

Adaptación de Dominio en Imágenes para una Mejor Detección de Espigas de Trigo

Domain Adaptation in Images for a Better Wheat Head Detection

Salas Ibañez, Jesús Eduardo; Moreno Chávez, Gamaliel
 Unidad Académica de Ingeniería Eléctrica
 Universidad Autónoma de Zacatecas
 Zacatecas, México
 eduardo.si@uaz.edu.mx

Palabras clave: IAR, espigas de trigo, adaptación de dominio, detección de objetos, visión por computadora, aprendizaje profundo.

Resumen- La densidad de espigas es un componente importante a la hora de determinar la cosecha de trigo. Por esta razón, se ha propuesto estimarla mediante un conteo automático de las espigas de trigo en imágenes a color, tarea en la cual los modelos de redes neuronales para detección de objetos han demostrado gran capacidad. Sin embargo, estos modelos pueden enfrentar problemas para identificar correctamente las espigas cuando existe mucha variación visual en su aspecto en distintas imágenes. Este trabajo presenta una forma de atacar este problema mediante la aplicación de un algoritmo de adaptación de dominio basada en transporte óptimo, con el cual se puede cambiar la paleta de colores de una imagen para que sea visualmente más parecida a otra, reduciendo así parte de esta variación visual. Al aplicar este algoritmo a las imágenes de la base de datos Global Wheat Head Detection 2021, se encontró que se puede aumentar el mAP50 de un modelo YOLOv5s hasta en un 4.1%, lo cual muestra el potencial que tienen las técnicas de adaptación de dominio en la mejora del desempeño de un modelo de detección de objetos.

Keywords: IAR, wheat heads, domain adaptation, optimal transport, object detection, neural networks.

Abstract- Spike density is an important parameter when determining the wheat yield. For this reason, it has been proposed to estimate it through the automatic counting of wheat heads in color images, a task in which object detection neural network models have demonstrated great capability. However, these models may face difficulties in correctly identifying wheat heads when there is significant visual variation in their appearance across different images. This work presents a way to address this issue by applying a domain adaptation algorithm based on optimal transport, which allows for changing the color palette of an image to make it visually more similar to another one, thereby reducing part of this visual variation. By applying this algorithm to the images from the Global Wheat Head Detection dataset 2021, it was found that the mAP50 of a YOLOv5s model can be increased by up to 4.1%, demonstrating the potential of domain adaptation techniques in improving the performance of an object detection model.

1. Introducción

El trigo posee un rol estratégico en la seguridad alimentaria mundial ya que es el cultivo más extendido en el mundo, con un estimado de 216 millones de hectáreas de área

sembrada en 2019 y una producción anual por país de más de 10000 toneladas. Sin embargo, en los siguientes años, la producción de trigo se verá desafiada a consecuencia del cambio climático, por lo que la adopción de nuevas tecnologías en esta área representa una

oportunidad para enfrentar estos retos y asegurar una producción sustentable [1].

El número de espigas por unidad de área o densidad de espigas es uno de los componentes agronómicos más importantes a la hora de determinar la cosecha de grano en el trigo [2]. Identificar las espigas mediante un conteo manual en el campo es un proceso lento y propenso a errores, por lo que las tecnologías de visión por computadora proporcionan una alternativa para hacer más viable esta tarea y además pueden asistir en el monitoreo del crecimiento del trigo en tiempo real [3]. Las imágenes a color de alta resolución, que pueden ser obtenidas a partir de cámaras digitales, permiten evaluar a detalle la estructura y textura de las plantas. El procesamiento de estas imágenes, principalmente con la introducción de las redes neuronales artificiales, ha tenido un impacto significativo en la automatización del monitoreo de los cultivos en años recientes [4].

De acuerdo a revisiones de artículos sobre el uso de técnicas de inteligencia artificial en la predicción de cosechas [5] y conteo de plantas [6], existen algunos estudios que utilizan técnicas de extracción de características de color, textura y morfología junto a algoritmos clásicos de machine learning como regresión lineal, bosques aleatorios o máquinas de vectores de soporte. Sin embargo, algunos de estos estudios citaban la poca disponibilidad de datos y la poca variación en las condiciones de obtención de estos como algunos de sus principales problemas, por lo que el desarrollo reciente de bases de datos más extensas y variadas, así como la disponibilidad de mejores GPUs, han causado un cambio en el enfoque de este tipo de investigaciones hacia el uso de redes neuronales. En este sentido, las redes neuronales convolucionales (CNN) han destacado sobre las demás, principalmente con arquitecturas como RCNN, YOLO, SSD, EfficientDet, entre otras.

