

Información científica y tecnológica

Automatización para el registro de resultados de laboratorio al utilizar la técnica de amplificación isotérmica mediada por bucle (LAMP)

Jorge Ochoa-Somuano^{1*} , Francisco Ruiz-Ruiz² ,
Julieta Cruz-Vázquez² , Verónica Ortega-Baranda³ ,
& José Francisco Delgado-Orta² 

Resumen

El procesamiento digital de imágenes tiene una variedad de aplicaciones en diferentes áreas, como son: ingeniería, robótica, industria, agrícola y salud, por mencionar algunas. Cuando los investigadores usan algunas técnicas colorimétricas, se presentan ciertas situaciones en las que se requiere el apoyo de herramientas computacionales para poder identificar de manera precisa el color, tonalidad de los resultados obtenidos, disminuyendo así la probabilidad de cometer errores. La técnica LAMP es una herramienta aplicada en la amplificación de ácidos nucleicos y es un ejemplo de un procedimiento colorimétrico. La propuesta de solución que se plantea en el presente reporte de investigación, es el desarrollo de un programa de computadora que utiliza procesamiento de imágenes digitales, para hacer el levantamiento de la información obtenida a partir del uso de la técnica LAMP. Como parte de la metodología de solución se utilizan técnicas de extracción de características con base en el color y la forma; con el objetivo de identificar los elementos que pertenecen a las muestras de interés. Después de realizar una serie de pruebas con diferentes configuraciones se logró la generación automática de archivos que almacenan la descripción de resultados procedentes de la técnica LAMP.

Palabras clave: Procesamiento digital de imágenes, segmentación de imágenes, extracción de características, detección automática.

Abstract

Digital image processing has a variety of applications in different areas, such as engineering, robotics, industry, agriculture, and health, to mention a few. When researchers use some colorimetric techniques, certain situations arise in which the support of computational tools is required to be able to accurately identify the color and tone of the results obtained, thus reducing the probability of making errors. The LAMP technique is a tool applied to nucleic acid amplification and is an example of a colorimetric procedure. The proposed solution presented in this research report is the development of a computer program that uses digital image processing to collect the information obtained from the use of the LAMP technique. Feature extraction techniques based on color and shape are used as part of the solution methodology; with the goal of identifying the elements that belong to the samples of interest. After carrying out a series of tests with different configurations, the automatic generation of files that store the description of results from the LAMP technique was achieved.

Key words: Digital image processing, image segmentation, feature extraction, automatic detection.

Recibido: 18 de septiembre de 2023.

Aceptado: 01 de julio de 2024.

¹Instituto de Industrias/ ²Instituto de Genética/ ³Instituto de Ecología, Universidad del Mar, Campus Puerto Escondido. Km. 2.5, Carretera Federal Puerto Escondido - Sola de Vega, 71980, San Pedro Mixtepec, Oaxaca.

* **Autor de correspondencia:** ochoa@zicatela.umar.mx (JOS)

Introducción

Se han encontrado varias publicaciones en la literatura, donde se reportan programas que permiten hacer detección de objetos, utilizando técnicas de procesamiento digital de imágenes. Ochoa-Somuano *et al.* (2016) reportaron los resultados de una investigación relacionada con el proceso para el sexado de plántulas de papaya utilizando procesamiento digital de imágenes; sin embargo, no se ha encontrado alguna investigación que permita procesar de forma automática los resultados de pruebas de laboratorio cuando se utiliza la técnica LAMP; por ello, el aporte que brinda la presente propuesta de solución es importante y viable para ser publicada y replicada en laboratorios de investigación donde utilicen esta técnica.

