

ARTIFICIAL NEURAL NETWORKS FOR SUSTAINABLE AGRIBUSINESS: A CASE STUDY OF FIVE ENERGETIC CROPS

REDES NEURALES ARTIFICIALES PARA AGRONEGOCIOS SOSTENIBLES: UN CASO DE ESTUDIO DE CINCO CULTIVOS ENERGÉTICOS

Mircea Untaru*, Vasile Rotarescu, Liliana Dorneanu

Ioan Slavici University, 144, Dr. A. Paunescu-Podeanu Street, 300587, Timisoara, Romania
(titusslavici@yahoo.com).

ABSTRACT

The growing agricultural economic environment referred to as agribusiness requires continuous balanced cost-benefit solutions. The use of artificial intelligence in this area provides complex solutions that are easily applicable. The objective of this study was to elaborate on innovative instruments from the field of artificial intelligence for the decision-making process related to energetic crops. The field of expertise of this paper is strongly related to current issues of sustainable development. The methodology used is artificial neural networks (ANN) and compares it with other tools. The targeted results regard the optimization of decision-making processes and the forecast of financial results in an agricultural economy. A case study of forecasting profits of five energetic crops is included.

Key words: energetic crops, neural networks, agribusiness, resource saving.

INTRODUCTION

The objective of this research was to contribute through practical solutions to optimize a balanced cost-benefit use of natural resources in agribusiness. Thus, the article suggests the use of energetic crops by firms. The research ensures an accessible artificial neural network (ANN) for helping such firms in profit estimation and decision making regarding the cultivation of those crops.

Environmental sustainability is a debated and supported matter in Europe and the world; energy savings is an urgent matter in agriculture. According

RESUMEN

El crecimiento del entorno agrícola-económico conocido como agronegocios requiere continuas soluciones equilibradas costo-beneficio. El uso de la inteligencia artificial en esta área ofrece soluciones complejas de fácil aplicación. El objetivo de este estudio fue elaborar instrumentos innovadores del campo de la inteligencia artificial para el proceso de toma de decisiones en cultivos energéticos. El campo de especialidad de este artículo está muy relacionado con los problemas actuales del desarrollo sostenible. La metodología usada es redes neuronales artificiales (ANN) y la compara con otras herramientas. Los resultados previstos consideran la optimización de los procesos de toma de decisiones y pronostican resultados financieros en una economía agrícola. Se incluye un estudio de caso de pronosticar utilidades de cinco cultivos energéticos.

Palabras clave: cultivos energéticos, redes neurales, agronegocios, ahorro de recursos.

INTRODUCCIÓN

El objetivo de este estudio fue contribuir a través de soluciones prácticas a optimar un uso equilibrado del costo-beneficio de los recursos naturales en los agronegocios. Así, el artículo sugiere el uso de cultivos energéticos por las empresas. La investigación asegura una red neural artificial (ANN) accesible para ayudar a estas empresas en la estimación de utilidades y toma de decisiones sobre la producción de estos cultivos.

La sostenibilidad ambiental es un asunto debatido y apoyado en Europa y el mundo; el ahorro de energía es un asunto urgente en la agricultura. De acuerdo con Hernández-Santoyo y Sánchez-Cifuentes (2003), se necesitan nuevos procesos en el área de ahorro de energía y su solución implica el uso de un sistema de trigeneración. Dentro de este marco

*Author for correspondence ♦ Autor responsable.

Received: January, 2011. Approved: July, 2012.

Published as ARTICLE in *Agrociencia* 46: 507-518. 2012.

to Hernandez-Santoyo and Sánchez-Cifuentes (2003), there is a need for new processes in the area of energy savings and their solution involves the use of a trigeneration system. Within this framework created by regulations and international agreements for the preservation and protection of the environment, a scientific approach to the agricultural economy has become increasingly important since the late 1990s. Hu and Kao (2007) point out that between 2001 and 2006, global sites where energy-saving ratios significantly improved include China, Hong Kong, Philippines, USA (which has the highest energetic efficiency level) and Chile-México-Taiwan. In Eastern Europe and Asia, Fischer *et al.* (2005) studied agro-ecological zones and supported the elaboration of global, regional and national assessments of agricultural potentials; the study provide a standardized framework for identifying climate soil and soil conditions relevant to crops. The models in this paper use environmental contexts as independent variables in forecasting profitable crops in agricultural businesses.

From the traditional features of the primary sector, the trend over the past decades has been toward the establishment of a business environment. Agricultural business (or agribusiness) represents an area of particular concern. The EU created a Common Agricultural Policy for European countries, later followed by the establishment of structural funds. This adequate specific legal European framework increased the regional development in weak rural economic areas. Bonanno (2003) describes three main directions concerning agriculture in Eastern Europe in the late 1990s: a wide variety in the primary sector, the role of the market in the reorganization of Eastern European agriculture and changing social stratification in rural regions. Previous guidelines have been developed within the context of agricultural transformation from an on-demand system to a market-oriented one. The use of energetic plants provides sustainable solutions for heating, but such crops can also grow in swamp areas, capitalizing on lands categorized as useless. The utilization of such plants in agribusiness is highly significant. However, in less developed countries, managers of agribusiness are hesitant to use such crops as a source of profit.