A pesar de la ventaja que suponen las técnicas basadas en tecnologías de visión por computadora, su uso para la identificación de espigas de trigo presenta múltiples obstáculos, entre los que se encuentran la variación de tamaño, forma y textura de las espigas, las distintas condiciones de iluminación en las imágenes, o la oclusión total o parcial de algunas espigas debida a la presencia de otras [3].

Para que un modelo de redes neuronales pueda superar los obstáculos antes mencionados e identificar de manera eficiente las espigas, es necesaria una base de datos que contenga imágenes que contemplen todas estas situaciones, incluyendo distintas variedades de trigo, etapas de desarrollo de la planta y condiciones de adquisición de las imágenes. Con este fin, [7] introdujo la base de datos Global Wheat Head Detection (GWHD), la cual en su versión 2021 contiene imágenes de espigas de trigo proporcionadas por 16 instituciones de 12 países y tiene como objetivo servir de punto de referencia para evaluar el desempeño de algoritmos en la tarea de identificación de espigas. Esta base de datos fue creada a partir del Global Wheat Challenge (GWC) en donde se buscaba los modelos de redes neuronales con mejor desempeño para la detección de espigas, siendo la red YOLOv5 la arquitectura más popular entre las soluciones ganadoras de la edición 2021 [8].

Las redes neuronales entrenadas en un cierto dominio pueden tener un desempeño reducido cuando son aplicadas a otro dominio, siendo este un problema relevante en el contexto de las plantas debido a que pueden existir cambios de dominio dentro de bases de datos de plantas de una misma especie, debidos principalmente a las diferencias en el equipo y las ubicaciones en que se tomaron las imágenes, la época del año, edad de la planta, entre otras. Por estas razones, los métodos de adaptación de dominio son utilizados para alterar las imágenes de entrenamiento para que

coincidan de mejor manera con un dominio objetivo, mejorando así el desempeño en las imágenes de prueba [9].

En este trabajo, se presenta una metodología de adaptación de dominio basada en la teoría de transporte óptimo, con la cual se pretende homogeneizar la distribución de colores en las imágenes de la base de datos GWHD 2021 para incrementar el desempeño del modelo YOLOv5s en la detección de espigas de trigo.

2. Metodología

2.1 Descripción de las imágenes

Las imágenes utilizadas para este análisis corresponden a las de la base de datos GWHD 2021 [5], la cual consta de 6515 imágenes a color, divididas en 3657 imágenes para el entrenamiento del modelo, 1476 para la validación y 1382 para pruebas. Esta base de datos se divide en 47 sub bases de datos o “dominios”, donde cada uno de ellos corresponde a un conjunto de imágenes adquiridas en la misma unidad experimental, durante la misma sesión de adquisición y con el mismo sensor. En la (Fig. 1) se puede observar un gráfico de la distribución de estos dominios de acuerdo a la etapa de desarrollo en que se encuentran las plantas que aparecen en las imágenes.

Durante la investigación se asumió que dentro de un dominio existe una distribución de colores similar en todas las imágenes, por lo que la adaptación de dominio se abordó como un cambio en esta distribución de colores en las imágenes de un dominio de origen, con el objetivo de que se parezcan a la distribución de colores de un dominio objetivo. Este proceso se abordó mediante un código de Python basado en un ejemplo del paquete “GeomLoss” [10], en el cual se aborda la transferencia de color con transporte óptimo (OT, por sus siglas en inglés) haciendo uso de la GPU.

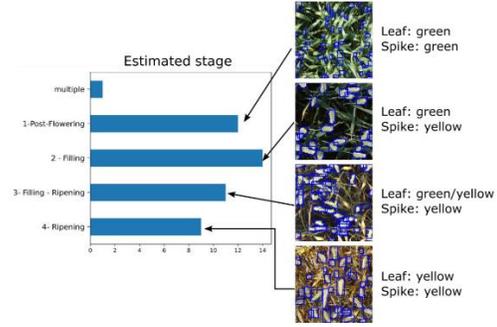


Figura 1. Distribución de los dominios de la base de datos y características de sus imágenes [7].

