

## **REDES NEURONALES PARA LA PREDICCIÓN DE PRECIOS EN EL SECTOR LÁCTEO ARGENTINO<sup>1</sup>**

Jimena Vicentin Masaro, Rodrigo García Arancibia  
Instituto de Economía Aplicada Litoral (IECAL)-Fac. de Ciencias Económicas,  
Universidad Nacional del Litoral. Moreno 2557 - S3000CVE-Santa Fe-Argentina  
jvicentin@fce.unl.edu.ar, rgarcia@fce.unl.edu.ar

Recibido 26 septiembre de 2016 y aceptado 30 de noviembre de 2016

---

### **Resumen**

Realizar pronósticos sobre precios resulta muy importante no sólo para la toma de decisiones de un sector productivo, sino también para la elaboración de políticas públicas; ya que permite reducir la incertidumbre de los posibles escenarios a los que se puede enfrentar dicho sector. Los precios son una variable clave en el análisis sectorial, y contar con estimaciones confiables de los mismos no es tarea fácil, mucho menos en países con alta volatilidad como lo es Argentina. A partir de una revisión de antecedentes, se ha encontrado que los métodos lineales multivariados han liderado en esta área de predicciones económicas. Sin embargo, trabajos recientes empiezan a implementar mecanismos no lineales que, mediante un diseño sencillo, han logrado una performance predictiva competentes a las primeras, al menos en el área económica. Dentro de estos mecanismos no lineales se encuentran las redes neuronales. El presente trabajo tiene como objetivo ajustar un modelo de red neuronal para realizar predicciones aplicadas al sector lácteo argentino, y comparar los resultados con las predicciones que arroja un modelo multivariado de series de tiempo. Sobre una base de datos mensual disponible para variables del sector desde 2000 a 2012, se logra obtener una red con tres capas, cuya capa interna tiene sólo dos nodos, para predecir los precios mensuales pagados a los productores tamberos. Los resultados obtenidos muestran que mediante una estructura sencilla y parsimoniosa de redes neuronales, pueden obtenerse mejores resultados predictivos respecto a alternativas más tradicionales de series de tiempo.

**Palabras Clave:** predicción, precios, redes neuronales, sector lácteo argentino

---

---

<sup>1</sup> Trabajo realizado en el marco del proyecto PICT 2014-2132-(2014)"Factores asociados con el comercio de lácteos argentina-Mercosur y perspectivas ante una potencial liberalización Mercosur-Unión Europea" y CAID 201101 00101-(2013) "Influencia de variables seleccionadas sobre la oferta láctea Argentina y la competitividad sectorial"

## **ARTIFICIAL NEURAL NETWORKS TO PREDICT ARGENTINE'S DAIRY SECTOR PRICES<sup>2</sup>**

Jimena Vicentin Masaro, Rodrigo García Arancibia  
Instituto de Economía Aplicada Litoral (IECAL)-Fac. de Ciencias Económicas,  
Universidad Nacional del Litoral. Moreno 2557 - S3000CVE - Santa Fe-  
Argentina.

jvicentin@fce.unl.edu.ar, rgarcia@fce.unl.edu.ar

Received September 26<sup>th</sup>2016, accepted November 30<sup>th</sup> 2016

---

### **Abstrac**

Forecasting prices is a very important aim not only to takes decision in a productive sector, but also for the development of policies in public sector; as it reduces the uncertainty of the possible scenarios that may face this productive sector. Prices are a key variable in the sectoral analysis, and doing good estimates of them is no easy task, much less in countries with high volatility like Argentina. Through a revision of bibliography, it has been found that multivariate linear methods have predominated in this area to economic forecasts. However, recent studies begin to implement nonlinear mechanisms, which with a simple design, have achieved a competent predictive performance to the first methodology, at least in the economic area. Within these new mechanisms, there are the nonlinear neural networks. This paper aims to get a neural network model to make predictions to the Argentine dairy sector, and compare its results with the predictions resulting in a multivariate time series model. It been obtained a monthly data of some variables in the sector since 2000 to 2012, and with them it was possible to obtain a network with three layers, the hidden layer has only two nodes, to predict the monthly prices paid to dairy farmers. The results show that by a simple and parsimonious neural network structure can be obtained better predictive results than traditional methodology.

**Key Words:** prediction, prices, neural network, argentine's dairy sector

---

---

<sup>2</sup> Work done under the framework of the project PICT 2132 -(2014) "Associated Factors to the Argentina-Mercosur commercial relation of dairy products and perspectives of a potential Mercosur- European Union liberalization" and CAID 201101 00101-(2013)"Effects of some selected variables over Argentine dairy supply and sectorial competitiveness"

## **1.INTRODUCCIÓN**

La predicción de los precios es una de las cuestiones claves en el análisis sectorial. Sin embargo, tanto el nivel de producción como los precios de los sectores agropecuarios son características altamente variables con fuertes dependencias de eventualidades, ya que están sujetos a shocks climáticos y políticos, complejizando la modelización de su comportamiento y, por consiguiente, la tarea de predecir o pronosticar su evolución futura (Jha y Sinha, 2013).

El complejo lácteo argentino no escapa a dicha complejidad y problemas de variabilidad a lo largo de su estructura. Es un sector que está integrado por niveles, a saber, la producción primaria por un lado; la industrialización por otro; la comercialización mayorista interna y externa; y por último, el consumo final (Castellano, Issaly, Iturrioz, Mateos, y Terán, 2009; Depetris, Rossini, García Arancibia, y Vicentin Masaro, 2011; Terán, 2008). El flujo de productos e insumos a lo largo de toda la cadena está coordinado por el sistema de precios, que además de ser clave para la distribución de ingresos sectoriales, constituye uno de los elementos críticos de los incentivos en la misma, y en la determinación de su competitividad.

Sin embargo, existen constantes conflictos entre los agentes que devienen, principalmente, de la falta de previsibilidad y transparencia en la formación de precios del sector. Una posible solución podría ser la decisión política de establecer las reglas de juego claras en el sector y transparentar el proceso de formación de precios, lo que permitiría reducir la variabilidad e imprevisibilidad del comportamiento de las variables claves en la toma de decisiones, a saber, los precios. Contar con estimaciones sobre la evolución futura de precios del sector, ayudaría en la toma de decisiones tanto de tipo productivas como de inversiones, ya que las mismas se realizarían sobre escenarios más probables. Por lo tanto, disponer de herramientas de predicción para dichos precios en Argentina, que a su vez sean confiables, sería de suma utilidad para todos los agentes de la cadena, incluso las decisiones de política estarían basadas sobre fundamentos reales y no en meras suposiciones.

