RECONOCIMIENTO DE ENFERMEDADES Y PLAGAS EN HOJAS DE CULTIVOS DE PAPA A TRAVÉS DE PRE-PROCESAMIENTO DE IMÁGENES Y RECONOCIMIENTO DE PATRONES

MSc. Fabián Chaparro Becerra I
PhD. Manuel Ricardo Pérez, II
PhD. Diego Méndez, III
MsC. Angela María Gonzales A IV

Universidad Santo Tomás I
Pontificia Universidad Javeriana II, III
Universidad Nacional Abierta y a Distancia IV
william.chaparro@usantoto.edu.co, manuel.perez@javeriana.edu.co, diego-mendez@unad.edu.co, angela.gonzalez@unad.edu.co

Abstract: Crop diseases is a problem for farmers, a fast and early detection avoid and reduce losses. A system that can be able to act effectively in circumstances of risk could help to farmers. Boyacá, Colombia has a wide geographic zone that allows for the production of a huge number of fruits and vegetables for human consumption. It has various relatively constant temperature zones, climates and microclimates through the year between 0 to 4600 m above sea level. In this document is presented a system that recognizes leaf samples using RGB color and Hue, Saturation and Intensity features through algorithm process. The components of the data are classified in key features through Neuronal Network and K-means clustering. The K-means and neuronal networks allow classify new leaves and assign a group or cluster of leaves with some disease or normal leaves present in the potato crops.

Keywords: RGB components, Hue, Saturation, Intensity, Classify, leaves, MLP, K-means

Resumen: Las enfermedades en los cultivos son un gran problema para los agricultores, una rápida y temprana detección reduciría y evitaría grandes pérdidas. Un sistema que pudiese estar disponible para actuar de manera efectiva en circunstancias de riesgo podría ayudar a los cultivos. Boyacá es una región en Colombia que posee un amplio rango de posibilidades de cultivo en razón a su gran riqueza de pisos térmicos que posibilita tener amplias posibilidades en el sector agrario durante todo el año con zonas desde los 0 – 4600 metros sobre el nivel del mar. En este documento se presenta un Sistema que reconoce las muestras de una hoja usando la representación en color RGB, la tonalidad, saturación e intensidad de las mismas a través de un proceso algorítmico. Los componentes de los datos extraídos son clasificados a través de agrupamiento en k-means y de una red neuronal entrenada previamente. Los mismos permitirán la clasificación de nuevas muestras que son asignadas a un grupo de características de hojas con alguna enfermedad u hojas normales presentes en cultivos de papa.

Palabras clave: Componentes RGB, Tono, Saturación, Intensidad, Clasificación, hojas, MLP, K-means

1. INTRODUCCIÓN

Boyacá, Colombia, tiene un amplio espectro de posibilidades para el crecimiento de cultivos agrícolas, la zona geográfica de este Departamento permite el crecimiento y la producción de un elevado número de frutos y vegetales para el consumo humano. El sector agrícola demanda la implementación de técnicas inteligentes que proyecten una mejora y eficiencia en la calidad de sus procesos y la prevención temprana de plagas o enfermedades que minimicen las pérdidas a toda la cadena de producción y comercialización de sus productos.

La papa o patata, es uno de los productos principales de la región por su tradición y reconocimiento en el ámbito local y nacional. El cultivo de la misma se presenta entre los 2500 y los 3200 msnm. En la etapa de producción se conocen diferentes fases entre las que encontramos la elección y clasificación de la semilla, el establecimiento o siembra del cultivo, en un tercer momento encontramos el desarrollo del proceso de cultivo y en esta fase es donde fortalecemos a nivel de producción el minimizar los riesgos por la presencia de plagas o enfermedades, para lo cual un oportuno y apropiado seguimiento reduce los efectos negativos de producción y otorga un nivel de calidad aceptable; por lo tanto, se puede estructurar al interior de esta fase la ejecución de mecanismos que permitan encontrar y actuar frente a los procesos de sanidad del cultivo donde se administra la reducción de efectos causados por plagas y/o enfermedades. La manera más simple de inferir anomalías en los cultivos es de manera visual, permitiendo diferenciar entre una cosecha en estado normal o la presencia de alguna patología particular asociada a muestras de pigmentación en las hojas del cultivo representadas por atenuaciones café, negra o amarilla, particularmente. Estas muestras que distan del color verde tradicional y que señalan un cultivo sano se asocian a enfermedades en estado tardío de corrección como la gota (Phythophthora infestans) en mayor proporción de recurrencia o Allternaria Solani que es muy similar a la gota, aunque menos agresiva en etapas tempranas de detección. En la Figura.1 se muestran las características generales de normalidad y anomalías en las hojas de un cultivo de papa.

