

DETECCIÓN DE YEMAS BROTADAS PARA LA ESTIMACIÓN TEMPRANA DEL RENDIMIENTO DE UNA PLANTACIÓN DE KIWI

Silvia N. Pérez¹, Gustavo A. Dejean¹, Mónica Giuliano¹, Alejandra Yommi³, María A. David³, Natalia L. Murillo⁴, Federico Balaguer², Ignacio A. García Ravlic¹, Dante H. Mendoza¹

¹Escuela de Informática, Universidad Nacional del Oeste

²Stream S.A., ³INTA, Estación Experimental Balcarce

⁴INTA, Agencia de Extensión Rural Otamendi

{sperez; gdejean; mgiuliano; igargia; hmendoza} @uno.edu.ar;

{yommi.alejandra; david.maria; murillo.natalia} @inta.gob.ar; federico.balaguer@digital-stream.com.ar

RESUMEN

Se presentan aquí resultados de detección de órganos vegetales en imágenes usando redes convolucionales, correspondientes a la primera etapa de un proyecto que propone desarrollar procedimientos para estimar en forma temprana el rendimiento de un lote de producción de kiwi. Para lograr la predicción del rendimiento, se consideran tres estadios fenológicos del crecimiento del kiwi y para validar, se dispondrá de resultados finales de cosecha. Para cada etapa se consideran 1000 imágenes, capturadas en toda el área cubierta por el cultivo, que permiten entrenar y elegir un modelo para conteo automático de objetos.

Además, el modelo se evalúa en 50 sitios elegidos al azar en la plantación, donde se compara el conteo manual con el conteo automático obtenido sobre imágenes de cada sitio. Los resultados en esta primera etapa, realizada sobre yemas brotadas en 47 sitios de la plantación, son promisorios en cuanto a la utilización de modelos de deep learning para detección de objetos y muestran la necesidad de profundizar en el ajuste de modelos y estrategias de conteo. Esto permite inferir que puede utilizarse el conteo automático como input en el modelo predictivo final. La metodología propuesta permitirá la predicción del rendimiento total de la plantación.

Palabras clave: *Procesamiento de Imágenes, Detección de objetos, Deep Learning, Estimación de producción.*

CONTEXTO

La línea de investigación que se presenta es parte del proyecto de investigación “Estimación temprana de rendimiento del cultivo de kiwi mediante el procesamiento de imágenes” que se desarrolla en forma conjunta por la Universidad Nacional del Oeste (UNO), el Instituto Nacional de Tecnología Agropecuaria (INTA) y la empresa Stream S.A. Cada una de estas entidades aborda los aspectos relacionados con su área de especialización [Dejean et al, 2021].

1. INTRODUCCIÓN

El kiwi (*Actinidia chinensis* var. *deliciosa*) es una planta introducida en Argentina en los años 80's, con una superficie en producción que se encuentra en crecimiento sostenido desde el año 2004. Actualmente se estima que hay cerca de 1000 ha plantadas de kiwi en el país, de las cuales 600 ha se sitúan en el sudeste de la provincia de Buenos Aires. Esta zona es la principal área productiva de kiwi, aportando más de la mitad del volumen nacional. [David et al, 2018, 2020].

El fruto de kiwi se posiciona internacionalmente como una fruta con muchos beneficios para la salud, lo que logró instalarlo en todo el mundo. En nuestro país se estima un consumo de medio kilo por habitante y por año [Ministerio de Agricultura, Ganadería y Pesca, 2020]. La producción se destina principalmente al mercado interno, aunque cubre sólo el 50% de la demanda total y el resto a la exportación (3000 tn en el año 2020). La importancia creciente del cultivo motiva investigaciones, fundamentalmente del INTA, que permitan

lograr un producto de calidad según estándares internacionales, a la vez que incrementar la producción local.