2.2 Planteamiento del problema de OT para la adaptación de dominio

El OT es un área de las matemáticas que tiene como objetivo resolver el problema de encontrar la manera más eficiente de transformar una distribución de masas en otra, relativo a una función de costo dada [11]. Sea $\Omega \in \mathbb{R}^d$ un espacio medible de dimensión d , $P(\Omega)$ denota el conjunto de todas las medidas de probabilidad sobre Ω . Si Ω_s y Ω_t son un dominio de origen y un dominio objetivo respectivamente y X son los elementos de Ω , entonces se consideran μ_s y μ_t como sus respectivas distribuciones marginales sobre X [12]. También se considera una transformación no lineal del espacio de entrada $T: \Omega_s \rightarrow \Omega_t$, la cual transforma la medida μ en su medida imagen denotada por $T_{\#}\mu$, que es otra medida de probabilidad sobre Ω_t , y que satisface la condición

$$T_{\#}\mu(x) = \mu(T^{-1}(x)), \quad \forall x \in \Omega_t(1)$$

En la Ec. (1), T es llamado el mapa de transporte de μ_s a μ_t si $T_{\#}\mu_s = \mu_t$. Para encontrar T , se propuso que éste minimice el costo del transporte $\mathcal{C}(T)$, el cual se puede expresar mediante

$$\mathcal{C}(T) = \int_{\Omega_s} c(x, T(x)) d\mu(x) (2)$$

donde la función de costo $c: \Omega_s \times \Omega_t \rightarrow \mathbb{R}^+$ en la Ec. (2) es una función de distancia sobre el espacio métrico Ω [12].

A diferencia de lo planteado por la Ec. (2) en las imágenes se considera un OT discreto, por lo que, de acuerdo a Feydy et al. [10], se definen dos medidas de probabilidad discretas α y β en el espacio RGB $[0,1]^3$:

$$\alpha = \frac{1}{N} \sum_{i=1}^N \delta_{xi}, \quad \beta = \frac{1}{M} \sum_{j=1}^M \delta_{yj} \quad (3)$$

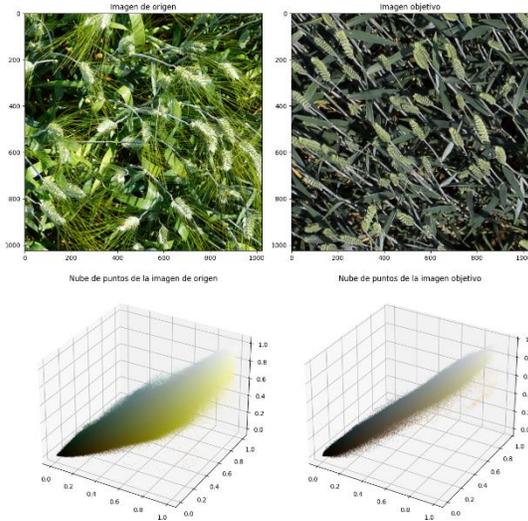


Figura 2. Representación de las imágenes como nubes de puntos en el espacio RGB.

donde $x \in (\mathbb{R}^3)^N$ y $y \in (\mathbb{R}^3)^M$ son tensores con valores reales y de dimensiones $(N,3)$ y $(M,3)$, que representan la información de los píxeles en cada uno de los tres canales de color. Por lo tanto, la adaptación de dominio se realizó con el objetivo de que la imagen de la izquierda en la (Fig. 2) termine con una paleta de colores más parecida a la de la imagen de la derecha, y para hacer esto posible se hace uso de la representación de ambas imágenes como nubes de puntos.

El OT se calcula a través de una aproximación con la divergencia de Sinkhorn $S_{\epsilon,\rho}$, ya que el algoritmo de Sinkhorn es utilizado para acelerar la convergencia del OT [10]. Como función de costo se utiliza la distancia de Wasserstein con $p = 2$, y al hacerlo, se encuentra que el gradiente de la divergencia de Sinkhorn

$$v_i = \frac{1}{\alpha_i} \nabla_{xi} S_{\epsilon,\rho}(\alpha, \beta) \quad (4)$$

define un mapeo cuya suavidad y alcance máximos se pueden definir como dos parámetros $blur = \sqrt{\epsilon}$ y $reach = \sqrt{\rho}$, respectivamente. Los parámetros $(\epsilon, \rho) = (0, +\infty)$ definen un OT perfecto, pero entre más se acerquen los parámetros a estos valores, al algoritmo le llevará más tiempo converger.

