

VIABILIDAD IDENTIFICACIÓN DE ESTADOS FENOLOGICOS EN LA ROSA
APLICANDO ALGORITMOS DE RECONOCIMIENTO DE IMAGENES

Proyecto de Grado

Jose Luis Osorio Naranjo

Asesor:

Rafael David Rincón Bermúdez

Departamento de Informática y Sistemas

UNIVERSIDAD EAFIT

MEDELLÍN

2019

Contents

Resumen	3
Solución	5
Objetivos	5
Objetivo general	5
Objetivos específicos	5
Marco teórico	7
Redes neuronales	7
Clasificación	7
Redes neuronales convolucionales	8
Alcance	10
Cronograma de Trabajo	10
Metodología de trabajo	10
Presupuesto	11
Especificaciones Servidor de desarrollo	11
Captura de Fotografías	12
Identificación de objetos de interés	14
Identificación de objetos de interés utilizando contraste de color	14
Mapa de calor de los detectores	14
Detección de color y visión por computador tradicional (Histogramas, Color Space)	15
Espectros de color HSL y HSV	16
Identificación de objetos de interés utilizando Faster-RCNN	17
Conclusiones	22
Referencias	23

Resumen

En este proyecto se comprueba la viabilidad de identificación y clasificación de estados fenológicos en la rosa, utilizando algoritmos de reconocimiento de imágenes. Se utilizaron redes neuronales convolucionales para la identificación y clasificación de objetos de interés y se comparó con técnicas de contraste de color. Por último, se realizaron mejoras a la precisión del modelo, utilizando clasificación binaria entre los estados fenológicos con menor probabilidad.

Definición del problema

Después del petróleo y sus derivados, las flores son el segundo producto más exportado por Colombia (Figura 1); a la fecha, es el segundo país del mundo que más exporta flores. El sector floricultor colombiano debe, por lo tanto, realizar esfuerzos logísticos, en términos de producción en campo, transferencia de tecnología, transporte, almacenamiento y distribución, para satisfacer la creciente demanda de flores.




Figura 1. Exportaciones de Colombia para el año 2018 (MinComercio Industria y Turismo, 2018)

Una labor clave para la producción de la flor es el corte o cosecha; antes del corte se debe identificar con exactitud el estado fenológico de la planta; tarea realizada por personal calificado y con alta experiencia. El procedimiento actual para establecer el estado fenológico es recorrer el cultivo, planta a planta; por consiguiente, se precisa de un numeroso equipo de profesionales calificados que cubran el área de todo el cultivo en poco tiempo.

En el mercado laboral están escaseando profesionales calificados que reconozcan los estados fenológicos¹, y la demanda para dicha tarea es alta. Además de esto, el costo de capacitación de nuevo personal es alto y el tiempo de aprendizaje es prolongado, lo que retrasa la programación del corte.

¹ La fenología es la ciencia que estudia la relación entre los factores climáticos y los ciclos de los seres vivos

Solución

Evaluar la viabilidad para realizar la identificación de los estados fenológicos de la rosa, aplicando algoritmos de reconocimiento de imágenes de inteligencia artificial.

Objetivos

Objetivo general

Evaluar qué tan viable es identificar los estados fenológicos de la rosa por medio de mecanismos de visión artificial.

Objetivos específicos

- Desarrollar un servicio que permita identificar objetos de interés, aislando el fondo
- Desarrollar un servicio que permita clasificar los siguientes estados fenológicos
- Realizar el conteo por los estados fenológicos identificados y clasificados

En las siguientes figuras se observan los estados fenológicos que se desean identificar de la rosa (Figura 2, Figura 3, Figura 4, Figura 5, Figura 6, Figura 7 y Figura 8).




Figura 2. Estado fenológico 0 (Arroz)



Figura 3. Estado fenológico 1 (Arveja)



Figura 4. Estado fenológico 2 (Garbanzo)




Figura 5. Estado fenológico 3 (Bola)




Figura 6. Estado fenológico 4 (Rayando).



Figura 7. Estado fenológico 5 (Separando)

Figura 8. Estado fenológico 6 (Corte)

Marco teórico

A continuación, se explican de manera resumida los principales conceptos que se emplearán en la identificación de los estados fenológicos de la rosa. Para tener una visión más detallada, se recomienda consultar las fuentes citadas.

