

# *Sistema de monitorización y detección de plagas en cultivos aplicando algoritmos de Deep Learning*

Claudia Ferrer Martínez

Máster en Ingeniería de  
Telecomunicación

Junio 2021

Equipo docente

David Crespo García  
Carlos Monzo Sánchez



# Índice

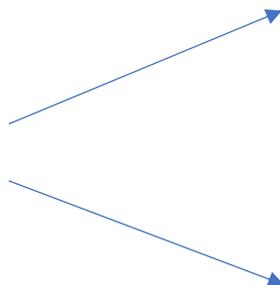
1. Introducción, contexto y objetivos
2. Estado del Arte
  - 2.1 Agricultura de precisión
  - 2.2 Machine Learning
3. Diseño de los sistemas de monitorización
  - 3.1 Infraestructura global
  - 3.2 Sistemas de adquisición de datos
4. Sistema de detección de plagas del cultivo en imágenes aplicando Deep Learning
  - 4.1 Arquitectura de la red neuronal convolucional
  - 4.2 Obtención del dataset
  - 4.3 Entrenamiento del modelo
  - 4.4 Resultados obtenidos
5. Conclusiones y líneas futuras



# 1. Introducción, contexto y objetivos

- Reporte ONU-FAO sobre el futuro de la agricultura y la alimentación, aumento de la producción de alimentos en un 70% para cubrir la demanda de alimentos en 2050
- Ámbito TIC: plantear nuevas soluciones tecnológicas para incrementar la productividad de los cultivos y optimizar el uso de recursos agrícolas (riego, productos fitosanitarios)
- Técnicas de agricultura de precisión e inteligente (Internet de las Cosas, Redes de sensores, Drones)

Objetivos  
del proyecto



Diseño de la infraestructura de un sistema de agricultura inteligente mediante sistemas de monitorización y adquisición de datos e imágenes

Sistema de detección de plagas en el cultivo mediante imágenes y algoritmos de Deep Learning



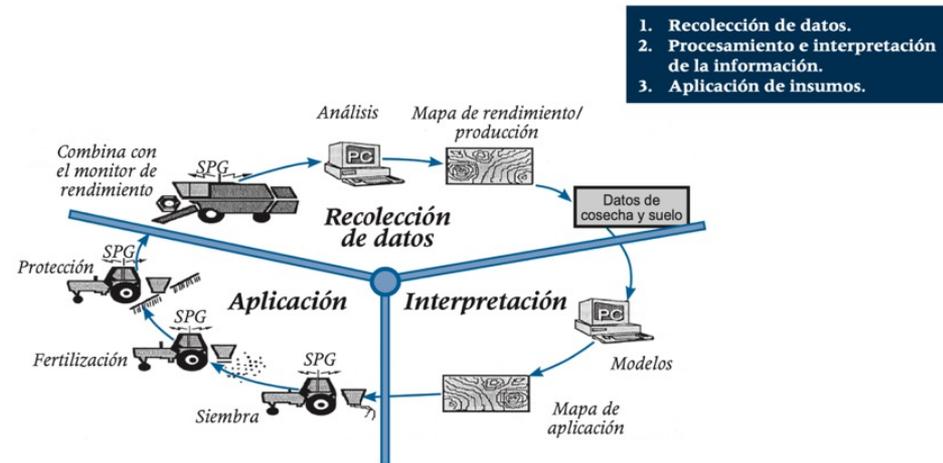
## 2. Estado del Arte

### 2.1 Agricultura de precisión

Recoge, procesa y analiza datos temporales, espaciales e individuales, y los combina con otra información para mejorar la gestión y eficiencia del uso de recursos, la productividad, la calidad, y la sostenibilidad de la producción agrícola

Técnicas y dispositivos:

