


**Figura 7.4:** Visualization of Grad-CAM activation maps in the interpretation of the Swin-T classification model for the species (a) *Atriplex patula*, (b) *Chenopodium album*, (c) *Convolvulus arvensis*, (d) *Cyperus rotundus*, (e) *Datura ferox*, (f) *Lolium rigidum*, (g) *Portulaca oleracea*, (h) *Salsola kali*, (i) *Solanum nigrum*, (j) *Sorghum halepense*, (k) maize and (l) tomato.

### 7.3.2 Data Augmentation GFPGAN on the Early Growth-Stage Dataset

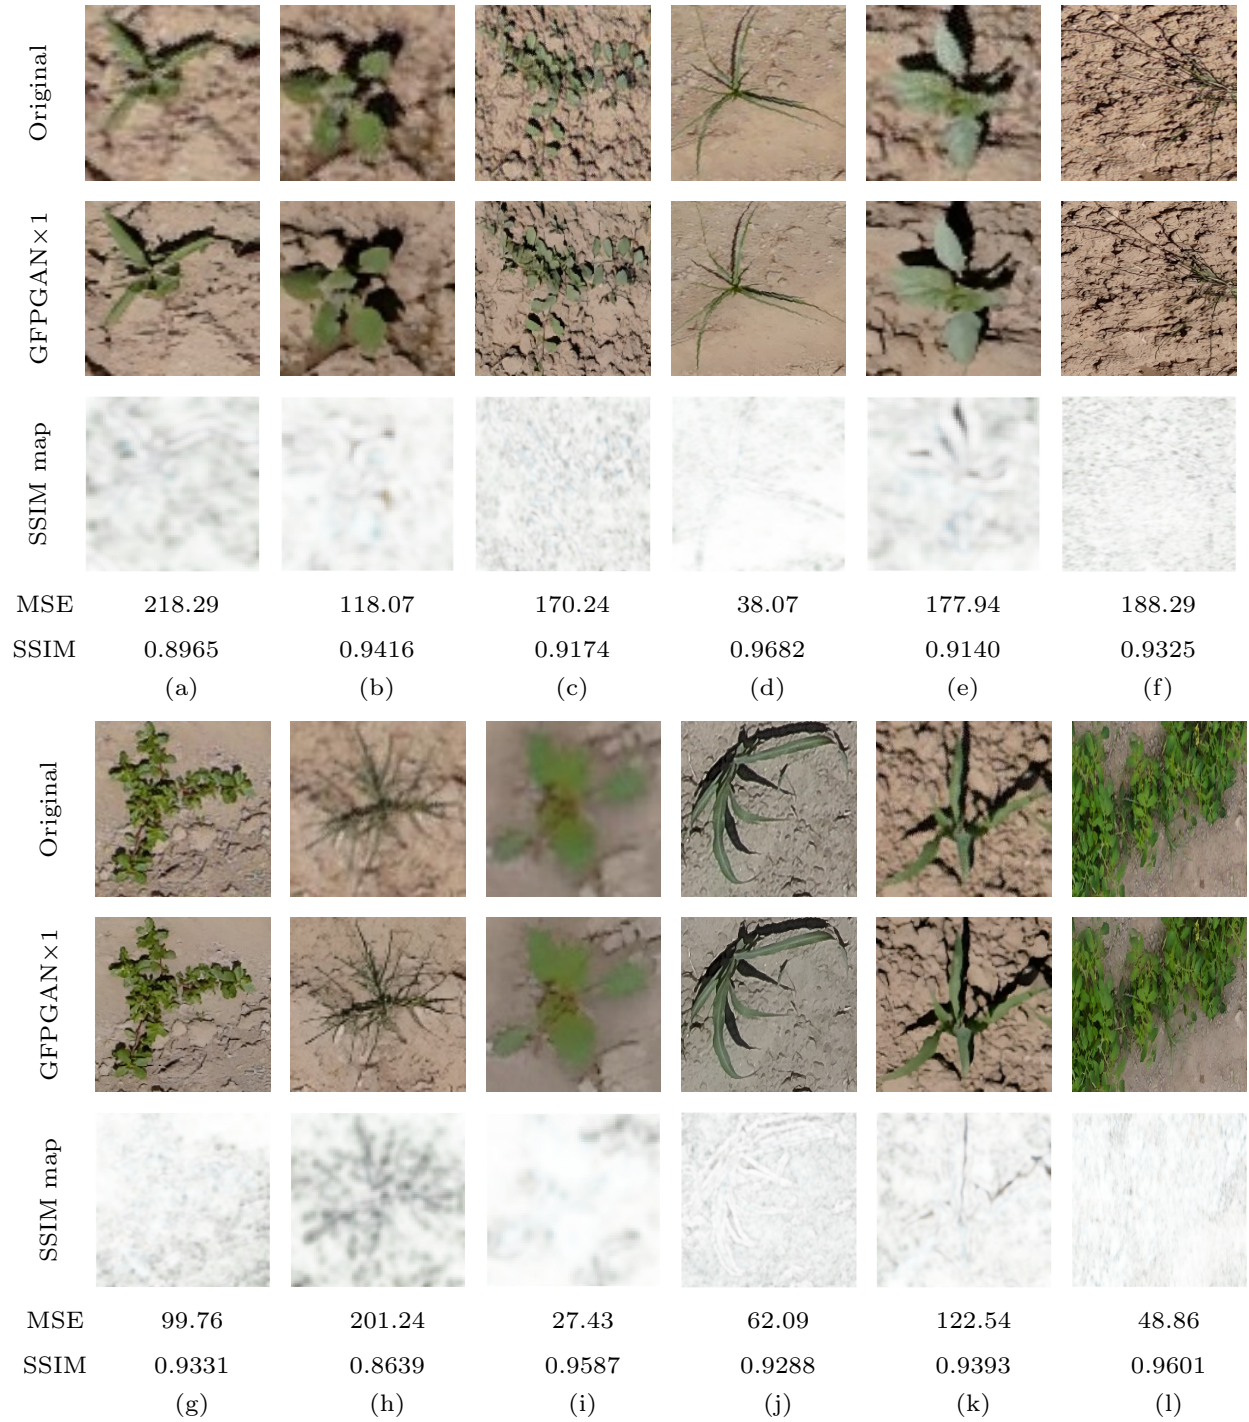
Figure 7.5 illustrates the contrasting results of synthetic images from our dataset, generated using the GFPGAN model's capabilities for color restoration and enhancement, employing upscaling factors of  $\times 1$ ,  $\times 2$  and  $\times 3$ , and highlighting an example with *D. ferox*.



**Figure 7.5:** Photorealistic images produced using the GFPGAN framework: (a) original image, (b) upscaled  $\times 1$ , (c) upscaled  $\times 2$  and (d) upscaled  $\times 3$ . The images represent the species *D. ferox*.

The results in this section demonstrate substantial advancements in image enhancement through generative AI (Figure 7.6). They highlight the GFPGAN model's capability to enhance texture and color of various elements within each image. Importantly, the images generated from our dataset exhibit a high degree of realism, effectively identifying and emphasizing important morphological features, such as leaf arrangement and the texture of both plants and the soil surface. SSIM values confirm these findings, since this quality metric closely correlates with the subjective perception of a human observer. Generally exceeding 0.9, SSIM values in the local SSIM map depict sparse regions of low similarity (e.g., dark pixels in Figure 7.6), where the processed image differs significantly from the reference image. Conversely, light pixels indicate areas of high local SSIM, typically coinciding with uniform regions in the reference image where changes, like blurring, have minimal impact on perceived image quality.

The image generation runtimes using the early growth-stage training dataset consisting of 23,842 labels showed minor variations based on different scaling factors. Processing at a factor of  $\times 1$  exhibited the shortest runtime, completing in 722.1 s, closely followed by the  $\times 2$  factor with a runtime of 724.2 s. In contrast, factor  $\times 3$  showed the longest execution time, taking 813.4 s to complete. It is important to emphasize that these results are specific to the dataset and hardware configuration used in this study.



**Figura 7.6:** Illustrative examples of the original UAV images, alongside their corresponding GFPGAN-processed images scaled at  $\times 1$ , and local SSIM maps, depicting ten weed species and two crop species during their early growth stages: (a) *Atriplex patula*, (b) *Chenopodium album*, (c) *Convolvulus arvensis*, (d) *Cyperus rotundus*, (e) *Datura ferox*, (f) *Lolium rigidum*, (g) *Portulaca oleracea*, (h) *Salsola kali*, (i) *Solanum nigrum*, (j) *Sorghum halepense*, (k) maize and (l) tomato. Additionally, MSE and SSIM values are provided.

### 7.3.3 Classification Inference after Data Augmentation on the Subsequent Growth-Stage Dataset

The results of the classification models, which were developed with the implementation of data augmentation on the dataset related to the subsequent growth stage, showed varying performance across different species (Table 7.4). In general, the Ori + GFPGAN×1 model enhanced the *F1-score* compared to the original Swin-T model, particularly for species like *S. nigrum*, highlighting its exceptional classification performance in that specific category. However, both the Ori + GFPGAN×2 and Ori + GFPGAN×3 models showed underperformance in most species when compared to the Ori+ GFPGAN×1. This indicates that the Ori + GFPGAN×1 model excelled in terms of overall performance across all species, regardless of species imbalance. Furthermore, the Ori + GFPGAN×1 + ×2 model showed a significant enhancement in its performance compared to the unweighted average accuracy. This suggests that the Ori + GFPGAN×1 + ×2 model is better suited for scenarios where species balance hold significance in the application.

**Tabla 7.4:** *F1-score* by species at the subsequent growth stage for various classification models generated through data augmentation.

Species	F1-score %					
	Original	Data augmentation				
	(Ori)	Ori + GFPGAN×1	Ori + GFPGAN×2	Ori + GFPGAN×3	Ori+GFPGAN×1 + ×2	Ori+GFPGAN×1+ ×2 + ×3
<i>Atriplex patula</i>	68.6	71.5	65.0	62.1	72.1	70.6
<i>Chenopodium album</i>	86.7	86.4	81.8	79.5	86.5	79.3
<i>Convolvulus arvensis</i>	70.7	70.7	72.4	64.7	74.6	72.18
<i>Cyperus rotundus</i>	58.1	60.8	57.4	51.4	58.5	63.8
<i>Datura ferox</i>	90.2	87.5	71.2	85.2	79.3	85.5
<i>Lolium rigidum</i>	52.6	67.0	53.0	69.1	69.5	63.1
<i>Portulaca oleracea</i>	95.4	88.6	73.0	81.0	84.8	83.5
<i>Salsola kali</i>	87.4	96.3	92.9	96.0	96.6	94.2
<i>Solanum nigrum</i>	99.1	99.3	98.9	98.0	97.9	97.1
<i>Sorghum halepense</i>	80.8	89.2	96.7	95.4	97.6	95.4
Maize	98.5	98.5	97.2	97.8	97.9	97.8
Tomato	94.7	96.8	95.2	95.6	97.0	96.7
Macro average	81.7	84.4	79.6	81.3	84.4	83.3
Weighted average	94.8	95.3	93.3	93.5	94.8	94.1

### 7.3.4 Detection of Weeds

#### Model Training

The training performance results of the three models indicate a higher mAP in the model trained with the Ori+GFPGAN×1 dataset compared to the model trained only with the original dataset (Table 7.5). Furthermore, the model trained with Ori+GFPGAN×1+×2 outperformed the model trained with Ori+GFPGAN×1, indicating continued improvement with the incorporation of additional data. Similarly, IoU also improved with increasing training data. The model trained with Ori+GFPGAN×1+×2 achieved the highest IoU, followed by the model trained with Ori+GFPGAN×1, and lastly, the model trained with the original dataset. This consistent pattern suggests that the inclusion of additional data sets (GFPGAN×1 and GFPGAN×2) has a significantly positive impact on both metrics.

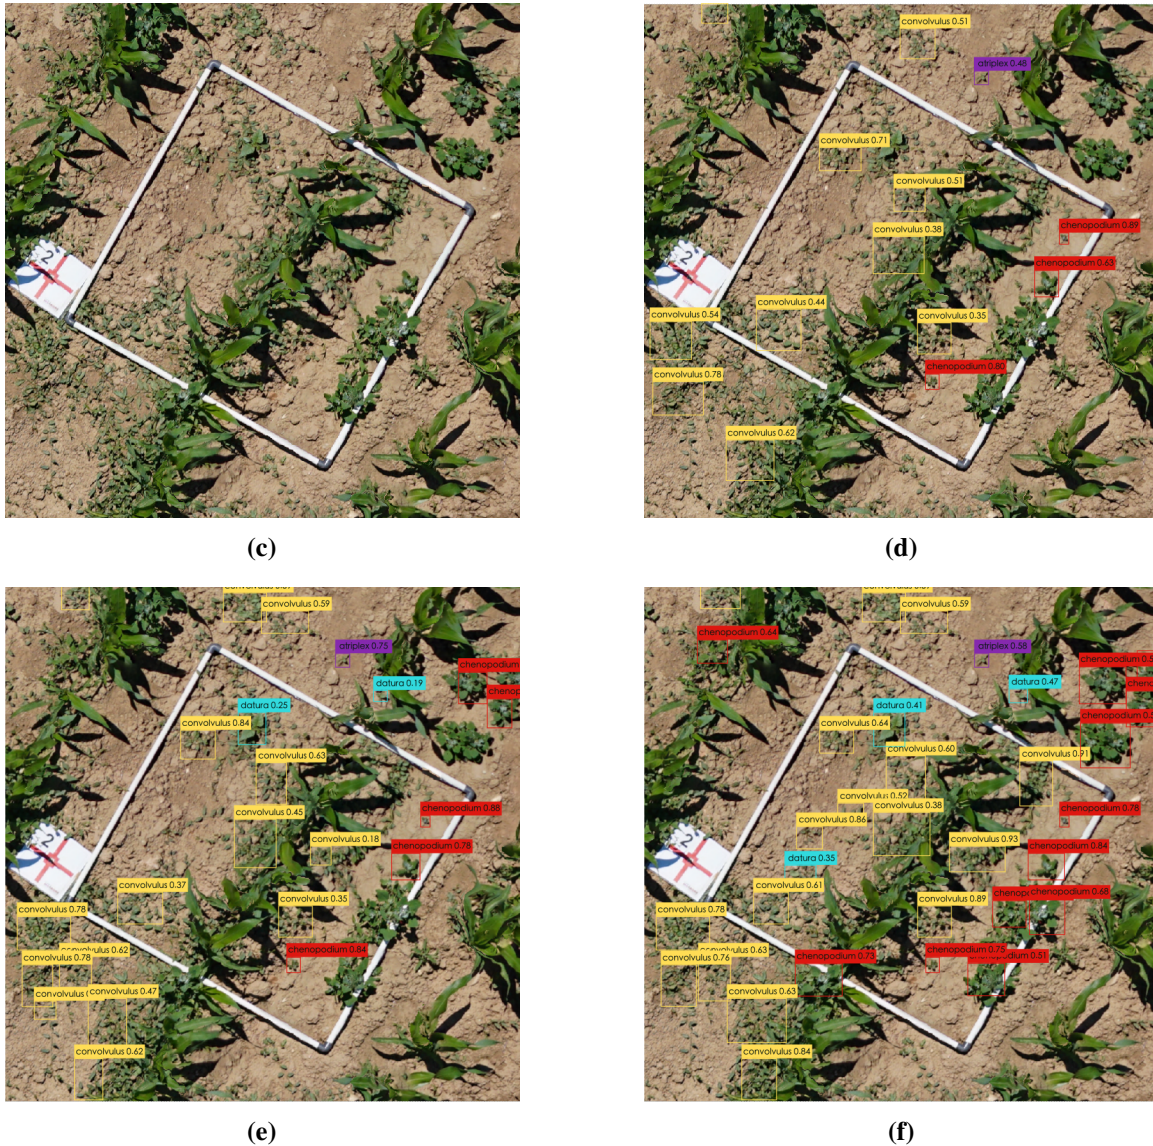
**Tabla 7.5:** Training performance (mAP and IoU metrics) for various detection models using datasets generated with data augmentation.

	Original	Ori + GFPGAN×1	Ori + GFPGAN×1 + ×2
mAP	0.060	0.191	0.234
mAP@[IoU = 0.50]	0.158	0.444	0.513
mAP@[IoU = 0.75]	0.030	0.129	0.171
mAP@[area = small]	0.031	0.072	0.096
mAP@[area = medium]	0.069	0.206	0.259
mAP@[area = large]	0.185	0.237	0.393
Recall@[maxDets = 1]	0.096	0.084	0.095
Recall@[maxDets = 10]	0.274	0.255	0.252
Recall@[maxDets = 100]	0.336	0.340	0.339
Recall@[area = small]	0.215	0.162	0.149
Recall@[area = medium]	0.351	0.366	0.372
Recall@[area = large]	0.408	0.447	0.522

### Model Inference

Figure 7.7 illustrates the inference results of the weed detection models. Detections are labeled with weed names and confidence values, demonstrating the models' effectiveness in identifying and locating the species present. The detected species include *C. arvensis*, *C. album*, *A. patula* and *D. ferox*, each marked with a bounding box and confidence values ranging from 0.18 to 0.93. Comparisons among the three models show consistency in detecting *C. arvensis* and *C. album*, with minor variations in confidence scores. The model trained with the Ori + GFPGAN×1 + ×2 dataset achieved the highest number of detections, demonstrating its ability to correctly identify weeds at the growth stages recommended to apply an efficient weed control treatment.





**Figura 7.7:** Examples of DETR model inference on  $1000 \times 1000$  pixel images of maize crops: original image (a) and model inference (b) at phenological stage BBCH14; original image (c) and model inference (d) at phenological stage BBCH17; model inference of Ori + GFPGAN $\times 1$  (e) and Ori + GFPGAN $\times 1 + \times 2$  (f) at phenological stage BBCH17. The images depict partitions of the orthomosaic.

Inference was performed on a set of images corresponding to partitioned orthomosaics, obtaining 1699 and 2010 images for the early growth phase in maize BBCH14 and tomato BBCH501, respectively. For the later growth phase, 2390 and 3669 images were obtained in maize BBCH17 and tomato BBCH509, respectively. Computational performance of each model and crop growth stages in term of number of parameters trained, disk size and inference times are shown in Table 7.6.

**Tabla 7.6:** Computational performance of object detector inference in terms of multiple metrics used in the evaluation of computer vision models.

Model	N° of Trainable Parameters ( $\times 10^6$ )	Size on Disk (MB)	Inference Time (s)			
			Early Growth Stage		Subsequent Growth Stage	
			Maize (BBCH14)	Tomato (BBCH501)	Maize (BBCH17)	Tomato (BBCH509)
Original	41.5	166.5	80.28	103.64	110.56	165.88
Ori + GFPGAN $\times 1$	41.5	166.5	-	-	115.28	166.14
Ori + GFPGAN $\times 1 + \times 2$	41.5	166.5	-	-	117.45	169.83

## 7.4 Discussion

The present study is based on a dataset that stands out for its considerable size and diversity, covering a wider range of species compared to datasets used in similar research. Indeed, previous studies, such as dos Santos Ferreira et al. (2017) with 1191 images of broadleaf weeds and 3520 images of grasses, Valente et al. (2019) with 631 images of *Rumex obtusifolius* plants, Petrich et al. (2020) with 8100 images of *Colchicum autumnale*, and Zhang et al. (2020a) with a collection of 2000 images including species such as *Cirsium setosum*, *Descurainia sophia*, *Euphorbia helioscopia*, *Veronica didyma* and *Avena fatua*, have worked with substantially smaller datasets. In contrast, our dataset comprised 31,002 (early growth stage) + 36,556 (subsequent growth stage) images, offering a robust foundation for comprehensive scientific investigations, such as weed detection, classification and segmentation. This is especially important for effective weed identification using supervised learning in the context of DL, as a sufficient amount of labeled data is required.

