

XVIII SIMPOSIO DE INGENIERÍA ELÉCTRICA

Redes Neuronales en el manejo de datos de cosecha de combinada cañera CASE-IH A8000

*Neural Networks in the management of sugar cane harvester CASE-IH
A8000 harvesting data.*

Robby Gustabello Cogle¹, Carlos Alejandro Perez Garcia², Aldo Peláez Toledo³

1-Robby Gustabello Cogle. Universidad Central "Marta Abreu" de Las Villas, Cuba. E-mail: robby@uclv.edu.cu.

2- Carlos Alejandro Perez Garcia. Universidad Central "Marta Abreu" de Las Villas, Cuba. E-mail: capgarcia@uclv.cu.

3- Aldo Peláez Toledo. Universidad Central "Marta Abreu" de Las Villas, Cuba. E-mail: aptoledo@uclv.cu.

Resumen:

Los datos de cosecha procedentes de las cosechadoras cañeras CASE-IH A8000 brindan información sobre la operación de estas máquinas. Su potencial crecimiento y valiosa información implícita conlleva un procesamiento más allá del ofrecido por los software disponibles para ello. Por tal razón el presente trabajo se traza el objetivo de determinar la utilidad de las redes neuronales artificiales para tal fin. A través del método exploratorio-deductivo los autores encuentran las potencialidades de la aplicación de esta técnica de inteligencia artificial a un área donde no se le usa tradicionalmente.

Abstract:

Harvesting data from CASE-IH A8000 sugarcane harvesters provide information about the operation of these machines. Their potential growth and valuable implicit

information entails a processing beyond that offered by the software available for it. For this reason, the present work is aimed at determining the usefulness of artificial neural networks for this purpose. Through the exploratory-deductive method the authors find the potentialities of the application of this technique of artificial intelligence to an area that is not traditionally used.

Palabras Clave: Datos de cosecha, redes neuronales artificiales, manejo de datos.

Keywords: *Harvesting data, artificial neural network, data management.*

1. Introducción

La aplicación de la automática a procesos de diversa índole ha sido uno de los motores impulsores del desarrollo global. Desde hace ya algunos años esta ciencia ha salido del clásico ambiente industrial para instalarse también en la agricultura. Ejemplo de ello resulta el variado número de máquinas y procesos agrícolas cuya operación se sustenta en novedosos sistemas que no necesitan la intervención del hombre para su total control. Algunos de ellos pueden encontrarse en (Avello Fernández, Izaguirre Castellanos, Vidal Díaz, Martínez Laguardia, & Hernández Santana, 2018) y en (Gustabello Cogle, Pérez García, Molina Hernández, Hernández Santana, & Mora Delgado, 2017).

En Cuba, la caña de azúcar ha sido históricamente uno de los cultivos priorizados en el empleo de la tecnología. Desde 2014 se encuentran operando en los campos cañeros las cosechadoras CASE-IH A8000 con una probada aceptación (Molina Hernández, Gustabello Cogle, & Hernández Santana, 2015).

La alianza estratégica conformada entre el Grupo de Automatización, Robótica y Percepción (GARP) de la Universidad Central “Marta Abreu” de Las Villas (UCLV), la Estación Territorial de Investigaciones de la Caña de Azúcar (ETICA) y la empresa azucarera de Villa Clara ha permitido llevar adelante investigaciones referentes a tales dispositivos. Entre ellas: (Pérez García, Gustabello Cogle, & Hernández Santana, 2016) y (Sánchez Ibáñez, Gustabello Cogle, & Pérez García, 2017). Uno de sus resultados ha sido la obtención de los datos de cosecha adquiridos por las máquinas y su

procesamiento por medio de software como SMS y AFS. Así, ha sido posible generar informes de operación y mapas de variables.