Different approaches are used to forecast profitable crops in agricultural businesses. Some

creado por los reglamentos y acuerdos internacionales para preservar y proteger el ambiente, un enfoque científico para la economía agrícola es cada vez más importante desde finales de 1990. Hu y Kao (2007) señalan que entre 2001 y 2006, los sitios globales donde las relaciones ahorro-energía mejoraron significativamente incluyen China, Hong Kong, Filipinas, EE.UU. (que tiene el más alto nivel de eficiencia energética) y Chile-México-Taiwan. En Europa oriental y Asia, Fischer *et al.* (2005) estudiaron las zonas agroecológicas y apoyaron la elaboración de evaluaciones mundiales, regionales y nacionales de los potenciales agrícolas; el estudio proporciona un marco estandarizado para identificar el clima, suelo y condiciones del suelo relevantes para los cultivos. Los modelos en este artículo usan los contextos ambientales como variables independientes para predecir cultivos rentables en los negocios agrícolas.

A partir de las características tradicionales del sector primario, la tendencia en las últimas décadas fue el establecimiento de un entorno empresarial. El negocio agrícola (o agronegocio) representa un área de interés particular. La UE creó una Política Agrícola Común para los países europeos, seguido con el establecimiento de fondos estructurales. Este adecuado y específico marco jurídico europeo aumentó el desarrollo regional de zonas rurales con una economía débil. Bonanno (2003) describe tres principales direcciones de la agricultura en Europa del Este a fines de los años 90: una amplia variedad en el sector primario, el rol del mercado en la reorganización de la agricultura de Europa del Este y la estratificación social cambiante en las regiones rurales. Directrices previas se desarrollaron en el contexto de transformación agrícola desde un sistema de demanda a uno orientado hacia el mercado. El uso de plantas energéticas proporciona soluciones sostenibles para la calefacción, pero estos cultivos también pueden crecer en áreas pantanosas, capitalizando tierras clasificadas como inútiles. La utilización de estas plantas en los agronegocios es altamente significativa. Sin embargo, en países menos desarrollados los administradores de agronegocios son reticentes a usar estos cultivos como fuente de utilidades.

Diferentes métodos se usan para pronosticar cultivos rentables en empresas agrícolas. Algunos estudios combinan áreas interdisciplinarias como los sistemas agrícolas dinámicos y no lineales. Estos requieren de técnicas y tecnologías avanzadas para soluciones

studies combine interdisciplinary areas such as non-linear and dynamic agricultural systems. These require advanced techniques and technologies for sustainable solutions in the primary sector. Moreover, the promotion of these technologies supports cost decreases and catalyzes sustainable development in agriculture (Murase, 2000).

Artificial neural networks are an effective tool for dealing with the complexity of agricultural data (high-variance, noise-affected, qualitative data). The use of neural networks in agribusiness has become frequent since the mid-1990s, and most of the research has addressed yield prediction, spatial modeling (irrigation management and spectral vegetation indices) and spatial-temporal forecasting (time series of the yield in a specific region).

One of the first uses of neural networks in agriculture is found in the study of Joerding *et al.* (1994), for estimating the yield of Bermuda grass (*Cynodon dactylon*) depending on the quantities of various fertilizers used on the crop. A study by Heinzow and Tol (2003) included seven of the most common crops in Germany and the authors constructed regional time series of crop yield under climate change, recording time series of temperature, precipitation and crop yields as input variables. According to the authors, the study was suited for the German regions considered and also for the adjacent European regions. Savin *et al.* (2007) constructed a neural network that predicted the crop yield for winter wheat in some regions of southern Russia with an average accuracy of approximately 75 %. Recent studies have proposed neural networks for forecasting yields for rice (*Oryza sativa*) in Northern India (Kumar, 2011), onion (*Allium cepa*) (Stastny *et al.*, 2011), tomato (*Solanum lycopersicum*) (Qaddoum *et al.*, 2011) and sunflower (*Helianthus annuus*) in saline fields (Dai *et al.*, 2011), taking into account the crop yield from an economical point of view. All of these studies require a level of knowledge more advanced than that of an investor without agricultural background and whose main objective is to establish a profitable agricultural business.

Our study considers five types of energetic crops in the moderate temperate continental climate specific to Western Romania. For each crops profit per ha was estimated for a three-year period. Six factors that influence the profit were identified, including natural disasters. The paper presents a model created through

sostenibles en el sector primario. Además, la promoción de estas tecnologías apoya una disminución de costos y cataliza el desarrollo sostenible en la agricultura (Murase, 2000).

Las AAN son una herramienta eficaz para enfrentar la complejidad de los datos agrícolas (datos de alta varianza, afectados por ruido, cualitativos). El uso de redes neurales en agronegocios es frecuente desde mediados de 1990, y la mayoría de la investigación ha sido para la predicción del rendimiento, modelado espacial (manejo del riego e índices espectrales de la vegetación) y pronóstico espacio-temporal (series de tiempo del rendimiento en una región específica).