Redes neuronales

Es un concepto desarrollado desde mediados del siglo XX, que apenas ha sido implementado en gran medida en las décadas de los 2000. Por los recientes avances tecnológicos, el uso de la red neuronal dejó de ser meramente académico, y se convirtió en una herramienta con la cual interactuamos día a día. La principal característica de la red neuronal es un algoritmo compuesto por operaciones matemáticas, que se ejecutan iterativamente. (Durán Suárez, 2017)

Clasificación

Los enfoques tradicionales de reconocimiento y clasificación no generalizan bien en tareas de clasificación de imágenes, debido a la elevada dimensión del espacio de características de las mismas. Hay muchas elecciones posibles para realizar el clasificador, desde árboles de clasificación hasta las redes neuronales.

Las redes neuronales han sido el sistema tradicional que mejores resultados han obtenido durante mucho tiempo en las tareas de clasificación supervisada de imágenes. Este fructífero enfoque nació en 1943, cuando McCulloch y Pitts propusieron un modelo computacional basado en un elemento lógico simple, similar a una neurona. (McCulloch 1990).

Es preciso tener en la cuenta, para el diseño de un clasificador mediante redes neuronales, una serie de aspectos prácticos a la hora de definir arquitectura del problema y la forma de enfocarlo. El primero de ellos es la selección de las entradas o características de nuestros datos que sean significativas. Tras ello, está el problema añadido de la definición de la arquitectura, en cuanto a capas y número de neuronas por capa, estando ambas elecciones ligadas.

Sin embargo, es muy difícil encontrar la forma en que las redes neuronales superen cierto nivel de acierto por el grave problema que sufren de falta de generalización ante nuevas entradas, sobre todo en espacios de entrada complejos, como son las imágenes. Aumentar el conjunto de entrenamiento suele acarrear el problema del sobre aprendizaje, es decir, la red se ajusta perfectamente a los datos de entrada, pero no ofrece buenos resultados ante nuevas imágenes.

Una práctica habitual para evitar el sobre aprendizaje es reservar una parte de los datos de prueba para crear un subconjunto llamado datos de validación. De forma periódica se repite el entrenamiento/prueba y se evalúa la red con este subconjunto para validar los meta-parámetros de diseño. Si los resultados de error en el subconjunto comienzan a aumentar, se asume que la red está aprendiendo excesivamente del conjunto de datos de entrenamiento, pero generalizando pobremente ante nuevos datos, con lo que se aborta el proceso de aprendizaje de forma temprana. Esta estrategia de trabajo supone necesitar de un conjunto de datos mayor: datos de entrenamiento, de prueba y de validación. Una asunción que se suele tomar es que el número de ejemplos de entrenamiento es a menudo proporcional al número de parámetros libres de la red.

Varias técnicas más se han propuesto para evitar este problema de sobre aprendizaje, aparte del de abortar la fase de entrenamiento de forma temprana; por ejemplo, ignorar ciertas variables de entrada a la red que pueden inducir a pobre generalización, lo que se conoce como podado de la red. Esto puede suponer una cantidad de procesamiento de estructuras alternativas exponencial, que se puede volver rápidamente intratable.

Redes neuronales convolucionales

La CNN (por sus siglas en inglés, Convolutional neural networks), es un tipo especializado de red neuronal para procesamiento de datos con una topología en grilla.

Estas redes tienen un tremendo éxito en aplicaciones prácticas; este nombre indica que la red emplea una operación matemática llamada convolución², la cual es un tipo especializado de operación lineal. Las redes convolucionales son simples redes neuronales que usan convolución en lugar de la matriz general de multiplicación, en al menos una de sus capas.

El *Neocognitrón* (**Figura 9**) de K. Fukushima, considerado el precursor de las redes neuronales convolucionales, es el primer modelo con estructura de conexiones que podemos considerar catalogable dentro del enfoque de aprendizaje profundo.

Es un modelo jerárquico y multinivel, su motivación es fuertemente biológica, basada en hallazgos de la estructura de conexiones y células del sistema nervioso visual.