2.3 Proceso para la detección de las espigas en las imágenes

Para poder medir el efecto de la adaptación de dominio con OT en la identificación de espigas, primero se entrenó la red neuronal de detección de objetos YOLOv5s, la cual es una red de tipo convolucional desarrollada en Pytorch y con una arquitectura dividida en tres secciones: tronco, cuello y cabeza [13]. Este entrenamiento se hizo mediante el paquete “Ultralytics” [14] y utilizando un modelo pre-entrenado en la base de datos COCO. Primero se entrenó el modelo con las imágenes de entrenamiento de la GWHD 2021 sin alterar, y se obtuvieron algunas métricas del desempeño de este modelo en los conjuntos de imágenes de validación y prueba. Posteriormente, se eligió un dominio objetivo de la base de datos y se realizó la adaptación de dominio de las imágenes de los demás dominios hacia este. Como el algoritmo de transferencia de color se realiza entre dos imágenes, para cada imagen de cada uno de los dominios de origen se eligió aleatoriamente una imagen del dominio objetivo. Una vez que se creó una copia de la base de datos con todas las imágenes adaptadas, se volvió a entrenar el modelo y se obtuvieron sus métricas de desempeño.

Tabla 1. Características del equipo de cómputo.

| MSI Pulse GL66 12UGKV | |
|-----------------------|-------------------------------|
| Sistema operativo | Ubuntu 22.04.3 (WSL2) |
| Procesador | Intel Core i7-12700H 2.70 GHz |
| RAM | 32 GB DDR4 |
| Tarjeta gráfica | NVIDIA GeForce RTX 3070 |

Este proceso se repitió algunas veces, haciendo la selección de dos dominios objetivo distintos y probando cuatro combinaciones de los parámetros de blur y reach para cada dominio.

Los códigos utilizados para esta investigación fueron desarrollados en Python. En la Tabla 1 se muestran las características del equipo de cómputo en que se ejecutaron todos los códigos. Para cada una de las cuatro elecciones de parámetros, se estableció la semilla aleatoria 0 para que la elección de las imágenes del dominio objetivo siempre fuera la misma. En cuanto al modelo YOLOv5s, también se estableció una semilla 0 para asegurar la reproducibilidad de los resultados eligiendo la misma configuración de parámetros en cada entrenamiento. Estos parámetros fueron un tamaño de imagen de 640x640, 100 épocas de entrenamiento y una paciencia de 10, dejando los demás parámetros con los valores por defecto que establece Ultralytics. La entrada de la red es un tensor de tamaño (3,640,640) que representa a la imagen de 3 canales y 640x640 píxeles por canal, mientras que su salida es un tensor de tamaño (N,6), donde N es el número de objetos detectados en la imagen, y el 6 representa las 4 coordenadas xywh que definen el cuadro delimitador de un objeto, más un nivel de confianza para el objeto y su índice de clase.

La validación del modelo se realizó mediante la división de los datos en tres conjuntos: uno de entrenamiento donde se aprenden los parámetros de la red, uno de validación para evaluar las predicciones del modelo y optimizar sus parámetros en base a estas predicciones, y finalmente uno de prueba que sólo se utiliza al final para evaluar el desempeño del modelo en imágenes no vistas [15]. Estos tres conjuntos se utilizaron de acuerdo a la división establecida por los autores de la base de datos y que se menciona al principio de esta sección.

3. Resultados y discusión

Como primer paso del análisis, se observaron los resultados en la adaptación de dominio con el fin de comprobar que el algoritmo funciona correctamente en las imágenes de espigas de trigo. A partir de esto, se realizaron pruebas con tres combinaciones de los parámetros de blur y reach eligiendo dos imágenes objetivo de dominios distintos. Se eligió una imagen al azar para realizar la adaptación de dominio y los resultados de ésta pueden observarse en la (Fig. 3), donde puede verse en la fila del medio que la imagen de origen posee colores muy parecidos a los de la imagen objetivo del dominio 1, y lo mismo sucede en el caso del dominio 2 en la fila de abajo. Entonces, se encuentra que el algoritmo realiza de manera correcta la transferencia de colores de una imagen a otra.