El diagnóstico de enfermedades en las plantas es considerado un arte que se aborda más desde la experiencia de los cultivadores al observar patrones de comportamiento y en menor medida desde el soporte tecnológico que podría mejorar la detección temprana y precisa de anormalidades en los cultivos.



Fig. 1 Hojas de plantas en cultivos de papa con comportamiento normal y con anomalías.

Procesamiento y análisis digital de imágenes ofrece una perspectiva de aprovechamiento de análisis y detección temprana. Lo anterior permite extraer los patrones, características y atributos que son implementados en un clasificador y en el cual permite inferir el pertenecer a una clase particular asociado al comportamiento de sus muestras; en este trabajo se ha implementado K-means clustering y una red neuronal para hacer frente al proceso de clasificación.

El artículo está organizado de la siguiente forma: En la sección II se describirán las herramientas teóricas utilizadas, en la sección III se presentará la solución propuesta, en la sección IV los resultados obtenidos, en la sección V las conclusiones y finalmente en la última sección las referencias utilizadas.

2. HERRAMIENTAS TEÓRICAS

En esta sección se presentan los conceptos trabajados para el desarrollo del Proyecto.

En un enfoque controlado se asume que las muestras de información vienen de una distribución conocida, en un enfoque que no es controlado o insostenible, se toma desde una perspectiva más laxa con un enfoque semi-parámetrico que permite una mezcla de distribuciones para ser usadas en la estimación de una muestra nueva de entrada.

La visión permite percibir, procesar y entender sucesos que se desarrollan alrededor de los seres humanos, la visión digitalizada y el procesamiento de imágenes permiten aumentar el

efecto de la visión humana a través de la percepción electrónica.

En la literatura es posible encontrar diversos trabajos que contemplan el uso del procesamiento de imágenes y clasificación de muestras; en (Pilli, Nallathambi, George, & Diwanji, 2015) se utiliza un mecanismo para la detección temprana de enfermedades en cultivos a través del procesamiento de imágenes, se construye una matriz de características con el objetivo de entrenar una red neuronal que posibilite clasificar los datos con rasgos normales o anormales referente a patologías. En (Laudien, Bareth, & Doluschitz, 2004) se utilizan imágenes satelitales con características de resolución espectral para detectar y analizar enfermedades en cultivos de remolacha en el sur de Alemania, los autores se concentran en analizar la información de las componentes roja e infra-roja para inferir el estado de vitalidad en la planta. En (Weizheng, Yachun, Zhanliang, & Hongda, 2008) se presenta un método de clasificación de enfermedades representado en las características de pigmentación foliar, la técnica utilizada integra un procesamiento de la imagen en las características de medición del área de la lesión contrastada con el área total de la imagen, particularmente el estudio se centra en el análisis de la soya.

Para el análisis de la información de los cultivos de papa se ha determinado escoger métodos de clasificación que integren procesos no supervisados, particularmente k-means y supervisado con el uso de redes neuronales.

2.1 K-means clustering

Los métodos de agrupamiento (clustering) permiten aprender desde parámetros mixtos de información(Alpaydin, 2010). En el procesamiento y análisis de imágenes es importante la segmentación como proceso que divide la imagen digital en múltiples segmentos para cambiar su representación en algo más accesible y fácil de analizar, entre las técnicas de segmentación de patrones en imágenes se encuentran los métodos de agrupamiento (clustering), para el cual el objetivo es dividir la información en grupos, dados unos patrones que reúnen los grupos con particularidades especiales diferenciables de los otros. El agrupamiento ha sido ampliamente estudiado en problemas de aplicación variado donde se incluyen las redes neuronales. La técnica de agrupamiento – clustering K-means ha sido una técnica bien conocida para solucionar tareas de segmentación de imágenes de bajo nivel que no contemplan el uso de etiquetas previas para representar los datos. Los algoritmos de agrupamiento son convergentes y su principal objetivo es la optimización en las decisiones de particionamiento de atributos definidos por el usuario y actualizados en cada iteración de procesamiento(Athanikar & Badar, 2016). Los resultados experimentales muestran que k-means es una técnica aceptable en la detección controlada de anomalías en hojas de cultivos agrícolas.

