

salida, cuya única neurona (S) estima el porcentaje de cobertura del suelo por residuos. El esquema general del modelo de RN se observa en la Figura 3.

La información entre las capas se propaga utilizando funciones matemáticas de transferencia (en este caso la tangente hiperbólica) aplicadas a la sumatoria de los datos, ponderados cada uno previamente por un peso.

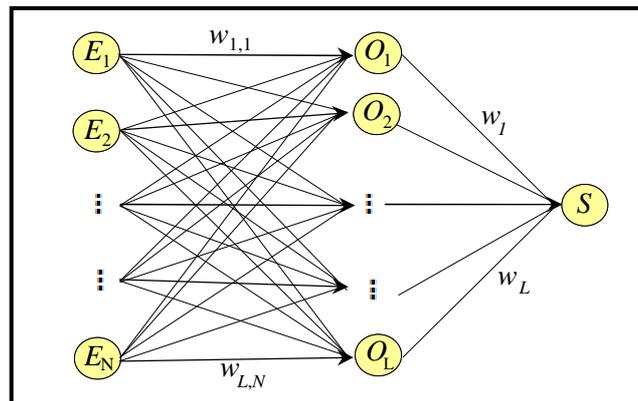


Fig. 3. Esquema de la Red Neuronal. Figura adaptada de [17]

Para que estas redes puedan aplicarse, requieren de una fase de entrenamiento en la cual se determinan iterativamente los pesos de las conexiones entre las distintas capas, a partir de un conjunto de datos de entrada y salida conocidos. Cada iteración incluye dos etapas, la primera hacia delante para calcular la salida y determinar su diferencia con el valor observado (error) y otra hacia atrás para actualizar los pesos y mejorar la predicción. Para acelerar el proceso de aprendizaje se incluyó una tasa de aprendizaje, que permitió corregir la dirección del error y un término de momento.

Una descripción más detallada del esquema general de los pasos y fórmulas del algoritmo de entrenamiento puede encontrarse en Bocco *et al.* [17]. Concluida la fase de entrenamiento, con los mejores pesos obtenidos en el transcurso del proceso iterativo, se realizó la fase de validación con un conjunto independiente de datos, para los cuales se conocía la verdad de terreno a fin de comprobar la eficiencia de la red y determinar los errores de estimación.

La Tabla 1 muestra las variables incluidas en la capa de entrada, donde los modelos construidos con CD se denominan RN_iCD y RN_iR a los que incluyen reflectancias y el número de neuronas en la capa oculta. Para el proceso de entrenamiento fueron usados el 70% de los datos, siendo éstos tomados al azar.

2.5 Análisis Estadístico

Los estadísticos usados para la evaluación y validación de los modelos fueron el coeficiente de determinación (R^2) y la raíz del error cuadrático medio (RECM), ambos calculados a partir de los valores de porcentaje de cobertura de suelo observados y estimados.

Tabla 1. Modelos de Redes Neuronales: capas de entrada y oculta.

Modelos	VARIABLES DE ENTRADA (TM bandas)	N° de neuronas Ocultas
RN ₁ CD RN ₁ R	b ₂ -b ₄	4
RN ₂ CD RN ₂ R	b ₂ -b ₅	4
RN ₃ CD RN ₃ R	b ₂ -b ₇	4
RN ₄ CD RN ₄ R	b ₃ -b ₅	4
RN ₅ CD RN ₅ R	b ₃ -b ₇	4
RN ₆ CD RN ₆ R	b ₅ -b ₇	4
RN ₇ CD RN ₇ R	b ₁ -b ₂ -b ₃ -b ₄ -b ₅ -b ₇	6
RN ₈ CD RN ₈ R	b ₂ -b ₃ -b ₄ -b ₅ -b ₇	5

Para obtener la verdad de terreno, necesaria para los procesos de aprendizaje y validación de las RN, se clasificaron las fotografías digitales obtenidas en los distintos viajes a campo en cada lote siguiendo la metodología propuesta por Pacheco y McNairn [4].

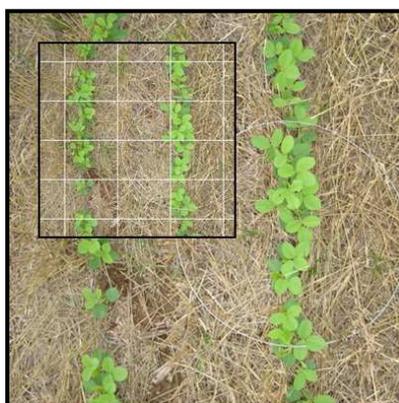


Fig. 4. Fotografía digital del lote 4 con suelo cubierto por residuo y fotografía con grilla superpuesta para obtener porcentaje de cobertura por residuo.

