



## PREDICCIÓN EN CAMPAÑA DE RENDIMIENTO DE BIOMASA EN MAÍZ MEDIANTE SENSORES REMOTOS

**Rossetti, María Lara<sup>1</sup>**

*<sup>1</sup>Facultad de Ciencias Agrarias-UNL*

*Director: Alesso, Agustín*

*Codirector: Bortoluzzi, Andrés*

*Área: Ciencias Naturales*


Palabras claves: imágenes satelitales, modelos estadísticos, mapas de rendimiento.

### INTRODUCCIÓN

Las reservas forrajeras, especialmente el silaje de maíz, son herramientas claves en los sistemas ganaderos para reducir el impacto de la variación estacional de la oferta forrajera, así como también, dependiendo del nivel de intensificación, aumentar la producción individual y/o global de leche y carne en los sistemas de explotación bovina. Desde el punto de vista de las empresas que confeccionan las reservas forrajeras, i.e. proveedoras de servicio de picado y embutido, la planificación logística y determinación del costo del servicio de confección de silo depende en gran parte de las expectativas de rendimiento del cultivo a ensilar. La estimación global y distribución espacial de la cantidad de forraje a picar y transportar, y el rendimiento grano es información valiosa para la optimización del proceso de confección de reservas. Actualmente, con el avance de la Agricultura de Precisión, existen en el mercado sistemas de mapeo de rendimiento tanto para cultivos de grano como forraje. Asimismo, existen disponibles imágenes satelitales de alta resolución espacial y temporal que proveen información sobre el estado del cultivo. La aplicación de técnicas de aprendizaje estadístico a conjuntos de datos espaciales de rendimiento (respuesta) y vigor de cultivo en campaña (predictores) puede ayudar a desarrollar modelos predictivos de rendimiento en campaña.

### OBJETIVOS

- Desarrollar un modelo estadístico para predecir en campaña la biomasa del cultivo de maíz para silo que sirva como fuente de información para la toma de decisiones de una empresa de picado.



Título del proyecto: Desarrollo de un método de estimación de la biomasa y rendimiento en grano del cultivo de maíz mediante técnicas de sensoramiento remoto para la optimización de la confección de silaje

Instrumento: IAP

Año convocatoria: 2017

Organismo financiador: Asactei

Director/a: Alesso, Agustín

## METODOLOGÍA

Se seleccionaron 19 y 20 lotes de maíz de primera y segunda, respectivamente, destinados a reserva forrajera correspondientes a las campañas 2017/18 y 2018/19. Los lotes fueron elegidos según criterios de disponibilidad de información sobre la fecha de siembra, condiciones de picado normales y disponibilidad de datos de rendimiento. Las estimaciones de rendimiento se recolectaron utilizando el sistema de sensado de rendimiento de la plataforma TeleMatics de CLAAS. Los datos brutos fueron filtrados para descartar datos extraños de los componentes de rendimiento, i.e. velocidad, materia seca, flujo; así como outliers distribucionales y espaciales de rendimiento.

Para cada lote seleccionado se adquirió la información multiespectral de sensores remotos montados en la plataforma satelital Sentinel-2 de la Agencia Espacial Europea (Delwart, 2015). Cada imagen multiespectral está compuesta de 13 bandas espectrales, siendo útiles para este trabajo solo las bandas 2, 3, 4 y 8 con resolución espacial de 10 m que detectan en intensidades 490 (azul), 560 (verde), 665 (rojo) y 842 (infra rojo cercano). Se procesaron en total 150 imágenes satelitales correspondientes a al período Septiembre-Marzo de las campañas 2017/18 y 2018/19. Sólo se consideraron las imágenes con menos de 30% de nubosidad. Para cada imagen se calcularon distintos índices espectrales: NG, NR, RVI, GRVI, NDVI, GNDVI, SAVI y GSAVI (Bannari et al, 1995).

Se estimó la fenología del cultivo en cada imagen calculando sumas térmicas a partir de la fecha de siembra y datos meteorológicos de la estación EEA Rafaela mediante la siguiente fórmula:

$$\text{Grados día acumulados} = \sum T^{\circ} b - T^{\circ} me$$

Donde:

$T^{\circ} b$  = temperatura a partir de la cual el cultivo activa su desarrollo. En maíz corresponde a 8°C.

$T^{\circ} me$  = temperatura media diaria que se calcula según la  $T^{\circ}$  máx y  $T^{\circ}$  min.