Para dar una idea y contextualizar algunos problemas que se han resuelto con procesamiento digital de imágenes enfocados a la detección de objetos se presentan algunos trabajos de interés. Juárez-Salinas *et al.* (2014) propuso un algoritmo que utiliza procesamiento digital de imágenes para detectar y evaluar heridas de pie diabético, la propuesta permite detectar de forma automática las úlceras y heridas presentes en el pie del paciente, es capaz de calcular el área y la ubicación de las úlceras y heridas, así como muchas otras características geométricas, si así se desea. Además, los autores comentan que los resultados en la evaluación de las variables ya no dependen del criterio del evaluador.

En el caso de Viera (2017) el principal objetivo consiste en el desarrollo de un sistema de visión artificial para la clasificación de granos de cacao según sus características externas como puede ser el tamaño en la fase final del secado, señalan la importancia de su sistema en cuanto a la reducción de tiempo que puede llevarle

al experto humano realizar el mismo trabajo, ya que el sistema tarda menos de dos segundos en realizar el proceso completo.

En Mejía & Rosales (2019) se busca desarrollar un sistema para la detección, clasificación y medición de diversas especies de peces, usan técnicas de visión por computadora como el algoritmo SURF (*Speeded-Up Robust Features*) y redes neuronales convolucionales. Para el desarrollo de las primeras pruebas se utilizaron imágenes de terceros publicadas en la plataforma *Kaggle*, también realizaron pruebas con un banco de imágenes propias. Se realizaron experimentos con dos especies de peces en dos etapas: detección y clasificación. En la primera reportan un 90% de precisión, en la segunda se tiene una certeza del 80%.

Castruita *et al.* (2020) presentaron una metodología para la detección y clasificación de señales de tráfico mexicanas mediante aprendizaje profundo. La metodología se divide en cinco etapas: la recolección de 1,284 imágenes de señales de tráfico en un ambiente no controlado, la propuesta de un proceso manual para la detección de señales de tráfico en las imágenes, el entrenamiento de una red neuronal convolucional con el conjunto CIFAR-10 para obtener conocimiento amplio de características de diferentes objetos, el uso de una red neuronal convolucional basada en regiones para detectar las señales, y el proceso de transferencia de conocimiento y de aumento de datos para la clasificación con ResNet-50 modificada. De acuerdo con los resultados obtenidos de los experimentos se concluye que la metodología propuesta permite reconocer señales de tráfico mexicanas con una exactitud del 95.33%.

Por otro lado, la técnica de reacción en cadena de la polimerasa (PCR, por sus siglas en inglés) fue concebida por

primera vez en 1992, consiste en la amplificación *in vitro* de una secuencia de nucleótidos específica (Mullis *et al.* 1992), es una técnica ampliamente utilizada en centros de investigación como en biociencias y ciencias forenses (Zhu *et al.* 2020). Al paso del tiempo han surgido variantes a la técnica de PCR y, por ende, sus aplicaciones han aumentado significativamente, como en la identificación del SARS-CoV-2 que desencadena la enfermedad respiratoria del coronavirus-2019 (Sharma *et al.* 2023). Posterior al descubrimiento de la PCR, algunos investigadores (Notomi *et al.* 2000) propusieron una técnica similar, la técnica de amplificación isotérmica mediada por bucle (LAMP, por sus siglas en inglés), ha sido gradualmente adoptada en un sin número de aplicaciones, en la detección del virus de Zika (Silva *et al.* 2019) en agricultura e industria alimenticia, esto por las ventajas sobresalientes que ofrece a diferencia de la PCR, como su alta especificidad de amplificación, facilidad y rapidez para la obtención de resultados (Panno *et al.* 2020).

En la pandemia, fue oportuno la aplicación de la técnica LAMP, esto para detectar de manera oportuna a los pacientes infectados por el COVID-19, pero surgieron algunos inconvenientes, uno de ellos fue la interpretación de los resultados colorimétricos a simple vista. Los investigadores Aoki *et al.* (2021), en su publicación referente a la detección del COVID-19 con la técnica LAMP, mencionaron que normalmente los resultados esperados son sólo dos colores, rosa para un resultado negativo y amarillo para un resultado positivo, pero en algunos casos, ellos registraron un color naranja, difícil de percibirse a simple vista, esta nueva tonalidad fue relacionada a un resultado positivo a la infección pero con una carga viral baja, por lo anterior, al analizar una

gran número de muestras, puede causar incertidumbre al momento de interpretar los resultados de manera correcta y dar al paciente un resultado incorrecto.