Siguiendo la metodología descrita al final de la sección anterior, se encontró primero el desempeño del modelo de detección de objetos con las imágenes sin alterar. Para evaluar este desempeño se reportan tres métricas estándar de la detección de objetos: Precision, Recall y mAP50. Los resultados de esta etapa pueden verse en la Tabla 2, donde se reportan tanto para el conjunto de imágenes de validación como para el de imágenes de prueba.

Posteriormente, se realizó el proceso de adaptación de dominio de todas las imágenes con las cuatro combinaciones de parámetros mencionadas y eligiendo los dominios identificados por los nombres Arvalis_3 y

ETHZ_1 dentro de la base de datos GWHD 2021. Los resultados de la detección de objetos para estos casos pueden observarse en las Tablas 3 y 4 respectivamente.

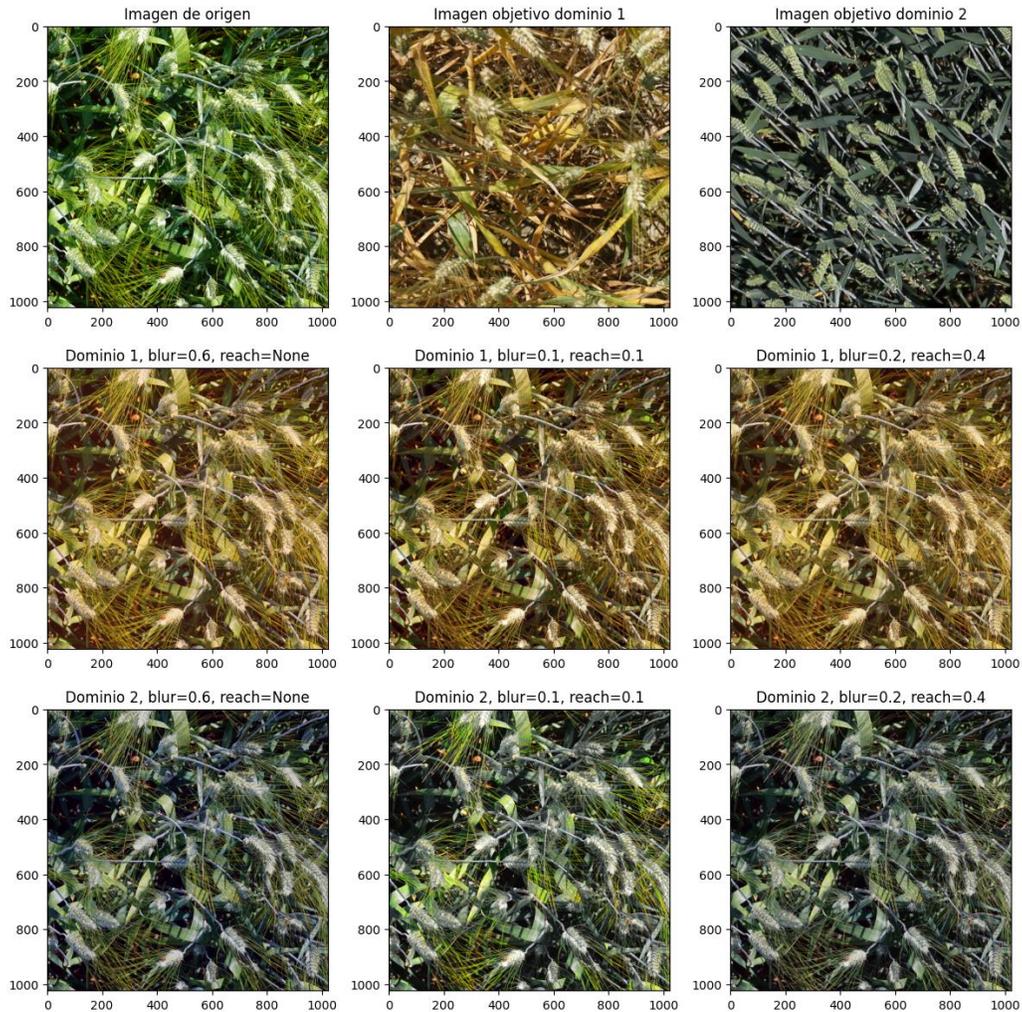


Figura 3. Resultado de la adaptación de dominio con dos dominios objetivo y distintos parámetros.

