




Deep Learning to support the recognition of pests and diseases in Yungay potato crops in the province of Cutervo, Angurra hamlet, Perú

Huarote Zegarra Raúl Eduardo, Maestro¹  Elis Dina Cabrera Herrera, Bachiller² , and Katherine Susan Llanos Chacaltana, Maestro³ 

¹Universidad Nacional Tecnológica de Lima Sur, Perú, rhuarote@untels.edu.pe

²Universidad Católica Santo Toribio De Mogrovejo, Perú, dinielys_23@hotmail.com

³Universidad Privada del Norte, Perú, susan.llanos@upn.edu.pe

I. INTRODUCCIÓN

Abstract– The present investigation efficiently covers the need to classify according to the diseases or pests of the Yungay potato leaf in the province of Cutervo, Angurra village (Peru), specifically classify them as fly plague (PM=1), weevil plague (PG=2), streak disease (ER=3) or as no plague (SP=0). To achieve this, the digital images have necessarily been prepared to decrease in size and at the same time obtain their representative, this in order to enter the SOM neural network (self-organizing map). The functions based on artificial vision for the preparation of the image (in jpg format of varied dimensions), to the shots of the potato leaves, are 1200 images for training and another 1200 for tests, only the image being extracted from each scene. sheet, scaled to a dimension of 256x256 pixels to homogenize, extract its characteristics from each disease and passed to a tone of gray to be learned in the neural network, managing to verify with this sequence an accuracy of 99.42%, a sensitivity of 1.0, 0.99, 0.99, 1.0, a specificity of 0.99, 0.99, 1.0, 0.99 for SP, PM, PG, ER respectively in identifying disease class.

Keywords-- yungay potato, pests, classification, artificial vision, SOM neural network.

Resumen– La presente investigación cubre de manera eficiente la necesidad de clasificar de acuerdo a las enfermedades o plagas de la hoja de papa Yungay en la provincia de Cutervo caserío Angurra (Perú), específicamente clasificarlas en Plaga de la mosca (PM=1), Plaga del gorgojo (PG=2), Enfermedad de la Ranca (ER=3) o como Sin plaga (SP=0). Para lograr esto necesariamente se ha preparado las imágenes digitales para disminuir en tamaño y a la vez obtener su representativo, esto con el fin de ingresar a la red neuronal SOM (mapa autoorganizativo). Las funciones basadas en visión artificial para la preparación de la imagen (en formato jpg de dimensión variada), a las tomas de las hojas de papa, son 1200 imágenes para el entrenamiento y otros 1200 para las pruebas, siendo extraídas de cada escena sólo la hoja, escalada a una dimensión de 256x256 píxeles para homogenizar, extraer sus características de cada enfermedad y pasadas a tono de gris para ser aprendidas en la red neuronal, logrando comprobar con esta secuencia una precisión de 99.42%, una sensibilidad de 1.0, 0.99, 0.99, 1.0, una especificidad de 0.99, 0.99, 1.0, 0.99 para SP, PM, PG, ER respectivamente en la identificación de clase de enfermedad.

Palabras clave— Papa yungay, plagas, Clasificar, visión artificial, Red neuronal SOM.

Actualmente la papa llamado científicamente *Solanum tuberosum* originario de Perú, es uno de los cinco tubérculo más cultivado por diversos países, con una creciente demanda en todos los continentes, tal así [1] resalta el consumo diario de papa a nivel mundial supera los mil millones de toneladas, entre ellos [2] resalta a China en el 2020 llegó a producir el 21.8% del total de producción de papa a nivel mundial, siendo este total de 354,812,093 toneladas, el segundo productor es la India con 14.3% (51,300,000), seguido de Ucrania con 5.8% (20,837,990), Rusia con 5.6% (19,607,361), Estados Unidos con 5.4% (18,789,97), entre otros países productores. En países sudamericanos tal es el caso de Perú esta primero en la lista con 5 467 041 toneladas de producción, seguido de Brasil con 3 767 769, Colombia con 2 625 272 toneladas, Argentina con 2 426 526 toneladas, entre otros países de la región. Cabe resaltar que para [3] en Perú cuenta con más de 4 mil variedades de papas, siendo las zonas altoandinas donde más se cultiva este tubérculo, con más de 40 variedades de papa, entre ellas Huagalina, Amarilla Tumbay, Amarilla del Centro, Peruanita, Huayro, Huamantanga, Ccompis, Yana Imilla, Yungay, entre otros. Sin embargo, su producción se ve afectada por múltiples factores, tal es el caso de las plagas y enfermedades que invaden el cultivo, evitando que crezcan y se desarrollen de manera normal, a pesar que [4] considera que los trabajos articulados entre el SENASA, el Instituto Nacional de Innovación Agraria (INIA), el Centro Internacional de la papa (CIP), el Gobierno regional de Piura, Municipalidad Provincial de Huancabamba diagnóstica que las causas que vienen originando la falta de formación del tubérculo de papa son por la plaga. Estas plagas mayormente se detectan cuando el cultivo está bastante afectado, lo cual dificulta su tratamiento, tal es el caso de la plaga mosca minadora, ranca, del gorgojo, etc, pero si se pudieran detectar a tiempo se podría llegar a realizar una fumigación con el tratamiento adecuado para que el cultivo no se vea perjudicado y se pueda controlar. A nivel mundial China como primer productor de papa también padece la plaga llamada *Phthorimaea operculella* que comúnmente se conoce como polilla afectando perjudicialmente a los cultivos en sectores secos y

Digital Object Identifier: (only for full papers, inserted by LACCEI).

ISSN, ISBN: (to be inserted by LACCEI).

DO NOT REMOVE

cálidos. En Colombia, como lo hace notar [5], también lo padecen por la plaga de *Rhizoctonia solani* afectando su producción y que puede llevar a la totalidad de la misma.

