



UNIVERSIDAD DE CHILE

FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

EVALUACIÓN DE PROGRAMACIÓN DE COMPRAS DE  
COMMODITIES AGRÍCOLAS BASADA EN MODELOS DE  
PREDICCIÓN DE PRECIOS

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL  
INDUSTRIAL

CRISTIÁN ALBERTO PACHECO ROBERT

PROFESOR GUÍA:  
PATRICIO CONCA KEHL

MIEMBROS DE LA COMISIÓN:  
RODOLFO URRUTIA URIBE  
VÍCTOR BUCAREY LÓPEZ

SANTIAGO DE CHILE  
2017

## **RESUMEN DE LA MEMORIA PARA OPTAR AL**

**TÍTULO DE:** Ingeniero Civil Industrial

**POR:** Cristián Pacheco Robert

**FECHA:** 21/08/2017

**PROFESOR GUÍA:** Patricio Conca Kehl

### **EVALUACIÓN DE PROGRAMACIÓN DE COMPRAS DE COMMODITIES AGRÍCOLAS BASADA EN MODELOS DE PREDICCIÓN DE PRECIOS**

En el mundo financiero, el precio de los commodities suele ser difícil de predecir debido a que se ven afectados por diversos factores, existiendo numerosas investigaciones gracias a la cantidad de información disponible. Sin embargo, la mayoría usa información “perfecta” para sus predicciones, constituyendo este trabajo un aporte, pues para predecir se usó información que hubiera estado disponible en la realidad, agregando un fin práctico al estudio.

El trabajo se realizó en la empresa IANSA, dentro la Gerencia de desarrollo estratégico, estudiando las compras realizadas por las áreas de Nutrición animal y Mascotas, pertenecientes a la unidad de negocios llamada Nutrición animal. Se tiene como fin el buscar establecer estrategias de compras factibles que permitan reducir los costos de compra de materias primas agrícolas y poder desarrollar ventajas competitivas frente a otros actores del mercado, abarcándose en este estudio, el afrechillo, triticale, maíz, y soya. Estos últimos representaron el 23% del costo de producción de la unidad en 2015 (15 MM USD), y sumándole el resto de materias primas, el 63% (42 MM USD).

En primer lugar, se realizó un estudio del mercado del trigo, maíz, y soya, para comprender su cadena de comercialización y variables que deben ser tomadas en cuenta, complementando estas últimas con las identificadas en la revisión bibliográfica, y agrupándose finalmente en mercado chileno, mercado internacional, macroeconomía, productos relacionados, y clima.

Siguiendo la bibliografía consultada, se usaron series de tiempo multivariadas, y adicionalmente regresiones lineales para facilitar el uso diario. Para la calibración se usó información entre 2006 y 2014, y para la evaluación, información entre 2015 y 2016, realizando predicciones a 1, 3, y 6 meses, cuyo MAPE fue menor a 10% en el caso del VECM en todos los períodos, mostrando un buen nivel de ajuste, y diferencias muy pequeñas respecto de la regresión.

En base a las predicciones se generaron estrategias de compras a 3 y 6 meses, que se compararon con la estrategia de IANSA, estrategia de compra mensual sin ninguna anticipación, y simulaciones del comportamiento de IANSA, todas durante el período 2015 y 2016. Se tuvo como resultado que siempre fue más conveniente la estrategia a 6 meses, con el maíz en Mascotas como principal fuente de ahorros, con 73 MM CLP (0,11 MMUSD) entre 2015 y 2016 frente a compras del área, equivaliendo a un 2% de ese costo (3.830 MM CLP o 5,89 MMUSD).

## AGRADECIMIENTOS

Termina un período de alrededor de un año trabajando en este proyecto, y si bien me gusta el tema, me da gran satisfacción y alegría terminar definitivamente, y poder disfrutar de lo que sigue.

Agradezco a todos quienes de una u otra manera hicieron posible que llegara hasta acá, y pudiera terminar de buena manera. En primer lugar, agradezco a mi familia por darme la oportunidad de estudiar, y estar presentes en momentos en que me compliqué un poco, aunque a veces fueran un poco exagerados.

A mi polola, Catalina Squella (Cata), por todo el apoyo, la buena onda, la preocupación, y la alegría, no solo en la vida universitaria, sino que en todos los aspectos de la vida. Y por escuchar varios monólogos sobre el tema que estaba haciendo en la tesis, y quejas por distintas causas, las que me ayudaba a dejar pasar por ser en realidad insignificantes.

A mis amigos de la universidad, por estar presentes para hablar del tema, y también obviamente, por estar siempre disponibles para salir en grupo y pasarlo bien. Víctor Puente (Vicky) y Emilio (Emily) tienen mención especial. Con el primero, al estar ambos en este proceso, nos juntamos periódicamente durante el último semestre para hablar de nuestros temas, y también para ir al gimnasio, aunque esto duró un par de semanas y luego se abortó por flojera de cada uno y los plazos de entrega de la tesis. Emilio me ayudó a pensar y verbalizar algunas cosas que eran difíciles de explicar, que luego usé para este trabajo. Eso sí, algunas veces me dejaba más complicado por empezar a hacerme miles de preguntas sobre el tema, y la forma en que lo estaba desarrollando.

Con mis amigos del colegio no hablé mucho del tema ya que la mayoría no hace tesis, y en realidad no se dio tanto el tema como para entrar en detalles. Pero esto no significa que no hayan sido un aporte, ya que siempre han inventado excusas para salir y pasarlo bien, especialmente Ricardo Ríos (Rioré), quien cuenta con gran insistencia, la cual a pesar de todo es muy valorada. No puedo agradecer de forma especial a Rafael Pérez (Perene), ya que está en Canadá y no pudo continuar su tradición de ayudar a los del grupo en la tesis.

A mi profesor guía, Patricio Conca, por darse el tiempo en varias ocasiones de juntarnos para hablar del tema y contarle mis dudas. Discutimos bastante y a veces no nos entendíamos porque el tema es bastante enredado de explicar, pero sirvieron mucho sus consejos.

Agradezco finalmente, a todos los que trabajaron conmigo en IANSA e hicieron posible que desarrollara el tema en esa empresa y pudiera resolver mis dudas, las cuales no fueron pocas, ya que no sabía nada del mundo agrícola; Daniel Feig, Magdalena Torrealba, y Carol Araya. Dentro de este grupo incluyo también a Santiago Camaño, quien, si bien trabaja en el sur y no en Santiago, siempre estuvo dispuesto a contestar las múltiples preguntas que le hice.

## TABLA DE CONTENIDO

1	INTRODUCCIÓN Y ANTECEDENTES GENERALES .....	1
1.1	Introducción .....	1
1.2	Características de la Organización/ Empresa .....	4
1.3	Mercado y/o Marco institucional.....	9
1.3.1	Mercado del maíz, trigo, y productos relacionados con el trigo: .....	10
1.3.2	Mercado internacional de la soya: .....	17
1.4	Desempeño organizacional .....	21
1.4.1	Mascotas: .....	21
1.4.2	Nutrición Animal: .....	23
2	DESCRIPCIÓN DEL PROYECTO Y JUSTIFICACIÓN .....	26
2.1	Información del área de la empresa en que se desarrolla el trabajo .....	26
2.1.1	Situación actual del proceso de compras:.....	27
2.2	Identificación del problema u oportunidad y su relevancia .....	31
2.3	Identificación de la hipótesis y posibles alternativas de solución para resolver el problema u oportunidad .....	33
2.4	Propuesta de valor de las posibles soluciones.....	34
3	OBJETIVOS .....	38
3.1	Objetivo general .....	38
3.2	Objetivos específicos.....	38
4	MARCO CONCEPTUAL.....	39
4.1	Modelos usados en la literatura y variables consideradas .....	39
4.2	Modelo de Vector de Corrección de Errores (VECM).....	42
4.3	Modelo de regresión lineal.....	43
5	METODOLOGIA .....	44
6	ALCANCES .....	48
7	VARIABLES Y SU DESCRIPCIÓN PARA LA IMPLEMENTACIÓN .....	49
7.1	Introducción.....	49
7.2	Variables .....	51
7.2.1	Variables dependientes: .....	51
7.2.2	Variables independientes:.....	52
8	RESULTADOS .....	61
8.1	Introducción.....	61
8.2	Resultados del modelo VECM (Modelo de Vector de Corrección de Errores)....	64
8.2.1	Estimación.....	64

8.2.2	Predicciones .....	75
8.3	Resultados del modelo de Regresión Lineal .....	79
8.3.1	Estimación .....	79
8.3.2	Predicciones .....	82
8.4	Programación de compras .....	86
8.4.1	Introducción .....	86
8.4.2	Estrategias de compra usadas como escenario de comparación.....	90
8.4.3	Resultados .....	92
8.5	Síntesis.....	102
9	DISCUSIÓN, CONCLUSIONES, Y POSIBLES LINEAS DE INVESTIGACIÓN.....	105
9.1	Discusión .....	105
9.2	Conclusiones .....	107
9.3	Recomendaciones .....	110
9.4	Posibles líneas de investigación .....	111
10	BIBLIOGRAFÍA .....	113
11	ANEXOS .....	116

# 1 INTRODUCCIÓN Y ANTECEDENTES GENERALES

## 1.1 Introducción

Históricamente las organizaciones han intentado desarrollar ventajas competitivas que les permitan tener una mejor posición en el mercado, respecto de sus competidores. En los últimos años la búsqueda de estas ventajas ha estado orientada al uso de la información para generar conocimiento que en un principio no estaba disponible, y con ello crear valor.

En esta búsqueda de generación de conocimiento para las organizaciones e industrias, la predicción de precios de commodities es un tema que ha sido ampliamente estudiado tanto a nivel nacional como mundial por académicos y distintas organizaciones, y en particular, los commodities agrícolas, debido a su gran influencia en múltiples industrias, especialmente la alimenticia. Siendo usados para su predicción por lo general modelos estadísticos, como modelos estructurales y series de tiempo principalmente, aunque también últimamente modelos como redes neuronales.

Para esta investigación se usarán modelos de series de tiempo multivariados conocidos como Modelos de vector de corrección del error (VECM por sus siglas en inglés), los cuales han demostrado un gran performance en cuanto a su poder predictivo de los precios que se intentan modelar, y una menor complejidad que modelos estructurales. Adicionalmente, se usarán regresiones lineales de manera de intentar simplificar los modelos para hacer más fácil su uso.


Los commodities agrícolas son ampliamente usados en la elaboración de alimentos tanto de consumo humano como de consumo animal. En este trabajo se pondrá el foco en alimentos de consumo animal, en particular perros y gatos, y ganado equino y bovino. En este tipo de alimentos, las materias primas juegan un rol muy importante dentro del costo total de los productos, por lo que un ahorro en este ámbito puede aumentar de manera significativa la eficiencia en su proceso de producción.

El mercado de las materias primas agrícolas, en particular del trigo y maíz en Chile, y la soya a nivel internacional, las cuales son los insumos a ser investigados, es bastante complejo, ya que existen múltiples interacciones entre distintos agentes de la cadena de suministro y distintas caracterizaciones para cada materia prima según el uso que se le vaya a dar, como humedad, porcentaje de proteínas, entre otros.

Las interacciones entre agentes, y múltiples factores producen variaciones en los precios internacionales y locales que en gran cantidad de ocasiones son

difíciles de predecir, teniendo en algunos casos bajas o alzas abruptas. Aunque como se puede ver en la Figura 1.1, es común que se presenten tendencias sostenidas por algunos meses. Por ejemplo, desde inicios de 2014 el precio de los 3 commodities presentados sufre una sostenida disminución en su valor, siendo la soya la única que ha podido recuperar cierta parte de su valor. En cambio, el trigo y el maíz han seguido bajando, especialmente el primero si es que se analiza con mayor detalle su precio.

**Figura 1.1:** Precio FOB Golfo de México internacional maíz, trigo, y soya en Bolsa de Chicago entre 2006 y 2016.



*Fuente: Elaboración propia en base a información de Indexamundi<sup>1</sup>.*

El estudio del mercado realizado a nivel local para el trigo y el maíz, y a nivel internacional para la soya, permite distinguir aquellos factores o agentes que influyen en mayor medida en los precios, como, por ejemplo, el hecho de que en el maíz Agrosuper es por lejos el mayor comprador, y que el precio del maíz es en gran medida influenciado por esta organización, o que China es el mayor importador de soya a nivel mundial, con alrededor del 65% del consumo total de este commodity.

También, se descubren importantes complejidades que dificultan la estimación de los costos que se tendrán que pagar por las materias primas. Algunos factores son el capital del cual dispone el proveedor, capacidad de almacenamiento, si ya dispone de la materia prima o no, entre otros. Todas estas variables transforman el problema en uno que es claramente no determinístico. Por esto, y debido a que el interés del trabajo está en la predicción de precios, se deja el estudio acabado de las condiciones que propone cada proveedor de materia prima para la venta de su producto para un trabajo posterior.

<sup>1</sup> Indexamundi es un portal donde se recopila información desde las instituciones financieras más relevantes a nivel mundial como bolsas de comercio, Banco mundial, entre otros, permitiendo recrear series históricas de precios.

La investigación se realiza en la empresa IANSA, empresa con bastante antigüedad en el país (alrededor de 65 años), y cuyos productos son comercializados en todos los supermercados del país. Se trabaja en las áreas Mascotas y Nutrición Animal, de manera de buscar mayores eficiencias en el proceso de compras de trigo, maíz y soya, representando alrededor del 25% del costo de producción de los productos de dichas áreas. El hecho de representar un alto porcentaje del costo total de producción de los productos de ambas áreas y la experiencia que tiene IANSA en productos agrícolas son la base para tomarlos en cuenta para este primer acercamiento a un proceso de compras que involucre predicción de precios.

Estas áreas presentan realidades dispares, pues la primera (Mascotas), que produce alimentos para perros y gatos, posee una pequeña participación en su mercado (alrededor del 7%), buscando consolidarse como un actor relevante en un mercado que se encuentra en constante crecimiento en los últimos años. En cambio, Nutrición Animal, cuyos productos se enfocan en bovinos y equinos, es un área ya consolidada, liderando ambos mercados con participaciones que rondan el 45% en bovinos y el 40% en equinos.

Actualmente, el proceso de compra de esos insumos se hace por parte de compradores técnicos, con vasta experiencia en el área, la cual usan para pronosticar precios y cerrar acuerdos con proveedores para el abastecimiento de las plantas. No obstante, no se hace uso de modelos que permitan apoyar los juicios de los compradores, y poder contrastar las compras realizadas con recomendaciones del modelo para generar una mayor trazabilidad y poder premiar o capacitar a los compradores.

Se espera comprender qué variables pueden tener influencia en las materias primas a estudiar, para hacer uso de los modelos nombrados anteriormente para pronosticar los precios mensuales del trigo y maíz puesto en la Región Metropolitana, y el precio mensual FOB de la soya puesto en el Golfo de México.

En base a esto se analiza si es que se alcanza una precisión que sea adecuada para ser usada como predicción de precios de compra de los insumos, y de ser así, se establecen estrategias que permitan aprovechar el conocimiento generado a través de los modelos de predicción para reducir el costo del proceso de compra al comprar en los momentos más convenientes, comparándolas frente a distintos escenarios para probar su real efectividad y posibilidad de aplicación en la realidad.



## 1.2 Características de la Organización/ Empresa

IANSA es una empresa privada chilena perteneciente al rubro de los alimentos, cuyo año de fundación es 1953. Inició sus operaciones en el área del azúcar, pero con el paso de los años fue agregando más negocios a su quehacer diario.

**Visión:** “Seremos la empresa de alimentos líder en comercialización de dulzura en Chile. En todos los mercados en que participamos, superaremos las expectativas de nuestros clientes y consumidores con innovación, y de forma rentable para nuestros accionistas, operando responsablemente con nuestros colaboradores, la comunidad y el medio ambiente”<sup>2</sup>.

