“Aplicación de tecnologías de Inteligencia Artificial basadas en *Deep Learning*, para el análisis de imágenes de campo en el ámbito agrícola”

Luis Ruiz García
Dr. Ingeniero Agrónomo.
Profesor titular en ETSIAAB
Universidad Politécnica de Madrid

UNIVERSIDAD POLITÉCNICA DE MADRID

¿Qué es la inteligencia artificial?

¿Qué es la inteligencia artificial?

- Definición básica: "*Sistemas informáticos que realizan análisis de datos y, a partir de estos toman decisiones similares a las de los seres humanos*".

- Garnet[1]: "*La inteligencia artificial utiliza analítica avanzada y técnicas basadas en la lógica, incluido el machine learning (aprendizaje automático), para interpretar eventos, apoyar y automatizar decisiones y emprender acciones*"

[1] https://www.gartner.com/en/information-technology/glossary/artificial-intelligence

¿Qué es la inteligencia artificial?

¿Qué fines se persiguen con el uso de la inteligencia artificial?

- Predecir el futuro → Regresión
- Identificar → Clasificar
- Descubrir grupos → *Agrupar*

Ejemplos de aplicación de IA en el sector agrario

Ejemplos de regresiones:

- *¿Cuánto va a producir esta parcela en esta campaña?*
- *¿Cuál será el precio de venta del trigo/lentejas/maíz/etc. el próximo mes/año/semana?*
- *¿Habrá un pronto un ataque de la plaga XX?¿Y de la enfermedad ZZZ?*

Ejemplos de aplicación de IA en el sector agrario

Ejemplos de “clasificar” con inteligencia artificial:

- *¿Qué es este “bicho”? ¿Ácaro?¿Insecto? ¿Especie?*
- *¿Qué especie es esta planta? ¿Es una “mala hierba”? ¿Es mi cultivo?*
- *¿Las manchas de las hojas son por un ataque de hongos o por una carencia de nutrientes?*

Ejemplos de aplicación de IA en el sector agrario

Ejemplos de “agrupar”:

- *¿Cómo se comportan los pollos/cerdos/corderos en la nave? ¿Se mueven mucho? ¿Tienen estrés?*
- *¿Hay diferencias en cuanto al vigor entre las plantas de una misma parcela? Creación de mapas, zonificación*

¿Qué es *Deep Learning*?

¿Qué es *Deep Learning*?

Es una técnica de ***Machine Learning*** (aprendizaje automático) que hace uso de **redes neuronales artificiales profundas.**

Redes neuronales naturales y redes neuronales artificiales

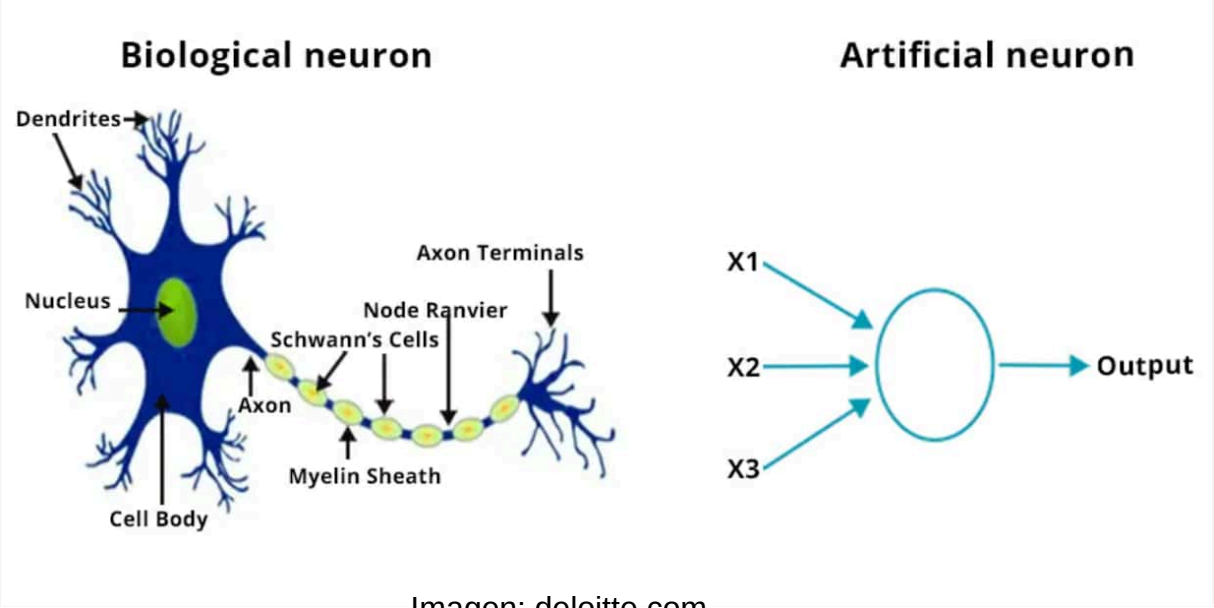

Imagen: deloitte.com

¿Qué es *Deep Learning*?

Diferencia entre redes neuronales convencionales y redes neuronales profundas

- La "profundidad" hace referencia al número de capas ocultas de la red neuronal
- Si tiene más de tres se considera red neuronal profunda

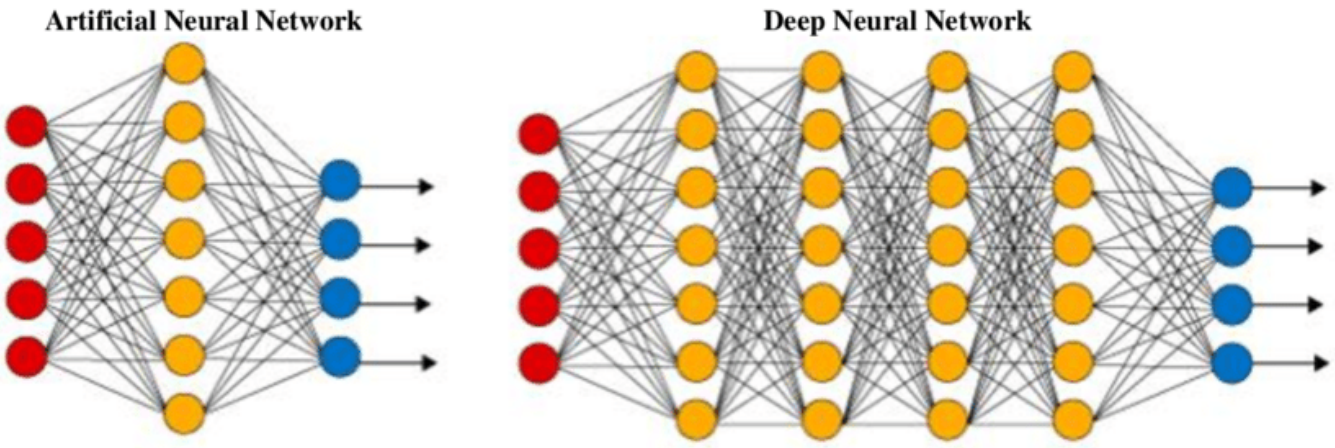

Imagen: Mostafa et al. 2020

Tipos de *Deep Learning*

Los sistemas de ***Deep Learning*** se pueden clasificar en función del tipo de redes neuronales profundas que utilizan:

- Redes neuronales recurrentes (RNN)
- Long-Short Term Memory (LSTM)
- Redes neuronales convolucionales (CNN)

Tipos de *Deep Learning*

Los sistemas de *Deep Learning* se pueden clasificar en función del tipo de redes neuronales profundas que utilizan:

- Redes neuronales recurrentes (RNN)
- Long-Short Term Memory (LSTM)
- Redes neuronales convolucionales (CNN)

Redes neuronales recurrentes (RNN)

¿Para qué se utilizan las redes neuronales recurrentes?