Al considerar el problema de identificar grupos o clúster de información en un espacio multidimensional, suponemos el tener datos $\{x_1, x_2, \ldots, x_N\}$ consecuentes con el número N de observaciones de una variable x Euclidiana Dimensional. El fin es particionar todos los datos dentro de un número de K clúster donde K es conocido. De manera intuitiva se piensa que un clúster es la cercanía de datos de un grupo para el cuál la distancia es pequeña comparada con la distancia de los datos que no pertenecen al clúster. Esta noción se puede formalizar introduciendo un conjunto de vectores dimensionales μ_k, donde k=1,...,K, para el cuál μ_k está asociado con el k-ésimo clúster respectivo y donde el mismo representa el centro del clúster (Jordan, Kleinberg, & Scho, n.d.)(Theodoridis & Koutroumbas, n.d.)(“Pattern Classification - Duda, 2ed (Wiley).pdf,” n.d.).

2.2 Redes Neuronales

Las redes neuronales se suelen definir como una forma de computación inspirada en los modelos biológicos, un modelo matemático compuesto por elementos de procesamiento organizados en capas o niveles, un sistema de procesamiento compuesto por elementos simples que procesan la información por medio de su estado dinámico como respuesta a entradas externas y como redes neuronales artificiales que son redes interconectadas masivamente en paralelo por elementos simples con organización jerárquica que pretenden interactuar con el mundo real de modo similar a la forma en que lo hace el sistema nervioso biológico. Su funcionamiento y estructura tienen características semejantes a las del cerebro humano como aprendizaje por medio de la experiencia o reutilizando soluciones a nuevos casos con condiciones similares. Entre sus principales áreas de aplicación tenemos el aprendizaje adaptativo, auto-organización, tolerancia a fallos, operación en tiempo real. Los elementos básicos que componen una red neuronal son las entradas, las salidas y las capas que se subdividen en capa de entrada, capa ocultas y capa de salida, en donde la capa oculta puede estas constituida por varias capas (Alpaydin, 2010; Deng & Yu, 2013; “Pattern Classification - Duda, 2ed (Wiley).pdf,” n.d.)