El éxito de una plantación de kiwi depende en gran medida de la cantidad de frutos cosechados por hectárea y de la proporción obtenida de frutos medianos a grandes, debido a que estos tamaños suelen tener precios diferenciales, mejorando el retorno económico [Testolin y Costa, 1992]. La cantidad de frutos obtenidos se sabe dependiente del número de yemas, del porcentaje de brotación de las yemas, del porcentaje de yemas brotadas que son reproductivas y del número de inflorescencias por brote reproductivo [Buwalda y Smith, 1988]. Esto motiva considerar como variables de estudio para la predicción del número de frutos, al conteo obtenido en cada una de tres estadios fenológicos: yemas brotadas (brotes/hojas), botones florales y frutos pequeños. El conteo automático de estos órganos frutales permite aprovechar la tecnología para lograr resultados más rápidos y eficientes en la toma de datos.

La utilización de tecnologías de detección de objetos en imágenes es una tendencia creciente en el área de producción frutihortícola [Sa 2016; Xia, 2022; Hussain, 2022]. Estos utilizan redes neuronales convolucionales profundas (DCNN, por sus siglas en inglés *Deep Convolutional Neural Networks*) para estimación de rendimiento de cultivos frutales, entrenando modelos para reconocimiento de objetos (frutos) en imágenes. Particularmente en producción de kiwi, varias publicaciones dan cuenta de la detección automática de frutos en una plantación como un desafío para la recolección por medios mecánicos automatizados [Williams et al, 2019; Song et al, 2019]. Una aplicación importante de las técnicas de DCNN corresponde a la detección de estadios tempranos del fruto con el objetivo de predecir la producción [Lim et al, 2020]. Actualmente, el método más utilizado para estimar el volumen de cosecha es el conteo visual de los frutos por unidad de superficie en una etapa avanzada. Esta modalidad conlleva dificultades en grandes plantaciones, así como también afecta la previsibilidad operativa dada

la cercanía con la etapa de cosecha. Una estimación temprana de la producción a obtener permitiría ajustar de modo sustentable los insumos necesarios para la producción, gestionar anticipadamente las necesidades operativas para la cosecha y controlar de modo más eficiente la capacidad de almacenamiento, así como gestionar la venta y distribución.

El brote de las yemas y el desarrollo de los botones florales y frutos a lo largo de la temporada es influenciado por las horas de frío acumuladas durante el periodo invernal, el perfil de heladas (duración e intensidad) y la cantidad de horas de stress térmico (considerando temperatura y humedad). Estas variables climáticas deben considerarse al momento de crear un modelo de predicción temprana del rendimiento. La obtención de este modelo a partir de los estadios más tempranos (yemas brotadas y botones florales) tendría mayores ventajas para el productor, aunque probablemente sea más complejo dado la mayor influencia de las variables climáticas.

En este proyecto se propone la identificación, conteo y seguimiento de brotes, botones florales y frutos pequeños de una plantación de kiwi, mediante la utilización de métodos de deep learning para detección de objetos en imágenes. El objetivo final de esta tarea es obtener estimaciones tempranas de rendimiento de producción de kiwi. Para esto, trabajan de modo colaborativo profesionales de la Fruticultura juntamente con otros de Informática y Procesamiento digital de la información.

2. LÍNEAS DE INVESTIGACIÓN Y DESARROLLO

La línea de investigación aquí presentada da una nueva perspectiva para UNO, correspondiente al procesamiento de imágenes con redes convolucionales (DCNN).

El proyecto propone estimar la cantidad de frutos de kiwi a producir en base al procesamiento de imágenes para detección y conteo automático de objetos en la plantación. Se suman a estas, mediciones obtenidas por sensores con datos de temperatura del aire,

humedad relativa, entre otras mediciones en la plantación. La detección de objetos en imágenes se realiza en cada una de tres etapas fenológicas asociadas a estados tempranos de desarrollo del cultivo: brotes/hojas, botones florales y frutos pequeños. Para esto se emplean modelos predictivos de *deep learning* para la detección de objetos, generando el conteo automático según cada etapa, los que se comparan con el conteo manual in situ.