² Se denomina convolución al proceso de distribución de una función f , en cada punto de otra función g (Mora González, y otros, 2008)




Figura 9. Estructura del Neocognitrón (Manzano Lizcano, 2015)

La red convolucional (**Figura 10**) es un tipo de red neuronal donde las neuronas individuales están conectadas a zonas denominadas campos receptivos que puede solaparse.

Comparadas con el enfoque tradicional, presentan la característica del aprendizaje profundo, consistente en que la red es responsable de aprender en su fase de entrenamiento los *kernels* o filtros convolucionales, que determinan los descriptores a los que va a ser sensible cada capa de la red. Esto tiene la ventaja de no ser dependiente de un conocimiento a priori de las características de las imágenes a analizar y también la inexistencia de una fase de complejo diseño de descriptores, tal como ocurre en otros modelos discriminativos.

Un ejemplo genérico de red neuronal convolucional se estructura con la alternancia de niveles de la siguiente figura:




Figura 10. Arquitectura de red neuronal convolucional (Manzano Lizcano, 2015)

En muchas aplicaciones no se dispone de una base de datos de entrenamiento con elevado número de muestras, lo que puede ser un problema, ya que las CNN requieren un gran conjunto de datos de entrada para evitar el sobre aprendizaje. Hay varias alternativas, una de ellas es aumentar el número de muestras mediante transformaciones de las imágenes de entrada, tales como rotaciones o pequeños cambios de escala. Otra posibilidad es entrenar la red con imágenes provenientes de un conjunto similar, al menos para aprendizaje de las capas inferiores. Posteriormente se continúa el entrenamiento con el conjunto de datos de interés. Este modelo mixto tiene visos de enfoque generativo, pero el entrenamiento del sistema sigue siendo un modelo discriminativo.

Alcance

Realizar el análisis, diseño e implementación de una aplicación que permita evaluar la posibilidad de identificar los estados fenológicos de la rosa, por medio de mecanismos de visión artificial.

Cronograma de Trabajo

Tabla 1. Cronograma de trabajo

Actividad	Duración	Inicio	Fin	Predecesor
Reconocimiento de imágenes	65 días	03/07/18	04/10/18	
Captura de fotografías	15 días	03/07/18	24/07/18	
Construcción componente clasificación manual	10 días	25/07/18	08/08/18	2
Construcción componente aislamiento de fondo	15 días	09/08/18	30/08/18	3
Construcción componente de clasificación multiclase	20 días	31/08/18	27/09/18	4
Pruebas y conclusiones	5 días	28/09/18	04/10/18	5

Metodología de trabajo

Se utilizará la metodología en cascada para la ejecución del proyecto, el cual tendrá las siguientes fases:

1. Análisis

- En esta fase se analizará las características de la cámara y la forma en que se deben capturar las fotos para realizar el entrenamiento del modelo de clasificación.

2. Diseño

- En esta fase se realizará la selección de los algoritmos y librerías a utilizar, como también el diseño de los diferentes componentes y pruebas de concepto.

3. Implementación de las funcionalidades

- En esta fase se realizará el entrenamiento del modelo de clasificación con los algoritmos seleccionados en la fase de análisis, pruebas unitarias y corrección de errores en los componentes desarrollados.

4. Pruebas

- En esta fase se realizarán las pruebas finales y se validará la viabilidad de identificación de los estados fenológicos de la rosa, según los resultados obtenidos.

Presupuesto

Tabla 2. Presupuesto del proyecto

Recurso	Valor (USD)
Captura de fotografías	1,700
Construcción componente de clasificación	5,700
Servidor de desarrollo (Microsoft Azure)	1,800
Total	9,200

Especificaciones Servidor de desarrollo

A continuación, se listan las especificaciones del servidor utilizado para el entrenamiento de los modelos:

CPU: 24 Núcleos

RAM: 224 GB

GPU: NVidia Tesla K80 4x Discos SSD

Habilitada para balanceo de carga.

(Azure NC24)

Captura de Fotografías

La captura de fotografías para el entrenamiento de los modelos de clasificación es fundamental para obtener una buena precisión del modelo. Para esto se debe identificar el tipo de cámara a utilizar y la posición de la cámara para la captura de las imágenes.