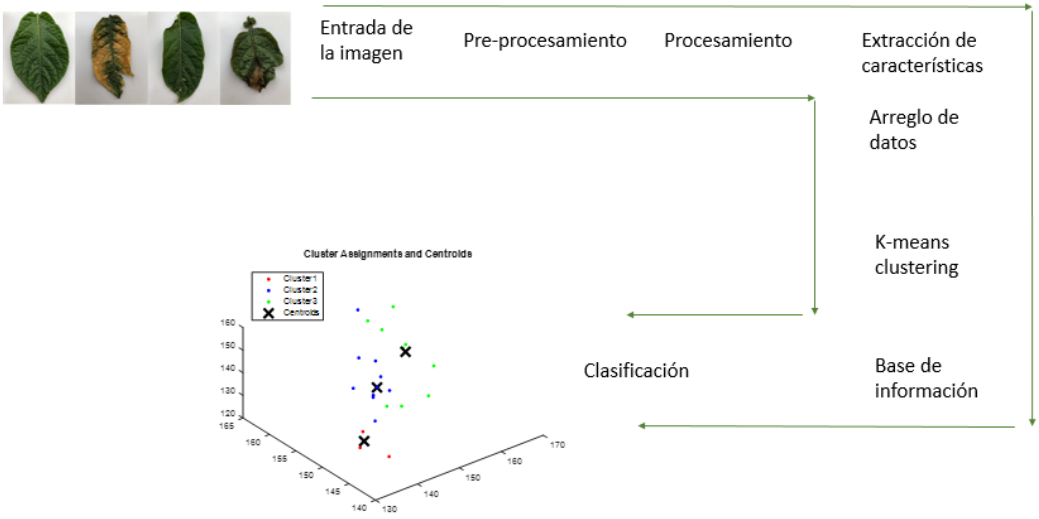


Fig. 2 Sistema de clasificación propuesto

agrupamiento que finalmente estructura las

3. SOLUCIÓN PROPUESTA

En esta sección se describen los mecanismos de solución propuestos, particularmente en los referentes de descripción del proceso de adquisición, ajuste y procesamiento de la información.

Para la implementación de la propuesta se adquirieron y procesaron imágenes de un cultivo de papa en el Departamento de Boyacá, las imágenes contenían muestras de un comportamiento normal y con anomalías de las hojas del cultivo.

En la fase experimental trabajada se han tomado imágenes que contiene muestras normales y anormales que incluyen pigmentaciones cafés, negras y amarillas – Figura 1. El 100% de la información tomada desde un cultivo ha sido recopilada con base en observaciones visuales.

Cada una de las muestras ha sido tomada en igual tamaño, igual formato de imagen, iguales condiciones de luminosidad e igual fondo, las mismas han sido el insumo para extraer a partir de ellas las componentes RGB (Red, Green and Blue) y el cálculo de las componentes de Tonalidad, Saturación e Intensidad (HSI) a partir de las primeras; con las muestras de información se tomaron los referentes de las medias, la desviación estándar, el rango, la kurtosis, la moda y la mediana por componente para la construcción de la base de datos de trabajo (matriz de características) en la clasificación y muestras con 21 características para procesamiento. Lo anterior fundamentado en artículos de consulta como (Athanikar & Badar, 2016) y (Mohanty, Hughes, & Salathe, 2016).

En la Figura 2 se puede observar el diagrama del Sistema de clasificación propuesto, el mismo describe las fases de interacción comenzando por la entrada de la imagen y el procesamiento descrito anteriormente (Transformaciones, operaciones con las componentes RGB y HSI), a su vez, el ordenamiento de la información y la organización de las características para ser ajustadas y colocadas en el clasificador; posteriormente se llaman los datos en el clasificador de grupos k-means y en la red neuronal para obtener los resultados de la clasificación.

Referentes de procesamiento como componentes “Lab” L(luminosidad)- a(espectro de rojo a verde)- b(gradiente de azul) en la imagen, fueron utilizados en el desarrollo del Proyecto, sin embargo las matrices de características construidos con los resultantes de la conversión RGB a Lab* no entregaron resultados aceptables ni satisfactorios en la clasificación, por lo anterior los mismos fueron descartados.