En este sentido la mayoría de los agricultores de papa a nivel mundial y Perú presentan problemas y deficiencias por no saber dar un tratamiento adecuado a la tierra antes de sembrar, sobre todo aquellos cultivos que presentaron alguna enfermedad o plaga, que contaminan no solo al cultivo sino a la tierra, inhabilitando al terreno por un promedio de tres años, la llamada cuarentena del terreno, hasta que la bacteria desaparezca, en este caso no se puede conservar ninguna semilla que haya sido infestada por esta plaga porque si no va a ir propagándose[6].

Por otro lado, en el Perú, se cultivan aproximadamente 5 467 toneladas en 215 mil 710 hectáreas de papa, siendo uno de los productos banderas del país, su cultivo mayormente se da en la sierra norte y sur del país. Sin embargo, al igual que en otros países, en Perú también existen problemas de plagas y enfermedades que disminuyen la producción hasta en un 80%, tal es el caso de la Plaga de la mosca, Plaga del gorgojo, Enfermedad de la Ranchara, entre otras. Siendo La ranchara y la bacteria son las enfermedades que más se presentan en los cultivos, en muchos casos se llega a perder el 70% de la producción por descuido o desconocimiento del agricultor [6].

En este sentido los cultivos de papa del caserío de Angurra, ubicado en la provincia de Cutervo Departamento Cajamarca-Perú, en donde el cultivo de papa es el más importante fuente de ingreso de la zona, cuya producción data de un promedio de mil hectáreas se sembró de papa, donde para el año 2023 se pretende elevar a un 5% más esta cantidad, a pesar que los costos de los insumos agrícolas se han incrementado hasta en un 56% en comparación a meses anteriores donde el producto costaba la mitad de lo que está costando hoy en día. Dentro de las variedades de papa que se cultivan están: La papa Amarilis, Yungay, Chaucha, Canchan y la Única, siendo la Yungay la que más se cultiva en la zona.

Sin embargo, los cultivos de esta zona se ven afectados continuamente por plagas y enfermedades que provocan grandes problemas en la producción, ocasionándoles gastos importantes para la fumigación, por otro lado, en cuanto a la mano de obra se ven en la necesidad de contratar personas que se encarguen de la fumigación del cultivo de papa.

La enfermedad que más ataca sus cultivos es la ranchara, que puede llegar a presentarse hasta en un 1% en el cultivo de papa, sin embargo, se llega a proliferar en cuestión de días, debido a que se expande rápidamente. Esta enfermedad ocasiona que las hojas del cultivo tomen un color negro, llegando a tener un aspecto a quemado, lo cual ocasiona que la planta se debilite por ende disminuya su producción.

Así también para [7], la plaga de la mosca minadora. Esta mosca en su etapa adulta se encuentra reposando en las hojas, iniciando daño en las hojas, debido a que de adultas se alimentan del mesófilo de las hojas, presentándose como minas de puntos blancos dentro de la hoja, disminuyendo su capacidad

fotosintética, al inicio se puede presentar en un 10% de afectación de la hoja sin embargo, sino se controla llega a expandirse al 100% afectando la producción.

Por último, el gorgojo de los andes, que al igual que la mosca minadora se alimenta del mesófilo de la planta, en este caso deja las hojas cortadas en media luna, es una plaga que se prolifera de noche y cuando hay lluvias se incrementa de 16% a 45% de la producción, si el agricultor no lleva un control rutinario adecuado o desconoce de estas plagas, la plaga avanza rápidamente causando pérdidas del 80% al 100%.[8].

Por tanto es muy necesario tomar en cuenta estos sucesos y estadísticas de afectación de la planta de cultivo de la papa Yungay, en el contexto del análisis y aplicación de diferentes funciones en el campo de la ciencia, específicamente en la inteligencia artificial, para identificar la clase de plaga a la que pertenece estas hojas de papas y poder ser aplicados en un medio tecnológico más accesible y de modo masivo como en la web, aplicativo móvil, etc.

En este campo se han suscitado múltiples y relevantes investigaciones, con el fin de mitigar la afectación de plagas en los diferentes cultivos, tales como [9] utilizó el método de clasificación basados en redes neuronales convolucionales (CNN) para el reconocimiento de imágenes de cultivos infectados de plagas de insectos en el campo, en su fase de larva para realizar un tratamiento temprano, reduciendo oportunamente la pérdida de rendimiento en los productos agrícolas, logrando un nivel de precisión de reconocimiento del 98,4% en la identificación de 30 clases de larvas.

También [10] ha aplicado su sistema de control de plagas IBPIS, ha logrado una mejorar el 64.6% de los agricultores respecto al control de plagas, ya que tienen una información disponible, para que les ayude a tomar decisiones para el control de plagas.

También [11] ha usado un modelo de red residual para extraer completamente las características de la plaga de 25 378 imágenes y 24 categorías, logrando una precisión de 72.5% en la identificación de la plaga.

En otra investigación de [12] usó un método moderno y no destructivo como es la visión artificial y el aprendizaje profundo por medio de una red neuronal, para la detección temprana de plagas en productos agrícolas. Tomándose como muestras a las 1519 imágenes de cítricos en tres etapas: 1) antes de la infestación de plagas, 2) al comienzo de la infestación de frutos y 3) ocho días después de la segunda etapa, en condiciones de luz natural (7000–11 000 lux). Los cuales fueron usados para clasificar las imágenes el 70% para la etapa de entrenamiento de la red, El 10% y el 20% de las imágenes se utilizaron para las etapas de prueba o testeo, obteniendo una precisión de 99.34%.

Otra investigación vinculada a la detección precisa de enfermedades y plagas, específicamente en el algodón, donde [13] ha usado el modelo YOLOX, el cual le ha realizado ciertas mejoras en su código fuente, con un total de 5760 imágenes de plagas y enfermedades del algodón de diferentes

tipos de plagas de algodón, alcanzando el 94,60%, de precisión en su investigación, adicionalmente que este modelo fue aplicado en campo, ósea en tiempo real.