**Misión:** “En IANSA somos líderes en comercialización, distribución y producción de dulzura en Chile –abasteciéndonos de producción nacional e importaciones– y mantenemos una participación relevante en el mercado de nutrición animal. Buscamos en nuestros negocios la permanente satisfacción de nuestros clientes, la adecuada rentabilidad para nuestros accionistas y el bienestar de nuestros colaboradores y proveedores”<sup>3</sup>.

Sus valores:

- Fundamentales: Transparencia, integridad, Valoración Integral de las Personas.
- Organizacionales: Orientación al cliente, confiabilidad, iniciativa, eficiencia, innovación.

El directorio de la empresa está compuesto por Joaquín Noguera (presidente), Gerardo Varela (vicepresidente), y los directores Patricio Claro, Sergio Guzmán, Arturo Mackenna, Rafael Muguero, y Gustavo Subercaseaux. A su vez, el comité de ejecutivos está integrado por José Luis Irrázaval (Gerente General), Luis Castro (Gerente Auditoría Interna), Cristián Morán (Gerente Administración y Finanzas), Paul de la Taille-Tréinville (Fiscal y Gerente de Personas), Daniel Feig (Gerente de Supply Chain y Proyectos), Rafael Thomas (Gerente General Mascotas), Raimundo Díaz (Gerente Comercial), Karl Huber (Gerente General Patagoniafresh), Álvaro Prieto (Gerente Agrícola y Operaciones), y Fernando Martínez (Gerente General ICATOM).

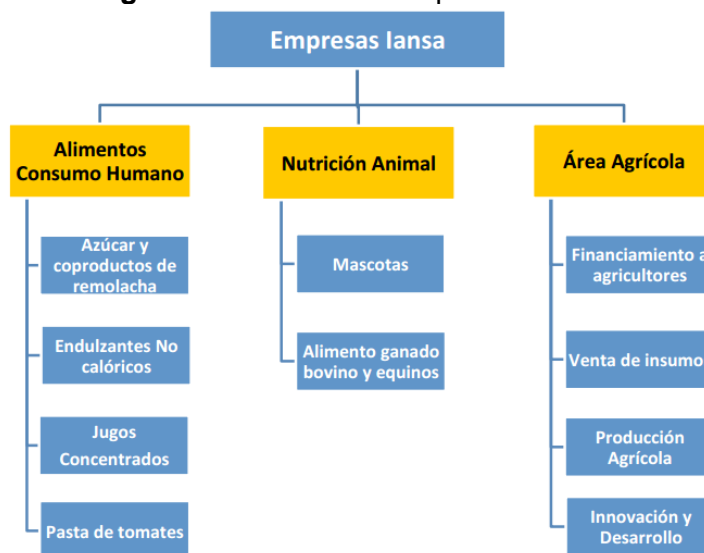
La empresa está dividida en tres unidades de negocios: Alimentos de consumo humano, Nutrición Animal (Si bien en la Figura 1.2 aparece como “Nutrición Animal”, en la práctica se le llama “Nutrición Animal y Mascotas”, haciendo referencia a los dos negocios que comprende, llamándosele de esa forma en lo que sigue del trabajo), y Área Agrícola. En la Figura 1.2 se pueden ver las

---

<sup>2,2</sup> Memorias IANSA, 2015

distintas áreas que existen en la empresa.

**Figura 1.2:** Estructura Empresas IANSA.



*Fuente: Memorias IANSA 2015.*

De manera de poder visualizar adecuadamente el funcionamiento de las distintas unidades de IANSA, estas se agrupan en las líneas de productos mostradas en la Figura 1.3, destacando el Azúcar y coproductos como principal fuente de ingresos. No obstante, presentan bajo margen, siendo los primeros en este indicador las pastas de tomates y jugos, y nutrición animal y mascotas.

**Figura 1.3:** Resultados de líneas de productos de IANSA en 2015.

Línea de productos	Ingresos (MMUSD)	Participación en Ingresos de IANSA(%)	Margen bruto (%)	Margen neto (%)
Azúcar y coproductos	298,4	54%	21%	4%
Nutrición animal y mascotas	70,9	13%	24%	7%
Agrícola	102,4	18%	15%	3%
Pasta de tomates y jugos	82,4	15%	27%	14%

*Fuente: Elaboración propia en base a Memorias IANSA 2015.*

Sus productos son consumidos por la mayoría de las personas a nivel nacional, en el caso del azúcar. Los mayores clientes a nivel industrial de IANSA son Embotelladora Andina, Embotelladoras Chilenas Unidas, Wal-Mart Chile Comercial, Nestlé Chile, Coca Cola Embonor, entre otros, llegando a otros mercados como Estados Unidos, México, Canadá y Japón.

Está catalogada como una empresa grande de acuerdo con la clasificación del Servicio de Impuestos Internos, teniendo más de 2600 trabajadores e ingresos por más de 530 MM USD. En el año 2014 figuraba dentro de las 150 empresas

más grandes del país<sup>4</sup>.

Sus operaciones se encuentran en Perú y Chile, con una planta productiva en Ica en el primero, y una oficina central, dos oficinas comerciales, dos centros de distribución, cuatro oficinas agrícolas, y nueve plantas productivas de diversos negocios en el segundo (Anexos Imagen 1).

Dentro de su principal línea de productos (Azúcar y coproductos) IANSA ha desarrollado una importante ventaja frente a otros competidores del mercado mundial al poseer uno de los rendimientos de remolacha más altos en todo el mundo, alcanzando el récord de rendimiento en 2010, 2011, y 2013<sup>5</sup>. Este rendimiento es sobre los agricultores con los que tiene contrato de compra de remolacha.

IANSA no se dedica a la plantación de materias primas para consumo propio, sino que compra a productores. En el caso particular de la remolacha, realiza gran investigación para desarrollar productos que aumenten el rendimiento de los cultivos y su calidad, siendo prueba de ello haber alcanzado el mayor rendimiento a nivel mundial en la remolacha, al trabajar de la mano con los agricultores con los que establece contratos de compra.

El proyecto estudiará el proceso de compras de la unidad de negocios de **Nutrición Animal y Mascotas**, desde el área de **Desarrollo Estratégico**. Se recuerda que, si bien en la Figura 1.2 la unidad se llama “Nutrición Animal”, en la práctica se le llama “Nutrición Animal y Mascotas”, haciendo referencia los dos negocios distintos que comprende. Esta unidad, como se menciona anteriormente, representó 14% de los ingresos del grupo IANSA en el segundo trimestre de 2015.

Si bien esta unidad es muy pequeña en comparación con la de azúcar, ha ganado participación, teniendo desde 2012 una participación bastante estable entre el 12,6% y 13,1% del total de ingresos (Figura 1.4). Además, posee un alto margen bruto que la ubica como la segunda unidad con mayor margen de la empresa.

**Figura 1.4:** Evolución indicadores financieros Nutrición Animal y Mascotas.

Año	Ingresos (MMUSD)	Participación en Ingresos de IANSA(%)	Margen bruto (%)
2011	60,9	9,5%	23,6%
2012	76,1	12,7%	25,8%
2013	78,7	12,6%	24,3%
2014	81	13,1%	23,0%
2015	70,9	12,8%	24,0%

*Fuente: Elaboración propia en base a Memorias de IANSA.*

<sup>4</sup> Ranking revista América Economía, Mayores empresas de Chile, 2014.

<sup>5</sup> Memorias IANSA, 2015.

Los productos de estas unidades son destinados a alimentación para mascotas en el caso del área Mascotas, dentro de la cual destacan las marcas Cannes y Minninos. En el caso de Nutrición animal, se comercializan principalmente a través de las marcas Suralim y Cosetán en los productos para bovinos, y Optimix para los equinos.

Las marcas del área Mascotas están orientadas al consumo de los hogares, siendo posible encontrarlas en la mayoría de las tiendas comerciales del país, especialmente en supermercados. En cambio, el área Nutrición animal está orientada a un consumo industrial, teniendo distribuidores como Colún, Cooprisem, y Covepa.

Ambas áreas poseen importantes ventajas competitivas en sus mercados. Las marcas más representativas de Mascotas, Cannes y Minninos, son las únicas del mercado que están certificadas por la Facultad de Ciencias Veterinarias y Pecuarias de la Universidad de Chile. Las marcas de Nutrición Animal por su parte tienen la ventaja única de que sus productos cuentan con subproductos de la elaboración del azúcar en sus recetas, dando un mayor valor nutricional, gracias a su condición de filial de IANSA. Además, firmó en 2002 un acuerdo de transferencia tecnológica y asistencia técnica con la empresa estadounidense Cargill Animal Nutrition<sup>6</sup>, líder mundial en nutrición animal con presencia en más de 26 países.

Como se mencionará en el apartado de Desempeño Organizacional (1.3), estas dos áreas viven procesos distintos. Mascotas se encuentra en etapa de crecimiento y búsqueda de nuevos clientes. Para esto ha aumentado su mix de productos y ha creado alianzas con organizaciones para tener una mayor visibilidad, como la Teletón, de la cual fue auspiciador. En cambio, Nutrición Animal es un área consolidada que busca seguir manteniendo el liderazgo en su rubro a través de la innovación tecnológica, siendo Cargill Animal Nutrition un fuerte aliado en esta misión.

Sus operaciones están separadas, Mascotas cuenta con una planta en Paine (región Metropolitana) y Nutrición Animal tiene dos, una en la región de La Araucanía y otra en la región de Los Ríos (Anexos Imagen 1)<sup>7</sup>. La planta de Mascotas fue recientemente ampliada para aumentar la capacidad productiva al doble de su capacidad inicial, pudiendo producir hoy hasta 3800 toneladas al mes, y las de Nutrición Animal poseen en conjunto una capacidad de 4000 toneladas al mes.

Del total producido en la unidad de negocios Nutrición Animal y Mascotas, la mayor parte del costo de producción se debe a las materias primas, siendo alrededor del 63% del total en 2015. Existe gran cantidad de materias primas

---

<sup>6</sup> Suralim (Marca del área Nutrición Animal), IANSA Nutrición Animal, 2017.

<sup>7</sup> En este trabajo solo se considera la planta de La Araucanía para efectos del abastecimiento, costos de compras, y cualquier otro factor.

usadas en la producción de los productos de ambas áreas, siendo un tópico relevante para analizar el de materias primas agrícolas, el que representó en 2015 el 23% del costo de producción (de ambas áreas combinadas). Específicamente, el maíz, productos relacionados con el trigo (afrechillo y triticales), y la soya.

La empresa posee una vasta experiencia en temas agrícolas dada su tradición agroindustrial, lo cual es una razón adicional para realizar este estudio con foco en las materias primas anteriores.

**Figura 1.5:** Valor promedio de compras anuales entre 2015 y 2016 para afrechillo, maíz, triticales, y soya.

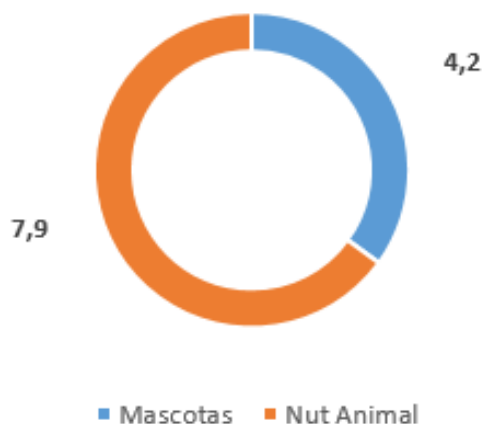
Valores promedio de 2015 y 2016	Área	Nutrición Animal				Mascotas				Total
	Unidad	Afrechillo	Maíz	Triticales	Soya	Afrechillo	Maíz	Triticales	Soya	
Miles de Ton		25,1	10,2	12,9	0,1	6,5	8,8	0,7	1,2	65,5
Millones de USD		3,2	2,1	2,5	0,04	0,7	2,9	0,1	0,5	12,1

*Fuente: Elaboración propia en base a Memorias de IANSA.*

De los insumos mencionados, en la Figura 1.5 se puede ver que los de mayor relevancia en compras en MM USD son el afrechillo y el maíz, cuyas compras equivalen al 75% del total de este grupo. En tanto, el triticales representa el 20% y la soya apenas un 5%. También, en base a la Figura 1.5 y al grafico en la Figura 1.6, Nutrición animal es el área con la mayor proporción de las compras, totalizando el 65% del total.

**Figura 1.6:** Valor promedio anual entre 2015 y 2016 de compras de materias primas para cada área (sólo se incluyen afrechillo, triticales, maíz y soya).

Compras por área promedio 2015 y 2016  
(MM USD)



*Fuente: Elaboración propia en base a Memorias de IANSA.*

Debido a lo anterior, los principales objetos de análisis serán el maíz y los productos relacionados con el trigo, siendo la soya un elemento más bien secundario por su bajo monto de compras, de alrededor de 640 mil dólares en promedio de los dos años (2015 y 2016).


### 1.3 Mercado y/o Marco institucional

A continuación, se describirá el mercado de referencia para el proceso de compras de materias primas agrícolas de las áreas Nutrición animal y Mascotas de IANSA, que corresponde a la cadena de comercialización del maíz, soya, afrechillo y triticales. Se describirá la cadena de comercialización del trigo en reemplazo de la del triticales y afrechillo, debido a que son muy similares por ser productos relacionados, y existe mayor información respecto a la cadena del trigo.

Estos insumos (maíz, soya, afrechillo y triticales) representan alrededor del 23% del costo de producción de la unidad de negocios de IANSA a la que pertenecen estas áreas. De estos, el más relevante en cuanto a compras en dinero es el maíz, el cual representa más del 40% del total, seguido por el afrechillo con un 31% de acuerdo con la Figura 1.7.

**Figura 1.7:** Participación de cada una de las materias primas estudiadas dentro del 23% del costo de producción de la unidad de negocios Nutrición Animal y Mascotas que representan en conjunto.

Participación porcentual de cada materia prima dentro de compras de soya, afrechillo, triticales, y maíz



Fuente: *Elaboración propia en base a registros de compras de IANSA.*

Posteriormente, se describirán las relaciones que se producen entre Nutrición animal y Mascotas, con los demás actores del mercado, pudiendo conocer cuáles son más influyentes para estas áreas, y por ende se les debe prestar

mayor atención.

Las caracterizaciones del trigo y maíz a continuación corresponden al mercado de cada una de las materias primas en Chile. Es decir, no se incluye lo que ocurre en otros países ni los usos que se le da en otros lugares, describiendo únicamente la cadena de comercialización nacional, de manera de representar el mercado que observan las áreas Mascotas y Nutrición animal en la compra de estos insumos. No obstante, las variables relacionadas con productos derivados como el etanol, o la oferta mundial de una materia prima, si serán incluidos en el análisis del trabajo, detallándose en el capítulo Marco Conceptual (4) y Variables (7).

En cuanto a la soya, ya que no es producida para fines comerciales en Chile y debe ser importada, se describirá el mercado internacional en cuanto a los mayores productores, importadores, los usos que se le dan a esta materia prima, y también los países desde los cuales proviene la mayor parte de la soya que se importa en Chile.

### **1.3.1 Mercado del maíz, trigo, y productos relacionados con el trigo:**

La cadena de comercialización está compuesta por productores pequeños, medianos, y grandes, empresas acopiadoras locales, corredores de productos agrícolas, y molinos. Adicionalmente, se incluirá a empresas que fabrican productos en base a estas materias primas y a empresas productoras de alimentos, para entender de mejor forma los efectos que tienen en el mercado tanto para los productores como para otros compradores del mercado.

Los mercados del trigo y maíz se caracterizarán de manera conjunta pues ambos tienen producción interna, y al ser granos su cadena es parecida. También, se incluye dentro de la cadena del trigo, productos relacionados con este (afrechillo y triticale), pues su comercialización se realiza de una manera muy similar.

De manera de cuantificar el tamaño de estos mercados, se multiplica la producción nacional total de trigo y maíz en 2016, por el precio promedio de la primera semana de julio de 2017 de cada insumo. Y a esto se le agrega el valor total de las importaciones en 2016 actualizado al dólar del 10 de julio de 2017<sup>8</sup>.

