

Base de conocimiento de prácticas agrícolas codificada en Deep Learning para la producción de Lima persa



Colaboración

Lidia Arely Díaz Hernández; Carlos Alexis Cano Villa; Roberto Ángel Meléndez Armenta; Eddy Sánchez de la Cruz; Gregorio Fernández Lambert, Instituto Tecnológico Superior de Misanfilia

RESUMEN: Presentamos la construcción de una base de conocimiento con datos de prácticas agrícolas y parámetros ambientales en el cultivo de Lima persa. La base de conocimiento fue procesada utilizando el software WEKA, y se encontró que, para validación cruzada con Percentage Split para 217 registros correspondiente a 66.66%, combinando los clasificadores AttributeSelectedClassifier+Multiplayer, la correlación resultante es de 99.65% de instancias correctamente clasificadas, con error medio absoluto de 895.79 kg, error absoluto relativo de 9.57%. Este resultado previo, genera confianza para futuras predicciones simulando escenarios de producción de Lima persa.

PALABRAS CLAVE: Selección de proveedor. Cadena de Suministro Alimentaria (CSA). Inteligencia Artificial. Red Neuronal Artificial. Deep Learning.

ABSTRACT: We present the construction of a knowledge-base with data of agricultural practices and environmental parameters in the cultivation of Persian Lima. The knowledge-base was processed using the WEKA software, and it was found that for cross-validation with Percentage Split for 217 records corresponding to 66.66%, combining the AttributeSelectedClassifier + Multiplayer classifiers, the resulting correlation is 99.65% of correctly classified instances, with mean absolute error of 895.79 kg, relative absolute error of 9.57%. This result generates confidence in future predictions for simulating production scenarios of Persian Lima.

KEYWORDS: Supplier selection. Food Supply Chain (FSC). Artificial Intelligence. Artificial Neural Network. Deep Learning.

INTRODUCCIÓN

La cadena de suministro implica personas, organizaciones, métodos los cuales interactúan en actividades relacionadas con el flujo y transformación de bienes, desde la etapa de materia prima hasta el usuario final, así como los flujos de información relacionados, dentro de procesos con diversos intereses que en ella intervienen. En este sentido, la sincronización de los diversos agentes involucrados en la cadena de

suministro requiere una planificación colaborativa con el fin de realizar un trabajo coordinado para satisfacer las exigencias de un mercado cada vez más competitivo. De aquí que, la sincronización de la cadena de suministros agroalimentaria es una tarea compleja que comprende acciones orientadas a lograr que los diferentes eslabones de las cadenas concurren en un esquema de trabajo armónico, con el objetivo común de lograr mejores ventajas y niveles de competitividad.

La gestión de la cadena de suministro de productos frescos (CSPF) se caracteriza por una incertidumbre en los requerimientos de su mercado y por una oferta en el volumen y la calidad de fruta de sus diversas fuentes de suministro, a saber: centrales de abasto y/o huertos agrícolas, dentro de las cuales, el factor perecedero y la estacionalidad de la fruta, hacen más compleja la búsqueda de la fruta fresca que atienda las necesidades del mercado. Este contexto de abastecimiento de fruta fresca incrementa la dificultad para encontrar productores-proveedores que satisfagan los requerimientos en volumen de fruta y calidad de la misma en el momento que así son requeridos, haciendo que la cadena agroalimentaria sea compleja en predecir y controlar.

Para atender la problemática de abastecimiento de fruta fresca, aunado a tener plantaciones propias, es característico que las empresas se apoyen en intermediarios, realicen compras de cosecha, y en otros casos, ubiquen centros de acopio en regiones productoras. Sin embargo, también es común que el productor agrícola tome la decisión de entregar al comprador del mejor postor.

La importancia de seleccionar al proveedor en la industria agroindustrial de frutos frescos radica en la relación como socios-miembros que asegure el abastecimiento de fruta fresca para mejorar la fluidez de los materiales a partir de una sincronización de sus operaciones con los niveles de calidad y volúmenes de fruta que ingresen al proceso. Esta premisa, es un buen principio para la gestión de la calidad de las salidas.