En otras investigaciones vinculadas al presente contexto encontramos a [14] donde implementa un sistema cuantitativo completo para aportar mucha información, como el nivel de desastre de plagas, el consumo de plaguicidas y las estrategias de control de plagas, basándose de las imágenes obtenidas de campo para ser aplicada en una red convolucional deformable para debilitar la influencia de los cambios de forma de las plagas, logrando obtener una precisión de 93.2%.

Desde el punto de vista internet de las cosas [15] donde en la fase de crecimiento de las plantas, toma información general y predice la infestación de plagas de cultivo, donde utiliza para mejorar la predicción inferencia difusa optimizada. Logrando identificar el momento adecuado para la realización del plantío de cultivo con el fin de que la ocurrencia de la plaga sea la mínima posible.

Por tanto la presente investigación pretende apoyar a en la detección de tipos de plagas en la papa Yungay, Usando como herramienta la visión artificial y la red neuronal artificial (específicamente la red neuronal SOM), para tener un criterio más cercano en la clasificación de tipos de plagas.

II. MODELO USADO

Con el objetivo de llegar a clasificar los diferentes tipos de plagas, necesariamente se tiene que ver cuál es la secuencia adecuada para lograr dicho objetivo, más si es que en diferentes investigaciones vinculados a la presente investigación tienen una tasa de precisión alta, por tanto es necesario mirar las secuencia hechas por otros investigadores para hacer posteriormente un símil, tales como [16] donde usa la conversión a patrones de entrada previa al ingreso de las redes neuronales artificiales, aplicando una serie de pasos que impiden los contactos neuronales (específicamente en la vinculación a una capa oculta específica) de manera aleatoria en el proceso de aprendizaje, siendo procesos de manera dinámica en tiempo y espacio. En otra investigación donde aplica una secuencia de pasos, donde [17] logra clasificar los tipos de células, tomando como base el análisis a nivel de pixeles de la vinculación morfológica de la proyección axonal, logrando cambiar en función del tiempo, encontrando una valuación adecuada, dentro de la variedad de opciones. También [18] dentro de la secuencia de pasos aplica un criterio sensoriomotor a las neuronas, para lograr separar las formas usando modelo lineal generalizado. Así la secuencia usada por [19] para la detección de Covid-19 basado en imágenes de torax, el cual aplica visión artificial fue a partir de la eliminación de ruido y el alargamiento de pixeles de la imagen previa al ingreso de la red neuronal artificial, mejorando dentro de la matriz de confusión a la sensibilidad y especificidad. Otra secuencia aplicada por [20] consiste en utilizar previamente al ingreso de datos a la red neuronal artificial, a cada una de las imágenes la extracción de la

información del PSD y la aplicación morfológica, a partir de ello se obtiene los datos para el entrenamiento de la red neuronal BiLSTM. En el campo de la energía [21] realiza un conjunto de pasos basado en CEEMDAN, como parte de obtención de datos en sus representativos, que estos pueden ser de menor dimensión y a la vez no perder los patrones característicos de cada escena y posteriormente aplicar a las redes neuronales artificiales, para poder pronosticar entre otras cosas a la radiación solar con una precisión mayor. También en la investigación de [22] aplica el proceso primero a las imágenes, resaltando en sus contornos (como resalte de bordes) con una combinación de modelos de resalte de contornos como el CT y GTV, para tener los datos específicos para el ingreso a la red neuronal artificial y así poder tener una mejor predicción en los diferentes resultados clínicos a partir de los datos de cáncer de H&N.

Así para la presente investigación se realiza la siguiente secuencia previa para el ingreso de patrones característicos de la red neuronal artificial. Tal como se muestra en la Fig 1. Realiza un gráfico genérico de este punto acerca de la secuencia previa para la obtención de datos en un formato idóneo para el ingreso a las redes neuronales artificiales a las imágenes de las hojas.

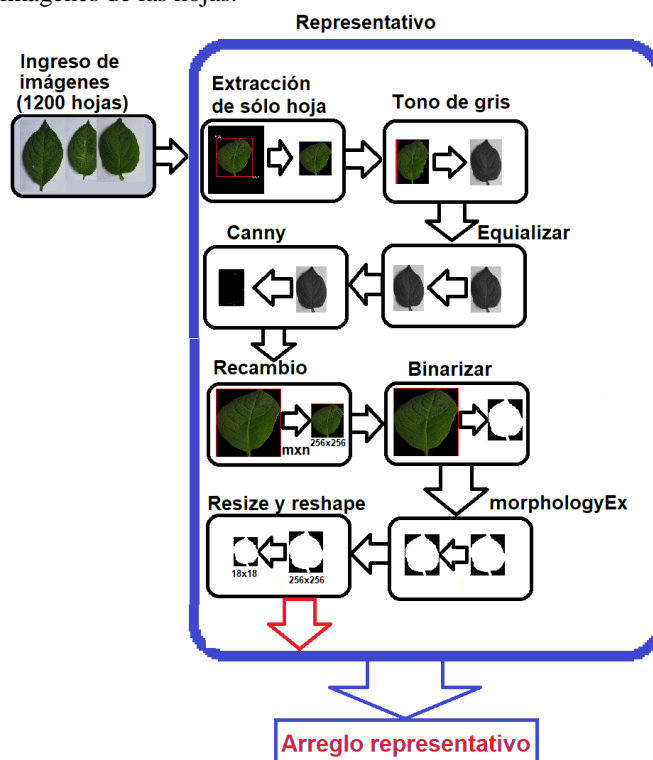


Fig. 1 Secuencia de pasos para obtener su representativo

En la Fig 2, se muestra cada uno de las clases de plagas para realizar el agrupamiento de las imágenes en formato jpg y tienen una dimensión variada mxnx3 (no especifica, puesto que son tomadas de diferentes fuentes), es necesario aplicar la secuencia de pasos, ya que después de aplicar dicha secuencia

se obtiene su representativo en dimensión 18x18 de cada imagen Si este último se le estira a se obtendrá un arreglo de 1x324 (estándar para el ingreso a la red neuronal SOM), con valores de [0 a 255] y también son valores enteros para ser ingresados a la red neuronal SOM para el aprendizaje.

