

“Análisis predictivo de lotes agrícolas para la siembra de soja”

Luca Mavolo (lucamavolo@gmail.com), Universidad Tecnológica Nacional; Daniel Xodo (daniel.xodo@gmail.com), Universidad Tecnológica Nacional; Pablo Antonio Mavolo (pmavolo@gmail.com), Universidad Tecnológica Nacional

Resumen

Problema y justificación, determinar el posible rendimiento de un lote agrícola en campos de gran extensión donde varía en gran medida la calidad de suelo y los escenarios climáticos año a año, dificultando una estrategia de siembra óptima. Objetivo, predecir 8 escenarios con el modelo de red neuronal a utilizar y estudiar la solidez del modelo. Luego predecir 7 escenarios viables para lograr una estrategia de siembra con asignación de lotes y tipos de semilla. Por último realizar una predicción a modo de prueba usando el promedio histórico de lluvia en los meses estudiados y observar las variaciones en los rindes de acuerdo a las predicciones anteriores. Método utilizado, es un modelo de Red Neuronal, brindado por el soft RISK Industrial 7.6 (complemento Neural Tools). Resultado: se compara con los datos relevados de los lotes pertenecientes a la empresa “Nueva Castilla” de Trenque Lauquen, Buenos Aires, Argentina, donde se tiene información de más de 17 años de datos climáticos, suelos y rendimientos cosecha de soja con distintos tipos de semilla, para determinar la viabilidad técnica y práctica del modelo.

Palabras clave: Red Neuronal; Soja (glycine max); precipitaciones; pronóstico rindes.

Antecedentes:

La estimación de la producción agrícola es necesaria para la planificación que deben realizar tanto los actores públicos como privados; desde una alerta temprana de la seguridad alimentaria y la sustentabilidad ambiental hasta en el plano científico la validación de modelos biofísicos de cultivos (Lyle, G 2013). La información confiable, anticipada y oportuna de rendimiento de los cultivos tiene influencia en la gestión de las actividades de cosecha, almacenamiento, importación/exportación, transporte y comercialización Lobell, D.B., (2003)

La agricultura extensiva es el principal uso productivo de la tierra en la zona central de Argentina y una de las mayores fuentes de ingresos económicos. Los cultivos de soja (*Glycine max* (L.) Merrill) y maíz (*Zea mays* L.) constituyen la principal actividad agrícola en la campaña de verano, alcanzando alrededor del 86% del área total sembrada en Argentina. Dentro de estos cultivos se destaca la soja, con 19.781.812 ha sembradas en la campaña 2013/2014, en particular, en la provincia de Córdoba se sembraron aproximadamente el 26% del total del país MINAGRI (2015)

En los últimos años información a priori de rendimiento se produce, generalmente, a partir de modelos, ya sea con información sobre el manejo del cultivo, datos del clima y de suelo, entre otros. Varios estudios demuestran el poder de los modelos de crecimiento de cultivos para predecir el rendimiento Batchelor, W.D (2002)

Las variaciones en el rendimiento de la soja son consecuencia de efectos del genotipo, del ambiente y de su interacción, siendo el efecto ambiental el que explica la mayor parte de estas variaciones. Las propiedades del suelo (físicas y químicas) en interacción con las variables meteorológicas (radiación, agua y regímenes térmicos) determinan diferentes ambientes para el cultivo de soja Salvagiotti, F . (2010).

Modelos matemáticos simples permiten describir adecuadamente el rendimiento a obtener en cultivos de soja y maíz a partir de imágenes satelitales obtenidas dos o tres meses anteriores a la cosecha. Mónica Bocco (2015)

El objetivo del proyecto es lograr a través de un modelo de inteligencia artificial, la predicción de rendimiento de soja en lotes conocidos y donde se tiene información relevada a lo largo del tiempo. Donde las variables fundamentales son las características del suelo, el tipo de semilla, fecha de siembra y las precipitaciones en los meses de desarrollo del cultivo.