Como se puede apreciar, el desarrollo de sistemas automatizados que permitan la detección de objetos mediante procesos de visión por computadora tiene vigencia e importancia en distintas disciplinas. Con base en lo anterior y debido a la trascendencia que tiene la técnica LAMP por la amplia variedad de aplicaciones en que puede ser implementada, surge el interés de hacer una propuesta de un prototipo de software que permita facilitar la adquisición de los resultados obtenidos por la técnica LAMP en poco tiempo.

Materiales y métodos

Para resolver la problemática planteada al inicio del presente documento, se ha propuesto una metodología de solución que consta de tres fases: la primera fase, que comprende las etapas de adquisición de la imagen y la calibración con base en los colores; la segunda etapa (o preprocesamiento) consta de tres etapas: la conversión de la imagen a escala de grises, la segmentación de la imagen y el reconocimiento e interpretación; y por último, la fase de resultados, conformada por la etapa de generación de los mismos (Fig. 1).

Adquisición de la imagen. Se adquiere una imagen digital a partir de una fotografía tomada a una placa de cultivo de 96 pocillos (8x12) que contiene las muestras que fueron analizadas con la técnica LAMP, para la identificación de plántulas hermafroditas de papaya (Carica papaya var. Maradol).

Calibración con base en los colores. Se hace la identificación de los colores que

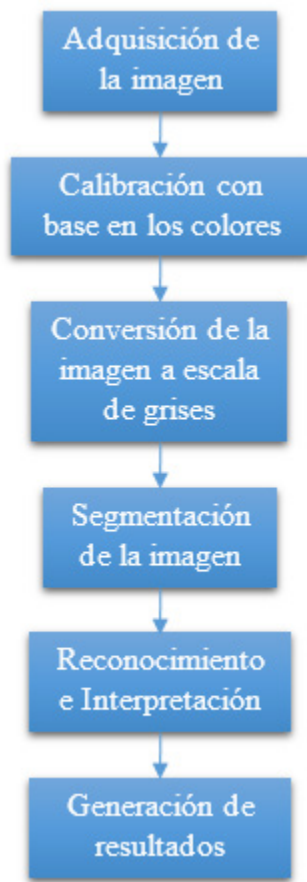


Figura 1. Metodología de solución para la identificación automática de plántulas hermafroditas de carica papaya variedad maradol.

representaran las clases a identificar en la metodología, solo son dos colores que permiten identificar las clases, un color para la clase positiva y otro para la clase negativa. La clase positiva representa las plántulas hermafroditas y la clase negativa representa las plántulas que no son hermafroditas, es decir, masculinas o femeninas.

Conversión de la imagen a escala de grises. Para realizar el proceso de segmentación se debe partir de una imagen en escala de grises por lo que se requiere, en esta etapa, hacer la conversión de la imagen original a color en su representación a escala de grises.

Segmentación de la imagen. Esta etapa es crucial en el proceso de la identificación

de plántulas hermafroditas, ya que es en la que se permite identificar los pozos de la rejilla que contienen la sustancia activa y separarlos del resto para pasar a la etapa de reconocimiento.

Reconocimiento e Interpretación. Con base en los resultados obtenidos en la etapa de calibración y segmentación, se realiza el reconocimiento e interpretación de las muestras que pertenecen a cada una de las clases posibles. El reconocimiento se realiza haciendo una detección con base en el color de los pocillos que no están vacíos y en la interpretación se le da un sentido a cada uno de los colores detectados, es decir, se les asocia a la clase que pertenecen.