La plantación de kiwi en estudio ocupa 2,2 hectáreas y se ubica cercana a la ciudad de Miramar, en la Provincia de Buenos Aires. Para lograr los objetivos del proyecto, se tomaron imágenes en distintos estadios fenológicos del cultivo, recorriendo toda la superficie de la plantación. Además, se colocaron al azar 50 marcos de 1 metro de ancho por 2,5 metros de largo, que se fijaron en plantas femeninas, donde se realizan los conteos manuales e imágenes. Los marcos se distribuyen según criterios de muestreo de la producción de la plantación.

Para cada una de las tres etapas de desarrollo del kiwi se consideraron dos tipos de imágenes: las de tipo A se corresponden a imágenes en variados puntos de la plantación en diferentes momentos del día con condiciones de iluminación variada. Las imágenes tipo B se corresponden con los 50 marcos y son utilizadas para comparación del modelo automático con el conteo manual. Las imágenes tipo A son aproximadamente 1000 por cada etapa y las de tipo B son tres por cada marco. El primer conjunto de imágenes es etiquetado manualmente para luego entrenar el modelo y aplicarlo a la detección de objetos en las imágenes de tipo B. Con esto, las imágenes tipo B permiten evaluar el modelo obtenido en contraste con la “verdad de campo” (conteo manual).

Las imágenes tipo A son etiquetadas por un operador y luego se separan al azar en tres conjuntos: entrenamiento, validación y prueba (65%, 34% y 1% respectivamente). Esto significa que cada una de esas imágenes tiene un cuadro delimitador para cada objeto encontrado por el operador.

En cada una de las tres etapas fenológicas, de forma independiente, se consideran modelos de redes convolucionales pre-entrenados, los que luego se ajustan a los datos propios utilizando los conjuntos de entrenamiento y validación, recursivamente hasta lograr convergencia en parámetros de pérdida. La evaluación de la calidad de cada uno de estos modelos se realiza analizando la detección sobre imágenes de prueba, las que se comparan con las imágenes originales. Esto permite seleccionar un modelo entre todos los modelos en competencia utilizando métricas usuales de calidad. Posteriormente, se comparan los conteos de detecciones obtenidos por el modelo elegido sobre las imágenes tipo B, con el conteo manual realizado por otros operadores en la misma plantación de kiwi.

En el proceso de detección se fija como probabilidad mínima para considerar detectado un objeto, un valor de corte de 0,5.

Para evaluar la calidad de un modelo se consideran tres métricas básicas: precisión y sensibilidad o *recall*, las cuales se definen como

$$\text{Precisión} = \text{VP} / (\text{VP} + \text{FP}) \quad \text{Recall} = \text{VP} / (\text{VP} + \text{FN})$$

donde:

VP: verdaderos positivos (yemas con brotes/hojas reales que fueron bien predichos por el modelo);

FP: falsos positivos (predichos erróneamente como yemas con brotes/hojas, también llamados detecciones falsas)

FN: falsos negativos (yemas con brotes/hojas que no fueron detectados por el modelo, también llamadas detecciones pérdidas)

Otra métrica de interés para medir la calidad del modelo es F1, que combina precisión y recall y se define como:

$$F1 = 2 * \text{precisión} * \text{recall} / (\text{precision} + \text{recall})$$

El procedimiento descrito permite elegir un modelo para el conteo automático en cada una de las tres etapas fenológicas. Estos conteos serán utilizados como input del modelo predictivo final. El conteo de frutos de la cosecha de cada uno de los marcos será la variable respuesta del conjunto de datos. Los resultados a obtener permitirán la predicción del rendimiento total de la plantación. Se

podrán jerarquizar los modelos según etapa fenológica y además mejorarlos sumando otras variables, como por ejemplo meteorológicas.

3. RESULTADOS OBTENIDOS Y ESPERADOS

Hasta el momento se completó la obtención de imágenes A y B, además de conteos manuales, para las tres etapas fenológicas (brotes/hojas, botones florales y frutos pequeños).

Con los conjuntos de entrenamiento y validación de imágenes tipo A de brotes/hojas, se entrenaron diferentes modelos que fueron validados apropiadamente. Para la elección del modelo a utilizar en el conteo automático en las imágenes B, se tomó en cuenta la métrica F1 la cual combina precisión y *recall*. El mejor valor obtenido fue $F1=0,915$.

