

Diseño de posibles soluciones al problema identificado: Uso de redes neuronales convolucionales, *transfer learning* y *fine tuning* para la detección de especies invasoras en primeras etapas de germinación, crecimiento detección de deficiencia nutricionales, enfermedades y plagas en especies de plantas de páramo y uso de bosques aleatorios para condiciones óptimas en etapa de rustificación

Equipo TerraVerde

Reto Presencial Hackathon GemaLab - Bogotá D.C

Formulación del problema:

El proceso de reforestación de los páramos consta de varias etapas clave. La primera etapa ocurre en los viveros, donde se plantan las semillas y se realiza un seguimiento detallado del proceso de germinación. Durante las primeras semanas de crecimiento, es crucial seleccionar el sustrato adecuado y detectar plántulas de especies no deseadas que puedan competir por nutrientes con las especies deseadas. En la segunda etapa, conocida como la fase de rustificación, se busca que las plantas, después del primer mes desde su germinación, se adapten gradualmente a condiciones menos favorables, preparando su futura adaptación al ecosistema de páramos, aunque manteniendo el ambiente necesario para un crecimiento saludable.

Finalmente, en la tercera etapa, una vez que las plantas son introducidas al ecosistema de los páramos, es necesario llevar un seguimiento continuo. Los operarios deben ser capaces de monitorear de manera eficiente el estado de las plantas, identificando si cuentan con los nutrientes adecuados y detectando posibles plagas o enfermedades.

Objetivo general:

Incorporar capacidades avanzadas de análisis de datos y pronósticos para optimizar el proceso de propagación y asegurar la viabilidad de las plantas.

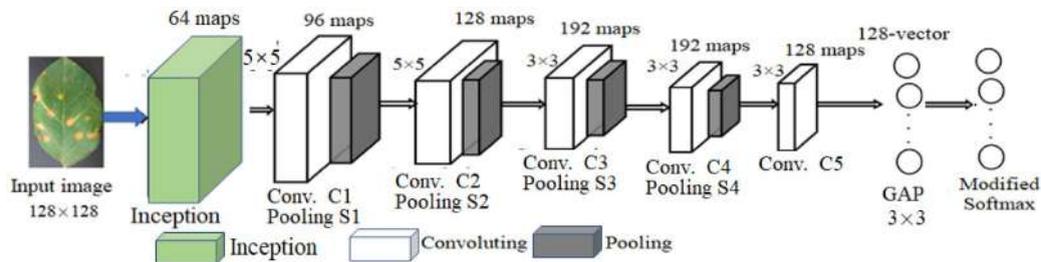
Objetivo específicos:

1. Desarrollar un sistema de identificación automática de plántulas e invasoras utilizando técnicas de visión por computadora, con el fin de diferenciar las especies deseadas de las plantas invasoras en los viveros.
2. Implementar un modelo predictivo basado en bosques aleatorios que analice las condiciones ambientales (temperatura, humedad, pH y características del suelo) para evaluar la viabilidad del crecimiento y desarrollo de las plantas en la etapa de endurecimiento y rustificación.
3. Diseñar un sistema de monitoreo continuo mediante visión por computadora e inteligencia artificial para identificar deficiencias nutricionales, plagas y enfermedades en las plantas reforestadas, proporcionando recomendaciones oportunas para el manejo y cuidado de las especies en el ecosistema.

Introducción:

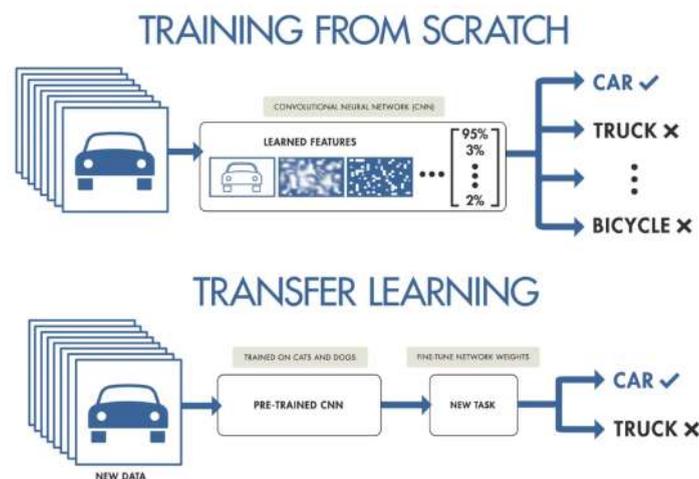
Las redes neuronales convolucionales (CNN) se han demostrado como herramientas altamente efectivas para el reconocimiento de patrones en imágenes y problemas de visión por computadora.