The Swin-T model achieved an outstanding of 99.1 % in the early growth-stage dataset, exceeds the performance of previous CNN-based approaches. For instance, the study conducted by Huang et al. (2018a) employed the ResNet-101 model to discriminate between rice crops and two weed species, *Cyperus iric* and *Leptochloa chinensis*, achieving a noteworthy accuracy of 94.0 %. Valente et al. (2019) and Lam et al. (2021) also tackled the challenge of *Rumex obtusifolius* identification using CNN models such as AlexNet and VGG16, respectively. Valente et al. (2019) achieved an accuracy exceeding 90.0 %, while Lam et al. (2021) reached an accuracy of 92.1 %. Furthermore, the efficacy of ViT-based classifiers for weed identification and discrimination is underscored by the work of Espejo-Garcia et al. (2023). In their study, they applied the Swin-v2 model, yielding top-1 accuracy scores ranging from 98.5 % to 98.6 % on the DeepWeeds dataset.

The *F1-scores* obtained in the inference at the advanced growth stages (BBCH17 and BBCH509), both on a per-species basis and in terms of the weighted average *F1-score* for each model, were lower compared to those in the study by Reedha et al. (2022). Reedha et al. implemented the ViT B-16 model and achieved an *F1-score* of 99.4 %. Notably, their research focused on the classification of five classes (weeds, beet, off-type beet, parsley and spinach), whereas our study involved the classification of ten weed species and two crops.

The results related to the execution time of the GFPGAN framework for generating new images indicate that processing at the  $\times 1$  factor is the most time-efficient option. This makes it an attractive choice for applications that demand rapid real-time data processing. The GFPGAN $\times 2$  model,

although slightly slower than the GFPGAN×1 model, still provides competitive performance and could be preferable in scenarios where a balance between accuracy and processing speed is required. Conversely, the GFPGAN×3 model, despite its slower processing speed, could be suitable for tasks where accuracy takes precedence, and ultra-rapid processing is not a critical requirement.

Inference conducted using the Ori + GFPGAN×1 model at the later phenological stages BBCH17 and BBCH509 demonstrated that the integration of synthetic images generated by the GFPGAN model, along with real images, is an effective strategy for enhancing the quality of datasets in weed monitoring. Consequently, our findings suggest that the application of GFPGAN in characterizing plant images holds great potential for practical applications in real-world scenarios, particularly in the context of weed management in the framework of precision crop protection.

Another distinctive aspect of our article is the development of a model using UAV images captured from an altitude of 11 m. In the existing literature, studies utilizing RGB images acquired by UAVs at a lower altitude of 2 m can be found, such as the one proposed by Khan et al. (2021). In their study, they introduced a semi-supervised GAN system (SGAN) for classifying weeds, including *Eleusine indica*, amidst pea and straw-berry crops.

The implementation of an object detector has underscored the critical role of both the quantity and quality of training data. The improvement observed in mAP and IoU metrics demonstrates that increasing relevant data significantly enhances the model's capacity to generalize and accurately detect weeds. This highlights how models trained on larger datasets effectively identify and classify weeds across various growth stages, essential for real-world scenarios where images exhibit high complexity and variability. While performance has improved with increased data, it is important to consider the law of diminishing returns. Beyond a certain point, additional data may only result in marginal improvements while increasing computational and storage costs. Moreover, our study identifies that DETR faces specific challenges, particularly in accurately detecting small objects and requiring extensive training durations, akin to issues noted in previous research (Shahi et al., 2023).

Gallo et al. (2023) evaluated the efficacy of the YOLOv7 model for weed detection in chicory crops, achieving an accuracy of 61.3 % and a recall of 62.1 %. While the YOLOv7 models are highly competitive, they could significantly benefit from data augmentation techniques to enhance accuracy across various IoU thresholds. This is shown in Table 7.5, where applying these techniques resulted in a notable mAP improvement from 0.060 to 0.234. This is particularly relevant given that the mAP@[IoU = 0.50] in Table 7.5 reaches a value of 0.513, indicating improved predictive capability through fine-tuning of the model and use of additional image processing techniques. Khan et al. (2021) proposed a semi-supervised GAN-based framework for crop and weed classification in UAV imagery, achieving 90 % accuracy using only 20 % labeled imagery, and reaching 94.17 % with 80 % labeled imagery. These results demonstrate exceptional performance, especially when compared to the overall mAP shown in Table 7.5. This suggests that the semi-supervised approach is highly efficient, even with a limited amount of labeled data, which could reduce the need for extensive data augmentation techniques. The work of Gašparović et al. (2020) on weed detection in oat fields using UAV imagery showed that automatic object-based classification achieved an overall accuracy of 89.0 %. This result reflects a high accuracy in weed segmentation, favorably comparable with the performance of the detection models presented in Table 7.5, when considering the mAP for large (0.393) and medium (0.259) areas. These findings highlight the robustness of the object-based approach, particularly in segmenting larger areas. Future investigations should focus on mitigating

these constraints, potentially through optimizing model architectures or adopting more efficient training techniques.

Visual transformers, such as Swin-T, employ attention mechanisms that weight the importance of different regions of an image, dividing it into patches and generating hierarchical representations that integrate both global and local features. In this context, the ability of Swin-T to identify parts of weeds and crop plants was highly dependent on the variability and quality of the training dataset. The presence of images with occlusions, deformations and variations in scale improved the generalization of the model, allowing it to recognize parts of weeds and crops in different conditions. In addition, detailed annotations that included information about the parts of weeds and crops were critical for the model to learn discriminative representations. Swin-T's self-attentional mechanisms facilitated focusing on the most relevant areas of the image, enhancing the identification of parts even in the presence of partial occlusions. Thus, although Swin-T was not specifically designed in this work for the identification of parts of weeds and crops, its inherent attentional and hierarchical representation capabilities enabled effective identification at the boundaries of the image cutouts made to the orthophotos.

In this study, we chose not to use automated hyperparameter optimization techniques, which has several key advantages from a scientific and practical perspective. The significant reduction in computational costs and run time allowed us to focus resources on faster and more accurate experimental iterations. This simplified approach facilitated efficient implementation and provided rigorous control over the hyperparameters, allowing specific adjustments based on accumulated expertise and qualitative observations of model behavior during training. In addition, by avoiding variations introduced by automated methods, the reproducibility of the experiments was improved, ensuring that the results obtained can be replicated more reliably in future studies. This strategy also promoted a deeper understanding of the interactions between hyperparameters and model performance, providing valuable insights for interpretation and continuous model improvement. In the context of exploratory or resource-constrained research, manual hyperparameter configuration proved to be an effective methodology, aligned with operational efficiency and scientific integrity.

The growth stages studied in this research occur mainly in the timely moment for weed treatment for two reasons. One, weed control is particularly effective when applied at early stages to minimize the adverse competence of the weeds with the crops. Two, overlap between crop plants is usually low in this critical treatment window, thus reducing the screening action of the crop plants on the application of an herbicide and thus increasing its efficacy. From a practical point of view, our results can be helpful to apply species- and site-specific weed control measures at the right time, but further work should be developed to deploy these CC models in more complex systems that combine detection, decision making and actuation tasks for weed treatment following precision agriculture strategies.

## 7.5 Conclusions

This research relied on a large UAV imagery dataset, collected at two phenological stages, to classify ten weed species and two crops using a cognitive computing-based system. By adapting a generative model originally designed for facial super-resolution, we enhanced our dataset to create a robust classification model capable of adapting to morphological variations in the studied species. Despite

its initial design for facial enhancement, this study demonstrates that the GFPGAN framework can be effectively repurposed for enhancing plant images, indicating significant potential for future weed management strategies. Our results highlight the Swin-T model's outstanding performance in multiclass classification of weed species from UAV imagery, showing remarkable adaptability across different phenological stages. This underscores its effectiveness in discerning image variations at various growth stages, establishing it as a robust tool for weed monitoring. By applying data augmentation and transfer learning techniques, we achieved significant improvements in result robustness, reducing the risks of overfitting and dataset unrepresentativeness. Models generated with the data augmentation showed enhanced *F1-scores* for most weed species within the unbalanced dataset associated with the later growth stages, demonstrating the methodology's adaptability over time. The proposed multiclass discrimination system, combining the classification and the DETR model for detecting multiple weed species, proved effective in accommodating variations across weed species' developmental stages, holding potential to improve weed management strategies in precision crop protection. This could lead to reduced herbicide usage, resistance prevention, optimized control costs, efficient resource allocation, and ultimately, improved crop quality.



# **Capítulo 8**

## **Discusión General**



## 8.1 Últimos avances en protección de cultivos de precisión

El análisis de datos representa un cuello de botella importante en la protección de cultivos de precisión. La diversidad de escenarios de cultivos y plagas, combinada con factores ambientales y decisiones de manejo, crea una gran complejidad en los datos agrícolas. Aunque los métodos de ML tienen la capacidad de aprender y gestionar esta complejidad, todavía existen desafíos significativos en términos de precisión y generalización de los modelos. En este contexto, la investigación futura debe centrarse en mejorar la capacidad de los algoritmos de ML para manejar datos ruidosos y diversos, y en desarrollar técnicas que permitan una mejor interpretación y utilización de los modelos generados.

El avance hacia la agricultura 5.0 se ve impulsado por 39 tecnologías emergentes identificadas, destinadas a liderar la próxima generación de sistemas de protección de cultivos. Estas tecnologías incluyen sensores inteligentes, robótica avanzada y sistemas de toma de decisiones autónomos. La convergencia de estas tecnologías con la IA y el ML abre nuevas posibilidades para una protección de cultivos más eficiente, precisa y sostenible. No obstante, la implementación exitosa de estas tecnologías requerirá un enfoque interdisciplinario y colaborativo, que involucre a expertos en agricultura, informática, ingeniería y otras disciplinas afines.

## 8.2 Base de datos

En el capítulo 4 de esta tesis se presenta la base de datos *DRONEWEED*. El análisis comparativo de *DRONEWEED*, *CoFly-WeedDB* (Krestenitis et al., 2022) y *DeepWeeds* (Olsen et al., 2019) resalta diferencias críticas en la representación geográfica y ecológica de las malas hierbas. *DRONEWEED* aborda cultivos intensivos de maíz y tomate, ofreciendo un enfoque relevante para sistemas agrícolas intensivos en regiones donde estos cultivos predominan. Por otro lado, *CoFly-WeedDB* se limita al algodón, con una representación geográfica localizada en Grecia, lo que podría limitar su aplicabilidad global, especialmente en contextos de manejo agrícola diverso. *DeepWeeds*, con su enfoque en zonas de pastoreo en Australia, representa un ecosistema diferente, priorizando malas hierbas típicas de áreas ganaderas.

El carácter de acceso abierto de *DRONEWEED* representa un avance significativo en la investigación científica aplicada a la agricultura de precisión. Este enfoque no solo facilita la transparencia y reproducibilidad en la ciencia de datos, sino que también promueve la colaboración global, permitiendo a investigadores y desarrolladores de IA contribuir con datos adicionales, validar modelos existentes y desarrollar soluciones adaptadas a contextos específicos.

## 8.3 Clasificación multiclase de malas hierbas a nivel de especie

### 8.3.1 Clasificación con modelos CNN en imágenes UAV

En el capítulo 5 de esta tesis se presenta un avance significativo en la detección, clasificación y localización de malas hierbas a nivel de especie durante su etapa temprana de crecimiento. Este enfoque es crucial para implementar estrategias de manejo y control adaptadas a cada especie, ya que las variaciones fisiológicas entre ellas requieren tratamientos específicos. La identificación de

especies de malas hierbas en una etapa temprana utilizando DL en imágenes UAV plantea un reto considerable debido a las limitaciones inherentes al tamaño de las bases de datos y a la resolución de las imágenes. El desarrollo de un método automatizado para detectar y clasificar especies de malas hierbas conlleva limitaciones, especialmente durante las fases de entrenamiento y prueba. En este sentido, en la presente tesis se evaluó el tamaño mínimo de la base de datos requerida para alcanzar un 90 % de exactitud. Los resultados revelaron que aumentar el número de etiquetas en las fases de entrenamiento y validación mejora la precisión de los modelos basados en CNN en la tarea de clasificación.

En el estudio las imágenes se adquirieron con un UAV a 11 metros de altura, lo que resultó en ortofotos con un tamaño de píxel de 0,17 cm. Esta resolución espacial es inferior a la de investigaciones similares (dos Santos Ferreira et al., 2017, 2019; Khan et al., 2021; Wang et al., 2019b) que emplearon alturas menores (2-5 metros) para obtener resoluciones espaciales más altas. Esta diferencia en resolución planteó un desafío adicional en la extracción de características útiles de las imágenes. Para mitigar este problema, una posible solución sería entrenar un modelo más complejo capaz de aprender a partir de imágenes más pequeñas, aunque esto conlleva un mayor tiempo de entrenamiento, mayor consumo de recursos informáticos y, por lo tanto, un mayor gasto energético.

Los modelos CNN evaluados en este estudio mostraron rendimientos diversos. En una base de datos equilibrada, se determinó que el tamaño mínimo de datos necesario para lograr exactitudes superiores al 90 % oscilaba entre 400 etiquetas para el modelo Inception-ResNet-v2 y 800 etiquetas para el modelo VGG16, con valores intermedios para ResNet152. La robustez de la base de datos permitió entrenar los modelos CNN con un número balanceado de etiquetas para cada especie, evitando sesgos hacia la clase dominante. Los modelos Inception-ResNet-v2, VGG16 y ResNet152 lograron elevadas exactitudes de 98,6 %, 95,6 % y 92,6 %, respectivamente, cuando se utilizaron etiquetas equilibradas por especie. Estos resultados destacan la capacidad de los modelos CNN para adaptarse a nuevos datos en entornos naturales y muestran un potencial prometedor para la implementación de SSWM en etapas tempranas del crecimiento de cultivos.

Investigaciones previas han demostrado la eficacia de combinar teledetección con ANN para diferenciar grupos de malas hierbas, como monocotiledóneas y dicotiledóneas (Torres-Sánchez et al., 2021). En un enfoque similar al evaluado en esta tesis, se utilizó el modelo CaffeNet en una base de datos segmentada para evaluar su rendimiento frente a clasificadores ML tradicionales, logrando una precisión superior al 98 % en la clasificación de todos los grupos (dos Santos Ferreira et al., 2017). Esto demostró que los modelos CNN pueden superar las limitaciones de los extractores de características utilizados en otros métodos. En esta tesis, se buscó ir un paso más allá al demostrar la capacidad de las arquitecturas CNN para discriminar entre múltiples especies de malas hierbas en campos de cultivo. Se utilizó un conjunto de datos basado en imágenes UAV, que resultó ser robusto para el entrenamiento de diversas arquitecturas CNN mediante técnicas de TL, obteniendo resultados notables en la clasificación de todas las especies de malas hierbas presentes en los campos investigados.

Cuando se llevó a cabo el análisis de la inferencia con una base de datos desbalanceada, los resultados estuvieron más ajustados a un escenario real. Bajo estas condiciones, el modelo Inception-ResNet-v2 presentó las mejores métricas, con un rendimiento (*F1-score*) que oscilaba entre 27,3 % y 99,7 %, en tanto que el modelo VGG16 obtuvo peores rendimientos con un rango entre 11,2 % y 99,4 %. Es

importante destacar que los valores bajos en las tres CNN correspondieron a los resultados para la especie minoritaria *Atriplex patula*, Esto se debió probablemente a su confusión con otra especie, *Solanum nigrum*, como lo indican los altos porcentajes de falsos negativos observados en las matrices de confusión. Al calcular el valor medio de todas las especies, el modelo Inception-ResNet-v2 mostró un rendimiento superior al 86 %, ResNet152 cerca del 80 % y VGG16 cerca del 74 %. Basándonos en estos resultados, la arquitectura Inception-ResNet-v2 demostró ser el modelo más efectivo para especies de malas hierbas, independientemente de si la base de datos estaba balanceada o no.

Una contribución fundamental de este estudio fue identificar cómo la precisión de clasificación depende de la proporción entre especies minoritarias y mayoritarias, lo cual impacta significativamente en la eficacia de los sistemas SSWM. Ignorar esta proporción puede llevar a errores en la toma de decisiones y a consecuencias negativas que afecten al control de malas hierbas y la productividad de los cultivos. Para alcanzar un rendimiento (*F1-score*) superior al 80 % para cada especie en bases de datos desbalanceadas, se debe mantener una proporción de 1:12, 1:24 y 1:107 entre especies mayoritarias y minoritarias para los modelos VGG16, ResNet152 e Inception-ResNet-v2, respectivamente. Los métodos de control suelen dirigirse a una especie específica, por lo que es crucial considerar la relación entre la especie objetivo y otras especies para evitar la aplicación incorrecta de métodos de control.

En resumen, los resultados indicaron que el modelo Inception-ResNet-v2 destaca por su rendimiento superior, logrando una precisión de más del 80 % con solo 400 etiquetas, mientras que ResNet152 y VGG16 requirieron 600 y 800 etiquetas, respectivamente. Esto sugiere que la arquitectura más profunda y con mayor capacidad de Inception-ResNet-v2 es más adecuada para capturar las características complejas presentes en las imágenes obtenidas por UAV a la resolución espacial alcanzada en las imágenes obtenidas por UAV., lo cual es crucial en AP para asegurar una identificación exacta y oportuna de especies de malas hierbas.

En el capítulo 6, se presenta una investigación reciente en la que se emplearon clasificadores avanzados, incluyendo CNN y ViT. Los resultados demostraron una alta exactitud en la clasificación de hasta nueve especies de malas hierbas a partir de imágenes capturadas por UAV, utilizando cinco modelos basados en CNN y ViT. Todos los modelos alcanzaron un *F1-score* ponderado entre el 85,5 % y el 98,3 %. Es destacable que, en comparación con otros estudios recientes sobre clasificación de malas hierbas, que generalmente se han centrado en categorías más amplias, como la diferenciación entre malas hierbas y cultivos, esta investigación se enfocó en la clasificación de especies específicas de malas hierbas.

La revisión del estado del arte muestra que la exactitud en la clasificación de malas hierbas basada en imágenes de UAV varía según la complejidad de la tarea y las técnicas empleadas (Rejeb et al., 2022). En general, los métodos más avanzados tienden a mejorar la precisión a medida que los clasificadores se vuelven más complejos, aunque sigue siendo un desafío el manejo de tareas multiclase (Kamilaris & Prenafeta-Boldú, 2018). Por ejemplo, técnicas de segmentación de imágenes y extracción de características han sido utilizadas en tareas más simples de detección de cobertura de malas hierbas (de Castro et al., 2018), obteniendo buenos resultados, pero a medida que las tareas se vuelven más específicas, como la clasificación de varias especies en cultivos complejos, se requieren modelos más robustos, como las redes neuronales y los clasificadores basados en técnicas de DL (Mohd, 2022).

La mayoría de los trabajos previos se han limitado a clasificar malas hierbas a nivel general, como la distinción entre hojas anchas y estrechas (Panduangnat et al., 2024; Torres-Sánchez et al., 2021), lo que plantea un desafío menor en comparación con la clasificación entre especies individuales. No obstante, algunos estudios han explorado con éxito la clasificación específica de malas hierbas en ciertos cultivos, alcanzando altas tasas de rendimiento (Chen et al., 2022; Espejo-García et al., 2023; Hasan et al., 2021; Zhang et al., 2020a). En comparación, este trabajo logró avances significativos al implementar modelos más recientes y complejos, como las arquitecturas CNN y ViT de última generación.

En este sentido, los avances más recientes en el uso de modelos CNN y ViT han mostrado una mejora sustancial en la precisión. Los modelos ViT, en particular, demostraron ser efectivos al capturar relaciones de largo alcance en los datos, lo que es especialmente útil en tareas de clasificación más complejas. En comparación, otros modelos CNN, como Inception-ResNet-v2 y EfficientNet-B0, mostraron dificultades para identificar patrones en imágenes con alta variabilidad inherente o menos representativas.