Materiales y métodos:

Se utilizó para la predicción de rendimientos, el software NeuralTools (PALISADE) el cual es un complemento de Microsoft Excel de Redes Neuronales. Las Redes neuronales son capaces de descubrir automáticamente relaciones entrada-salida en función de datos empíricos, merced a su capacidad de aprendizaje a partir de ejemplos Bonifacio M (1994). La base de datos utilizada corresponde a una empresa agrícola de la ciudad de Trenque Lauquen, Buenos Aires Argentina. Donde se cuenta con el relevamiento de datos de siembra y cosecha de más de 17 años. La empresa identifica cada lote con un código interno, al cual se le asigna una característica A, B o C donde la misma corresponde a la calidad de suelo donde A reúne las características más ideales, como mayor composición de materia orgánica, tipo de relieve loma y en el otro extremo suelos tipo C donde son más arenosos y con relieves semi loma o bajos. También se identifican las precipitaciones en cada mes que afecta al desarrollo del cultivo desde el periodo de siembra hasta los meses próximos a la cosecha, el cultivo antecesor al periodo de siembra en cada lote, la fecha de

siembra ubicada en bloques de 10 días (ej 1- 10 de octubre), si el cultivo es de ciclo largo o corto y finalmente de la base de datos se seleccionaron dos tipos de semillas DM 3700 y DM 4800, dado que las mismas fueron ensayadas en una correlación mayor a 5 años y permite un análisis con mayor información para utilizar la red neuronal.

Base de datos a utilizar la red:

YEAR	CLASS	TYPE	CYCLE	CROP	ANT	DATE	Sept	Oct	Nov	Dec	Jan	Feb	March	KG/HA
2001/02	B	DM 4800	LARGO	MAIZ		21-31 OCT	214	128	277	53	163	5	311	2463
2001/02	C	DM 4800	LARGO	MAIZ		21-31 OCT	214	128	277	53	163	5	311	3128
2001/02	B	DM 4800	LARGO	MAIZ		21-31 OCT	214	128	277	53	163	5	311	3671
2001/02	A	DM 4800	LARGO	MAIZ		21-31 OCT	214	128	277	53	163	5	311	4512
2001/02	A	DM 4800	LARGO	MAIZ		21-31 OCT	214	128	277	53	163	5	311	3266
2001/02	A	DM 4800	LARGO	MAIZ		21-31 OCT	214	128	277	53	163	5	311	4058

Tabla 1 Campaña 2001/02

La base de datos posee 311 escenarios desde la campaña 2001/02 hasta 2015/16, donde varían los suelos, semillas y fechas de siembra, y factores externos que exceden la decisión del agricultor como las precipitaciones.

Resultados

Se realizaron 3 predicciones, para la primera predicción se simuló 8 escenarios para verificar la solidez del modelo, y donde se aceptaría la herramienta de trabajo para una variación menor 5-6% dado que son los márgenes aceptables desde el criterio agronómico para suelos del tipo A y donde se tiene más tolerancia para suelos B y C, donde al ser más pobres se tienen mayores variaciones en los rendimientos.

Test 1	A	DM 4800	LARGO	PAST	1-10 NOV	31	133	152	204	63	81	216
Test 2	B	DM 4800	LARGO	VI	21-31 OCT	50	71	21	8	157	65	84
Test 3	C	DM 4800	LARGO	PAST	1-10 NOV	50	71	21	8	157	65	84
Test 4	B	DM 4800	LARGO	SOJA	21-31 OCT	19	173	84	84	49	128	145
Test 5	B	DM 3700	CORTO	MAIZ	21-31 OCT	97	94	68	34	146	129	0
Test 6	A	DM 3700	CORTO	MAIZ	21-31 OCT	97	94	68	34	146	129	0
Test 7	C	DM 4800	LARGO	PAST	1-10 NOV	55	141	44	108	10	66	75
Test 8	C	DM 4800	LARGO	FINA/SOJA	21-30 NOV	45	58	118	39	33	117	75

Test 1	A	Predic	3997	98,58%
Test 2	B	Predic	2748	92,09%
Test 3	C	Predic	2097	93,19%
Test 4	B	Predic	1734	99,84%
Test 5	B	Predic	3225	92,38%
Test 6	A	Predic	3919	99,98%
Test 7	C	Predic	437	91,14%
Test 8	C	Predic	2784	99,57%

Tabla 2 Certeza del modelo

Como se observa en las tablas anteriores las predicciones realizadas en los lotes de suelo tipo A, se obtuvo una precisión del 98,58% y 99,98% siendo un modelo solido para la calidad requerida desde el criterio agronómico. Y la precisión en los suelos tipo B, varia del 92,09% hasta 99,84% teniendo mayor variación pero dentro de los márgenes tolerables, de igual forma sucede con los suelos tipo C variando desde 91,14% hasta 99,57%.