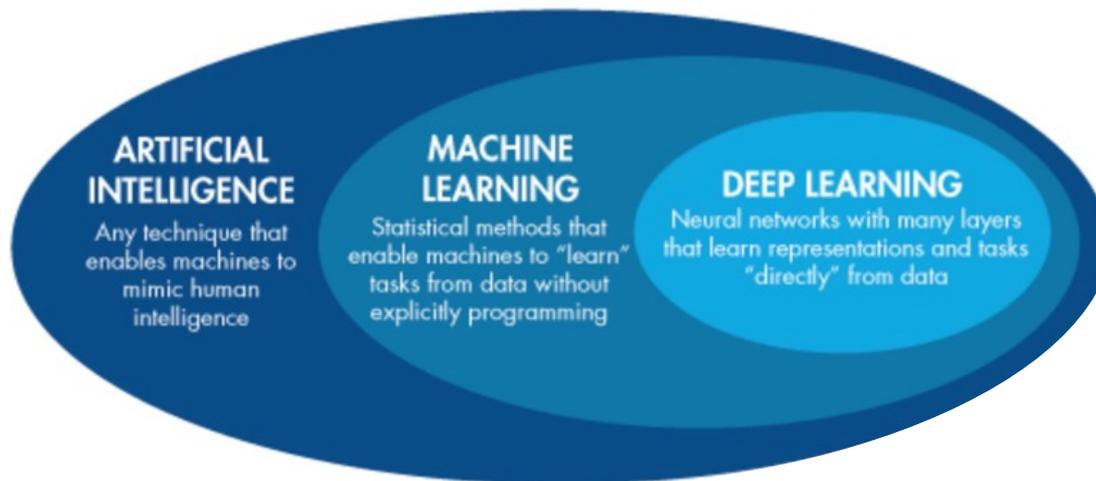
- Gestión variabilidad intraparcelsaria
- Sensores ambientales
- Sistemas de información geográfica (SIG)
- Imágenes multiespectrales aéreas por satélite o dron
- Inteligencia Artificial, robótica, aprendizaje automático