Finalmente, se compuso una base de datos con los datos de rendimiento e índices espectrales y sumas térmicas dentro de cada lote. Dicho conjunto de datos se dividió en entrenamiento y validación. Se ajustaron modelos predictivos de rendimiento utilizando el algoritmo Random Forest, (James et al. 2013) con el conjunto de datos de entrenamiento. Los modelos se estimaron para cada cultivo (maíz de primer y segunda) y rangos de grados día. 500-800°C día, 800-1000 °C día y más de 1000 °C día. En cada caso se modelaron las dos campañas en conjunto y por separado. Utilizando los datos del subconjunto de validación se calcularon métricas de bondad de ajuste, capacidad predictiva de los modelos e importancia de las variables. La manipulación de datos y análisis se realizó utilizando el sistema de información geográfico QGIS (QGIS Development Team, 2019) y el software estadístico R (R Core Team, 2019).

## CONCLUSIONES

Las campañas de 2017/18 y 2018/19 se caracterizaron por tener condiciones climáticas muy diferentes. En la primera campaña las precipitaciones fueron escasas, con un déficit marcado en los meses estivales, de gran importancia para el crecimiento del cultivo. En cambio, en la campaña 2018/19 las precipitaciones superaron lo normal en la época primavero-estival, lo que conllevó a alcanzar altos rendimientos de biomasa pero con dificultades para cosechar el cultivo en momento óptimo.

En las tablas 1 y 2 se presentan los resultados de la validación de los modelos según clase de sumas térmicas y campaña para cultivos de primera y segunda respectivamente. En general el nivel de precisión alcanzado por los modelos en ambos cultivos fue moderado a bajo. Para maíces de primera la máxima precisión relativa de 24% y en cultivos de segunda del 20%. En el cultivo de primera, el mejor modelo se obtuvo para la clase de sumas térmicas > 1000, con un error de predicción de 9.87 tn ha<sup>-1</sup> para ambas campañas. Para demostrar gráficamente, se puede observar en la figura N° 1 la relación entre rendimientos predichos y observados, con una alta dispersión y una baja correlación entre ambos (la recta azul se aleja de la recta roja) la cual es menor en la campaña 2017/18. En el caso de los cultivos de segunda, los resultados demuestran que la mejor predicción coincidió con el rango de 800-1000 para ambas campañas.

Tablas N° 1 y 2: “Error medio de predicción (absoluto y relativo), correlación lineal entre observados y predichos y sesgo de los modelos de predicción para maíz de primera(izq.) y maíz de segunda(der.)”

Clase	Campaña	RMSE	RMSE rel	r	Sesgo	Clase	Campaña	RMSE	RMSE rel	r	Sesgo
500-800	2017/18	12.49	0.40	0.20	-5.17	500-800	2017/18	9.52	0.23	0.54	-0.66
500-800	2018/19	8.85	0.19	0.28	2.41	500-800	2018/19	7.62	0.19	0.49	0.19
800-1000	2017/18	13.24	0.45	0.21	-5.95	800-1000	2017/18	9.46	0.21	0.39	3.44
800-1000	2018/19	8.92	0.19	0.41	2.41	800-1000	2018/19	7.50	0.19	0.56	-0.31
>1000	2017/18	11.98	0.39	0.30	-5.33	>1000	2017/18	9.17	0.22	0.60	1.32
>1000	2018/19	8.79	0.19	0.38	2.46	>1000	2018/19	8.54	0.21	0.36	-1.11
500-800	ambas	10.04	0.24	0.46	0.21	500-800	ambas	8.06	0.20	0.50	0.01
800-1000	ambas	10.30	0.25	0.53	0.10	800-1000	ambas	7.79	0.20	0.55	0.19
>1000	ambas	9.87	0.24	0.52	0.10	>1000	ambas	8.86	0.22	0.51	0.10




Figura N° 1: “Correlación entre rendimientos observados y predichos en ambas campañas para maíz de 1° con sumas térmicas >1000”

## BIBLIOGRAFÍA BÁSICA

Bannari, A., D. Morin, F. Bonn, y A. R. Huete. «A Review of Vegetation Indices». *Remote Sensing Reviews* 13, n.º 1-2 (agosto de 1995): 95-120.  
<https://doi.org/10.1080/02757259509532298>.

Teal, R. K., B. Tubana, K. Girma, K. W. Freeman, D. B. Arnall, O. Walsh, y W. R. Raun. «In-Season Prediction of Corn Grain Yield Potential Using Normalized Difference Vegetation Index». *Agronomy Journal* 98, n.º 6 (2006): 1488. <https://doi.org/10.2134/agronj2006.0103>.

James, Gareth, Daniela Witten, Trevor Hastie, y Robert Tibshirani. *An Introduction to Statistical Learning*. Vol. 103. Springer Texts in Statistics. New York, NY: Springer New York, 2013.  
<https://doi.org/10.1007/978-1-4614-7138-7>.