Uno de los primeros usos de las redes neurales en la agricultura está en el estudio de Joerding *et al.* (1994), para estimar el rendimiento del pasto Bermuda (*Cynodon dactylon*) en función de las cantidades de varios fertilizantes usados en el cultivo. Un estudio de Heinzow y Tol (2003) incluyó siete de los cultivos más comunes en Alemania y se construyeron series de tiempo regional del rendimiento de los cultivos ante el cambio climático, registrando series de tiempo de temperatura, precipitación y rendimientos de los cultivos como variables de entrada. Según los autores, el estudio era adecuado para las regiones alemanas consideradas y para las regiones europeas adyacentes. Savin *et al.* (2007) construyeron una red neural que predijo el rendimiento de los cultivos de trigo de invierno en algunas regiones del sur de Rusia con una precisión media aproximada de 75 %. Estudios recientes han propuesto redes neurales para predecir los rendimientos en arroz (*Oryza sativa*) en el norte de la India (Kumar, 2011), cebolla (*Allium cepa*) (Stastny *et al.*, 2011), tomate (*Solanum lycopersicum*) (Qaddoum *et al.*, 2011) y girasol (*Helianthus annuus*) en campos salinos (Dai *et al.*, 2011), considerando el rendimiento de los cultivos desde un punto de vista económico. Todos estos estudios requieren un nivel de conocimientos más avanzado que los que un inversionista sin antecedentes agrícolas y cuyo principal objetivo es establecer un negocio agrícola rentable.

El presente estudio considera cinco tipos de cultivos energéticos en el clima moderado continental templado específico para el oeste de Rumania. Para cada cultivo, la utilidad por hectárea se calculó para tres años. Se identificaron seis factores que influyen sobre la utilidad, incluyendo los desastres naturales. El artículo presenta un modelo creado a través de ANN para determinar el nivel de utilidades de

ANN to determine the profit level of agricultural firms regarding the use of energetic crops.

MATERIALS AND METHODS

Theoretical aspects of artificial neural networks and their application to the case studies

In this section, a short summary of the main theoretical aspects of ANN and their use in this study is provided. Neural networks are considered the most accurate tools for economic decision-making (Slavici, 2006). Its learning capacity is most likely the fundamental feature of a neural network, and modern algorithms aim to emulate this characteristic by using computers (Russell and Norvig, 2002).

The fundamental features of ANN can be classified into two categories:

- 1) The ANN architecture which defines the structure and determines the number of neurons and their connections; its other features include the input/output (I/O), the synapse intensity, deviations and activations.
- 2) The ANN properties that consist of: the learning method, the synapse reactivation, and the continuous associations and comparisons of new information with existing one to assess how the new information is categorized.

Our ANN is trained to store a wide database regarding energetic plants and all of their parameters and usage features with various types of crops and geographical areas in Eastern Europe. The database has been subsequently used for economic forecasting and decision-making. The economic results of the crops have been forecasted, and decisions were made regarding the cultivation of the most profitable energetic crops.

General description of the database used in the application

A database was constructed using data collected by Ioan Slavici University by administering yearly questionnaires from 2008 to 2010 in Eastern Europe (three countries) on a sample of 120 agricultural firms. Additional data was collected during a series of experiments on the energetic willow (*Salix viminalis*) at the University's field laboratories. The collected data have been statistically processed using Statgraphics Centurion; the mean and dispersion were computed and the noise of the data (irrelevant values) was eliminated. The hypotheses were derived from the interpretation of the questionnaire. The University has agreed to the publication of the studies and results concerning the database that was used.

empresas agrícolas respecto al uso de cultivos energéticos.

MATERIALES Y MÉTODOS

Aspectos teóricos de las redes neurales artificiales y su aplicación para los estudios de caso

En esta sección se proporciona un breve resumen de los principales aspectos teóricos de ANN y su uso en este estudio. Las redes neurales se consideran las herramientas más precisas para tomar decisiones económicas (Slavici, 2006). Su capacidad de aprendizaje es muy probablemente el aspecto fundamental de una red neural, y los algoritmos modernos aspiran a emular esta característica usando computadoras (Russell y Norvig, 2002).

Las características fundamentales de ANN pueden clasificarse en dos categorías:

- 1) La arquitectura ANN que define la estructura y determina el número de neuronas y sus conexiones; sus otras características incluyen el input/output (I/O), la intensidad de la sinapsis, desviaciones y activaciones.
- 2) Las propiedades ANN que consisten en: método de aprendizaje, reactivación sináptica, asociaciones y comparaciones continuas de nueva información con la existente para evaluar como categorizar la nueva información.

Esta ANN está entrenada para almacenar una amplia base de datos de plantas energéticas y todo lo de sus parámetros y características de uso con varios tipos de cultivos y áreas geográficas en Europa del Este. La base de datos se usó subsecuentemente para pronóstico económico y toma de decisiones. Los resultados económicos de los cultivos se pronosticaron, y se tomaron decisiones respecto a la producción de los cultivos energéticos más redituables.

Descripción general de la base de datos usada en la aplicación

Una base de datos se construyó con datos recogidos por la Universidad Ioan Slavici administrando cuestionarios anuales del 2008 a 2010 en Europa del Este (tres países) a una muestra de 120 empresas agrícolas. Se recogió información adicional durante una serie de experimentos sobre el sauce energético (*Salix viminalis*) en los laboratorios de campo de la Universidad. Los datos se procesaron estadísticamente con el Statgraphics Centurion; la media y la dispersión se computaron y el ruido de los datos (valores irrelevantes) se eliminó. Las hipótesis de trabajo se derivaron de la interpretación del procesamiento del

The average results of the costs and generated income are presented in Tables 1 and 2.