Caracterísiticas	137,8932686	151,23214	142,454346	145,963573	140,23658	145,155048	152,431934	147,164883	148,884373	156,543831	156,709244
mean_G_ok	149,1493607	156,806419	149,927849	156,834404	150,480808	152,435108	160,90313	153,309273	153,961891	162,464481	164,47348
mean_B_ok	124,2672615	141,908398	131,643028	133,557529	127,718121	136,52145	136,458393	138,276554	140,74889	147,614033	149,425327
std_R_ok	82,82883046	72,8859607	81,2365601	82,07084	83,9233527	83,5256915	75,2505754	80,0317508	77,2757913	70,8436394	76,0582733
std_G_ok	71,40366742	66,429455	72,1160399	70,1594127	73,0721418	74,4034276	63,4283549	71,7446603	70,5920684	61,3897713	66,19528
std_B_ok	89,34351006	82,2283797	88,0773029	92,2222582	92,6041595	89,856949	90,779686	86,5872616	84,2686271	82,2310835	84,9984676
Range_R_ok	249	249	242	250	243	246	226	243	246	229	238
Range_G_ok	234	243	238	233	236	237	205	235	236	212	224
Range_B_ok	255	253	245	255	255	246	244	238	247	237	243
kurtosis_R_ok	1,215862485	1,42476596	1,18789762	1,21600195	1,16609709	1,27303505	1,3978246	1,27668846	1,3774213	1,90472762	1,65259532
kurtosis_G_ok	1,329211957	1,52320758	1,28391559	1,3099735	1,25843911	1,33511863	1,4669999	1,34872218	1,42287453	1,90848109	1,76380384
kurtosis_B_ok	1,196200402	1,33401217	1,15320269	1,21056886	1,14152106	1,24202562	1,33431137	1,24840279	1,33638211	1,85320334	1,5606445
moda_R_ok	226	206	213	219	227	216	219	228	211	226	211
moda_G_ok	219	204	212	220	229	216	232	214	210	226	233
moda_B_ok	213	202	209	218	227	214	211	223	208	225	234
mediana_R_ok	101	193	197	192	161	200	190	193	192	188	195
mediana_G_ok	128	192	194	192	159	198	186	190	189	188	195
mediana_B_ok	77	190	189	187	148	194	183	186	186	186	194
H component_ok	1,000000809	1,00001521	1,00000542	1,00000044	1,00000106	1,00000158	1,00000823	1,00000801	1,00001645	1,00001007	1,00000025
S component_ok	0,093623098	0,05383249	0,06861889	0,08177488	0,08431681	0,05654596	0,08985964	0,05452082	0,04812605	0,05096251	0,04745365
I Component_ok	137,1032969	149,982319	141,341741	145,451836	139,478503	144,703869	149,931152	146,250237	147,865051	155,540782	156,86935
mean_R_sick	161,3205757	161,757195	157,440495	138,852478	148,02523	147,185566	155,196419	145,963585	157,878803	159,159645	146,890049
mean_G_sick	153,7908058	161,804047	156,045559	144,44323	151,609627	148,68961	149,933704	153,058952	156,8871	161,883423	151,243565
mean_B_sick	136,8854179	151,086704	145,873337	126,462845	138,691132	136,616608	133,654011	135,992687	142,800255	142,643585	133,067585
std_R_sick	56,6215897	64,7984966	71,4222173	76,52387	76,3291	73,2785923	60,8969679	75,231357	66,1141295	72,3278365	73,2497468
std_G_sick	59,26465806	61,5154684	68,2128756	70,9089385	71,6001531	70,1997641	63,3752371	68,5854277	65,2830468	65,777788	66,739629
std_B_sick	75,57222336	72,6137534	77,1706906	84,7714233	84,2315433	81,0901647	79,5804076	83,4885079	79,4091952	83,1553111	82,197762
Range_R_sick	246	253	247	237	250	249	247	241	240	247	251
Range_G_sick	241	250	241	235	249	249	245	241	238	240	245
Range_B_sick	246	245	247	233	248	251	247	242	240	249	252
kurtosis_R_sick	2,785444938	2,58443214	2,15504546	1,27599973	1,5076317	1,51574529	2,27646843	1,27254499	1,83890509	1,7421574	1,36829106
kurtosis_G_sick	2,036566391	2,51566127	2,05113536	1,37273588	1,60499343	1,58857879	1,8071819	1,40339589	1,75081914	1,79973148	1,50321496
kurtosis_B_sick	1,565112656	2,40095602	1,99012869	1,20497745	1,38720009	1,42880191	1,43892319	1,19916116	1,51991387	1,49372149	1,28252579
moda_R_sick	168	223	227	224	201	224	172	226	194	225	233
moda_G_sick	229	222	226	225	184	224	171	227	223	228	232
moda_B_sick	228	215	219	223	212	222	215	225	221	225	230
mediana_R_sick	174	185	181	167	190	178	173	191	188	192	177
mediana_G_sick	168	182	176	163	187	174	171	190	186	187	172
mediana_B_sick	165	176	171	143	185	170	168	185	181	182	166
H component_sick	1,00004937	1,00000117	1,00000209	1,00000022	1,00000027	1,0000008	1,00000386	1,00000004	1,00000165	1,00000062	1,00000038
S component_sick	0,624190328	0,59044279	0,53355334	0,43973931	0,47758676	0,49169953	0,58364287	0,48118121	0,56652741	0,53204711	0,49037887
I Component_sick	150,6655998	158,215982	153,119797	136,586184	146,108663	144,163928	146,261378	145,005075	152,522053	154,562218	143,733733

Fig. 3. Matriz de características

La solución propuesta fue evaluada a partir de la adquisición de la información entregada; primero se toma en la entrada el procesamiento de imágenes de hojas a color con las características presentadas en la sección de la solución propuesta; la extracción de la información permite condensar las características de las componentes de color, tonalidad, saturación e intensidad de las mismas. Con los vectores de estas características se estructuran datos estadísticos que van a correlacionar la totalidad de la matriz de características para cada una de las hojas procesadas, encontrándose dentro de los resultados de este procesamiento los datos señalados como matriz de características en la Figura 3.