La selección y evaluación de proveedores es un tema bastante reportado en la literatura científica en diferentes periodos y campos industriales [7]; [8]; [3]. Sin embargo, para el campo agrícola toma mayor atención con el desarrollo de la inteligencia artificial con técnicas como la Lógica Difusa [5], las Redes Neuronales Artificiales [1], y técnicas integradas como sistemas de apoyo a la decisión y sistemas expertos [9]. Estos avances están enmarcados en la primera década por una fuerte literatura de modelos matemáticos como apoyo a la selección de proveedores en diferentes sectores industriales [4]. Esta muestra de trabajos describe el uso individual o integrado de técnicas considerando diversos criterios de decisión

para el proceso de evaluación y selección de proveedores como se muestra en [9]; [8], que aportan criterios comúnmente utilizados para la selección de proveedores en empresas de transformación. Sin embargo, en cadenas alimentarias, los criterios son más específicos al problema que se atiende [6].

El dinamismo improductivo del sector agrícola ha capturado la atención de académicos e industriales, en mayor grado, en los últimos veinte años para resolver problemas del campo agrícola utilizando técnicas de la Inteligencia Artificial. Este artículo, propone la construcción de una base de conocimiento relacionada con el suministro histórico de fruta fresca a una exportadora de Lima persa, con el objetivo evaluar la calidad de suministro de los diferentes proveedores en calidad de fruta exportable y calidad nacional.

MATERIAL Y MÉTODOS

El abastecimiento de fruta lo determina el departamento de compras de la empresa exportadora. La fruta es solicitada a los diferentes proveedores de Lima persa, los cuales pueden ser proveedores de huertos propios, proveedores locales, proveedores regionales y proveedores foráneos. Posteriormente una persona experta evalúa visualmente la calidad de fruta, clasificándola en calidades descritas por la empresa. Una vez que la fruta fresca se encuentra en la empresa se realiza el proceso de selección, lavado, secado, encerado y empaqueo de Lima persa.

La Figura 1 describe el enfoque de análisis apoyado del software Waikato Environment for Knowledge Analysis (WEKA)® V. 3.8 demo. Se dispone una base histórica de Lima persa de cada proveedor, con la cual se evalúa de acuerdo con la experiencia de un panel de expertos. La base histórica se conforma de 23 proveedores de Lima persa. Los valores históricos de proveeduría del año 2016 a 2019. Dicha información se procesa en WEKA, combinado clasificadores de dos enfoques distintos, para obtener la predicción de confiabilidad de cada proveedor; el resultado describe los kilogramos de fruta exportable.




Figura 1. Enfoque de estudio basado en WEKA.

A partir de (Gerón, M. 2018. Evaluación de proveedores para la empacadora limones Mónica, S.A. de C.V, Basado en la técnica Deep Learning).

RESULTADOS

La Tabla 1 describe una sección de la base de conocimiento generada a partir de la proveeduría histórica de 23 fuentes de proveeduría de Lima persa. Esta base de conocimiento tiene la característica de describir prácticas agrícolas que dan origen a la fruta que se ingresa a la empresa: Foliar, Nutriente, Herbicida, entre otras relacionadas con el tipo de tierra en la que se encuentra el cultivo de la Lima persa, así como las condiciones climáticas prevalecientes durante el cultivo del cítrico. La base se construye como se describe en la Figura 2.




Figura 2. Integración del conocimiento en la base de datos WEKA® 3.8 demo. Elaboración propia

Tabla 1. Corte de 19 registros de la base de conocimiento relacionada con la proveeduría histórica 2016-2019, que alimenta al Soft WEKA: Parte 1

