS3), lenguaje que permitió elaborar los diseños y presentación de la página web, además se incorporó el lenguaje de hipertexto (HTML5) en su versión 5, además de php para el desarrollo de la aplicación web, todo esto subido a un servidor de hospedaje para sitios web, denominado hosting y para su visualización se considera cualquier navegador, Chrome, Firefox, opera, entre otros.

Resultados y discusión

Una vez finalizado el proyecto se ha obtenido la interfaz para la detección de piezas dentarias que se presenta en la figura 7. Totalmente programada desde el IDE de Matlab R2016a, en ella se ejecuta algoritmos de procesamiento de imágenes a través de la red neuronal entrenada y muestra las características de la pieza dental.



Figura 7. Interfaz Gráfica para el reconocimiento de piezas dentarias.

Se creó una base de datos de información para catalogar las piezas dentales en función del odontograma que es un esquema que está dividido en dos segmentos superior e inferior y encontramos todas las piezas dentales diseñada tales como; incisivo central, incisivo lateral, canino, primer premolar, segundo premolar, primer molar, segundo molar y tercer molar.

Con la red neuronal entrenada con varias imágenes de piezas dentales de diferentes ángulos de personas adultas, se obtuvieron resultados en la identificación de un diente o muela, con una precisión de un 94.49% en la detección de dientes.



La red neuronal, presenta una efectividad de un 87.5% en la detección de muelas, teniendo un margen de error de 12.5%. Este margen de error se produce por la calidad de la imagen y el uso del espectro visible y no visible de una imagen subida al sistema.

Conclusiones

La obtención de las imágenes (piezas dentales) fue fundamental para este trabajo, debido a que ellas permitieron realizar pruebas de segmentación, a través del uso de diversas imágenes que contenía distintos panoramas. Por otro lado, se puede concluir que, a mayor cantidad de imágenes para ser procesadas y analizadas, se puede obtener un mejor resultado, es decir, aumenta la precisión.

La red neuronal presenta mejor efectividad de detección en dientes que en muelas, debido a la calidad de las imágenes que se almacenan en la base de imágenes.

Recomendaciones

El estudio fue enfocado a la detección e identificación por medio de la estructura morfológica de las piezas dentales en la cavidad bucal; sin embargo, se deja abierta la posibilidad de implementar este modelo en la detección de patologías existentes en la cavidad bucal, como son: gingivitis, periodontitis y sobre todo en la descalcificación dental.

Se pone en consideración la posibilidad de utilizar otras herramientas de procesamiento de datos basados en un lenguaje de programación distinto, al utilizado en este trabajo como Python ya que permite realizar el análisis de imágenes digitales y detección de objetos, con otros recursos o librerías.

Conflictos de intereses

Los autores no poseen conflictos de intereses.

Contribución de los autores

1. Conceptualización: Alfonso A. Guijarro-Rodríguez, Juan A. Quinde-Bayas, María I. Galarza-Soledispa, Mirella C. Ortiz-Zambrano.
2. Curación de datos: Alfonso A. Guijarro-Rodríguez.



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional**
(CC BY 4.0)

3. Análisis formal: María I. Galarza-Soledispa, Mirella C. Ortiz-Zambrano.
4. Investigación: Alfonso A. Guijarro-Rodríguez, Juan A. Quinde-Bayas.
5. Metodología: Alfonso A. Guijarro-Rodríguez, Juan A. Quinde-Bayas.
6. Administración del proyecto: María I. Galarza-Soledispa.
7. Software: Alfonso A. Guijarro-Rodríguez, Juan A. Quinde-Bayas.
8. Supervisión: María I. Galarza-Soledispa, Mirella C. Ortiz-Zambrano.
9. Validación: María I. Galarza-Soledispa, Mirella C. Ortiz-Zambrano.
10. Visualización: Alfonso A. Guijarro-Rodríguez, Juan A. Quinde-Bayas.
11. Redacción – borrador original: Alfonso A. Guijarro-Rodríguez, Juan A. Quinde-Bayas, María I. Galarza-Soledispa, Mirella C. Ortiz-Zambrano.
12. Redacción – revisión y edición: Alfonso A. Guijarro-Rodríguez, Juan A. Quinde-Bayas, María I. Galarza-Soledispa, Mirella C. Ortiz-Zambrano.