Una vez verificado el modelo se realizó la predicción de cultivo en escenarios reales para comparar con la campaña actual.

PREDIC 1	A	DM 3700	CORTO	MAIZ	21-31 OCT	66	45	87	78	172	79	85
PREDIC 2	B	DM 3700	CORTO	MAIZ	1-10 NOV	66	45	87	78	172	79	85
PREDIC 3	C	DM 3700	CORTO	MAIZ	21-31 DIC	66	45	87	78	172	79	85
PREDIC 4	A	DM 4800	LARGO	PAST	21-31 OCT	66	45	87	78	172	79	85
PREDIC 5	B	DM 4800	LARGO	PAST	1-10 NOV	66	45	87	78	172	79	85
PREDIC 6	C	DM 4800	LARGO	PAST	21-31 DIC	66	45	87	78	172	79	85
PREDIC 7	B	DM 3700	CORTO	Soja	1-10 NOV	66	45	87	78	172	79	85

PREDIC 1	A	21-31 OCT	DM 3700	3629
PREDIC 2	B	1-10 NOV	DM 3700	2856
PREDIC 3	C	21-31 DIC	DM 3700	2784
PREDIC 4	A	21-31 OCT	DM 4800	3605
PREDIC 5	B	1-10 NOV	DM 4800	2447
PREDIC 6	C	21-31 DIC	DM 4800	2087
PREDIC 7	B	1-10 NOV	DM 3700	2175

Tabla 3 Predicción del rendimiento del cultivo

También se planteó la posibilidad de lograr una predicción de rendimiento al momento de tomar la decisión de asignación de lotes para la siembra utilizando el promedio histórico de lluvias de cada mes para cada alternativa del agricultor.

El escenario que se planteo tiene las mismas condiciones donde se evaluo la solides del modelo de red neuronal. De esta forma se tiene un parámetro de comparación de los resultados obtenidos.

Test average 1	A	DM 4800	LARGO	PAST	1-10 NOV	49	94	90	93	93	84	116
Test average 2	B	DM 4800	LARGO	VI	21-31 OCT	49	94	90	93	93	84	116
Test average 3	C	DM 4800	LARGO	PAST	1-10 NOV	49	94	90	93	93	84	116
Test average 4	B	DM 4800	LARGO	SOJA	21-31 OCT	49	94	90	93	93	84	116
Test average 5	B	DM 3700	CORTO	MAIZ	21-31 OCT	49	94	90	93	93	84	116
Test average 6	A	DM 3700	CORTO	MAIZ	21-31 OCT	49	94	90	93	93	84	116
Test average 7	C	DM 4800	LARGO	PAST	1-10 NOV	49	94	90	93	93	84	116
Test average 8	C	DM 4800	LARGO	FINA/SOJA	21-30 NOV	49	94	90	93	93	84	116

		Model	Real
Test average 1	3435	83,63%	82,44%
Test average 2	3347	82,10%	75,61%
Test average 3	1707	77,15%	71,89%
Test average 4	3307	52,43%	52,35%
Test average 5	3394	95,02%	87,78%
Test average 6	3973	98,64%	98,62%
Test average 7	1707	25,60%	23,33%
Test average 8	2780	99,85%	99,42%

Tabla 4 Comparación de resultados

Discusión

Como se vio en la primera simulación se verifico que el modelo de red neuronal utilizado es sólido para la actividad que se quiere realizar. Teniendo una certeza que varía entre 1-2% para lotes tipo A donde los parámetros tolerables desde el criterio agronómico son 5-6%. Y para lotes tipo B o C donde la variabilidad es mayor por los paisajes y composición que los caracteriza varían entre el 2-8,86% cuando los márgenes tolerables para este tipo de suelo son entre el 19-15%.

De esta forma el modelo es sólido para los dos objetivos principales del proyecto, lograr un predicción real del cultivo soja para las posibles alternativas del agricultor y por otro lado simular escenarios donde se utilice el promedio histórico de precipitaciones para cada lote.