La Fig. 1 muestra la detección de yemas con brotes/hojas realizada por el modelo seleccionado en una porción de uno de los marcos. La Fig. 2 muestra un detalle de la detección de un brote, donde se aprecia la probabilidad con la que fue detectado como tal.

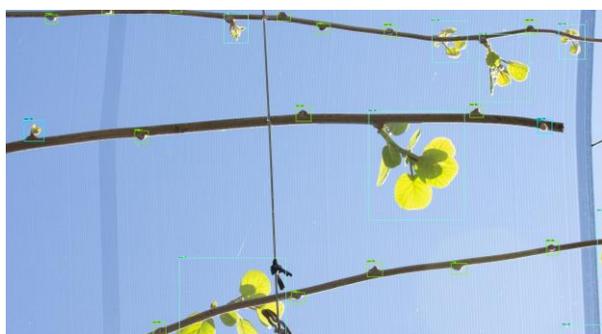


Fig. 1: Yemas con brotes/hojas detectadas por el modelo.



Fig.2. Detalle de la Fig.1 donde se observa la probabilidad con que se detectó el brote.

El conteo automático realizado sobre cada marco (Mo) se comparó con el conteo manual in situ (Ma). Las diferencias entre ambos valores, relativas al conteo manual, permite evaluar el error del modelo en cada imagen. De los 50 marcos de la plantación se juzgaron útiles sólo 47. En la Tabla 1 se observa los valores promedio de conteo automático y conteo manual, 23,60 y 26,68, respectivamente, así como el promedio de la diferencia relativa resultó de -0,10.

Medida	conteo del modelo (Mo)	conteo manual (Ma)	$\frac{(Mo-Ma)}{Ma}$
Promedio	23,60	26,68	-0,10
Mínimo	9	13	-0,44
Máximo	37	44	0,75

Tabla 1: Comparación relativa de conteos (n=47)

En la etapa de yemas con brotes/hojas se observa que el modelo automático subestima el conteo en general en los marcos, sin embargo, en el 83% de los mismos se obtuvo un error en valor absoluto inferior a 0,25. Dado que se observaron algunas diferencias importantes entre ambos conteos, se realizó una revisión de los casos particulares lo que sugiere revisar las estrategias del conteo manual. Esto motiva la necesidad de replicar el ensayo en la próxima temporada introduciendo un control mayor en los conteos en los marcos.

La acumulación de horas de frío invernales y las temperaturas en primavera inciden sobre la brotación y la diferenciación de las yemas. En años en que se acumulan al menos 950 horas de frío y las temperaturas son cálidas, se espera una alta brotación de yemas, con predominancia de yemas reproductivas que darán fruta, respecto a las vegetativas, que sólo producen brotes y hojas. Se evaluará la influencia de las horas de frío acumuladas y de las temperaturas, así como la ocurrencia de heladas, en las predicciones de rendimiento basadas en el conteo automático de yemas para considerarlas en el modelo predictivo.

Se continuará con la evaluación de modelos predictivos a partir de la detección automática y manual de botones florales y de frutos

pequeños. Considerando alguno de los estadíos fenológicos en estudio, se espera lograr un modelo predictivo para estimar tempranamente el rendimiento (n° de frutos/ha) de la producción de kiwi a partir de imágenes, que a su vez podrá mejorarse en las siguientes temporadas.

En la etapa cumplida hasta el momento se obtuvieron resultados promisorios al aplicar algoritmos de *deep learning* para la detección de yemas brotadas.

La estimación temprana del rendimiento de un cultivo de kiwi fue planteada como una necesidad por productores del sudeste de la provincia de Buenos Aires. Los productores, a través del INTA, tendrán una herramienta para estimar la producción y contribuir con una mejor gestión de los recursos ambientales y de los insumos. Esto permitirá mejorar la gestión de la cosecha, el almacenaje de la fruta y su comercialización, y también beneficiará a empacadores y exportadores.