Comparando estas métricas se puede observar que en el dominio ETHZ_1, el cual corresponde a imágenes como la del dominio 2 en la (Fig. 3), se obtienen mejores resultados que los de la Tabla 3 en todos los casos, y también en tres de las cuatro combinaciones de parámetros se consigue mejorar los resultados de la Tabla 2. En cambio, los resultados en el dominio Arvalis_3, que corresponde a imágenes como el dominio 1 de la (Fig. 3),

sólo logran superar los resultados de la Tabla 2 en una ocasión.

Tabla 2. Resultados de la detección de espigas para las imágenes sin modificar.

| Conjunto de imágenes | Precision | Recall | mAP50 |
|----------------------|-----------|--------|-------|
| Validación | 0.908 | 0.827 | 0.905 |
| Prueba | 0.792 | 0.618 | 0.701 |

También, se puede ver que para ambos dominios los mejores resultados obtenidos se hicieron con los parámetros de $blur = 0.6$ y $reach = \infty$, donde este último es el valor por

defecto del parámetro. Esto quiere decir que la elección de parámetros resulta también importante para lograr una adaptación de dominio que mejore la detección de espigas.

Tabla 3. Resultados de la detección de espigas realizando la adaptación de las imágenes hacia el dominio Arvalis_3 con distintas combinaciones de parámetros.

| Parámetros | | Validación | | | Prueba | | |
|------------|-------|--------------|--------------|--------------|--------------|--------------|--------------|
| blur | reach | Precision | Recall | mAP50 | Precision | Recall | mAP50 |
| 0.1 | 0.1 | 0.903 | 0.799 | 0.889 | 0.758 | 0.564 | 0.645 |
| 0.6 | - | 0.914 | 0.841 | 0.914 | 0.806 | 0.630 | 0.709 |
| 0.6 | 0.3 | 0.906 | 0.815 | 0.894 | 0.744 | 0.594 | 0.671 |
| 0.2 | 0.4 | 0.906 | 0.799 | 0.886 | 0.758 | 0.554 | 0.637 |

Tabla 4. Resultados de la detección de espigas realizando la adaptación hacia el dominio ETHZ_1 con distintos parámetros.

| Parámetros | | Validación | | | Prueba | | |
|------------|-------|--------------|--------------|--------------|--------------|--------------|--------------|
| blur | reach | Precision | Recall | mAP50 | Precision | Recall | mAP50 |
| 0.1 | 0.1 | 0.912 | 0.850 | 0.917 | 0.802 | 0.633 | 0.712 |
| 0.6 | - | 0.912 | 0.857 | 0.923 | 0.824 | 0.663 | 0.742 |
| 0.6 | 0.3 | 0.920 | 0.862 | 0.924 | 0.829 | 0.648 | 0.732 |
| 0.2 | 0.4 | 0.909 | 0.833 | 0.907 | 0.794 | 0.613 | 0.690 |

4. Conclusiones

La adaptación de dominio, abordada como una transferencia de colores en imágenes de espigas de trigo y realizada mediante el OT con la divergencia de Sinkhorn, tiene el potencial de mejorar la detección de espigas de un modelo YOLO. Sin embargo, no siempre se logrará mejorar la detección, ya que se puede observar que la elección de parámetros para el algoritmo utilizado, y principalmente la elección de un dominio objetivo, pueden

influir de manera significativa en si se mejora o no la detección y en qué porcentaje. A partir de las pruebas realizadas en esta investigación, se pudo obtener una mejora de hasta 1.8% en el mAP50 para las imágenes de validación, y de hasta 4.1% para las imágenes de prueba de la base de datos GWHD 2021.

Los resultados muestran avances prometedores en la aplicación de adaptación de dominio con transporte óptimo para mejorar el desempeño en la detección de objetos. Cabe destacar que durante la

investigación se hizo la suposición de que los dominios de la base de datos poseían una similitud interna en cuanto a la distribución de colores de las imágenes que los componen. En futuros trabajos, se planea realizar una definición más objetiva de los dominios a través de alguna técnica de agrupamiento, donde además se mida esta similitud interna de las imágenes de un dominio, con el fin de elegir de manera más objetiva el dominio objetivo y comprobar si esto podría aumentar aún más las métricas de detección de objetos.

Agradecimientos

Los autores agradecen al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por los recursos otorgados para la realización de esta investigación.