- Especializadas en procesar datos secuenciales o series temporales.
- Aplicaciones:
  - Traducciones de texto
  - Reconocimiento de voz
  - Generar textos artificiales
- Punto débil: memoria a corto plazo

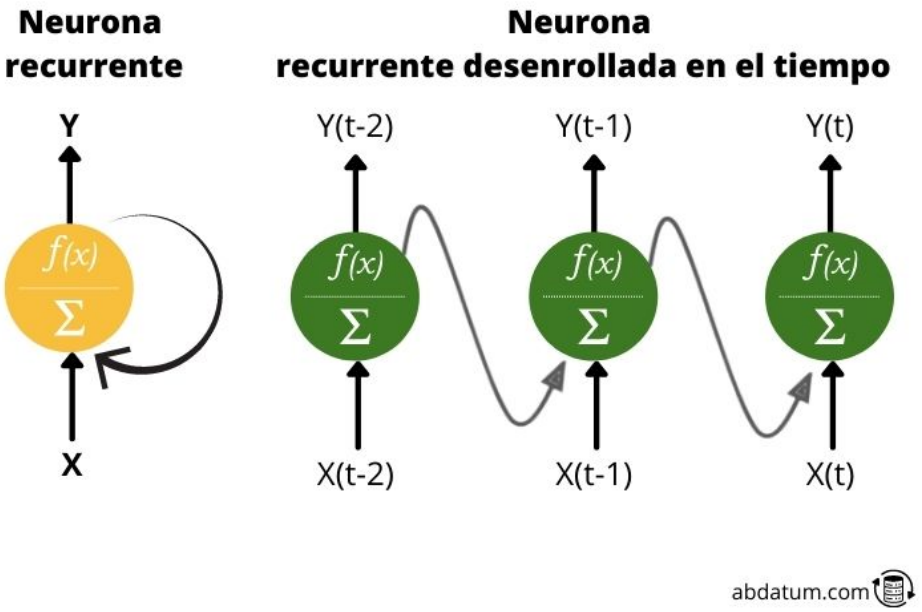

Tipos de *Deep Learning*

Los sistemas de *Deep Learning* se pueden clasificar en función del tipo de redes neuronales profundas que utilizan:

- Redes neuronales recurrentes (RNN)
- Long-Short Term Memory (LSTM)
- Redes neuronales convolucionales (CNN)

Long-Short Term Memory (LSTM)

¿Para qué se utilizan las redes neuronales LSTM?

- Para procesar series temporales y hacer predicciones.
- Son RNN que tienen la memoria ampliada para aprender de situaciones que ocurrieron hace más tiempo.

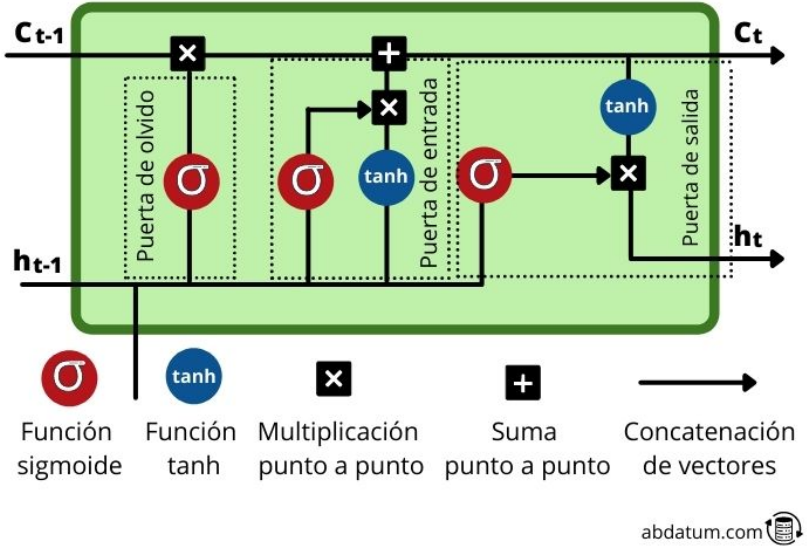

Tipos de *Deep Learning*

Los sistemas de *Deep Learning* se pueden clasificar en función del tipo de redes neuronales profundas que utilizan:

- Redes neuronales recurrentes (RNN)
- Long-Short Term Memory (LSTM)
- Redes neuronales convolucionales (CNN)

Redes neuronales convolucionales (CNN)

Tipos de *Deep Learning*

¿Para qué se utilizan las redes neuronales convolucionales?

- Operan como un ojo humano
- Aplicaciones:
  - Visión artificial
  - Detección de patrones en imágenes

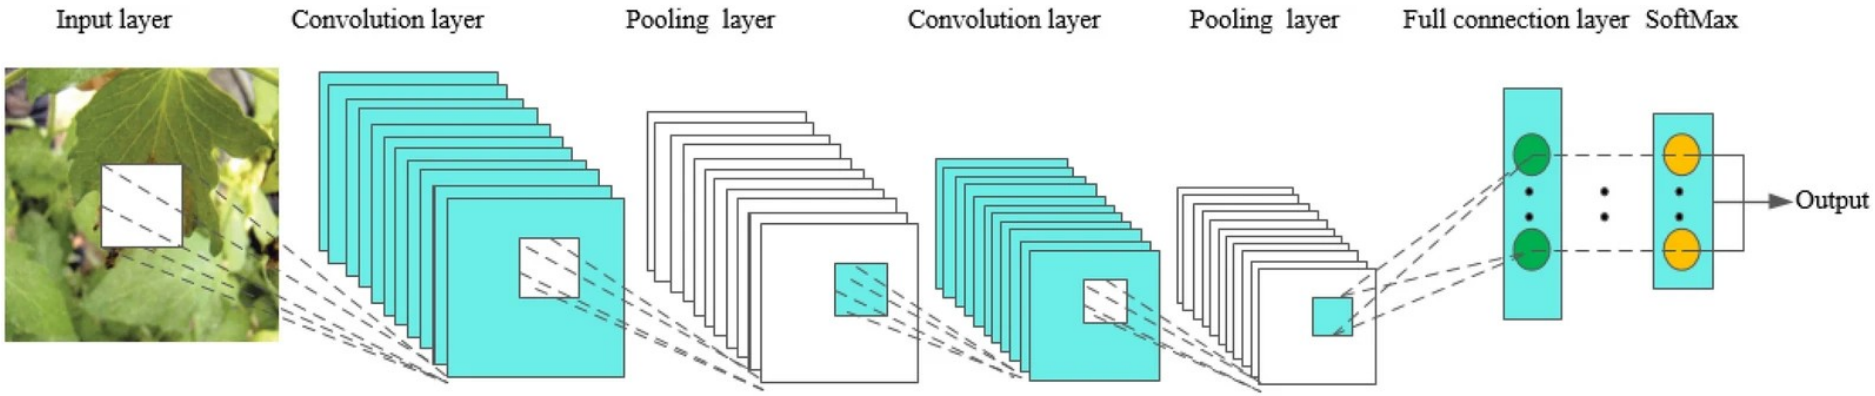

Imagen: Liu, J y Wang, X., 2021

Ejemplos de Deep Learning

Ejemplo 1: Identificar el contenido de una imagen

Ejemplos de *Deep Learning*

Identificar el contenido de una imagen

¿Qué es esto?