Para el trigo se obtiene un valor para la producción nacional de 2016 de 238 mil MM CLP (66% del total), y de 124 mil MM CLP (34% del total) para las importaciones de 2016. Sumando ambas cantidades se obtiene un valor de 362 mil MM CLP, es decir, unos 540 MM USD.

---

<sup>8</sup> La información de la producción del mercado del trigo y maíz en 2016, precios semanales e importaciones se obtiene desde la página web de COTRISA (Comercializadora de Trigo S.A).

En el caso del maíz, la producción nacional en 2016 representó 157 mil MM CLP (45%) y las importaciones alrededor de 195 mil MM CLP (55%). Esto da un valor total de mercado de 352 mil MM CLP, es decir, 530 MM USD aproximadamente, una cantidad muy cercana al valor del mercado del trigo.

Respecto a los usos que se les da a estas materias primas en Chile, alrededor del 85% de la oferta total de trigo en el mercado se utiliza para la producción de harina. De este proceso, el cual en base a alrededor de 1,7 millones de trigo produce 1,2 millones de toneladas de harina y 360 mil toneladas de subproductos (valores correspondientes al año 2005), los principales clientes son la industria panadera (83% del total de harina), de pastas (8%), y galletas (3%). Los subproductos por su parte son principalmente usados para la alimentación animal, ya que no son aptos para consumo humano.<sup>9</sup>

En el caso del maíz, ocurre exactamente lo contrario, la mayor parte de este no es procesado en molinos, sino que se comercializa en forma de granos para consumo animal (pollos, porcinos, entre otros), representando esto el 93% de la oferta total del mercado. El 7% restante es usado para hacer harina de maíz con lo que se producen productos relacionados con la papelería, alimentos para consumo humano (jarabes y almidones), y también para animales (gluten)<sup>10</sup>.

El uso que se le dará al trigo depende de su clasificación; fuerte, intermedio, suave. Estas clasificaciones hacen referencia al porcentaje de proteínas y gluten disponibles en el mismo, siendo el trigo fuerte el con mayor porcentaje de proteínas y gluten disponible (Figura 1.8). El trigo fuerte es usado principalmente para la elaboración de pan de molde, baguettes y croissants, el intermedio es usado para otros tipos de panes (marraqueta y hallulla principalmente, aunque puede mezclarse con trigo fuerte), y el suave se usa para la elaboración de galletas y productos de pastelería.

**Figura 1.8:** Clasificación de trigo harinero (blanco) en Chile.

<b>CLASIFICACIÓN DEL TRIGO HARINERO EN CHILE (Opcional)</b>			
<b>Según Características Físico-Químicas</b>			
<b>Clase</b>	<b>Proteína<sup>4</sup> (%)</b>	<b>Gluten Húmedo<sup>1</sup> (%)</b>	<b>Sedimentación Corregida (ml)</b>
<b>Fuerte</b>	≥ 10.5	≥ 30	≥ 33.0
<b>Intermedio</b>	9.0 – 10.4	25.0 - 29.9	27.0 – 32.9
<b>Suave</b>	7.0 – 8,9	18.0 - 24.9	17.0 – 26.9

*Fuente: Norma Chilena Oficial. Trigo Harinero. NCh 1237 Of 2000*

<sup>9,9</sup> Fundación Chile. (2005). Una nueva visión para el sector triguero en Chile. Recuperado de: <http://www.odepa.cl/odepaweb/servicios-informacion/publica/VisionTrigoFunChile.pdf> (10 de julio).

<sup>10</sup> Oficina de Estudios y Políticas Agrarias (ODEPA). (2007). Análisis y evaluación de la competitividad y transparencia del mercado nacional del maíz. Recuperado de: <http://www.odepa.gob.cl/odepaweb/publicaciones/informeMaiz2007.pdf> (10 de julio).



De acuerdo con cifras de la Federación Chilena de Panaderías, el uso de harina a nivel nacional se dedica en un 80% a la producción de marraqueta, hallulla, y otros panes. En estos se usa trigo intermedio a fuerte, por lo que estos son la mayoría del trigo comercializado en Chile<sup>11</sup>.

Este tipo de trigo es conocido como trigo blanco, representante más del 85% del total de trigo comercializado en el país. El otro tipo de trigo comúnmente vendido es el trigo candeal, el cual se usa principalmente para la elaboración de pastas<sup>12</sup>.

En cuanto al maíz, también existen distintas categorías dentro de esta materia prima, diferenciándose por el porcentaje de grano partido e impurezas, y el porcentaje de grano dañado. Por lo general, todas las categorías presentan el mismo nivel de humedad. En la práctica en Chile la única categoría comercializada es el maíz número 2 (Figura 1.9), la que se vende principalmente como granos para alimentar animales, aunque también se usa para producir harina de maíz, en una pequeña proporción.

**Figura 1.9:** Clasificación del maíz en Argentina, Estados Unidos, y Chile.

Características	Grado								
	Argentina			Estados Unidos					Chile
	1	2	3	1	2	3	4	5	Único (2)
Grano partido e impurezas	3,0%	4,5%	7,0%	2,0%	3,0%	4,0%	5,0%	7,0%	4,5%
Grano dañado	3,0%	5,0%	8,0%	3,0%	5,0%	7,0%	10,0%	15,0%	5,0%
Humedad	14,5%			14,5%					14,5%

Fuente: Fundación Chile. (2005). *Una nueva visión para el sector triguero en Chile*.

Ambas materias primas son cosechas anuales, es decir, son producidas una vez al año. El período de cosecha del trigo por lo general se da entre diciembre y febrero (del año siguiente), posterior a lo cual se vuelve a preparar la tierra y a plantar las semillas. Y en el caso del maíz, la cosecha se da entre abril y junio de cada año.

En los períodos de cosecha suelen verse descensos en los precios de ambos granos, anotado en gran cantidad de ocasiones, el valor promedio mensual más bajo del año dentro de algunos meses de cosecha, o contiguos a estos (Se explica esta estacionalidad en el capítulo 7).

También, existen regiones que son muy predominantes en la producción del trigo y maíz. Para el primero, la región de La Araucanía representó el 41% de la producción de trigo durante los últimos 10 años en promedio, y la región de

<sup>11</sup> Federación Chilena de Panaderías. (2012). Gremio Industria del Pan. Recuperado de: [http://www.sofo.cl/\\_doc/gremial/seminario%20trigo/Fechipan.pdf](http://www.sofo.cl/_doc/gremial/seminario%20trigo/Fechipan.pdf) (11 julio).

<sup>12</sup> Fundación Chile. (2005). *Una nueva visión para el sector triguero en Chile*. Recuperado de: <http://www.odepa.cl/odepaweb/servicios-informacion/publica/VisionTrigoFunChile.pdf> (10 de julio).

O'Higgins el 48% del total del maíz nacional en promedio en ese mismo período<sup>13</sup>.

Finalmente, en el caso del trigo y el maíz existe un ente que busca velar por que se venda a precios que corresponden a precios de mercado, COTRISA (Comercializadora de Trigo S.A)<sup>14</sup>, empresa privada cuyo mayor accionista es CORFO (Corporación de Fomento de la Producción) con el 97% del total de acciones. En el mercado del trigo principalmente, esta empresa actúa directamente al realizar compras y ventas a productores (especialmente pequeños) para intentar evitar distorsiones en el mercado, y proteger a los productores pequeños de compras a precios abusivos por parte de grandes poderes de compra. Así, si bien es una empresa privada su mayor accionista es el estado a través de CORFO, siendo un agente regulador y ejecutor de políticas públicas.

### Productores:

Los productores de maíz y trigo de acuerdo con la Oficina de Estudios y Políticas Agrarias (ODEPA)<sup>15</sup>, son agrupados en pequeños, medianos, y grandes. El aspecto que caracteriza a cada grupo es la superficie de explotación disponible, siendo menor a 50 ha, entre 50 y 500 ha, y 500 ha o más, para los productores pequeños, medianos, y grandes, respectivamente.

En el mercado del trigo existen grandes diferencias en cuanto a la capacidad productiva de cada grupo (Figura 1.10). El grupo de productores pequeños equivale al 88% de plantaciones totales y produce el 22%. En cambio, el grupo de productores grandes apenas equivale al 1% del total, pero produce el 35% de la producción local.

**Figura 1.10:** Participación en la siembra de trigo por tamaño de la explotación. Nota:(qq (quintales) equivale a 100 kg).

Participación en la superficie de siembra de trigo por tamaño de la explotación			
	Nº de explotaciones	Superficie	Producción
Explotaciones con trigo	45.358	220.132 ha	10.500.924 qq
Menores de 50 ha	87%	32%	22%
Entre 50 y 500 ha	12%	40%	43%
Más de 500 ha	1%	28%	35%

Fuente: elaborado por Odepa con información de INE y del Censo Agropecuario 2007.

También se aprecian enormes diferencias en cuanto al rendimiento de dichas plantaciones (Figura 1.11). Los grandes productores tienen el doble de

<sup>13</sup> Registros de producción de trigo y maíz de COTRISA (Capítulo 7).

<sup>14</sup> COTRISA, 2017.

<sup>15</sup> Servicio público dependiente de la Presidencia de la República a través del Ministerio de Agricultura.

rendimiento que los pequeños. Lo anterior debido a la mayor capacidad de estudios, inversión, y rendimientos a escala de las plantaciones. Ciertamente, supone un gran desafío para las políticas públicas potenciar al grupo de productores pequeños.

**Figura 1.11:** Rendimiento por cultivo y tamaño de la explotación. Nota:(qqm (quintales métricos) equivale a 100 kg, al igual que qq).

Rendimiento por cultivo y tamaño de la explotación		
Cultivo	Trigo (qqm/ha)	Maiz (qqm/ha)
Menor a 50 ha	32,80	104,86
Entre 50 y 500 ha	51,28	114,51
Más de 500 ha	59,63	115,28

*Fuente: Elaboración propia en base a Censo Agropecuario 2007 y ODEPA.*

Por otro lado, en el mercado del maíz las diferencias son mucho menores. Los porcentajes de participación por grupo en plantaciones son similares al mercado del trigo de acuerdo con la Figura 1.12, pero los de participación en producción varían sustancialmente. Los productores pequeños de maíz producen casi el doble que los productores pequeños en el caso del trigo, llegando al 41%, y los grandes se reducen al 11% (Figura 1.12).

**Figura 1.12:** Participación en la siembra de maíz por tamaño de la explotación.

Participación en la superficie de siembra de maíz por tamaño de la explotación			
	Nº Explotaciones	Superficie (ha)	Producción (qqm)
Explotaciones con maíz	18.650	101.720,8	11.230.911
Menor a 50 ha	88,2%	43,4%	41,2%
Entre 50 y 500 ha	11,0%	45,5%	47,2%
Más de 500 ha	0,8%	11,1%	11,6%

*Fuente: Elaboración propia en base a Informe de agricultura chilena, mayo 2012, ODEPA.*

Parte de las posibles causas de esto es que los rendimientos no tienen gran variación entre grupos, siendo de 104 quintales métricos (qqm) por hectárea para los pequeños y 115 para los grandes.

Los productores venden su producción principalmente a los molinos, quienes se encargan de procesar el trigo para producir la harina, en el caso del trigo. En el caso del maíz, la mayor parte se vende a empresas productoras de alimentos, para alimentar a sus animales, especialmente aves y porcinos.

#### **Empresas acopiadoras locales:**

Las empresas acopiadoras locales son en general, privados con infraestructura propia o arrendada, y que cumplen con prestar servicios de pesaje, análisis de muestras, secado, acopio y guarda a los agentes compradores de granos. Los acopiadores no son dueños del producto, pues de esta forma no asumen riesgo frente a los vaivenes del mercado, y no deben contar con fuerza de venta.

## **Corredores de productos agrícolas:**

Son en general, empresas que ofrecen servicios de corretaje de propiedades, productos agrícolas, asesorías de importaciones/ exportaciones, entre otros. En este apartado se incluirán además de los corredores nacionales, corredores connotados a nivel internacional que proveen servicios en el mercado local.

Los corredores ofrecen ventajas para los productores al otorgarles fácil acceso a transportistas y contactos que comprenden sus productos, a través de amplias redes dentro de la cadena de comercialización del trigo y del maíz. También, ofrecen ventajas para los molinos y empresas productoras de alimentos, pues agrupan la producción de gran cantidad de productores. Esto facilita la compra de los insumos, al reducir la necesidad de buscar productores distintos.

Los corredores nacionales operan con todos los tipos de productores, ya sean pequeños o grandes. No obstante, existen diferencias en los servicios que les proveen. A los pequeños se les provee generalmente servicios de venta, pero también de almacenaje, pues muchos no cuentan con infraestructura o capital suficiente para este proceso, teniendo especial contacto con ellos durante el período de cosecha.

Los compradores medianos y grandes suelen poseer esta infraestructura de acopio y guarda, por lo que el contacto es luego de las cosechas, cuando ya se empieza a vender el producto. Un importante servicio que les proveen es el de transporte, pues al momento de finalizar las cosechas es muy demandado y los precios se elevan fuertemente.

Los corredores internacionales por su parte, para el mercado local ofrecen importación de producción internacional. Dado el costo de traer productos desde otros países, traen grandes cantidades de producto en cada envío. La ventaja de contar con este tipo de corredores es que se reduce la necesidad de comprar directamente a productores internacionales ante la falta de trigo y maíz para satisfacer la demanda local. En promedio, entre 2011 y 2014 el 37% y 43% del consumo local corresponde a trigo y maíz importados<sup>16</sup>, respectivamente. Algunos corredores internacionales que destacan en el mercado local son DSM, AMEROPA, y Burger.

De las importaciones de trigo, en promedio entre 2015 y 2016 sus principales países de origen fueron Canadá (55%), Argentina (26%), y Estados Unidos (21%)<sup>17</sup>. En tanto, para las de maíz fueron Paraguay (47%), Estados Unidos (30%), y Argentina (23%)<sup>18</sup>. En valores anuales total, las importaciones promedio entre 2015 y 2016 fueron 0,47 y 1,4 millones de toneladas en trigo y maíz, respectivamente.

---

<sup>16</sup> Boletines del mercado de maíz y del trigo, ODEPA, agosto 2015.

<sup>17</sup> Boletín del mercado del trigo, ODEPA, mayo 2017 y junio 2016.

<sup>18</sup> Boletín del mercado del maíz, ODEPA, mayo 2017 y junio 2016.

## Molinos:

Siguiendo lo mencionado anteriormente, para el trigo y el maíz, los molinos presentan situaciones muy distintas en cuanto a su poder dentro de la cadena de comercialización de estas materias primas. En el caso del trigo, el 85% del trigo presente en el mercado (importado y nacional) es usado para la producción de harina, en cambio, para el maíz corresponde apenas al 7%. Esto se debe a la diferencia que existe entre los usos de cada uno. El trigo es para consumo casi en su totalidad humano, y el maíz casi en su totalidad para alimentar animales, especialmente aves y porcinos.

Por lo general, la harina presente en el mercado en ambos productos corresponde en su mayoría a harina producida en suelo nacional, siendo muy escasa la importada en comparación a la local, lo que no significa que solo se use materia prima nacional para producirla, ya que de acuerdo con la sección anterior (productores) alrededor del 40% de consumo local equivale a trigo y maíz importados.

La ubicación de los molinos no necesariamente se condice con las regiones de mayor capacidad productiva. En el caso del trigo, alrededor del 40% es producido solamente en la región de La Araucanía, y en torno al 75% si se considera otras regiones del sur de Chile<sup>19</sup>. Aun así, el 45% de la capacidad molinera del país se concentra en la región Metropolitana<sup>20</sup>.

Los mayores molinos productores de harina de trigo, en términos de compra de trigo de acuerdo con estadísticas de 2008 (Figura 1.12) son Molino Carozzi (24%), Molino Heredia (11,4%), y Molino Castaño (11,28%).