Posteriormente la matriz es llamada para procesamiento en el algoritmo de Clustering k-means y en la red neuronal encargada de la clasificación.

4. RESULTADOS

En esta sección se describen los resultados.

Los algoritmos de clustering k-means se evaluaron para determinar la interacción de clasificación en dos clúster - Figura 4 y tres clústeres en la Figura 5. La solución de red neuronal permite alcanzar una precisión del 80% de clasificación con los datos de entrenamiento y de un 76% con los datos de prueba.

En virtud de los resultados obtenidos encontramos dos referentes: cuando se realiza el agrupamiento en 2 grupos encontramos las muestras que tienen condiciones i) normales y ii) anormales (patologías) de representación; cuando se implementa el agrupamiento en tres grupos, encontramos las muestras que poseen características i) normales, ii) patología de gota con características de pigmentación café – negra y iii) patología de virus con características de pigmentación amarilla; consecuente con los resultados obtenidos se encuentra un clasificador que otorga unos resultados aceptables en los métodos con aprendizaje supervisado (red neuronal) y no supervisado (k-means), respectivamente.

5. CONCLUSIONES

El trabajo presentado muestra una perspectiva rápida y aceptable en precisión para la clasificación de características en hojas para un cultivo de papa, el sistema está en capacidad de identificar condiciones normales de la hoja o anomalías que pudiesen representar una enfermedad o virus por la cual la misma estuviese siendo afectada.

El sistema emplea técnicas iniciales de procesamiento de imágenes; con técnicas más avanzadas donde se contemplen además del procesamiento de color, características de textura, forma, bordes, entre otros, el sistema podrá mejorar sus índices de clasificación y con ello la precisión de los resultados.

K-means clustering es un método que permite clasificar información extraída del procesamiento de imágenes donde recurrentemente se busca diferenciar las muestras con comportamiento normal o con anomalías.