Ejemplos de *Deep Learning*

Identificar el contenido de una imagen

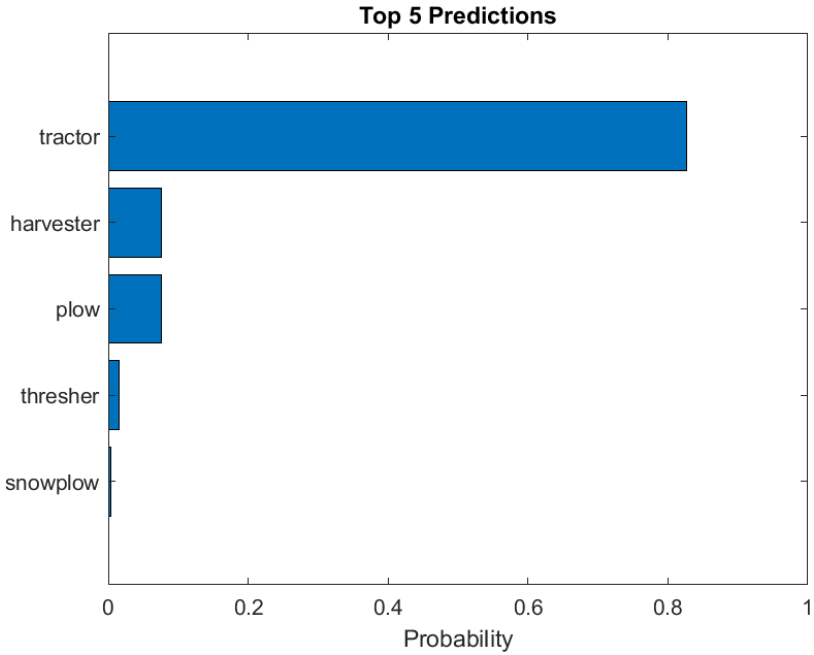

Predicción hecha con **Googlenet**

Ejemplos de *Deep Learning*

Identificar el contenido de una imagen

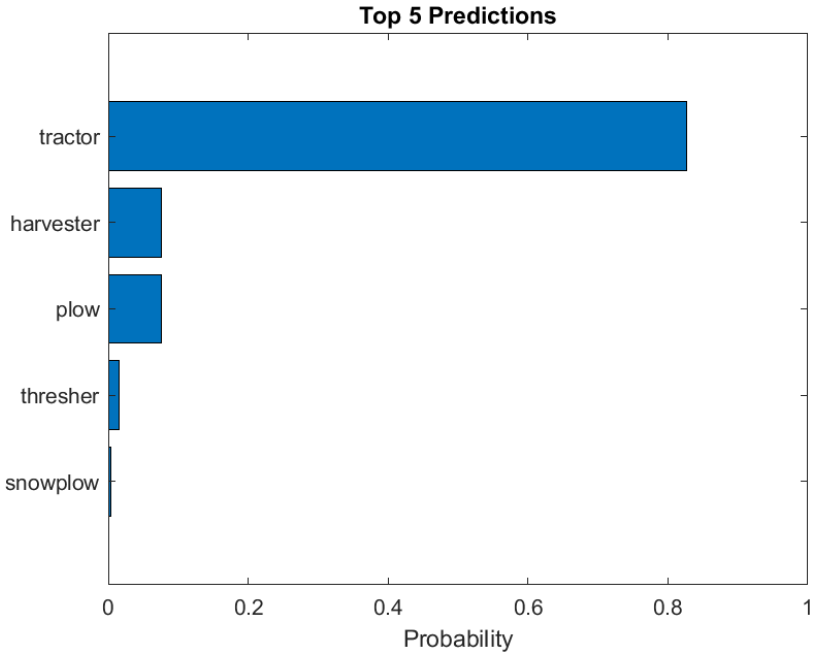

Predicción hecha con **Googlenet**

¿Qué es Googlenet?

¿Qué es Googlenet?

Un modelo de *Deep Learning* preentrenado para clasificar imágenes

Googlenet: ejemplo de modelo preentrenado

- Prentrenado para reconocer 1.000 categorías de objetos diferentes:
  - teclado, ratón, lápiz, perro, gato, **tractor**, etc.
- Podemos entrenarla para reconocer otros objetos

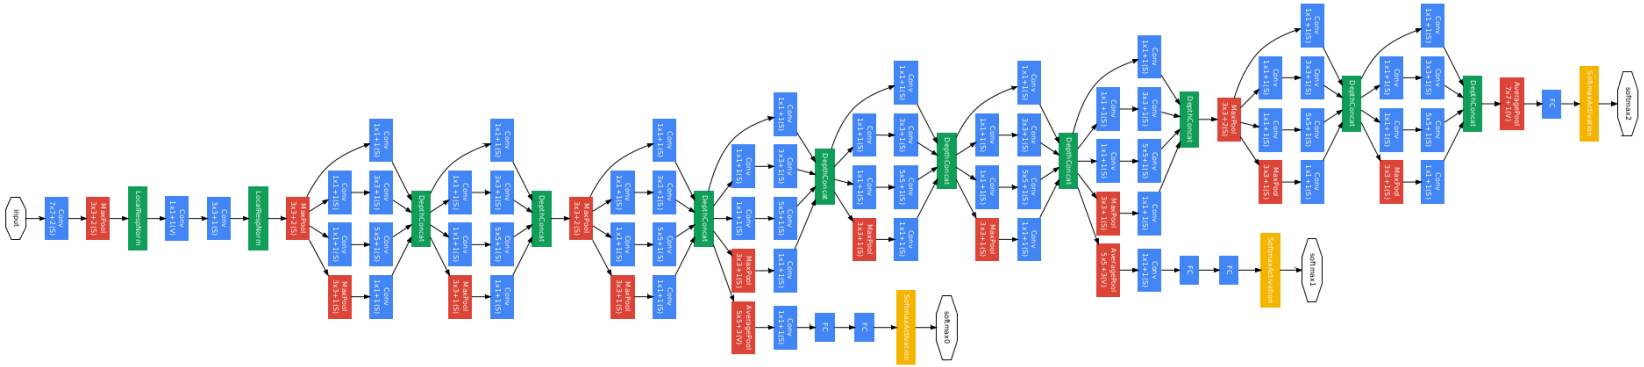

Arquitectura de **Googlenet**

Modelos preentrenados para clasificar imágenes

Modelos de *Deep Learning* preentrenados

- LeNet
- AlexNet
- VGGNet
- GoogLeNet
- ResNet
- ZFNet
- DenseNet
- CapsNet
- SENet
- Etc.