## 2. Estado del Arte

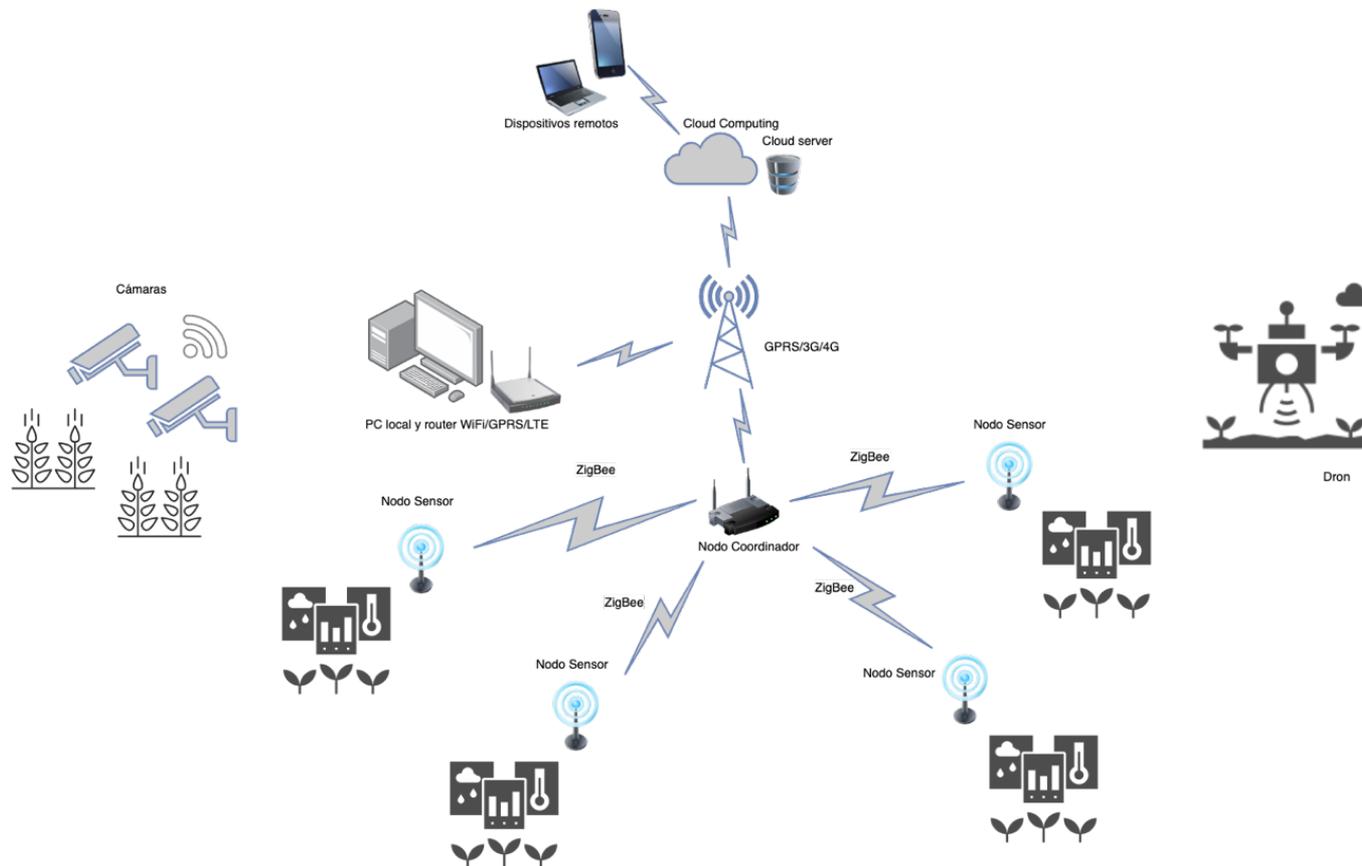
### 2.2 Machine Learning

- Aprendizaje supervisado
- Aprendizaje no supervisado
- Aprendizaje por refuerzo
- Deep Learning: Redes Neuronales



# 3. Diseño de los sistemas de monitorización

## 3.1 Diseño global de la infraestructura



## 3.2 Sistemas de adquisición de datos

### *Sistema de sensores*

- Sensor de temperatura y humedad del suelo
- Sensor de temperatura y humedad del ambiente
- Sensor de pH
- Sensor de humedad de la hoja
- Estación meteorológica

### ○ Requisitos:

- Bajo ancho de banda (kbps)
- Bajo consumo de energía
- Alta disponibilidad de los datos
- Escalabilidad



### ○ Tecnologías propuestas:

- Red de sensores inalámbricos en estrella formada por nodo sensor y nodo coordinador
- ZigBee y 3G/LTE



## 3.2 Sistemas de adquisición de datos

### *Sistema de dron*

- UAV con cámara multispectral y óptica para obtener imágenes del campo

#### ○ Requisitos:

- Ancho de banda mayor (Gbps)
- Cobertura amplia y conectividad continua
- Baja latencia
- Bajo consumo de energía

#### ○ Posibles escenarios:

- Zona rural sin conexión a internet o conexión limitada (3G) → procesamiento local de las imágenes obtenidas
- Posible escenario futuro con conexión alta velocidad (5G o 4G+) → envío en tiempo real de las imágenes a la nube