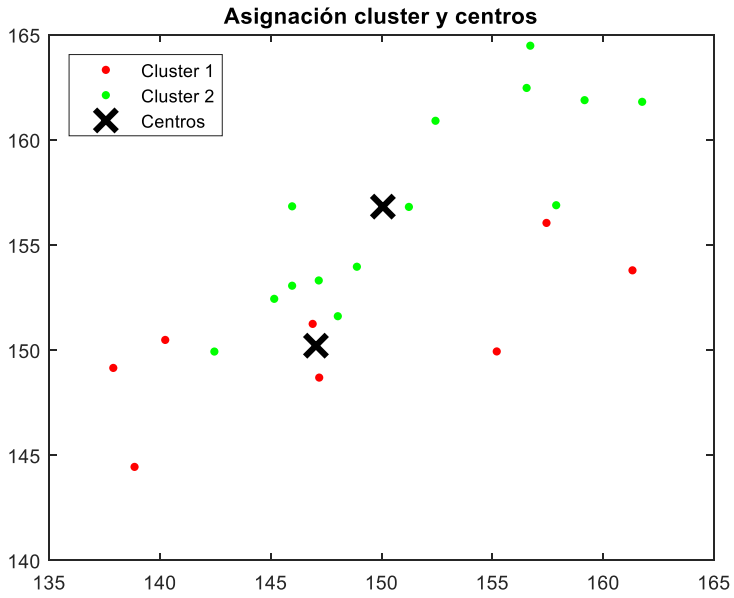


Fig. 4 Dos (2) clúster

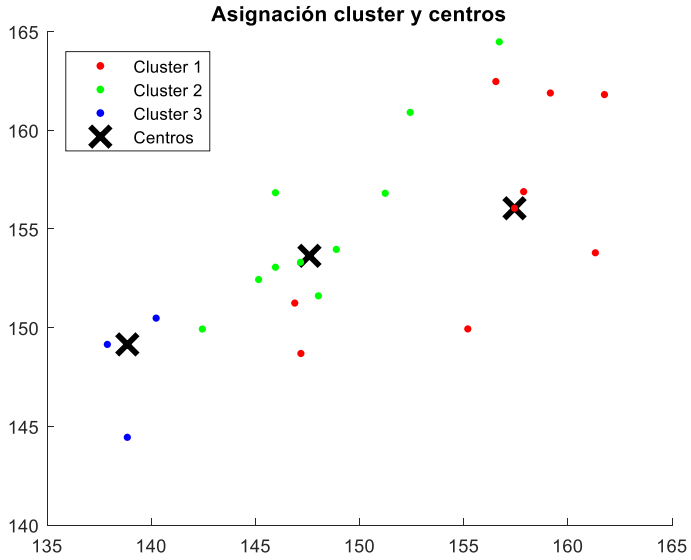


Fig. 5 Tres (3) clúster

La red neuronal entrenada permite inferir la clasificación de muestras con etiquetas normales o con anomalías, los datos de prueba alcanzan valores de clasificación cercanos a los datos utilizados para el entrenamiento.

Los sistemas desarrollados pueden ser usados para la detección y clasificación de anomalías en las hojas de una planta de una cosecha de papa y ayudar a los agricultores en la toma de decisiones frente a sus cultivos; estas representaciones son evidenciables en el mediano plazo de desarrollo del cultivo, por tanto, es importante considerar más herramientas de análisis y procesamiento para detectar los riesgos de un cultivo en etapas más tempranas de desarrollo y de esta forma minimizar el impacto negativo económico que pudiese presentarse en la cosecha del mismo.

En trabajo futuro se perfeccionarán los métodos de pre-procesamiento de la imagen con el fin de filtrar ruido que infiere en la precisión de clasificación para las herramientas presentadas en este documento.

5. AGRADECIMIENTOS

Los autores desean agradecer el apoyo brindado por la Gobernación de Boyacá, beca 733 de Colciencias, Universidad Santo Tomás, Pontificia Universidad Javeriana, Universidad Nacional Abierta y a Distancia, a todos ellos por su financiación y respaldo.

REFERENCIAS

Alpaydin, E. (2010). *Introduction to Machine Learning. Second Edition*. *Massachussetts Institute of Technology*.

Athanikar, G., & Badar, M. P. (2016). Potato Leaf Diseases Detection and Classification System, *5*(2), 76–88.

Deng, L., & Yu, D. (2013). Deep Learning: Methods and Applications. *Foundations and Trends® in Signal Processing*, *7*(3–4), 197--387. https://doi.org/10.1136/bmj.319.7209.0a

Jordan, M., Kleinberg, J., & Scho, B. (n.d.). *No Title*.

Laudien, R., Bareth, G., & Doluschitz, R. (2004). Comparison of Remote Sensing Based Analysis of Crop Diseases By Using High Resolution Multispectral and Hyperspectral Data -Case Study: Rhizoctonia Solani in Sugar Beet. *Geoinformatics*, (June), 7–9. Retrieved from http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.460.6544&rep=rep1&type=pdf

Mohanty, S. P., Hughes, D. P., & Salathe, M. (2016). Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, *7*, 10. https://doi.org/10.3389/fpls.2016.01419

Pattern Classification - Duda, 2ed (Wiley).pdf. (n.d.).

Pilli, S. K., Nallathambi, B., George, S. J., & Diwanji, V. (2015). eAGROBOT- A Robot for Early Crop Disease Detection using Image Processing, (Icecs), 1–6.

Theodoridis, S., & Koutroumbas, K. (n.d.). *Pattern Recognition*.

Weizheng, S., Yachun, W., Zhanliang, C., & Hongda, W. (2008). Grading Method of Leaf Spot Disease Based on Image Processing. *2008 International Conference on Computer Science and Software Engineering*, 491–494. https://doi.org/10.1109/CSSE.2008.1649