Generación de resultados. Finalmente se hace una representación en forma matricial con base en los resultados teniendo en cuenta tres opciones posibles: clase positiva, clase negativa u otra (en esta última opción se agrupa la ausencia de información o algún color que no pertenezca ni a la clase positiva ni a la clase negativa) representada por los símbolos "---". Los resultados se almacenan en un archivo de tipo CSV (datos separados por comas) que puede ser leído por cualquier editor de textos o editor de hojas de cálculo, estos archivos podrán ser utilizados por usuarios finales en la elaboración de reportes en la etapa de experimentación al utilizar la técnica LAMP para el sexado de plántulas de papaya, automatizando de esta manera el proceso de elaboración de reportes.

Pruebas y resultados

Para mostrar los resultados que se obtienen al aplicar la metodología propuesta se han generado una serie de pruebas, mismas que se han realizado con colores artificiales dado el costo que implica

realizar pruebas reales en laboratorio. Sin embargo, es de suma importancia señalar que el sistema se puede calibrar con base en los colores reales sin inconveniente, pues esta es una característica inherente del procesamiento digital de imágenes. Después de cada prueba se describen los resultados. En la primera prueba se describirán las etapas de acuerdo con la metodología descrita en la figura 1, en las pruebas sucesivas, sólo se mostrarán los resultados principales.

Prueba 1. Se utiliza una imagen con solo una muestra por clase, una muestra positiva y una muestra negativa (Fig. 2). La muestra positiva es de color amarillo (clase 1), la negativa de color rojo (clase 2).

El siguiente paso consiste en hacer la calibración con base en los colores que representan a cada una de las clases. En la figura 3 se puede ver el mensaje que aparece una vez que se ha terminado dicho proceso.

La siguiente fase es el procesamiento, el cual está integrado por tres etapas que son parte de la metodología de solución; al ser procesos internos, se muestran los resultados de la separación de las clases en binario en las figuras 4 y 5. Las etapas que comprende son: conversión de la imagen a escala de grises, segmentación de la imagen y reconocimiento e interpretación.

La última etapa es la generación de resultados, en ésta se crea un archivo




Figura 2. Imagen de ejemplo para la prueba 1, con dos muestras, una de cada clase, el color rojo representa la clase negativa, el color amarillo la clase positiva.




Figura 3. Mensaje que da aviso sobre la terminación de la etapa de calibración de los colores para cada una de las clases representativas.




Figura 4. Resultado de la prueba 1 al realizar la separación de la clase 1 de la imagen original.

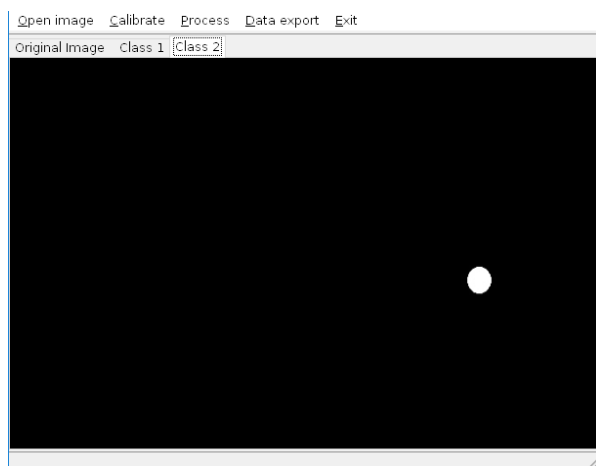


Figura 5. Resultado de la prueba 1 al realizar la separación de la clase 2 de la imagen original.

CSV con los datos que corresponden a las muestras dispuestas en la rejilla, en la tabla I se puede ver su representación.

Prueba 2. Se consideró como entrada una imagen en la que se colocan las

muestras en forma circular, se tienen distribuidas de forma aleatoria 14 muestras de la clase positiva y 12 muestras de la clase negativa. La distribución original de las muestras se puede ver en la figura 6.