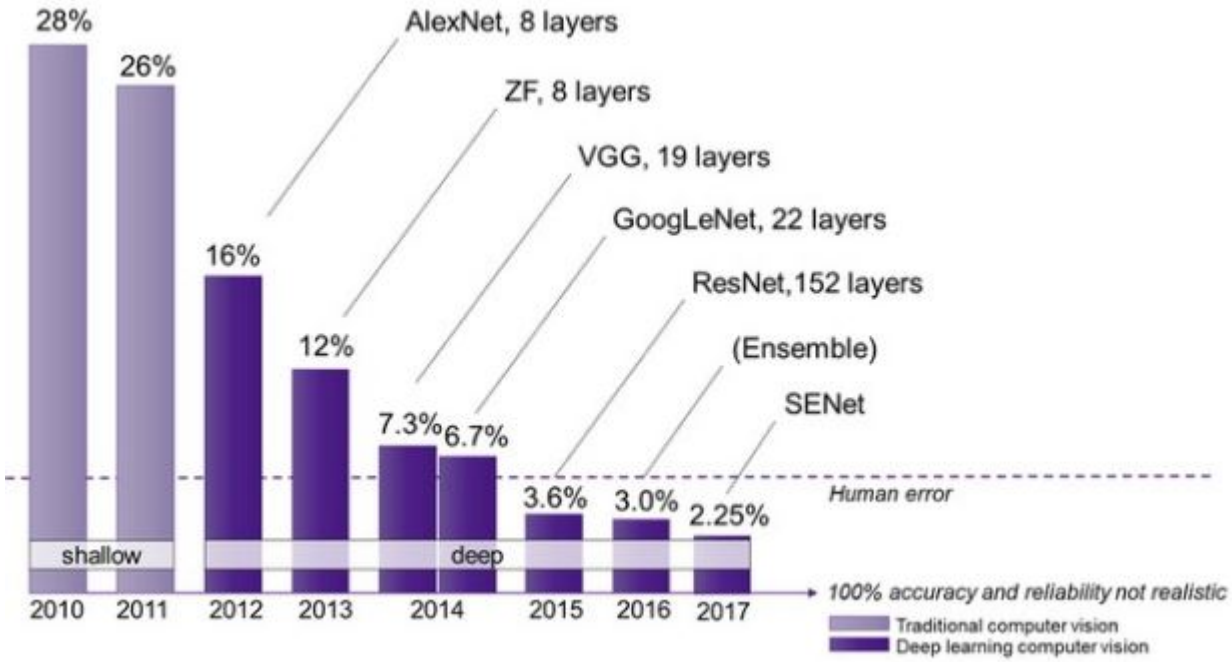

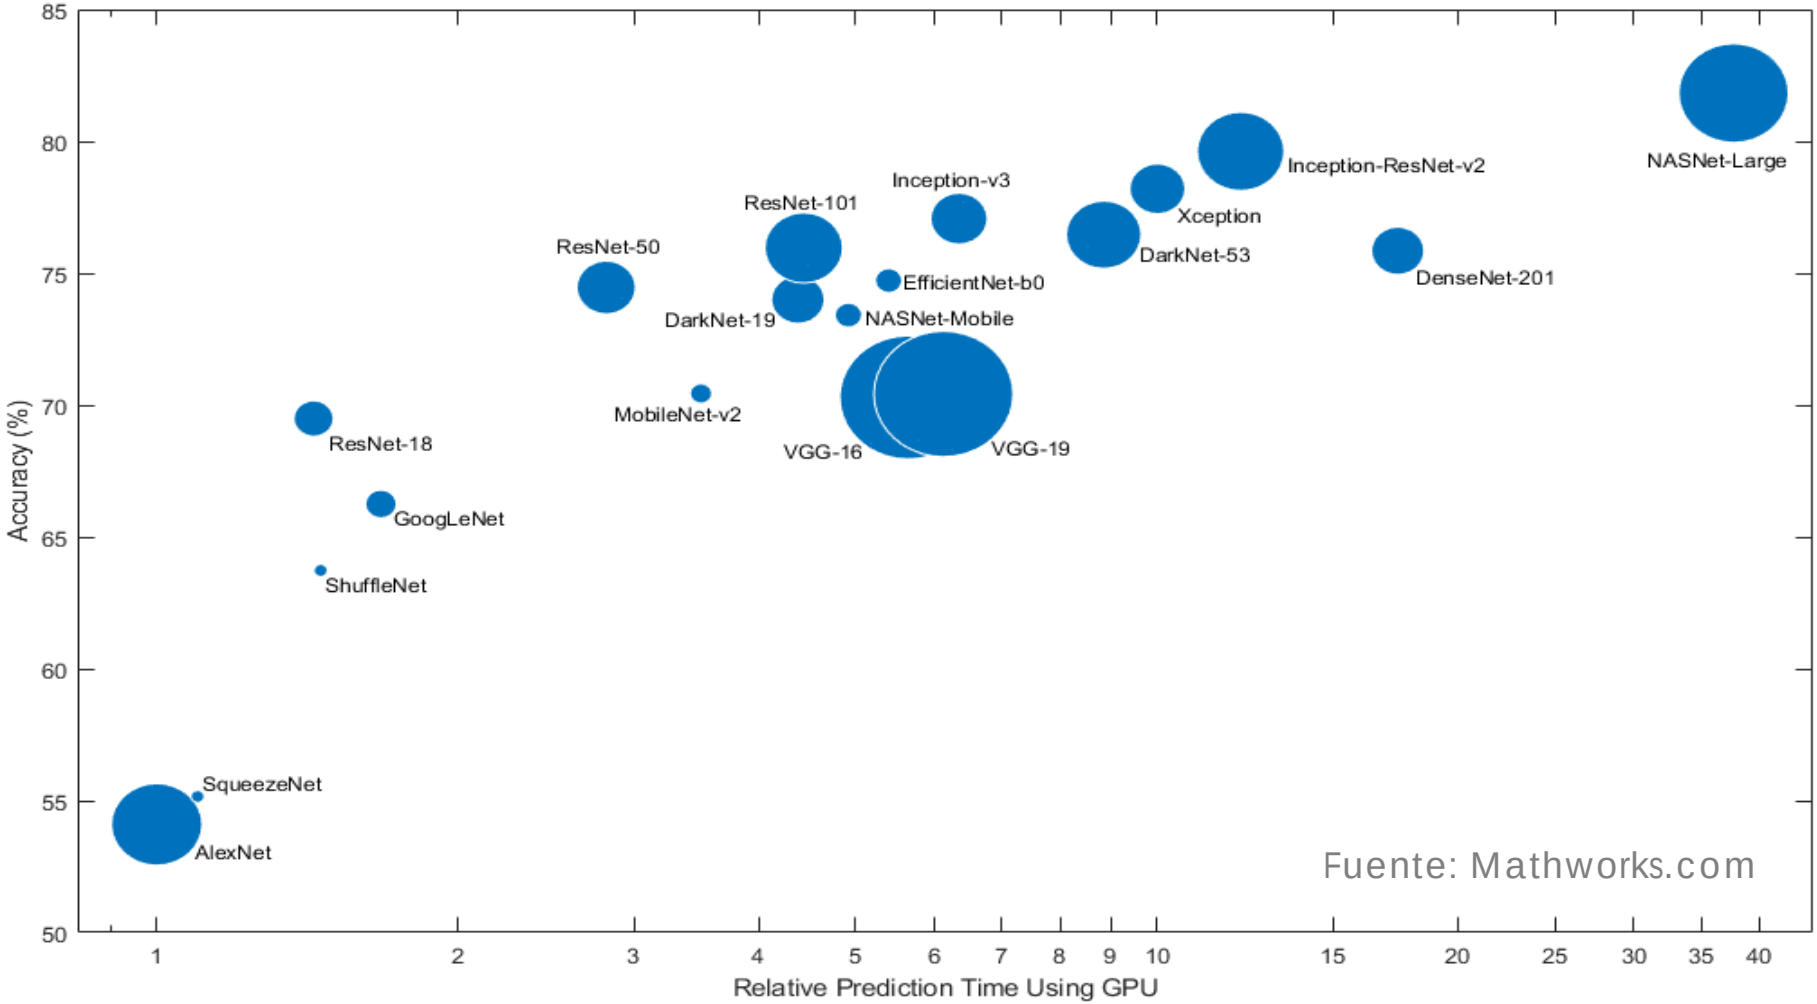
Accuracy (%)
85
80
75
70
65
60
55
50
Relative Prediction Time Using GPU
1
2
3
4
5
6
7
8
9
10
15
20
25
30
35
40
NASNet-Large
Inception-ResNet-v2
Xception
DarkNet-53
DenseNet-201
Inception-v3
ResNet-101
ResNet-50
EfficientNet-b0
DarkNet-19
NASNet-Mobile
MobileNet-v2
VGG-16
VGG-19
ResNet-18
GoogLeNet
ShuffleNet
SqueezeNet
AlexNet
Fuente: Mathworks.com

Ejemplo 2: Entrenar un modelo de Deep Learning para clasificar imágenes

Ejemplos de *Deep Learning*

¿De qué marcas son estos tractores?