Aunque todavía no se tiene un mecanismo para la recolección estable de los datos, el aumento progresivo de las máquinas en operación y el hecho de que estos son captados a intervalos de un segundo, hacen prever un escenario donde exista un alto volumen de información. Su análisis, más allá de lo elemental que permiten los software ya mencionados, no es una práctica contemplada por la empresa azucarera hasta el momento. Se conoce de la aplicación de Redes Neuronales Artificiales (RNA) al procesamiento de imágenes y otros tipos de datos, pero no se tiene referencia sobre su empleo con datos de cosecha. Teniendo en cuenta la situación anterior se deriva el siguiente problema científico:

- ¿Cuál es la posible utilidad de las Redes Neuronales Artificiales en el manejo de los datos de cosecha obtenidos por las cosechadoras cañeras CASE-IH A8000 en Cuba?

Como objetivo general se plantea:

- Determinar la posible utilidad de las Redes Neuronales Artificiales en el manejo de los datos de cosecha obtenidos por las cosechadoras cañeras CASE-IH A8000 en Cuba?

La investigación tiene un alcance exploratorio-descriptivo, en tanto no se encuentra bibliografía referente al manejo de datos de cosecha de máquinas agrícolas, pero se tiene la experiencia de investigaciones anteriores y el intercambio con especialistas de la industria. En el caso de las RNA se realiza una breve descripción de sus aspectos fundamentales.

2. Metodología

2.1 Caracterización de los datos de cosecha

La búsqueda de una definición formal de “dato de cosecha” (o su análogo en inglés: harvesting data) en bases de datos internacionales como: Web de la Ciencia y Scopus no produce resultados positivos. En fuentes como: (López-Granados, Peña-Barragán, Jurado-Expósito, & García-Torres, 2010), (Casado, Amiama, & Bueno, 2012), (Chartuni Mantovani & Magdalena, 2014), (Aguirre González, 2017), (Gustabello

II CONVENCION CIENTIFICA INTERNACIONAL “II CCI UCLV 2019”



Cogle, Pérez García, Hernández Santana, & Sánchez Ibáñez, 2017) y (Benítez-Puig, Viñas-Quintero, de León-Ortiz, & Guillén-Sosay, 2018) se maneja esta nomenclatura para hacer referencia a los datos provenientes de la operación de cosechadoras cañeras¹, pero en ninguna se brinda el concepto. La búsqueda en diccionarios especializados online como Agrovoc, de la FAO, tampoco arroja resultados halagüeños.

En opinión de los autores, discutida con colegas de GARP, algunas causas a las que obedece esta situación pudieran ser:

- La inexistencia de caña de azúcar como cultivo económicamente jugoso en países del Primer Mundo.
- La ausencia, en países tercermundistas, de cosechadoras cañeras capaces de adquirir los datos.
- La dificultad para acceder a los datos de cosecha.
- El desconocimiento de su existencia o utilidad.

En (Molina Hernández, Gustabello Cogle and Hernández Santana, 2015) se da a conocer que los datos de cosecha de las CASE-IH A8000 son generados por los sensores existentes en los equipos y están formados por el conjunto de variables adquiridas y la geocalización de cada punto de recolección. El monitor de rendimiento es el encargado de su almacenamiento temporal y su transmisión, vía interfaz USB, a un dispositivo de almacenamiento masivo.

El acceso a ellos no es posible sino a través de alguno de los software apropiados. Al usar el SMS, en su versión avanzada, se encuentran:

¹ Extensible a las máquinas agrícolas en general

II CONVENCION CIENTIFICA INTERNACIONAL "II CCI UCLV 2019"