**Figura 1.13:** Participación de molinos en compra de trigo comercializado en mercado chileno en 2008.

Molino	Participación (%)
Carozzi	24,22
Heredia	11,39
Castaño	11,28
Garcia Koehler	3,51
Arguinarena	2,05
Otros	47,55

*Fuente: Fiscalía Nacional Económica. Investigación por denuncia de Ministerio de Agricultura por presuntos actos contra la libre competencia en el mercado del trigo, harina, y pan.*

<sup>19</sup> Comercializadora de Trigo S.A. (COTRISA) (2016). Datos productivos maíz. Recuperado de: <https://www.cotriza.cl/mercado/maiz/nacional/productivos.php> (10 de julio).

<sup>20</sup> Fundación Chile. (2005). Una nueva visión para el sector triguero en Chile. Recuperado de: <http://www.odepa.cl/odepaweb/servicios-informacion/publica/VisionTrigoFunChile.pdf> (10 de julio).

La molienda de trigo es vendida principalmente a empresas productoras de pan, repostería, y pastas. Y los subproductos de este proceso, como el afrechillo, son vendidos a empresas que elaboran alimentos para animales o que usan este subproducto para alimentar a sus animales, como las empresas dedicadas al rubro de la leche.

Por su parte la molienda de maíz es vendida a empresas que fabrican productos derivados del procesamiento de la harina, como productos de papelería, jarabes y almidones para consumo humano, y gluten para consumo animal, siendo esta cantidad una parte muy pequeña del uso total de maíz en Chile (7%).

### **Empresas productoras de alimentos y fabricantes de productos en base a trigo y maíz:**

En este ítem se agruparán a las empresas que usan trigo, maíz, y sus subproductos para producir cualquier tipo de producto, con el fin de establecer cuál rubro es el más relevante dentro de cada materia prima.

Para el trigo, se mencionó que la mayor parte de la oferta a nivel nacional se transforma en harina (85%). Y de este total, la mayor parte se usa para la producción de pan. Esta industria está altamente atomizada, siendo el 97% de las empresas de este rubro, MIPE (micro y pequeña empresa).

En el caso del maíz, la mayoría de la comercialización es en base a maíz en grano, usado como alimento para aves y porcinos en su mayoría. Las empresas más importantes en cuanto a la compra de maíz son Agrosuper y Ariztía<sup>21</sup>, ya que poseen la mayor parte del mercado de carne de pollo en Chile, la cual es la más vendida, con un 39% del total de ventas del sector de carnes.

Solamente estas dos empresas dan cuenta del 85% del total de ventas del mercado de pollos, los cuales son alimentados con maíz, siendo la industria de mayor consumo de maíz. Así, estos dos marcan fuertemente el precio de compra del maíz, lo que significa que para la gran mayoría del resto de los compradores su precio de compra será “precio Agrosuper o Ariztía más un costo extra”<sup>22</sup>.

### **1.3.2 Mercado internacional de la soya:**

Como se mencionó anteriormente, la soya no es producida con fines comerciales en Chile por lo que se describe el mercado internacional a grandes rasgos, donde la producción mundial de soya en 2016 alcanzó los 313 millones de

---

<sup>21</sup> La Tercera Edición Impresa, 2017.

<sup>22</sup> <sup>22</sup> Oficina de Estudios y Políticas Agrarias (ODEPA). (2007). Análisis y evaluación de la competitividad y transparencia del mercado nacional del maíz. Recuperado de: <http://www.odepa.gob.cl/odepaweb/publicaciones/informeMaiz2007.pdf> (10 de julio).

toneladas (Globalsoybeanproduction.com, 2017), lo cual a precios de diciembre de 2016 representa un total de 117 mil MM USD en el mundo.

La soya es usada por lo general en dos formatos distintos, harina de soya y aceite de soya. Estos dos productos son obtenidos en la molienda del grano de soya, y tienen usos distintos, siendo aproximadamente el 85% de los granos de soya destinados a molienda (Soyatech.com, 2017).

La harina de soya se destina casi en su totalidad (95%) para alimentación animal por su alto valor nutricional, siendo un suplemento alimenticio usado en todo el mundo. El resto es usado para la elaboración de productos de consumo humano. De modo de revisar cuán usada es esta materia prima en cada rubro de la industria animal (aves, porcinos, bovinos, entre otros), se obtiene la cantidad promedio suministrada a los animales, por cada kilo de carne (peso promedio cerdos 200 kg, pollos 2 kg, vacas 500 kg) a nivel mundial.

Para los cerdos, por cada kilo de carne se suministraron 260 gramos, para los pollos 570 gramos, para las vacas 170, y por cada huevo consumido, se suministró 300 gramos de harina de soya (Wwf.panda.org<sup>23</sup>, 2017).

Respecto al aceite de soya, en el mundo la mayor parte es usado para productos de alimentación humana; tofu, margarinas, entre otros. También, una pequeña cantidad (alrededor del 2%) es usada para la producción de biodiesel.


#### **Productores a nivel mundial:**

La soya es producida en una gran cantidad de países en todo el mundo, no obstante, a nivel mundial, apenas 3 países concentran el 82% de la oferta total de soya (considera producción total de cada país independiente de si se destina a consumo interno o exportaciones) (Figura 1.14). Estados Unidos lidera con el 35%, seguido de Brasil (30%), y posteriormente Argentina (17%).

---

<sup>23</sup> World Wildlife Fund (WWF) es la mayor ONG conservacionista del mundo.

**Figura 1.14:** Producción mundial de granos de soya por país en 2016, en miles de toneladas métricas.



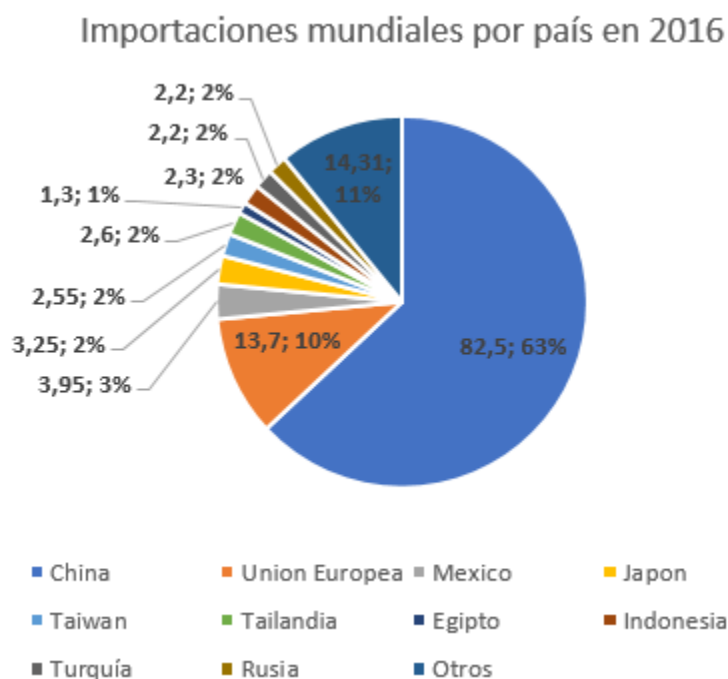
*Fuente: The soybean processors association of India.*

**Importadores a nivel mundial:**

Si la mayor parte de la producción de soya está concentrada solo en 3 países, la importación de soya está aún más concentrada (Figura 1.15). Solo China representa más del 60% del total de importaciones a nivel mundial, seguido por la Unión Europea (11%), y por México (3%).



**Figura 1.15:** Importaciones mundiales de granos soya por país en 2016, en millones de toneladas métricas.



*Fuente: Elaboración propia en base a información de Statista.org, volumen de soya importado por país entre 2013 y 2016.*


Claramente, en la importación de soya, China es un actor determinante a nivel mundial, por lo que un alza o caída en las proyecciones de sus importaciones afectan directamente el precio internacional de este insumo.

**Mayores exportadores de soya a Chile:**

Las importaciones de grano de soya en 2016 alcanzaron un valor total de alrededor de 45 MM USD en total entre todos los orígenes desde donde viene el producto. Dentro de los exportadores, el mayor por amplia mayoría es Argentina (Figura 1.16), con el 93% del total de importaciones a Chile, lo que le asigna una vital importancia dentro del rubro.

**Figura 1.16:** Importaciones de soya en Chile por origen promedio 2014-16, en toneladas métricas.

Importaciones chilenas de soya por origen promedio  
2014-2016



Fuente: Elaboración propia en base a información de Trademap.org y Aduanas Chile.


## 1.4 Desempeño organizacional

El desempeño de las áreas de Nutrición Animal y Mascotas se debe evaluar en el mercado de sus productos terminados, para lo cual se describirá el estado de cada uno, su crecimiento, porción de mercado con que cuenta cada área, entre otros.

### 1.4.1 Mascotas:

El mercado de alimentos para mascotas es un mercado que ha estado en constante crecimiento durante los últimos años. Específicamente, de acuerdo con la Figura 1.17, ha crecido a una tasa de entre 8% y 14% cada año en términos de ventas de la industria entre 2011 y 2014. Este crecimiento se explica por la creciente tendencia de los chilenos a tener mascotas en sus hogares, y una mayor conciencia de su cuidado, lo que ha ocasionado que aparezcan marcas Premium dentro del sector.

**Figura 1.17:** Crecimiento de la industria de alimentos para mascotas en Chile, en millones de pesos y en toneladas.



*Fuente: Presentación a inversionistas abril 2015, IANSA.*

El área es bastante reciente, pues si bien en 1994 entró al mercado, salió del mismo en 1999 volviendo recién en 2007. A pesar de esto, ha logrado alcanzar una importante porción de mercado llegando al 5,8% del total de ventas de acuerdo con las Memorias de IANSA en 2014, y a 2017, ostenta una participación de mercado 7,23%.

Lo anterior se condice con el aumento en sus ventas en 2015 con respecto a 2014 en la Figura 1.18 en el área de Mascotas desde 21,5 MM USD a 23 MM USD. Con esto, esta área que es relativamente nueva dentro de las unidades de IANSA representa un 4,2% de los ingresos totales de IANSA (537,6 MM USD, Memorias IANSA 2015).

**Figura 1.18:** Ingresos de la unidad de negocios en 2014 y 2015.

Año	Ventas anuales mascotas(MMUSD)	Ventas anuales Nut. Animal (MMUSD)	Total (MMUSD)
2015	23	47,9	70,9
2014	21,5	59,5	81

*Fuente: Elaboración propia en base a Memorias de IANSA 2015.*

Parte de este éxito también se debe a la inclusión de nuevos productos dentro de sus líneas. Por parte de Cannes se cuenta con alimentos para cachorros, adulto y senior, con 3 categorías cada uno; secos, húmedos y snacks. Y Minninós posee solamente productos secos, en dos sabores; carne y pescado. También, para ambas marcas estos productos están disponibles en distintos tamaños.

Los alimentos secos son la comida para mascotas más tradicional, en formato de pellets. Los snacks corresponden a galletas, y los húmedos corresponden a salsas para acompañar las comidas.

Recientemente, Cannes introdujo un nuevo producto dentro de su categoría de productos húmedos, agregando nuevas variedades para los perros en etapa de cachorros y adultos en forma de latas. Minninos si bien no ha agregado nuevos productos, hizo un relanzamiento de sus fórmulas de manera de mejorarlos

Ambas marcas de alimentos para mascotas del área (Cannes y Minninos) cuentan con certificación de la Facultad de Ciencias Veterinarias y Pecuarias de la Universidad de Chile. Siendo la única del mercado que cuenta con certificación de esta facultad, una de las más reconocidas en ese ámbito, obteniendo una ventaja por sobre otras marcas del mercado. También, el hecho de ser parte de IANSA le otorga ventajas en cuanto a capacidad de inversión y logística frente a firmas que no posean un gran tamaño.


Lo anterior muestra que esta área y la industria misma están lejos de poder ser categorizadas como estables o consolidadas. El área Mascotas está en constante crecimiento y esto también se traduce en mayor capacidad productiva para prepararse para nuevos desafíos, al aumentar su capacidad a casi el doble, es decir, unas 3800 ton/mes, y tasas de crecimiento promedio para el mercado que se sitúan alrededor del 12% anual. Un objetivo que se busca actualmente es mejorar los procesos, y estandarizar la producción de sus productos.

Así, el área de Mascotas de IANSA busca transformar sus marcas en los líderes en el mercado y exceder las expectativas de los consumidores, estando alineada con la misión y visión de IANSA. Para esto no solo se aumentó el mix y la capacidad de producción, y mejoró sus procesos, sino también la exposición de la marca a los posibles clientes. La marca Cannes participó en la Teletón como auspiciador con una campaña en que los clientes debían cargar videos en la página de la marca, logrando llegar a cientos de miles de personas y recaudando más de tres mil videos en solo dos meses.

#### **1.4.2 Nutrición Animal:**

A diferencia del área de mascotas, Nutrición animal con sus tres principales marcas (Cosetán, Optimix, y Suralim) tiene una gran presencia dentro del mercado, con un 57% de participación en el sector bovino y 35% en el equino según las Memorias de IANSA de 2014. Esto los sitúa como el principal actor en ambos mercados, y como un agente consolidado en el mismo con más de 25 años de experiencia. No obstante, este mercado presenta fuertes oscilaciones por diversos factores como la condición del forraje, por lo que algunos años las ventas pueden aumentar o verse reducidas en gran medida, como se observa en la Figura 1.19, donde en algunos años se observa un importante crecimiento, y en otros años se tienen caídas de hasta 8% en el volumen de ventas.

**Figura 1.19:** Volumen de ventas del área de nutrición animal entre 2011 y 2014.



*Fuente: Presentación a inversionistas abril 2015, IANSA.*

Entre 2010 y 2014 el área Nutrición animal promedió altas tasas de crecimiento, debiendo parte de este éxito al aprovechamiento de sinergias existentes con otras áreas de negocios de la empresa (área de azúcar y coproductos), ya que el uso de subproductos de la remolacha en las recetas de Nutrición animal agrega un alto valor nutricional a los productos, constituyendo una ventaja competitiva frente a los demás competidores.

No obstante, de acuerdo con la Figura 1.18 presentada en la sección anterior, se ve que las ventas del área Nutrición animal anotaron una importante caída en 2014, respecto de 2015. Sus resultados pasaron de casi 60 MM USD a poco menos de 50 MM USD en 2015.

Las ventas de este mercado están fuertemente indexadas al precio de la leche, en el cual influye la demanda por la misma, y las condiciones del forraje, el cual es un sustituto al producto que vende esta organización. La demanda por leche es un indicador de la cantidad de ganado que hay, por ende, cuando sube su precio también se demanda más producto de nutrición animal. Esta por lo general ha ido aumentando año a año, dando pie para que las ventas de alimentos de nutrición animal aumenten.

Como se mencionó anteriormente, en 2016 las ventas cayeron fuertemente, llegando a representar un menor porcentaje en las compras de materia prima que el área de mascotas según la Figura 1.20, la cual siempre había estado bordeando el 30% de participación total de la unidad de negocio). Así, este año se ha caído hasta niveles de producción de 1.400 ton/mes, menos de la mitad de la capacidad de las plantas (4.000 ton/mes, planta ubicada en región de La Araucanía).

**Figura 1.20:** Participación de cada área en las compras de materia prima de la unidad de negocios que conforman, entre 2013 y agosto de 2016.

Año	Mascotas (MMUSD)	Nutricion animal (MMUSD)
2013	29%	71%
2014	30%	70%
2015	33%	67%
2016	57%	43%

*Fuente: Elaboración propia datos de IANSA.*

## 2 DESCRIPCIÓN DEL PROYECTO Y JUSTIFICACIÓN

### 2.1 Información del área de la empresa en que se desarrolla el trabajo

Como ya se ha mencionado, en el trabajo se estudiará la unidad de negocios que comprende las áreas Nutrición animal y Mascotas. Específicamente, se trabajará dentro de la Gerencia de Desarrollo estratégico, cuya misión es “*guiar a la compañía en su camino de creación de valor, a través del desarrollo proactivo de estrategias de negocio y capacidades funcionales para transformar a IANSA en una compañía agrícola y de ingredientes alimenticios líder*”<sup>24</sup>.