Asimismo, en tareas de clasificación multiclase con bases de datos desequilibradas, se observó que los modelos ViT y YOLOv8 superaron ligeramente a otros modelos CNN. Esto se debe a su capacidad para manejar mejor las relaciones complejas y las discrepancias en la cantidad de datos por clase. Estudios previos también han evidenciado que los modelos CNN tienden a tener un rendimiento inferior cuando se enfrentan a bases de datos multiclase desequilibradas (Liu et al., 2022). No obstante, en esta tesis, entrenar los modelos con un número balanceado de imágenes por clase permitió evitar la necesidad de aplicar técnicas adicionales, como la ampliación de datos o el uso de métodos avanzados para la generación de muestras sintéticas.

Más allá de la precisión de los modelos, que suele ser el foco principal de muchas investigaciones, es crucial abordar otros aspectos igualmente relevantes pero menos explorados, como la convergencia del entrenamiento, el tamaño del modelo y el tiempo de ejecución. Estos factores tienen un impacto significativo en la aplicabilidad práctica de los modelos para el manejo de malas hierbas de precisión. En cuanto a la convergencia del entrenamiento, modelos como Inception-ResNet-v2 y YOLOv8 alcanzaron su máxima precisión y mínimos valores de pérdida en solo 10 *epochs*, lo que indica una convergencia rápida en comparación con otros modelos. Esto sugiere que captaron las características clave de los datos de manera más eficiente, lo que resultó en una generalización robusta en menos tiempo. Por otro lado, ViT-Base y Swin-T mostraron una convergencia más lenta, posiblemente debido a su capacidad para detectar patrones más sutiles, lo cual requiere más tiempo de entrenamiento. EfficientNet-B0, aunque con una tasa de convergencia más baja, mostró una evolución constante y gradual, sugiriendo que invirtió más tiempo en explorar la base de datos y capturar patrones más complejos.

La variabilidad del progreso de aprendizaje a lo largo de las iteraciones también proporcionó información sobre los patrones de pérdida durante la fase de entrenamiento. Todos los modelos lograron reducir consistentemente los valores de pérdida, con YOLOv8 destacando por alcanzar los niveles más bajos desde las primeras etapas del entrenamiento. En contraste, Swin-T mostró una tasa de pérdida más alta, lo que sugiere que aún requiere optimizaciones adicionales para mejorar su rendimiento, especialmente en el contexto de imágenes UAV.

La relación entre el número de parámetros entrenables y el rendimiento de los modelos evidenció

una interacción compleja entre la capacidad de los modelos para aprender patrones sofisticados y el tiempo necesario para procesarlos. Inception-ResNet-v2 y ViT-Base tuvieron los tiempos de ejecución más largos, mientras que EfficientNet-B0 y Swin-T lograron un buen equilibrio entre rendimiento y tiempos de ejecución más cortos, gracias a su menor cantidad de parámetros entrenables. Por su parte, YOLOv8 presentó un tiempo de ejecución más largo, probablemente debido a la mayor complejidad de sus parámetros, lo que lo convierte en un caso interesante para analizar en términos de eficiencia computacional.

## 8.4 Detección y localización de malas hierbas a nivel de especie

En el capítulo 5, se analizó el algoritmo Faster R-CNN para detectar y localizar especies de malas hierbas en cultivos de maíz y tomate. Los tiempos de inferencia del modelo fueron de 120,7 segundos para maíz y de 141,6 segundos para tomate. Este dato no solo proporciona una visión de la eficiencia computacional del modelo, que depende del hardware utilizado y de la complejidad de los ortomosaicos, sino que también ofrece una visión general de la rapidez con la que el modelo puede analizar y procesar grandes bases de datos. Es importante destacar que la eficiencia demostrada por el modelo no es comparable con la de los expertos humanos que podrían realizar manualmente la misma tarea. En la detección de plantas individuales, el algoritmo demostró una eficacia destacable al identificar un total de 70.134 plantas individuales para maíz y 14.377 para tomate, evidenciando su capacidad para discriminar entre cultivos y malas hierbas. De hecho, la evaluación de la exactitud de predicción del modelo Faster R-CNN Inception-ResNet-v2 frente a los datos de referencia reveló tasas de detección de especies generalmente satisfactorias, aunque con algunas excepciones, como *Chenopodium album* en maíz y *Solanum nigrum* en campos de tomate. La menor tasa de detección para estas especies podría atribuirse posiblemente al pequeño tamaño de sus plántulas durante las primeras etapas, generalmente menores de 5 cm<sup>2</sup>. Abordar este desafío podría requerir imágenes UAV de mayor resolución, lo que permitiría una identificación y localización más exactas.

Este modelo demostró una capacidad prometedora, aunque su desempeño fue influenciado por la capacidad de generalización en escenarios con bases de datos desbalanceadas, una situación común en condiciones reales donde los cultivos suelen ser la clase predominante frente a las malas hierbas. La exactitud en la detección disminuye notablemente en escenarios de datos desbalanceados, subrayando la importancia de mantener un balance adecuado entre las especies minoritarias y mayoritarias durante el entrenamiento del modelo. En resumen, empleando 850 etiquetas para cada especie en las fases de entrenamiento y validación de la arquitectura Faster R-CNN - Inception-ResNet-v2, este enfoque logró identificar con éxito todas las especies de malas hierbas en los experimentos de maíz y tomate. La identificación exacta de las clases individuales de malas hierbas y cultivos ha permitido la generación de mapas detallados y personalizados, lo que facilita estrategias de manejo SSWM.

En el capítulo 6 se evaluó el rendimiento de dos modelos de detección de objetos para identificar y localizar diversas especies de malas hierbas: YOLOv8m, basado en CNN, y DETA, basado en ViT. Los resultados del entrenamiento mostraron que YOLOv8m alcanzó una mayor precisión promedio en la detección de objetos de distintos tamaños, mientras que DETA destacó en el número total de objetos detectados, particularmente en entornos con alta densidad y para objetos pequeños y medianos. Esta diferencia sugiere que la elección entre los modelos depende del caso de uso

específico: YOLOv8m es más adecuado para aplicaciones que priorizan la exactitud, mientras que DETA es más eficiente en contextos que requieren una alta tasa de detección general.

El análisis computacional reveló que YOLOv8m, a pesar de tener menos parámetros entrenables y un mayor tamaño de archivo, logró tiempos de inferencia considerablemente más cortos, lo que lo convierte en una opción ideal para aplicaciones en tiempo real. Por otro lado, DETA, con más parámetros y un menor tamaño de archivo, resultó ser más eficiente en términos de tiempo de entrenamiento y validación, siendo especialmente útil en aplicaciones donde la optimización del entrenamiento es más relevante que la velocidad de inferencia. Por lo tanto, la elección entre estos modelos debe basarse en las necesidades específicas de cada aplicación, ya sea priorizando la velocidad o la capacidad de procesamiento.

El análisis realizado en un entorno real, utilizando un conjunto de plantas identificadas como "*ground-truth*", demostró que YOLOv8m obtuvo un rendimiento superior tanto en la detección como en la clasificación precisa de malas hierbas en ambos cultivos. En contraste, DETA mostró una menor precisión, especialmente en el cultivo de tomate. La diferencia en el número de plantas correctamente clasificadas fue particularmente significativa en este cultivo de tomate, donde YOLOv8m superó ampliamente a DETA. En el cultivo de maíz, aunque las diferencias entre ambos modelos fueron menos pronunciadas, YOLOv8m mantuvo un mejor desempeño. Esta discrepancia puede explicarse, al menos parcialmente, por la capacidad de los modelos para manejar objetos pequeños y variaciones morfológicas. Además, la precisión de ambos modelos, como se observa en los resultados, pudo estar influenciada por la resolución espacial y la variabilidad de las malas hierbas. DETA, por ejemplo, tuvo dificultades para detectar y clasificar malas hierbas en áreas de alta densidad, como ocurrió en el cultivo de tomate, posiblemente debido a su limitada capacidad para gestionar oclusiones y la heterogeneidad en el crecimiento de las malas hierbas, lo que dificulta su reconocimiento automático.

La detección de objetos en imágenes capturadas por UAV, particularmente la detección de malas hierbas en diferentes etapas fenológicas, representa un desafío técnico considerable. Esta tarea requiere no solo una alta precisión sino también una gran capacidad de generalización por parte del modelo. En el capítulo 7, se introduce una innovación significativa con la implementación del detector de objetos DETR, basado en ViTs. A diferencia de los enfoques tradicionales, DETR elimina componentes manuales como la generación de anclas y la supresión de no máximos, lo que simplifica el proceso y lo automatiza. Este enfoque es particularmente ventajoso en entornos agrícolas, donde la diversidad de especies y condiciones ambientales varían considerablemente.

Este estudio ha destacado la importancia crítica tanto de la cantidad como de la calidad de los datos de entrenamiento. Las mejoras observadas en las métricas mAP e IoU demuestran que el aumento de datos relevantes mediante el uso de GAN mejora significativamente la capacidad del modelo para generalizar y detectar malas hierbas con precisión. En efecto, los modelos entrenados con bases de datos más amplias logran identificar y clasificar eficazmente las malas hierbas en distintas etapas de crecimiento, un aspecto crucial en escenarios reales, donde las imágenes presentan una alta complejidad y variabilidad. La mejora en la métrica mAP al utilizar imágenes sintéticas generadas por GANs subraya el potencial de estas técnicas para fortalecer los modelos de detección, especialmente en casos donde la obtención de datos etiquetados es limitada. Sin embargo, el estudio también revela la importancia de la ley de los rendimientos decrecientes: a partir de cierto punto, la adición de más datos genera solo mejoras marginales, mientras que aumenta los costos computacionales y de almacenamiento.

Por otro lado, este trabajo también reveló que los detectores de objetos como DETR presentan dificultades particulares, en particular en la detección precisa de objetos pequeños, además de requerir extensos períodos de entrenamiento, problemas similares a los señalados en investigaciones previas. En este sentido, existen modelos como YOLOv7 altamente competitivos, que podrían beneficiarse significativamente de técnicas de aumento de datos para mejorar su precisión (Gallo et al., 2023). De hecho, existen estudios que propusieron un marco basado en GAN semi-supervisado para la clasificación de cultivos y malas hierbas en imágenes UAV, logrando una precisión del 90 % utilizando solo el 20 % de imágenes etiquetadas y alcanzando un 94,17 % con el 80 % de imágenes etiquetadas (Khan et al., 2021). Esto sugiere que el enfoque semi-supervisado es altamente eficiente, incluso con una cantidad limitada de datos etiquetados, lo que podría reducir la necesidad de técnicas extensas de aumento de datos. Estos hallazgos destacan la robustez del enfoque basado en objetos, particularmente en la segmentación de áreas más grandes. Las investigaciones futuras deberían centrarse en mitigar estas limitaciones, posiblemente optimizando las arquitecturas de los modelos o adoptando técnicas de entrenamiento más eficientes.

La combinación de GANs y *Transformers* podría establecer un nuevo estándar en la detección de malas hierbas, aunque enfrenta el desafío del incremento en la complejidad computacional. A pesar de las mejoras logradas con el uso de técnicas de aumento de datos, el DETR sigue presentando limitaciones, especialmente en la detección de objetos pequeños como las malas hierbas en sus etapas tempranas de crecimiento. Esto indica que futuras investigaciones deberían centrarse en mejorar la resolución espacial y temporal del modelo, así como en optimizar los tiempos de entrenamiento para facilitar su aplicación en tiempo real.

Las etapas de crecimiento de las malas hierbas analizadas en esta investigación coinciden con el momento más adecuado para la aplicación de tratamientos herbicidas por dos razones principales: primero, el control es más efectivo en las fases tempranas de crecimiento, cuando la competencia de las malas hierbas con los cultivos es menor. Segundo, durante esta etapa, el solapamiento entre las plantas de cultivo es limitado, lo que reduce la interferencia y mejora la eficacia del herbicida. Los resultados obtenidos pueden contribuir a la implementación de estrategias de control específicas para cada especie y sitio en el momento óptimo. No obstante, será necesario desarrollar investigaciones adicionales para integrar estos modelos en sistemas más complejos que combinen detección, toma de decisiones y acciones automatizadas, alineándose con las estrategias de agricultura de precisión.

#### **8.4.1 Clasificación mediante un sistema basado en Computación Cognitiva**

El capítulo 7 presenta un estudio cuyo objetivo fue desarrollar un sistema de clasificación multiclase robusto y automatizado, capaz de identificar con precisión diversas especies de malas hierbas, independientemente de su etapa de crecimiento. Para ello, se emplearon los avances en Computación Cognitiva, con un enfoque particular en la aplicación de modelos de DL como ViTs y GANs. Además, la base de datos utilizada significativamente más amplia que la del capítulo anterior, incluyendo 31.002 imágenes etiquetadas en la etapa temprana de crecimiento (maíz BBCH14 y tomate BBCH501) y 36.556 imágenes en una etapa posterior (maíz BBCH17 y tomate BBCH509), proporcionando así una base sólida para la detección, clasificación y segmentación de especies de malas hierbas.

El modelo Swin-T, basado en la arquitectura ViT, alcanzó una precisión destacada del 99,1 % en

la etapa temprana de crecimiento, superando significativamente a enfoques previos basados en CNN (Mesías-Ruiz et al., 2024a). Resultados similares, que destacan la capacidad de los modelos basados en ViT para la identificación y discriminación de especies de malas hierbas, han sido citados recientemente, con precisiones superiores al 90 %.

A pesar del éxito alcanzado en las etapas tempranas de crecimiento, los resultados de inferencia en etapas más avanzadas mostraron un rendimiento inferior en comparación con otros estudios que usaron modelos similares. Este descenso en los *F1-scores* puede atribuirse a la mayor complejidad de las imágenes en etapas fenológicas avanzadas y a la clasificación de un mayor número de especies. No obstante, la capacidad del Swin-T para captar relaciones de largo alcance dentro de las imágenes mejora significativamente la precisión de clasificación, especialmente en bases de datos complejas y desbalanceadas. Este es un punto clave de la arquitectura ViT, que maneja bien los desequilibrios de clase, donde algunas especies de malas hierbas son menos comunes que otras. La implementación de un muestreador personalizado, que ajusta el peso de las clases según su representación en la base de datos, ha demostrado mejorar significativamente el rendimiento del modelo, contrastando con métodos más convencionales que tienden a sesgarse hacia las clases mayoritarias.

Swin-T mostró un gran potencial gracias a su mecanismo de atención, que pondera diferentes regiones de una imagen. Esta capacidad fue fundamental para identificar partes de malas hierbas y cultivos, especialmente cuando la base de datos de entrenamiento incluía imágenes con oclusiones, deformaciones y variaciones de escala. Estas características permitieron al modelo generalizar mejor y reconocer elementos relevantes bajo diversas condiciones. Aunque Swin-T no fue específicamente entrenado con partes de plantas, su capacidad de atención y representación jerárquica permitió una detección efectiva incluso en situaciones con oclusiones parciales. En este trabajo, se decidió no utilizar técnicas automatizadas para la optimización de hiperparámetros. Esta elección ofreció varias ventajas: redujo los costos computacionales y los tiempos de ejecución, permitiendo iteraciones experimentales más rápidas y precisas. Asimismo, este enfoque permitió un control más riguroso sobre los hiperparámetros, lo que, a su vez, facilitó ajustes específicos basados en observaciones empíricas durante el entrenamiento. Esto mejoró la reproducibilidad de los experimentos y proporcionó una comprensión más profunda de las interacciones entre los hiperparámetros y el rendimiento del modelo, lo cual es especialmente relevante en investigaciones exploratorias o con limitaciones de recursos.

Otro aspecto destacado de este trabajo fue la integración del marco GFPGAN para la generación de imágenes sintéticas, lo cual demostró ser una herramienta eficaz para mejorar la calidad de la base de datos. La capacidad del modelo GFPGAN×1 (procesamiento en el factor ×1) para generar imágenes de manera eficiente en tiempo real, junto con su balance entre velocidad y precisión, lo convierte en una opción atractiva para aplicaciones prácticas. A su vez, la implementación de GFPGAN×3 (procesamiento en el factor ×3), aunque más lenta, ofrece ventajas en tareas donde la precisión es prioritaria y el procesamiento ultrarrápido no es un requisito crítico.

La inferencia realizada utilizando el modelo original + GFPGAN×1 en las etapas fenológicas posteriores (BBCH17 y BBCH509) demostró que la integración de imágenes sintéticas generadas por el modelo GFPGAN, junto con imágenes reales, es una estrategia eficaz para mejorar la calidad de las bases de datos en el monitoreo de malas hierbas. En consecuencia, los hallazgos del presente estudio sugieren que la aplicación de GFPGAN en la caracterización de imágenes de plantas tiene un gran potencial para aplicaciones prácticas en escenarios del mundo real, particularmente en el

contexto del manejo de malas hierbas dentro del marco de la protección de cultivos de precisión.

Desde una perspectiva amplia, la utilización de modelos ViT, como Swin-T, junto a GANs, podría representar un cambio de paradigma en la clasificación de imágenes agrícolas, ofreciendo un rendimiento superior en tareas que requieren la discriminación de detalles finos entre especies morfológicamente similares. Sin embargo, es necesario continuar explorando la aplicabilidad de estos modelos en diferentes contextos geográficos y tipos de cultivos para generalizar sus beneficios y asegurar su eficacia en diversas condiciones agrícolas.

## 8.5 Mapas de prescripción

En el capítulo 6, el análisis de los mapas de densidad de malas hierbas generados utilizando un conjunto de plantas identificadas como *ground-truth* mostró rendimientos ligeramente inferiores a los reportados en estudios previos. Esta diferencia se atribuye a la mayor cantidad de especies consideradas en este estudio y al enfoque en un modelo generalizado para dos tipos de cultivos distintos. Esto resalta la complejidad añadida por la diversidad de especies, subrayando la necesidad de optimizar continuamente los modelos para mejorar su precisión en escenarios más diversos.

La altitud de vuelo tiene un impacto directo sobre la resolución y calidad de las imágenes, lo cual es un factor crítico que podría influir en la exactitud del modelo y que merece un análisis más profundo. Además, la investigación sobre clasificadores y detectores de malas hierbas basados en imágenes UAV es fundamental para seleccionar los modelos más precisos y rápidos, facilitando la futura implementación de UAVs equipados con *hardware* de IA avanzado y sistemas de telecomunicaciones de última generación. Estos UAVs podrían detectar, analizar y tratar rodales de malas hierbas en una operación única, permitiendo un control específico y localizado en operaciones precisas y en tiempo real, como por ejemplo la pulverización de herbicidas con UAVs.



# **Capítulo 9**

## **Conclusiones**



El presente capítulo proporciona una evaluación crítica de los resultados en relación con los objetivos planteados.