Registro	Fecha Semanal	Tipo de Suelo	Porta Injerto	Temporada	m.s.n.m	Edad Promedio	Árboles en producción	Tipo de Poda	Temperatura	Millímetros de lluvia	Foliar(lt/ha)
1302	SEM 11 2016	Arenoso	Swingle	baja	87	2	357	Estresante	29	39	0
1303	SEM 22 2016	Arenoso	Swingle	baja	87	2	357	Estresante	33	50	400
1304	SEM 22 2016	Arenoso	Swingle	Alta	87	2	357	Estresante	32	47	400
1305	SEM 23 2016	Arenoso	Swingle	Alta	87	2	357	Estresante	30	206	0
1306	SEM 24 2016	Arenoso	Swingle	Alta	87	2	357	Estresante	31	180	0
1307	SEM 28 2016	Arenoso	Swingle	Alta	87	2	357	Estética	31	214	400
1308	SEM 29 2016	Arenoso	Swingle	Alta	87	2	357	Estética	29	209	400
1309	SEM 30 2016	Arenoso	Swingle	Alta	87	2	357	Estética	28	178	400
1310	SEM 31 2016	Arenoso	Swingle	Alta	87	2	357	Estética	29	215	400
1311	SEM 33 2016	Arenoso	Swingle	Alta	87	2	357	Estética	30	267	400
1312	SEM 33 2016	Arenoso	Swingle	Alta	87	2	357	Estética	29	245	400
1313	SEM 34 2016	Arenoso	Swingle	Alta	87	2	357	Estética	28	229	400
1314	SEM 35 2016	Arenoso	Swingle	Alta	87	2	357	Estética	29	241	400
1315	SEM 35 2016	Arenoso	Swingle	Alta	87	2	357	Estética	28	255	400
1316	SEM 37 2016	Arenoso	Swingle	baja	87	2	357	Estética	27	232	400
1317	SEM 38 2016	Arenoso	Swingle	baja	87	2	357	Estética	29	222	400
1318	SEM 39 2016	Arenoso	Swingle	baja	87	2	357	Estética	27	243	400
1319	SEM 40 2016	Arenoso	Swingle	baja	87	2	357	Estética	27	211	400
1320	SEM 41 2016	Arenoso	Swingle	baja	87	2	357	Estética	28	178	400

Elaboración propia.

Tabla 1: Corte de 19 registros de la base de conocimiento relacionada con la proveeduría histórica 2016-2019, que alimenta al Soft WEKA: Parte 2.

Nutriente (gr/ rbol)	Herbicida (lt/ha)	Kg Cosecha	kg fruta exportable	C110	C150	C175	C200	C230	C250	kg fruta nacional
500	200	2478	1632	10	33	11	19	16	7	846
500	0	29891	26554	17	123	276	381	542	223	26554
500	0	32825	30600	4	86	300	578	731	101	2225
0	200	9120	7905	1	22	96	118	157	71	1215
0	200	45630	41497	2	939	302	519	537	142	4133
0	200	183396	144449	95	1894	2835	2234	1116	323	38947
0	200	30915	23885	6	201	448	505	209	36	7030
0	200	94947	47668	48	1182	677	643	227	27	47279
0	200	124896	80444	108	1449	1149	1121	519	386	44452
0	200	50067	35598	314	782	578	257	112	51	14469
0	200	11501	3944	0	92	78	47	11	4	11498
0	200	5480	4420	42	79	65	42	21	11	1060
0	200	30830	26095	283	530	380	182	111	49	30827
0	200	6228	5032	51	87	74	54	24	6	1196
0	200	4842	4250	31	67	75	45	19	13	592
0	200	4280	3570	6	44	63	52	38	7	710
0	200	5465	4335	8	57	70	67	38	15	1130
250	0	6347	5593	21	81	85	88	40	14	754
0	200	625	425	1	6	6	8	4	0	200

Elaboración propia.

Variables de izquierda a derecha: Fecha Semanal, Tipo de Suelo, Porta Injerto, Temporada, m.s.n.m, Edad Promedio, Árboles en producción, Tipo de Poda, Temperatura, mm de lluvia, Foliar(lt/ha), Nutriente (gr/árbol), Herbicida (lt/ha), Kg Cosecha, kg fruta exportable, Calidades de fruta, Kg fruta nacional.