Validaciones condiciones del campo

- Altura requerida para captura del ancho del rosal
- Cobertura de la cama a lo largo del rosal
- Inclinación de la cama, requerida para la toma de fotografías

Toma de fotografías desde vista superior de la cama, con trípode, haciendo recorrido completo de la cama, identificando manualmente tallos en todos los estados fenológicos (Figura 11).



Figura 11. Vista superior de una cama de rosas

Toma de fotografías laterales a diferentes alturas.



Figura 12. Vista lateral de una cama de rosas

Toma de fotografías con cámara GoPro



Figura 13. Capturas realizadas a una cama de rosas usando cámara GoPro

Toma de fotografías con cámara análoga de resolución estándar



Figura 14. Capturas realizadas a una cama de rosas usando cámaras VGA

Como resultado del ejercicio, se obtienen los siguientes resultados:

- Se descarta la captura lateral, porque no es posible determinar el inicio y el fin de la cama de rosas.
- Se descarta el uso de cámara GoPro, porque el lente angular deforma la imagen y no es óptimo para el procesamiento.
- Las fotografías tomadas desde la parte superior son óptimas para la identificación de la mayoría de los tallos.
- La toma de fotografías de entrenamiento se debe realizar con una cámara HD.
- La altura óptima para la toma de fotografías es 2.5 metros.

Identificación de objetos de interés

Se realiza la identificación de objetos de interés utilizando Faster R-CNN y tres técnicas diferentes de contraste de color, obteniendo mejores resultados con la utilización de Faster R-CNN

Identificación de objetos de interés utilizando contraste de color

Mapa de calor de los detectores

El proceso para filtrar una imagen consiste en superponer una matriz de tamaño $N \times N$ (generalmente 3×3) a cada uno de los píxeles de la imagen. La matriz está compuesta por números enteros que expresan una transformación de la información en función del píxel central y los valores circundantes, luego, el resultado final se pondera y se divide por un escalar.

El proceso de filtrado consiste en la aplicación a cada uno de los píxeles de la imagen de una matriz de filtrado de tamaño $N \times N$ (generalmente de 3×3 , aunque puede ser mayor), compuesta por números enteros y que genera un nuevo valor mediante una función del valor original y los de los píxeles circundantes. El resultado final se divide entre un escalar, generalmente la suma de los coeficientes de ponderación, donde i y j representan, respectivamente, la fila y la columna de cada píxel, $ND_{i,j}$ su Nivel Digital y $ND'_{i,j}$, el Nivel Digital obtenido tras hacer el filtrado. (Ecuación 1).

$$ND'_{i,j} = \frac{ND_{i-1,j-1} + ND_{i,j-1} + ND_{i+1,j-1} + ND_{i-1,j} + ND_{i,j} + ND_{i+1,j} + ND_{i-1,j+1} + ND_{i,j+1} + ND_{i+1,j+1}}{9} \quad (1)$$

Hay que tener en cuenta que los bordes de la imagen no podrán procesarse, ya que la ventana de filtrado saldría de la imagen. De este modo se pierden $N - 2$ filas y $N - 2$ columnas por cada lado de la imagen (como ejemplo, para el caso de una matriz de 3×3). Una diferencia importante entre las técnicas de filtrado y las de visualización, es que el filtrado modifica necesariamente la imagen, ya que pretenden extraer información cuantitativa que debe almacenarse como una nueva capa, en lugar de una paleta de colores. Los filtros son operadores de vecindad de álgebra de mapas.

Utilizando esta técnica no se logran ver los estados fenológicos más pequeños (Figura 15).




Figura 15. Identificación de objetos de interés usando mapa de calor de los detectores

Detección de color y visión por computador tradicional (Histogramas, Color Space)

La segmentación de la imagen según patrones, consiste en la comparación de los distintos grupos de píxeles que componen la imagen con una serie de patrones previamente entrenados. A partir de dicha comparación se obtiene la probabilidad de pertenencia a cada uno de los patrones (o de no pertenencia a ninguno de ellos), obteniendo de esta forma una matriz de las mismas dimensiones que la imagen, con valores de probabilidad entre 0 y 1.0, susceptible de ser transformada en una imagen en escala de grises y segmentada a partir de un cierto umbral. De esta manera, aquellos conjuntos de píxeles cuya combinación de colores sea más similar a los patrones entrenados (tengan mayor probabilidad) serán aquellos considerados como candidatos a ser el objeto a seguir. Para el entrenamiento de los patrones y posterior comparación de las diferentes combinaciones de colores, se utiliza por una parte el algoritmo de Estimación – Maximización, que además actualiza los patrones entrenados de manera adaptativa, y por otro los histogramas correspondientes a los conjuntos de píxeles procesados. En su implementación práctica, se hace uso de las correspondientes herramientas de la librería OpenCV.