Estas redes son ampliamente utilizadas en diversos campos, incluyendo la robótica, la ingeniería, y en aplicaciones específicas como la agricultura y la conservación de especies [1]. La imagen a continuación ilustra una arquitectura particular de una CNN diseñada para la detección de enfermedades en plantas. Esta arquitectura transforma la información visual en un espacio latente de características, que luego es procesado por un perceptrón multicapa para realizar la clasificación mediante una función de activación Softmax.



Fuente: [2] (Jing, 2022)

Aunque es posible construir redes neuronales desde cero, no siempre es lo más conveniente dado que existen redes pre entrenadas, como Inception V3 de Google, que son ampliamente utilizadas. En este caso, hemos optado por Inception V3 debido a su versatilidad y capacidad para adaptarse al prototipo que estamos desarrollando para resolver el problema planteado. Así, la red neuronal que se construye para la detección de enfermedades, plagas y deficiencias de nutrientes se basa en esta red pre entrenada y ha sido ajustada con una base de datos específica de plantas. La técnica basada en el uso de redes pre entrenadas se conoce como *Transfer Learning* y permite que nuestro modelo aprenda mejor sus tareas de reconocimiento en menos tiempo y con menos recursos.



Fuente:

<https://purnasaigudikandula.medium.com/deep-view-on-transfer-learning-with-image-classification-pytorch-5cf963939575>

La base de datos utilizada en este prototipo para entrenar las redes neuronales convolucionales es un conjunto de datos abierto titulado "An Open Leaf Image Dataset for Plant Stress Recognition," disponible en [3].

Primer servicio: etapa de identificación de plántulas invasoras

Este primer servicio, busca mejorar el crecimiento de las plántulas y la implementación de un mecanismo para distinguir entre plantas invasoras y las especies que se desea producir. Para esto, se pueden emplear técnicas de visión por computadora para la identificación de las especies, basadas en imágenes. Al entrenar un modelo de aprendizaje automático con imágenes de las diferentes plantas, el sistema tendrá la capacidad de reconocer de manera automática las especies invasoras.



modelo entrenado: [seedling_image_detection.keras](#)

clases = ["Alopecurus myosuroides", "Apera spica-venti", "Beta vulgaris",
"Capsella bursa-pastoris", "Chenopodium album", "Galium aparine",
"Geranium pusillum", "Matricaria perforata", "Sinapis arvensis",
"Stellaria media", "Triticum aestivum", "Zea mays", "No invasora"]

Segundo servicio: Condiciones ajustables en etapa de endurecimiento y rustificación

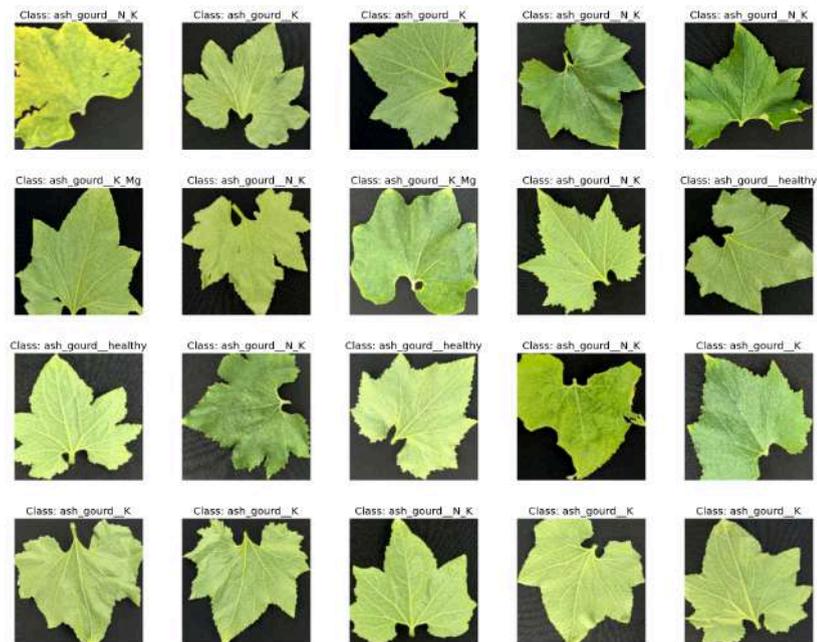
En la segunda etapa, el objetivo es preparar a las plantas para condiciones más adversas mediante la evaluación de variables ambientales como temperatura, suelo, humedad y pH. El uso de un modelo de bosques aleatorios resulta adecuado para analizar múltiples variables y evaluar la viabilidad del crecimiento de las plantas en diferentes condiciones. Este modelo puede alimentarse con datos históricos y de sensores para realizar predicciones y tomar decisiones informadas sobre el momento y lugar más óptimos para la plantación.