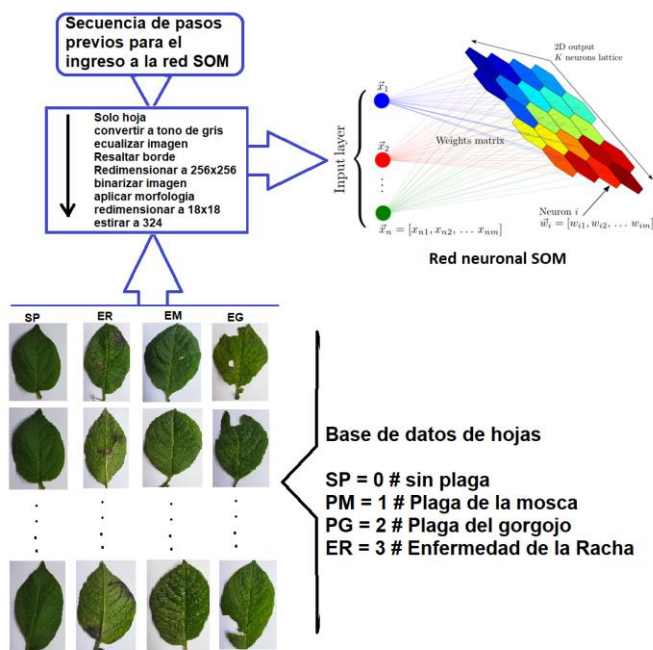


Fig. 2 Secuencia de pasos hasta ingresar a la red SOM

El conjunto de imágenes que es la base de datos de hojas, tienen la particularidad de padecer plaga de la mosca (PM=1), plaga del gorgojo (PG=2), enfermedad de la racha (ER=3) o sin plaga (SP=0), que consta de un conjunto de 400 imágenes de cada uno, así como para el testeo se tiene un conjunto de imágenes ejemplares de las 3 clases, el cual no es parte del entrenamiento. Cada imagen de la hoja es una imagen en RGB de dimensión variable, pero que está dentro de una carpeta asociada con una etiqueta de PM, PG, ER y SP, haciendo referencia a cada tipo de plaga de la papa. Por tanto son 3 clases las que se van a considerar para la presente investigación y una clase de la hoja de la papa sin plaga. Las imágenes de esta fuente de datos de hojas en los diferentes escenarios de plaga o sin plaga, sirven para poder comprobar la investigación de agruparlas en las 3 clases establecidas y para la evaluación comparativa de los algoritmos de aprendizaje automático basado en red SOM. Teniendo en cuenta que para la evaluación o mapeo o comprobación se debe realizar el mismo procedimiento a las imágenes para el entrenamiento (ósea hacer su representativo), por lo tanto deben tener el mismo tamaño de imagen y estructura de divisiones de entrenamiento y prueba. Por tanto proporciona el insumo necesario para poder aplicar en esta investigación.

Cada ejemplar de entrenamiento y prueba se asigna a una de las siguientes etiquetas:

- 0 SP Sin plaga
- 1 PM Plaga de la mosca
- 2 PG Plaga del gorgojo
- 3 ER Enfermedad de la racha

III. INTELIGENCIA ARTIFICIAL

Para [23] considera a la inteligencia artificial como “el medio por el cual las computadoras, los robots y otros dispositivos realizan tareas que normalmente requieren de inteligencia humana”, así también para [24] considera a la inteligencia artificial “es el estudio de cómo lograr que las computadoras realicen tareas que, por el momento, los humanos hacen mejor”, también [25] afirma que para la inteligencia artificial “es la rama de la ciencia de la computación que se ocupa de la automatización de la conducta inteligente”, así también [26] asevera que “el medio por el cual las computadoras, los robots y otros dispositivos realizan tareas que normalmente requieren de la inteligencia humana”. También [27] afirma que la inteligencia artificial puede definirse como “si bien es imposible pronosticar con precisión lo que se puede esperar de esta disciplina en el futuro, es evidente que las computadoras que posean una inteligencia a nivel humano o superior, tendrán repercusiones importantes en la vida diaria, así como en el devenir de la civilización”. Otro punto de vista [28] considera que la inteligencia artificial “está formada por una serie de algoritmos lógicos suficientemente entrenados a partir de los cuales las máquinas son capaces de tomar decisiones para casos concretos a partir de normas generales”, aseverando que va a ser parte de nuestra cotidianidad, ya que ello nos facilita las labores en diferentes aspectos y toma cierto grado de autonomía por nosotros. También para [29] considera a la inteligencia artificial como “la construcción de algoritmos ha logrado que las computadoras y las máquinas aprendan a resolver problemas” en los diferentes campos como la medicina, entre otros campos.

Por tanto la inteligencia artificial emula en lo posible todas las capacidades propias del humano plasmadas en algoritmos, agenciándose de tecnologías de información (software y hardware) para su implementación.

A. Visión artificial

Para [30] permite que las computadoras y los sistemas obtengan información significativa de imágenes digitales, videos y otras entradas visuales, y tomen medidas o hagan recomendaciones basadas en esa información.

Por tanto la visión artificial se basa extraer información a partir de una escena.

Para el caso en particular, se tiene usar esta herramienta para poder resaltar los patrones característicos de la hoja de papa Yungay con las plagas o enfermedades si las tuviese.