Utilizando esta técnica se hace separación de color por rangos y tonos, se obtiene alta entropía en la imagen entre estados y fondo (hojas similares a botones, Figura 16).




Figura 16. Identificación de objetos de interés usando histogramas, color space

Espectros de color HSL y HSV

El HSV (HueSaturation-Value, Matiz-Saturación-Brillo). Este modelo, a diferencia del RGB posee un matiz de colores circular, definida entre 0° a 360°, la saturación y el valor oscilan entre 0% a 100%. La transformación del espacio de color RGB a HSV está dada por (1), (2) y (3).

$$H(R, G, B) = \tan^{-1} \left(\frac{\sqrt{3}(G-B)}{(R-G)+(R-B)} \right) \quad (1)$$

$$S(R, G, B) = 1 - \frac{\min(R, G, B)}{R+G+B} \quad (2)$$

$$V = \text{Max}; \text{Max} = \{R, G, B\} \quad (3)$$

Para identificar el área de interés (objeto) dentro de la imagen obtenida, se establecen las condiciones del entorno, las cuales son, fondo blanco, iluminación constante o de poca variación y el color del objeto contrasta evidentemente con el fondo. Con base en estos elementos, la segmentación por histograma ofrece una alternativa viable para separar el objeto del resto de la imagen. Esta técnica requiere de la definición de un umbral, es decir, un rango de valores delimitados por un mínimo y un máximo, utilizado para discriminar los pixeles que no son parte del objeto. Para esto, se toma como referencia el histograma del canal S formado en el eje y, por el valor de los pixeles entre 0 y 1; y en el eje x, por la ocurrencia de los mismos en la imagen.

El canal S representa la saturación del color, los valores cercanos al 0 tienden al color blanco, por lo tanto, el fondo de la imagen cuya área es la mayor, se encuentra representada por los pixeles de mayor ocurrencia con valores cercanos al 0. Posteriormente, se binariza la imagen con el umbral definido para obtener la máscara de segmentación; al fondo se le asignan valores de 0 y al objeto valores en 1.

La máscara es una matriz de dimensiones NxM, del mismo tamaño que la imagen original. El producto puntal de estas dos matrices da como resultado la imagen segmentada; sin embargo, existe la probabilidad de encontrar defectos (huecos) en el área de interés.

Utilizando esta técnica se obtienen los mismos resultados de Histogramas y color space (Figura 17).




Figura 17. Identificación de objetos de interés usando HSL y HSV

Identificación de objetos de interés utilizando Faster-RCNN

De la imagen de entrada ocurren dos procesos que pueden ser realizados de forma independiente: la extracción de características de la imagen completa y la generación de proposals, estos se generan a partir de las características extraídas de las capas convolucionales de la red utilizada. A continuación, se realiza una proyección de los proposals sobre el mapa de características y por cada uno de ellos se realiza una clasificación.




Figura 18. Estructura del sistema Faster-RCNN

Como se ve en la Figura 18, el sistema consta de tres etapas:

1. Extracción de Proposals: Se generan alrededor de 2000 proposals utilizando Selective Search.

3. Clasificación: Se clasifican los proposals a partir de las características extraídas con SVM (Support Vector Machine). Usando CNN Multiclase.




Figura 19. Proceso que se ejecuta para la identificación y clasificación de objetos de interés (Estados fenológicos en la rosa)

El resultado final es la clasificación de los objetos de interés con su respectivo porcentaje de probabilidad.



Figura 20. Resultado de la ejecución de identificación y clasificación de objetos de interés (Estados fenológicos en la rosa)

La precisión obtenida para la clasificación de objetos de interés utilizando Faster RCNN es de 83.7%. Se realiza un ejercicio que consiste en disminuir los estados fenológicos a 6 estados, ya que las probabilidades en los estados 1,2 y 3 son muy bajos. En la Figura 21 se muestran los resultados de la ejecución de ambos modelos.