The energetic crops for this study were energetic willow, miscanthus (*Miscanthus giganteus*), reed (*Phragmites australis*), sorghum (*Sorghum saccharatum*) and rapeseed (*Brassica rapa oleifera*). However, the users can introduce data for any type of energetic crop.

The data presented in Tables 1 and 2 represent average values of the costs and corresponding incomes. The database was constructed over three years by collecting multiple data, including plant type, soil, climate and specific conditions (groundwater and surface water gleying, salinity/sodicity, topsoil texture, soil pollution, slope, landslides, groundwater depth, liability to inundation, total porosity, calcium carbonate levels, soil reaction, physiologically useful volume, humus reserve, excess moisture, etc.) and economic criteria (land concession price, grouping of areas for insuring a minimum of 150 ha, the wages of the local workforce, etc.). Next, the incomes over multiple years were determined, and the final step was the determination of the profits.

cuestionario. La Universidad acordó publicar los estudios y los resultados de la base de datos usada.

Los resultados promedio de los costos e ingresos generados se presentan en los Cuadros 1 y 2.

Los cultivos energéticos para este estudio fueron el sauce energético, miscanthus (*Miscanthus giganteus*), carrizo o caña común (*Phragmites australis*), sorgo (*Sorghum saccharatum*) y colza (*Brassica rapa oleifera*). Sin embargo, los usuarios pueden introducir datos para cualquier tipo de cultivo energético.

Los datos presentados en los Cuadros 1 y 2 representan valores promedio de los costos e ingresos correspondientes. La base de datos se construyó en más de tres años recogiendo datos múltiples incluyendo tipo de planta, suelo, clima y condiciones específicas (agua subterránea y agua superficial gleying, salinidad/sódico, textura del suelo superficial, contaminación del suelo, pendiente deslizamiento de tierra, profundidad del agua subterránea, exposición a las inundaciones, porosidad total, niveles de carbonato de calcio, reacción del suelo, volumen fisiológicamente útil, reserva de humus, exceso de humedad, etc.) y criterios económicos (precio de concesión de tierras,

Table 1. Detailed average costs for energetic plant crops from 2008 to 2010.

Cuadro 1. Costos promedio detallados para cultivos de plantas energéticas del 2008 a 2010.

Plants	Plantation and soil preparation			Maintenance			Harvesting, depositing, drying			Total costs		
	Year			Year			Year			Year		
	1	2	3	1	2	3	1	2	3	1	2	3
Costs (€/ha)												
<i>Salix viminalis</i> (Energetic willow)	1450	0	0	211	256	195	313	298	302	1974	554	497
<i>Miscanthus giganteus</i> (Miscanthus)	2600	0	0	200	200	200	0	300	300	2800	500	500
<i>Phragmites australis</i> (Reed)	2500	0	0	200	200	200	0	300	300	2700	500	500
<i>Sorghum saccharatum</i> (Sorghum)	258	258	258	100	100	100	300	300	300	658	658	658
<i>Brassica rapa oleifera</i> (Rapeseed)	258	258	258	100	100	100	150	150	150	508	508	508

Table 2. Average production costs, income, profit and costs for energetic crops from 2008 to 2010.

Cuadro 2. Costos promedio de producción, ingresos, ganancias y costos para cultivos energéticos del 2008 a 2010.

Plants	Average price per unit (€/tonne)	Production (t/ha)			Income (€/ha)			Profit (€)		
		1	2	3	1	2	3	1	2	3
<i>Salix viminalis</i> (Energetic willow)	40	20	40	60	800	1600	2400	-1174	1046	1903
<i>Miscanthus giganteus</i> (Miscanthus)	40	0	12.5	20	0	500	800	-2800	0	300
<i>Phragmites australis</i> (Reed)	40	0	10	18	0	400	720	-2700	-100	220
<i>Sorghum saccharatum</i> (Sorghum)	24	90	90	90	2160	2160	2160	1502	1502	1502
<i>Brassica rapa oleifera</i> (Rapeseed)	480	2	2	2	960	960	960	452	452	452

The profit was calculated as the difference between income and total cost. In addition, the income has been calculated as a product of production and price per unit.

Sustainable decisions using artificial neural networks in cultivating energetic plants

For simulation purposes, we used MATLAB and its neural network toolbox to try predicting the financial gain of harvesting five energetic crops (energetic willow, miscanthus, reed, sorghum saccharatum and rapeseed) under various quantifiable conditions.

The list of conditions fed to the system is extracted from the following six one-dimensional column vectors X_i , with the value of i ranging from 1 to 6. Thus, X_1 represents "Plant type", X_2 - "Year of observation relative to planting year", X_3 - "Rainfall/year", X_4 - "State of the economy", X_5 - "Natural disasters" and X_6 - "Demand/supply market elasticity".

Because the study examined five plants, "Plant type" varies from 1 to 5 with the following interpretations: energetic willow plant, miscanthus plant, reed, sorghum saccharatum and rapeseed.

Even though the simulation takes into account the data collected from 2008 to 2010 through surveys, the actual plantations were conducted 10 years before the data were collected. Thus, the "Year of observation" vector contains relative values ranging from 1 to 10.