B. Red neuronal artificial

Para [31] las redes neuronales artificiales “están formadas por capas de variables interconectadas entre sí con unos pesos que el algoritmo va calculando y ajustando mediante iteraciones (repeticiones) de un proceso que se conoce como «descenso del gradiente»”. Para [32] atribuye el éxito de las redes neuronales artificiales en usar varios algoritmos de optimización y varias estructuras de la red, como la normalización por lotes.

Por tanto la red neuronal artificial emula en algoritmos la manera de aprender basándose del modelo biológico del humano, a pesar que existen otros factores o niveles que aún no están contempladas.

C. Red neuronal SOM

Para [33] ha mostrado el modelo de red neuronal autoorganizativo, en una red en el cual no se considera un tutor en el proceso de aprendizaje, para lograr ello se basó en la manera como la información es captada a través de los órganos sensoriales de los animales (específicamente en el córtex superior), donde las zonas detectoras se ordenan y representan internamente formas de mapas bidimensionales (la capa competitiva), donde compiten y se agrupan según las características resaltantes de cada imagen ingresadas. Este tipo de red neuronal permite clasificar de acuerdo a los patrones característicos, este tipo de red neuronal tiene un aprendizaje basado en competencia, por tanto no se considera un tutor para que maneje el error en el proceso de aprendizaje, ya que no se considera un valor deseado en el cual tienda los resultados. Formalizado en la ecuación 1 para encontrar la neurona vencedora ya se realiza por un método competitivo, la ecuación 2 refleja la actualización de pesos y la ecuación 3 para encontrar el radio. En la Fig. 3 un ejemplo de agrupación de datos mediante colores. Este modelo de clasificación por medio de la red SOM se puede aplicar en la clasificación plagas de la papa Yungay a partir de las imágenes que son obtenidas en campo, considerando los parámetros de entrada posterior a la obtención del representativo para poder utilizar la red neuronal.

$$\min \|X_p - W_j\| = \min \sum_{i=1}^N (X_{pi} - W_{ji})^2 \quad (1)$$

Dónde: $X_p: X_{p1}, X_{p2}, \dots, X_{pN}$, y el vector de pesos W_j :

$$W_{j1}, W_{j2}, \dots, W_{jN}$$

$$\Delta W_{ji}(n+1) = \alpha(n)(X_{pi} - W_{ji}(n)) \quad (2)$$

Donde n : es el número de ciclos, α es la tasa de aprendizaje

$$r(t) = r_0 e^{-\frac{t}{\lambda}} \quad (3)$$

Dónde: r_0 es el radio inicial para cubrir todos los nodos.




Fig. 3 Ejemplo visual de clasificación de la red SOM

En la Fig. 4 muestra la arquitectura competitiva de la red neuronal SOM, en la capa de entrada que tiene N neuronas de manera lineal donde representan la información inicial y a su vez estos se transmite los datos a la capa competitiva, formada por M neuronas para realizar el proceso de aprendizaje. En cada neurona i está conectada con cada una de las neuronas de la capa de competitiva j mediante un W_{ji} que tiene asociado, considerando que una neurona elegida pertenece a una vecindad N_j de la neurona j , y la cantidad de sus vecinas es fijo durante el proceso de entrenamiento, por tanto la elegida es resaltada y los que están a su costado tienen cierto grado de afectación en función de la distancia del elegido, donde por lo general se establece con una matriz llamada gaussiana.

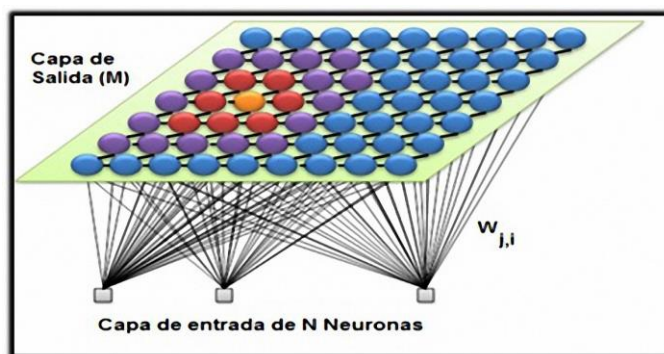


Fig. 4 Ejemplo de clasificación de la red SOM

IV. PROCESO DE APRENDIZAJE

En el proceso de aprendizaje de las imágenes en la red neuronal SOM, se aplica previamente la secuencia de pasos para tener su representativo de las imágenes en un tamaño pequeño sin perder lo característico de cada hoja, genera un gráfico de índices, propio de la red SOM, donde se ve agrupada por las 3 clases a las 1200 imágenes de hojas, tal como se muestra en la Fig 5. Estas clases se pueden representar de esta manera según las etiquetas de la tabla I.

TABLA I
CLASE, ETIQUETA Y DETALLE DE LAS ENFERMEDADES DE LA PLAGA

Clase	Etiqueta	Detalle
0	SP	En la imagen identificado sin plaga.
1	PM	En la imagen identificado con la plaga de la mosca.
2	PG	En la imagen identificado con la plaga del gorgojo.
3	ER	En la imagen identificado con la enfermedad de la ranca.




Fig. 5 Imágenes de las hojas etiquetadas, (a) sin plaga, (b) plaga de la mosca, (c) plaga del gorgojo y (d) enfermedad de la ranca.

La previa de pasos para aplicar, como resultado obtenemos en la siguiente figura, necesario solo la hoja para que pueda ingresar a la red neuronal artificial SOM, considerando que estos dato (finales) es necesario estirarlo para que ingrese como patrones de entrada, tal como se visualiza en la Fig 6.




Fig. 6 Imágenes de las hojas etiquetadas, (a) sin plaga, (b) plaga de la mosca, (c) plaga del gorgojo y (d) enfermedad de la ranca.