Figura 21. Precisión del modelo con 7 estados y 6 estados fenológicos

Realizando la disminución de un estado fenológico se mejora considerablemente la probabilidad en la predicción de los estados 1, 2 y 3. Como resultado se obtiene una precisión para el modelo de 6 estados fenológicos, de 90.85%.

Se desarrolla un segundo ejercicio, realizando una clasificación binaria entre los estados 2 y 3 en el modelo de 7 estados fenológicos, obteniendo una mejora en la precisión del modelo. La precisión obtenida después del ejercicio, es de 89%.


En la figura 22 se muestran 7 ejecuciones de clasificación de objetos de interés con su respectiva predicción y porcentaje de probabilidad.






Clase Original: **Arroz**
Clase Predicción: **Garbanzo**

FALSO




Clase Original: **Fondo**
Clase Predicción: **Fondo**

VERDADERO



Clase Original: **Corte**
Clase Predicción: **Corte**

VERDADERO



Clase Original: **Arroz**
Clase Predicción: **Arroz**

VERDADERO




Figura 22. Clasificación de Objetos de Interés.

Conclusiones

Es viable la identificación, clasificación y conteo de estados fenológicos en la rosa, utilizando algoritmos de reconocimiento de imágenes. La principal dificultad identificada es que todos los objetos de interés no son visibles en las fotografías, debido a que las hojas de las rosas más grandes tapan las flores más pequeñas.

El estado fenológico mas relevante para la estimación de corte en las fincas es el 3 (Bola). Esto debido a que, a partir de este estado, en promedio la flor esta lista para corte en cuatro semanas. El proceso manual que se realiza en las fincas actualmente solo cuenta las rosas que se encuentran en estado fenológico 3 (Bola), y el proceso de conteo dura 1 hora por cada bloque en promedio. Debido a que las rosas en este estado fenológico miden entre 1.60 y 1.80, la labor de conteo es difícil y en ocasiones el conteo no es preciso.

Utilizando reconocimiento de imágenes para la identificación de los estados fenológicos el proceso duraría entre 5 y 10 minutos por bloque, teniendo cámaras instaladas en cada cama del bloque. Adicionalmente se tendría la información de todos los estados fenológicos y no solo uno como en el proceso manual, permitiendo realizar análisis de crecimiento entre cada uno de los estados fenológicos para obtener un pronóstico de corte mas acertado.

Actividades sugeridas para realizar:

- La automatización de la captura de imágenes en las respectivas camas de rosas, para realizar el conteo de estados fenológicos de forma automática.
- Realizar un modelo de predicción de corte de rosa (cosecha), utilizando el conteo de los estados fenológicos y el tiempo de transición entre cada uno de los estados.
- Utilizar reconocimiento de imágenes para otros procesos en las fincas, como la clasificación de flor nacional y flor exportación.

Referencias

- Durán Suárez, J. (2017). Redes neuronales convolucionales en R : Reconocimiento de caracteres escritos a mano. Sevilla, España. Obtenido de <https://idus.us.es/xmlui/handle/11441/69564>
- Manzano Lizcano, J. A. (2015). Dialnet. *Sistema de ayuda al diagnóstico y reconocimiento de microcalcificaciones en mamografía mediante descriptores de escala y redes jerárquicas*. Madrid, España. Obtenido de Dialnet: <https://dialnet.unirioja.es/servlet/tesis?codigo=116508>
- MinComercio Industria y Turismo. (02 de 2018). *MinCit*. Recuperado el 25 de 05 de 2018, de http://www.mincit.gov.co/publicaciones/15815/informes_de_exportaciones
- Mora González, M., Casillas Rodríguez, F. J., Muñoz Maciel, J., Martínez, J. C., Luna Rosas, F. J., de Luna Ortega, C. A., . . . Peña Lecona, F. G. (2008). Reducción de ruido digital en señales ECG utilizando filtraje por convolución. *Investigación y Ciencia: de la Universidad Autónoma de Aguascalientes*, 40, 27. Obtenido de <https://dialnet.unirioja.es/servlet/articulo?codigo=6106127>