En términos teóricos, no existe una sola herramienta de predicción; para problemas económicos multivariados, los VECM son los más utilizados en series de tiempo ya que, generalmente las variables no son

estacionarias y esta metodología tiene en cuenta esta cuestión de modo de no generar resultados espurios (Ahumada, y Cornejo, 2014; Arias, y Torres, 2004; Basso, 2009; Engle, y Granger, 1987; Granger, 1981; Lütkepohl, 2007; Otero, y Trujillo, 1993). Sin embargo, existe una utilización creciente de las ANN<sup>3</sup> en la modelización de series de tiempo con objetivos predictivos, dada su flexibilidad para reconocer tanto patrones lineales como no lineales (Binner, Gazaly, Chen, yChie, 2004; Huarng y Yu, 2006; Joeke, 2002; Maciel, y Ballini, 2010; Swanson y White, 1997; entre otros).

El presente trabajo tiene como objetivo utilizar esta última herramienta en el mercado lácteo argentino para luego, analizar su performance con respecto a resultados de otras metodologías comúnmente usadas, bajo la hipótesis de que podría resultar competente e incluso mejor para realizar predicciones.

### **1.1. Antecedentes**

Desde una perspectiva empírica-aplicada, existe literatura donde se compara la performance predictiva de los modelos de serie de tiempo tradicionales con los de ANN en aplicaciones de diferentes áreas. Dependiendo de los datos utilizados, algunos son univariados (Abudu, King, y Sheng, 2012; Claveria, y Torra, 2013; Jha, y Sinha, 2013; entre otros) y otros involucran múltiples variables (Binner *et al.*, 2004; Fouladgar *et al.*, 2013; Maciel, y Ballini, 2010; Otero, y Trujillo, 1993; Swanson, y White, 1997; entre otros). Los resultados obtenidos por dichos estudios fueron múltiples, pero en general destacaron la mejor performance de las ANN.

Con respecto a la predicción de precios agropecuarios específicamente, también se han encontrado antecedentes de estudios comparativos, sin embargo, todos ellos aplican técnicas de series de tiempo univariada versus ANN (Chakraborty, Mehrotra, Mohan, y Ranka, 1992; Hamm, y Brorsen, 1997; Kohzadi, Boyd, Kermanshashi, yKaastra, 1996; Zou, Xia, Yang, y Wang, 2007; entre otros). En estos casos univariados también se destaca la superior performance predictiva de las ANN en comparación con los modelos tradicionales.

---

<sup>3</sup> Por sus siglas en inglés *Artificial Neural Networks*

Por otro lado, con respecto a predicciones de precios del sector lácteo en particular sucede algo similar, con el agregado de que tampoco se observan aplicaciones de ANN, pero sí metodologías clásicas de series de tiempo, como por ejemplo, el trabajo de Fernández-Amador, Baumgartner y Crespo-Cuaresma (2010) o, el de Haden y Van Tassell (1988), entre otros (e.g. Hansen, y Li, 2015; Keough, 1991; Mosheim, 2012).

## 2. MATERIALES Y MÉTODOS

### 2.1. Marco Teórico

Utilizando la explicación de Heien (1977) sobre cómo se determinan los precios en los sectores agrícolas-ganaderos, y trasladándola al sector lácteo específicamente, se puede describir el funcionamiento de éste teniendo en cuenta la estructura de cadena así como los procesos de corto y largo plazo. En el equilibrio, Heien afirma que la cantidad ofrecida y demandada en cada nivel del sector se igualan, indicando los factores que afectan tanto a oferta como demanda para cada nivel, donde los precios del bien comercializado en el nivel, como también el de los bienes que de dicho producto se obtiene mediante el proceso productivo son las primeras variables tenidas en cuenta; y en segundo lugar, las variables productivas del nivel. Básicamente se puede resumir en que,

$$\begin{aligned} Q_{n_t}^o &= f_{on} (p_{n_t}^e, z_t^{on}), \\ Q_{n_t}^d &= f_{dn} (p_{n_t}^e, p_{n+1_t}^e, z_t^{dn}), \\ Q_{n_t}^o &= Q_{n_t}^d, \end{aligned} \quad (2.1)$$

donde  $Q_{n_t}^o$  son las cantidades ofrecidas en el nivel  $n$ , en el momento  $t$ ; y  $Q_{n_t}^d$  son las cantidades demandadas correspondientes;  $p_{n_t}^e$  son los precios esperados del bien en el nivel  $n$ ;  $p_{n+1_t}^e$  los precios esperados del producto que del bien se realiza en el nivel siguiente  $n+1$ ;  $z_t^{on}$  hace referencia a otras variables que pueden influir sobre las cantidades ofrecidas (o) o demandadas (d) en el  $n$ -ésimo nivel.

Sin embargo, en el corto plazo, puede suceder que la demanda minorista de lácteos se incremente por un aumento en el ingreso de los consumidores, lo que se traslada a la industria que, a su vez, demandará mayor cantidad de leche al sector primario para responder a dicho desequilibrio. Como la producción de leche cruda es inelástica en el corto plazo y no puede responder en forma inmediata, pasará un cierto tiempo hasta que la oferta pueda aumentar su producción y adecuarse a la nueva demanda. Mientras tanto, la industria habrá reducido/agotado los stocks, y ante la escasez relativa de leche, los precios al productor aumentarán. Ese aumento será trasladado al minorista, lo que enfriará la demanda, y ese aletargamiento o disminución, recomenzará un nuevo ciclo en la cadena. Por lo tanto, en el corto plazo se producirán desequilibrios entre la oferta y demanda, produciendo fluctuaciones en los precios resultantes, mientras que en el mediano/largo plazo deberán equilibrarse. En el corto plazo existen efectos de las cantidades sobre los precios a lo largo de la cadena, lo que Heien llama «Noción de la Dependencia del Precio».