The production quantity is expressed in t/ha and rainfall is expressed in average mm/year. The "State of the economy" parameter can take only one of two values: "1," meaning that the economy was in a normal state when the data were collected, or "0," which is interpreted as indicating "bad economical times" or "economic crisis."

The "Natural disasters" vector reflects values of the amount of damage sustained by the crop in that year when being hit by a natural calamity (wildfire, drought, hail, etc.). Its values can be interpreted as follows: "0" indicates there were few or no natural problems associated with the crop and a 100 to 75 % harvesting record was obtained, "0.33" indicates that the crop was partially affected by nature and a 75 to 50 % harvesting record was obtained, "0.66" indicates that the crop sustained massive natural damage and a 50 to 25 % estimated harvesting potential was recovered, and "1" indicates that the crop was almost completely destroyed by natural events and only 25 to 0 % of it was recovered. The last input parameter of the system was the "Demand/supply" coefficient: a value less than "1" indicate that there was a demand deficit, a value of "1" indicate that the market was at an equilibrium and a value exceeding "1" indicate a supply deficit. By merging these vectors, the training matrix $P = [X_1 X_2 X_3 X_4 X_5 X_6]$ was obtained. Any line (row)

agrupación de áreas para asegurar un mínimo de 150 ha, salarios de la mano de obra local, etc.). Luego, se determinaron los ingresos de varios años y al final se determinaron las utilidades.

La ganancia se calculó como la diferencia entre ingreso y costo total. Además, el ingreso se calculó como un resultado de la producción y precio por unidad.

Decisiones sostenibles usando redes neurales artificiales en el cultivo de plantas energéticas

Para fines de simulación se utilizó MATLAB y su caja de herramientas de redes neurales para tratar de predecir el beneficio económico de la cosecha de cinco cultivos energéticos (saúce energético, miscanthus, carrizo, sorgo saccharatum y colza) bajo diversas condiciones cuantificables.

La lista de condiciones dadas al sistema se extrajo de los siguientes seis vectores X_i de columna unidimensional, con el valor de i desde de 1 a 6. Así, X_1 representa "Tipo de planta", X_2 - "Año de observación respecto al año de siembra", X_3 - "Lluvia/año", X_4 - "Estado de la economía", X_5 - "Desastres naturales" y X_6 - "Elasticidad de la demanda/oferta del mercado".

Dado que el estudio examinó cinco plantas, "Tipo de planta" varía de 1 a 5, con las siguientes interpretaciones: planta del saúce energético, planta de miscanthus, carrizo, sorgo saccharatum y colza.

Aunque la simulación considera los datos recogidos de 2008 a 2010 mediante encuestas, las plantaciones se efectuaron 10 años antes de recolectar los datos. Así, el vector "Año de observación" contiene valores relativos de 1 a 0.

La cantidad de producción se expresa en t/ha y la lluvia se expresa en promedio mm/año. El parámetro "Estado de la economía" puede sólo tomar uno de dos valores: "1," significa que la economía estaba en un estado normal al recolectar los datos, o "0," que se interpreta como indicando "malos tiempos económicos" o "crisis económica."

El vector "Desastres naturales" refleja valores de la cantidad de daños sufridos por el cultivo en ese año al sufrir una calamidad natural (incendios forestales, sequía, granizo, etc.). Sus valores se pueden interpretar así: "0" indica que había pocos o ningún problema natural asociado con el cultivo y se obtuvo un registro de cosecha de 100 a 75 %, "0.33" indica que el cultivo fue afectado parcialmente por la naturaleza y se obtuvo 75 a 50% de registro de cosecha, "0.66" indica que el cultivo sufrió un daño masivo natural y se recuperó 50 a 25 % potencial estimado de la cosecha, y "1" indica que el cultivo fue casi completamente destruido por los sucesos naturales y sólo se recuperó 25 a 0 %. El último parámetro del sistema fue el coeficiente "Demanda/oferta": un valor menor a "1" indica que había un déficit de la demanda, un valor de "1" indica que

in this newly formed matrix is considered a training sample for the neural network.

In the construction and use of the network (Figure 1), three steps were taken:

Step 1: Training of the network

The training of the network used a set of 90 records, randomly chosen, representing 75 % of the input data.

Step 2: Network validation

After training the network, the process continued with the actual evaluation of its performance (validation of ANN according to the latest version of the MATLAB program). The validation set consisted of 25 inputs, representing 20.83 % of the input data. This result was achieved by acquiring further input samples, applying them to the network and examining and comparing its output. It is from this output that the error rate per sample is calculated and further summed.

Step 3: Testing the network

The ANN, which has been trained in Step 1 and validated in Step 2, was tested using 5 records, representing 4.17 % of the input data.

el mercado estaba en equilibrio y un valor mayor a “1” indica un déficit en la oferta. Al combinar estos vectores, se obtuvo la matriz de entrenamiento $P = [X1 X2 X3 X4 X5 X6]$. Cualquier línea (fila) en esta matriz recién formada se considera una muestra de entrenamiento para la red neural.

En la construcción y uso de la red (Figura 1) se tomaron tres pasos:

Paso 1: Entrenamiento de la red

El entrenamiento de la red usó un conjunto de 90 registros escogidos al azar y representa 75.5 % de los datos de entrada.