Referencias

- [1] P. Langridge *et al.*, “Meeting the Challenges Facing Wheat Production: The Strategic Research Agenda of the Global Wheat Initiative,” Nov. 2022, *MDPI*. doi: 10.3390/agronomy12112767.
- [2] J. A. Fernandez-Gallego, S. C. Kefauver, N. A. Gutiérrez, M. T. Nieto-Taladriz, and J. L. Araus, “Wheat ear counting in-field conditions: High throughput and low-cost approach using RGB images,” *Plant Methods*, vol. 14, no. 1, Mar. 2018, doi: 10.1186/s13007-018-0289-4.
- [3] Y. Zhang, M. Li, X. Ma, X. Wu, and Y. Wang, “High-Precision Wheat Head Detection Model Based on One-Stage Network and GAN Model,” *Front Plant Sci*, vol. 13, Jun. 2022, doi: 10.3389/FPLS.2022.787852.
- [4] S. Rasti, C. J. Bleakley, N. M. Holden, R. Whetton, D. Langton, and G. O’Hare, “A survey of high resolution image processing techniques for cereal crop growth monitoring,” Jun. 01, 2022, *China Agricultural University*. doi: 10.1016/j.inpa.2021.02.005.
- [5] T. van Klompenburg, A. Kassahun, and C. Catal, “Crop yield prediction using machine learning: A systematic literature review,” *Comput Electron Agric*, vol. 177, p. 105709,

Oct. 2020, doi: 10.1016/J.COMPAG.2020.105709.

- [6] A. Sanaeifar, M. L. Guindo, A. Bakhshipour, H. Fazayeli, X. Li, and C. Yang, “Advancing precision agriculture: The potential of deep learning for cereal plant head detection,” *Comput Electron Agric*, vol. 209, p. 107875, Jun. 2023, doi: 10.1016/J.COMPAG.2023.107875.
- [7] E. David *et al.*, “Global Wheat Head Dataset 2021: more diversity to improve the benchmarking of wheat head localization methods,” May 2021, [Online]. Available: <https://arxiv.org/abs/2105.07660v2>
- [8] E. David *et al.*, “Global Wheat Head Detection Challenges: Winning Models and Application for Head Counting,” *Plant Phenomics*, vol. 5, Jun. 2023, doi: 10.34133/PLANTPHENOMICS.0059/SUPPL_FILE/PLANTPHENOMICS.0059.F1.DOCX.
- [9] Z. K. J. Hartley and A. P. French, “Domain adaptation of synthetic images for wheat head detection,” *Plants*, vol. 10, no. 12, Dec. 2021, doi: 10.3390/plants10122633.
- [10] J. Feydy, T. Séjourné, F. X. Vialard, S. I. Amari, A. Trounev, and G. Peyré, “Interpolating between Optimal Transport and MMD using Sinkhorn Divergences,” in *The 22nd International Conference on Artificial Intelligence and Statistics*, PLMR, 2019, pp. 2681–2690. [Online]. Available: <https://arxiv.org/abs/1810.08278v1>
- [11] S. Kolouri, S. R. Park, M. Thorpe, D. Slepcev, and G. K. Rohde, “Optimal Mass Transport: Signal processing and machine-learning applications,” *IEEE Signal Process Mag*, vol. 34, no. 4, pp. 43–59, Jul. 2017, doi: 10.1109/MSP.2017.2695801.
- [12] N. Courty, R. Flamary, D. Tuia, and A. Rakotomamonjy, “Optimal Transport for Domain Adaptation,” *IEEE Trans Pattern Anal Mach Intell*, vol. 39, no. 9, pp. 1853–1865, Jul. 2015, doi: 10.1109/TPAMI.2016.2615921.
- [13] J. Terven and D. Cordova-Esparza, “A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS,” Apr. 2023, doi: 10.3390/make5040083.

- [14] G. Jocher, J. Qiu, and A. Chaurasia, “Ultralytics YOLO,” Jan. 2023, 8.0.0. [Online]. Available: <https://github.com/ultralytics/ultralytics>
- [15] Y. Xu and R. Goodacre, “On Splitting Training and Validation Set: A Comparative Study of

Cross-Validation, Bootstrap and Systematic Sampling for Estimating the Generalization Performance of Supervised Learning,” *J Anal Test*, vol. 2, no. 3, pp. 249–262, Jul. 2018, doi: 10.1007/S41664-018-0068-2/FIGURES/9.