1. Conjunto de datos	19. Modo cortador	37. RPM motor (rpm)
2. Producto	20. Longitude	38. Temp. aceite hid. (°C)
3. Cuenta de área	21. Latitude	39. Volts bat(V)
4. Estado dif.	22. Lote	40. RPM transport (rpm)
5. Estado trabajo	23. Id obj.	41. Pres cortador(kPa)
6. Temp refrig.FR	24. Distancia (m)	42. Velocidad ventilador (rpm)
7. Niv refrigerante baj	25. Curso(deg	43. Conf cóncava
8. Pres aceite m FR	26. Duración (s)	44. Conf criba 1
9. Niv aceite baj	27. Elevación (m)	45. Conf criba 2
10. T Aceite h FR	28. Tiempo	46. Num. de paso
11. Aceite hid. bajo	29. Anch. de fja. (m)	47. Velocidad (km/h)
12. Filtr comb OK	30. Desviación Y(m)	48. Prod. (ha/h)
13. Filtr aceite OK	31. Combust utilizado (L)	49. Cons. comb. (A)(L/ha)
14. Filtr aire OK	32. Ef. comb. (A)(ha/L)	50. Cons. comb. (T)(L/h)
15. Código parada E	33. Fuerza mot.(W)	51. Ef. comb.(km/L)
16. Torn. desc. detall.	34. Carga mot. (%)	52. Fecha
17. Estado elev detall	35. Temp refrigerante (°C)	
18. Niv potencia	36. Presión aceite (kPa)	

A pesar de que la mayoría de los nombres pueden ser inferidos, esto no sucede en todos los casos y hasta el momento no ha sido posible esclarecer esta problemática.

Las 19 primeras variables mostradas son de tipo texto y las demás son numéricas. De las textuales existen 18 que son binarias, con valores como: Sí/No, Manual/Automático, entre otros. De las numéricas se tienen 3 de tipo fecha-hora y todas las demás pueden ser consideradas analógicas.

Como se aprecia, no aparece aquí una variable tan importante como el rendimiento cañero, el cual constituye la base para la realización de Agricultura de Precisión. En investigaciones como (Cerri & Magalhães, 2005), (Esquivel et al., 2008) y (Lago González, Sepúlveda Peña, Fernández Sarría, & Camacho González, 2008) se hace referencia a métodos de cálculo de rendimiento a partir de tecnologías externas a las

cosecadoras, pero no existe ninguna referencia a un trabajo similar basado en los datos de cosecha de las CASE-IH A8000.

2.2 *Redes Neuronales Artificiales*

Las RNA, también conocidas como Sisemas Neuronales Artificiales y Sistemas Conexionistas (Martín del Brío & Sanz Molina, 2002), vieron la luz en la década del 1940. Warren S. McCulloch y Walter Pitts son considerados como sus creadores (Russell & Norvig, 1995). Otros investigadores como Donald Hebb, Frank Rosenblatt, David E. Rumelhart, Geoffrey E. Hinton y Ronald J. Williams enriquecieron las ideas iniciales y las llevaron a un plano superior.

Son un modelo computacional destinado a imitar el comportamiento de las neuronas en el cerebro humano, con el objetivo de dotar a los sistemas computacionales con la capacidad de aprender o descubrir automáticamente relaciones entrada-salida (o rasgos característicos) en función de datos empíricos y llevar a cabo procesos que se realizan en el cerebro de forma básica (Martín del Brío & Sanz Molina, 2002).

Suelen ser utilizadas como herramientas para la predicción de tendencias y como clasificadoras de conjuntos de datos.

Los parámetros que definen el “conocimiento” son: las conexiones y el estado de activación de sus unidades de procesamiento. Estas últimas se denominan neuronas artificiales y poseen 5 características básicas (Piloto Rodríguez, 2017) :

- 1- Conjunto de entradas, $x_j(t)$.
- 2- Pesos sinápticos, $w_{ij}(t)$.
- 3- Regla de propagación, $h_i(t) = f(x_j(t), w_{ij})$.
- 4- Función de activación, $a_i(t) = f(h_i(t))$.
- 5- Función de salida $y_i(t) = f(a_i(t))$.

La figura 1 ilustra las características anteriores




Figura 1. Esquema de una neurona artificial (Fuente: Martín del Brío & Sanz Molina, 2002)

El conjunto de entradas constituye el elemento de acceso a la información para la neurona artificial. Cada entrada puede provenir de otra neurona artificial o de una variable del elemento bajo estudio.