Se considera que, más allá de cumplidos los objetivos de estimación temprana del rendimiento, esta línea de investigación permite formar un equipo de trabajo capaz de proponer nuevos proyectos relacionados con detección automática de objetos, aplicables en otros cultivos frutihortícolas.

4. FORMACIÓN DE RECURSOS HUMANOS

En el proyecto participan siete investigadores formados y dos becarios alumnos. Estos últimos se inician de este modo en la investigación en el área de informática aplicada. El trabajo realizado ha permitido también la realización del trabajo final de carrera de la Licenciatura en Informática de uno de los alumnos becarios.

5. BIBLIOGRAFÍA

[Buwalda y Smith, 1988] Buwalda, J.G. and Smith, G.S. 1988. A mathematical model for predicting annual fertiliser requirements of kiwifruit vines. *Scientia Hort.* 37:71-86.

[David et al, 2018] David, M.A., Yommi, A., Sánchez, E. 2018. Fenología del cultivo de kiwi en el sudeste de Buenos Aires.

<https://inta.gov.ar/documentos/fenologia-del-cultivo-de-kiwi-en-el-sudeste-de-buenos-aires>.

- [David et al, 2020] David, M.A., Yommi, A., Sanchez, E. 2020. Elección del terreno y plantación del cultivo de kiwi. 1a ed. Balcarce, Buenos Aires: Ediciones INTA. Libro digital, 39 p.
- [Dejean et al, 2021] Dejean, G., Balaguer, F., Yommi, A., Doorn, J., David, A., Murillo, N., García I., Mendoza, D. Integración del Procesamiento Imágenes e Internet de las Cosas en la estimación temprana del rendimiento de cultivos frutales. XXIII Workshop de Investigadores en Ciencias de la Computación (WICC 2021, Univ. Nac. de Chilecito).
- [Hussain et al, 2022] Hussain, D.; Hussain, I.; Ismail, M.; Alabrah, A.; Ullah, S.; Alaghbari, H. (2022) A Simple and Efficient Deep Learning-Based Framework for Automatic Fruit Recognition, *Computational Intelligence and Neuroscience*, vol. 2022, Article ID 6538117, 8 pages, 2022.
- [Lim et al, 2020] Lim, J.; Ahn, H.S.; Nejati, M.; Bell, J.; Williams, H.; MacDonald, B.A. Deep Neural Network Based Real-time Kiwi Fruit Flower Detection in an Orchard Environment. arXiv 2020, arXiv:2006.04343.
- [Ministerio de Agricultura, Ganadería y Pesca, 2020] Ministerio de Agricultura, Ganadería y Pesca, 2020. Cadena de kiwi. 16 págs. http://www.alimentosargentinos.gov.ar/HomeAlimentos/Cadenas%20de%20Valor%20de%20Alimentos%20y%20Bebidas/informes/Resume_n_Cadena_KIWI_ENERO_2020.pdf
- [Sa et al, 2016] Sa I, Ge Z, Dayoub F, Upcroft B, Perez T, McCool C. DeepFruits: A Fruit Detection System Using Deep Neural Networks. *Sensors*. 2016; 16(8):1222.
- [Song et al, 2019] Song, Z., Fu, L., Wu, J., Liu, Z., Li, R., & Cui, Y. (2019). Kiwifruit detection in field images using Faster R-CNN with VGG16. *IFAC-PapersOnLine*, 52(30), 76-81.
- [Testolin y Costa, 1992] Testolin, R., and Costa, G. 1992. Modelling a kiwifruit orchard. *Acta Hort.* 313:99-103.
- [Williams et al, 2020] Williams, H. A., Jones, M. H., Nejati, M., Seabright, M. J., Bell, J., Penhall, N. D., ... & MacDonald, B. A. (2019). Robotic kiwifruit harvesting using machine vision, convolutional neural networks, and robotic arms. *biosystems engineering*, 181, 140-156.
- [Xia et al, 2022] Xia, X.; Chai, X.; Zhang, N.; Zhang, Z.; Sun, Q.; Sun, T. Culling Double Counting in Sequence Images for Fruit Yield Estimation. *Agronomy* 2022, 12, 440.