modelo entrenado: [modelo_prediccion_viabilidad.pkl](#)

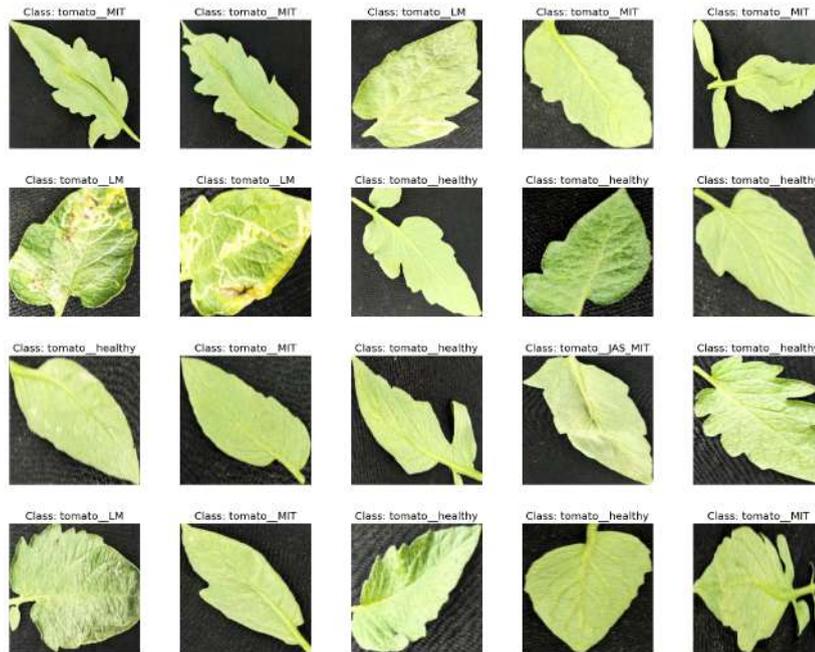
Tercer servicio: Seguimiento de las plantas ya introducidas en el ecosistema

En este servicio se busca una automatización de los procesos de identificación de plantas, de sus necesidades nutricionales y hacer un seguimiento a posibles enfermedades y plagas.

1. Deficiencias nutricionales: Las deficiencias nutricionales se identifican mediante el análisis del color de las hojas y los patrones de crecimiento. La imagen siguiente muestra hojas de una planta de calabaza del conjunto de datos de entrenamiento [3], que ilustran tres tipos distintos de deficiencias de nutrientes: nitrógeno, magnesio y potasio.



2. Plagas y enfermedades: La identificación se realiza mediante el análisis de patrones en las hojas. La imagen siguiente muestra hojas de una planta de tomate del conjunto de datos de entrenamiento [3], destacando hojas afectadas por tres tipos distintos de plagas: "Chicharrita," "Minador de hojas," y "Ácaro," así como hojas de plantas sin plagas reconocibles.



El sistema procesa estas imágenes ofreciendo sugerencias o recomendaciones a los encargados de las operaciones, como qué nutrientes aportar o qué medidas tomar frente a una plaga.