Así, alcanzar una mayor eficiencia en los procesos de la compañía de manera transversal (en cada una de las unidades de negocios) está dentro de sus objetivos, en particular, reducir el costo de compra de insumos para las áreas Nutrición animal y Mascotas. Esto es relevante para toda la compañía, ya que, si bien los ingresos en conjunto representan el 13% del total de la empresa, presenta el segundo mayor margen de acuerdo con la Figura 2.1. Por lo tanto, la eficiencia que se logre al poder comprar materias primas a menor costo, o con precios más estables, puede hacer gran diferencia en los resultados operacionales de esta unidad de negocios y de Empresas IANSA.

**Figura 2.1:** Resultados de líneas de productos de IANSA en 2015.

Línea de productos	Ingresos (MMUSD)	Participación en Ingresos de IANSA(%)	Margen bruto (%)	Margen neto (%)
Azúcar y coproductos	298,4	54%	21%	4%
Nutrición animal y mascotas	70,9	13%	24%	7%
Agrícola	102,4	18%	15%	3%
Pasta de tomates y jugos	82,4	15%	27%	14%

*Fuente: Elaboración propia en base a Memorias IANSA 2015.*

Específicamente, al interior de la unidad de negocios que engloba estas áreas, las compras de materias primas representan alrededor del 63% de los costos totales de producción, como se muestra en la Figura 2.2. Y en particular, las compras de maíz, trigo, derivados de trigo, y soya, significaron un gasto de 15 MM USD en compras en 2015 (Figura 2.2).

**Figura 2.2:** Participación de materias primas en costos de producción de la unidad de negocios que comprende Nutrición Animal y Mascotas en 2014 y 2015.

Costos	2015 (MMUSD)	% costo de producción	2014 (MMUSD)	% costo de producción
Total costos de producción	67		77	
Costo de materias primas	42	63%	50	65%
Costo maíz, trigo, derivados de trigo, y soya	15	23%	19	25%

*Fuente: Elaboración propia en base a Memorias de IANSA 2015.*

<sup>24</sup> Declaración de principios de Gerencia de Desarrollo Estratégico.

Dentro de las compras de maíz, trigo, productos relacionados con el trigo, y soya, en promedio entre 2013-2016 los insumos más significativos han sido el maíz y el triticale, con un 37% y 31% del total de compras en USD (Figura 2.3), respectivamente. Al comparar las compras en cantidad de kilos comprados, el más significativo ha sido el afrechillo. Su bajo precio respecto de otras materias primas hace que reduzca su participación en USD.

**Figura 2.3:** Participación de materias primas compras en KG y USD de la unidad de negocios que comprende Nutrición Animal y Mascotas.

Materia prima	Participación en cantidad (%)	Participación en usd (%)
AFRECHILLO	39%	29%
SUPLEMENTO DE SOYA 43%	1%	2%
MAIZ	33%	37%
TRITICALE	28%	31%

*Fuente: Elaboración propia en base a Memorias de IANSA 2015.*

La soya por otra parte es muy poco relevante dentro del análisis de estas materias primas al representar apenas un 1% y 2% de las compras en cantidad y USD, respectivamente.

También, es relevante señalar que una mala coordinación dentro del proceso de compras puede significar que haya quiebres de stock ocasionando que la producción quede detenida. Detener la producción por falta de producto retrasa el plan de producción original y condiciona la posibilidad de llevar a cabo la estrategia de la empresa en cuanto a ventas y posicionamiento. Especialmente para el área de mascotas, donde se expandió recientemente la capacidad productiva para tomar un mayor posicionamiento dentro del mercado.

Para un entendimiento acabado del proceso de compras se describe a continuación la situación actual para cada una de las áreas en estudio.

### **2.1.1 Situación actual del proceso de compras:**

Recordando lo mencionado en secciones anteriores, las áreas Nutrición animal y Mascotas si bien conforman una unidad de negocios, poseen operaciones totalmente separadas no solo en ámbitos financieros o logísticos, sino también geográficos, ya que la planta de producción de Mascotas está ubicada en Paine (región Metropolitana), y la de Nutrición animal está en Quepe (región de La Araucanía), existiendo una distancia aproximada de 700 kilómetros entre ellas.

Así, cada área se abastece de manera independiente con proveedores cercanos a la localización de sus plantas, y sigue también, estrategias distintas de abastecimiento, las que no necesariamente son iguales para todos los insumos que se deben comprar. A continuación, se describen las estrategias que siguen




las áreas para la compra de maíz, triticale y afrechillo, cuyo costo representa el 98% del total de compras de los insumos estudiados según la Figura 2.3.

Respecto de las compras de maíz, en la Figura 2.4 se puede observar que, si bien existen meses en los que se realizan compras grandes en Mascotas, en ninguno se supera el 30% de participación con respecto al total de compras del año. Y los porcentajes de participación por lo general oscilan entre el 5% y 15%, con lo que se asume que Mascotas no sigue una estrategia de abastecimiento con la que compre producto para satisfacer demanda para varios meses, y fijando el precio del mismo por un largo período.

En la región Metropolitana existen mayores dificultades para disponer de capacidad de almacenamiento que en la región de La Araucanía (donde se ubica la planta de Nutrición animal) debido al precio de los terrenos, factor que favorece la estrategia de compras que usa Mascotas, cuya planta se encuentra en la región Metropolitana.

Este escenario es totalmente contrario al área de Nutrición animal. Se establecen grandes órdenes de compra en los meses de abril y mayo, los cuales coinciden con la cosecha del maíz, que representan en conjunto en esos meses prácticamente el 100% de las compras de cada año.


**Figura 2.4:** Participación de las compras de cada mes en las áreas Mascotas y Nutrición animal respecto del total comprado de maíz en cada año, entre 2015 y 2016.



*Fuente: Elaboración propia en base a registros de compras de IANSA.*

A diferencia de lo descrito anteriormente, en el afrechillo y triticale las compras son bastante más parejas que las de maíz. En la Figura 2.5, en ninguna de las áreas se establecen órdenes de compra superiores al 25% del total comprado de cada año en 2015 y 2016. Esto se condice con la baja sostenida que ha tenido el precio del trigo en este período, como se revisará más adelante en la sección 2.4.

**Figura 2.5:** Participación de las compras de cada mes en las áreas Mascotas y Nutrición animal respecto del total comprado de maíz en cada año, entre 2015 y 2016.



*Fuente: Elaboración propia en base a registros de compras de IANSA.*

En la misma línea, es difícil establecer diferencias entre las estrategias que han seguido estas áreas para la compra de estos insumos. Nutrición posee mayor número de meses con participaciones sobre el 15%, pero no existen grandes diferencias como en el maíz.

La estrategia de compras a seguir varía según los precios y la estacionalidad de cada materia prima, pero por lo general se busca aprovechar estacionalidades conocidas, como la estacionalidad en el maíz (el precio suele ser bajo en temporada de cosecha, entre abril y junio), donde se suelen observar órdenes de compra grandes. Estos acuerdos de compra consisten en órdenes de compra donde se fija un precio y cantidad de un insumo, cuya entrega se materializa mes a mes hasta completar el total, ocurriendo lo mismo con el pago por parte de la empresa a su proveedor.

Si bien es cierto que existen mayores restricciones de almacenamiento en la zona central, existen posibilidades de establecer acuerdos a mayor plazo que solo para un mes en la compra de insumos y que se realicen entregas mensuales por cierta parte de la compra, como lo hace Nutrición animal en las compras de maíz. Esto, como se definirá más adelante, será evaluado de manera de establecer cuál estrategia de compras resulta más conveniente, y qué mejoras se pueden realizar a los procesos de abastecimiento de cada área.

La variación del precio pactado cuando se retira inmediatamente el producto, o cuando se acuerda un precio fijo por un mes, o cuando se acuerdan envíos mensuales por varios meses depende en gran medida de la situación del mercado en ese momento, del stock disponible y futuro del proveedor y sus condiciones financieras, entre otros. Por esto, es muy difícil saber de antemano las diferencias en costos de cada una de las modalidades de compra anteriores y se definen al momento de la negociación con el proveedor.

Dentro de este proceso de abastecimiento no se considera el arriendo de bodegas, silos, u otras maneras de almacenamiento. La razón es que ambas

áreas almacenan sus insumos necesarios en sus plantas y no es una práctica habitual el arriendo de almacenamiento. También, cuando se negocia la compra de materias primas para varios meses de demanda (como en el caso de Nutrición animal), los proveedores realizan envíos mensuales cuya carga es almacenada en sus bodegas (de la planta del área respectiva), y no es claro que el hecho de que un proveedor realice entregas mensuales de producto tenga un costo significativo como se menciona anteriormente.

En ambas áreas el proceso de compras es realizado por compradores técnicos, cuyas decisiones en cuanto a las compras se basan en su experiencia, conocimiento del mercado y publicaciones de agencias especializadas (ODEPA<sup>25</sup>, COTRISA<sup>26</sup>, entre otros).

En general, Nutrición animal y Mascotas compran insumos dentro del país, aun cuando el origen del producto pueda variar. Esto se debe a que traders (empresas de corretaje de productos) o grandes empresas productoras traen grandes volúmenes desde el exterior hacia Chile. Es muy poco común que IANSA compre directamente a un productor en otro país.

La cantidad por comprar se obtiene desde el plan de producción de cada unidad, y éste desde el plan de ventas del área comercial. Dentro de los actores posibles a los que se puede comprar las materias primas, se compra en mayor medida a traders y a grandes productores por la capacidad que tienen para manejar grandes pedidos, y mayor confiabilidad, variando los proveedores elegidos entre ambas áreas debido a la localización de sus plantas y la de los proveedores.

#### **Variaciones en las recetas:**

Es relevante mencionar que la cantidad a comprar de cada insumo puede variar dependiendo del precio de los mismos. Esto hace referencia a la flexibilidad que tienen las recetas usadas para adaptarse a los costos de los insumos y mantener al mismo tiempo características similares. De manera general, la receta para productos distintos es obviamente distinta, existiendo una receta distinta para cada uno.

Para el área Mascotas las recetas en general se mantienen constantes para cada producto, pues venden un producto estándar a todos los clientes que lo compran en los puntos de venta existentes (supermercados en su mayoría), cada cliente no pide un producto con cierta composición específica. Eso sí, lo anterior no significa que no varíe la composición del producto si es que se producen cambios relevantes en los precios de las materias primas usadas., no obstante, las variaciones por esta razón son muy pequeñas.

---

<sup>25</sup> Oficina de Estudios y Políticas Agrarias, dependiente de la Presidencia de la República a través del Ministerio de Agricultura.

<sup>26</sup> Comercializadora de Trigo S.A.

En cuanto a Nutrición animal, existen diferencias con Mascotas puesto que, si bien existen clientes industriales que compran producto estándar sin pedir ningún tipo de cambio, existen otros que solicitan un producto especial de acuerdo con las condiciones específicas que experimenta el proveedor. En ese caso se usa una receta totalmente distinta a las demás cuya composición variará el uso de materias primas, y por ende, la cantidad de cada una que se compra normalmente.

Las posibles variaciones en las recetas debido a variaciones en los precios no serán incluidas dentro de la evaluación, pues las variaciones significativas corresponden a variaciones realizadas por clientes que quieren deliberadamente cambiar el producto recibido, y no a cambios en los precios.

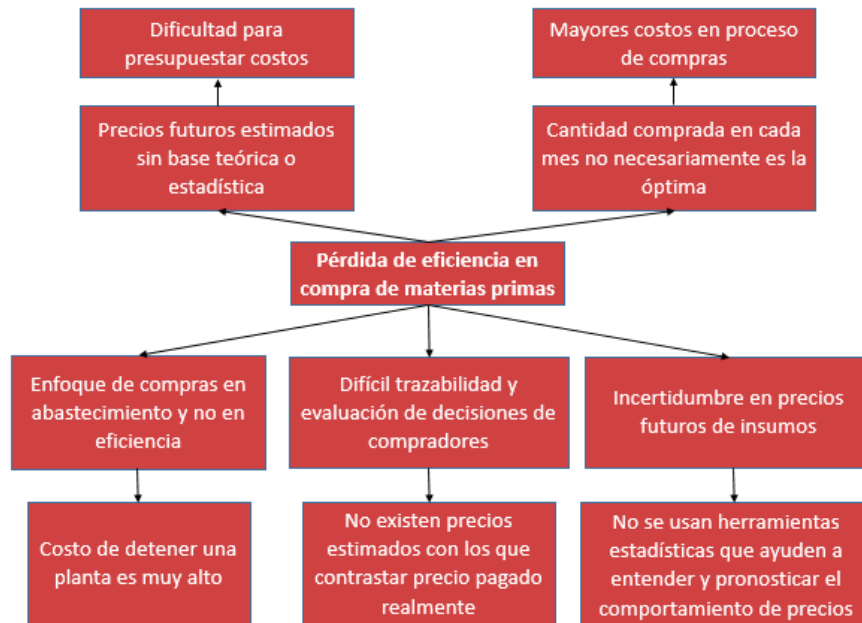
## **2.2 Identificación del problema u oportunidad y su relevancia**

Como se menciona anteriormente, las materias primas por sí solas representan alrededor del 63% del costo de producción de la unidad de negocios de Nutrición Animal y Mascotas, lo que a la postre significó compras por 42 MM USD en 2015, considerando todas las materias primas.

En la Figura 2.6 se puede observar el problema central identificado, sus efectos y causas, donde como causas principales se ubica que el incentivo está centrado en abastecer las plantas, pero no necesariamente en lograr los mayores ahorros posibles. Que actualmente no se usan herramientas que permitan hacer pronósticos de precios para el horizonte que se busca abastecer con las compras, lo que produce mayor incertidumbre para los compradores. Y también, que se hace difícil la evaluación y trazabilidad de sus decisiones, ya que no existe un punto de comparación con el cual contrastar su desempeño.

No necesariamente existen beneficios por establecer grandes órdenes de compra, ya que puede ocurrir que los precios en ese momento sean altos o que el precio vaya a la baja. No obstante, realizar una evaluación de las decisiones tomadas, cada cierto período de tiempo favorece una mayor conciencia de lo realizado y permite buscar maneras de aumentar la eficiencia.

**Figura 2.6:** Árbol de problemas del problema identificado.



*Fuente: Elaboración propia.*

Actualmente, cada área (Nutrición animal y Mascotas) presenta distintas políticas de compras, sin aprovechar sinergias posibles en cuanto a cómo se podría llevar a cabo un proceso más eficiente, pues si bien no compran de manera conjunta, sí se podrían evaluar los resultados que obtiene cada una según sus prácticas y criterios que se usan.

Tampoco se observa un objetivo definido en cuanto a la búsqueda de eficiencia en el proceso, mejoras posibles, ni una evaluación continua en cuanto a las decisiones y criterios que usan los compradores para abastecer las plantas de cada Paine (región Metropolitana) y Quepe (región de La Araucanía).

Si bien se usa SAP como sistema ERP de apoyo, no se hace uso de herramientas estadísticas que permitan complementar la experiencia de los compradores para llevar a cabo sus negociaciones. El uso de modelos podría reducir la incertidumbre relativa a los precios futuros y servir como un apoyo en la toma de decisiones de compra, ya que en la actualidad se realizan compras para varios meses, especialmente para el maíz, como se menciona en la sección 2.1.1, donde se aprecian grandes compras en algunos meses y menor en otros, lo que indica que se estableció una orden de compra que abastece más de un mes.

Así, este problema afecta directamente la misión de la Gerencia de Desarrollo Estratégico, pues no solo busca establecer estrategias de negocios que permitan aumentar la eficiencia de la empresa, sino también hacerlo de manera eficiente, lo que puede verse dificultado debido a las situaciones descritas anteriormente en esta sección.

Estas pérdidas de eficiencia u oportunidades de mejora de eficiencia inciden de distinta manera en cada una de las áreas. En el área Mascotas son de difícil y lenta transferencia a los clientes ya que son productos que se venden generalmente en supermercados, y las marcas que comercializa esta área poseen una pequeña porción del mercado (5,8% en 2014)<sup>27</sup>. Con esto se tiene limitado poder negociador en comparación con retailers y también una limitada capacidad para retener a las personas que compran estos alimentos para sus mascotas en caso de aumentar los precios.