Paso 2: Validación de red

Después de entrenar a la red, el proceso continuó con la evaluación real de su desempeño (validación de ANN de acuerdo a la última versión del programa MATLAB). El conjunto de validación consistió de 25 entradas, representando 20.83 % de los datos de entrada. Este resultado se logró adquiriendo nuevas muestras de entrada, su aplicación a la red y examinando y comparando su salida. A partir de este resultado la tasa de error por muestra se calcula y luego se suma.

Paso 3: Probando la red

La ANN, entrenada en el Paso 1 y validada en el Paso 2, se probó con 5 registros, que representan 4.17 % de los datos de entrada.

RESULTS AND DISCUSSION

Artificial neural network performance

For the training phase there was a strong correlation between targets and outputs, the correlation coefficient was 1 and the error $2.5e-007$ (Figure 2A). For the validation phase the correlation coefficient between the targets and outputs was 0.999, showing that the outputs were properly estimated (Figure 2B). For the test phase, the correlation coefficient between the outputs and the targets was 0.997, an indicator of




Figure 1. The topology of the neural net used by the system.
Figura 1. Topología de la red neural usada por el sistema.

RESULTADOS Y DISCUSIÓN

Rendimiento de la red neural artificial

Para la fase de entrenamiento hubo una fuerte correlación entre objetivos y resultados, con un coeficiente de correlación de 1 y error de $2.5e-007$ (Figura 2A). Para la fase de validación el coeficiente de correlación entre los objetivos y resultados fue 0.999, esto es, los resultados se calcularon adecuadamente (Figura 2B). Para la fase de prueba el coeficiente de correlación entre las salidas y las metas fue 0.997, un indicador de la alta precisión de la red (Figura 2C). Así, el coeficiente de correlación general entre las salidas y las metas fue 0.999 (Figura 2D). Esto representa un indicador del alto rendimiento alcanzado por la red propuesta.

La fase de validación se resume en el Cuadro 3. Las cantidades X1 a X6 representan las entradas de

the high accuracy of the network (Figure 2C). Thus, the overall correlation coefficient between outputs and targets was 0.999 (Figure 2D). This represents an indicator of the high performance achieved by the network we propose.

The validation phase is summarized in Table 3. The quantities X1 to X6 represent the inputs of the network, as depicted above. Oo the obtained output (the profit predicted by the network), Co the correctly measured output (the profit actually obtained while harvesting a particular crop) and Err (%) the signed percentage error, given by

$$Err(\%) = 100 - O_o / C_o * 100 \quad (1)$$

The absolute average error value observed from these evaluation data was 5.69 %. In the end, we

la red, como se describió. Oo representa la salida obtenida (la utilidad predicha por la red), Co la salida correctamente medida (la utilidad obtenida efectivamente al cosechar un cultivo en particular) y Err (%) el porcentaje de error firmado, dado por

$$Err(\%) = 100 - O_o / C_o * 100 \quad (1)$$

El valor absoluto de error promedio observado de estos datos de evaluación fue 5.69 %. Al final se obtuvieron los medios para predecir con exactitud la ganancia al cosechar cinco cultivos energéticos, considerando diversos parámetros no cuantificables, como lluvias, clima del mercado o elasticidad de la demanda.

El grupo objetivo de la presente aplicación se compone de los agentes económicos en el entorno




Figure 2. Regression error graphs.
Figura 2. Gráficas del error de regresión.

Table 3. Sample outputs of the model for the validation phase.
Cuadro 3. Salidas de la muestra del modelo para la fase de validación.

X1	X2	X3	X4	X5	X6	Oo	Co	Err (%)
1	2	750	1	0	1	1093.2	1180	-7.34 %
1	5	420	1	0.33	1	1147.9	1100	4.36 %
1	1	637	0	0	0.89	-1598.5	-1650	-3.12 %
1	10	610	1	0	1	2015.0	1960	2.81 %
2	4	450	1	1	1.7	-284.9	-280	1.75 %
2	6	850	1	0	1	297.1	300	-0.95 %
2	3	637	1	0.66	1.5	-105.98	-113	-6.21 %
2	7	637	1	0	0.42	-105.3	-101	4.3 %
3	1	710	1	0	1	-2778.3	-2700	2.9 %
3	2	637	0	0	0.5	-309.2	-295	4.83 %
3	7	637	1	1	2.3	-286.1	-260	-10.05 %
3	3	637	0	0.33	1.4	-111.6	-120	-7 %
4	5	637	1	0	1	1593.9	1502	6.12 %
4	2	750	1	0	1	1525.1	1592	-4.2 %
4	8	637	0	0	0.85	1045.8	1040	0.56 %
4	4	637	0	0.66	0.9	49.2	45	9.52 %
5	9	637	1	0.33	1.45	167.2	161.5	3.56 %
5	8	637	1	0.66	1.8	-138.3	-125	10.68 %
5	5	637	0	0	0.37	177.7	185	-3.91 %
5	4	410	1	0	1	471.6	452	4.34 %

obtained the means of accurately predicting the gain of harvesting five energetic crops, taking into account various non-quantifiable parameters such as rainfall, market climate and/or demand elasticity.