3. Reconocimiento de especies: reconocimiento de familia de especies en el ecosistema de páramos [4]. En la imagen siguiente se muestran 8 especies diferentes de páramo. El modelo fue entrenado con diversas imágenes tomadas de internet y en portales nacionales.

ageratina fastigiata	buddleja bullata	escallonia myrtilloides	escallonia paniculata
			
morella pubescens	polylepis quadrijuga	vallea stipularis	weinmannia tomentosa



4. Reconocimiento de deficiencia de nutrientes de acuerdo a las hojas. Las plantas necesitan diferentes cantidades de nutrientes, que se dividen en macronutrientes y micronutrientes. Los macronutrientes son necesarios en mayores cantidades en comparación con los micronutrientes, ya que son fundamentales para el desarrollo celular y tisular de las plantas. Los macronutrientes incluyen nitrógeno (N), fósforo (P), potasio (K), calcio (Ca), azufre (S) y magnesio (Mg). En cambio, los micronutrientes, que se requieren en menores cantidades, abarcan hierro (Fe), zinc (Zn), cobre (Cu) y manganeso (Mn).

La deficiencia de macronutrientes puede afectar el crecimiento de las hojas y provocar una interrupción en la formación de alimentos, lo que contribuye a trastornos del crecimiento como el enanismo de las plantas, así como una mala floración y fructificación. Los síntomas de deficiencia de nutrientes suelen aparecer de inmediato en el color de las hojas y el crecimiento del follaje. Los detalles específicos de estos síntomas se presentan en la siguiente tabla.

Macronutrientes	Síntomas
Nitrógeno (N)	Verde claro en las hojas superiores y amarillo en las hojas inferiores.
Potasio (K)	Hojas amarillas y moradas con bordes marrones y mala floración y fructificación.
Fósforo (P)	Crecimiento lento y follaje amarillo.
Magnesio (Mg)	Amarillo entre las venas de las hojas con tintes marrón rojizo y caída prematura de las hojas.



Ejemplo de deficiencia de nutriente en hojas de árbol de frijol negro [5]

modelos entrenados: [nutrient_deficiency_detection.h5](#), [diseases_detection.keras](#)

```
familias_plantas = [  
    "Rosaceae",      # Polylepis quadrijuga  
    "Myricaceae",   # Morella pubescens  
    "Asteraceae",   # Ageratina fastigiata  
    "Scrophulariaceae", # Buddleja bullata  
    "Elaeocarpaceae", # Vallea stipularis  
    "Escalloniaceae", # Escallonia paniculata  
    "Cunoniaceae"   # Weinmannia tomentosa  
    ]
```

```
clases_nutrientes = [  
    "Deficiencia de Potasio (K)",  
    "Deficiencia de Magnesio (Mg)",  
    "Deficiencia de Nitrogeno (N)",  
    "Planta sin deficiencia nutricional reconocible"]
```

```
clases_plagas = [  
    "Chicharrita",  
    "Minador de hojas",  
    "Ácaro",  
    "Planta sin plagas reconocibles"]
```

Referencias:

- [1] Watchareeruetai, U., Noinongyao, P., Wattanapaiboonsuk, C., Khantiviriya, P., & Duangsrissai, S. (2018). *Identification of plant nutrient deficiencies using convolutional neural networks*. In *2018 International Electrical Engineering Congress (iEECON)*. <https://doi.org/10.1109/ieecon.2018.8712217>
- [2] Li, P., Jing, R., & Shi, X. (2022). *Apple disease recognition based on convolutional neural networks with modified softmax*. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.820146>
- [3] Orka NA, Uddin MN, Toushique FM, Hossain MS. OLID I: an open leaf image dataset for plant stress recognition. *Front Plant Sci*. 2023 Sep 12;14:1251888. doi: 10.3389/fpls.2023.1251888. PMID: 37771492; PMCID: PMC10523147.
- [4] Vargas Ríos, O., Angulo, A., Nieves, L., & Rodríguez, L. H. (2021). *Propagación y manejo de plantas nativas para la restauración ecológica del páramo y bosque altoandino*. Universidad Nacional de Colombia y Terra Integrity.
- [5] vi, L.A., Agung, A., Gunawan, S., Qurania, A., Harsani, P., Tarawan, F., & Hermawan, R. (2019). *plant nutrient deficiency detection using deep convolutional neural network*. <https://core.ac.uk/download/pdf/322855101.pdf>