En cambio, en Nutrición animal es más fácil transferir el costo a los clientes pues son clientes industriales donde se negocian precios en cada venta en cada transacción. Las marcas del área son líderes del mercado en ambos segmentos (bovinos y equinos) con el 57% y 35% de las ventas<sup>28</sup>, poseyendo un fuerte poder negociador en el mercado.

### **2.3 Identificación de la hipótesis y posibles alternativas de solución para resolver el problema u oportunidad**

En base a la situación expuesta, se cree que existe la posibilidad de mejorar los rendimientos de este proceso a través una herramienta estadística para complementar la información que disponen los agentes compradores, y las prácticas actuales de cada área en cuanto al proceso de compras.

La existencia de un modelo permite tener mayor evidencia a la hora de tomar decisiones y podría hacer posible la evaluación de las decisiones que ha tomado cada comprador, de manera de revisar los criterios usados y posiblemente establecer un sistema de incentivos. Con esto se pueden tomar decisiones basadas en algo más que la intuición, reforzando lo que realizan los compradores y evaluando su desempeño, y también, es posible reducir los costos de compras al establecer planes que se adecúen a los precios futuros estimados y busquen la mayor eficiencia posible.

En este estudio se considerarán estrategias de 3 y 6 meses que puedan ser aplicadas en la compra de insumos, en base a las predicciones de los modelos estadísticos que serán usados. A medida que incrementa el período de predicción disminuye la precisión de los modelos, y también las posibilidades de conseguir precios fijos durante el período de predicción por parte de los proveedores, esto es, si se recomienda acordar un precio para un determinado número de meses, mientras mayor sea la cantidad de meses es más difícil por lo general que el precio no sufra sobrecargos.

Las estrategias se considerarán como independientes para cada área, es decir,

---

<sup>27,12</sup> Memorias de IANSA, 2014.

la evaluación se hará sobre la base de que ambas áreas compran de manera separada.

En la práctica es muy complejo explicar el comportamiento de una variable en su totalidad, por lo que es posible que las predicciones no tengan la exactitud necesaria para ser usadas. Esto es un riesgo a tomar a la hora de realizar la investigación. Con el modelo no se busca reemplazar el juicio de los compradores, sino que apoyar sus decisiones, por lo que tan solo con reducir la incertidumbre futura y permitir una mayor comprensión de la dinámica que gobierna los precios estudiados se podrán evaluar cambios en las prácticas actuales.

Los modelos a usar, que serán descritos en el capítulo Marco Conceptual (4), corresponderán a modelos que hayan sido usados en la literatura a revisar sobre el tema, especialmente aquellos usados para predecir precios de materias primas agrícolas. También, se favorecerá modelos cuya utilización no sea extremadamente difícil debido a la aplicación práctica que se le quiere dar al proyecto, de manera que pueda seguir siendo usado posterior a su finalización.

La información a tomar en cuenta es la data histórica de los precios de los insumos, variables macro y micro económicas, climáticas, entre otros factores recomendados por la literatura y expertos de IANSA, para encontrar relaciones que complementen y mejoren la capacidad predictiva de los agentes de compras del área de abastecimientos.

Así, la hipótesis a estudiar es si *“el desarrollo de un modelo de predicción de compras que se use como insumo en conjunto con el plan de compras del área, puede generar estrategias de compra que reduzcan el costo pagado por este concepto en las materias primas estudiadas”*, cuya posibilidad de ahorro dependerá de las estacionalidades, tendencias de precios, entre otros.

## **2.4 Propuesta de valor de las posibles soluciones**

Se realizó una estimación de los potenciales beneficios de los modelos a desarrollar (para cada materia prima) y dos estrategias de compras (para 3 y 6 meses), tomando escenarios donde se tiene capacidad de predecir el mejor precio mensual para periodos de tres y seis meses, y se establece una estrategia de compra que busque abastecer el próximo periodo de tres y seis meses.

Esto constituye un escenario ideal donde el área de abastecimientos hubiera tenido la posibilidad de saber cuál sería el mes de precios más bajos y haber aprovechado esto para comprar los insumos necesarios para cada trimestre o semestre al precio más barato pagado en la situación real, respectivamente.

Para esto se usaron los datos de compras de IANSA entre enero de 2013 y agosto 2016. Para cada materia prima según la estrategia a usar (3 o 6 meses)

se fue eligiendo el precio a pagar, para al final compararlo con el costo real que se tuvo en todo el período estudiado. Cabe mencionar que este costo representa el costo del insumo puesto en la planta de IANSA (Mascotas o Nutrición Animal), por lo que el costo del transporte ya está incluido.

La Figura 2.7 presenta los beneficios potenciales de la propuesta, los cuales llegan a ser de hasta 1 MM USD anuales. Estos resultados avalan la rentabilidad de una solución de este tipo y la oportunidad que existe para mejorar el proceso de compras, pues puede producir importantes ahorros con una inversión prácticamente nula, pudiendo aumentar el margen bruto en casi 2%.

**Figura 2.7:** Beneficios potenciales de propuesta de solución según cada escenario. (En el escenario mensual no hay ahorro ni beneficios porque es el nivel base, reducción de costos, aumento de margen equivalen a promedio anuales, y costo de oportunidad máximo equivale a máximo entre 2013 y 2016).

Indicador / Modelo	Semestral	Trimestral	Mensual
Ahorro anual(MMUSD)	1	0,5	
Reducción de costos de compra (%)	6,5%	3,2%	
Aumento margen bruto (%)	1,8%	1,0%	
Costo oportunidad máximo (MMUSD)	7,2	3,8	
Eficiencia (base modelo 6 meses) (%)	100%	97%	93%

*Fuente: Elaboración propia en base información de compras de IANSA.*

Si bien se ven beneficios bastante relevantes para la empresa, se cree que estos podrían haber sido mayores. Entre 2013 y 2016 el precio del trigo bajó fuertemente de forma continua, lo que provocó que el precio que IANSA pagó por productos relacionados con el trigo (afrechillo y triticale) bajara también. Este descenso continuo de los precios reduce la eficiencia de comprar a mayor plazo, pues al generalmente estar a la baja los precios, en muchos casos lo mejor que se podía hacer era comprar materias primas solo para el mes siguiente.


Lo anterior se observa en la Figura 2.8, donde los ahorros alcanzados en el escenario de compra semestral (“ESC 1”), y en el escenario de compra trimestral (“ESC 2”) son bastante parejos entre los años 2013 y 2015, dándose el mayor ahorro en términos porcentuales respecto del total de compras de materias primas (todas las materias primas, sumando 42 MM USD en 2015) en 2015, con alrededor de un 9% y 4% para el escenario semestral y trimestral, respectivamente. Pero en 2016 se reducen fuertemente, revirtiendo la tendencia y alcanzando ahorros que son menores a la mitad que en otros años para ambos escenarios, con 0,3 MM USD y 0,2 MM USD, respectivamente.

**Figura 2.8:** Ahorro alcanzado por cada escenario evaluado en MM USD entre los años 2013 y 2016, en conjunto para las áreas Mascotas y Nutrición animal. (El ahorro



porcentual se calcula respecto del total de compras de materias primas de cualquier tipo).

### Comparación de ahorro alcanzado por escenario



Fuente: Elaboración propia en base información de compras de IANSA.

Esto hace que la historia sea muy relevante al decidir las estrategias de compra, pues si se está en un escenario donde el precio se mantiene relativamente estable y hay estacionalidades, el modelo puede dar grandes beneficios. Pero si los precios están a la baja, puede dar muy poco margen como para tener la certeza de que se producirán beneficios.

Para medir la eficiencia se consideró la razón entre máximo costo de oportunidad de cada modelo (pago al contado de las materias primas) y la compra promedio mensual actual. Luego, se dividió por la cantidad de meses de predicción. Mientras menor sea la razón obtenida el modelo produce más ahorro, por lo que si no hay beneficios esta razón es 1. El modelo semestral como era de esperar fue el más eficiente con una ratio de 0,93 (el modelo trimestral obtuvo 0,97). Se usó como índice base para obtener la eficiencia del resto de los modelos.

Por simplicidad, para la estimación de beneficios se consideró que las materias primas fueron compradas en conjunto para ambas áreas, y que las recetas no variaron durante el período evaluado. Y no se consideraron costos de almacenamiento de las materias primas, ya que como se menciona en la sección 2.1.1 existe gran incertidumbre en su valor, pues dependen de condiciones al momento de la negociación.

Además, la manera en que se compra actualmente consiste en que se fija el precio por cierto número de meses en base a una orden de compra, y la materia prima será entregada durante el número de meses estipulado. Así, no es necesario tener más capacidad de almacenamiento que para un mes de demanda o semana según se acuerden las entregas, la cual IANSA en ambas áreas (Nutrición animal y Mascotas) sí posee.

Podría existir un recargo por parte del proveedor por almacenar el producto hasta el momento de cada entrega, pero esto depende de si efectivamente tiene todo el producto al momento de pactar la orden de compra, de su necesidad de capital, entre otros. Por esto, como se menciona en la sección 2.1.1, no se considera esta variación en el precio.

Como última condición, no se consideraron costos de quiebres de stock, ya que para estos productos una compra con poca o muy poca anticipación no implica necesariamente un mayor costo. Lo que define el costo es principalmente el precio de mercado, por lo que un mayor costo extra se debería a que se compre producto en una época donde el precio esté alto.

Todo lo anterior muestra que existen posibilidades de ahorro dentro del proceso de compras, pero no solo existen beneficios en ese aspecto. También el uso de una herramienta que permita hacer predicciones y generar estrategias puede servir como herramienta de control para los compradores, en cuanto a que es posible saber si siguen lo recomendado por el modelo o no, y revisar cuales fueron las razones de lo anterior. Así, se pueden evaluar las decisiones que han tomado los encargados de compras, y establecer métodos de compensaciones por un buen desempeño.

### **3 OBJETIVOS**

#### **3.1 Objetivo general**

Establecer una estrategia de compras factible que permita disminuir el costo actual de las compras de materias primas agrícolas de las áreas de la unidad de negocios Mascotas y Nutrición animal de IANSA, considerando los costos reales de compra, a través de modelos de predicción de precios basados en un análisis de datos históricos y variables relacionadas.

#### **3.2 Objetivos específicos**

- Desarrollar modelos usados en la literatura para pronosticar el comportamiento de los precios de materias primas en base a información histórica, y definir cuál es el que tiene mayor capacidad predictiva en términos de ajuste.
- Alcanzar una visión integral del proceso de compras al comprender el comportamiento normal del mercado de productores y compradores, modificaciones posibles a las políticas de compra de IANSA y sus costos.
- Proponer estrategias de compras en base a las predicciones de los modelos desarrollados, las cuales sean posibles de ejecutar en la realidad.
- Evaluar el beneficio generado por las estrategias de compras propuestas frente a la actual, estableciendo escenarios para distintos horizontes de compra. Establecer en qué casos es rentable seguir otro comportamiento y sus beneficios asociados.

## 4 MARCO CONCEPTUAL

### 4.1 Modelos usados en la literatura y variables consideradas

Dentro de la literatura de estimación de precios de commodities existe una gran cantidad de modelos utilizados. Tradicionalmente los modelos más sofisticados han consistido en dos grupos: modelos estructurales y modelos que se basan en series de tiempo (Vicentín Massaro, 2016). Estos constituyen gran parte de los modelos actuales, desarrollados desde los años 80 y 90 con el auge de programas estadísticos especializados. Aunque también se han usado modelos de regresión lineal, los cuales poseen un proceso de calibración más sencillo y la posibilidad de interpretar los coeficientes resultantes para cada variable.

Los primeros, por lo general usan gran cantidad de ecuaciones que permiten describir el ambiente que se está modelando, pudiendo captar variaciones que no necesariamente han ocurrido en el pasado, como shocks en la economía, “carteles”, entre otros. Estos presentan una ventaja frente a los basados en series de tiempo, por poder predecir escenarios que varían de las condiciones normales, en cambio, los de series de tiempo ante un fuerte cambio en las condiciones iniciales entregan predicciones que tienen poca cercanía con la realidad.

No obstante, no siempre se tiene toda la información necesaria para la gran cantidad de variables que contempla un modelo estructural dentro y fuera de la muestra (dentro de la muestra es la parte de los datos usados para la calibración del modelo, y fuera de la muestra los datos usados para evaluar sus predicciones fuera del período de calibración), y además, supone grandes necesidades computacionales para su cálculo. Su evaluación frente a otros modelos por lo general es difícil, y se ha evidenciado que, si bien tienen gran capacidad predictiva dentro de la muestra, fuera de ella esta baja fuertemente (Engel, & Valdés, 2001). También, previamente se requiere un importante estudio del mercado para establecer ecuaciones que lo representen de manera correcta.

Dentro de los modelos de series de tiempo, se han distinguido los univariados y multivariados. En los primeros, el resultado de la variable que se está prediciendo depende de valores anteriores de esa variable. Y en los últimos, el resultado de la variable que se está tratando de predecir depende de la misma variable, pero también de otras, y de sus valores anteriores.

Así, los modelos multivariados permiten describir una variable en base a otras que puedan ser representativas del sector que se está tratando. Los modelos ARMA<sup>29</sup> y ARIMA<sup>30</sup> son muy populares dentro de los univariados, y modelos

---

<sup>29</sup> Modelo Autorregresivo de Media Móvil (ARMA).

<sup>30</sup> Modelo Autorregresivo Integrado de Media Móvil (ARIMA).

como VECM<sup>31</sup>, y VAR<sup>32</sup>, son los más comunes dentro de los multivariados (Clavería & Torra, 2013). Las variables económicas por lo general no son estacionarias, sino que se ven influenciadas por distintos factores que alteran su comportamiento en el tiempo. De acuerdo con Ahumada & Cornejo (2014), y Arias & Torres (2004), los VECM han mostrado ser superiores en pronóstico frente a modelos VAR y ARIMA al usar series no estacionarias.

Por su parte, si bien con las regresiones lineales no se pueden incluir rezagos en las variables utilizadas por problemas de correlación entre ellas con lo que podrían presentar resultados menos exactos al identificar con menor precisión las dinámicas dentro de los procesos de generación de precios, tal como se menciona anteriormente, tienen ciertas ventajas frente a otros modelos.

Las ventajas principales se refieren a la facilidad para implementarlas y usarlas para obtener predicciones, ya que se puede usar programas básicos como Microsoft Excel para hacer esto. También, tienen la ventaja de que sus coeficientes se pueden interpretar, de manera de conocer el efecto de cada variable, y también su significancia, a diferencia de los modelos de series de tiempo donde esto no es posible.

En cuanto a variables que pueden resultar relevantes para el modelamiento de precios, Keatinge (2015) realiza un interesante trabajo al investigar los factores que influyen en la modelación econométrica del precio del trigo en Estados Unidos. En él, describe 5 campos principales que a priori pueden tener influencia en el precio; oferta, demanda, macroeconómico, clima, y recursos naturales, teniendo como hipótesis de la investigación el que estos tengan influencia significativa en el precio, de manera de poder reducir la especulación en predicciones.

Así, para describir el precio del trigo toma en cuenta el rendimiento por acre, el stock disponible de trigo en Estados Unidos respecto de la demanda total, inflación promedio en EUA, precio del petróleo WTI, y un llamado ONI (Índice Oceánico del Niño), usado por agencias meteorológicas a nivel mundial para predecir el fenómeno del niño, de acuerdo a su comportamiento histórico. Por medio de una regresión lineal logra obtener un coeficiente de determinación de hasta 90%, siendo las variables anteriores muy significativas, todas significativas al 5%.

También, el Servicio de Investigación Económica del Departamento de Agricultura de Estados Unidos (USDA), condujo un estudio en 2014 (Janzen, et al) donde se demuestra la gran importancia de variables como la oferta y la demanda de trigo a nivel mundial para determinar su precio internacional, específicamente en episodios donde existen shocks en alguna de estas variables.

---

<sup>31</sup> Modelo de Vector de Corrección de Errores (VECM).

<sup>32</sup> Modelo de Vectores Autorregresivos (VAR).