The target group of the present application is composed of the economic agents in the agricultural economic environment. Except for the classic economic benefit obtained by using such methods, social benefits can be obtained. These consist of quality improvement of the lands (sanitation of watery lands, cleared forests), saved energy (or consumption avoided), reduction of greenhouse gases that affect the environment and new jobs for an unskilled labor force during the break from the crop when the leaves fall. Additionally, it must be considered that during autumn agricultural machinery is used only for the crops. According to the European Commission, all of these benefits must be quantified (the revenue from the energy sale at appropriate shadow prices). The latter can be approximated, wherever possible, by estimating the willingness to pay for energy (the quantification of marginal costs incurred to acquire energy when installing and using private generators) (DG Regional Policy, 2008).

Once constructed, because of its ease of use, ANN represents an innovative tool for business

económico agrícola. Excepto para el beneficio económico clásico obtenido al usar tales métodos, pueden obtenerse beneficios sociales. Estos consisten en el mejoramiento de calidad de las tierras (saneamiento de tierras acuosas, bosques talados), energía ahorrada (o evitar el consumo), reducción de gases de efecto invernadero que afectan el ambiente y nuevos empleos para una fuerza laboral no calificada durante el descanso de la cosecha, cuando las hojas caen. Además, se debe considerar que durante el otoño la maquinaria agrícola se usa sólo para los cultivos. De acuerdo con la Comisión Europea, todos estos beneficios se deben cuantificar (los ingresos por la venta de energía a precios sombra apropiados). Este último se puede aproximar, siempre que sea posible, al estimar la disposición a pagar por la energía (la cuantificación de los costes marginales incurridos en la adquisición de energía al instalar y usar generadores privados) (DG Regional Policy, 2008).

Una vez construida, debido a su facilidad de uso, la ANN representa una herramienta innovadora para administración de negocios y está disponible incluso para administradores agrícolas medio expertos. Este instrumento representa una inversión para empresas pequeñas y resultará en tecnologías nuevas e

management that is available even for medium-skilled agricultural managers. Such an instrument represents an investment for small enterprises and will result in new innovative technologies being included in the agricultural sector, which Eastern Europe especially lacks. Directions for future research include the development of a quantitative analysis of the social benefits regarding this case.

Artificial neural networks optimization to increase the forecast accuracy

In this section we summarize the optimization of the neural network presented previously. Hence, it is necessary to stress the use of several statistical tools regarding the optimization of the neural networks used. In this case, the statistical tools are not for the economic analysis but for the network optimization (Slavici, 2006). From the user perspective, an ANN functions on the black box principle. In contrast, the computer scientist must create the most effective black box for users. Thus, the parameters of the network must be optimized.

The optimization function is the forecast accuracy and the input variables are the network topology, the learning method, the non-linearity function established, the number of hidden layers, the neuron number of each layer and the number of training epochs. The optimization was performed in two phases. First, a quasi-empirical optimization of the ANN was made using different values for the network's parameters. Second, the results obtained were statistically analyzed and a relationship between the input variables and the forecast accuracy was obtained. This phase was achieved according to the following methodology:

- 1) The most relevant variables were chosen by using the Fischer test, consisting of the number of training epochs (e) and the number of layers (s).
- 2) Scientific planning of the experiment was made (factorial model).
- 3) In the end, a second-degree model for the forecast accuracy was obtained:

$$\text{Forecast accuracy} = 43.543 + 11.501*s + 0.182*e - 1.542*s*s + 0.002*s*e \quad (2)$$

innovadoras que se incluyen en el sector agrícola, de lo que Europa del Este en especial carece. Las guías para futuras investigaciones incluyen el desarrollo de un análisis cuantitativo de los beneficios sociales en este caso.

La optimización de redes neuronales artificiales para aumentar la precisión de los pronósticos

En esta sección se resume la optimización de la red neural ya presentada. Así, es necesario acentuar el uso de varias herramientas estadísticas respecto a la optimización de las redes neurales usadas. En este caso, las herramientas estadísticas no son para el análisis económico sino para optimizar la red (Slavici, 2006). Desde la perspectiva del usuario, una ANN funciona sobre el principio de la caja negra. En contraste, el científico computacional debe crear la caja negra más eficaz para los usuarios. Así, los parámetros de la red deben ser optimizados.

La función de optimización es la precisión del pronóstico y las variables de entrada son la topología de la red, el método de aprendizaje, la función de no-linealidad establecida, el número de capas ocultas, el número de neuronas de cada capa y el número de épocas de formación. La optimización se realizó en dos fases. Primero, una optimización cuasi-empírica de la ANN se realizó usando diferentes valores para los parámetros de la red. Después, los resultados obtenidos se analizaron estadísticamente y se obtuvo una relación entre las variables de entrada y la precisión de los pronósticos. Esta fase se logró de acuerdo con la metodología siguiente:

- 1) Las variables más relevantes se eligieron usando la prueba de Fischer, que consta del número de épocas de formación (e) y el número de capas (s).
- 2) Se realizó la planificación científica del experimento (modelo factorial)
- 3) Al final se obtuvo un modelo de segundo grado para la:

$$\text{Precisión del pronóstico} = 43.543 + 11.501*s + 0.182*e - 1.542*s*s + 0.002*s*e \quad (2)$$

Su representación gráfica es como sigue (Figura 3):

Its graphic representation is as follows (Figure 3):

Following the optimization process described, the forecast accuracy increased. According to Figure 3, the forecast accuracy varied from an average value of 64 % with classical methods to over 95 % when the number of layers is close to 4 and the number of training epochs is close to 350. It can also be observed that the forecast accuracy is more affected by the number of training epochs than the number of layers, that is, for a given number of training epochs, the forecast accuracy is nearly constant when the number of layers increases. This result is useful for identifying the optimum value for the network parameters that ensures the maximum forecast accuracy.