Financiamiento

La investigación no requirió fuente de financiamiento externa.

Referencias

- Aperador-chaparro, Bautista-ruiz, & Mejía. (2013). Determinación Por Visión Artificial Del Factor De Degradación En Aleaciones Biocompatibles Computer Vision For Determination Of Degradation Factor In Biocompatible Alloys, 24(2), 109–120. Obtenido de <https://doi.org/10.4067/S0718-07642013000200012>
- Bendemra. (2018). Construye Tu Primer Clasificador De Deep Learning Con Tensorflow: Ejemplo De Razas De Perros. Recuperado el 23 de February de 2019, de <https://medium.com/datos-y-ciencia/construye-tu-primero-clasificador-de-deep-learning-con-tensorflow-ejemplo-de-razas-de-perros-ed218bb4df89>
- Castillo Ruiz, & Irvin Anderson. (2020). Aplicación de imágenes médicas en biomecánica ortodóntica. Obtenido de <https://pirhua.udep.edu.pe/handle/11042/4573>
- Cintas, C., Delrieux, C., Bianchi, G., & Defossé, N. (2012). Procesamiento inteligente de imágenes: Posicionamiento de vértebras mediante landmarks y. *XIV Workshop de Investigadores en Ciencias de la Computación*.
- Gálvez. (2014). Operadores De Detección De Bordes. Santiago: Universidad De Chile.
- González, Rodríguez, & Orozco. (2017). Marcadores Para Segmentación Watershed Usando Transformada De Radon Watershed. *Revista Cubana De Ciencias Informáticas*. 11 (1), 136- 152. 138.



- Guijarro-Rodríguez, A. A., Witt-Rodriguez, P. M., Cevallos-Torres, L. J., Contreras-Puco, S. F., Ortiz-Zambrano, M. C., & Torres-Martínez, D. E. (2019). Image segmentation techniques application for the diagnosis of dental caries. Obtenido de https://scholar.google.es/citations?view_op=view_citation&hl=es&user=4ctWkT0AAAAJ&citation_for_view=4ctWkT0AAAAJ:Wp0gIr-vW9MC
- Infaimon. (2010). Visión Artificial Aplicada A La Industria. Recuperado el 27 de Agosto de 2018, de [Http://www.Jcee.Upc.Es/JCEE2010/Pdf_Ponencias/Pdfs/25_11_10/INFAIMON Vision%20artificial.Pdf](Http://www.Jcee.Upc.Es/JCEE2010/Pdf_Ponencias/Pdfs/25_11_10/INFAIMON%20Vision%20artificial.Pdf)
- José Ignacio Peláez, Vaccaro, G., & Guijarro, A. (2015). Un Modelo para la Categorización de Hormigones Mediante Procesamiento Digital de Imágenes. Obtenido de https://scholar.google.es/citations?view_op=view_citation&hl=es&user=4ctWkT0AAAAJ&citation_for_view=4ctWkT0AAAAJ:qjMakFHDy7sC
- López, & Luna. (2014). Segmentación De Imágenes Mediante El Algoritmo De K-Medias. 2. Obtenido de <Http://Opera.Eii.Us.Es/Pid/Public/Uploads/Pid/Entregables/2013-2014/G2013-2014-15/Grupo15Documentacin57.Pdf>
- Magaña, Atoche, & Sandoval. (july de 2015). Detección De Objetos En Imágenes Utilizando Opencv Para Raspberry. Recuperado el 3 de December de 2018
- Rai, C. S., & Andree, M. Q. (2016). Detección automática de caries utilizando reconocimiento de patrones en placas radiográficas. Obtenido de <https://repositorio.uss.edu.pe/bitstream/handle/20.500.12802/163/11%20Informe%20Desarrollo%20de%20Tesis.pdf?sequence=1&isAllowed=y>
- Valverde. (2007). Detección De Bordes Mediante El Algoritmo De Canny. Trujillo : Universidad Nacional De Trujillo. 2.
- Zion. (2012). The Use Of Computer Vision Technologies In Aquaculture – A Review, Computers And Electronics In Agriculture, 88, 125-132.