En la figura 7 se pueden ver las muestras que solo pertenecen a la clase positiva y en la figura 8 las muestras que conforman únicamente la clase negativa.

En la generación de resultados, se obtiene el archivo CSV con la información que corresponde al llenado de la rejilla con base en la información de las muestras, en la tabla 2 se puede ver el resultado.

Prueba 3. Como imagen de entrada se tomó un grupo de muestras distribuidas en forma rectangular, la distribución se consideró de forma aleatoria, 19 muestras de la clase positiva y 13 muestras de la clase negativa. La distribución de las muestras se presenta en la figura 9.

Después de haber concluido el procesamiento de la imagen, se obtienen las imágenes binarias que representan las dos clases. En la figura 10 se pueden ver las muestras que pertenecen a la clase positiva y en la figura 11 las muestras que conforman la clase negativa.

En la etapa de generación de resultados, se obtiene un archivo CSV con base en la información de las muestras, en la tabla III se puede ver la salida de este último proceso.

Prueba 4. Se consideró como entrada para la presente prueba una imagen en la que agrega información que no pertenece a ninguna de las dos clases con las que se está trabajando. El objetivo de esta prueba se enfoca en la habilidad que tiene el programa para discriminar posibles sustancias que no pertenecen a los experimentos. Para ello se utilizó un color diferente, de tal manera que el programa debe omitir

Tabla I. Resultado de la generación de datos de salida en un archivo CSV, a partir de la prueba 1.

fil/col	1	2	3	4	5	6	7	8	9	10	11	12
1	-	-	-	-	-	-	-	-	-	-	-	-
2	-	-	-	-	-	-	-	-	Positive	-	-	-
3	-	-	-	-	-	-	-	-	-	-	-	-
4	-	-	-	-	-	-	-	-	-	-	-	-
5	-	-	-	-	-	-	-	-	-	-	Negative	-
6	-	-	-	-	-	-	-	-	-	-	-	-
7	-	-	-	-	-	-	-	-	-	-	-	-
8	-	-	-	-	-	-	-	-	-	-	-	-




Figura 6. Imagen de ejemplo para la prueba 2, con 26 muestras, 14 pertenecen a la clase positiva (amarilla) y 12 a la clase negativa (roja).

Tabla II. Resultado de la generación de datos de salida en un archivo CSV, a partir de la prueba 2.

fil/col	1	2	3	4	5	6	7	8	9	10	11	12
1	-	-	-	-	-	-	-	-	-	-	-	-
2	-	-	-	-	-	-	Positive	Negative	Negative	-	-	-
3	-	-	-	-	-	Negative	Negative	Positive	Positive	Negative	-	-
4	-	-	-	-	-	Positive	Positive	Positive	Positive	Positive	Negative	-
5	-	-	-	-	-	Positive	Negative	Positive	Negative	Positive	-	-
6	-	-	-	-	-	-	Negative	Positive	Positive	Negative	-	-
7	-	-	-	-	-	-	Positive	Negative	Negative	-	-	-
8	-	-	-	-	-	-	-	-	-	-	-	-

Tabla III. Resultado de la generación de datos de salida en un archivo CVS, a partir de la prueba 3.

fil/col	1	2	3	4	5	6	7	8	9	10	11	12
1	—	—	—	—	Positive	Positive	Positive	Negative	—	—	—	—
2	—	—	—	—	Negative	Negative	Positive	Positive	—	—	—	—
3	—	—	—	—	Positive	Positive	Negative	Positive	—	—	—	—
4	—	—	—	—	Negative	Positive	Negative	Negative	—	—	—	—
5	—	—	—	—	Positive	Negative	Positive	Positive	—	—	—	—
6	—	—	—	—	Negative	Positive	Positive	Negative	—	—	—	—
7	—	—	—	—	Positive	Negative	Negative	Positive	—	—	—	—
8	—	—	—	—	Positive	Positive	Positive	Negative	—	—	—	—

esa información de entrada y se debe enfocar exclusivamente en los rangos de color para los que se ha calibrado inicialmente. Las muestras tienen una distribución similar a la prueba 3 con la particularidad de que se tienen 4 muestras contaminadas, 15 muestras de la clase positiva y 13 muestras de la clase negativa. La distribución de las muestras se puede apreciar en la figura 12.