## **2.2. Metodología**

Predecir datos de series de tiempo mediante ANN implica diseñar el procesamiento de patrones que se extienden en el tiempo. Un valor particular de una variable en el tiempo  $t$  puede depender no sólo de los valores pasados de la misma, sino también del valor en  $t$  de otras variables relacionadas (y sus respectivos valores anteriores). El tipo de ANN que contempla esta arquitectura, son aquellas inventadas por Rosenblatt (1958) llamadas perceptrón multicapa, ya que contienen varias capas con estructura no lineal.

Una red de este tipo tiene tres partes, una capa de entrada (o *input*), la parte oculta o *hidden* (que pueden ser una o más capas), y la capa de salida (*output*). En cada capa hay nodos, que están interconectados con las capas siguientes a partir de las ponderaciones (o pesos) las cuales son estimadas por medio de un proceso iterativo de modo de reducir la función de costo. Por lo tanto, para estimar una ANN primero se necesitan definir sus diferentes componentes, las relaciones entre ellos, así como los procedimientos y parámetros de estimación, a saber: (a) la arquitectura e interconexiones; (b) la/s función/es de activación o de transferencia; (c) la función de costo, que evalúa la/s salidas de la red con sus valores originales; (d) el algoritmo de entrenamiento, que cambia

de manera iterativa las ponderaciones para minimizar la función de costo.

Una formulación general de una ANN proalimentada<sup>4</sup> (o *feedforward*) con cuatro capas (dos ocultas) la posibilidad de incluirse una segunda capa oculta con un total de  $e$  nodos:

$$y_u = f_o \left( \sum_{d=1}^e w_d f_{h_2} \left( \sum_{j=1}^s w_j f_{h_1} \left( \sum_{i=1}^n w_{ij} x_i \right) \right) \right) \quad (2.2)$$

Donde  $n$  es el total de nodos en la capa de entrada;  $s$  la cantidad total de nodos en la capa oculta y,  $m$  la cantidad de nodos en la capa salida. Por otro lado,  $x_i$  es el  $i$ -ésimo *input*,  $w$  corresponde a las ponderaciones, las cuales pueden ser: (a) interconexiones *inputs-hiddenlayer* ( $w_{ij}$ ), (b) *hiddenlayer-output* ( $w_j$ ), o (c) *input-output* ( $w_u$ );  $f_{h_k}$  y  $f_o$  son las funciones de transferencias (o activación) de las capas ocultas y del *output*, respectivamente; y por último,  $y_u$  es el  $u$ -ésimo *output*.

Se utilizan dos tipos de funciones de activación, a saber, la logística para los nodos de la/s capas ocultas, y la lineal para la salida. Cuando el interés es hacer predicciones del *output*, la función lineal es el tipo de función de activación en la capa de salida a utilizar (Barrientos *et al.*, 2012).

Con respecto al diseño, se utiliza uno *ad-hoc*, donde las variables de entrada surgen de la teoría económica y, del conocimiento y la disponibilidad de información del sector económico de aplicación para reconocer los factores que pueden estar relacionados a lo largo de la cadena productiva láctea argentina. Se utiliza la variable de interés predictivo como neurona de salida. Y la cantidad de capas ocultas y sus correspondientes nodos, se seleccionan a partir de un procedimiento de prueba y error, quedando el modelo que más capacidad predictiva tenga, resguardando los requisitos de forma de las ANN.

---

<sup>4</sup> El flujo de información recorre a lo largo de la red en una única dirección o sentido

El procedimiento de aprendizaje es supervisado<sup>5</sup> y se utiliza un algoritmo de *Backpropagation* para la estimación de los pesos que interconectan los nodos de la red.

Los resultados serán analizados y comparados con los obtenidos mediante la modelización por medio de Modelos de Vectores de Corrección por el Error (*VECM*)<sup>6</sup> (Dickey, y Fuller, 1979, 1981; Enders, 1995; Engle, y Granger, 1987). Con cada metodología se pronostica el último año disponible, y a partir de las diferencias entre las predicciones y los valores reales observados se calculan tres medidas de error, a saber, la raíz del error cuadrático medio (*RSME*), la desviación media absoluta (*MAD*) y el máximo porcentaje de error (*MPE*).

### 2.3. Variables y fuentes

Las variables utilizadas son: a) los precios mensuales pagados al productor lácteo ( $P_{\text{prod}}$ ), medidos en \$/lt. (de interés predictivo); b) los precios mensuales minorista mix lácteos ( $P_{\text{min}}^{\text{mix}}$ ), medidos en \$/kg.; c) los precios mensuales mayorista mix lácteos ( $P_{\text{may}}^{\text{mix}}$ ), medidos en \$/kg.; d) los precios de exportación mix lácteos ( $P_{\text{exp}}^{\text{mix}}$ ), medidos en u\$/kg.; e) las cantidades (lts.) producidas mensuales de leche cruda ( $Q_{\text{lts}}$ ); y f) una indicadora de la estacionalidad alta en los precios al productor (Alta.precios). Los precios mix son un índice de precios en función de una canasta de bienes relevantes en cada nivel de la cadena, ponderados por su importancia en dicho nivel; y la variable relacionada con la estacionalidad es incorporada mediante una *dummy* indicando las estaciones con altos niveles de precios o por encima del nivel medio, cuando los precios son constantes.

Todas las variables tienen una periodicidad mensual que va desde 2000 a 2012; y las mismas (excepto la de estacionalidad) son transformadas en logaritmo, estos son, *lp.prod*, *lp.min*, *lp.may*, *lp.exp* y *lq.litros*, respectivamente. Esta transformación usualmente utilizada en economía, permite analizar las estimaciones en términos de

---

<sup>5</sup> Proceso que incorpora un tutor externo y/o información global de control, de modo que, con cada conjunto de *inputs*, se suministre a la red el *output* esperado y, permita evaluar el error producido. En economía, este tipo es el más utilizado.