Los pesos sinápticos representan la intensidad de la conexión entre la neurona artificial y la entrada en cuestión. Dada una entrada, si el peso es positivo excitará a la neurona postsináptica, si el peso es negativo la inhibirá. Normalmente el valor está acotado a un intervalo.

La regla de propagación permite obtener el valor del potencial postsináptico, a partir de las entradas y los pesos. La función más comúnmente empleada es la sumatoria de las multiplicaciones entre las entradas y sus pesos correspondientes, sumado algebraicamente con un valor umbral.

La función de activación indica la posible activación de la neurona en un instante de tiempo dado. Se suele considerar determinista y, en la mayor parte de los modelos, es monótona creciente y continua. La figura 2 ilustra alguna de las más empleadas.

	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{signo}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -1 \\ x, & \text{si } -1 \leq x \leq 1 \\ +1, & \text{si } x > 1 \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gausiana	$y = A.e^{-bx^2}$	$[0, +1]$	

Figura 2. Funciones de activación más empleadas.

La función de salida proporciona la salida global de la neurona. En muchos se emplea simplemente la función identidad, por lo que la función de activación constituye directamente la salida.

Un ejemplo clásico de la implementación de una neurona artificial es el brindado en la figura 3




Figura 3. Esquema de neurona artificial que implementa una compuerta lógica NAND (Fuente: Russell & Norvig, 1995).

Una RNA está formada por múltiples neuronas interconectadas. Pueden encontrarse disímiles arquitecturas o estructuras. Según (Russell & Norvig, 1995) una clasificación básica es de acuerdo a la direccionalidad de las conexiones, pudiendo ser: recurrentes o direccionales (con propagación hacia adelante).

Las redes recurrentes son aquellas donde los enlaces entre neuronas se realizan en cualquier dirección, incluyendo la realimentación. A pesar de que estas se acercan más al funcionamiento real del cerebro, su implementación práctica es muy compleja ya que se vuelven inestables y su entrenamiento toma mucho tiempo. Dos ejemplos clásicos de esta arquitectura son las redes de Hopfield y las máquinas de Boltzmann.




Figura4. Esquema de una red de Hopfield (Fuente: Martín del Brío & Sanz Molina, 2002).

En las redes direccionales, por su parte, los enlaces entre neuronas se establecen en una sola dirección. Se consideran conformadas por capas. Estas pueden ser: de entrada, oculta o de salida. Las neuronas de cada una se conectan solo a una o más de la capa posterior (figura 5).




Figura5. Esquema de una red direccional (Fuente: Martín del Brío & Sanz Molina, 2002).

La cantidad de neuronas artificiales y capas ocultas, así como el método y el algoritmo de aprendizaje empleado, influyen grandemente en el éxito de la red. Cuando existen una o más capas ocultas la RNA es conocida como multicapa (MLP por sus siglas en inglés). Si posee solo una, puede representar cualquier función lineal. Si posee más puede, incluso, representar funciones no lineales (figura 6).

Estructura	Regiones de Decisión	Clases con Regiones Mezcladas	Formas de Regiones más Generales
1 Capa 	Medio Plano Limitado por un Hiperplano		
2 Capas 	Regiones Cerradas o Convexas		
3 Capas 	Complejidad Arbitraria Limitada por el Número de Neuronas		

Figura6. Regiones identificables en un plano según la cantidad de capas ocultas de una RNA.

Cuando se construye un sistema neuronal, se parte de un cierto modelo de neurona y de una determinada arquitectura de red, estableciéndose los pesos sinápticos iniciales según alguna regla. Para que la red resulte operativa es necesario entrenarla. Existen

cuatro métodos fundamentales para ello: el supervisado, el no supervisado, el híbrido y el reforzado (Martín del Brío & Sanz Molina, 2002).

En el supervisado se presenta a la red un conjunto de patrones, junto con la salida deseada. Iterativamente esta ajusta sus pesos hasta que su salida tiende a ser la deseada. En este proceso de ajuste se usa algún algoritmo que, normalmente, se basa en el error cometido en en cada paso.