- A1.** Se revisaron los algoritmos de ML aplicados a la protección de cultivos de precisión, estableciendo una taxonomía que clasifica tanto enfoques tradicionales como los avances recientes en ANNs. La investigación destaca el impacto de estas técnicas en la optimización de la agricultura de precisión ante los desafíos actuales, y propone un marco conceptual para orientar futuras aplicaciones en los ámbitos científico, agronómico e industrial.
- A2.** Se crearon dos bases de datos abiertas de imágenes representativas y de alta calidad en formato JPG, destinadas a la detección temprana de malas hierbas mediante imágenes UAV. Estas bases de datos permiten tareas como clasificación y detección de objetos, y son ideales para desarrollar modelos avanzados, como CNN y ViT, para la identificación de malas hierbas en las primeras fases de crecimiento, comunes en los de cultivos de maíz y tomate.
- A3.** Los algoritmos de ML, especialmente los basados en DL, demostraron ser altamente efectivos en la detección y clasificación de malas hierbas en entornos agrícolas complejos. Esto se debe a su capacidad para extraer características de las imágenes sin la necesidad de predefinirlas manualmente.
- B1.** La selección de *frameworks* especializados fue un elemento esencial para el desarrollo de modelos de DL, ya que permitió centrarse en el diseño y la experimentación sin las complicaciones asociadas a la gestión de datos, facilitando la adaptación de modelos a tareas específicas, además de ofrecer un alto control sobre el flujo de datos y el preprocesamiento. Esta capacidad demostró ser fundamental para comparar diversas configuraciones y técnicas de optimización orientadas a desarrollar algoritmos computacionalmente eficientes.
- B2.** La utilización de tensores en *frameworks* como TensorFlow, Keras y PyTorch fue fundamental para integrar la diversidad de imágenes RGB como estructuras de datos multidimensionales, facilitando el manejo de grandes volúmenes de datos de alta dimensionalidad y la ejecución de operaciones matemáticas complejas. Además, estos *frameworks* optimizaron el uso de tensores mediante técnicas de paralelización y gestión de memoria, lo que permitió un manejo eficiente de los datos y contribuyó a la implementación de un método general que combina la diversidad de imágenes RGB con un alto rendimiento computacional.
- C1.** Los modelos evaluados, que incluyen VGG16, ResNet152, Inception-ResNet-v2, EfficientNet-B0, YOLOv8, ViT-Base y Swin-T, demostraron ser efectivos para la identificación temprana de malas hierbas, mostrando adaptabilidad frente a la elevada variabilidad espacial y temporal observada. Se comprobó que la capacidad de estos modelos para manejar las diferencias en las condiciones del suelo y la densidad de siembra es crucial para mantener la exactitud en la identificación de especies. Por tanto, se logró establecer un marco sólido para la aplicación de estas técnicas en la mejora del monitoreo agrícola bajo condiciones cambiantes.
- C2.** Se demostró que la combinación de imágenes UAV con modelos basados en CNN y ViT permite una adecuada identificación de especies de malas hierbas en etapas tempranas de crecimiento. La metodología desarrollada incluye la creación de una base de datos robusta y la adaptación de las entradas de los modelos para alinearse con la resolución de las imágenes UAV. Con este enfoque se logró superar el 90 % de exactitud en escenarios balanceados.

Además, se destaca la importancia de mantener un equilibrio adecuado entre las especies minoritarias y mayoritarias en la base de datos de entrenamiento, con el fin de evitar la clasificación incorrecta de las especies menos representadas. La integración de algoritmos para la detección y localización de malas hierbas demostró ser efectiva en la generación de mapas de densidad de malas hierbas. Por lo tanto, esta metodología representa un avance significativo hacia la identificación temprana y precisa de especies de malas hierbas en escenarios reales.

- D1.** La comparación de arquitecturas basadas en CNN avanzadas y ViT en términos de rendimiento para la detección y clasificación precisa de malas hierbas a nivel de especie en etapas tempranas de crecimiento, donde las diferencias morfológicas son mínimas, reveló que los modelos YOLOv8 y Swin-T presentaron un rendimiento equilibrado en todas las clases. Por lo tanto, ambas arquitecturas son herramientas prometedoras para la gestión sostenible de malas hierbas en la postemergencia temprana.
- D2.** El uso de técnicas avanzadas de aumento de datos, como las GANs, ha demostrado ser fundamental para mejorar la capacidad de generalización de los modelos de clasificación en situaciones de datos desbalanceados. En particular, la implementación del modelo GFPGAN para la generación de imágenes sintéticas permite ampliar la diversidad de la base de datos de entrenamiento sin necesidad de realizar esfuerzos adicionales y costosos de recolección de datos. Esto no solo reduce el riesgo de sobreajuste (*overfitting*) al proporcionar representaciones más amplias del espacio de características, sino que también incrementa de manera significativa la exactitud en la clasificación de etapas de crecimiento posteriores, logrando una mejora promedio del *F1-score* del 95,3 % en escenarios de datos aumentados.
- E.** La automatización de la generación de mapas georreferenciados se vio potenciada por la integración de modelos de DL, como las CNNs y los ViTs, lo que facilitó la ubicación precisa de áreas afectadas, que luego pueden utilizarse para crear mapas de distribución de malas hierbas. La combinación de estas técnicas de DL con los SIG permite la creación de mapas dinámicos y actualizados, mejorando la capacidad de respuesta en la gestión de cultivos.

## 9.1 Futuras líneas de investigación

El avance continuo en la AP, combinado con la IA y las tecnologías de la información, abre nuevas oportunidades para mejorar la eficiencia y sostenibilidad de la producción agrícola. Las siguientes líneas de investigación futuras se presentan como una extensión natural de los logros alcanzados en esta tesis doctoral, buscando profundizar y expandir las aplicaciones de los modelos y algoritmos desarrollados:

**A. Evaluación en campo del proceso de detección, clasificación, mapeo y aplicación de las estrategias SSWM en cultivos de maíz y tomate: Análisis agronómico y económico.**

La implementación y validación en campo del proceso desarrollado en esta tesis, aplicado a cultivos relevantes como el maíz y el tomate, tiene como objetivo principal evaluar la capacidad de la metodología y los modelos para generar mapas georreferenciados de especies de malas hierbas de forma automática, garantizando su exactitud y escalabilidad. Además, se busca implementar estrategias de SSWM que permitan diseñar mapas de tratamiento adaptados a las condiciones específicas de cada parcela, optimizando el uso de herbicidas y reduciendo su impacto ambiental. También se analizará el impacto de este proceso en los cultivos seleccionados mediante la medición de indicadores relacionados con el rendimiento agrícola, la calidad del producto, la sostenibilidad ambiental y la viabilidad económica. Esta propuesta no solo valida la robustez y fiabilidad del modelo desarrollado, sino que también explora su potencial para ser escalado y aplicado en otros sistemas de cultivo, promoviendo así prácticas agrícolas más sostenibles, eficientes y alineadas con los principios de la agricultura de precisión.

**B. Evaluación e implementación de los modelos estudiados en sistemas embebidos de bajo consumo energético.**

Una dirección prometedora es la implementación de los modelos predictivos y de clasificación desarrollados en esta tesis en sistemas embebidos de bajo consumo energético. Esto no solo permitirá llevar la tecnología a dispositivos en campo, sino que también optimizará el uso de recursos, especialmente en entornos agrícolas remotos o de difícil acceso. La investigación deberá enfocarse en la adaptación de estos modelos para su ejecución en hardware con capacidades limitadas, como microcontroladores y dispositivos de edge computing. Además, será crucial evaluar el rendimiento de estos sistemas en términos de precisión, tiempo de procesamiento y consumo energético, con el objetivo de desarrollar soluciones escalables y económicamente viables para los agricultores.

**C. Evaluación de los algoritmos para la entrada de información en formato de video (pregrabado o en tiempo real).**

Los avances en visión artificial y procesamiento de imágenes han permitido el desarrollo de algoritmos que procesan imágenes estáticas de manera efectiva. Sin embargo, la evaluación de estos algoritmos para la entrada de información en formato de video representa un desafío y una oportunidad para mejorar la detección en tiempo real de parámetros agronómicos clave. La futura investigación debe centrarse en la optimización de estos algoritmos para procesar secuencias de video, tanto grabado como en tiempo real, asegurando que la detección de malas hierbas y otros factores relevantes mantenga una alta precisión y robustez en diferentes condiciones de campo.

**D. Determinación de los parámetros óptimos del UAV y sensor RGB para la detección en tiempo real.**

Una parte crucial para la implementación práctica de los sistemas de detección en campo es la configuración óptima de los UAVs y los sensores utilizados. La futura investigación deberá abordar la determinación de los parámetros óptimos para los UAVs, como altura de vuelo, velocidad, ángulos de captura y frecuencia de muestreo, en conjunto con la calibración de sensores RGB para diferentes condiciones de luz y ambientales. Estos estudios permitirán no solo mejorar la precisión en la detección de malas hierbas, sino también reducir los tiempos de operación y los costos asociados, haciendo que la tecnología sea más accesible y efectiva para su aplicación en la agricultura de precisión.

**E. Diseño de experimentos para la ejecución en *edge computing* y *edge AI*.**

La implementación de algoritmos de IA directamente en dispositivos de *edge computing* representa una línea de investigación con un gran potencial. Los estudios futuros deberán centrarse en el diseño de experimentos que exploren cómo los modelos de detección de malas hierbas pueden ser optimizados para su ejecución en estos entornos distribuidos. Esto incluirá la evaluación del *trade-off* entre la complejidad del modelo y las limitaciones de hardware, así como la exploración de técnicas de compresión de modelos y *federated learning* para mantener un rendimiento elevado sin necesidad de una conexión constante a la nube. La validación en entornos de campo reales será crucial para demostrar la viabilidad de esta aproximación.

**F. Creación de gemelos digitales para simular la detección de malas hierbas desde plataformas móviles autónomas.**

La creación de gemelos digitales ofrece una oportunidad única para modelar, simular y optimizar los sistemas de detección de malas hierbas antes de su implementación en el campo. Estos gemelos digitales permitirán replicar las condiciones de operación de los UAVs y otras plataformas autónomas en entornos controlados, facilitando la evaluación de diferentes estrategias de detección y respuesta. La investigación futura deberá centrarse en el desarrollo de estos modelos virtuales, incluyendo la simulación de la dinámica del vuelo, las condiciones ambientales y la interacción con el terreno y la vegetación. Además, el uso de estos gemelos digitales para el entrenamiento y ajuste de los algoritmos de IA será una herramienta poderosa para acelerar el desarrollo y despliegue de nuevas tecnologías.

**G. Necesidad de anotaciones de alta calidad y métodos de etiquetado automatizados.**

Las anotaciones precisas de datos son cruciales para entrenar modelos de IA capaces de identificar malas hierbas en etapas tempranas. La calidad de las etiquetas afecta directamente la precisión del modelo. No obstante, el etiquetado manual de grandes volúmenes de imágenes es laborioso y propenso a errores. En este contexto, el desarrollo de métodos de etiquetado automatizados o semi-automatizados, que aprovechen el aprendizaje activo y la IA, podría acelerar el proceso de anotación y mejorar la precisión del entrenamiento del modelo, al tiempo que se reducen los costos y el tiempo requeridos. Las investigaciones futuras deben centrarse en el desarrollo de modelos de IA que combinen enfoques supervisados y no supervisados para mejorar la capacidad de detección de malas hierbas en sus etapas más tempranas.

**H. Ampliación de la metodología a otros cultivos, especies de malas hierbas y campos de la protección de cultivos.**

Finalmente, la metodología desarrollada en esta tesis, que ha demostrado ser eficaz en un

contexto específico, debe ser expandida a otros cultivos y especies de malas hierbas. La adaptabilidad de los modelos a diferentes escenarios agrícolas es clave para su generalización y adopción amplia. Además, se propone explorar la aplicación de estos métodos en otros campos de la protección de cultivos, como la detección de plagas y enfermedades, la estimación de la salud del cultivo y la optimización del uso de insumos. Estas investigaciones no solo expandirán el impacto de las tecnologías desarrolladas, sino que también contribuirán a una agricultura más sostenible y resiliente a nivel global.

Estas futuras líneas de investigación no solo fortalecerán los logros de la presente tesis, sino que también contribuirán a la creación de un marco tecnológico más robusto y versátil, capaz de responder a los desafíos emergentes en la agricultura de precisión.



# Referencias

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M., . . . Zheng, X. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv*. <https://doi.org/https://arxiv.org/abs/1603.04467>
- Abdulridha, J., Ampatzidis, Y., Ehsani, R., & de Castro, A. I. (2018). Evaluating the performance of spectral features and multivariate analysis tools to detect laurel wilt disease and nutritional deficiency in avocado. *Computers and Electronics in Agriculture*, 155(155), 203-211. <https://doi.org/10.1016/j.compag.2018.10.016>
- Aghav-Palwe, S., & Gunjal, A. (2021). Chapter 1 - Introduction to cognitive computing and its various applications. En M. Mittal, R. R. Shah & S. Roy (Eds.), *Cognitive Computing for Human-Robot Interaction* (pp. 1-18). Academic Press. <https://doi.org/10.1016/B978-0-323-85769-7.00009-4>
- Ajayi, O. G., & Ashi, J. (2023). Effect of varying training epochs of a Faster Region-Based Convolutional Neural Network on the Accuracy of an Automatic Weed Classification Scheme. *Smart Agricultural Technology*, 3, 100128. <https://doi.org/10.1016/j.atech.2022.100128>
- Alatise, M. B., & Hancke, G. P. (2020). A Review on Challenges of Autonomous Mobile Robot and Sensor Fusion Methods. *IEEE Access*, 8, 39830-39846. <https://doi.org/10.1109/ACCESS.2020.2975643>
- Albiero, D., Garcia, A. P., Umezu, C. K., & de Paulo, R. L. (2022). Swarm robots in mechanized agricultural operations: A review about challenges for research. *Computers and Electronics in Agriculture*, 193(193), 106608. <https://doi.org/10.1016/j.compag.2021.106608>
- Allmendinger, A., Spaeth, M., Saile, M., Peteinatos, G. G., & Gerhards, R. (2022). Precision Chemical Weed Management Strategies: A Review and a Design of a New CNN-Based Modular Spot Sprayer. *Agronomy*, 12(7), 1620. <https://doi.org/10.3390/agronomy12071620>
- Andújar, D., Ribeiro, A., Carmona, R., Fernández-Quintanilla, C., & Dorado, J. (2010). An assessment of the accuracy and consistency of human perception of weed cover. *Weed Research*, 50(6), 638-647. <https://doi.org/10.1111/j.1365-3180.2010.00809.x>
- Arbib, M. (1969). Review of 'Perceptrons: An Introduction to Computational Geometry' (Minsky, M., and Papert, S.; 1969). *IEEE Transactions on Information Theory*, 15(6), 738-739. <https://doi.org/10.1109/TIT.1969.1054388>
- Argüelles, L., & March, H. (2022). Weeds in action: Vegetal political ecology of unwanted plants. *Progress in Human Geography*, 46(1), 44-66. <https://doi.org/10.1177/03091325211054966>

- Bagheri, N. (2020). Application of aerial remote sensing technology for detection of fire blight infected pear trees. *Computers and Electronics in Agriculture*, 168(168), 105147. <https://doi.org/10.1016/j.compag.2019.105147>
- Bah, M. D., Hafiane, A., & Canals, R. (2018). Deep Learning with Unsupervised Data Labeling for Weed Detection in Line Crops in UAV Images. *Remote Sens.*, 10(11), 1690. <https://doi.org/10.3390/rs10111690>
- Barbedo, J. G. A. (2020). Detecting and Classifying Pests in Crops Using Proximal Images and Machine Learning: A Review. *AI*, 1(2), 312-328. <https://doi.org/10.3390/ai1020021>
- Barreto, A., Paulus, S., Varrelmann, M., & Mahlein, A.-K. (2020). Hyperspectral imaging of symptoms induced by *Rhizoctonia solani* in sugar beet: comparison of input data and different machine learning algorithms. *Journal of Plant Diseases and Protection*, 127(4), 441-451. <https://doi.org/10.1007/s41348-020-00344-8>
- Basinger, N. T., Jennings, K. M., Hestir, E. L., Monks, D. W., Jordan, D. L., & Everman, W. J. (2020). Phenology affects differentiation of crop and weed species using hyperspectral remote sensing. *Weed Technology*, 34(6), 897-908. <https://doi.org/10.1017/wet.2020.92>
- Behmann, J., Mahlein, A.-K., Rumpf, T., Römer, C., & Plümer, L. (2015). A review of advanced machine learning methods for the detection of biotic stress in precision crop protection. *Precision Agriculture*, 16(3), 239-260. <https://doi.org/10.1007/s11119-014-9372-7>
- Belhajem, I., Maissa, Y. B., & Tantaoui, A. (2016). A robust low cost approach for real time car positioning in a smart city using Extended Kalman Filter and evolutionary machine learning. En *2016 4th IEEE International Colloquium on Information Science and Technology (CiSt)* (pp. 806-811). IEEE. <https://doi.org/10.1109/CIST.2016.7804998>
- Birrell, S., Hughes, J., Cai, J. Y., & Iida, F. (2020). A field-tested robotic harvesting system for iceberg lettuce. *Journal of Field Robotics*, 37(2), 225-245. <https://doi.org/10.1002/rob.21888>
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2-16. <https://doi.org/10.1016/j.isprsjprs.2009.06.004>
- Bogue, R. (2016). Robots poised to revolutionise agriculture. *Industrial Robot: An International Journal*, 43(5), 450-456. <https://doi.org/10.1108/IR-05-2016-0142>
- Bonomi, F., Milito, R., Zhu, J., & Addepalli, S. (2012). Fog computing and its role in the internet of things. *Proceedings of the First Edition of the MCC Workshop on Mobile Cloud Computing*, 13-16. <https://doi.org/10.1145/2342509.2342513>
- Botta, A., Cavallone, P., Baglieri, L., Colucci, G., Tagliavini, L., & Quaglia, G. (2022). A Review of Robots, Perception, and Tasks in Precision Agriculture. *Applied Mechanics*, 3(3), 830-854. <https://doi.org/10.3390/applmech3030049>
- Brette, R., Rudolph, M., Carnevale, T., Hines, M., Beeman, D., Bower, J. M., Diesmann, M., Morrison, A., Goodman, P. H., Harris, F. C., Zirpe, M., Natschläger, T., Pecevski, D., Ermentrout, B., Djurfeldt, M., Lansner, A., Rochel, O., Vieville, T., Muller, E., ... Destexhe, A. (2007). Simulation of networks of spiking neurons: A review of tools and strategies. *Journal of Computational Neuroscience*, 23(3), 349-398. <https://doi.org/10.1007/s10827-007-0038-6>
- Bustio-Martínez, L., Cumplido, R., Letras, M., Hernández-León, R., Feregrino-Uribe, C., & Hernández-Palancar, J. (2022). FPGA/GPU-based Acceleration for Frequent Itemsets Mining: A Comprehensive Review. *ACM Computing Surveys*, 54(9), 1-35. <https://doi.org/10.1145/3472289>

- Calderón, R., Navas-Cortés, J. A., & Zarco-Tejada, P. J. (2015). Early Detection and Quantification of Verticillium Wilt in Olive Using Hyperspectral and Thermal Imagery over Large Areas. *Remote Sensing*, 7(5), 5584-5610. <https://doi.org/10.3390/rs70505584>
- Cao, Y.-J., Jia, L.-L., Chen, Y.-X., Lin, N., Yang, C., Zhang, B., Liu, Z., Li, X.-X., & Dai, H.-H. (2019). Recent Advances of Generative Adversarial Networks in Computer Vision. *IEEE Access*, 7, 14985-15006. <https://doi.org/10.1109/ACCESS.2018.2886814>
- Cardim Ferreira Lima, M., Damascena de Almeida Leandro, M. E., Valero, C., Pereira Coronel, L. C., & Gonçalves Bazzo, C. O. (2020). Automatic Detection and Monitoring of Insect Pests—A Review. *Agriculture*, 10(5), 161. <https://doi.org/10.3390/agriculture10050161>
- Carion, N., Massa, F., Synnaeve, G., Usunier, N., Kirillov, A., & Zagoruyko, S. (2020). End-to-End Object Detection with Transformers. <https://doi.org/10.48550/arXiv.2005.12872>
- Castaldi, F., Pelosi, F., Pascucci, S., & Casa, R. (2017). Assessing the potential of images from unmanned aerial vehicles (UAV) to support herbicide patch spraying in maize. *Precision Agriculture*, 18(1), 76-94. <https://doi.org/10.1007/s11119-016-9468-3>
- Castro, S., Iñacasha, J., Mesias, G., & Oñate, W. (2023). Prototype Based on a LoRaWAN Network for Storing Multivariable Data, Oriented to Agriculture with Limited Resources. En X.-S. Yang, S. Sherratt, N. Dey & A. Joshi (Eds.), *Proceedings of Seventh International Congress on Information and Communication Technology* (pp. 245-255). Springer Nature Singapore. <https://doi.org/10.1007/978-981-19-1610-6>
- Chadha, S., Sharma, M., & Sayyed, A. (2021). Chapter 12 - Advances in sensing plant diseases by imaging and machine learning methods for precision crop protection. En A. Kumar & S. Drobny (Eds.), *Microbial Management of Plant Stresses* (pp. 157-183). Woodhead Publishing. <https://doi.org/10.1016/B978-0-323-85193-0.00012-7>
- Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly detection: A survey. *ACM Computing Surveys*, 41(3), 15:1-15:58. <https://doi.org/10.1145/1541880.1541882>
- Chen, D., Lu, Y., Li, Z., & Young, S. (2022). Performance evaluation of deep transfer learning on multi-class identification of common weed species in cotton production systems. *Comput. Electron. Agric.*, 198, 107091. <https://doi.org/10.1016/j.compag.2022.107091>
- Chew, R., Rineer, J., Beach, R., O'Neil, M., Ujeneza, N., Lapidus, D., Miano, T., Hegarty-Craver, M., Polly, J., & Temple, D. S. (2020). Deep Neural Networks and Transfer Learning for Food Crop Identification in UAV Images. *Drones*, 4, 7(1). <https://doi.org/10.3390/drones4010007>
- Chhikara, P., Jain, N., Tekchandani, R., & Kumar, N. (2020). Data dimensionality reduction techniques for Industry 4.0: Research results, challenges, and future research directions. *Software: Practice and Experience*, 52(3), 658-688. <https://doi.org/10.1002/spe.2876>
- Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1800-1807. <https://doi.org/10.1109/CVPR.2017.195>
- Chopra, G., Kumar Jha, R., & Jain, S. (2017). A survey on ultra-dense network and emerging technologies: Security challenges and possible solutions. *Journal of Network and Computer Applications*, 95(95), 54-78. <https://doi.org/10.1016/j.jnca.2017.07.007>
- Čížek, Pavel and Sadıkoğlu, Serhan. (2020). Robust nonparametric regression: A review. *Wiley Interdisciplinary Reviews: Computational Statistics*, 12(3), e1492. <https://doi.org/10.1002/wics.1492>
- Coble, H. D., & Mortensen, D. A. (1992). The Threshold Concept and Its Application to Weed Science. *Weed Technology*, 6(1), 191-195.

