

Modelos de Machine learning para predecir la gravedad del Marchitamiento y secado anticipado del girasol (*Verticillium dahliae*) mediante índices espectrales

Dillchneider A.^{1*}, Colombo, D.N.¹, Corró Molas, A.², Dominguez, M.³

¹ EEA “Guillermo Covas” INTA Anguil. Ruta Nacional N°5 km 580, Anguil, 6326, La Pampa, Argentina. dillchneider.a@inta.gob.ar

² AER INTA Gral. Pico. Calle 13, N°857, General Pico, 6360, La Pampa, Argentina / Fac. Agronomía UNLPam, Ruta Nacional N°35 km 334, Santa Rosa, 6300, La Pampa, Argentina.

³ EEA Pergamino. Ruta 32 km 4,5, Pergamino, 2700, Buenos Aires.

Los sensores remotos surgen como una herramienta que facilita la obtención de datos de evaluación de enfermedades y características fisiológicas en los cultivos.

El objetivo fue determinar el nivel de síntomas causados por *Verticillium dahliae* (*Vd*) en un grupo de líneas F5 de una población MAGIC de girasol mediante bandas e índices espectrales utilizando sensores remotos en Vant (Vehículos aéreos no tripulados).

Se sembraron 80 líneas MAGIC F5 y 20 surcos de testigo susceptible para *Vd* en 2 repeticiones de surcos de 5 m distanciados a 0.52 m. en la EEA INTA Anguil. En cada surco se cuantificó la incidencia (% de plantas con enfermedad) y la severidad (% de síntomas causados *Vd* de cada planta) (Bertero y Vázquez, 1985) de *Vd* en los estados fenológicos R1, R3, R5 y R7 (Schneiter & Miller, 1981). Al mismo tiempo se tomaron imágenes con un drone Phantom 4 con cámara multiespectral, que colecta datos de reflectancia del azul, verde, rojo, borde rojo e infrarrojo cercano, con un solapamiento del 70 % y a una altura de 40 m. Se realizó el ortomosaico con el software Agisoft Metashape. Se calcularon índices de vegetación mediante la combinación de las diferentes bandas espectrales.



Figuras. Síntomas de marchitamiento por *Verticillium dahliae* en girasol.