En la Fig 7 y su representación de etiquetas en la Fig 8 se visualiza la matriz index agrupada después del aprendizaje no supervisado, donde la parte circular rojo representa a la clase que no tiene plaga (SP), la parte triangular verde representa a la clase de plaga de la mosca (PM), la parte triangular de color azul a la clase plaga del gorgojo (PG) y la parte triangular de color amarillo representa a la clase de la plaga con la enfermedad de la ranca. A partir de los datos entrenados, representado en la matriz index, se ha realizado las pruebas, donde a las pruebas de las mismas imágenes de entrenamiento (1200 imágenes) se ha obtenido un 99.42% de certeza, frente a las imágenes que no han sido parte del entrenamiento (1200 imágenes), obtuvo un resultado de 99.2% en promedio, tal como se muestra en la Tabla II, y una de las pruebas se evidencia en la Fig 9.

TABLA II
DETALLE DEL PORCENTAJE DE CERTAZA EN MAPEO SEGUN LAS CLASE DE PLAGAS

Clase	Etiqueta	% de certeza con imágenes de entrenamiento (1200)	% de certeza con imágenes que no son parte del entrenamiento (1200)
0	SP	100 %	100 %
1	PM	99 %	99 %

2	PG	99 %	99 %
3	ER	100 %	100 %

En la Fig 7 se visualiza que en base a la variable de la cantidad de neuronas y ver la variación según la cuantización del error, se observa que van desde 20 hasta el valor 50 como límite de dimensión cuadrada para la capa competitiva, según los resultados reflejados en la gráfica, con valores 20 el aprendizaje toma un tuna cuantización del error más visible de 24.5%, mientras más neurona utilizemos, hasta llegar a un valor ideal para las neuronas 50, generando una cuantización de error de 18,11%, y esto se logra establecer la cuantizacion de error a pesar de incrementar la cantidad de neuronas.




Fig. 7 Matriz index de la red SOM aplicada a las 45 imágenes y 3 clases

```

+ Código + Texto

#SP = 0 # sin plaga
#PM = 1 # Plaga de la mosca
#PG = 2 # Plaga del gorgojo
#ER = 3 # Enfermedad de la Ranca
MM = M#np.rot90(M)
print(MM)
N = MM.astype(np.str)
N[N=='0.0'] = 'SP'
N[N=='1.0'] = 'PM'
N[N=='2.0'] = 'PG'
N[N=='3.0'] = 'ER'
print("Etiquetas")
print(N)

[[[-1. -1. 0. ... 0. -1. -1.]
 [-1. -1. -1. ... -1. 3. -1.]
 [-1. 0. -1. ... -1. -1. 0.]
 ...
 [-1. -1. 2. ... 0. -1. -1.]
 [ 0. 3. -1. ... -1. 2. -1.]
 [ 3. -1. 3. ... -1. -1.]]
Etiquetas
[['-1.0' '-1.0' 'SP' ... 'SP' '-1.0' '-1.0']
 ['-1.0' '-1.0' '-1.0' ... '-1.0' 'ER' '-1.0']
 ['-1.0' 'SP' '-1.0' ... '-1.0' '-1.0' 'SP']
 ...
 ['-1.0' '-1.0' 'PG' ... 'SP' '-1.0' '-1.0']
 ['SP' 'ER' '-1.0' ... '-1.0' 'PG' '-1.0']
 ['ER' '-1.0' 'ER' ... '-1.0' '-1.0' '-1.0']]

```

Fig. 8 Matriz index de la red SOM con las etiquetas de las 4 clases

```
[ ] w = som.winner(representativo2('jpg/SP_10.jpg'))
print(w,N[w])
w = som.winner(representativo2('jpg/PM_10.jpg'))
print(w,N[w])
w = som.winner(representativo2('jpg/PG_10.jpg'))
print(w,N[w])
w = som.winner(representativo2('jpg/ER_10.jpg'))
print(w,N[w])

(29, 16) SP
(10, 9) PM
(47, 2) PG
(19, 34) ER
```

Fig. 9 ejemplo en google colab de una de las pruebas

La cantidad de iteraciones es relevante, por que hace que genere un agrupamiento ideal, cabe resaltar que esto puede llevar en desventaja si es que se exagera, ya que consume recurso, para la presente investigación se consideró los parámetros para la red neuronal SOM lo siguiente:

Máximas iteraciones a 5000, alpha máximo a 0.5, dimensión de la matriz competitiva de 50x50, dimensión de la matriz index 50x50, dimension de patrones de entrada a 324, y la cantidad para el entrenamiento es de 1200, topología hexagonal, función de activación la distancia euclideana.

En la Fig. 10 se considera a partir de la matriz de confusión los valores obtenidos en función de las pruebas realizadas, evidenciando para cada clase de plaga, se obtiene una precisión, sensibilidad y especificidad superiores al 99%.

```
from sklearn.metrics import confusion_matrix
from matplotlib import pyplot as plt
from sklearn.metrics import classification_report

conf_mat = confusion_matrix(y_true=Yi, y_pred=Y_simulado)
print('Matriz de Confusión - DATOS ORIGINALES:\n', conf_mat)
print('Métricas de Matriz de Confusión - DATOS ORIGINALES:\n', classification_report(Yi, Y_simulado))
labels = ['Class 0', 'Class 1', 'Class 2', 'Class 3']
fig = plt.figure()
ax = fig.add_subplot(111)
cax = ax.matshow(conf_mat, cmap=plt.cm.Blues)
fig.colorbar(cax)
ax.set_xticklabels([''] + labels)
ax.set_yticklabels([''] + labels)
plt.xlabel('Predicted')
plt.ylabel('Expected')
plt.show()

Matriz de Confusión - DATOS ORIGINALES:
[[298  1  1  0]
 [ 1 297  2  0]
 [ 0  0 300  0]
 [ 0  1  1 298]]

Métricas de Matriz de Confusión - DATOS ORIGINALES:
              precision    recall  f1-score   support

   0             1.00      0.99      0.99       300
   1             0.99      0.99      0.99       300
   2             0.99      1.00      0.99       300
   3             1.00      0.99      0.99       300

 accuracy                   0.99       1200
 macro avg                  0.99      0.99      0.99       1200
weighted avg                  0.99      0.99      0.99       1200
```

Fig. 10 Matriz de confusión para la formalización de los resultados.