Clasificación mediante *Deep Learning*

Entrenamiento de una red de *Deep Learning*

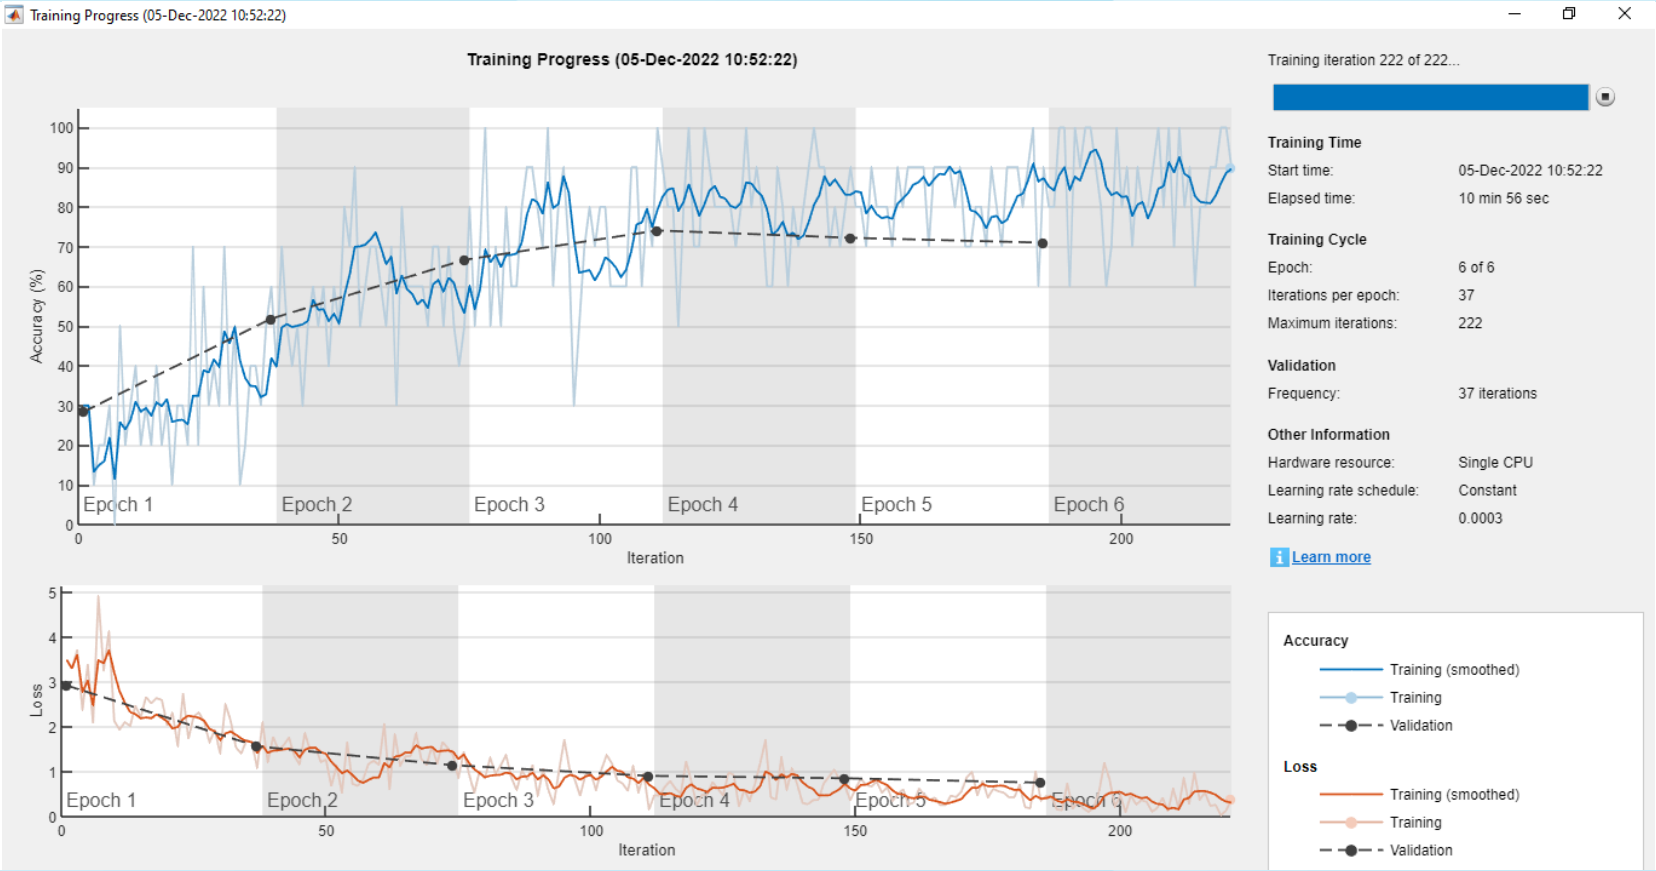

Ejemplos de *Deep Learning*

Clasificar tractores por marcas según su imagen

John Deere, 100%

Fendt, 96.5%

John Deere, 100%

Landini, 37.7%

Aplicaciones del Deep Learning: casos prácticos con imágenes de campo

Detección de plagas y enfermedades

Contexto europeo

Nuevas normativas

Bruselas propone obligar a reducir 50% el uso de pesticidas en UE para 2030

Redacción Tierras 23/06/2022 1217

El MAPA, no obstante, cree que la propuesta es demasiado compleja, por lo que será necesario hacer un esfuerzo de simplificación de algunos aspectos dentro del Consejo de la Unión Europea.

La **Comisión Europea** (CE) ha presentado una propuesta para obligar a reducir en un 50% el uso de plaguicidas químicos en la Unión Europea para 2030, lo que se traducirá en objetivos nacionales diferentes, en función de la situación de partida de cada Estado miembro.

Para compensar el impacto sobre los agricultores, que tendrán que hacer un especial esfuerzo para ajustarse a las nuevas normas, Bruselas ha propuesto que puedan beneficiarse de las ayudas de la Política Agrícola Común (PAC) durante cinco años, según informa EFE.

Identificación de síntomas en hojas

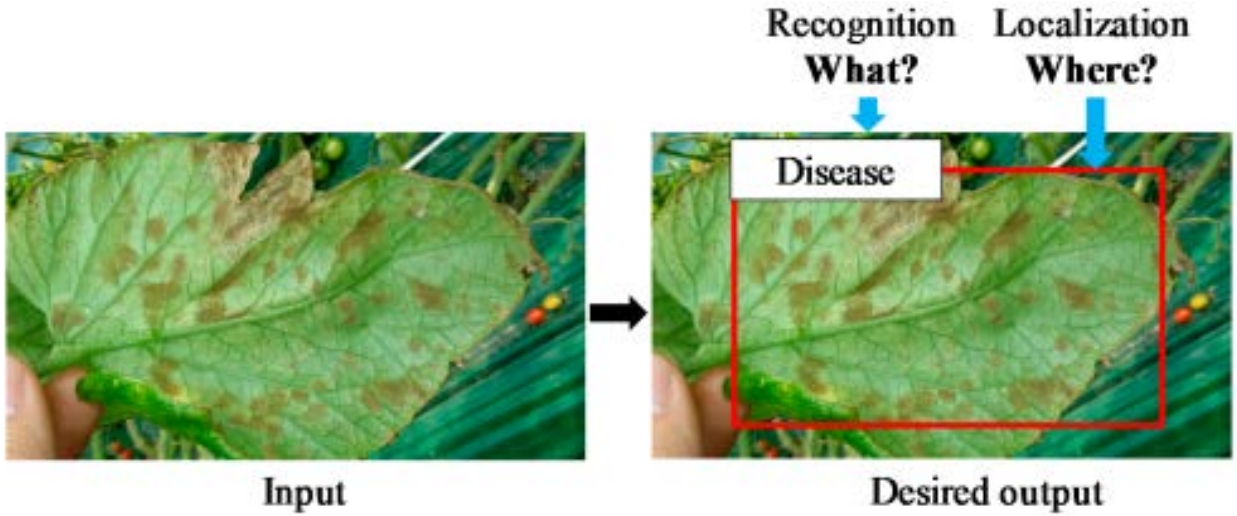

Fuentes, A., Yoon, S., Kim, S. C., & Park, D. S. (2017). A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*, *17*(9), 2022.

Identificación de síntomas en hojas

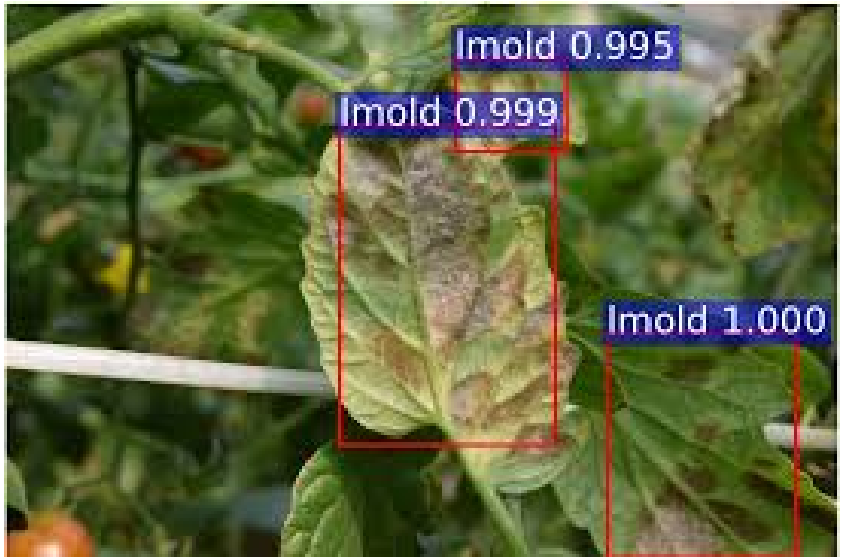

Fuentes, A., Yoon, S., Kim, S. C., & Park, D. S. (2017). A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition. *Sensors*, *17*(9), 2022.

Detección de plagas y enfermedades

Identificación de síntomas en hojas

Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and electronics in agriculture*, *145*, 311-318.

Detección de plagas y enfermedades

Identificación de síntomas en hojas

Ferentinos, K. P. (2018). Deep learning models for plant disease detection and diagnosis. *Computers and electronics in agriculture*, *145*, 311-318.

Ejemplos de repositorios de imágenes en abierto

Nombre del repositorio	Tipo de imagen	Número de imágenes
PlantVillage-Dataset	Hojas por separado sobre fondo uniforme	162.916
Rice Leaf Diseases Data Set	Hojas en campo sobre fondo blanco	120
Image Database for Plant Disease Symptoms (PDDB)	Campo	2.326
New Plant Diseases Dataset (Augmented)	Hojas por separado sobre fondo uniforme	87.000
Dataset de Tyr Wiesner-Hanks y Mohammed Brahimi	Campo	18.222
Academia China de Ciencias	Campo	17.624
PlantDoc dataset	Campo	2.598
Dataset of apple leaf disease	Campo	3.651
IP102: Insect Pest Recognition Database	Campo	75.000

Repositorios de imágenes en abierto

Repositorios en abierto

Ejemplos de imágenes con problemas fitopatológicos

PlantVillage

Ampliación de datos (Data augmentation)

Data augmentation o Data amplification

¿Qué es la ampliación de datos?