Una vez concluido el procesamiento de la imagen, se generan las imágenes binarias que representan las dos clases. En la figura 13 se pueden ver las muestras que pertenecen a la clase positiva y en la figura 14 las muestras de la clase negativa.

Como se puede apreciar, los datos contaminados no aparecen ni en la figura 13, ni en la figura 14, debido a que el programa ignora las muestras contaminadas tal como se esperaba.

En el proceso de generación de resultados, se obtiene el archivo CSV con base en la información de las muestras, en la tabla 4 se puede ver el resultado.

También se puede apreciar en la tabla IV que, en el llenado de la información, las celdas que corresponden a las muestras contaminadas se rellenan como si no hubiera información en la imagen, acción prevista en la programación del software.

Prueba 5. En esta última prueba se consideró como entrada una imagen en la que se colocan las muestras en toda la rejilla, se tienen distribuidas de forma aleatoria 53 muestras de la clase positiva y 43 muestras de la clase negativa. La distribución de las muestras se puede ver en la figura 15.

Al finalizar el procesamiento de la imagen, se generan las imágenes binarias




Figura 7. Grupo de muestras que pertenecen a la clase 1, resultado de la prueba 2.




Figura 8. Grupo de muestras que pertenecen a la clase 2, resultado de la prueba 2.




Figura 9. Imagen de ejemplo para la prueba 3, con 32 muestras, 19 pertenecen a la clase positiva (amarilla) y 13 a la clase negativa (roja).




Figura 10. Grupo de muestras que pertenecen a la clase 1, resultado de la prueba 3.




Figura 11. Grupo de muestras que pertenecen a la clase 2, resultado de la prueba 3.

que representan las dos clases. En la figura 16 se pueden ver las muestras que pertenecen a la clase positiva y en la figura 17 las muestras de la clase negativa.

En la etapa de generación de resultados, se obtiene un archivo en formato CSV con la información que corresponde al llenado de la rejilla con base en la información de las muestras. En la tabla V se puede ver la

salida de este último proceso, por espacio se modificó la información del archivo original, de tal manera que se utiliza para las muestras negativas (Neg) y para las muestras positivas (Pos).

Discusión

Cuando los investigadores hacen trabajo




Figura 12. Imagen de ejemplo para la prueba 4, con 32 muestras, 4 se consideran contaminadas (verde), 15 pertenecen a la clase positiva (amarilla) y 13 a la clase negativa (roja).




Figura 13. Grupo de muestras que pertenecen a la clase 1, resultado de la prueba 4.




Figura 14. Grupo de muestras que pertenecen a la clase 2, resultado de la prueba 4.

de laboratorio, su principal objetivo es obtener resultados con base en la experimentación de su línea de investigación o de algún proyecto en específico. Su concentración debe estar enfocada en el seguimiento de sus metodologías para obtener resultados confiables y procesos que deben cumplir con una estructura bien definida; sin embargo, para cumplir con lo mencionado anteriormente, también

deben dedicar una buena parte de su tiempo a la recopilación de los resultados principalmente en papel, y posteriormente también deben dedicar más tiempo a la digitalización de dichos resultados, con la intención de plasmarlos finalmente en un documento, que bien puede ser un reporte de investigación, notas personales o principalmente en algún artículo científico que pueda publicar en algún medio de difusión. La integración de técnicas de




Figura 15. Imagen de ejemplo para la prueba 5, con 96 muestras, 53 pertenecen a la clase positiva (amarilla) y 43 a la clase negativa (roja).