Para obtener el porcentaje de cobertura de suelo por rastrojo se superpuso sobre cada fotografía una cuadrícula y se registró la presencia de residuos en cada intersección de la cuadrícula (Figura 4). Los valores obtenidos en todas las fotografías de cada lote se promediaron, obteniéndose así el porcentaje que se asignó para cada lote en cada fecha de viaje.

3 Resultados y discusión

Los resultados obtenidos en la etapa de validación para los modelos propuestos y tipo de cobertura de residuos, se presentan en la Tabla 2. Como puede observarse, si es posible, siempre es preferible utilizar el mayor número de bandas (tanto para CD como para valores de reflectancias).

Tabla 2. Valores de ajuste estadístico para los modelos de RN que estiman porcentaje de cobertura de suelo por residuos.

Modelos	R ²	RECM
RN ₁ CD	0,86	8,61
RN ₁ R	0,87	7,80
RN ₂ CD	0,89	7,89
RN ₂ R	0,90	7,39
RN ₃ CD	0,84	9,28
RN ₃ R	0,85	8,94
RN ₄ CD	0,90	7,65
RN ₄ R	0,90	7,31
RN ₅ CD	0,83	9,77
RN ₅ R	0,83	9,78
RN ₆ CD	0,65	14,54
RN ₆ R	0,27	22,85
RN ₇ CD	0,92	6,10
RN ₇ R	0,93	5,93
RN ₈ CD	0,92	6,42
RN ₈ R	0,92	5,96

Los resultados obtenidos en este trabajo son comparables a los presentados por [10] quienes utilizando la misma metodología de modelación y con el fin de estudiar la adopción de siembra directa o labranza convencional, a partir de dos bandas (b_5 y b_7) de LANDSAT 5 TM, clasificaron cobertura del suelo por residuos conjuntos de los cultivos de maíz, soja, sorgo y trigo. Estos autores presentaron valores del coeficiente de determinación que osciló entre 0,66 y 0,80. Para lotes ubicados en Canadá, [4] usando una imagen de AWiFS (Advanced Wide Field Sensor) correspondiente a

octubre 2010, estimaron cobertura de suelo por residuos de cultivos de canola, lentejas, trigo, cebada, avena y centeno conjuntamente, obteniendo valores de $R^2 = 0,83$ y $RECM = 20,18$. Estos autores utilizaron un modelo espectral no mixto que utiliza como entrada las reflectancias mayores de la imagen.

Para el modelo con el que se logran los mejores ajustes a los datos independientes en el proceso de validación del mismo (RN_7R) en la Figura 4 se pueden observar los valores observados y estimados de porcentaje de cobertura de suelo por rastrojo cuando se consideran ambos tipos de residuos y las diferencias con respecto a la recta identidad.

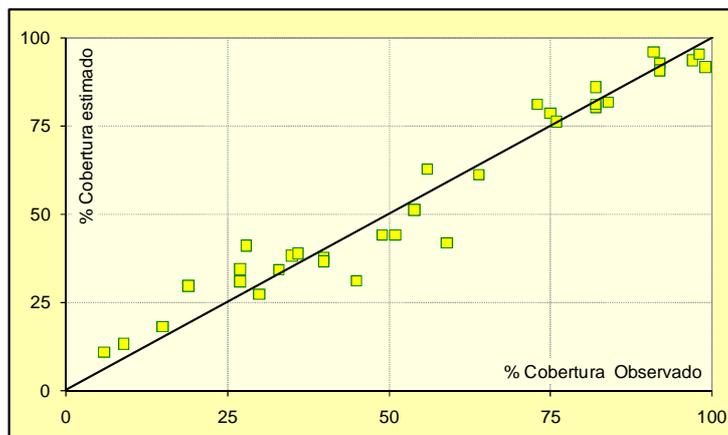


Fig. 4. Gráfico scatter plot de porcentaje observado y estimado de suelo cubierto por residuo (Modelo RN_7R).

Es importante destacar que, si el porcentaje de cobertura del suelo por cualquiera de los dos tipos de rastrojo supera el 75%, esto es residuos posteriores pero inmediatos a la cosecha, se consigue el mejor ajuste entre los valores observados y estimados (Figura 4).

4 Conclusiones

Los modelos matemáticos construidos con la metodología de redes neuronales que utilizan como patrones de entrada datos espectrales de imágenes LANDSAT permiten estimar adecuadamente el porcentaje de cobertura de suelo por rastrojo de soja y maíz.

La estimación del porcentaje de cobertura por residuo de soja o maíz, obtenida a partir del mejor modelo de RN desarrollado presentó un valor de $R^2 = 0,93$ y de raíz del error cuadrático medio de 5,93%.

Como continuación de este trabajo se plantea validar estos modelos contemplando factores que podrían incidir en los resultados, por ejemplo variaciones en la humedad

de suelo, condiciones atmosféricas y principalmente diferencia de reflectancias de los rastrojos de soja y maíz en las diferentes etapas de descomposición de los mismos.