- Generar imágenes sintéticas para incrementar el tamaño del dataset con el fin de evitar sobre ajustes en los modelos.
- Diferentes técnicas:
    - Rotar
    - Recortar
    - Reducir
    - Alterar la intensidad de los colores
    - Etc.

Data augmentation o Data amplification

Ejemplo de aplicación: Diagnóstico de enfermedades en plantas

Técnicas de aumentación empleadas

Dataset con 61.459 imágenes → BIM, DCGAN, NST → Dataset con 147.500 imágenes

BIM DCGAN NST

Pandian, J. A., Kumar, V. D., Geman, O., Hnatiuc, M., Arif, M., & Kanchanadevi, K. (2022). Plant Disease Detection Using Deep Convolutional Neural Network. *Applied Sciences*, *12*(14), 6982.

¿Cómo de buenos son estos modelos?

Evaluación de los modelos de clasificación

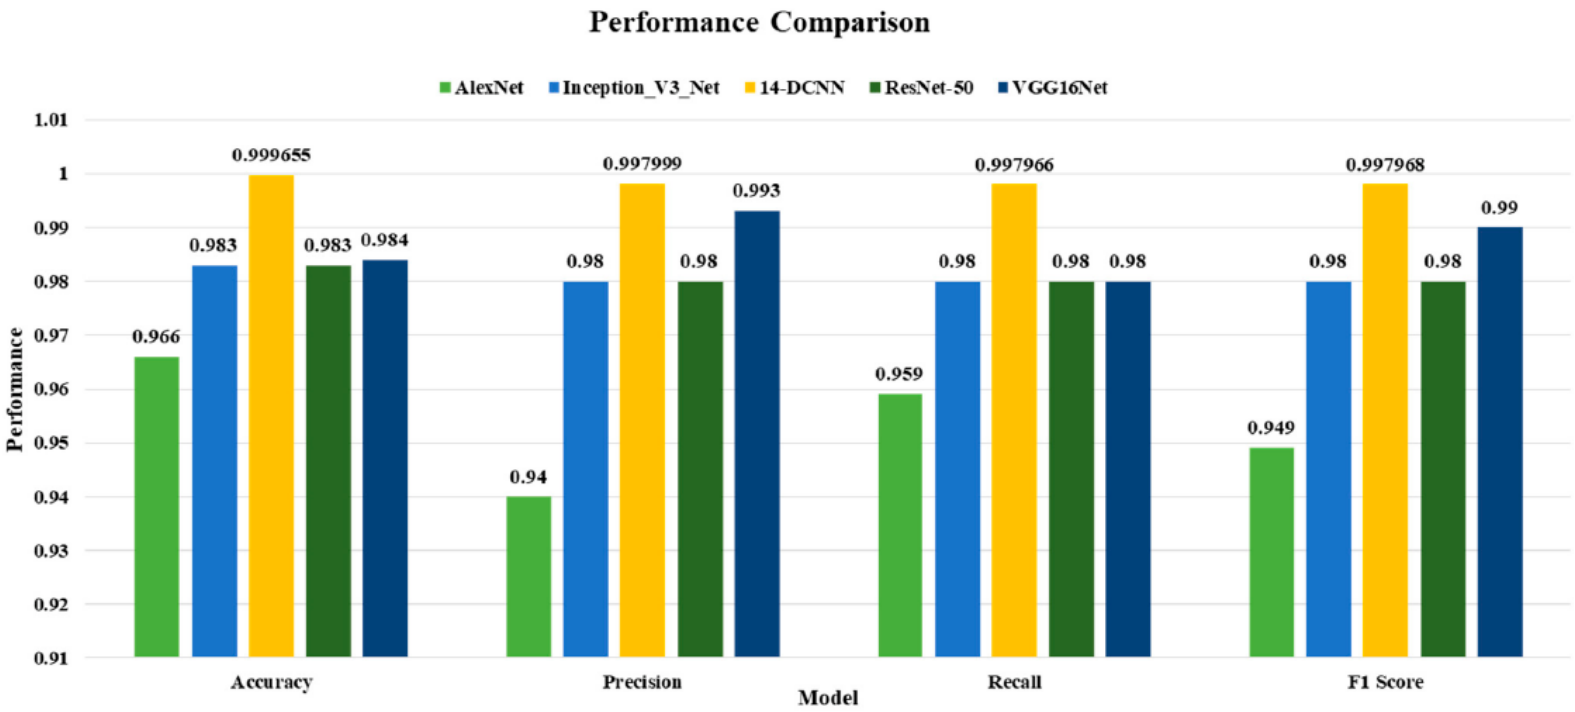

Pandian, J. A., Kumar, V. D., Geman, O., Hnatiuc, M., Arif, M., & Kanchanadevi, K. (2022). Plant Disease Detection Using Deep Convolutional Neural Network. *Applied Sciences*, *12*(14), 6982.

Evaluación de los modelos de clasificación

¿Qué métricas se utilizan para evaluar los modelos?

- La **exactitud** ("*accuracy*") mide el porcentaje de casos que el modelo ha acertado
- La **precisión** ("*precision*") nos da la calidad de la predicción: *¿qué porcentaje de los que hemos dicho que son la clase positiva, en realidad lo son?*
- La **exahustividad** ("*recall*") nos da la cantidad: *¿qué porcentaje de la clase positiva hemos sido capaces de identificar?*
- **F1** combina precisión y exhaustividad en una sola medida

Detección de malas hierbas

Contexto europeo y mundial

agroclm
El diario del campo de Castilla-La Mancha

Agricultura | Ganadería | Desarrollo Rural y PAC | Agua, Ecología y Medio Ambiente | Cooperativas, DDOO y Empresas | Turi Enol Gast

Agricultura | Destacadas

Prohibición del glifosato ¿qué alternativas hay al herbicida más utilizado en el mundo?

Completa recopilación de otras prácticas del blog especializado Mi Agrónomo

28 noviembre, 2022

Detección de malas hierbas

Ejemplo: detección de malas hierbas en cultivo de pimiento

Subeesh, A., Bhole, S., Singh, K., Chandel, N. S., Rajwade, Y. A., Rao, K. V. R., ... & Jat, D. (2022). Deep convolutional neural network models for weed detection in polyhouse grown bell peppers. *Artificial Intelligence in Agriculture*, *6*, 47-54.