Esta base de conocimiento relacionada con la proveeduría histórica alimenta al programa WEKA. Para la clasificación se utilizan dos criterios de muestreo: la Cross-Validation con 10 carpetas (folds) y Percentage Split a 66.66%. El procesamiento de la información permitió clasificar, procesar, asociar y visualizar la base de datos histórica de proveedores con los criterios a analizar. La combinación de clasificadores fue de la siguiente manera: se seleccionó uno a uno cada clasificador ensamblado (en WEKA meta-clasificador) y cada uno se combinó con una Red Neuronal Artificial Perceptrón Multicapa (en WEKA DI4JMlpClassifier), para producir una exhaustiva búsqueda de patrones. Cada uno utiliza un meta algoritmo que aprende según las salidas de los clasificadores en los que se basa. En términos generales partiendo de los datos se construyen n clasificadores distintos. Las salidas de estos se usan como atributos de un nuevo clasificador. La Tabla 2 muestra los resultados, que se han distinguido con el Meta-clasificador Attribute Selected Classifier Multiplayer Perceptron con validación cruzada con Percentage Split de 99.65%, con error medio absoluto de 895.79 kg. Este error es comparado con el error reportado en la expertix de productores con 1300 kg a 1800 kg por hectárea cultivada.

Tabla 2: Reporte de validación WEKA.

meta clasificador	Función	validación cruzada										validación cruzada									
		Conjuntos de entrenamiento	Error de prueba	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación	Error de validación			
Attribute Regression	MultiLayerPerceptron	0.3407	13456.3268	23445.5879	127.916	425.375	212	783	0.8274	4936.8959	7395.4315	52.735	68.448	77	252						
Attribute Selected Classifier	MultiLayerPerceptron	0.0795	264.622	1331.5389	97.296	212.791	212	783	0.9989	1532.2515	1384.5116	0.376	35.848	77	252						
Bagging	MultiLayerPerceptron	0.0795	9988.3201	14829.4565	95.242	97.276	212	783	0.9989	1532.2515	1384.5116	0.448	53.724	77	252						
C4.5rules/Selection	MultiLayerPerceptron	0.3301	11758.5325	16789.1364	132.276	309.383	212	783	0.8983	4835.9518	5789.8202	45.189	48.224	77	252						
NearestClassifierOptimizer	MultiLayerPerceptron	0.0795	10747.6209	15871.9653	102.026	102.106	212	783	0.8457	1356.8183	1032.1721	118.188	118.103	77	252						
NaiveBayes	MultiLayerPerceptron	0.0795	10747.6209	15871.9653	102.026	102.106	212	783	0.8457	1356.8183	1032.1721	118.188	118.103	77	252						
NaiveBayes	MultiLayerPerceptron	0.1667	10479.3243	15348.1483	100%	100%	212	783	0.9989	1532.2515	1384.5116	0.448	53.724	77	252						
RandomCommittee	MultiLayerPerceptron	0.3311	10670.291	15689.4515	101.874	100.983	212	783	0.8983	4835.9518	5789.8202	45.189	48.224	77	252						
RandomizedPerceptronClassifier	MultiLayerPerceptron	0.0795	1317.291	2686.1363	93.138	17.076	212	783	0.9989	1532.2515	1384.5116	0.376	35.848	77	252						
RandomSubspace	MultiLayerPerceptron	0.0795	9489.724	1376.1762	92.206	94.574	212	783	0.9799	1643.5438	1482.6899	83.576	87.763	77	252						
RandomSubspaceClassifier	MultiLayerPerceptron	0.0795	9489.724	1376.1762	92.206	94.574	212	783	0.9799	1643.5438	1482.6899	83.576	87.763	77	252						
Vote	MultiLayerPerceptron	0.1667	10479.3243	15348.1483	100%	100%	212	783	0.9989	1532.2515	1384.5116	0.448	53.724	77	252						
WeightedClassifierEnsemble	MultiLayerPerceptron	0.3301	11758.5325	16789.1364	132.276	309.383	212	783	0.8983	4835.9518	5789.8202	45.189	48.224	77	252						

Elaboración propia.