<sup>6</sup>Por sus siglas en inglés *Vector Error Correction Model*

elasticidades; y el en contexto de ANN, permite corregir grandes diferencias de escala entre las variables. Las predicciones que se realizan son devueltas a su unidad de medida original, ya que el interés está sobre los precios al productor tambero. No se hacen ajustes por inflación, ya que no se han encontrado indicadores adecuados para deflactar los distintos niveles de precios, por lo que se está asumiendo un efecto equivalente de los cambios en el nivel general de precios sobre el precio recibido en todos los eslabones analizados.

Las fuentes son varias, pero principalmente es el Ministerio de Agricultura, Ganadería y Pesca de la Nación Argentina, sección Lechería (MiniAgri), de donde se obtuvo información sobre a) precios mayoristas por productos, con periodicidad mensual; b) cantidades destinadas al consumo interno de lácteos, mensuales por productos; así como c) la cantidad de leche cruda producida mensualmente en la Argentina.

En particular, los precios al productor primario lechero se obtienen tanto de la Secretaría de Lechería de la Provincia de Santa Fe y del MiniAgri. La serie de precios del MiniAgri tiene una longitud menor, y recién a partir de noviembre de 2009 comenzaron a publicar información sobre pagos por litro de leche a nivel nacional, por ello se hace un empalme entre las series de estas dos fuentes a modo de obtener una serie de precios con mayor longitud.

Por otra parte, los precios minoristas mensuales por productos, son obtenidos del Instituto de Estadísticas y Censos de la Provincia de Santa Fe (IPEC). A nivel nacional no se dispone de datos sobre los precios minoristas, por lo tanto, teniendo en cuenta que la provincia mencionada es una de las más importantes en el consumo nacional, se asume que los precios de la misma se comportan como lo hacen a nivel nacional. Claramente, ésta resulta una simplificación importante; sin embargo, ante la escasez de información, se propone como paliativo ante dicha situación.

### **3. RESULTADOS**

#### **3.1. Descripción General**

El precio al productor primario es la variable a predecir. En la figura 3.1 se muestra la evolución de la misma. A partir de la crisis del 2001-2002

los precios de la leche cruda han tenido una evolución positiva, que resulta más marcada a partir de 2007. A fines de 2009 y principios de 2010, los precios han tenido una escalada importante.

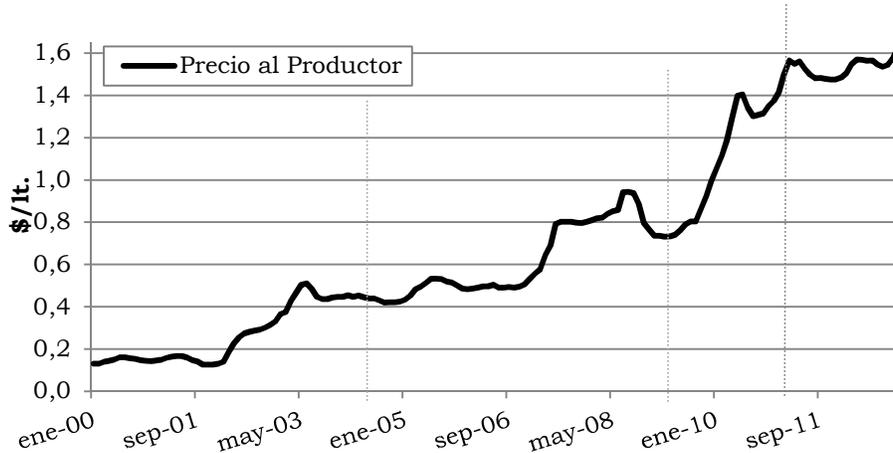


Figura 3.1. Precio Pagado al Productor. Período 2000-2012.  
 Fuente: Elaboración propia con datos de MiniAgri y Secretaría de Lechería de Santa Fe.

En cuanto a los precios mayoristas y minoristas del mix ponderado, la evolución también ha sido positiva y con similares comportamientos a los de la leche cruda (figura 3.2). La tasa de crecimiento de los precios minoristas ha sido más pronunciada que la de los mayoristas, sobre todo a partir de 2007. Sin embargo, antes de 2006, la evolución es muy similar entre ellos, con una pendiente similar y bastante estable.

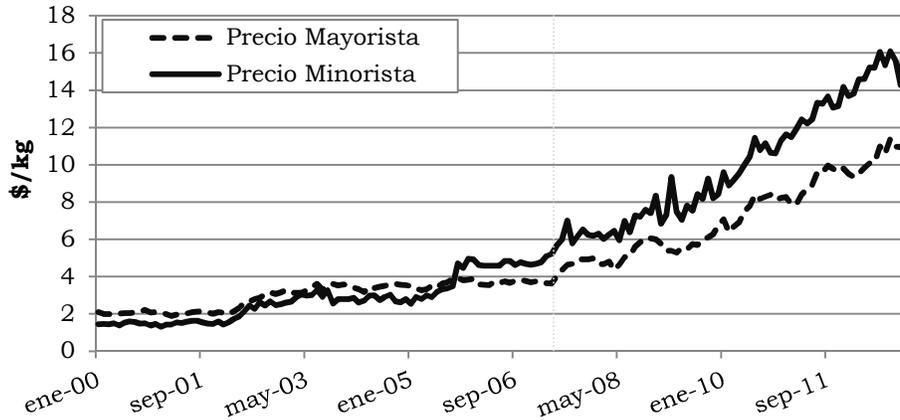


Figura 3.2. Precio (Índice) Mayorista y Minorista. Período 2000-2012.

Fuente: Elaboración propia con datos de IPEC y MiniAgri.

La cantidad de litros de leche cruda producida es otra de las variables consideradas relevantes, ya que la escasez relativa en el corto plazo puede generar fricciones en los precios de los bienes lácteos.

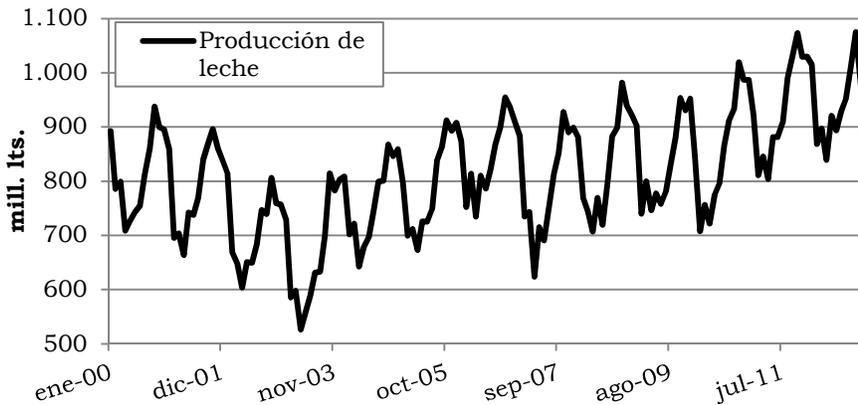


Figura 3.3. Cantidad (mill. lts.) de Leche Cruda Producida. Período 2000-2012.