En el no supervisado se presentan a la red un conjunto de patrones sin adjuntar la respuesta que deseada. La RNA, por medio de su algoritmo de aprendizaje, estima la función densidad de probabilidad que describe la distribución de patrones pertenecientes al espacio de entrada. A partir de ello es posible, por ejemplo, extraer rasgos, o agrupar patrones según su similitud.

En el híbrido coexisten los dos anteriores, pero tienen lugar en distintas capas de neuronas.

El reforzado, o de premio-castigo, se ubica en medio de los dos primeros. Como en el no supervisado no existe información de la salida deseada, pero se suministra información sobre el error cometido.

4. Conclusiones

A pesar de que las mayores aplicaciones de las RNA se reportan en el campo del procesamiento de imágenes, existen múltiples ejemplos que acreditan su uso con datos de otra naturaleza (Buduma, 2017).

Para el caso de los datos de cosecha de las CASE-IH A8000, podría trabajarse en diferentes direcciones. Algunas de ellas son:

- 1- Usar entrenamiento no supervisado encontrar patrones en los campos cultivados. Variables como el consumo de combustible son de alta importancia para el sector. Por tanto, determinar índices de comportamiento que provoquen un alto consumo puede ayudar al mejoramiento energético de la zafra.
- 2- Si se pudiera contar con el rendimiento cañero a pequeña escala (quizá hasta a nivel de campo pueda servir) podría usarse entrenamiento supervisado para encontrar un modelo que permita inferir el rendimiento a partir de los datos de cosecha existentes en un campo o una sección de este.

3- Si se tuviera la información relativa a las roturas que sufren las máquinas, pudiera realizarse un entrenamiento supervisado en aras de encontrar un modelo que permitiera predecir la ocurrencia de fallos a partir de los datos de cosecha y, así, evitarlos.

Evidentemente habría que estudiar las diferentes variantes para encontrar la arquitectura de red y el algoritmo de aprendizaje adecuados, así como seleccionar los datos que realmente deben ser empleados.

En la medida que los datos disponibles crezcan se puede corregir la red implementada y ajustar su salida.

4. Referencias bibliográficas

- Aguirre González, J. A. (2017). *Desarrollo de un modelo de mantenimiento preventivo para la calibración y ajuste del sistema de pesaje a equipos de precisión de la caña de azúcar en el ingenio riopaila castilla s.a.* Universidad Nacional abierta y a distancia, Colombia.
- Avello Fernández, L., Izaguirre Castellanos, E., Vidal Díaz, M. L., Martínez Laguardia, A. S., & Hernández Santana, L. (2018). Remote supervision and control based on wireless technology to operation of central pivot irrigation machine. *Sistemas y Telemática*, 16(44), 63–74.
- Benítez-Puig, L., Viñas-Quintero, Y., de León-Ortiz, M. E., & Guillén-Sosay, S. (2018). Contribución al manejo sostenible del cultivo de la caña de azúcar en Cuba. *Revista Ingeniería Agrícola*, 8(2), 62–67.
- Buduma, N. (2017). *Fundamentals of Deep Learning: Designing next-generation machine intelligence algorithms.* (M. Loukides & S. Cutt, Eds.). O'Reilly Media, Inc.
- Cascudo, N., Amiama, C., & Bueno, J. (2012). Sistema de ayuda a la decisión (SAD) para la planificación de rutas en la campaña de maíz forrajero. In *XVI Congreso Internacional de Ingeniería de Proyectos*. Valencia. Retrieved from https://www.aepro.com/files/congresos/2012valencia/CIIP12_0896_0905.3767.pdf
- Cerri, D. G. P., & Magalhães, P. S. G. (2005). Monitoreo de Rendimiento en

II CONVENCION CIENTIFICA INTERNACIONAL “II CCI UCLV 2019”