Agradecimientos, Los autores expresan su gratitud a la Secretaría de Ciencia y Técnica – Universidad Nacional de Córdoba - Argentina (Secyt-UNC) por el apoyo financiero que permitió la realización de este trabajo.

Referencias

1. Daughtry, C. S. T., Serbin, G., Reeves, J. B., Doraiswamy, P. C., Hunt, E. R. Jr.: Spectral reflectance of wheat residue during decomposition and remotely sensed estimates of residue cover. *Remote Sensing*, 2, 416--431 (2010)
2. Morrison, J. E., Huang, C. H., Lightle, D. T., Daughtry, C. S. T.: Residue measurement techniques. *Journal of Soil and Water Conservation*, 48, 478--483 (1993)
3. Molloy, J. M., Moran, C. J.: Compiling a field manual from overhead photographs for estimating crop residue cover. *Soil Use and Management*, 7(4), 177--183 (1991)
4. Pacheco, A., McNairn, H.: Evaluating multispectral remote sensing and spectral unmixing analysis for crop residue mapping. *Remote Sensing of Environment*, 114, 2219--2228 (2010)
5. Obade, V. P.: Remote Sensing, Surface Residue Cover and Tillage Practice. *Journal of Environmental Protection*, 3, 211--217 (2012)
6. Serbin, G., Daughtry, C., Hunt, E., Reeves, J., Brown, D.: Effects of soil composition and mineralogy on remote sensing of crop residue cover. *Remote Sensing of Environment*, 113, 224--238 (2009)
7. Galloza, M., Crawford, M.: Exploiting multisensor spectral data to improve crop residue cover estimates for management of agricultural water quality. In: *IEEE International Geoscience and Remote Sensing Symposium, IGARSS 2011, Vancouver*, pp. 3668--3671 (2011).
8. Bocco, M., Ovando, G., Sayago, S., Willington, E.: Modelos simples para estimar cobertura de suelo agrícola a partir de Imágenes MODIS: aplicación a la zona central de Córdoba (Argentina). In: *42 JAIIO Congreso Argentino de AgroInformática, CAI 2013, Córdoba*, pp. 61--69 (2013).
9. Bannari, A., Chevrier, M., Staenz, K., McNairn, H.: Senescent vegetation and crop residue mapping in agricultural lands using artificial neural networks and hyperspectral remote sensing. In: *International Geoscience and Remote Sensing Symposium, Toulouse*, 4292--4294 (2003).
10. Sudheer K., Gowda, P., Chaubey, I., Howell, T.: Artificial Neural Network Approach for Mapping Contrasting Tillage Practices. *Remote Sensing*, 2(2), 579--590 (2010)
11. Bocco, M., Ovando, G., Sayago, S., Willington, E., Heredia, S.: Estimating Soybean Ground Cover from Satellite Images Using Neural Networks Models. *International Journal of Remote Sensing* 33, 1717--1728 (2012).
12. Barberis, N. A., Bongiovanni, R.: Resultado económico esperado de la agricultura, campaña agrícola 2013/2014. Cartilla Digital Manfredi-INTA EEA Manfredi (2013), pp. 1--17. http://inta.gob.ar/documentos/resultado-economico-esperado-de-la-agricultura-campana-agricola-2013-2014.-julio-2013-i/at_multi_download/file/INTA_Informe_economico_para_el_productor_I_departamento_Rfo_Segundo_Cordoba_julio2013.pdf
13. Agencia Córdoba Ambiente e Instituto Nacional de Tecnología Agropecuaria: Los suelos. Ed. Gobierno de la Provincia de Córdoba. (2006).

14. Piatti, F., Ferreira, L.: Evaluación de cultivares comerciales de soja. Campaña 2008/09. Cartilla Digital Manfredi-INTA-EEA (2009), <http://agrolluvia.com/wp-content/uploads/2010/02/eea-inta-manfredi-evaluacion-de-cultivares-comerciales-de-soja-2008-2009.pdf>
15. Piatti, F., Ferreira L.: Ensayos comparativos de rendimiento de maíz: Red interna de INTA Manfredi, campaña 2007-08. Cartilla Digital Manfredi-INTA- EEA (2008), <http://agrolluvia.com/wp-content/uploads/2010/03/eea-manfredi-ensayos-comparativos-derendimiento-de-maiz-red-interna-campana-2007-08.pdf>
16. Chavez, P. S. Jr.: Radiometric calibration of LANDSAT Thematic Mapper multispectral images. Photogrammetric Engineering and Remote Sensing, 55, 1285--1294 (1989)
17. Bocco, M., Willington, E., Arias, M.: Comparison of Regression and Neural Networks Models to Estimate Solar Radiation. Chilean Journal of Agricultural Research 70, 428--435 (2010)