- Coulibaly, S., Kamsu-Foguem, B., Kamissoko, D., & Traore, D. (2022). Deep learning for precision agriculture: A bibliometric analysis. *Intelligent Systems with Applications*, 16(16), 200102. <https://doi.org/10.1016/j.iswa.2022.200102>
- Dainelli, R., Toscano, P., Di Gennaro, S. F., & Matese, A. (2021). Recent Advances in Unmanned Aerial Vehicles Forest Remote Sensing - A Systematic Review. Part II: Research Applications. *Forests*, 12(4). <https://doi.org/10.3390/f12040397>
- Davies, M., Srinivasa, N., Lin, T.-H., China, G., Cao, Y., Choday, S. H., Dimou, G., Joshi, P., Imam, N., Jain, S., Liao, Y., Lin, C.-K., Lines, A., Liu, R., Mathaikutty, D., McCoy, S., Paul, A., Tse, J., Venkataramanan, G., . . . Wang, H. (2018). Loihi: A Neuromorphic Manycore Processor with On-Chip Learning. *IEEE Micro*, 38(1), 82-99. <https://doi.org/10.1109/MM.2018.112130359>
- de Camargo, T., Schirrmann, M., Landwehr, N., Dammer, K.-H., & Pflanz, M. (2021). Optimized Deep Learning Model as a Basis for Fast UAV Mapping of Weed Species in Winter Wheat Crops. *Remote Sensing*, 13(9). <https://doi.org/10.3390/rs13091704>
- de Carvalho Alves, M., Pozza, E. A., Sanches, L., Belan, L. L., & de Oliveira Freitas, M. L. (2022). Insights for improving bacterial blight management in coffee field using spatial big data and machine learning. *Tropical Plant Pathology*, 47(1), 118-139. <https://doi.org/10.1007/s40858-021-00474-w>
- de Castro, A. I., Ehsani, R., Ploetz, R., Crane, J. H., & Abdulridha, J. (2015). Optimum spectral and geometric parameters for early detection of laurel wilt disease in avocado. *Remote Sensing of Environment*, 171, 33-44. <https://doi.org/10.1016/j.rse.2015.09.011>
- de Castro, A. I., Peña, J. M., Torres-Sánchez, J., Jiménez-Brenes, F. M., Valencia-Gredilla, F., Recasens, J., & López-Granados, F. (2020). Mapping *Cynodon dactylon* infesting cover crops with an automatic decision tree-OBIA procedure and UAV imagery for precision viticulture. *Remote Sensing*, 12(1), 56. <https://doi.org/10.3390/rs12010056>
- de Castro, A. I., Shi, Y., Maja, J. M., & Peña, J. M. (2021). UAVs for Vegetation Monitoring: Overview and Recent Scientific Contributions. *Remote Sensing*, 13(11), 2139. <https://doi.org/10.3390/rs13112139>
- de Castro, A. I., Torres-Sánchez, J., Peña, J. M., Jiménez-Brenes, F. M., Csillik, O., & López-Granados, F. (2018). An Automatic Random Forest-OBIA Algorithm for Early Weed Mapping between and within Crop Rows Using UAV Imagery. *Remote Sensing*, 10(2). <https://doi.org/10.3390/rs10020285>
- de Castro, A. I., Jurado-Expósito, M., Gómez-Casero, M. T., & López-Granados, F. (2012). Applying Neural Networks to Hyperspectral and Multispectral Field Data for Discrimination of Cruciferous Weeds in Winter Crops. *The Scientific World Journal*, 2012(e630390), 11. <https://doi.org/10.1100/2012/630390>
- de Castro, A. I., López-Granados, F., & Jurado-Expósito, M. (2013). Broad-scale cruciferous weed patch classification in winter wheat using QuickBird imagery for in-season site-specific control. *Precision Agriculture*, 14(4), 392-413. <https://doi.org/10.1007/s11119-013-9304-y>
- de Castro Megías, A. I., Pérez-Roncal, C., Thomasson, J. A., Ehsani, R., López-Maestresalas, A., Yang, C., Jarén, C., Wang, C., Tianyi and Cribben, Marin, D., Isakeit, T., Urrestarazu, J., Lopez-Molina, C., Wang, X., Nichols, R. L., Santesteban, G., Arazuri, S., & Peña, J. M. (2021). Applications of Sensing for Disease detection. En R. Kerry & A. Escolà (Eds.), *Sensing Approaches for Precision Agriculture* (pp. 369-398). Springer International Publishing. [https://doi.org/10.1007/978-3-030-78431-7\\_13](https://doi.org/10.1007/978-3-030-78431-7_13)

- De-An, Z., Jidong, L., Wei, J., Ying, Z., & Yu, C. (2011). Design and control of an apple harvesting robot. *Biosystems Engineering*, 110(2), 112-122. <https://doi.org/10.1016/j.biosystemseng.2011.07.005>
- DeVries, T., & Taylor, G. W. (2017). Improved Regularization of Convolutional Neural Networks with Cutout. <https://doi.org/10.48550/arXiv.1708.04552>
- Diehl, P. U., Neil, D., Binas, J., Cook, M., Liu, S.-C., & Pfeiffer, M. (2015). Fast-classifying, high-accuracy spiking deep networks through weight and threshold balancing. *2015 International Joint Conference on Neural Networks (IJCNN)*, 1-8. <https://doi.org/10.1109/IJCNN.2015.7280696>
- Djafri, L., & Gafour, Y. (2022). Machine Learning Algorithms for Big Data Mining Processing: A Review. En B. Lejdel, E. Clementini & L. Alarabi (Eds.), *Artificial Intelligence and Its Applications* (pp. 43-55). Springer International Publishing. [https://doi.org/10.1007/978-3-030-96311-8\\_5](https://doi.org/10.1007/978-3-030-96311-8_5)
- Dong, Y., Hou, J., Zhang, N., & Zhang, M. (2020). Research on How Human Intelligence, Consciousness, and Cognitive Computing Affect the Development of Artificial Intelligence (R. Rao, Ed.) [Publisher: Hindawi]. *Complexity*, 2020, 1680845. <https://doi.org/10.1155/2020/1680845>
- Donthu, N., Kumar, S., Mukherjee, D., Pandey, N., & Lim, W. M. (2021). How to conduct a bibliometric analysis: An overview and guidelines. *Journal of Business Research*, 133, 285-296. <https://doi.org/10.1016/j.jbusres.2021.04.070>
- dos Santos Ferreira, A., Freitas, D. M., da Silva, G. G., Pistori, H., & Folhes, M. T. (2019). Unsupervised deep learning and semi-automatic data labeling in weed discrimination. *Comput. Electron. Agric.*, 165, 104963. <https://doi.org/10.1016/j.compag.2019.104963>
- dos Santos Ferreira, A., Matte Freitas, D., Gonçalves da Silva, G., Pistori, H., & Theophilo Folhes, M. (2017). Weed detection in soybean crops using ConvNets. *Computers and Electronics in Agriculture*, 143, 314-324. <https://doi.org/10.1016/j.compag.2017.10.027>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2021). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *arXiv preprint arXiv:2010.11929*. <https://doi.org/10.48550/arXiv.2010.11929>
- Durmuş, H., Güneş, E. O., & Kırcı, M. (2017). Disease detection on the leaves of the tomato plants by using deep learning. En *2017 6th International Conference on Agro-Geoinformatics* (pp. 1-5). IEEE. <https://doi.org/10.1109/Agro-Geoinformatics.2017.8047016>
- Dyrmann, M., Karstoft, H., & Midtby, H. S. (2016). Plant species classification using deep convolutional neural network. *Biosyst. Eng.*, 151, 72-80. <https://doi.org/10.1016/j.biosystemseng.2016.08.024>
- Ebrahimi, M., Khoshtaghaza, M., Minaei, S., & Jamshidi, B. (2017). Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*, 137, 52-58. <https://doi.org/10.1016/j.compag.2017.03.016>
- Eickenberg, M., Gramfort, A., Varoquaux, G., & Thirion, B. (2017). Seeing it all: Convolutional network layers map the function of the human visual system. *NeuroImage*, 152, 184-194. <https://doi.org/10.1016/j.neuroimage.2016.10.001>
- Ejaz, W., Basharat, M., Saadat, S., Khattak, A. M., Naeem, M., & Anpalagan, A. (2020). Learning paradigms for communication and computing technologies in IoT systems. *Computer Communications*, 153(153), 11-25. <https://doi.org/10.1016/j.comcom.2020.01.043>

- Emmi, L., Gonzalez-de-Soto, M., Pajares, G., & Gonzalez-de-Santos, P. (2014). New Trends in Robotics for Agriculture: Integration and Assessment of a Real Fleet of Robots. *The Scientific World Journal*, 2014(404059), 21. <https://doi.org/10.1155/2014/404059>
- Espejo-Garcia, B., Panoutsopoulos, H., Anastasiou, E., Rodríguez-Rigueiro, F. J., & Fountas, S. (2023). Top-tuning on transformers and data augmentation transferring for boosting the performance of weed identification. *Computers and Electronics in Agriculture*, 211, 108055. <https://doi.org/10.1016/j.compag.2023.108055>
- Esser, S. K., Merolla, P. A., Arthur, J. V., Cassidy, A. S., Appuswamy, R., Andreopoulos, A., Berg, D. J., McKinstry, J. L., Melano, T., Barch, D. R., di Nolfo, C., Datta, P., Amir, A., Taba, B., Flickner, M. D., & Modha, D. S. (2016). Convolutional networks for fast, energy-efficient neuromorphic computing. *Proceedings of the National Academy of Sciences*, 113(41), 11441-11446. <https://doi.org/10.1073/pnas.1604850113>
- Ezugwu, A. E., Ikotun, A. M., Oyelade, O. O., Abualigah, L., Agushaka, J. O., Eke, C. I., & Akinyelu, A. A. (2022). A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects. *Engineering Applications of Artificial Intelligence*, 110(110), 104743. <https://doi.org/10.1016/j.engappai.2022.104743>
- Falkland, T., & White, I. (2020). Freshwater Availability Under Climate Change. En L. Kumar (Ed.), *Climate Change and Impacts in the Pacific* (pp. 403-448). Springer International Publishing. [https://doi.org/10.1007/978-3-030-32878-8\\_11](https://doi.org/10.1007/978-3-030-32878-8_11)
- Farooq, A., Hu, J., & Jia, X. (2019). Analysis of Spectral Bands and Spatial Resolutions for Weed Classification Via Deep Convolutional Neural Network. *IEEE Geoscience and Remote Sensing Letters*, 16(2), 183-187. <https://doi.org/10.1109/LGRS.2018.2869879>
- Feng, Z.-H., Wang, L.-Y., Yang, Z.-Q., Zhang, Y.-Y., Li, X., Song, L., He, L., Duan, J.-Z., & Feng, W. (2022). Hyperspectral Monitoring of Powdery Mildew Disease Severity in Wheat Based on Machine Learning. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.828454>
- Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*, 145, 311-318. <https://doi.org/10.1016/j.compag.2018.01.009>
- Fernandez-Quintanilla, C., Dorado, J., Andújar, D., & Peña-Barragán, J. M. (2022). Advanced detection technologies for weed scouting. En K. Pereditor (Ed.), *Advances in Integrated Weed Management* (pp. 205-227). Burleigh Dodds Science Publishing Limited 2021. <https://doi.org/10.19103/AS.2021.0098.09>
- Fernández-Quintanilla, C., Peña, J. M., Andújar, D., Dorado, J., Ribeiro, A., & López-Granados, F. (2018). Is the current state of the art of weed monitoring suitable for site-specific weed management in arable crops? *Weed Research*, 58(4), 259-272. <https://doi.org/10.1111/wre.12307>
- Fernández-Quintanilla, C., Dorado, J., Andújar, D., & Peña, J. M. (2020). Site-Specific Based Models. En G. R. Chantre & J. L. González-Andújar (Eds.), *Decision Support Systems for Weed Management* (pp. 143-157). Springer International Publishing. [https://doi.org/10.1007/978-3-030-44402-0\\_7](https://doi.org/10.1007/978-3-030-44402-0_7)
- Filho, F. H. I., Heldens, W. B., Kong, Z., & de Lange, E. S. (2020). Drones: Innovative Technology for Use in Precision Pest Management. *Journal of Economic Entomology*, 113(1), 1-25. <https://doi.org/10.1093/jee/toz268>
- Floreano, D., & Wood, R. J. (2015). Science, technology and the future of small autonomous drones. *Nature*, 521(7553), 460-466. <https://doi.org/10.1038/nature14542>

- Fraccaro, P., Butt, J., Edwards, B., Freckleton, R. P., Childs, D. Z., Reusch, K., & Comont, D. (2022). A Deep Learning Application to Map Weed Spatial Extent from Unmanned Aerial Vehicles Imagery. *Remote Sensing*, 14(17). <https://doi.org/10.3390/rs14174197>
- Fuentes, S., Tongson, E., Unnithan, R. R., & Gonzalez Viejo, C. (2021). Early Detection of Aphid Infestation and Insect-Plant Interaction Assessment in Wheat Using a Low-Cost Electronic Nose (E-Nose), Near-Infrared Spectroscopy and Machine Learning Modeling. *Sensors*, 21(17), 5948. <https://doi.org/10.3390/s21175948>
- Fürnkranz, J., & Kliegr, T. (2015). A brief overview of rule learning. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9202, 54-69. [https://doi.org/10.1007/978-3-319-21542-6\\_4](https://doi.org/10.1007/978-3-319-21542-6_4)
- Gaitán, C. F. (2020). Chapter 7 - Machine learning applications for agricultural impacts under extreme events. En J. Sillmann, S. Sippel & S. Russo (Eds.), *Climate Extremes and Their Implications for Impact and Risk Assessment* (pp. 119-138). Elsevier. <https://doi.org/10.1016/B978-0-12-814895-2.00007-0>
- Gallo, I., Rehman, A. U., Dehkordi, R. H., Landro, N., La Grassa, R., & Boschetti, M. (2023). Deep Object Detection of Crop Weeds: Performance of YOLOv7 on a Real Case Dataset from UAV Images. *Remote Sensing*, 15(2). <https://doi.org/10.3390/rs15020539>
- Gao, J., Liao, W., Nuyttens, D., Lootens, P., Xue, W., Alexandersson, E., & Pieters, J. (2024). Cross-domain transfer learning for weed segmentation and mapping in precision farming using ground and UAV images. *Expert Systems with Applications*, 246, 122980. <https://doi.org/10.1016/j.eswa.2023.122980>
- Gao, J., Nuyttens, D., Lootens, P., He, Y., & Pieters, J. G. (2018). Recognising weeds in a maize crop using a random forest machine-learning algorithm and near-infrared snapshot mosaic hyperspectral imagery. *Biosystems Engineering*, 170(170), 39-50. <https://doi.org/10.1016/j.biosystemseng.2018.03.006>
- Gao, W., & Zhou, P. (2019). Customized High Performance and Energy Efficient Communication Networks for AI Chips. *IEEE Access*, 7, 69434-69446. <https://doi.org/10.1109/ACCESS.2019.2916338>
- García-Ruiz, F., Sankaran, S., Maja, J. M., Lee, W. S., Rasmussen, J., & Ehsani, R. (2013). Comparison of two aerial imaging platforms for identification of Huanglongbing-infected citrus trees. *Computers and Electronics in Agriculture*, 91(91), 106-115. <https://doi.org/10.1016/j.compag.2012.12.002>
- García-Valls, M., Dubey, A., & Botti, V. (2018). Introducing the new paradigm of Social Dispersed Computing: Applications, Technologies and Challenges. *Journal of Systems Architecture*, 91(91), 83-102. <https://doi.org/10.1016/j.sysarc.2018.05.007>
- Gašparović, M., Zrinjski, M., Barković, Đ., & Radočaj, D. (2020). An automatic method for weed mapping in oat fields based on UAV imagery. *Computers and Electronics in Agriculture*, 173, 105385. <https://doi.org/10.1016/j.compag.2020.105385>
- Gerhards, R., Andújar Sanchez, D., Hamouz, P., Peteinatos, G. G., Christensen, S., & Fernandez-Quintanilla, C. (2022). Advances in site-specific weed management in agriculture—A review. *Weed Research*, 62(2), 123-133. <https://doi.org/10.1111/wre.12526>
- Ghosh-Dastidar, S., & Adeli, H. (2009). Spiking neural networks. *International Journal of Neural Systems*, 19(4), 295-308. <https://doi.org/10.1142/S0129065709002002>
- Giampieri, F., Mazzoni, L., Cianciosi, D., Alvarez-Suarez, J. M., Regolo, L., Sánchez-González, C., Capocasa, F., Xiao, J., Mezzetti, B., & Battino, M. (2022). Organic vs conventional