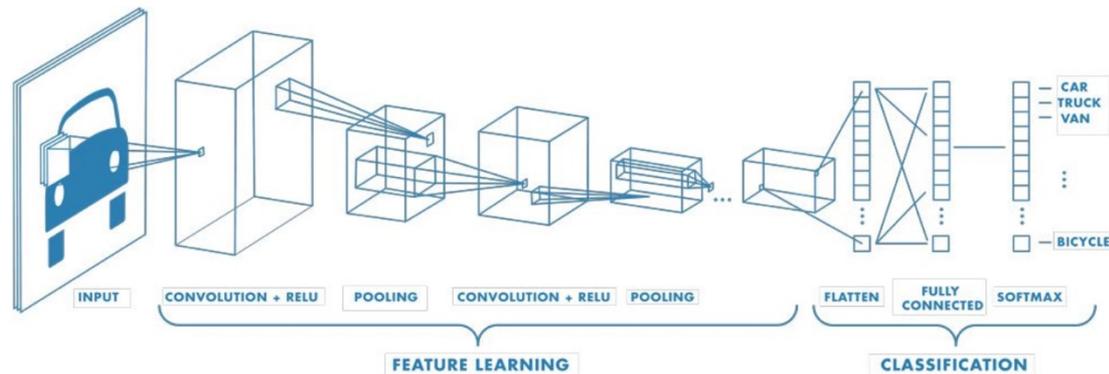
### *Sistema de cámaras*

- Cámaras instaladas en áreas donde se requiera una monitorización constante del estado del cultivo (crecimiento de la planta, estado de maduración, evolución al aplicar tratamientos, etc.)
- Cámaras IP de exterior conectadas por WiFi para acceder a las imágenes en la red local o a través de Internet.



## 4. Sistema de detección de plagas del cultivo en imágenes aplicando Deep Learning

### 4.1 Arquitectura de la red neuronal convolucional



- Capa de entrada de imagen (*Image input layer*)
- Capa convolucional (*Convolutional Layer*)
- Capa de unidad lineal rectificada - *Rectified linear unit (ReLU)*
- Capa de agrupación (*Pooling*)
- Capa totalmente conectada (*Fully Connected Layer*)
- *Softmax layer*
- Capa de clasificación (*Classification layer*)



## 4. Sistema de detección de plagas del cultivo en imágenes aplicando Deep Learning

### 4.2 Obtención del dataset para entrenar el modelo

Fresa sana:



Fresa con plaga:



Manzano sano:



Manzano  
con plaga:



## 4. Sistema de detección de plagas del cultivo en imágenes aplicando Deep Learning

### 4.3 Entrenamiento del modelo



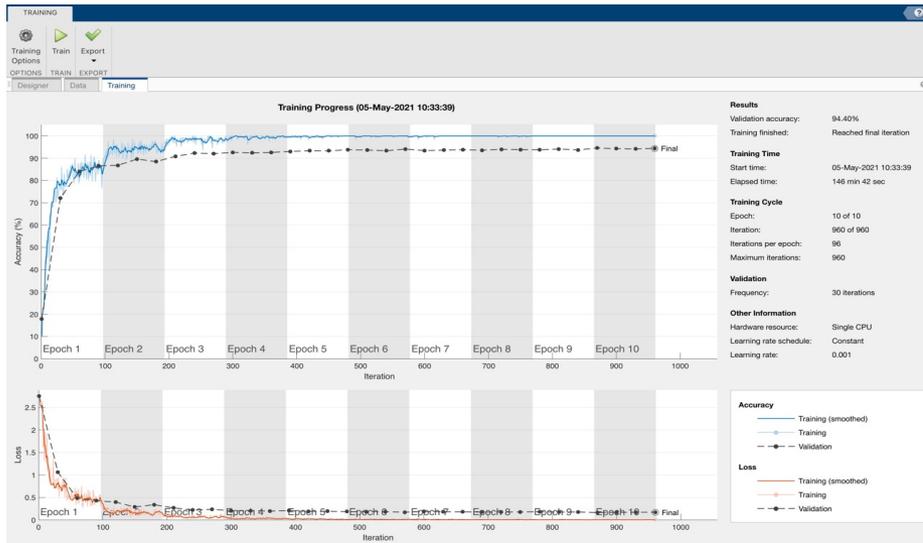
#### Parámetros de entrenamiento:

- Tasa de aprendizaje inicial
- Número máximo de épocas
- Tamaño de mini lote (*Mini batch size*)
- Datos de validación
- Frecuencia de validación