Esto reafirma otra investigación del USDA (Wescott & Hoffman, 1999), donde factores de la oferta como la cantidad de acres plantados y el rendimiento son significativos junto con la tasa de préstamo en créditos para compra de commodities, demanda por granos para fabricación de alimentos, entre otros. Este último se refiere al trigo y al maíz, teniendo factores similares.

No obstante, debido a que este último estudio data de 1999, no está actualizado sobre las nuevas posibilidades de uso de alguna de estas materias primas, como el etanol, siendo el maíz el componente principal de este, y, por tanto, un factor que puede influir en su precio.

El etanol ha tenido un enorme crecimiento en las últimas décadas, pasando Estados Unidos de producir unos 1.500 galones en 1999 a más de 15.000 en 2016<sup>33</sup>, aun con proyecciones de crecimiento en esta década. Este crecimiento es especialmente abrupto entre 2006 y 2008, potenciado por políticas de producción de ese país, que hoy concentra alrededor del 60% de la producción mundial.

El efecto del uso de este combustible ha sido estudiado por Fortenbery & Park (2008), quienes explican por medio de regresiones que el precio del maíz ha aumentado significativamente debido al aumento en la producción de etanol, y, lo que, es más, la demanda por maíz para la producción de etanol tuvo el impacto más alto en la determinación del precio del maíz en el período de ese estudio (primera década de los 2000).

Lo anterior también se replica en la soya, cuyo mercado relevante en los combustibles alternativos es el del biodiesel. Este ha crecido enormemente desde principios de la década pasada, consumiendo grandes cantidades de soya para su producción. Gavilánez (2012) señala numerosas investigaciones que dan cuenta de la influencia de ambos combustibles (biodiesel y etanol) en las alzas de los precios de la soya y el maíz.

Sin embargo, debido a que en el país no se produce soya, el estudio de este commodity será realizado sobre el precio internacional. En este contexto, así como para el precio en Chile es relevante revisar el comercio con los mayores importadores y exportadores el mercado local, se debe considerar el efecto del comercio internacional. Especialmente de países que sean grandes consumidores, siendo China el más relevante en este aspecto según la USDA y Gavilánez (2012), cuyo consumo el año 2016 representó alrededor del 60% del total de consumo de soya a nivel mundial.

---

<sup>33</sup> Renewable Fuels Association (Representante de la industria del etanol en Estados Unidos), 2017.

## 4.2 Modelo de Vector de Corrección de Errores (VECM)

Debido a que en la investigación se quiere modelar precios en función de varias variables para conocer cómo influyen en ellos, se descarta el uso de modelos univariados. Y dentro de los multivariados, se usará el modelo VECM siguiendo los resultados de la literatura que catalogan a este modelo como superior frente a otros modelos de series de tiempo típicamente usados.

Casos en que se usan los modelos VECM para realizar predicciones de la variable dependiente a futuro donde se modelan commodities son múltiples. Vicentín Massaro (2016) usa un modelo VECM para la predicción del precio mensual de la leche en Argentina, basado en variables de la industria, obteniendo resultados bastante cercanos a la realidad en cuanto a la magnitud de los valores y la tendencia que se logra capturar, comprobando la buena reputación que ha alcanzado este modelo en la academia.

Para el modelamiento con esta herramienta se debe tener en cuenta también las características de los mercados que se están modelando, ya que se deben establecer variables endógenas y exógenas en el modelo. En Chile se han hecho varios estudios sobre las materias primas que se revisarán en este trabajo, de manera que se puede tener idea de cómo se debe proceder a la hora de definir las características de las variables (exógenas o endógenas).

La diferencia entre estos atributos radica en cómo será incluida en el modelo la variable. Si una variable es definida como endógena implica que sus rezagos también serán incluidos, y que es susceptible de presentar una relación a largo plazo con la variable dependiente. Además, se generará un modelo VECM para cada una de estas variables, pues se toma como supuesto que dependen unas de las otras.

Uno de los estudios que revisa alguna de las materias primas que se analizará, en el mercado nacional, es el realizado por Valdés, Von Cramon-Taubadel, & Díaz (2011). Estudian el mercado del trigo chileno, donde se busca analizar la integración del mercado chileno respecto del estadounidense y el argentino. En él, se obtiene que el mercado argentino tiene mayor influencia a corto plazo que el mercado estadounidense, en términos de velocidad de ajuste de precios, dando como posible causa la distancia geográfica con cada uno de esos países, por lo que un elemento a considerar debe ser también las políticas arancelarias de Argentina en este rubro.

Si bien ambos países tienen gran influencia sobre Chile, Estados Unidos ejerce una influencia directa sobre ambos países del cono sur. En ese estudio, como en otros (Engler & Nahuenhual, 2006) se modela a EUA, Argentina, y Chile como un mercado integrado donde las dos primeras son consideradas como cointegradas, lo que implica que un movimiento en el precio argentino afecta al chileno y viceversa, dado que se puede modelar como una ecuación simultánea.

Lo anterior equivale a un equilibrio de a largo plazo, pero a corto plazo se presenta como bastante dudosa la situación en que el precio en Chile pueda influir en el precio en Estados Unidos. Esto da cuenta de los análisis que se pueden realizar con los modelos VECM, y la utilidad de cada uno según lo que se quiere modelar, pues si se intenta predecir a corto plazo, el foco no estará en las relaciones de largo plazo sino en las dinámicas de corto plazo.

### **4.3 Modelo de regresión lineal**

El uso del modelo de regresión lineal en este trabajo es motivado principalmente por la ya citada facilidad que tiene este método para ser utilizado, y para interpretar los efectos que tiene cada variable independiente sobre la variable dependiente.

Para mercados relacionados al estudio que se llevará a cabo, un buen ejemplo de trabajos con buen performance es el realizado por Keatinge (2015). Este toma variables como el rendimiento de las cosechas, el precio del petróleo, indicadores climáticos, entre otros, para estimar el precio del trigo en Estados Unidos. Este logra identificar las variables que son significativas dentro del grupo de variables que habían sido seleccionados, y los efectos de cada una.

Esto es lo que se pretende realizar con la regresión lineal, de manera de complementar las predicciones del modelo VECM. Aunque, aun cuando este modelo sea de los más recomendados en la literatura, también se realizarán predicciones con la regresión lineal, para comparar los rendimientos y determinar si realmente existen diferencias significativas entre ambos modelos.



## 5 METODOLOGIA

Posterior a la revisión bibliográfica existe claridad sobre los modelos que serán usados; VECM, y Regresión lineal. También, se sientan las bases sobre las áreas en que se deben buscar las variables a usar para los modelos, las cuales de acuerdo con la bibliografía revisada y con las características del estudio se dividen en mercado interno, mercado externo, clima, macroeconomía, y productos relacionados (se toman algunas áreas que describe Keatinge (2015), y se complementan con otras que pueden ser relevantes según lo descrito en la sección 1.2).

La primera etapa consiste en revisar las fuentes de información y definir dentro de las áreas mencionadas anteriormente, qué variables se usarán. Y conforme a esto, realizar la búsqueda de información para estructurar una base de datos que sirva de input para los modelos. La selección de las variables a usar se hace siguiendo las recomendaciones de otros estudios, de compradores de IANSA, y de la información recopilada en este estudio sobre el mercado de cada materia prima que se quiere predecir.

En algunos casos, para algunas variables se deben crear índices que permitan su extrapolación para periodos futuros y así poder realizar predicciones. En el capítulo 7 se describe la forma en que se realiza esto, variando según el plazo del modelo, pues a 6 meses la información se actualiza con menos frecuencia que frente al modelo que predice solo 1 mes hacia adelante (se usan modelos que realizan predicciones a 1 mes, 3 meses, y 6 meses), donde a causa de que cada mes se vuelve a “ver las condiciones del mundo” se actualiza la información con mucha mayor frecuencia.

Con la base de datos lista, se procede en primer lugar a implementar el modelo VECM. Antes de llegar a las especificaciones finales se deben verificar ciertas condiciones que permiten su utilización, resumiéndose en Test de raíces unitarias, Test de Granger, Test de rezagos, Test de autocorrelación, Test de normalidad, Test de heterocedasticidad, y Test de cointegración. Luego de haber realizado todas estas pruebas, se puede obtener el modelo VECM.

El propósito principal de usar el VECM es hacer predicciones de corto plazo (1-6 meses), debido a su ya mencionada superioridad a otros modelos de series de tiempo y relativa facilidad de implementación frente a Modelos Estructurales. Dado que el enfoque está en las predicciones, no se realizará un análisis mayor de la cointegración y los efectos que esto produce en el largo plazo.

Luego, se realiza la calibración de la Regresión Lineal, primero verificando al igual que en el modelo VECM todas sus condiciones; linealidad en coeficientes, normalidad, homocedasticidad, y no excesiva colinealidad en variables. Verificadas las condiciones, se obtienen las ecuaciones finales de las regresiones con los valores más significativos. En este punto se realizará un

análisis de las variables relevantes y sus efectos en el precio, ya que se busca facilitar la toma de decisiones por medio de un mejor entendimiento de la dinámica de precios.

También para este modelo se realizan las predicciones correspondientes para el período 2015-2016. Las variables a tomar en cuenta para las regresiones serán las usadas por los modelos VECM que resulten ser los mejores dentro de cada periodo de estimación (1, 3, y 6 meses) y materia prima, debido al objetivo de explicar el modelo obtenido con las series de tiempo.

Entre ambos modelos se compararán los resultados de sus predicciones, para ver cuál de ellos es el mejor en términos de predicción. De acuerdo con la teoría el VECM debería tener mayor poder, pero puede que este no produzca una gran diferencia por lo que pudiera ser más práctico usar las regresiones.

La forma en que serán usados los datos es la siguiente, para la calibración de los modelos se usarán datos entre agosto de 2006 y diciembre de 2014, a lo cual se llamará “datos dentro de la muestra”. Y para la evaluación del rendimiento de los modelos propuestos anteriormente se usarán datos entre enero de 2015 y diciembre de 2016, lo cual se llamará “datos fuera de la muestra”.

Los “datos fuera de la muestra” consisten en observaciones que hubiera sido posible obtener en caso de haber estado usando el modelo en ese momento, razón por la que se usan rezagos de las variables, encuestas de expectativas de expertos, proyecciones de organismos especialidades, entre otros, de manera de replicar con la mayor precisión posible la situación real. No obstante, los pronósticos en las fechas de predicción de lluvias y del Índice de la corriente del Niño (explicado en la sección 7.2) no estaban disponibles, por lo que se usan datos observados y no rezagos ni estimaciones de esas variables.

Las predicciones a 1 mes se realizarán en cada uno de los meses de 2015 y 2016, es decir, en enero se realizará una predicción para el mes de febrero, y en febrero una para marzo, y así sucesivamente. En el caso de los modelos a 3 meses, se harán predicciones en el primer mes de cada trimestre cada año entre 2015 y 2016, por lo que los períodos de predicción serán enero-marzo, abril-junio, Julio-septiembre, octubre-diciembre. Y para los modelos a 6 meses se realizará de manera análoga a los de 3 meses, pero tomando como mes de predicción el primer mes de cada semestre, es decir los períodos de predicción serán enero-junio, Julio-diciembre para 2015 y 2016.

En cada uno de estos meses en que se hace la predicción, se usa información que hubiera sido posible conseguir en ese momento, salvo como se mencionó anteriormente, los valores para los pronósticos de lluvias y la corriente del Niño.

Se aclara que lo único que cambiará en los modelos al usar los “datos fuera de la muestra” son los valores que toman las variables, pues los coeficientes se mantendrán estáticos durante todo el período de evaluación (2015 y 2016),

permaneciendo iguales a los que se obtuvieron al calibrar cada modelo con los datos “dentro de la muestra”.

Debido a que la información sobre algunas variables usadas en el modelo está disponible aproximadamente entre el 10-15 de cada mes, para la estimación del modelo y la generación de predicciones se considera que cada período (1 mes, 3 meses y 6 meses) inicia el día 15 mes del actual (considerando como actual el mes en que se realizan las predicciones a futuro).

Posteriormente, de modo de evaluar el objetivo global del trabajo, el cual busca no solo desarrollar un modelo, sino que estudiar la posibilidad de establecer estrategias de compra que presenten beneficios frente a la situación actual, se presentarán posibles estrategias a considerar para la compra de materias primas generadas en base a predicciones del mejor modelo para cada materia prima. Existirán dos horizontes para las estrategias, 3 meses y 6 meses.

Estas estrategias hacen referencia a la manera en que IANSA debería haber comprado materias primas de acuerdo con los resultados cada modelo en los años 2015 y 2016. Para cada materia prima se evaluará el resultado en costos de compra que se produjo en la realidad versus el que se produjo gracias al modelo. Para la creación de las estrategias se tomará como input la demanda por compras desde las plantas, que se obtiene desde los registros de órdenes de compra de IANSA.

La generación de las mismas se realizará en base a una comparación de los precios pronosticados para cada mes, como se verá en la sección 8.4. Esto se debe a que las características y supuestos usados en el problema a resolver en esta memoria no hacen necesario un modelo de optimización complejo.

De modo de analizar si es que los beneficios o pérdidas que se observan en los resultados son una casualidad debido a la forma en que IANSA compró en un determinado período, o reflejan una tendencia consistente, se realizarán simulaciones que usan una distribución estadística representativa del comportamiento de compras.

También, se compararán las estrategias de los modelos frente a la estrategia de comprar sin ninguna anticipación, es decir, todos los meses se compran los insumos para el próximo mes, que constituiría una estrategia muy conservadora y básica. Así, se podrá estudiar en qué trimestres se obtienen los mayores beneficios, y estudiar reglas de negocio posibles para su aplicación.

Es necesario recordar que debido a que las estrategias se hacen en base a las proyecciones de los modelos (a 3 y 6 meses según corresponda), no existe la posibilidad de “actualizar” los modelos en cada mes del trimestre o semestre de manera de actualizar las estrategias. Esta es una restricción presente para la etapa de evaluación de este estudio debido a la gran cantidad de escenarios del pasado que se debían recrear, pero no aplica en caso de usarse en la realidad.

Finalmente, en base a los resultados obtenidos se realizarán recomendaciones en cuanto a las materias primas que muestran mayores beneficios, y reglas de negocio posibles que permiten regular el riesgo de las estrategias y maximizar el retorno.

## 6 ALCANCES

Los insumos a incluir en el proyecto son maíz, soya, trigo, y productos relacionados con el trigo (afrechillo y triticale), los cuales representaron el 2015, alrededor del 23% del costo de producción de la unidad de negocios que agrupa Mascotas y Nutrición animal. También, la empresa posee gran experiencia en productos agrícolas (más de 60 años), por lo que se aprovechará esa ventaja para este proyecto, pues por razones de tiempo no es imposible estudiar todos los insumos de manera acabada. Se predecirán solo las materias primas principales (trigo, maíz, soya) sin ninguno de sus productos relacionados, ya que no existe información de precios para estos en el mercado chileno.

Se estudiará la compra global de los insumos, y no separado por los productos que comercialice cada área, puesto que el objetivo del proyecto es dar una mirada general del proceso de compras, y no para un producto o línea específica. Pero, estas compras estarán separada por área, es decir, se evaluarán a parte las compras de Mascotas de las de Nutrición animal.

Tampoco se considerará la posibilidad de arriendo de almacenamiento dentro de las estrategias a desarrollar y evaluar, ya que como se mencionó en la sección 2.1.1, los sobrecargos son muy inciertos, dependen en gran medida del momento en que se esté negociando y del proveedor, y no es una práctica habitual en ninguna de las áreas.

Para efectos del proyecto, se tomará el plan de producción desarrollado en base a la proyección de ventas como un input, sin cuestionar su real precisión. En base a las predicciones de los modelos se estudiarán estrategias de compras que posteriormente serán comparadas con las registradas en IANSA, para evaluar qué materias primas podrían tener ahorros con el modelo planteado.