- plant-based foods: A review. *Food Chemistry*, 383(383), 132352. <https://doi.org/10.1016/j.foodchem.2022.132352>
- Girshick, R. (2015, diciembre). Fast R-CNN. En *2015 IEEE International Conference on Computer Vision (ICCV)* (pp. 1440-1448). IEEE Xplore. <https://doi.org/10.1109/ICCV.2015.169>
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. En *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 580-587). IEEE Xplore. <https://doi.org/10.1109/CVPR.2014.81>
- Glaessgen, E., & Stargel, D. (2012). *The Digital Twin Paradigm for Future NASA and U.S. Air Force Vehicles*. Aerospace Research Central.
- Gold, K. M., Townsend, P. A., Herrmann, I., & Gevens, A. J. (2020). Investigating potato late blight physiological differences across potato cultivars with spectroscopy and machine learning. *Plant Science*, 295(295), 110316. <https://doi.org/10.1016/j.plantsci.2019.110316>
- Golzarian, M., Lee, M.-K., & Desbiolles, J. (2012). Evaluation of Color Indices for Improved Segmentation of Plant Images. *Transactions of the ASABE*, 55(1), 261-273. <https://doi.org/10.13031/2013.41236>
- Gómez-Casero, M. T., Castillejo-González, I. L., García-Ferrer, A., Peña-Barragán, J. M., Jurado-Expósito, M., García-Torres, L., & López-Granados, F. (2010). Spectral discrimination of wild oat and canary grass in wheat fields for less herbicide application. *Agronomy for Sustainable Development*, 30(3), 689-699. <https://doi.org/10.1051/agro/2009052>
- Gonzalez-de-Santos, P., Ribeiro, A., Fernandez-Quintanilla, C., Lopez-Granados, F., Brandstoetter, M., Tomic, S., Pedrazzi, S., Peruzzi, A., Pajares, G., Kaplanis, G., Perez-Ruiz, M., Valero, C., del Cerro, J., Vieri, M., Rabatel, G., & Debilde, B. (2017). Fleets of robots for environmentally-safe pest control in agriculture. *Precision Agriculture*, 18(4), 574-614. <https://doi.org/10.1007/s11119-016-9476-3>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative Adversarial Nets. En Z. Ghahramani, M. Welling, C. Cortes, N. Lawrence & K. Weinberger (Eds.), *Advances in Neural Information Processing Systems* (Vol. 27). Curran Associates, Inc.
- Grimstad, L., & From, P. J. (2017). The Thorvald II Agricultural Robotic System. *Robotics*, 6(4). <https://doi.org/10.3390/robotics6040024>
- Gu, F., Niu, J., Jiang, L., Liu, X., & Atiquzzaman, M. (2020). Survey of the low power wide area network technologies. *Journal of Network and Computer Applications*, 149(149), 102459. <https://doi.org/10.1016/j.jnca.2019.102459>
- Guansong, P., Chunhua, S., Longbing, C., & Anton, V. D. H. (2022). Deep Learning for Anomaly Detection: A Review. *ACM Computing Surveys*, 54(2), 1-38. <https://doi.org/10.1145/3439950>
- Gutierrez, A., Ansuategi, A., Susperregi, L., Tubío, C., Rankić, I., & Lenža, L. (2019). A Benchmarking of Learning Strategies for Pest Detection and Identification on Tomato Plants for Autonomous Scouting Robots Using Internal Databases. *Journal of Sensors*, 2019(e5219471), 15. <https://doi.org/10.1155/2019/5219471>
- Hasan, A. S. M. M., Soheli, F., Diepeveen, D., Laga, H., & Jones, M. G. (2021). A survey of deep learning techniques for weed detection from images. *Computers and Electronics in Agriculture*, 184, 106067. <https://doi.org/10.1016/j.compag.2021.106067>

- Hashimoto, N., Ozawa, S., Ban, T., Nakazato, J., & Shimamura, J. (2018). A Darknet Traffic Analysis for “IoT” Malwares Using Association Rule Learning. *Procedia Computer Science*, 144(144), 118-123. <https://doi.org/10.1016/j.procs.2018.10.511>
- He, K., Gkioxari, G., Dollar, P., & Girshick, R. (2017). Mask R-CNN. En *2017 IEEE International Conference on Computer Vision (ICCV)* (pp. 2980-2988). IEEE Xplore. <https://doi.org/10.1109/ICCV.2017.322>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778. <https://doi.org/10.1109/CVPR.2016.90>
- Hoegh-Guldberg, O., Jacob, D., Taylor, M., Bolaños, T. G., Bindi, M., Brown, S., Camilloni, I. A., Diedhiou, A., Djalante, R., Ebi, K., Engelbrecht, F., Guiot, J., Hijioka, Y., Mehrotra, S., Hope, C. W., Payne, A. J., Pörtner, H.-O., Seneviratne, S. I., Thomas, A., . . . Zhou, G. (2019). The human imperative of stabilizing global climate change at 1.5°C. *Science*, 365(6459), eaaw6974. <https://doi.org/10.1126/science.aaw6974>
- Hong, S.-J., Kim, S.-Y., Kim, E., Lee, C.-H. L. J.-S., Lee, D.-S., Bang, J., & Kim, G. (2020). Moth Detection from Pheromone Trap Images Using Deep Learning Object Detectors. *Agriculture*, 10(5), 170. <https://doi.org/10.3390/agriculture10050170>
- Hooftman, D. A., Bullock, J. M., Jones, L., Eigenbrod, F., Barredo, J. I., Forrest, M., Kindermann, G., Thomas, A., & Willcock, S. (2022). Reducing uncertainty in ecosystem service modelling through weighted ensembles. *Ecosystem Services*, 53(53), 101398. <https://doi.org/10.1016/j.ecoser.2021.101398>
- Horvath, D. P., Clay, S. A., Swanton, C. J., Anderson, J. V., & Chao, W. S. (2023). Weed-induced crop yield loss: a new paradigm and new challenges. *Trends in Plant Science*, 28(5), 567-582. <https://doi.org/10.1016/j.tplants.2022.12.014>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *arXiv preprint arXiv:1704.04861*, abs/1704.04861. <https://doi.org/10.48550/ARXIV.1704.04861>
- Huang, G., Liu, Z., van der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. En *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 2261-2269). <https://doi.org/10.1109/CVPR.2017.243>
- Huang, H., Deng, J., Lan, Y., Yang, A., Deng, X., Wen, S., Zhang, H., & Zhang, Y. (2018a). Accurate Weed Mapping and Prescription Map Generation Based on Fully Convolutional Networks Using UAV Imagery. *Sensors*, 18(10). <https://doi.org/10.3390/s18103299>
- Huang, H., Deng, J., Lan, Y., Yang, A., Deng, X., Zhang, L., Wen, S., Jiang, Y., Suo, G., & Chen, P. (2018b). A two-stage classification approach for the detection of spider mite- infested cotton using UAV multispectral imagery. *Remote Sensing Letters*, 9(10), 933-941. <https://doi.org/10.1080/2150704X.2018.1498600>
- Huang, H., Lan, Y., Yang, A., Zhang, Y., Wen, S., & Deng, J. (2020). Deep learning versus Object-based Image Analysis (OBIA) in weed mapping of UAV imagery. *Int. J. Remote Sens.*, 41(9), 3446-3479. <https://doi.org/10.1080/01431161.2019.1706112>
- Huang, Y., Lan, Y., Thomson, S. J., Fang, A., Hoffmann, W. C., & Lacey, R. E. (2010). Development of soft computing and applications in agricultural and biological engineering. *Computers and Electronics in Agriculture*, 71(2), 107-127. <https://doi.org/10.1016/j.compag.2010.01.001>

- Huang, Y., Zhao, X., Pan, Z., Reddy, K. N., & Zhang, J. (2022). Hyperspectral plant sensing for differentiating glyphosate-resistant and glyphosate-susceptible johnsongrass through machine learning algorithms. *Pest Management Science*, 78(6), 2370-2377. <https://doi.org/10.1002/ps.6864>
- Hussain, N., Farooque, A. A., Schumann, A. W., Abbas, F., Acharya, B., McKenzie-Gopsill, A., Barrett, R., Afzaal, H., Zaman, Q. U., & Cheema, M. J. M. (2021). Application of deep learning to detect Lamb's quarters (*Chenopodium album* L.) in potato fields of Atlantic Canada. *Computers and Electronics in Agriculture*, 182(182), 106040. <https://doi.org/10.1016/j.compag.2021.106040>
- Ibrahim, A., & Gebali, F. (2022). Compact hardware accelerator for field multipliers suitable for use in ultra-low power IoT edge devices. *Alexandria Engineering Journal*, 61(12), 13079-13087. <https://doi.org/10.1016/j.aej.2022.07.013>
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. En F. Bach & D. Blei (Eds.), *Proceedings of the 32nd International Conference on Machine Learning* (pp. 448-456, Vol. 37). PMLR.
- IPPC Secretariat. (2021). *Scientific review of the impact of climate change on plant pests: A global challenge to prevent and mitigate plant-pest risks in agriculture, forestry and ecosystems*. FAO on behalf of the IPPC Secretariat.
- ISPA. (2021). Precision Agriculture Definition. En J. Arnó, S. Best, R. Bongiovanni, A. Escolà, E. Gil, R. Ortega, J. M. Peña, F. Scaramuzza, P. T. Kelly & C. V. Ubierna (Eds.), *Precision Agriculture Definition*. International Society of Precision Agriculture.
- Jaderberg, M., Simonyan, K., Zisserman, A., & kavukcuoglu koray, k. (2015). Spatial Transformer Networks. En C. Cortes, N. Lawrence, D. Lee, M. Sugiyama & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 28). Curran Associates, Inc.
- Jeong, H., & Shi, L. (2019). Memristor devices for neural networks. *Journal of Physics D: Applied Physics*, 52(2), 023003. <https://doi.org/10.1088/1361-6463/aae223>
- Jiménez-Brenes, F. M., López-Granados, F., Torres-Sánchez, J., Peña, J. M., Ramírez, P., Castillejo-González, I. L., & de Castro, A. I. (2019). Automatic UAV-based detection of *Cynodon dactylon* for site-specific vineyard management. *PLOS ONE*, 14(6), 1-21. <https://doi.org/10.1371/journal.pone.0218132>
- Jin, X., Jie, L., Wang, S., Qi, H. J., & Li, S. W. (2018). Classifying Wheat Hyperspectral Pixels of Healthy Heads and Fusarium Head Blight Disease Using a Deep Neural Network in the Wild Field. *Remote Sensing*, 10(3), 395. <https://doi.org/10.3390/rs10030395>
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). YOLO by Ultralytics.
- Juroszek, P., Racca, P., Link, S., Farhumand, J., & Kleinhenz, B. (2020). Overview on the review articles published during the past 30 years relating to the potential climate change effects on plant pathogens and crop disease risks. *Plant Pathology*, 69(2), 179-193. <https://doi.org/10.1111/ppa.1311>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147(147), 70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Khalifa, N. E., Loey, M., & Mirjalili, S. (2021). A comprehensive survey of recent trends in deep learning for digital images augmentation. *Artif. Intell. Rev.* <https://doi.org/10.1007/s10462-021-10066-4>

- Khan, S., Tufail, M., Khan, M. T., Khan, Z. A., Iqbal, J., & Alam, M. (2021). A novel semi-supervised framework for UAV based crop/weed classification. *PLoS One*, *16*(5), e0251008. <https://doi.org/10.1371/journal.pone.0251008>
- Khanal, S., Fulton, J., & Shearer, S. (2017). An overview of current and potential applications of thermal remote sensing in precision agriculture. *Computers and Electronics in Agriculture*, *139*(139), 22-32. <https://doi.org/10.1016/j.compag.2017.05.001>
- Khanji, S., Iqbal, F., & Hung, P. (2019). ZigBee Security Vulnerabilities: Exploration and Evaluating. En *2019 10th International Conference on Information and Communication Systems (ICICS)* (pp. 52-57). IEEE. <https://doi.org/10.1109/IACS.2019.8809115>
- Kingma, D. P., & Ba, J. (2017). Adam: A Method for Stochastic Optimization.
- Kowsari, K., Jafari Meimandi, K., Heidarysafa, M., Mendu, S., Barnes, L., & Brown, D. (2019). Text Classification Algorithms: A Survey. *Information*, *10*(4), 150. <https://doi.org/10.3390/info10040150>
- Krestenitis, M., Raptis, E. K., Kapoutsis, A. C., Ioannidis, K., Kosmatopoulos, E. B., Vrochidis, S., & Kompatsiaris, I. (2022). CoFly-WeedDB: A UAV image dataset for weed detection and species identification. *Data Brief.*, *45*, 108575. <https://doi.org/10.1016/j.dib.2022.108575>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet Classification with Deep Convolutional Neural Networks. *Commun. ACM*, *60*(6), 84-90. <https://doi.org/10.1145/3065386>
- Kudsk, P., & Streibig, J. C. (2003). Herbicides – a two-edged sword. *Weed Research*, *43*(2), 90-102. <https://doi.org/10.1046/j.1365-3180.2003.00328.x>
- Lam, O. H. Y., Dogotari, M., Prüm, M., Vithlani, H. N., Roers, C., Melville, B., Zimmer, F., & Becker, R. (2021). An open source workflow for weed mapping in native grassland using unmanned aerial vehicle: using Rumex obtusifolius as a case study. *European Journal of Remote Sensing*, *54*(sup1), 71-88. <https://doi.org/10.1080/22797254.2020.1793687>
- Lassalle, G. (2021). Monitoring natural and anthropogenic plant stressors by hyperspectral remote sensing: Recommendations and guidelines based on a meta-review. *Science of The Total Environment*, *788*(788), 147758. <https://doi.org/10.1016/j.scitotenv.2021.147758>
- Lati, R. N., Rasmussen, J., Andujar, D., Dorado, J., Berge, T. W., Wellhausen, C., Pflanz, M., Nordmeyer, H., Schirrmann, M., Eizenberg, H., Neve, P., Jørgensen, R. N., & Christensen, S. (2021). Site-specific weed management—constraints and opportunities for the weed research community: Insights from a workshop. *Weed Res.*, *61*(3), 147-153. <https://doi.org/10.1111/wre.12469>
- Lauwers, M., De Cauwer, B., Nuyttens, D., Cool, S. R., & Pieters, J. G. (2020). Hyperspectral Classification of *Cyperus esculentus* Clones and Morphologically Similar Weeds. *Sensors*, *20*(9), 2504. <https://doi.org/10.3390/s20092504>
- Lavric, A. (2019). LoRa (Long-Range) High-Density Sensors for Internet of Things. *Journal of Sensors*, *2019*(3502987), 9. <https://doi.org/10.1155/2019/3502987>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436-444. <https://doi.org/10.1038/nature14539>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, *86*(11), 2278-2324. <https://doi.org/10.1109/5.726791>
- Li, Y., Guo, Z., Shuang, F., Zhang, M., & Li, X. (2022). Key technologies of machine vision for weeding robots: A review and benchmark. *Computers and Electronics in Agriculture*, *196*(196), 106880. <https://doi.org/10.1016/j.compag.2022.106880>

- Liakos, K. G., patrizia Busato, Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors*, 18(8), 2674. <https://doi.org/10.3390/s18082674>
- Lin, T., Wang, Y., Liu, X., & Qiu, X. (2022). A survey of transformers. *AI Open*, 3, 111-132. <https://doi.org/10.1016/j.aiopen.2022.10.001>
- Lin, T.-Y., Dollar, P., Girshick, R., He, K., Hariharan, B., & Belongie, S. (2017a). Feature Pyramid Networks for Object Detection. En *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 936-944). IEEE Xplore. <https://doi.org/10.1109/CVPR.2017.106>
- Lin, T.-Y., Goyal, P., Girshick, R., He, K., & Dollar, P. (2017b). Focal Loss for Dense Object Detection. En *Proceedings of the IEEE International Conference on Computer Vision (ICCV)* (pp. 2999-3007). IEEE Xplore. <https://doi.org/10.1109/ICCV.2017.324>
- Liu, D., Zhao, J., Wu, J., Yang, G., & Lv, F. (2022). Multi-category classification with label noise by robust binary loss. *Neurocomputing*, 482, 14-26. <https://doi.org/10.1016/j.neucom.2022.01.031>
- Liu, L., Wang, R., Xie, C., Yang, P., Wang, F., Sudirman, S., & Liu, W. (2019). PestNet: An End-to-End Deep Learning Approach for Large-Scale Multi-Class Pest Detection and Classification. *IEEE Access*, 7, 45301-45312. <https://doi.org/10.1109/ACCESS.2019.2909522>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016). SSD: Single Shot MultiBox Detector. En B. Leibe, J. Matas, N. Sebe & M. Welling (Eds.), *Computer Vision – ECCV 2016* (pp. 21-37). Springer International Publishing. [https://doi.org/10.1007/978-3-319-46448-0\\_2](https://doi.org/10.1007/978-3-319-46448-0_2)
- Liu, Y., Zhang, Y., Wang, Y., Hou, F., Yuan, J., Tian, J., Zhang, Y., Shi, Z., Fan, J., & He, Z. (2023). A Survey of Visual Transformers. *IEEE Transactions on Neural Networks and Learning Systems*, 35, 1-21. <https://doi.org/10.1109/TNNLS.2022.3227717>
- Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., & Guo, B. (2021). Swin Transformer: Hierarchical Vision Transformer using Shifted Windows. *2021 IEEE/CVF International Conference on Computer Vision (ICCV)*, 9992-10002. <https://doi.org/10.1109/ICCV48922.2021.00986>
- Lonij, V., & Fiot, J.-B. (2016). Chapter 8 - Cognitive Systems for the Food–Water–Energy Nexus. En V. N. Gudivada, V. V. Raghavan, V. Govindaraju & C. Rao (Eds.), *Cognitive Computing: Theory and Applications* (pp. 255-282, Vol. 35). Elsevier. <https://doi.org/10.1016/bs.host.2016.07.003>
- López-Correa, J. M., Moreno, H., Ribeiro, A., & Andújar, D. (2022). Intelligent Weed Management Based on Object Detection Neural Networks in Tomato Crops. *Agronomy*, 12(12), 2953. <https://doi.org/10.3390/agronomy12122953>
- López-Granados, F., Torres-Sánchez, J., de Castro, A.-I., Serrano-Pérez, A., Mesas-Carrascosa, F.-J., & Peña, J.-M. (2016a). Object-based early monitoring of a grass weed in a grass crop using high resolution UAV imagery. *Agronomy for Sustainable Development*, 36(4), 67. <https://doi.org/10.1007/s13593-016-0405-7>
- López-Granados, F., Torres-Sánchez, J., Serrano-Pérez, A., de Castro, A. I., Mesas-Carrascosa, F.-J., & Peña, J.-M. (2016b). Early season weed mapping in sunflower using UAV technology: variability of herbicide treatment maps against weed thresholds. *Precision Agriculture*, 17(2), 183-199. <https://doi.org/10.1007/s11119-015-9415-8>
- Loshchilov, I., & Hutter, F. (2019). Decoupled Weight Decay Regularization.