Figura 16. Grupo de muestras que pertenecen a la clase 1, resultado de la prueba 5.




Figura 17. Grupo de muestras que pertenecen a la clase 2, resultado de la prueba 5.

Inteligencia Artificial, específicamente las involucradas en el procesamiento digital de imágenes, permite que a partir de una imagen digital se pueda obtener un archivo en formato CSV para la representación de los resultados en la experimentación de laboratorio, para este caso de investigación, específicamente en la interpretación de resultados utilizando la técnica LAMP.

Conclusiones

La generación automática en la interpretación de resultados de laboratorio tiene un importante aporte para minimizar los tiempos en la documentación que tienen que realizar los investigadores. El hacer un “vaciado” de forma manual a una hoja de cálculo u otro medio electrónico implica la inversión de tiempo, en ocasiones excesivo, dado que al hacer la anotación de

Tabla IV. Resultado de la generación de datos de salida en un archivo CVS, a partir de la prueba 4.

fil/col	1	2	3	4	5	6	7	8	9	10	11	12
1	—	—	—	—	—	Positive	Positive	Negative	—	—	—	—
2	—	—	—	—	Negative	Negative	Positive	Positive	—	—	—	—
3	—	—	—	—	Positive	Positive	Negative	—	—	—	—	—
4	—	—	—	—	Negative	Positive	Negative	Negative	—	—	—	—
5	—	—	—	—	Positive	Negative	Positive	Positive	—	—	—	—
6	—	—	—	—	Negative	—	Positive	Negative	—	—	—	—
7	—	—	—	—	Positive	Negative	Negative	—	—	—	—	—
8	—	—	—	—	Positive	Positive	Positive	Negative	—	—	—	—

Tabla V. Resultado de la generación de datos de salida en un archivo CVS, a partir de la prueba 5.

fil/col	1	2	3	4	5	6	7	8	9	10	11	12
1	Neg	Neg	Neg	Neg	Neg	Neg	Neg	Neg	Pos	Neg	Neg	Pos
2	Pos	Pos	Neg	Pos	Pos	Neg	Neg	Neg	Pos	Neg	Pos	Pos
3	Pos	Neg	Pos	Pos	Neg	Pos	Neg	Pos	Neg	Neg	Pos	Neg
4	Neg	Pos	Neg	Pos	Pos	Neg	Pos	Neg	Pos	Pos	Pos	Neg
5	Pos	Pos	Pos	Neg	Neg	Neg	Neg	Pos	Pos	Neg	Pos	Pos
6	Neg	Pos	Neg	Pos	Pos	Pos	Neg	Pos	Neg	Pos	Neg	Pos
7	Pos	Neg	Pos	Pos	Neg	Neg	Pos	Pos	Pos	Neg	Pos	Neg
8	Neg	Neg	Pos	Pos	Pos	Pos	Pos	Pos	Pos	Pos	Pos	Pos

forma individual por muestra, o bien, por pequeños grupos, puede ser tedioso y cansado ya que se tiene que llevar un control sobre los pozos de la rejilla de muestras que ya se han vaciado al medio digital, además se invierte tiempo innecesario por parte del investigador para volver a ubicarse en qué pozo se quedó y volver a tomar nota de los datos.

Con el programa que se presenta como resultado de la presente investigación, sólo se toma la fotografía de las muestras y el programa se encarga del proceso de levantamiento de datos de forma semiautomática, ya que debe elegir qué imagen es la que debe procesar. Sin embargo, el llenado del archivo en formato CSV se efectúa de forma automática. A partir del archivo que se genera, se pueden tomar los datos para insertarlos en el reporte o artículo que estén escribiendo con los resultados de su investigación, lo que

permite un ahorro de tiempo en dicho proceso. Con base en los mismos resultados y sobre el mismo archivo, los investigadores podrían generar gráficas u otro tipo de representación de los datos como lo hacen de forma habitual.