Estos resultados proporcionan la confianza para simular escenarios con base al enfoque que se describe en la Figura 1, de la siguiente forma: El sistema de apoyo a la decisión se alimenta de los valores-registros proporcionados por el citricultor relacionados con variables de entrada – el Tipo de Suelo, Porta Injerto, Temporada de cosecha, los m.s.n.m en que se ubica el huerto, la Edad Promedio de los árboles en producción, el número de árboles en producción, el Tipo de Poda practicada al árbol, la Temperatura promedio prevaleciente en el periodo de cultivo, el promedio de los mm de lluvia durante el periodo de cultivo, los lt/ha de Foliar utilizados a cada árbol, los gr/árbol de Nutriente aplicados a cada árbol, los lt/ha de Herbicida aplicados al huerto. Las variables de salida son los Kg Cosecha, los Kg fruta exportable, Calidades de fruta, y los Kg fruta nacional.

CONCLUSIONES

Se construye una base de conocimiento que registra las variables de: Fecha Semanal, Tipo de Suelo, Porta Injerto, Temporada, m.s.n.m, Edad Promedio, Árboles en producción, Tipo de Poda, Temperatura, mm de lluvia, Foliar(lt/ha), Nutriente (gr/árbol), Herbicida (lt/ha), Kg Cosecha, kg fruta exportable, Calidades de fruta, Kg fruta nacional, para el cultivo de Lima persa. El entrenamiento se realiza con el 66.6% de los datos con validación cruzada con Percentage Split. La correlación resulta en 99.65%, con error medio absoluto de 895.79 kg, error absoluto relativo de 9.57%.

Estos resultados de validación generan la confianza para predicciones en la simulación de escenarios de producción de Lima persa, bajo la actual base de conocimiento. El seguimiento a estos resultados es el diseño de un sistema de apoyo a la decisión para estimar la calidad de Lima persa en huertos de temporal.

AGRADECIMIENTO

Esta investigación es financiada por el proyecto TECN M Clave: 7165.19.P.

BIBLIOGRAFÍA

[1] Chun Ching Lee, y C. Ou-Yang. (2009) *A neural networks approach for forecasting the supplier's bid prices in supplier selection negotiation process*, *Expert Systems with Applications*, 36, 2961-2970.

[2] Desheng Wu. (2009) *"Supplier selection: A hybrid model using DEA, decision tree and neural network"*, *Expert Systems with Applications*, 36. 9105-9112.

[3] Gaikwad, Lokpriya, and Vivek Sunnapwar. (2019). *"Supplier Evaluation and Selection in Automobile Industry."* *Industrial Engineering*, 1-12. <https://doi.org/10.5772/intechopen.84383>.

[4] Hakan Kagnicioglu C. (2006) *A fuzzy multiobjective programming approach for supplier selection in a supply chain*, *The Business Review*, Cambridge, Vol. 6, Num. 1, 2006.

[5] Fernández L. G., Alberto A. A. Lasserre, Marco M. A., Constantino G. M. S., Blanca O. I. R., Catherine Azzaro-Pantel. (2014) *An expert system for predicting orchard yield and fruit quality and its impact on the Persian lime supply chain*, *Engineering Applications of Artificial Intelligence*, Volume 33, Pages 21-30, <https://doi.org/10.1016/j.engappai.2014.03.013>.

[6] Fernández L. G., Alberto A. L., Catherine Azzaro-Pantel, Marco A. M. A., Rubén P.V., María del Rosario P. S. (2015) *Behavior patterns related*

to the agricultural practices in the production of Persian lime (Citrus latifolia tanaka) in the seasonal orchard, *Computers and Electronics in Agriculture*, Volume 116, Pages 162-172, <https://doi.org/10.1016/j.compag.2015.06.007>.

[7] Saman, Hassanzadeh Amin. y Jafar Razmi. "An integrated fuzzy model for supplier management: A case study of ISP selection and evaluation", *Expert Systems with Applications*, 36, 8639-8648, 2009.

[8] Stević, Željko. (2017). *"Criteria for Supplier Selection: A Literature Review International Journal of Engineering, Business and Enterprise Applications (IJEBEA) Criteria for Supplier Selection: A Literature Review."* *International Journal of Engineering, Business and Enterprise Applications (IJEBEA)* 19 (1): 23-27.

[9] Sung Ho Ha and Ramayya Krishnan. (2008) *A hybrid approach to supplier selection for the maintenance of a competitive supply chain*, *Expert Systems with Applications*, 34. 1303-1311.