- Lottes, P., Behley, J., Chebrolu, N., Milioto, A., & Stachniss, C. (2020). Robust joint stem detection and crop-weed classification using image sequences for plant-specific treatment in precision farming. *Journal of Field Robotics*, 37(1), 20-34. <https://doi.org/10.1002/rob.21901>
- Lowenberg-DeBoer, J., Franklin, K., Behrendt, K., & Godwin, R. (2021). Economics of autonomous equipment for arable farms. *Precision Agriculture*, 22(6), 1992-2006. <https://doi.org/10.1007/s11119-021-09822-x>
- Lowenberg-DeBoer, J., Huang, I. Y., Grigoriadis, V., & Blackmore, S. (2020). Economics of robots and automation in field crop production. *Precision Agriculture*, 21(2), 278-299. <https://doi.org/10.1007/s11119-019-09667-5>
- Lu, J., Ehsani, R., Shi, Y., Abdulridha, J., de Castro, A. I., & Xu, Y. (2017). Field detection of anthracnose crown rot in strawberry using spectroscopy technology. *Computers and Electronics in Agriculture*, 135, 289-299. <https://doi.org/10.1016/j.compag.2017.01.017>
- Lu, J., Ehsani, R., Shi, Y., de Ana Isabel Castro & Wang, S. (2018). Detection of multi-tomato leaf diseases (late blight, target and bacterial spots) in different stages by using a spectral-based sensor. *Scientific Reports*, 8(1), 2793. <https://doi.org/10.1038/s41598-018-21191-6>
- Lytras, M. D., & Visvizi, A. (2021). Artificial Intelligence and Cognitive Computing: Methods, Technologies, Systems, Applications and Policy Making. *Sustainability*, 13(7). <https://doi.org/10.3390/su13073598>
- Lytridis, C., Kaburlasos, V. G., Pachidis, T., Manios, M., Vrochidou, E., Kalampokas, T., & Chatzistamatis, S. (2021). An Overview of Cooperative Robotics in Agriculture. *Agronomy*, 11(9), 1818. <https://doi.org/10.3390/agronomy11091818>
- Machleb, J., Peteinatos, G. G., Kollenda, B. L., Andújar, D., & Gerhards, R. (2020). Sensor-based mechanical weed control: Present state and prospects. *Computers and Electronics in Agriculture*, 176(176), 105638. <https://doi.org/10.1016/j.compag.2020.105638>
- Maes, W. H., & Steppe, K. (2019). Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. *Trends in Plant Science*, 24(2), 152-164. <https://doi.org/10.1016/j.tplants.2018.11.007>
- Mahmoud, M. S., & Xia, Y. (2019). *Networked Control Systems: Cloud Control and Secure Control*. Butterworth-Heinemann.
- Maniah, Abdurachman, E., Gaol, F. L., & Soewito, B. (2019). Survey on Threats and Risks in the Cloud Computing Environment. *Procedia Computer Science*, 161(161), 1325-1332. <https://doi.org/10.1016/j.procs.2019.11.248>
- McCarthy, J., et al. (2007). What is artificial intelligence.
- McCool, C., Beattie, J., Firn, J., Lehnert, C., Kulk, J., Bawden, O., Russell, R., & Perez, T. (2018). Efficacy of Mechanical Weeding Tools: A Study Into Alternative Weed Management Strategies Enabled by Robotics. *IEEE Robotics and Automation Letters*, 3(2), 1184-1190. <https://doi.org/10.1109/LRA.2018.2794619>
- Meier, U. (2018). Growth stages of mono- and dicotyledonous plants: BBCH Monograph. <https://doi.org/10.5073/20180906-074619>
- Mesías-Ruiz, G., Borra-Serrano, I., Peña, J., de Castro, A., Fernández-Quintanilla, C., & Dorado, J. (2024a). Weed species classification with UAV imagery and standard CNN models: Assessing the frontiers of training and inference phases. *Crop Protection*, 182, 106721. <https://doi.org/10.1016/j.cropro.2024.106721>
- Mesías-Ruiz, G. A., Borra-Serrano, I., Peña, J., de Castro, A. I., Fernández-Quintanilla, C., & Dorado, J. (2024b). Unmanned Aerial Vehicle Imagery for Early Stage Weed Classification

- and Detection in Maize and Tomato Crops. *DIGITAL.CSIC*. <https://doi.org/10.20350/digitalCSIC/16131>
- Mesías-Ruiz, G. A., Peña, J. M., de Castro, A. I., Borra-Serrano, I., & Dorado, J. (2024c). Cognitive Computing Advancements: Improving Precision Crop Protection through UAV Imagery for Targeted Weed Monitoring. *Remote Sensing*, *16*(16). <https://doi.org/10.3390/rs16163026>
- Mesías-Ruiz, G. A., Pérez-Ortiz, M., Dorado, J., de Castro, A. I., & Peña, J. M. (2023). Boosting precision crop protection towards agriculture 5.0 via machine learning and emerging technologies: A contextual review. *Frontiers in Plant Science*, *14*. <https://doi.org/10.3389/fpls.2023.1143326>
- Meyer, G. E., & Neto, J. C. (2008). Verification of color vegetation indices for automated crop imaging applications. *Computers and Electronics in Agriculture*, *63*(2), 282-293. <https://doi.org/10.1016/j.compag.2008.03.009>
- Mirza, M., & Osindero, S. (2014). Conditional Generative Adversarial Nets. <https://doi.org/10.48550/arXiv.1411.1784>
- Mishra, S., Sachan, R., & Rajpal, D. (2020). Deep Convolutional Neural Network based Detection System for Real-time Corn Plant Disease Recognition. *Procedia Computer Science*, *167*, 2003-2010. <https://doi.org/10.1016/j.procs.2020.03.236>
- Mohd, A. H. (2022). CNN Based Automated Weed Detection System Using UAV Imagery. *Computer Systems Science and Engineering*, *42*(2), 837-849. <https://doi.org/10.32604/csse.2022.023016>
- Montull, J., Soenderskov, M., Rydahl, P., Boejer, O., & Taberner, A. (2014). Four years validation of decision support optimising herbicide dose in cereals under Spanish conditions. *Crop Protection*, *64*, 110-114. <https://doi.org/10.1016/j.cropro.2014.06.012>
- Mourhir, A., Papageorgiou, E. I., Kokkinos, K., & Rachidi, T. (2017). Exploring Precision Farming Scenarios Using Fuzzy Cognitive Maps. *Sustainability*, *9*(7). <https://doi.org/10.3390/su9071241>
- Muhammad, A., Mohammad, A.-U., Zubair, S., Ali, M., & M., A. E.-H. (2019). Internet-of-Things (IoT)-based smart agriculture: Toward making the fields talk. *IEEE Access*, *7*, 129551-129583. <https://doi.org/10.1109/ACCESS.2019.2932609>
- Mulla, S., Singh, S. K., Singh, K. K., & Praveen, B. (2020). Climate Change and Agriculture: A Review of Crop Models. En V. Venkatramanan, S. Shah & R. Prasad (Eds.), *Global Climate Change and Environmental Policy: Agriculture Perspectives* (pp. 423-435). Springer Singapore. [https://doi.org/10.1007/978-981-13-9570-3\\_15](https://doi.org/10.1007/978-981-13-9570-3_15)
- Mumuni, A., & Mumuni, F. (2022). Data augmentation: A comprehensive survey of modern approaches. *Array*, *16*, 100258. <https://doi.org/10.1016/j.array.2022.100258>
- Munteanu, S., Sudacevschi, V., Ababii, V., Branishte, R., Turcan, A., & Leashcenco, V. (2021). Cognitive Distributed Computing System for Intelligent Agriculture. *24*, 334-342.
- Muppala, C., & Guruviah, V. (2020). Machine vision detection of pests, diseases, and weeds: A review. *Journal of Phytology*, *12*, 9-19. <https://doi.org/10.25081/jp.2020.v12.6145>
- Murtagh, F., & Contreras, P. (2012). Algorithms for hierarchical clustering: An overview. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, *2*(1), 86-97. <https://doi.org/10.1002/widm.53>
- Nanda, S. J., & Panda, G. (2014). A survey on nature inspired metaheuristic algorithms for partitional clustering. *Swarm and Evolutionary Computation*, *16*(16), 1-18. <https://doi.org/10.1016/j.swevo.2013.11.003>

- Norris, R. F. (1999). Ecological implications of using thresholds for weed management. En *Expanding the context of weed management* (pp. 31-58). CRC Press.
- Nugent, P. W., Shaw, J. A., Jha, P., Scherrer, B., Donelick, A., & Kumar, V. (2018). Discrimination of herbicide-resistant kochia with hyperspectral imaging. *Journal of Applied Remote Sensing*, *12*(1), 016037. <https://doi.org/10.1117/1.JRS.12.016037>
- Oberti, R., & Schmilovitch, Z. (2021). Robotic Spraying for Precision Crop Protection. En A. Bechar (Ed.), *Innovation in Agricultural Robotics for Precision Agriculture: A Roadmap for Integrating Robots in Precision Agriculture* (pp. 117-150). Springer International Publishing. [https://doi.org/10.1007/978-3-030-77036-5\\_6](https://doi.org/10.1007/978-3-030-77036-5_6)
- Oerke, E.-C. (2006). Crop losses to pests. *The Journal of Agricultural Science*, *144*(1), 31-43. <https://doi.org/10.1017/S0021859605005708>
- Oerke, E.-C., & Dehne, H.-W. (2004). Safeguarding production—losses in major crops and the role of crop protection. *Crop Protection*, *23*(4), 275-285. <https://doi.org/10.1016/j.cropro.2003.10.001>
- Oerke, E.-C., Dehne, H.-W., Schönbeck, F., & Weber, A. (2012). *Crop Production and Crop Protection: Estimated Losses in Major Food and Cash Crops*. Elsevier.
- Olaniyi, E., Chen, D., Lu, Y., & Huang, Y. (2022). Generative Adversarial Networks for Image Augmentation in Agriculture: A Systematic Review. *arXiv preprint arXiv:2204.04707*. <https://doi.org/10.48550/arXiv.2204.04707>
- Olsen, A., Konovalov, D. A., Philippa, B., Ridd, P., Wood, J. C., Johns, J., Banks, W., Girgenti, B., Kenny, O., Whinney, J., Calvert, B., Azghadi, M. R., & White, R. D. (2019). DeepWeeds: A Multiclass Weed Species Image Dataset for Deep Learning. *Sci. Rep.*, *9*(1), 2058. <https://doi.org/10.1038/s41598-018-38343-3>
- Oñate, W., & Sanz, R. (2023). Analysis of architectures implemented for IIoT. *Heliyon*, *9*(1), e12868. <https://doi.org/10.1016/j.heliyon.2023.e12868>
- Ouyang-Zhang, J., Cho, J. H., Zhou, X., & Krähenbühl, P. (2022). NMS Strikes Back. <https://doi.org/10.48550/arXiv.2212.06137>
- Pan, S. J., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Trans. Knowl. Data Eng.*, *22*(10), 1345-1359. <https://doi.org/10.1109/TKDE.2009.191>
- Panduangnat, L., Posom, J., Saikaew, K., Phuphaphud, A., Wongpichet, S., Chinapas, A., Sukpancharoen, S., & Saengprachatanarug, K. (2024). Time-efficient low-resolution RGB aerial imaging for precision mapping of weed types in site-specific herbicide application. *Crop Protection*, *184*, 106805. <https://doi.org/10.1016/j.cropro.2024.106805>
- Patterson, J., & Gibson, A. (2017). *Deep learning a practitioner's approach* (1. ed). O'Reilly Media.
- Pätzold, S., Hbirkou, C., Dicke, D., Gerhards, R., & Welp, G. (2020). Linking weed patterns with soil properties: a long-term case study. *Precision Agriculture*, *21*(3), 569-588. <https://doi.org/10.1007/s11119-019-09682-6>
- Pauline, M., Adrien, M., Clélie, A., Nicolas, P., Guy-Junior, R., Olivier, R., & Serena, I. (2019). Human Movement and Ergonomics: an Industry-Oriented Dataset for Collaborative Robotics. *The International Journal of Robotics Research*, *38*(14), 1529-1537. <https://doi.org/10.1177/0278364919882089>
- Peña, J. M., Torres-Sánchez, J., Serrano-Pérez, A., de Castro, A. I., & López-Granados, F. (2015). Quantifying Efficacy and Limits of Unmanned Aerial Vehicle (UAV) Technology for Weed Seedling Detection as Affected by Sensor Resolution. *Sensors*, *15*(3), 5609-5626. <https://doi.org/10.3390/s150305609>

- Peña, J. M., Torres-Sánchez, J., de Castro, A. I., Kelly, M., & López-Granados, F. (2013). Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. *PLOS ONE*, 8(10), null. <https://doi.org/10.1371/journal.pone.0077151>
- Peña-Barragán, J. M., López-Granados, F., Jurado-Expósito, M., & García-Torres, L. (2006). Spectral discrimination of *Ridolfia segetum* and sunflower as affected by phenological stage. *Weed Research*, 46(1), 10-21. <https://doi.org/10.1111/j.1365-3180.2006.00488.x>
- Pérez-Ortiz, M., Peña, J. M., Gutiérrez, P. A., Torres-Sánchez, J., Hervás-Martínez, C., & López-Granados, F. (2015). A semi-supervised system for weed mapping in sunflower crops using unmanned aerial vehicles and a crop row detection method. *Applied Soft Computing*, 37(37), 533-544. <https://doi.org/10.1016/j.asoc.2015.08.027>
- Pérez-Ortiz, M., Peña, J. M., Gutiérrez, P. A., Torres-Sánchez, J., Hervás-Martínez, C., & López-Granados, F. (2016). Selecting patterns and features for between- and within- crop-row weed mapping using UAV-imagery. *Expert Systems with Applications*, 47(47), 85-94. <https://doi.org/10.1016/j.eswa.2015.10.043>
- Pérez-Ruiz, M., Gonzalez-de-Santos, P., Ribeiro, A., Fernandez-Quintanilla, C., Peruzzi, A., Vieri, M., Tomic, S., & Agüera, J. (2015). Highlights and preliminary results for autonomous crop protection. *Computers and Electronics in Agriculture*, 110(110), 150-161. <https://doi.org/10.1016/j.compag.2014.11.010>
- Pérez-Ruiz, M., Slaughter, D. C., Fathallah, F. A., Gliever, C. J., & Miller, B. J. (2014). Co-robotic intra-row weed control system. *Biosystems Engineering*, 126(126), 45-55. <https://doi.org/10.1016/j.biosystemseng.2014.07.009>
- Petrich, L., Lohrmann, G., Neumann, M., Martin, F., Frey, A., Stoll, A., & Schmidt, V. (2020). Detection of *Colchicum autumnale* in drone images, using a machine-learning approach. *Precision Agriculture*, 21(6), 1291-1303. <https://doi.org/10.1007/s11119-020-09721-7>
- Piao, S., Liu, Q., Chen, A., Janssens, I. A., Fu, Y., Dai, J., Liu, L., Lian, X., Shen, M., & Zhu, X. (2019). Plant phenology and global climate change: Current progresses and challenges. *Global Change Biology*, 25(6), 1922-1940. <https://doi.org/10.1111/gcb.14619>
- Picon, A., Alvarez-Gila, A., Seitz, M., Ortiz-Barredo, A., Echazarra, J., & Johannes, A. (2019). Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild. *Computers and Electronics in Agriculture*, 161(161), 280-290. <https://doi.org/10.1016/j.compag.2018.04.002>
- Polder, G., Blok, P. M., de Villiers, H. A. C., van der Wolf, J. M., & Kamp, J. (2019). Potato Virus Y Detection in Seed Potatoes Using Deep Learning on Hyperspectral Images. *Frontiers in Plant Science*, 10. <https://doi.org/10.3389/fpls.2019.00209>
- Poniszewska-Maranda, A., Matusiak, R., Kryvinska, N., & Yasar, A.-U.-H. (2020). A real-time service system in the cloud. *Journal of Ambient Intelligence and Humanized Computing*, 11(3), 961-977. <https://doi.org/10.1007/s12652-019-01203-7>
- Preto, A., Aravecchia, S., Burgard, W., Chebrolu, N., Dornhege, C., Falck, T., Fleckenstein, F., Fontenla, A., Imperoli, M., Khanna, R., Liebisch, F., Lottes, P., Milioto, A., Nardi, D., Nardi, S., Pfeifer, J., Popović, M., Potena, C., Pradalier, C., ... Nieto, J. (2019). Building an Aerial-Ground Robotics System for Precision Farming: An Adaptable Solution. *IEEE Robotics & Automation Magazine*, 28(3), 29-49. <https://doi.org/10.1109/mra.2020.3012492>
- Qiu, J., Wang, J., Yao, S., Guo, K., Li, B., Zhou, E., Yu, J., Tang, T., Xu, N., Song, S., Wang, Y., & Yang, H. (2016). Going Deeper with Embedded FPGA Platform for Convolutional

- Neural Network. *Proceedings of the 2016 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays*, 26-35. <https://doi.org/10.1145/2847263.2847265>
- Radicetti, E., & Mancinelli, R. (2021). Sustainable Weed Control in the Agro-Ecosystems. *Sustainability*, 13(15). <https://doi.org/10.3390/su13158639>
- Rai, N., Zhang, Y., Ram, B. G., Schumacher, L., Yellavajjala, R. K., Bajwa, S., & Sun, X. (2023). Applications of deep learning in precision weed management: A review. *Computers and Electronics in Agriculture*, 206, 107698. <https://doi.org/10.1016/j.compag.2023.107698>
- Rakhmatulin, I., Kamilaris, A., & Andreassen, C. (2021). Deep Neural Networks to Detect Weeds from Crops in Agricultural Environments in Real-Time: A Review. *Remote Sensing*, 13(21), 4486. <https://doi.org/10.3390/rs13214486>
- Ramcharan, A., McCloskey, P., Baranowski, K., Mbilyini, N., Mrisho, L., Ndalaha, M., Legg, J., & Hughes, D. P. (2019). A mobile-based deep learning model for cassava disease diagnosis. *Frontiers in Plant Science*, 10. <https://doi.org/10.3389/fpls.2019.00272>
- Ramos, A. P. M., Gomes, F. D. G., Pinheiro, M. M. F., Furuya, D. E. G., Gonçalves, W. N., Junior, J. M., Michereff, M. F. F., Blassioli-Moraes, M. C., Borges, M., Alaumann, R. A., Liesenberg, V., de Castro Jorge, L. A., & Osco, L. P. (2022). Detecting the attack of the fall armyworm (*Spodoptera frugiperda*) in cotton plants with machine learning and spectral measurements. *Precision Agriculture*, 23(2), 470-491. <https://doi.org/10.1007/s11119-021-09845-4>
- Reddy, K. N., Huang, Y., Lee, M. A., Nandula, V. K., Fletcher, R. S., Thomson, S. J., & Zhao, F. (2014). Glyphosate-resistant and glyphosate-susceptible Palmer amaranth (*Amaranthus palmeri* S. Wats.): hyperspectral reflectance properties of plants and potential for classification. *Pest Management Science*, 70(12), 1910-1917. <https://doi.org/10.1002/ps.3755>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- Reedha, R., Dericquebourg, E., Canals, R., & Hafiane, A. (2022). Transformer Neural Network for Weed and Crop Classification of High Resolution UAV Images. *Remote Sensing*, 14(3). <https://doi.org/10.3390/rs14030592>
- Rejeb, A., Abdollahi, A., Rejeb, K., & Treiblmaier, H. (2022). Drones in agriculture: A review and bibliometric analysis. *Computers and Electronics in Agriculture*, 198, 107017. <https://doi.org/10.1016/j.compag.2022.107017>
- Remya, R., Sumithra, M., & Krishnamoorthi, M. (2023). Foundation of Cognitive Computing. En M. Sumithra, R. K. Dhanaraj, C. Iwendi & A. M. Manoharan (Eds.), *Technological Advancements and Applications* (pp. 19-34). De Gruyter. <https://doi.org/10.1515/9783110750584-002>
- Ren, G., Lin, T., Ying, Y., Chowdhary, G., & Ting, K. C. (2020). Agricultural robotics research applicable to poultry production: A review. *Computers and Electronics in Agriculture*, 169(169), 105216. <https://doi.org/10.1016/j.compag.2020.105216>
- Ren, S., He, K., Girshick, R., & Sun, J. (2016a). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Ren, Y., Zhang, L., & Suganthan, P. (2016b). Ensemble Classification and Regression-Recent Developments, Applications and Future Directions [Review Article]. *IEEE Computational Intelligence Magazine*, 11(1), 41-53. <https://doi.org/10.1109/MCI.2015.2471235>

- Rich, E. (1985). Artificial Intelligence and the Humanities. *Computers and the Humanities*, 19(2), 117-122.
- Ridnik, T., Ben-Baruch, E., Noy, A., & Zelnik-Manor, L. (2021). Imagenet-21k pretraining for the masses. *arXiv preprint arXiv:2104.10972*. <https://doi.org/10.48550/arXiv.2104.10972>
- Roslim, M. H. M., Juraimi, A. S., Che'Ya, N. N., Sulaiman, N., Manaf, M. N. H. A., Ramli, Z., & Motmainna, M. (2021). Using Remote Sensing and an Unmanned Aerial System for Weed Management in Agricultural Crops: A Review. *Agronomy*, 11(9), 1809. <https://doi.org/10.3390/agronomy11091809>
- Sa, I., Popović, M., Khanna, R., Chen, Z., Lottes, P., Liebisch, F., Nieto, J., Stachniss, C., Walter, A., & Siegwart, R. (2018). WeedMap: A Large-Scale Semantic Weed Mapping Framework Using Aerial Multispectral Imaging and Deep Neural Network for Precision Farming. *Remote Sens.*, 10(9). <https://doi.org/10.3390/rs10091423>
- Sachin, R., Sowmya, V., Govind, D., & Soman, K. P. (2018). Dependency of Various Color and Intensity Planes on CNN Based Image Classification. En S. M. Thampi, S. Krishnan, J. M. Corchado Rodriguez, S. Das, M. Wozniak & D. Al-Jumeily (Eds.), *Advances in Signal Processing and Intelligent Recognition Systems* (pp. 167-177). Springer International Publishing. [https://doi.org/10.1007/978-3-319-67934-1\\_15](https://doi.org/10.1007/978-3-319-67934-1_15)
- Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *WIREs Data Mining and Knowledge Discovery*, 8(4), e1249. <https://doi.org/10.1002/widm.1249>
- Saiz-Rubio, V., & Rovira-Más, F. (2020). From Smart Farming towards Agriculture 5.0: A Review on Crop Data Management. *Agronomy*, 10(2), 207. <https://doi.org/10.3390/agronomy10020207>
- Saleem, M. H., Potgieter, J., & Arif, K. M. (2021). Automation in Agriculture by Machine and Deep Learning Techniques: A Review of Recent Developments. *Precision Agriculture*, 22(6), 2053-2091. <https://doi.org/10.1007/s11119-021-09806-x>
- San Martín, C., Andújar, D., Barroso, J., Fernández-Quintanilla, C., & Dorado, J. (2016). Weed Decision Threshold as a Key Factor for Herbicide Reductions in Site-Specific Weed Management. *Weed Technology*, 30(4), 888-897. <https://doi.org/10.1614/WT-D-16-00039.1>
- Sancho-Adamson, M., Trillas, M. I., Bort, J., Fernandez-Gallego, J. A., & Romanyà, J. (2019). Use of RGB Vegetation Indexes in Assessing Early Effects of Verticillium Wilt of Olive in Asymptomatic Plants in High and Low Fertility Scenarios. *Remote Sensing*, 11(6). <https://doi.org/10.3390/rs11060607>
- Santos, C. F. G. D., & Papa, J. P. (2022). Avoiding Overfitting: A Survey on Regularization Methods for Convolutional Neural Networks. *ACM Comput. Surv.*, 54(10s). <https://doi.org/10.1145/3510413>
- Santos Valle, S., & Kienzle, J. (2020). *Agriculture 4.0—Agricultural robotics and automated equipment for sustainable crop production*. FAO: Food and Agriculture Organization of the United Nations.
- Sapkota, B., Singh, V., Cope, D., Valasek, J., & Bagavathiannan, M. (2020). Mapping and Estimating Weeds in Cotton Using Unmanned Aerial Systems-Borne Imagery. *AgriEngineering*, 2(2), 350-366. <https://doi.org/10.3390/agriengineering2020024>
- Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*, 2(6), 420. <https://doi.org/10.1007/s42979-021-00815-1>
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural Networks*, 61, 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>