Agradecimientos

Los autores agradecen el apoyo económico recibido por parte del Programa para el Desarrollo Profesional Docente (PRODEP) para la realización de la presente investigación, así como a la Universidad del Mar por las facilidades recibidas. También agradecemos a los árbitros anónimos que se dieron el tiempo de revisar y nutrir el presente documento.

Referencias

Castruita, R., C. Mendoza, O.O. Vergara, & V.G. Cruz. 2020. Detección y clasificación de señales de tráfico mexicanas mediante aprendizaje profundo,

- Research in Computing Science 149(8): 435-449, ISSN 1870-4069.
- Juárez-Salinas, J.J., L.O. Solís-Sánchez, R. Castañeda-Miranda, J.M. Ortiz-Rodríguez & H. Gamboa-Rosales. 2014.** Algoritmo de procesamiento digital de imágenes para la detección y evaluación de heridas de pie diabético, *Revista de difusión científica, ingeniería y tecnologías* 8(1): 11-16.
- Mejía, R. & G. Rosales. 2020.** Sistema de detección y clasificación de peces utilizando visión computacional. Pp. 127-141. *Actas del II Congreso Internacional de Ingeniería de Sistemas*, DOI: 10.26439/ciis2019.5507.
- Mullis, K., F. Faloona, S. Scharf, R. Saiki, G. Horn, & H. Erlich. 1986.** Specific enzymatic amplification of DNA *in vitro*: the polymerase chain reaction, *Cold Spring Harbor Symposia on Quantitative Biology*, Volume 51: pp. 263-273. DOI: 10.1101/sqb.1986.051.01.032.
- Notomi, T., H. Okayama, H. Masubuchi, T. Yonekawa, K. Watanabe, N. Amino, & T. Hase. 2000.** Loop-mediated isothermal amplification of DNA, *Nucleic acids research*, 28(12): e63i-e63vii. DOI: 10.1093/nar/28.12.e63.
- Ochoa-Somuano, J., F.G. Ruiz-Ruiz, J.K. Cruz-Vázquez, & V. Ortega-Brandá. 2016.** Extracción de variables mediante la técnica SIFT para la identificación de plántulas de papaya de tipo hermafrodita, *Revista Ciencia y Mar*, XX(58): 59-67, ISSN: 1665-0808.
- Panno, S., S. Matić, A. Tiberini, A.G. Caruso, P. Bella, L. Torta, R. Stassi & S. Davino. 2020.** Loop mediated isothermal amplification: principles and applications in plant virology *Plants*, 4(4): p 461. DOI: 10.3390/plants9040461.
- Sharma, S., S. Shrivastava, S.B. Kausley, B. Rai, & A.B. Pandit. 2023.** Coronavirus: a comparative analysis of detection technologies in the wake of emerging variants, *Infection* 51(1): 1-19. DOI: 10.1007/s15010-022-01819-6.
- Ribeiro, S.J., K. Pardee, & L. Pena. 2020.** Loop-mediated isothermal amplification (LAMP) for the diagnosis of Zika virus: a review *Viruses*, 12(1): p 19. DOI: 10.3390/v12010019.
- Viera, G. 2017.** Procesamiento de imágenes usando OpenCV aplicado en Raspberry Pi para la clasificación del cacao. Tesis de licenciatura en Ingeniería Mecánico-Eléctrica, Universidad de Piura, Facultad de Ingeniería. Programa Académico de Ingeniería Mecánico-Eléctrica. Piura, Perú.
- Zhu, H., H. Zhang, Y. Xu, S. Laššáková, M. Korabečná & P. Nežil. 2020.** PCR past, present and future, *Biotechniques* 69(4): 317-325. DOI: 10.2144/btn-2020-0057.