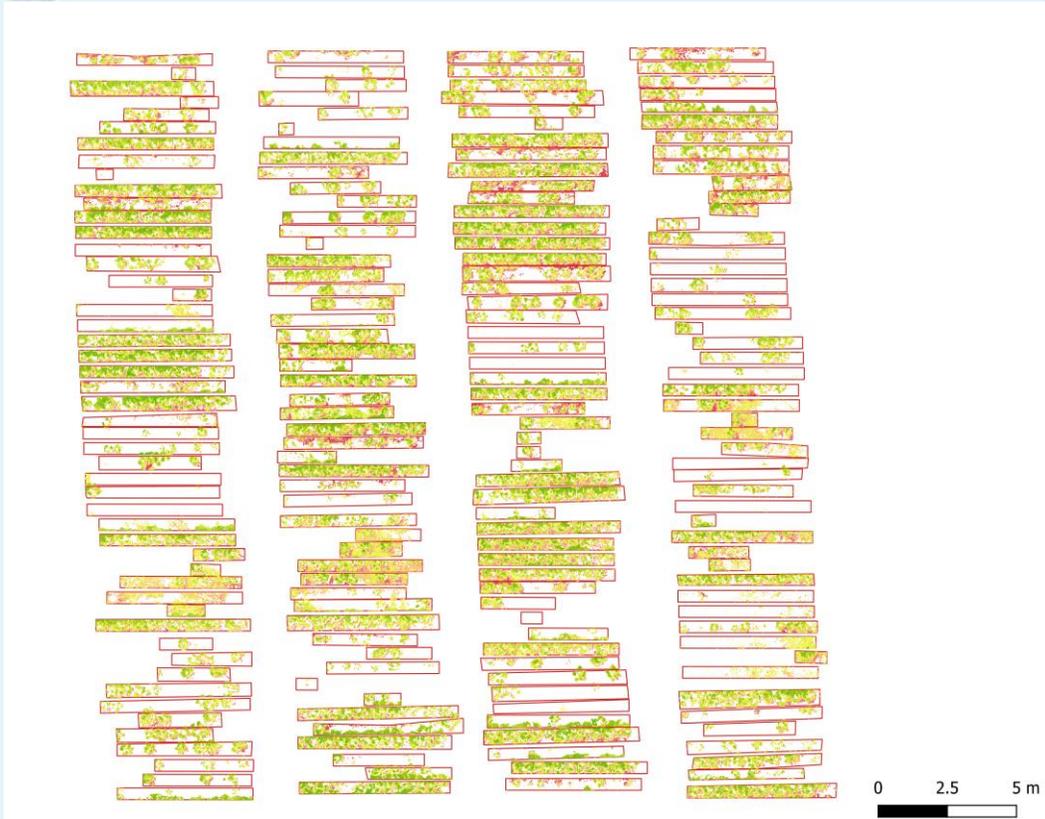


Figura 1. Líneas experimentales con la aplicación de máscara de vuelo para extracción de bandas espectrales.

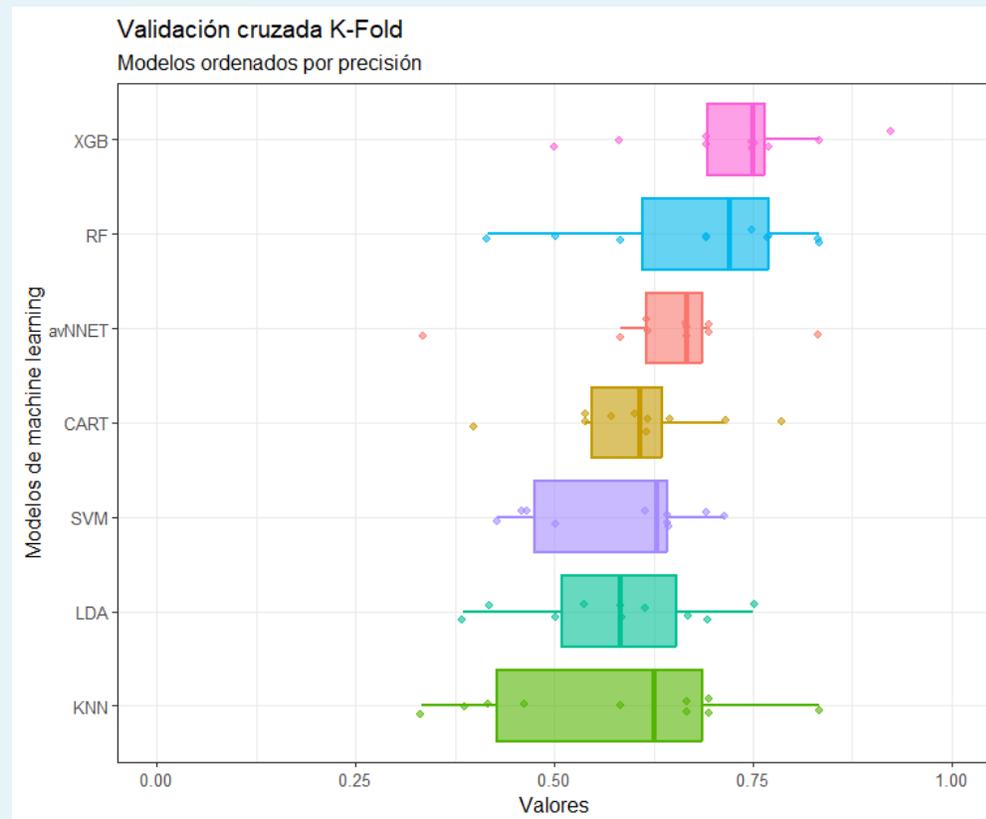


Figura 2. Comparación de modelos de machine learning empleados en función de su precisión en la predicción

Se calcularon los índices de NDVI, GNDVI, EVI, NDRE, GRVI, GLI, PSRI, DVI, VARI y CIRE para cada vuelo.

Los modelos más precisos fueron RF y XGB con una precisión de la predicción de la categoría fenotípica de cada surco por encima del 65 % (Figura 2). Estos resultados muestran la capacidad y el potencial que tiene la implementación de drones con cámaras multispectrales como herramienta de asistencia al fenotipado de *Vd* en girasol.