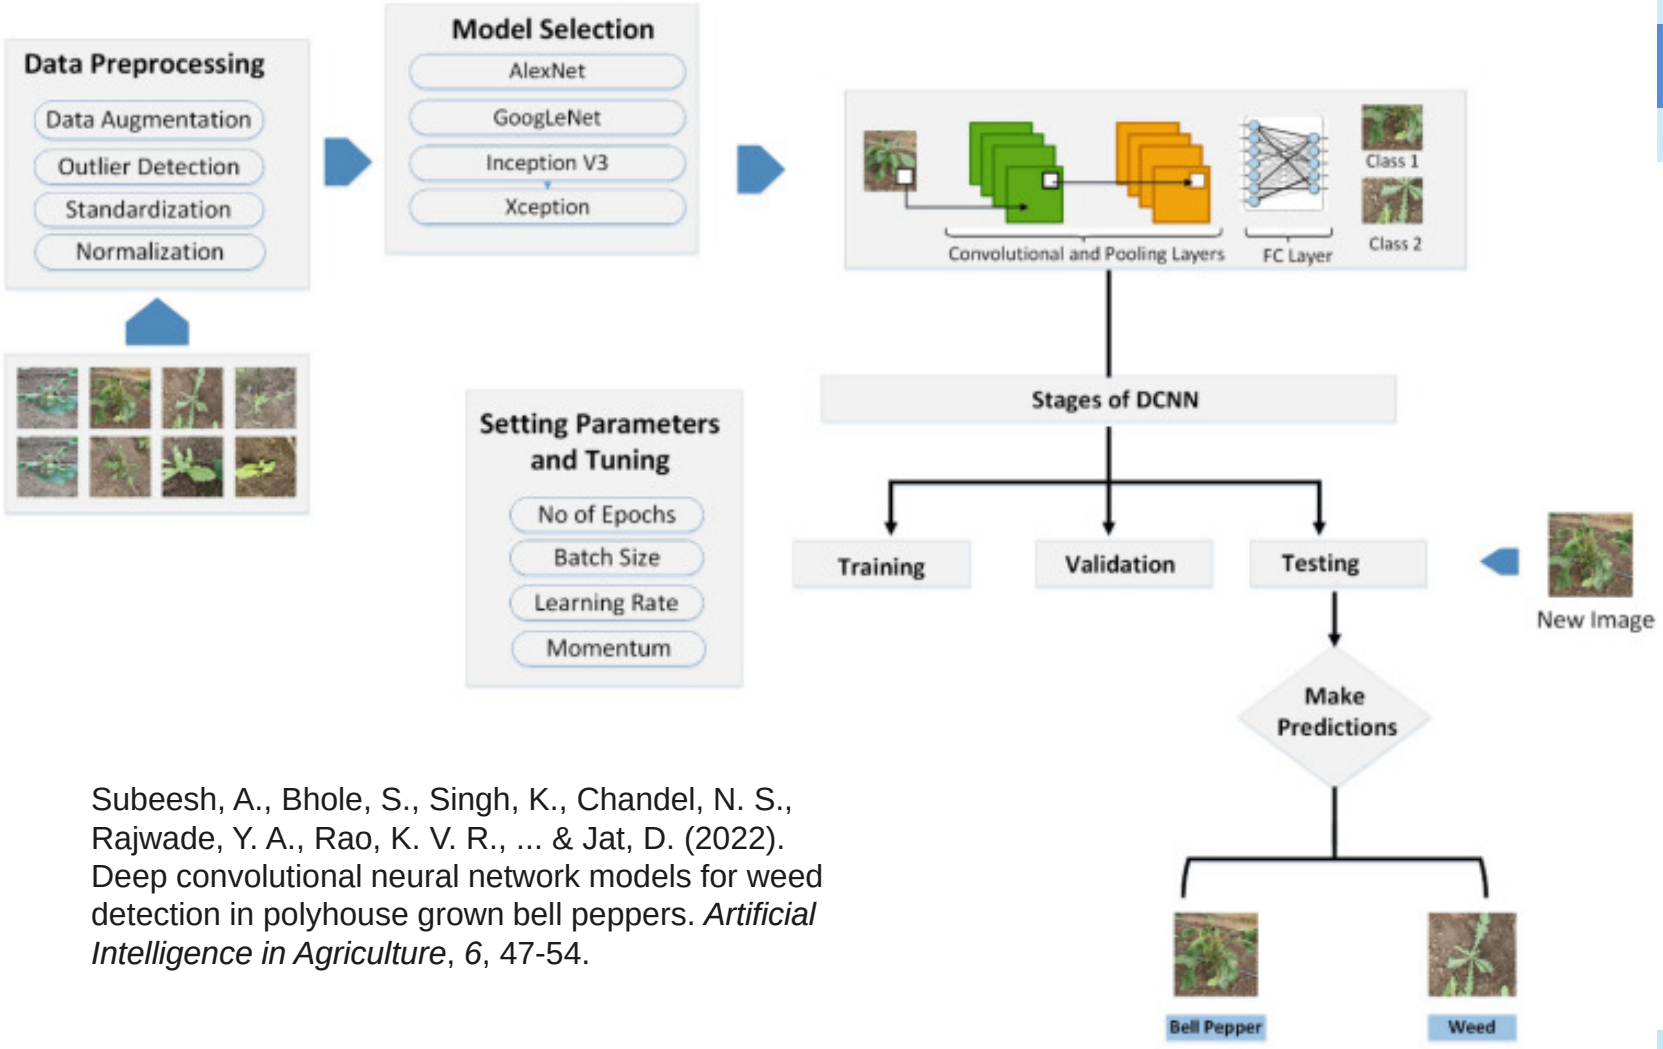

Subeesh, A., Bhole, S., Singh, K., Chandel, N. S., Rajwade, Y. A., Rao, K. V. R., ... & Jat, D. (2022). Deep convolutional neural network models for weed detection in polyhouse grown bell peppers. *Artificial Intelligence in Agriculture*, *6*, 47-54.

Detección de malas hierbas

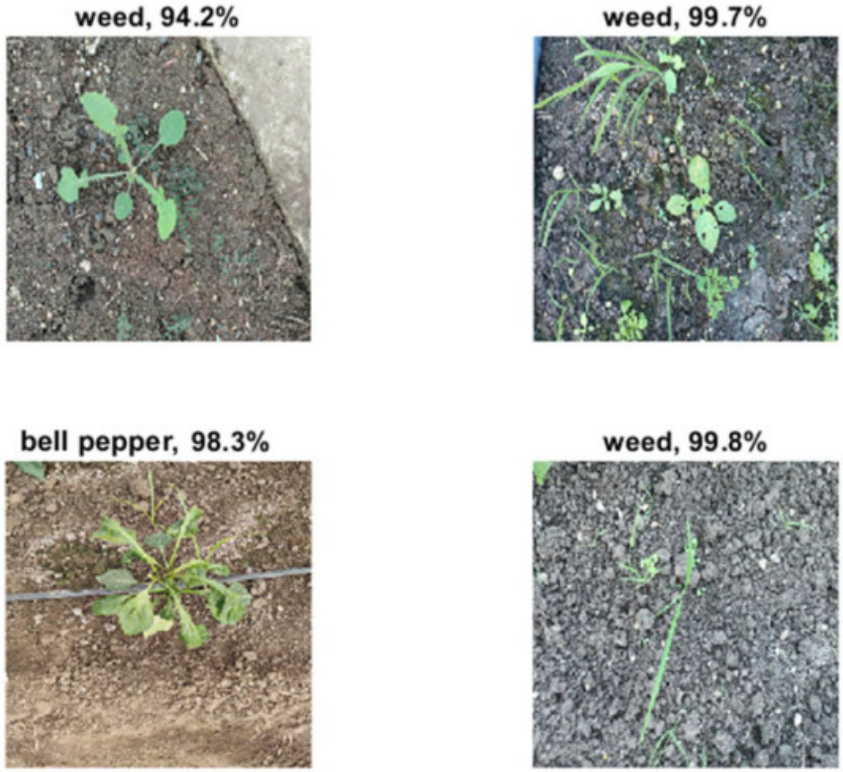

Subeesh, A., Bhole, S., Singh, K., Chandel, N. S., Rajwade, Y. A., Rao, K. V. R., ... & Jat, D. (2022). Deep convolutional neural network models for weed detection in polyhouse grown bell peppers. *Artificial Intelligence in Agriculture*, *6*, 47-54.

Ejemplo: detección de malas hierbas en trigo

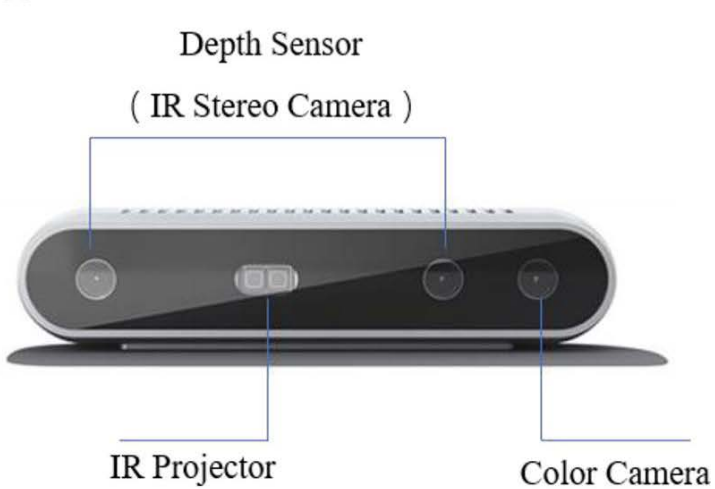

Xu, K., Zhu, Y., Cao, W., Jiang, X., Jiang, Z., Li, S., & Ni, J. (2021). Multi-modal deep learning for weeds detection in wheat field based on RGB-D images. *Frontiers in Plant Science*, 2572.

Detección de malas hierbas

Ejemplo: detección de malas hierbas en trigo

Verde: verdaderos positivos. **Azul:** Etiquetado de los resultados
Rosa: Falsos negativos. **Rojo:** falsos positivos

Xu, K., Zhu, Y., Cao, W., Jiang, X., Jiang, Z., Li, S., & Ni, J. (2021). Multi-modal deep learning for weeds detection in wheat field based on RGB-D images. *Frontiers in Plant Science*, 2572.