# 4. Sistema de detección de plagas del cultivo en imágenes aplicando Deep Learning

## 4.3 Entrenamiento del modelo



Gráfica de progreso de entrenamiento

**Confusion Matrix**

Output Class	Fresa - Oídio	Fresa sana	Manzana - Oxido del cedro y manzano	Manzana - Podredumbre negra	Manzana - Sarna del manzano	Manzana sana	Melocotón - Mancha bacteriana	Melocotón sano	Patata - Tizón tardío	Patata - Tizón temprano	Patata sana	Target Class
Fresa - Oídio	365 8.8%	0 0.0%	0 0.0%	0 0.0%	1 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	3 0.1%	0 0.0%	98.6% 1.4%
Fresa sana	4 0.1%	372 9.0%	0 0.0%	10 0.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.1%	95.9% 4.1%
Manzana - Oxido del cedro y manzano	0 0.0%	0 0.0%	368 8.9%	0 0.0%	1 0.0%	1 0.0%	2 0.0%	2 0.0%	0 0.0%	0 0.0%	4 0.1%	97.4% 2.6%
Manzana - Podredumbre negra	0 0.0%	1 0.0%	0 0.0%	336 8.1%	9 0.2%	1 0.0%	0 0.0%	0 0.0%	2 0.0%	0 0.0%	3 0.1%	95.5% 4.5%
Manzana - Sarna del manzano	0 0.0%	2 0.0%	5 0.1%	5 0.1%	353 8.6%	1 0.0%	4 0.1%	0 0.0%	0 0.0%	2 0.0%	1 0.0%	94.1% 5.9%
Manzana sana	1 0.0%	0 0.0%	0 0.0%	3 0.1%	3 0.1%	355 8.6%	5 0.1%	1 0.0%	14 0.3%	1 0.0%	8 0.2%	90.8% 9.2%
Melocotón - Mancha bacteriana	1 0.0%	0 0.0%	1 0.0%	0 0.0%	4 0.1%	2 0.0%	351 8.5%	0 0.0%	5 0.1%	0 0.0%	0 0.0%	96.4% 3.6%
Melocotón sano	0 0.0%	0 0.0%	1 0.0%	12 0.3%	0 0.0%	10 0.2%	2 0.0%	370 9.0%	0 0.0%	0 0.0%	2 0.0%	93.2% 6.8%
Patata - Tizón tardío	0 0.0%	0 0.0%	0 0.0%	2 0.0%	2 0.0%	2 0.0%	10 0.2%	0 0.0%	347 8.4%	7 0.2%	16 0.4%	89.9% 10.1%
Patata - Tizón temprano	4 0.1%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	0 0.0%	0 0.0%	1 0.0%	3 0.1%	363 8.8%	4 0.1%	96.3% 3.7%
Patata sana	0 0.0%	0 0.0%	0 0.0%	7 0.2%	0 0.0%	2 0.0%	1 0.0%	1 0.0%	2 0.0%	0 0.0%	334 8.1%	96.3% 3.7%
	97.3% 2.7%	99.2% 0.8%	98.1% 1.9%	89.6% 10.4%	94.1% 5.9%	94.7% 5.3%	93.6% 6.4%	98.7% 1.3%	92.5% 7.5%	96.8% 3.2%	89.1% 10.9%	94.9% 5.1%

Matriz de confusión

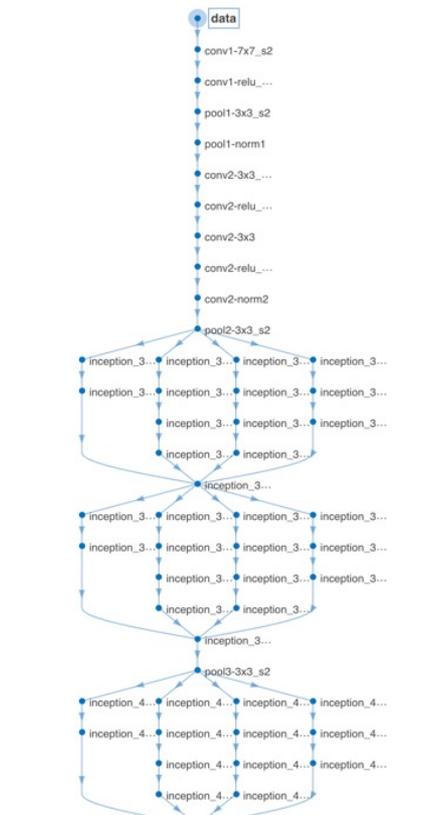


# 4. Sistema de detección de plagas del cultivo en imágenes aplicando Deep Learning

## 4.4 Resultados obtenidos

- Pruebas realizadas con 3 datasets de tamaño diferente
- Comparación red neuronal simple vs redes neuronales preentrenadas (SqueezeNet y GoogleNet) mediante transferencia del aprendizaje