Fuente: Elaboración propia a partir de datos de MiniAgri.

En la figura 3.3 se muestra la evolución de la cantidad de leche producida en Argentina, en el período de análisis. Se puede observar un comportamiento marcadamente estacional, pero con una clara

tendencia positiva a partir de 2003. Antes de 2003, la tendencia de las cantidades producidas de leche cruda era negativa.

Por otra parte, los precios de exportación son determinados afuera del país, por lo que suele ser considerados una variable exógena en la determinación de los precios locales<sup>7</sup>.

En la figura 3.4 se puede ver una evolución bastante parecida a la de los precios pagados al productor primario, excepto en el periodo 2007-2009 en donde se aplicaron precios de corte a los exportadores.

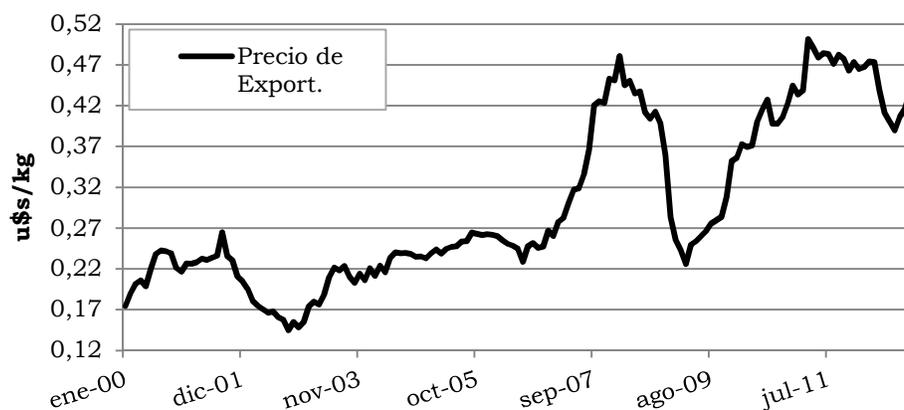


Figura 3.4. Precios (Índice) de Exportación de un Mix Lácteo. Período 2000-2012.  
Fuente: Elaboración propia a partir de datos de Aduana.

### 3.2. Estimaciones del precio pagado al productor

Con las variables expuestas en metodología, se ha estimado un VECM, cuyos parámetros estimados se encuentran en el Anexo. Dado que es un sistema multiecuacional el número de parámetros estimados es alto, ya que no sólo se estiman las relaciones de largo plazo (o parámetros de cointegración) sino que también los de corto plazo. Aquí no se exponen más detalles sobre esta metodología, porque no es de interés de los autores ahondar en la misma, pero se ha utilizado las estimaciones expuestas en el Anexo para realizar predicciones sobre el precio al productor para el año 2012, y calcular las correspondientes medidas de performance.

<sup>7</sup>En un trabajo anterior (Vicentin Masaro, 2016), se ha realizado un test de exogeneidad débil que lo confirma.

En cuando al modelo ANN, en la figura 3.5 se muestra la arquitectura seleccionada con los coeficientes estimados para las conexiones. Se ha estimado una ANN con tres capas, con cuatro nodos de entrada, dos en la oculta y uno sólo en la salida.

El algoritmo de estimación de la red ha convergido bastante rápido (menos de 100 iteraciones) a errores de entrenamiento relativamente cercanos a cero, tanto en el conjunto de entrenamiento como en el de prueba<sup>8</sup>

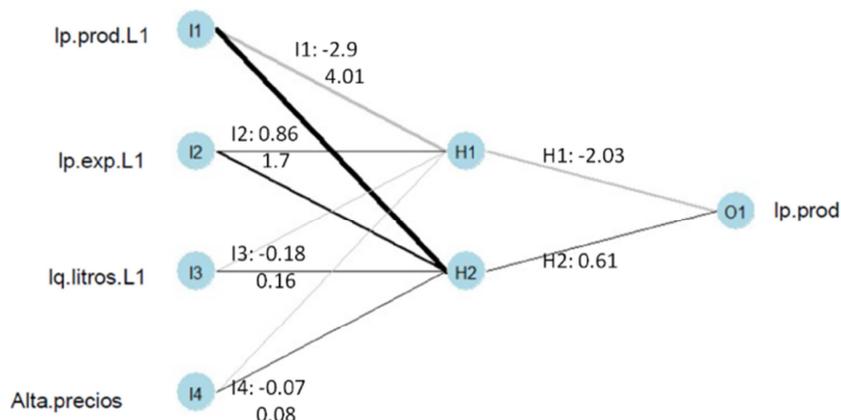


Figura 3.5. Estructura de la Red para Predecir el *lp.prod*.

Nota: Los nodos reguladores del error están contemplados en el modelo, aunque no son expuestos.

Fuente: Elaboración propia.

Las predicciones comparadas de ambos modelos se muestran en la figura 3.6. En promedio, las predicciones del VECM tienen errores superiores que las correspondientes a la de ANN (RMSE: 0.0387 vs. 0.0186; MAD: 0.034 vs. 0.0153, y MPE (%): 7.64 vs. 3.5, respectivamente). En la figura 3.6 se puede apreciar mejor la evolución

<sup>8</sup> El conjunto de datos se subdivide en tres: como se quieren realizar 12 predicciones y evaluar las mismas, se dejan de prueba los últimos 12 periodos disponibles. Esto hace una proporción aproximada de 92% y 8% para el conjunto de entrenamiento-validación y el de prueba, respectivamente. Luego, el 92% es subdividido, dejando un 5% de los mismos como datos de validación (7 periodos en validación y 136 en el de entrenamiento).

de las predicciones de ambos modelos y los valores reales del precio pagado al productor argentino de leche cruda.