Detección de insectos

Detección de insectos

Comparación de diferentes técnicas de *Machine Learning*

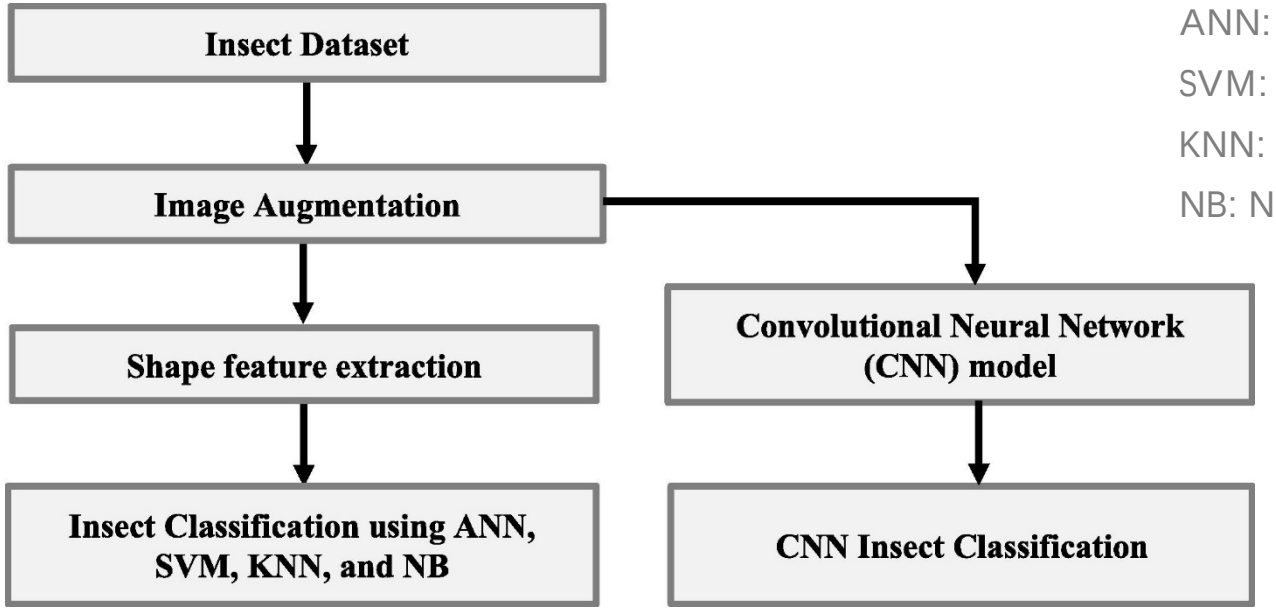

ANN: Artificial Neural Networks

SVM: Support Vector Machine

KNN: K-Nearest Neighbors

NB: Naive Bayesian

Kasinathan, T., Singaraju, D., & Uyyala, S. R. (2021). Insect classification and detection in field crops using modern machine learning techniques. *Information Processing in Agriculture*, *8*(3), 446-457.

Image aumentation para incrementar los datasets

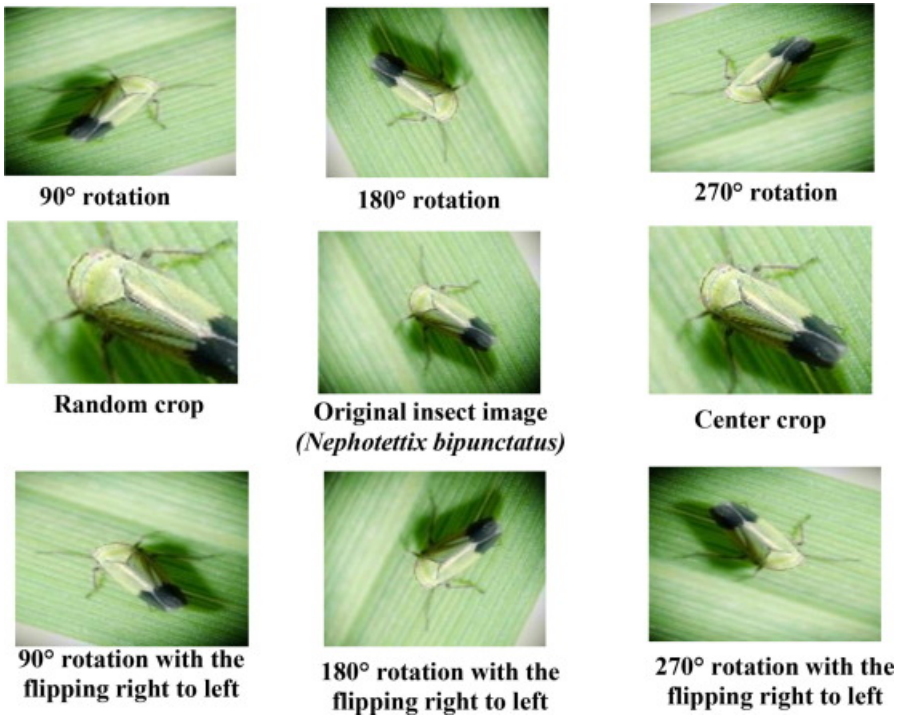

Kasinathan, T., Singaraju, D., & Uyyala, S. R. (2021). Insect classification and detection in field crops using modern machine learning techniques. *Information Processing in Agriculture*, *8*(3), 446-457.

Detección de insectos

Comparación de diferentes técnicas de *Machine Learning*

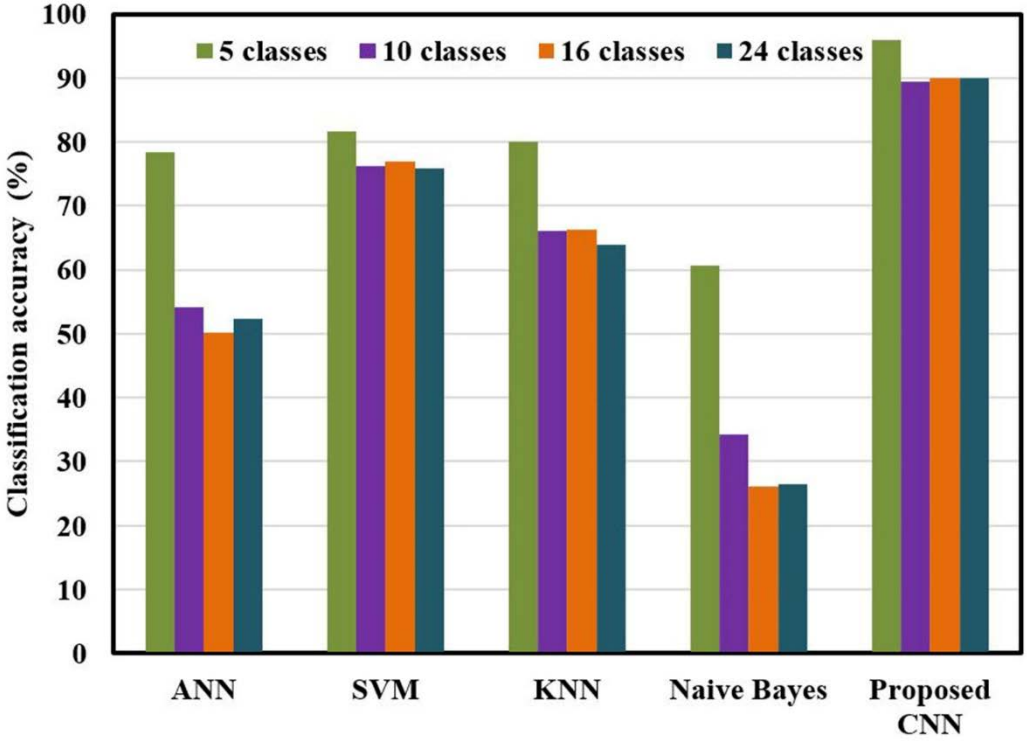

Kasinathan, T., Singaraju, D., & Uyyala, S. R. (2021). Insect classification and detection in field crops using modern machine learning techniques. *Information Processing in Agriculture*, *8*(3), 446-457.

“Aplicación de tecnologías de Inteligencia Artificial basadas en *Deep Learning*, para el análisis de imágenes de campo en el ámbito agrícola”

Luis Ruiz García
Dr. Ingeniero Agrónomo.
Profesor titular en ETSIAAB
Universidad Politécnica de Madrid

UNIVERSIDAD POLITÉCNICA DE MADRID