En la predicción de los cultivos de los 7 escenarios propuestos por el agricultor, se predijo un escenario para cada tipo de lote variando la fecha de siembra y el tipo de semilla a utilizar. En los lotes de tipo A se obtuvieron rendimientos de 3629 kg para la semilla DM 3700 y 3605kg para la semilla DM 4800 en el mismo periodo de siembra. Desde el punto de vista agronómico son resultados normales de acuerdo a las condiciones planteadas pero no excelente. Para los lotes tipo B se obtuvo 2175kg y 2856kg para la semilla DM3700 y 2447 kg para la semilla DM4800 en el mismo periodo de siembra, son rendimientos razonables y estables para las características del suelo. Por ultimo para los suelos tipo C se obtuvo 2784kg para la semilla DM3700 y 2087kg para la semilla DM4800 en el mismo periodo, donde el segundo rendimiento es coherente de acuerdo al tipo de suelo y el primer resultado es optimista de acuerdo a la calidad de suelo. La alta variabilidad entre un resultado y otro es que las características del suelo no permiten una estabilidad de rendimiento por tratarse de relieves donde coexisten pendientes o bajo inundables, y tipo de suelos arenosos. Los resultados bajo la inspección agronómica y experiencia de la empresa son coherentes.

Utilizando el promedio histórico de precipitaciones, el objetivo del modelo era obtener un rendimiento para alguno de los tipos de suelo y se comparó los resultados con los obtenidos en el testeo del modelo donde se verifico la certeza de la red neuronal (tabla 2) y luego con los escenarios reales. En los testeos 6 y 8 se obtuvo variaciones entre el 1-2% resultados ideales. Pero en el resto de los escenarios planteados se tienen variaciones desde 12,24-76,66%, como en la mayoría de los ensayos los resultados varían en gran medida, utilizar

los promedios históricos de precipitaciones vuelven inestable el modelo y no arroja resultados coherentes ni dentro de los márgenes agronómicos aceptables.

Conclusión

En el proyecto se observó la viabilidad de utilizar un modelo de red neuronal para predecir rendimientos agronómicos del cultivo soja. Para esto se debe contar con una base de datos extensa que permita entrenar el modelo para darle mayor solides. Las variaciones obtenidas siempre estuvieron dentro de los márgenes agronómicos aceptables por lo cual el modelo puede ser de gran utilidad para la empresa al momento de la toma de decisión en la asignación de lotes, tipo de semilla a utilizar y fecha para la realización de la siembra. Se descarta la utilización del promedio histórico de precipitaciones para evaluar escenarios de rendimientos para la toma de decisiones dado que presentan mucha variabilidad.

Se propone para futuros trabajos la posibilidad de utilizar un modelo de red neuronal en otro cultivo como lo es el maíz (*Zea mais*) donde las variaciones desde el punto de vista agronómico son mayores y para el agricultor presenta grandes dificultades lograr una estimación del rendimiento.

Bibliografía:

1. Lyle, G., Lewis, M., Ostendorf, B.: Testing the Temporal Ability of Landsat Imagery and Precision Agriculture Technology to Provide High Resolution Historical Estimates of Wheat Yield at the Farm Scale. *Remote Sens.* 5, 1549–1567 (2013)

Lobell, D.B., Asner, G.P., Ortiz-Monasterio, J.I., Benning, T.L.: Remote sensing of regional crop production in the Yaqui Valley, Mexico: Estimates and uncertainties. *Agr. Ecosyst. Environ.* 94, 205–220 (2003)

Ministerio de Agricultura Ganadería y Pesca, Estimaciones Agrícolas: Series Históricas, http://www.siia.gob.ar/sst_pcias/estima/estima.php (2015)

Batchelor, W.D., Basso, B., Paz, J.O.: Examples of strategies to analyze spatial and temporal yield variability using crop models. *Eur. J. Agron.* 18, 141–158 (2002)

Mónica Bocco¹, Silvina Sayago¹, Soraya Violini² y Enrique Willington¹ **Modelos simples para estimar rendimiento de cultivos agrícolas a partir de imágenes satelitales: una herramienta para la planificación** STS 2015, 2º Simposio Argentino sobre Tecnología y Sociedad.

Salvagiotti, F., Enrico, J., Bodrero, M. y Bacigaluppo, S. Producción de soja y uso eficiente de los recursos. Para Mejorar La Producción 45, 151–154. INTA EEA Oliveros. (2010). <http://inta.gob.ar/sites/default/files/script-tmp-produccion-de-soja-y-uso-eficiente-de-losrecursos.Pdf>

Bonifacio Martin del Brio, & Alfredo Sanz Molina,. (1994). Redes Neuronales y sistemas borrosos.

Ing. Badino, Estadística rindes y precipitaciones Nueva Castilla (2018). (n/a).