- Caña de Azúcar. In *2005 ASAE Annual Internacional Meeting*. Tampa, USA: INTA. <https://doi.org/10.1017/CBO9781107415324.004>
- Chartuni Mantovani, E., & Magdalena, C. (2014). *Manual de agricultura de precisión*. (E. Chartuni Mantovani & C. Magdalena, Eds.). Montevideo: PROCISUR/IICA. Retrieved from www.iica.int
 - Esquivel, M., Hernández, B., Marreno, S., Ponce, E., Quintana, L., González, L., García, J. (2008). Agricultura de precisión en la caña de azúcar. *Mapping*, 5(127), 42–49.
Retrieved from <https://dialnet.unirioja.es/servlet/articulo?codigo=2688196>
 - Gustabello Cogle, R., Pérez García, C. A., Hernández Santana, L., & Sánchez Ibáñez, N. D. (2017). Empleo de “ SMS Advanced ” para la gestión de datos de cosecha en caña de azúcar. In *XV Encuentro Internacional de Gestión del Conocimiento y Empresas de Alto Desempeño “TECNOGEST 2017.”* La Habana, Cuba: GECYT.
 - Gustabello Cogle, R., Pérez García, C. A., Molina Hernández, J., Hernández Santana, L., & Mora Delgado, I. (2017). CASE-IH A 8000 en la automatización de la agricultura cañera. In *XVII Simposio de Ingeniería Eléctrica*. Universidad Central " Marta Abreu " de Las Villas.
 - Lago González, C., Sepúlveda Peña, J. C., Fernández Sarría, F., & Camacho González, A. (2008). Utilización de la tecnología GPS en la generación automática de Mapas de Rendimiento en el Cultivo de la Caña de Azúcar. In *14 Convención Científica de Ingeniería y Arquitectura* (p. 10). La Habana. Retrieved from <http://ccia.cujae.edu.cu/index.php/siia/siia2008/paper/view/1181>
 - López-Granados, F., Peña-Barragán, J. M., Jurado-Expósito, M., & García-Torres, L. (2010). Obtención de mapas de infestación de malas hierbas mediante teledetección para su aplicación en agricultura de precisión. In *36 Feria Internacional de la Maquinaria Agrícola* (pp. 44–52). Zaragoza.
 - Martín del Brío, B., & Sanz Molina, A. (2002). *Redes Neuronales y Sistemas Difusos* (2da ed.). Alfaomega Ra-Ma.
 - Molina Hernández, J., Gustabello Cogle, R., & Hernández Santana, L. (2015). *Cosechadoras cañeras CASE IH A8000 para la Agricultura de Precisión en*

II CONVENCION CIENTIFICA INTERNACIONAL "II CCI UCLV 2019"



- Cuba. Universidad Central" Marta Abreu" de Las Villas. Facultad de Ingeniería Eléctrica. Retrieved from <http://dspace.uclv.edu.cu/handle/123456789/4824>
- Pérez García, C. A., Gustabello Cogle, R., & Hernández Santana, L. (2016). *Metodología para la extracción de datos de cosecha en cosechadoras cañeras Case IH A8000*. Universidad Central" Marta Abreu" de Las Villas. Facultad de Ingeniería Eléctrica. Retrieved from <http://dspace.uclv.edu.cu/handle/123456789/7755>
 - Piloto Rodríguez, R. (Universidad T. de L. H. "José A. E. (2017). *Redes Neuronales Artificiales. Conceptos básicos y algunas aplicaciones en Energía*. La Habana. <https://doi.org/10.13140/RG.2.2.23326.54083>
 - Russell, S. J., & Norvig, P. (1995). *Artificial Intelligence. A modern approach*. New Jersey: Prentice Hall. <https://doi.org/10.1017/S0269888900007724>
 - Sánchez Ibáñez, N. D., Gustabello Cogle, R., & Pérez García, C. A. (2017). *Metodología para la creación de informes de cosecha de CASE-IH A8000 con SMS Advanced*. Universidad Central" Marta Abreu" de Las Villas. Facultad de Ingeniería Eléctrica. Retrieved from <http://dspace.uclv.edu.cu:8089/handle/123456789/7967>