También puede destacarse la mayor similitud de las predicciones de la ANN a los valores reales, así como también su evolución y comportamiento. Sin embargo, la evolución de las dos predicciones, en general, concuerda con la real, pero con una mayor dispersión de las del VECM.

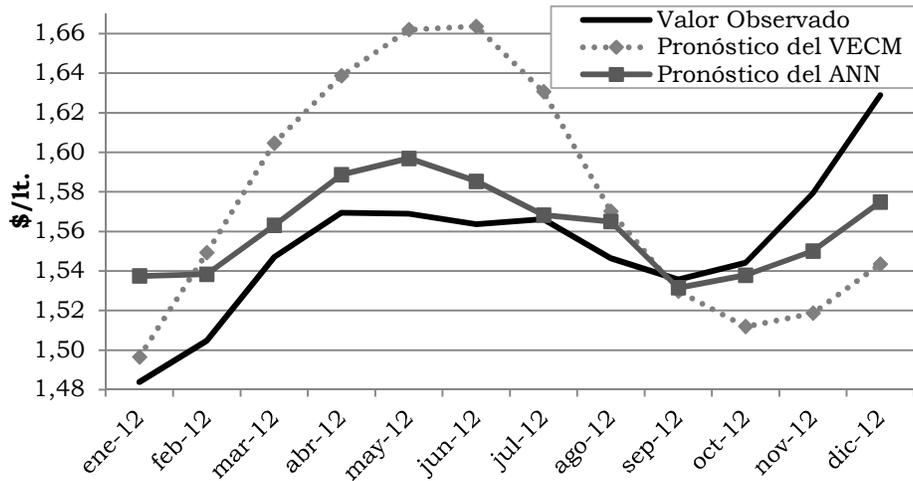


Figura 3.6. Valores Observados y Predicciones Realizadas para el Precio al Productor Lechero con los Modelos Estáticos. Año 2012.

Fuente: Elaboración propia

#### 4. CONCLUSIONES

Realizar pronósticos sobre el comportamiento de precios es de suma relevancia en el área económica en general, y en el sector lácteo en particular. Tener predicciones confiables que permitan tomar decisiones con menor incertidumbre es precisamente muy valorado por parte de los agentes que interactúan en el sector, dado que permitiría una planificación más seria sobre sus actividades. Sin embargo, no siempre es fácil contar con una metodología que permita arribar a tal objetivo. El grado de fiabilidad de las predicciones muchas veces depende de la

estabilidad del sector, y en particular el sector agrícola ganadero suele estar atado a imprevistos, tanto de tipo climáticos como políticos, que hacen difícil su proyección.

El sector lácteo argentino está compuesto por distintos niveles, y todos ellos, coordinados por el sistema de precios, objeto de constantes conflictos entre los distintos niveles del sector. En particular, los productores primarios son los que frecuentemente se encuentran en descontento con los precios pagados. Resultan ser el eslabón con menor poder de negociación y con problemas para obtener información sobre dichos precios recibidos. Por estos motivos, el interés predictivo de la presente tesis está centrado en los precios al productor primario lácteo. Con tal objetivo, se analizó una metodología relativamente nueva en el ámbito de predicciones económicas, con vistas de evaluar su performance.

Se utilizaron distintas variables que representan al sector y que se creen relevantes a la hora de modelar los precios primarios. La mayoría corresponde a los precios de cada nivel, aunque también se incorporaron tanto cantidades producidas como indicadora de estacionalidad del nivel con interés predictivo. Las variables índices intentan resumir el comportamiento de precios en un nivel donde existen multiproductos. Con una base de datos mensual desde 2000 hasta 2011, se modelizó con cada metodología, a saber, VECM y ANN, y se realizaron predicciones para el 2012 y calcularon medidas de performance para ambas metodologías.

Se pudo observar que si bien ambas predicciones siguen una evolución similar a los datos reales, los errores de predicción del modelo ANN fueron menores a los del VECM, con lo que se concluye que en términos predictivos la utilización de la ANN permite cometer menores errores que el VECM con un modelo más parsimonioso y simple. Por consiguiente, para predecir los precios pagados a los productores primarios de leche cruda, dicho modelo es el más adecuado.

En este caso particular, un modelo de ANN resulta más apropiado para realizar predicciones, pero estos resultados no implican que lo sea para todos los casos. El presente es un intento por comenzar a evaluar esta metodología, siendo de fundamental relevancia destacar que la misma debe seguir siendo mejorada, de modo de estudiar modelizaciones más

complejas y que impliquen proceso de búsquedas y arquitecturas más mecanizadas y que se sometan a procesos de evaluación más severos.

## **BIBLIOGRAFÍA**

Abudu, S., King, J. P. y Sheng, Z. (2012). Comparison of the Performance of Statistical Models in Forecasting Monthly Total Dissolved Solids in the Rio Grande. *Journal of the American Water Resources Association*, 48(1), 10–24.

Ahumada, H. y Cornejo, M. (2014). Explaining Commodity Prices by a Cointegrated Time Series-Cross Section Model. *Empirical Economics*, 48(4), 1667–1690.

Arias, E., y Torres, C. (2004). *Modelos VAR y VECM para el Pronóstico de Corto Plazo de las Importaciones de Costa Rica* (Documento de Trabajo No. 22). Obtenido de la página del Departamento de Investigaciones Económicas del Banco Central de Costa Rica: <http://www.bccr.fi.cr/investigacioneseconomicas/metodoscuantitativos/>. Barrientos et al., 2012

Basso, M. A. (2009). *Variaciones en los Precios y Tipo de Cambio. La Paridad de Poder de Compra Argentina* (Tesis de Maestría). Universidad Nacional de Córdoba, Córdoba, Argentina.

Binner, J. M., Gazel y, A. M., Chen, S. H., y Chie, B. T. (2004). Financial Innovation and Divisia Money in Taiwan: Comparative Evidence from Neural Network and Vector Error-Correction Forecasting Models. *Contemporary Economic Policy*, 22(2), 213–224.