V. CONCLUSIONES

Al aplicar la secuencia propuesta para esta investigación basada en visión artificial y aplicar la red SOM para el proceso de aprendizaje, se obtuvo como resultado de efectividad de 99.42% en la clasificación de plagas en las hojas de papa Yungay (SP, PM, PG, ER), para lograr ello se usó 1200 imágenes obtenidas en campo para el entrenamiento de la red, representando un valor alentador, considerando que las pruebas para el testeo se ha realizado las 1200 imágenes clasificadas en cada una de las clases establecidas y que no fueron parte del entrenamiento.

Cada vez que la matriz index genere los datos de las clases, se agruparán las clases de manera diferente, los valores de las etiquetas que representa cada caso (SP, PM, PG, ER) estarán en posiciones diferentes. En la Fig 7, se muestra la gráfica del resultado de la aplicación del modelo de la red SOM propuesto por [33] y la aplicación de la secuencia de pasos de la Fig 2. Al aplicar la red neuronal SOM para clasificar tipos de plagas aportando a nuevas investigaciones, ya que se puede extender a otros tipos de tuberculos. Se ha utilizado la librería Minisom en un entorno Colab, donde nos proporcionan datos suficientes para realizar un buen análisis de nuestros resultados y obtener más información. Tal como se muestra en la siguiente Fig 11.

```
[ ] def representativo2(img) :
    img=solohoja(cv2.imread(img))
    img = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
    img=cv2.equalizeHist(img)
    img=cv2.Canny(img,50,200)
    medi=recambio(img,256,256)
    _,mediana=cv2.threshold(medi,20,255,cv2.THRESH_BINARY_INV)
    mediana=cv2.morphologyEx(mediana,cv2.MORPH_OPEN,np.ones((2,2)))
    EE=cv2.resize(mediana,(18,18),interpolation=cv2.INTER_CUBIC)
    return np.asarray(EE).reshape(-1)

Xi = np.zeros([1200,324],np.float32)# dimension de 15x324
imagenes=os.scandir("jpg")
contador=0
Yi = []
Labels=[]
val=""
for imagen in imagenes:
    if imagen.name.find("_")!=-1:
        Xi[contador,:]=representativo2(imagen.path)
        Xi[contador+1,:]=cv2.rotate(Xi[contador,:], cv2.ROTATE_90_CLOCKWISE)
        Xi[contador+2,:]=cv2.rotate(Xi[contador+1,:], cv2.ROTATE_90_CLOCKWISE)

        if imagen.name.find("SP")!=-1:# sin plaga
            Yi.append(0)
            Yi.append(0)
            Yi.append(0)
        if imagen.name.find("PM")!=-1:# Plaga de la mosca
            Yi.append(1)
            Yi.append(1)
            Yi.append(1)
        if imagen.name.find("PG")!=-1:# Plaga del gorgojo
            Yi.append(2)
            Yi.append(2)
            Yi.append(2)
        if imagen.name.find("ER")!=-1:# Enfermedad de la Racha
            Yi.append(3)
            Yi.append(3)
            Yi.append(3)
        contador+=3
print(Xi.shape)
print(len(Yi))
print(Yi)
```



```

max_iter = 5000
alpha_max = 0.5
som = MiniSom(x=50, y=50, input_len=324, sigma=1.0, learning_rate=alpha_max, activation_distance='euclidean',
              topology='hexagonal', neighborhood_function='gaussian')
som.random_weights_init(Xi)
som.train_random(data=Xi, num_iteration=max_iter)

```

Fig. 11 Parte del código Fuente para realizar el aprendizaje.

VI. DISCUSIÓN

Si hacemos la comparativa de los resultados obtenido por [12] indica que usó visión artificial y red neuronal artificial profunda donde obtuvo una precisión de 99.34% en la detección de plagas de productos agrícolas, frente a la presente investigación usando una estrategia de datos y la red neuronal SOM tiene 99.42%. Así también [13] en su investigación de tuvo un 94.6% de certeza implicando una diferencia de menor de 4.82% de precisión frente a la presente investigación. También según la investigación [14] aplicando una red neuronal deformable una precisión de 93.2%, por tanto hay una diferencia menor de 6.21%.

AGRADECIMIENTO

Agradecimiento a todos los participantes de la presente investigación, con el fin de cubrir una necesidad de clasificar los diagnósticos de plagas de la papa Yungay redes neuronales artificiales, específicamente en la red neuronal artificial SOM y poder tomar mejores decisiones al momento de agrupar.