- Selvaraj, M. G., Vergara, A., Montenegro, F., Ruiz, H. A., Safari, N., Raymaekers, D., Ocimati, W., Ntamwira, J., Tits, L., Omondi, A. B., & Blomme, G. (2020). Detection of banana plants and their major diseases through aerial images and machine learning methods: A case study in DR Congo and Republic of Benin. *ISPRS Journal of Photogrammetry and Remote Sensing*, 169(169), 110-124. <https://doi.org/10.1016/j.isprsjprs.2020.08.025>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *2017 IEEE International Conference on Computer Vision (ICCV)*, 618-626. <https://doi.org/10.1109/ICCV.2017.74>
- Sen, P. C., Hajra, M., & Ghosh, M. (2020). Supervised Classification Algorithms in Machine Learning: A Survey and Review. En J. K. Mandal & D. Bhattacharya (Eds.), *Emerging Technology in Modelling and Graphics* (pp. 99-111). Springer Singapore. [https://doi.org/10.1007/978-981-13-7403-6\\_11](https://doi.org/10.1007/978-981-13-7403-6_11)
- Shafi, U., Mumtaz, R., García-Nieto, J., Hassan, S. A., Zaidi, S. A. R., & Iqbal, N. (2019). Precision Agriculture Techniques and Practices: From Considerations to Applications. *Sensors*, 19(17). <https://doi.org/10.3390/s19173796>
- Shahi, T. B., Dahal, S., Sitaula, C., Neupane, A., & Guo, W. (2023). Deep Learning-Based Weed Detection Using UAV Images: A Comparative Study. *Drones*, 7, 624(10). <https://doi.org/10.3390/drones7100624>
- Shamshiri, R. R., Weltzien, C., Hameed, I. A., Yule, I. J., Grift, T. E., Balasundram, S. K., Pitonakova, L., Ahmad, D., & Chowdhary, G. (2018). Research and development in agricultural robotics: A perspective of digital farming. *International Journal of Agricultural and Biological Engineering*, 11(4), 1-14. <https://doi.org/10.25165/ijabe.v11i4.4278>
- Shankar, P., Johnen, A., & Liwicki, M. (2020). Data Fusion and Artificial Neural Networks for Modelling Crop Disease Severity. En *2020 "IEEE" 23rd International Conference on Information Fusion (FUSION)* (pp. 1-8). IEEE. <https://doi.org/10.23919/FUSION45008.2020.9190211>
- Sharma, A., Shukla, A., Attri, K., Kumar, M., Kumar, P., Suttee, A., Singh, G., Barnwal, R. P., & Singla, N. (2020). Global trends in pesticides: A looming threat and viable alternatives. *Ecotoxicology and Environmental Safety*, 201, 110812. <https://doi.org/10.1016/j.ecoenv.2020.110812>
- Shawahna, A., Sait, S. M., & El-Maleh, A. (2019). FPGA-Based Accelerators of Deep Learning Networks for Learning and Classification: A Review. *IEEE Access*, 7, 7823-7859. <https://doi.org/10.1109/ACCESS.2018.2890150>
- Shawky, O. A., Hagag, A., El-Dahshan, E.-S. A., & Ismail, M. A. (2020). Remote sensing image scene classification using CNN-MLP with data augmentation. *Optik*, 221, 165356. <https://doi.org/10.1016/j.ijleo.2020.165356>
- Shixin, L., Fankai, C., Zhongyuan, S., Zhiren, Z., Liming, Z., & Tang, K. (2024). Research on YOLOv8 Object Detection Algorithm in UAV Scenarios. *Research Square*. <https://doi.org/10.21203/rs.3.rs-3995816/v1>
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv preprint arXiv:1409.1556*. <https://doi.org/10.48550/ARXIV.1409.1556>
- Singh, V., & Prasad, S. (2023). Speech emotion recognition system using gender dependent convolution neural network [International Conference on Machine Learning and Data Engineering]. *Procedia Computer Science*, 218, 2533-2540. <https://doi.org/10.1016/j.procs.2023.01.227>

- Søgaard, H., & Lund, I. (2007). Application Accuracy of a Machine Vision-controlled Robotic Micro-dosing System. *Biosystems Engineering*, 96(3), 315-322. <https://doi.org/10.1016/j.biosystemseng.2006.11.009>
- Sohn, S.-I., Oh, Y.-J., Pandian, S., Lee, Y.-H., Zaukuu, J.-L. Z., Kang, H.-J., Ryu, T.-H., Cho, W.-S., Cho, Y.-S., & Shin, E.-K. (2021). Identification of *Amaranthus* Species Using Visible-Near-Infrared (Vis-NIR) Spectroscopy and Machine Learning Methods. *Remote Sensing*, 13(20), 4149. <https://doi.org/10.3390/rs13204149>
- Sony. (2020). *First Intelligent Vision Sensors with AI Processing Functionality*. IMX500.
- Sparrow, R., & Howard, M. (2021). Robots in agriculture: prospects, impacts, ethics, and policy. *Precision Agriculture*, 22(3), 818-833. <https://doi.org/10.1007/s11119-020-09757-9>
- Sreedevi, A., Nitya Harshitha, T., Sugumaran, V., & Shankar, P. (2022). Application of cognitive computing in healthcare, cybersecurity, big data and IoT: A literature review. *Information Processing & Management*, 59(2), 102888. <https://doi.org/10.1016/j.ipm.2022.102888>
- Strukov, D. B., Snider, G. S., Stewart, D. R., & Williams, R. S. (2008). The missing memristor found. *Nature*, 453(7191), 80-83. <https://doi.org/10.1038/nature06932>
- Su, J., Yi, D., Coombes, M., Liu, C., Zhai, X., McDonald-Maier, K., & Chen, W.-H. (2022). Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery. *Computers and Electronics in Agriculture*, 192(192), 106621. <https://doi.org/10.1016/j.compag.2021.106621>
- Sun, P. (2020). Security and privacy protection in cloud computing: Discussions and challenges. *Journal of Network and Computer Applications*, 160(160), 102642. <https://doi.org/10.1016/j.jnca.2020.102642>
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. (2017). Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning. *31st AAAI Conf. Artif. Intell. AAAI 2017*, (1), 4278-4284. <https://doi.org/10.1609/aaai.v31i1.11231>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9. <https://doi.org/10.1109/CVPR.2015.7298594>
- Tan, M., & Le, Q. V. (2020). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. <https://doi.org/10.48550/arXiv.1905.11946>
- Tang, Z., Yang, J., Li, Z., & Qi, F. (2020). Grape disease image classification based on lightweight convolution neural networks and channelwise attention. *Computers and Electronics in Agriculture*, 178, 105735. <https://doi.org/10.1016/j.compag.2020.105735>
- Telikani, A., Tahmassebi, A., Banzhaf, W., & Gandomi, A. H. (2022). Evolutionary Machine Learning: A Survey. *ACM Computing Surveys*, 54(8), 1-35. <https://doi.org/10.1145/3467477>
- Thakur, D., Kumar, Y., Kumar, A., & Singh, P. K. (2019). Applicability of Wireless Sensor Networks in Precision Agriculture: A Review. *Wireless Personal Communications*, 107(1), 471-512. <https://doi.org/10.1007/s11277-019-06285-2>
- Torres-Sánchez, J., Mesas-Carrascosa, F. J., Jiménez-Brenes, F. M., de Castro, A. I., & López-Granados, F. (2021). Early Detection of Broad-Leaved and Grass Weeds in Wide Row Crops Using Artificial Neural Networks and UAV Imagery. *Agronomy*, 11(4). <https://doi.org/10.3390/agronomy11040749>
- Tugrul, B., Elfatimi, E., & Eryigit, R. (2022). Convolutional Neural Networks in Detection of Plant Leaf Diseases: A Review. *Agriculture*, 12(8), 1192. <https://doi.org/10.3390/agriculture12081192>

- Tzutalin. (2015). LabelImg.
- Ullah, Z., Al-Turjman, F., & Mostarda, L. (2020). Cognition in UAV-Aided 5G and Beyond Communications: A Survey. *IEEE Transactions on Cognitive Communications and Networking*, 6(3), 872-891. <https://doi.org/10.1109/TCCN.2020.2968311>
- Valente, J., Doldersum, M., Roers, C., & Kooistra, L. (2019). DETECTING RUMEX OBTUSIFOLIUS WEED PLANTS IN GRASSLANDS FROM UAV RGB IMAGERY USING DEEP LEARNING. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV-2/W5, 179-185. <https://doi.org/10.5194/isprs-annals-IV-2-W5-179-2019>
- Valente, J., Hiremath, S., Ariza-Sentís, M., Doldersum, M., & Kooistra, L. (2022). Mapping of Rumex obtusifolius in nature conservation areas using very high resolution UAV imagery and deep learning. *Int. J. Appl. Earth Obs. Geoinf.*, 112, 102864. <https://doi.org/10.1016/j.jag.2022.102864>
- van Dijk, M., Gramberger, M., Laborde, D., Mandryk, M., Shutes, L., Stehfest, E., Valin, H., & Faradsch, K. (2020). Stakeholder-designed scenarios for global food security assessments. *Global Food Security*, 24(24), 100352. <https://doi.org/10.1016/j.gfs.2020.100352>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is All you Need. En I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 30). Curran Associates, Inc.
- Wang, A., Zhang, W., & Wei, X. (2019a). A review on weed detection using ground-based machine vision and image processing techniques. *Computers and Electronics in Agriculture*, 158, 226-240. <https://doi.org/10.1016/j.compag.2019.02.005>
- Wang, S., Han, Y., Chen, J., Pan, Y., Cao, Y., Meng, H., & Zheng, Y. (2019b). A Deep-Learning-Based Low-Altitude Remote Sensing Algorithm for Weed Classification in Ecological Irrigation Area. En I. S. Bajwa, F. Kamareddine & A. Costa (Eds.), *Intelligent Technologies and Applications* (pp. 451-460). Springer Singapore.
- Wang, X., Li, Y., Zhang, H., & Shan, Y. (2021). Towards Real-World Blind Face Restoration with Generative Facial Prior. *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 9164-9174. <https://doi.org/10.1109/CVPR46437.2021.00905>
- Wang, Y. E., Wei, G.-Y., & Brooks, D. (2019c). Benchmarking TPU, GPU, and CPU platforms for deep learning. *arXiv preprint arXiv:1907.10701*, abs/1907.10701, 1907.10701. <https://doi.org/10.48550/arXiv.1907.10701>
- Wang, Z., Bovik, A., Sheikh, H., & Simoncelli, E. (2004). Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600-612. <https://doi.org/10.1109/TIP.2003.819861>
- Wei, P., Lu, Z., & Song, J. (2015). Variable importance analysis: A comprehensive review. *Reliability Engineering & System Safety*, 142(142), 399-432. <https://doi.org/10.1016/j.res.2015.05.018>
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236, 111402. <https://doi.org/10.1016/j.rse.2019.111402>
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M.-J. (2017). Big Data in Smart Farming – A review. *Agricultural Systems*, 153(153), 69-80. <https://doi.org/10.1016/j.agsy.2017.01.023>
- Xia, D., Chen, P., Wang, B., Zhang, J., & Xie, C. (2018). Insect Detection and Classification Based on an Improved Convolutional Neural Network. *Sensors*, 18(12), 4169. <https://doi.org/10.3390/s18124169>

- Xia, Q., & Yang, J. J. (2019). Memristive crossbar arrays for brain-inspired computing. *Nature Materials*, 18(4), 309-323. <https://doi.org/10.1038/s41563-019-0291-x>
- Xiao, D., Pan, Y., Feng, J., Yin, J., Liu, Y., & He, L. (2022). Remote sensing detection algorithm for apple fire blight based on UAV multispectral image. *Computers and Electronics in Agriculture*, 199(199), 107137. <https://doi.org/10.1016/j.compag.2022.107137>
- Xiuling, Z., Huijuan, W., Yu, S., Gang, C., Suhua, Z., & Quanbo, Y. (2024). Starting from the structure: A review of small object detection based on deep learning. *Image and Vision Computing*, 146, 105054. <https://doi.org/10.1016/j.imavis.2024.105054>
- Xu, X., Liang, T., Zhu, J., Zheng, D., & Sun, T. (2019). Review of classical dimensionality reduction and sample selection methods for large-scale data processing. *Neurocomputing*, 328(328), 5-15. <https://doi.org/10.1016/j.neucom.2018.02.100>
- Yang, Y., Jiao, L., Liu, X., Liu, F., Yang, S., Feng, Z., & Tang, X. (2022). Transformers Meet Visual Learning Understanding: A Comprehensive Review. <https://doi.org/10.48550/arXiv.2203.12944>
- Yun, S., Han, D., Chun, S., Oh, S. J., Yoo, Y., & Choe, J. (2019). CutMix: Regularization Strategy to Train Strong Classifiers With Localizable Features. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*, 6022-6031. <https://doi.org/10.1109/ICCV.2019.00612>
- Zaidi, S. S. A., Ansari, M. S., Aslam, A., Kanwal, N., Asghar, M., & Lee, B. (2022). A survey of modern deep learning based object detection models. *Digital Signal Processing*, 126, 103514. <https://doi.org/10.1016/j.dsp.2022.103514>
- Zarco-Tejada, P. J., Camino, C., Beck, P. S. A., Calderon, R., Hornero, A., Hernández-Clemente, R., Kattenborn, T., Montes-Borrego, M., Susca, L., Morelli, M., Gonzalez-Dugo, V., North, P. R. J., Landa, B. B., Boscia, D., Saponari, M., & Navas-Cortes, J. A. (2018). Previsual symptoms of *Xylella fastidiosa* infection revealed in spectral plant-trait alterations. *Nature Plants*, 4(7), 432-439. <https://doi.org/10.1038/s41477-018-0189-7>
- Zarco-Tejada, P. J., Poblete, T., Camino, C., Gonzalez-Dugo, V., Calderon, R., Hornero, A., Hernandez-Clemente, R., Román-Écija, M., Velasco-Amo, M. P., Landa, B. B., Beck, P. S. A., Saponari, M., Boscia, D., & Navas-Cortes, J. A. (2021). Divergent abiotic spectral pathways unravel pathogen stress signals across species. *Nature Communications*, 12(1), 6088. <https://doi.org/10.1038/s41467-021-26335-3>
- Zeadally, S., Siddiqui, F., & Baig, Z. (2019). 25 Years of Bluetooth Technology. *Future Internet*, 11(9), 194. <https://doi.org/10.3390/fi11090194>
- Zhai, Z., Martínez, J. F., Beltran, V., & Martínez, N. L. (2020). Decision support systems for agriculture 4.0: Survey and challenges. *Computers and Electronics in Agriculture*, 170(170), 105256. <https://doi.org/10.1016/j.compag.2020.105256>
- Zhang, K., Lammers, K., Chu, P., Li, Z., & Lu, R. (2021). System design and control of an apple harvesting robot. *Mechatronics*, 79(79), 102644. <https://doi.org/10.1016/j.mechatronics.2021.102644>
- Zhang, R., Wang, C., Hu, X., Liu, Y., Chen, S., et al. (2020a). Weed location and recognition based on UAV imaging and deep learning. *International Journal of Precision Agricultural Aviation*, 3(1).
- Zhang, X., Cao, Z., & Dong, W. (2020b). Overview of Edge Computing in the Agricultural Internet of Things: Key Technologies, Applications, Challenges. *IEEE Access*, 8, 141748-141761. <https://doi.org/10.1109/ACCESS.2020.3013005>

- Zhang, X., Han, L., Dong, Y., Shi, Y., Huang, W., Han, L., González-Moreno, P., Ma, H., Ye, H., & Sobeih, T. (2019a). A Deep Learning-Based Approach for Automated Yellow Rust Disease Detection from High-Resolution Hyperspectral UAV Images. *Remote Sensing*, *11*(13), 1554. <https://doi.org/10.3390/rs11131554>
- Zhang, Y., Gao, J., Cen, H., Lu, Y., Yu, X., He, Y., & Pieters, J. G. (2019b). Automated spectral feature extraction from hyperspectral images to differentiate weedy rice and barnyard grass from a rice crop. *Computers and Electronics in Agriculture*, *159*(159), 42-49. <https://doi.org/10.1016/j.compag.2019.02.018>
- Zheng, Z., Wang, P., Ren, D., Liu, W., Ye, R., Hu, Q., & Zuo, W. (2022). Enhancing Geometric Factors in Model Learning and Inference for Object Detection and Instance Segmentation. *IEEE Transactions on Cybernetics*, *52*(8), 8574-8586. <https://doi.org/10.1109/TCYB.2021.3095305>
- Zhong, Z., Zheng, L., Kang, G., Li, S., & Yang, Y. (2020). Random Erasing Data Augmentation. *Proceedings of the AAAI Conference on Artificial Intelligence*, *34*(07), 13001-13008. <https://doi.org/10.1609/aaai.v34i07.7000>
- Zhou, Z., Chen, X., Li, E., Zeng, L., Luo, K., & Zhang, J. (2019). Edge Intelligence: Paving the Last Mile of Artificial Intelligence With Edge Computing. *Proceedings of the IEEE*, *107*(8), 1738-1762. <https://doi.org/10.1109/JPROC.2019.2918951>
- Zhu, H., Chu, B., Zhang, C., Liu, F., Jiang, L., & He, Y. (2017). Hyperspectral Imaging for Presymptomatic Detection of Tobacco Disease with Successive Projections Algorithm and Machine-learning Classifiers. *Scientific Reports*, *7*(1), 4125. <https://doi.org/10.1038/s41598-017-04501-2>
- Zhu, X., Su, W., Lu, L., Li, B., Wang, X., & Dai, J. (2021). Deformable DETR: Deformable Transformers for End-to-End Object Detection. <https://doi.org/10.48550/arXiv.2010.04159>
- Zidan, M. A., Strachan, J. P., & Lu, W. D. (2018). The future of electronics based on memristive systems. *Nature Electronics*, *1*(1), 22-29. <https://doi.org/10.1038/s41928-017-0006-8>
- Zou, H., & Hastie, T. (2005). Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, *67*(2), 301-320. <https://doi.org/10.1111/j.1467-9868.2005.00503.x>