Castellano, A., Issaly, L., Iturrioz, G., Mateos, M., y Terán, J. C. (2009). *Análisis de la Cadena de la Leche en Argentina* (Documento de Trabajo No. 4). Obtenido de la página del Instituto Nacional de Tecnología Agropecuaria (INTA): <http://inta.gob.ar/documentos/analisis-de-la-cadena-de-la-leche-en-argentina-2>.

Chakraborty, K., Mehrotra, K., Mohan, C. K., y Ranka, S. (1992). Forecasting the Behavior of Multivariate Time Series Using Neural Networks. *Neural Networks*, 5(6), 961–970.

- Claveria, O. y Torra, S. (2013). Forecasting Tourism Demand to Catalonia: Neural Networks vs. Time Series Models. *EconomicModelling*, 36, 220–228.
- Depetris, E., Rossini, G., García Arancibia, R. y Vicentin Masaro, J. (2011). *Competitividad del Complejo Lácteo Santafesino*. Santa Fe, Argentina: Ediciones UNL.
- Dickey, D. A. y Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*, 74(366a), 427–431.
- Dickey, D. A. y Fuller, W. A. (1981). Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. *Econometrica*, 49(4), 1057–1072.
- Enders, W. (1995). *Applied Econometrics Times Series*. New York, United States: Wiley.
- Engle, R. F. y Granger, C. W. J. (1987). Cointegration and Error Correction: Representation, Estimation and Testing. *Econometrica*, 55(2), 251–276.
- Fernández-Amador, O., Baumgartner, J. y Crespo-Cuaresma, J. (2010). *Milking The Prices: The Role of Asymmetries in The Price Transmission Mechanism for Milk Products in Austria* (Working Paper No. 2010-21). Retrieved from University of Innsbruck website: <http://eeecon.uibk.ac.at/wopec2/repec/inn/wpaper/2010-21.pdf>
- Fouladgar, M. M.; Yazdani, M.; Khazaei, S.; Zavadskas, E. K. y Fouladgar, V. (2013). Comparison of Vector Time Series and ANN Techniques for Forecasting of WTI Oil Price. *Economic Computation and Economic Cybernetics Studies and Research (ECECSR)*, 47(4), 19–35.
- Granger, C. W. J. (1981). Some Properties of Time Series Data and Their Use in Econometric Model Specification. *Journal of Econometrics*, 16(1), 121–130.
- Haden, K. L. y Van Tassel, L. W. (1988). Application of Vector Autoregression to Dynamic Relationships Within the U.S. Dairy Sector. *North Central Journal of Agricultural Economics*, 10(2), 209–216.
- Hamm, L. y Brorsen, W. B. (1997). Forecasting Hog Prices with a Neural Network. *Journal of Agribusiness*, 15(1), 37–54.

Hansen, B. G. y Li, Y. (2015). *Future World Market Prices of Milk and Feed Looking into the Crystal Ball* (Discussion Paper No. 2015/17). Retrieved from NHH Dept. of Business and Management Science website:  
[ttp://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=2592976](http://papers.ssrn.com/sol3/papers.cfm?abstract_id=2592976).

Heien, D. (1977). Price Determination Processes for Agricultural Sector Models. *American Journal of Agriculture Economics*, 59(1), 126–132.

Huarng, K. y Yu, T. H. K. (2006). The Application of Neural Networks to Forecast Fuzzy Time Series. *Physica A: Statistical Mechanics and its Applications*, 363(2), 481–491.

Instituto Nacional de Estadísticas y Censos (2015) de la Nación Argentina. URL: [www.indec.mecon.gov.ar/](http://www.indec.mecon.gov.ar/)

Jha, G. K. y Sinha, K. (2013). Agricultural Price Forecasting Using Neural Network Model: An Innovative Information Delivery System. *Agricultural Economic Research Review*, 26(2), 229–239.

Joekes, S. (2002). *Aplicación de Redes Neuronales Robustas en Series de Tiempo: Un Estudio Comparativo* (Tesis de maestría). Universidad Nacional de Córdoba, Córdoba, Argentina. Keough, 1991;

Kohzadi, N.; Boyd, M. S.; Kermanshahi, B. y Kaastra, I. (1996). A Comparison of Artificial Neural Network and Time Series Models for Forecasting Commodity Prices. *Neurocomputing*, 10(2), 169–181.

Lütkepohl, H. (2004a). Univariate Time Series Analysis. In H. Lütkepohl y M. Kräzig. (Ed.), *Applied Time Series Econometrics*, Cambridge, United Kingdom: Cambridge University Press.

Maciel, L. S., y Ballini, R. (2008). Design a Neural Networks for Time Series Financial Forecasting: Accuracy and Robustness Analysis. *Anales do 9º Encontro Brasileiro de Finanças*, Sao Paulo, Brazil.

Ministerio de Agricultura, Ganadería, Pesca y Alimentos (SAGPyA) de la Nación Argentina. (2015). URL: [http://www.minagri.gob.ar/site/\\_subsecretaria\\_de\\_lecheria/lecheria/index.php](http://www.minagri.gob.ar/site/_subsecretaria_de_lecheria/lecheria/index.php)

Mosheim, R. (2012). *A Quarterly Econometric Model for Short-Term Forecasting of the US Dairy Industry* (Technical Bulletin No. TB-1932).

Washington, United States: US Department of Agriculture. Retrieved from <http://purl.umn.edu/184305>

Otero, J. M. y Trujillo, F. (1993). Predicción Multivariante y Multiperíodo de una Serie Temporal Económica Mediante una Red Neuronal. *Estadística Española*, 35(133), 345-375.

Swanson, N. R. y White, H. (1997). Forecasting Economic Time Series Using Flexible versus Fixed Specification and Linear versus Nonlinear Econometric Models. *International Journal of Forecasting*, 13(4), 439-461.

Terán, J. C. (2008). *Caracterización de la Cadena Agroalimentaria de la Leche en la Provincia de Santa Fe*. (Informe Anual 2008). Rafaela, Argentina: Instituto Nacional de Tecnología Agropecuaria. Obtenido de: <http://inta.gob.ar/documentos/caracterizacion-de-la-cadena-agroalimentaria-de-la-leche-en-la-provincia-de-santa-fe>

Vicentin Masaro, J. (2016). Predicción de Precios mediante Modelización Multivariada de Series de Tiempo. Una Aplicación al Sector Lácteo Argentino (Tesis de maestría). Universidad Nacional de Córdoba, Córdoba, Argentina.