REFERENCES

- [1] Mehmet Emin Çalişkan, Allah Bakhsh, Khawar Jabran, "Potato Production Worldwide", *Academic Press*, 2023.
- [2] Food and Agriculture Organization Corporate Statistical Database, "list of countries by potato production", 2021.
- [3] Ministerio de Desarrollo Agrario y Riego del Perú, "Ficha técnica de la papa", 2021.
- [4] Servicio Nacional de Sanidad Agraria (SENASA), "SENASA: 'Zebra chip', plaga de la papa, no está presente en el Perú", Perú, 2021.
- [5] Ministerio de Agricultura del Colombia (Minagricultura), "Plagas y enfermedades de la papa", Colombia 2020.
- [6] Direccion General de Desarrollo Agrícola y Agroecología en Perú, "ASPECTOS RELEVANTES EN LA FASE DEL CULTIVO: CASO PAPA", 2022.
- [7] Dirección de Ciencia y Tecnología Agropecuaria (DICTA) - Honduras, "Manejo de la mosca minadora (*Liriomyza huidobrensis*) en el cultivo de la papa", 2019.
- [8] Ecofertilizin, "N° 0022: El gorgojo de los Andes *Premnotypes sp.*", 2021. <https://ecofertilizing.pe/el-gorgojo-de-los-andes/>
- [9] T. Zheng, X. Yang, J. Lv, L. Ming, S. Wang and L. Wenyong, "An efficient mobile model for insect image classification in the field pest management", *Engineering Science and Technology, an International Journal*, Volume 39, 2023.
- [10] E. Mwenda, N. Elijah, E. Muang, W. Marther and A. Kosgei, "Impact of ICT-based pest information services on tomato pest management practices in the Central Highlands of Kenya", *Sustainable Technology and Entrepreneurship*, 2023.
- [11] F. Qi, G. Chen, J. Liu and Z. Tang, "End-to-end pest detection on an improved deformable DETR with multihead criss cross attention", *Ecological Informatics*, 2022.
- [12] R. Hadipour-Rokni, E. Askari Asli-Ardeh, A. Jahanbakhshi, I. Esmaili paeen-Afrakoti and S. Sabzi, "Intelligent detection of citrus fruit pests

- using machine vision system and convolutional neural network through transfer learning technique", *Computers in Biology and Medicine*, 2023.
- [13] Y. Zhang, B. Ma, Y. Hu, L. Cong and L. Yujie, "Accurate cotton diseases and pests detection in complex background based on an improved YOLOX model", *Computers and Electronics in Agriculture*, 2022.
- [14] N. Zhao, L. Zhou, T. Huang, M. Farag Taha, H. Yong and Q. Zhengjun, "Development of an automatic pest monitoring system using a deep learning model of DPeNet", *Measurement*, Volume 203, 15 November 2022.
- [15] R. Priya Sharma, R. Dharavath and R. Damodar, "IoT-FIS: Internet of farm things based prediction for crop pest infestation using optimized fuzzy inference system", *Internet of Things*, Volume 21, April 2023.
- [16] E. Agil, A. Kulkarni and P. Robin Hiesinger, "Neuronal strategies for meeting the right partner during brain wiring", *Current Opinion in Neurobiology*, Volume 63, August 2020, Pages 1-8.
- [17] J. Winnubst, N. Spruston and J. AHarris, "Linking axon morphology to gene expression: a strategy for neuronal cell-type classification", *Current Opinion in Neurobiology*, Volume 65, December 2020, Pages 70-76.
- [18] C. Rodgers, R. Nogueira, B. Pil, E. Greeman, J. Park, Y. Hong, S. Fusi and R. Bruno, "Sensorimotor strategies and neuronal representations for shape discrimination", *Neuron*, Volume 109, Issue 14, 21 July 2021, Pages 2308-2325.e10.
- [19] M. Momeny, A. Neshat, M. Hussain, S. Kia, M. Marhamati, A. Jahanbakhshi and G. Hamarneh, "Learning-to-augment strategy using noisy and denoised data: Improving generalizability of deep CNN for the detection of COVID-19 in X-ray images", *Computers in Biology and Medicine*, Volume 136, September 2021
- [20] P. Zhang and Y. Zhen-Yu, "A novel deep learning-based modelling strategy from image of particles to mechanical properties for granular materials with CNN and BiLSTM", *Computer Methods in Applied Mechanics and Engineering*, Volume 382, 15 August 2021
- [21] B. Gao, X. Huanga, J. Shia, Y. Taia and J. Zhang, "Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks", *Renewable Energy*, Volume 162, December 2020, Pages 1665-1683.
- [22] S. Pang, M. Field, J. Dowling, S. Vinod, L. Holloway and A. Sowmy, "Training radiomics-based CNNs for clinical outcome prediction: Challenges, strategies and findings", *Artificial Intelligence in Medicine*, Volume 123, January 2022.
- [23] Gómez, R., La inteligencia Artificial ¿Hacia dónde nos lleva? ¿Cómo lo vez?, México, UNAM, 2013
- [24] Elaine Rich y Knight Kevin. *Inteligencia Artificial*. Segunda Edición. McGraw Hill: México, 1994.
- [25] Luger, G., Stubblefield W., *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*, BC, 1993.
- [26] G. H. Renato, "La inteligencia artificial. ¿Hacia dónde nos lleva? ¿Cómo ves?" México: UNAM, 2013.
- [27] P. P. Cruz, "Inteligencia artificial con aplicaciones a la ingeniería", México: Alfaomega Grupo Editores S.A. de C.V., México, 2010.
- [28] J. Avila-Tomás, M. Mayer-Pujadas, V. Quesada-Varela, "Artificial intelligence and its applications in medicine I: introductory background to AI and robotics", *Atención Primaria*, Volume 52, Issue 10, December 2020, Pages 778-784.
- [29] M. Regalado, A. Medina and C. Pizarro, "Artificial intelligence: phones smart phones and advanced technology stethoscopes", *Atención Primaria*, Volume 53, Issue 10, December 2021.
- [30] IBM, "¿Qué es la Visión Artificial?", 2021.
- [31] A. Martorell, A. Martín-Gorgojo, E. Ríos-Viñuela, J. M. Rueda-Carnero, F. Alfageme and R. Taberner, "Artificial Intelligence in Dermatology: A Threat or an Opportunity?", *Actas Dermo-Sifiliográficas*, Volume 113, Issue 1, January 2022, Pages 30-46
- [32] H. Zhang, L. Feng, X. Zhang, Y. Yang and J. Li, "Necessary conditions for convergence of CNNs and initialization of convolution kernels", *Digital Signal Processing*, Volume 123, 30 April 2022
- [33] K. Tuvo, "Self-organizing maps", Berlin: Springer, 1989.