CONCLUSIONS

In conclusion, our study provides useful information for the economic agents investing in agribusiness, in Eastern Europe or similar geoclimatic regions: a database containing information about previous experience in similar conditions and an optimized neural network which could accurately

Tras el proceso de optimización descrito, la precisión del pronóstico aumentó. De acuerdo con la Figura 3, la precisión del pronóstico varió desde un valor promedio de 64 % con métodos clásicos a más del 95 % cuando el número de capas está cerca de 4 y el número de épocas de formación está cerca de 350. También puede observarse que la exactitud del pronóstico es más afectada por el número de épocas de formación que el número de capas, es decir, para un número dado de épocas de formación, la exactitud del pronóstico es casi constante cuando el número de capas aumenta. Este resultado es útil para identificar el valor máximo para los parámetros de la red que aseguren la máxima precisión del pronóstico.

CONCLUSIONES

En conclusión, este estudio ofrece información útil para los agentes económicos que invierten en agronegocios en Europa del Este o regiones geoclimáticas similares: una base de datos que contiene información acerca de una experiencia anterior en condiciones similares y una red neural optimizada que podría predecir con precisión el resultado de varios




Figure 3. Forecast accuracy.
Figura 3. Precisión del pronóstico.

predict the outcome of various energetic crops. Thus, this paper expands the actual knowledge with information corresponding to a previously not investigated context: the outcome of several types of energetic plants in a specific geo-climatic area.

cultivos energéticos. Así, este artículo amplía el conocimiento actual con información que corresponde a un contexto no investigado previamente: el resultado de varios tipos de plantas energéticas en una área geoclimática determinada.

LITERATURE CITED

—Fin de la versión es español—



- Bonanno, A. 2003. Some reflections on Eastern European agriculture. An introductory essay to the special issue on agriculture in Eastern Europe. *Agric. Human Values* 10(1): 2-10.
- Dai, X., Z. Huo, and H. Wang. 2011. Simulation for response of crop yield to soil moisture and salinity with artificial neural network. *Field Crops Res.* 121: 441-449.
- DG Regional Policy. 2008. Guide to cost-benefit analysis of investment projects. http://ec.europa.eu/regional_policy/sources/docgener/guides/cost/guide2008_en.pdf (Accessed: November 2010).
- Fischer, G., S. Prieler, and H. Van Velthuizen. 2005. Biomass potentials of miscanthus, willow and poplar: results and policy implications for Eastern Europe in Northern and Central Asia Proceedings of the joint IEA Bioenergy Task 30 and Task 31 Workshop Sustainable Bioenergy Production Systems: Environmental, Operational and Social Implications 28(2): 119-132.
- Heinzow, T., and R. S. J. Tol. 2003. Prediction of crop yields across four climate zones in Germany: an artificial neural network approach, No FNU-34, Working Papers, Research unit Sustainability and Global Change, Hamburg University, <http://EconPapers.repec.org/RePEc:sgc:wpaper:34>. (Accessed: May, 2012).
- Hernandez-Santoyo, J., and A. Sanchez-Cifuentes. 2003. Trigenation: an alternative for energy savings. *Appl. Energy* 76(1-3): 373-382.
- Hu, J., and C. Kao. 2007. Efficient energy-saving targets for APEC economies. *Energy Policy* 35(1): 372-382.
- Joerding, W., Y. Li, and D. Young. 1994. Feedforward neural network estimation of a crop yield response function. *J. Agric. Appl. Econ.* 26(1): 252-263.
- Kumar, P. 2011. Crop yield forecasting by adaptive neuro fuzzy inference system. *Mathematical Theory and Modeling* 1 (3): 1-7.
- Murase, H. 2000. Artificial intelligence in agriculture *Computers and Electronics Agric.* 29(1-2): 1-2.
- Qaddoum, K., E. Hines, and D. Illiescu. 2011. Adaptive neuro-fuzzy modeling for crop yield prediction. *Proceedings of the 10th WSEAS International Conference on Artificial Intelligence, Knowledge Engineering and Data Bases (AIKED'11)*: 199-204.
- Russell, S., and P. Norvig. 2002. *Artificial Intelligence: A Modern Approach*. 2nd Edition. Prentice Hall Series in Artificial Intelligence. Fort Collins, CO. 1132 p.
- Savin, I., D. Stathakis, T. Negre, and V. A. Isaev. 2007. Prediction of crop yields with the use of neural networks. *Russian Agric. Sci.* 33(6): 361-363.
- Slavici, T. 2006. *Artificial Intelligence*. Eurostampa Publishing House. Timisoara, Romania. 208 p.
- Stastny, J., V. Konecny, and O. Trenz. 2011. Agricultural data prediction by means of neural network, *Agric. Econ.-Czech.* 57(7): 356-361.