Zou, H. F.; Xia, G. P.; Yang, F. T. y Wang, H. Y. (2007). An Investigation and Comparison of Artificial Neural Network and Time Series Models for Chinese Food Grain Price Forecasting. *Neurocomputing*, 70(16), 2913-2923.

### **ANEXO**

Se estima un modelo VEC con cuatro rezagos y tendencia en el vector de cointegración, el cual resultó ser uno sólo. Todas las variables resultaron ser  $I(1)$  según test de Dicke y Fuller Aumentado y *KPSS*. Las estimaciones de los parámetros del VECM se muestran en la tabla A.1. Los resultados corresponden a un vector de cuatro variables endógenas, a saber, el precio al productor, el precio mayorista, el minorista y las cantidades producidas de leche cruda (todas en logaritmo); y dos exógenas: el precio de exportación (en logaritmo) y la estacionalidad. Siendo las variables endógenas  $I(1)$ , se estimó un VECM con cuatro rezagos<sup>9</sup>, y una tendencia lineal en el vector de cointegración.

---

<sup>9</sup> Con 4 rezagos los residuos resultaron normal, sin autocorrelación serial ni heterocedasticidad condicional, con un 5% de nivel de significancia.

| <b>Vector de Cointegración</b> |                       |  |  |  |
|--------------------------------|-----------------------|--|--|--|
|                                | Coeficientes:         |  |  |  |
| <b>lp.prod</b>                 | 1                     |  |  |  |
| <b>lp.may</b>                  | -0.32995 (0.24242) ·  |  |  |  |
| <b>lp.min</b>                  | -0.26516 (0.24787) ·  |  |  |  |
| <b>lq.litros</b>               | 3.35858 (0.34725)***  |  |  |  |
| <b>Tendencia</b>               | -0.01107 (0.00403)*** |  |  |  |

| <b>Modelo de Corrección del Error (ECM)</b> |                          |                          |                         |                          |
|---|--------------------------|--------------------------|-------------------------|--------------------------|
|   | Diff.lp.prod             | Diff.lp.may              | Diff.lp.min             | Diff.lq.lts              |
| ECT <sup>1</sup>                            | -0.04514<br>(0.01813)*   | -0.07222<br>(0.01659)*** | 0.044973<br>(0.03803)   | -0.15953<br>(0.02781)*** |
| Constante                                   | 0.94583<br>(0.37859)*    | 1.51395<br>(0.34639)***  | -0.92611<br>(0.79422)   | 3.27572<br>(0.58081)***  |
| lp.exp                                      | 0.00839<br>(0.01201)     | 0.04412<br>(0.01098)***  | -0.01579<br>(0.02518)   | 0.07639<br>(0.01842)***  |
| Alta.precios                                | -0.03731<br>(0.01012)*** | 0.00211<br>(0.00926)     | 0.026 (0.02123)         | 0.05829<br>(0.01553)***  |
| Diff.lp.prod.L1                             | 0.462105<br>(0.08853)*** | 0.430427<br>(0.08099)*** | 0.37703<br>(0.18571)*   | 0.16613<br>(0.13581)     |
| Diff.lp.may.L1                              | 0.06933<br>(0.11284)     | -0.43704<br>(0.10325)*** | 0.34182<br>(0.23672)    | -0.41843<br>(0.17311)*   |
| Diff.lp.min.L1                              | -0.05222<br>(0.04323)    | 0.00804<br>(0.03956)     | -0.63079<br>(0.0907)*** | 0.15482<br>(0.06633)*    |
| Diff.lq.lts.L1                              | -0.16042<br>(0.05912)**  | 0.31269<br>(0.05409)***  | -0.222<br>(0.12401) ·   | 0.32888<br>(0.09069)***  |
| Diff.lp.prod.L2                             | 0.20973<br>(0.09934)*    | 0.135491<br>(0.0909)     | -0.030039<br>(0.20841)  | 0.05226<br>(0.1524)      |
| Diff.lp.may.L2                              | -0.00341<br>(0.11396)    | -0.36673<br>(0.10427)*** | 0.12069<br>(0.23906)    | -0.60629<br>(0.17483)*** |
| Diff.lp.min.L2                              | -0.05372<br>(0.05027)    | 0.05305<br>(0.046)       | -0.23297<br>(0.10547)*  | 0.22965<br>(0.07713)**   |
| Diff.lq.lts.L2                              | -0.15639<br>(0.0699)*    | 0.38232<br>(0.06396)***  | -0.04826<br>(0.14665)   | 1.01556<br>(0.10724)***  |
| Diff.lp.prod.L3                             | -0.11267<br>(0.09114)    | 0.02134<br>(0.08339)     | 0.26749<br>(0.19121)    | -0.04026<br>(0.13983)    |
| Diff.lp.may.L3                              | -0.05811<br>(0.10289)    | 0.05108<br>(0.09414)     | 0.34776<br>(0.21585)    | -0.10682<br>(0.15785)    |
| Diff.lp.min.L3                              | 0.00925<br>(0.04352)     | 0.0638<br>(0.03982)      | -0.01745<br>(0.09131)   | 0.1727<br>(0.06677)*     |

|                                    |                      |                      |                       |                       |
|------------------------------------|----------------------|----------------------|-----------------------|-----------------------|
| Diff.lq.lts.L3                     | 0.06847<br>(0.06881) | 0.04541<br>(0.06296) | -0.13976<br>(0.14435) | 0.533453<br>(0.10556) |
| R <sup>2</sup>                     | 0.6479               | 0.5474               | 0.3987                | 0.6132                |
| R <sup>2</sup> Ajustado            | 0.6024               | 0.489                | 0.3212                | 0.5633                |
| Estadístico<br>F <sub>16,124</sub> | 14.26                | 9.374                | 5.14                  | 12.29                 |

Tabla A.1. Estimaciones del VECM.

Notas: Significativo al nivel del: · 10%, \* 5%, \*\* 1%, \*\*\* 0.1%

<sup>1</sup>Error CorrectionTerm.

Fuente: Elaboración propia.