Tipo de red neuronal		Red neuronal simple	SqueezeNet	GoogleNet
Número de capas		15	68	144
Tasa de aprendizaje inicial		0.01	0.0003	0.0003
Número de épocas		6	6	6
Precisión de validación	Dataset 11/100	9.09%	72.73%	87.58%
	Dataset 11/500	28.9%	92.36%	96.06%
	Dataset 11/1500	12.02%	96.65%	95.90%



Extracto de la red neuronal Googlenet



## 4. Sistema de detección de plagas del cultivo en imágenes aplicando Deep Learning

### 4.4 Resultados obtenidos

- Resultados obtenidos red neuronal simple al realizar los ajustes de entrenamiento
- Ajustes tasa de aprendizaje inicial y número de épocas

		Red Neuronal Simple			
<b>Tasa de aprendizaje inicial</b>		0.01		0.001	
<b>Frecuencia de validación</b>		30		30	
<b>Número de épocas</b>		6	10	6	10
<b>Precisión de validación</b>	Dataset 11/100	9.09%	10.18%	81.82%	79.27%
	Dataset 11/500	28.9%	24.73%	89.96%	88.29%
	Dataset 11/1500	12.02%	67.76%	91.81%	94.88%



# Video simulación

The screenshot displays the MATLAB R2019b environment. The main window shows the script 'Final\_test\_trained\_network.m' with the following code:

```

3
4 %testear la red entrenada con nuevas imagenes de test
5 load('TrainedNetwork.mat')
6 imdsTest = imageDatastore('test');
7
8
9 %clasificamos las imagenes de test con la red entrenada trainedNetwork_1
10 [YPred,probs] = classify(trainedNetwork_1,imdsTest);
11
12 %se muestran 25 imagenes aleatorias y su clasificacion
13
14 idx = randperm(numel(imdsTest.Files),16);
15
16 |
17 figure
18 for i = 1:16
19     subplot(4,4,i)
20     I = readimage(imdsTest,idx(i));
21     imshow(I)
22     label = YPred(idx(i));
23
24 %extraemos el nombre real de la imagen
25 fullFileNames = vertcat(imdsTest.Files(idx(i)));
26 for k = 1 : length(fullFileNames)
27     [folder, baseFileNameNoExt, ext] = fileparts(fullFileNames{k});
28     end
29
30 title(['Categoría real:' + (baseFileNameNoExt)
31     ['Predicción: " + string(label) + ", " + num2str(100*max(probs(idx(i),:)),3) + '%']});
32 end
33

```

The Command Window at the bottom shows the prompt 'fx >>'.

The Workspace window on the right is empty, showing columns for Name and Value.

The status bar at the bottom indicates 'Ready', 'UTF-8', 'script', and 'Ln 16 Col 1'.

## 5. Conclusiones

- Diseño global de la arquitectura de un sistema de monitorización de un huerto inteligente desde un enfoque de agricultura de precisión e IoT.
- Análisis y diseño de los sistemas de monitorización (sensores, dron, cámaras), componentes y protocolos de comunicación.
- Implementación de sistema detector de plagas aplicando métodos de Deep Learning, entrenando redes neuronales convolucionales con imágenes de las hojas del cultivo.
- Comparación modelos de redes neuronales convolucionales simples y redes convolucionales profundas preentrenadas mediante transferencia de aprendizaje.
- Se han obtenido resultados satisfactorios al ajustar los parámetros de entrenamiento en la red neuronal simple con un número reducido de capas.
- Líneas futuras:
  - Implementación del detector de plagas en una aplicación móvil o software y optimización del modelo para detectar las hojas del cultivo en imágenes en movimiento.
  - Integrar los datos obtenidos por el sistema de detección de plagas con los datos del sistema de sensores para obtener posibles patrones ambientales que causen la aparición de plagas.
  - Sistema de riego automático y aplicación de fitosanitarios inteligente a partir de la información obtenida.