El desarrollo de una interfaz gráfica para hacer uso del modelo, actualizar datos, y mejorarlo, no constituirá parte de este proyecto. El cumplimiento estará dado por el desarrollo de modelos de compras, evaluación de estrategias de compra generadas en base a los resultados de los modelos, y, por último, recomendaciones para su aplicación en la realidad, en cuanto a la forma de operar.

## 7 VARIABLES Y SU DESCRIPCIÓN PARA LA IMPLEMENTACIÓN

### 7.1 Introducción

En este apartado se da cuenta de las variables a usar en los modelos, en base a la literatura revisada, los aportes de agrónomos de IANSA, quienes cuentan con vasta experiencia en compra de materias primas, y el estudio del mercado de cada insumo presente en la sección 1.2.

De manera similar a la usada por Keatinge (2015), se identificaron varios campos que podían ser relevantes para determinar el precio de las materias primas a estudiar; Mercado chileno, Mercado internacional, Clima, Macroeconomía, y Productos relacionados. Dentro del mercado nacional se encuentran no solo datos de producción o siembra de la materia prima, sino que también de otras variables como el tipo de cambio de dólar a peso chileno, precio del petróleo, precio del etanol, entre otros. Todas las variables, salvo las dummies y aquellas que sean un índice, se expresarán en logaritmo natural al momento de estimar los modelos.

Para el estudio se omitieron las variables cuya frecuencia fuera mayor a un mes (se actualizan 1 vez cada año, por ejemplo), para poder tener predicciones mensuales de cada materia prima, de lo contrario se producen problemas entre los rezagos al poseer distintas medidas temporales (años y meses). La mayor parte de las variables que no se consideraron por esta razón pertenecen al mercado chileno; siembra y rendimiento, los cuales se actualizan como máximo 2 o 3 veces al año, considerando las encuestas que hace la Oficina de estudios y políticas agrarias (ODEPA) a agricultores y entes relacionados.

Debido al interés predictivo “fuera de la muestra” en el trabajo (fuera de los datos usados para estimar el modelo), existen dos formas distintas de obtener los datos. Para la calibración de los modelos se usarán datos entre agosto de 2006 y diciembre de 2014, a lo cual se llamará “datos dentro de la muestra”. Y para la evaluación del rendimiento de los modelos propuestos anteriormente se usarán datos entre enero de 2015 y diciembre de 2016, lo cual se llamará “datos fuera de la muestra”.

Los “datos fuera de la muestra” consisten en observaciones que hubiera sido posible obtener en caso de haber estado usando el modelo en ese momento, razón por la cual se usan rezagos de las variables, encuestas de expectativas de expertos, proyecciones de organismos especialidades, entre otros, de manera de replicar con la mayor precisión posible la situación real. No obstante, los pronósticos en las fechas de predicción de lluvias y del Índice de la corriente del Niño (explicado en este capítulo, sección 7.2.2) no estaban disponibles, por lo que se usan datos observados, por lo que se usan datos observados y no rezagos ni estimaciones de esas variables.

Las predicciones a 1 mes se realizarán en cada uno de los meses de 2015 y 2016, es decir, en enero se realizará una predicción para el mes de febrero, y en febrero una para marzo, y así sucesivamente. En el caso de los modelos a 3 meses, se harán predicciones en el primer mes de cada trimestre cada año entre 2015 y 2016, por lo que los períodos de predicción serán enero-marzo, abril-junio, julio-septiembre, octubre-diciembre. Y para los modelos a 6 meses se realizará de manera análoga a los de 3 meses, pero tomando como mes de predicción el primer mes de cada semestre, es decir los períodos de predicción serán enero-junio, julio-diciembre para 2015 y 2016.

En cada uno de estos meses en que se hace la predicción, se usa información que hubiera sido posible conseguir en ese momento, salvo como se mencionó anteriormente, los valores para los pronósticos de lluvias y la corriente del Niño.

Lo único que cambiará en los modelos al usar los “datos fuera de la muestra” son los valores que toman las variables, pues los coeficientes se mantendrán estáticos durante todo el período de evaluación (2015 y 2016), permaneciendo iguales a los que se obtuvieron al calibrar cada modelo con los datos “dentro de la muestra”.

Se recuerda que debido a que la información sobre algunas variables usadas en el modelo está disponible aproximadamente entre el 10-15 de cada mes, para la estimación del modelo y la generación de predicciones se considera que cada período (1 mes, 3 meses y 6 meses) inicia el día 15 mes del actual (considerando como actual el mes en que se realizan las predicciones a futuro).

Para el trigo y el maíz se considerará como origen el mercado chileno debido a que ambos son producidos a nivel local<sup>34</sup>, y se agregarán variables internacionales que puedan tener repercusión en el proceso de precios. En cambio, para la soya se considerará solo el mercado internacional (no es producida en Chile), tomando como origen el mercado estadounidense, ya que es el mayor productor del mundo (alrededor del 35% en 2016), y esta materia prima no es producida en el país, siendo importada en su totalidad.

De manera de evaluar si es que los contratos futuros o predicciones de expertos permiten mejorar las predicciones de los precios promedios mensuales del trigo, maíz, y soya, para cada modelo (VECM y regresión lineal) se harán estimaciones que usen solamente variables rezagadas (por ejemplo, el precio promedio del petróleo en el mes anterior), y estimaciones que usen futuros de estas variables, de acuerdo al índice de futuros que se explicará en este capítulo. También en algunos casos se usarán predicciones de expertos, como para el dólar, que se usa la Encuesta de Expectativas Económicas del Banco Central, realizada a grupos de expertos en esta materia para obtener sus opiniones respecto de los futuros valores de variables relevantes para la economía chilena.

---

<sup>34</sup> Alrededor del 60% del consumo de trigo y maíz en Chile corresponde a producto nacional.

Por último, para el desarrollo de los modelos presentados en el capítulo 8, en base a las variables que se describirán a continuación, se usó el programa Eviews 6. Este es un programa especializado en modelos estadísticos que permite su estimación, y también la generación de predicciones.

## 7.2 Variables

En este trabajo las variables de interés para explicar son el precio promedio mensual en Chile del trigo y del maíz puestos en Santiago, registrados semanalmente por COTRISA en su página web<sup>35</sup>. En el caso de la soya por ser un producto que no se produce en Chile, la variable a explicar es su precio promedio mensual internacional FOB en el Golfo de México, registrado en la Bolsa de Chicago de Estados Unidos (CBOT), y obtenido a través de la página web de Indexmundi<sup>36</sup>, portal que contiene estadísticas de gran cantidad de precios y mercados a nivel mundial recopilados desde bolsas de comercio, agencias estatales, ente otros.

Estos precios intentan ser explicados por las variables que se organizan en los cinco campos mencionados en el apartado anterior. No todas las variables descritas aplican en todos los modelos pues depende de qué mercado se considera como el de referencia y las características propias, por lo que el siguiente apartado es un compendio de todas las variables estudiadas.

Las variables precio chileno (trigo y maíz), las pertenecientes al mercado chileno (excepto el dólar), y las pertenecientes al mercado internacional (excepto el petróleo) son obtenidas y diferenciadas para el trigo, maíz y soya, obteniéndose los datos para cada una de ellas.

En el caso de la soya no se incluye la variable precio chileno, ni nada relativo al mercado chileno excepto la variable estacionalidad, la cual por comodidad fue agregada junto a las demás variables de estacionalidad descritas en el apartado de mercado chileno.

### 7.2.1 Variables dependientes

Precio Chileno: El precio chileno (de maíz y trigo) equivale al promedio mensual de los registros semanales observados en la página de COTRISA<sup>37</sup> durante el período de junio de 2006 hasta diciembre de 2016, expresado en pesos/kilo. Se buscó obtener en todos los meses el precio puesto en la región Metropolitana, y en caso de no existir transacciones en algún mes en dicha zona, se incluyeron

---

<sup>35</sup> [www.cotrisa.cl](http://www.cotrisa.cl)

<sup>36</sup> <http://www.indexmundi.com/commodities/?commodity=soybeans>

<sup>37</sup> <https://www.cotrisa.cl/>




precios de la materia prima puesta en la VI región.

Precio Internacional: Equivale al promedio mensual del precio diario FOB de los granos de soya cotizados en la Chicago Board of Trade (CBOT) en el Golfo de México, cuyos valores se obtuvieron desde el sitio web Indexmundi<sup>38</sup>.

En la Figura 7.1 se puede ver cómo han evolucionado en el tiempo los precios de las materias primas. Desde mediados de 2008 en adelante comienzan un alza sostenida, luego del estallido de la crisis subprime en Estados Unidos, hasta comenzar a caer en 2012 conjuntamente de manera sostenida. Se puede observar también que poseen una significativa variabilidad, pero suelen seguir tendencias al alza o a la baja por varios meses. Además, se ve que están muy correlacionados, pero sin haber a simple vista un precio que dicte la tendencia de los otros.

**Figura 7.1:** Evolución de los precios internacionales del maíz, trigo, soya entre 2006-2014 en términos reales, en USD por tonelada.



Fuente: Elaboración propia en base información de Indexmundi.

## 7.2.2 Variables independientes:

### Mercado chileno:

Dólar: Dentro del mercado chileno se considera el precio del dólar frente al peso. Se usó el precio promedio de cada mes publicado por el Banco Central<sup>39</sup>. Esto también se complementó con la Encuesta de Expectativas Económicas<sup>40</sup>

<sup>38</sup> <http://www.indexmundi.com/commodities/>

<sup>39</sup> <http://si3.bcentral.cl/siete/secure/cuadros/arboles.aspx>

<sup>40</sup> <http://si3.bcentral.cl/siete/secure/cuadros/arboles.aspx>

realizada por la misma entidad, que pregunta a expertos sobre los valores futuros del dólar y otros índices económicos relevantes. Para la predicción fuera de la muestra se usaron estos datos como precio futuro del dólar frente al peso chileno.

Importaciones desde Argentina e Importaciones a nivel mundial a Chile: Se usan dos variables que dan cuenta de la cantidad de importaciones en toneladas hacia Chile. Estas se usan únicamente para el maíz y el trigo, creando una variable distinta específica para Argentina para evaluar su papel como proveedor de materias primas para Chile, mencionado en múltiples estudios, donde se muestra la integración que existe entre Chile y Argentina en estas materias primas (Valdés et al., 2011). La información necesaria fue obtenida desde la página web de TradeMap<sup>41</sup>, que contiene los registros de comercio entre países a nivel mundial.

Estacionalidad del precio: Las materias primas suelen tener estacionalidades bastante marcadas en cada ciclo, siendo en el caso de estas materias primas, cada ciclo equivalente a un año. Esta estacionalidad generalmente va de la mano con el período de cosecha de cada una, siendo la cosecha el período de menor precios, y a medida que transcurre el año comercial (tiempo entre cosechas) aumenta el precio hasta llegar nuevamente a la cosecha.


En las Figuras 7.2 a 7.4 se puede observar el en forma de gráficos de “cajas y bigotes” los precios promedio de cada mes en comparación con enero de cada año. Para el trigo la cosecha es entre diciembre-febrero, para el maíz entre marzo-mayo, y para la soya (en USA) es entre septiembre y noviembre.

En general, para ninguna de las materias primas se observa una tendencia absoluta, es decir, que en todos los años los meses de cosechas hayan sido más baratos. Pero, los promedios (línea negra) sí muestran este comportamiento, y también lo hacen la distribución de los datos, donde se puede ver que al menos para la mitad de las observaciones se cumple la existencia de estacionalidad, ya que los datos hasta el segundo quintil (línea horizontal dentro de cada caja azul), es decir, al menos el 50% muestra precios menores en época de cosecha que en otros períodos del año.

---


<sup>41</sup> <http://www.trademap.org/Index.aspx?lang=es>

**Figura 7.2:** Estacionalidad del precio mensual del trigo puesto en la región Metropolitana entre 2006-2014, donde las cajas azules representan los datos entre el segundo y tercer cuartil.




*Fuente: Elaboración propia en base a información de COTRISA.*

**Figura 7.3:** Estacionalidad del precio mensual del maíz puesto en la región Metropolitana entre 2006-2014, donde las cajas azules representan los datos entre el segundo y tercer cuartil.



*Fuente: Elaboración propia en base a información de COTRISA.*

**Figura 7.4:** Estacionalidad del precio FOB (Golfo de México) internacional mensual de la soya entre 2006-2014, donde las cajas azules representan los datos entre el segundo y tercer cuartil.



Fuente: Elaboración propia en base información de Bolsa de Chicago de Estado Unidos.

### Mercado internacional:

Precio internacional (para la soya esta variable es considerada como su precio local): Se usa el precio promedio mensual FOB en el Golfo de México de la materia prima correspondiente, en la Bolsa de Chicago en Estados Unidos (CBOT) recuperado desde la página web de Indexmundi<sup>42</sup>.

Precio de futuros agrícolas: De la misma manera que los precios internacionales, se usan los precios promedios mensuales de los futuros de cada materia prima transados en la CBOT. El vencimiento de estos futuros no es en cada mes, sino que existen 4-5 meses en cada año en el caso del trigo, maíz, y soya, en que ocurre este vencimiento.

Para solucionar este inconveniente (de que no existan futuros para todos los meses) se usa una interpolación lineal entre valores de futuros para proyectar el valor que se “predice” (el futuro no es una predicción, pero se usará como el valor de la materia prima a futuro) en cada mes. La razón de la inclusión de esta variable es evaluar cuál de las variables usadas; el precio rezagado, o el valor del futuro usado como precio futuro, es mejor a la hora de predecir el precio de las materias primas.

Es importante recalcar lo anterior sobre el uso de los futuros como predicciones. Si en febrero el precio promedio del futuro de trigo que tiene como mes de cierre mayo vale 100 dólares, se tomará para el modelo que ese precio es el que se predice que se tendrá en mayo. Y para meses que no son mes de cierre (fin de contrato del futuro) se usa interpolación. En este caso del mes de febrero, para

<sup>42</sup> <http://www.indexmundi.com/commodities/>

calcular el precio a incluir en el modelo para abril se toma el promedio (es una interpolación para un solo período entre los valores por lo que resulta en el promedio entre ellos) entre el precio promedio del futuro con cierre en marzo y el de mayo. Y así se construye un índice para todos los meses.

Dado que la construcción de este índice requiere precios pasados, y no se encuentran disponibles en la página de la Bolsa de Chicago, se obtuvieron desde Quandl<sup>43</sup>, ente que registra precios históricos de gran cantidad de insumos transados a nivel mundial desde el Banco Mundial, Naciones Unidas, entre otros, desde su fundación en 2011 y provee servicios en todo el mundo.

Precio del petróleo: Promedio mensual del precio internacional del petróleo WTI del New York Mercantile Exchange (NYMEX) (Registros históricos obtenidos desde Indexmundi<sup>44</sup>). Al igual que para los precios de materias primas agrícolas, se usa el precio observado con rezagos temporales, y también se hacen modelos con los precios promedios de los futuros de petróleo usando interpolaciones lineales, salvo que para el petróleo todos los meses son meses de cierre o vencimiento.

Esta variable es incluida debido a que el precio del petróleo influye en el costo del transporte a nivel nacional e internacional, afectando los precios de compra del trigo, maíz, y soya.

Indicadores de oferta y demanda del mercado estadounidense: Estados Unidos si bien no es el único productor de las materias primas, en todas representa un gran porcentaje de la producción, y posee una gran cantidad de material que se actualiza mensualmente. Así, desde el United States Department of Agriculture<sup>45</sup> (USDA) se obtuvo la Oferta, rendimiento, stock final estimado de cada año, ratio entre stock final y oferta. De estas variables, el stock final estimado de cada año y el ratio se actualizan todos los meses por lo que solo se incluyen estas dos variables para respetar la frecuencia mensual del modelo.

Importaciones de soya por parte de China: Dado que para la soya se busca predecir el precio mensual internacional de la misma, basado en la Bolsa de Chicago, se crea esta variable que representa las exportaciones en toneladas de China en cada mes, siendo este país el responsable del 61% de las importaciones a nivel mundial, y abasteciéndose en un 35% de soya de USA en 2015 <sup>46</sup>.

---

<sup>43</sup> <https://www.quandl.com/collections/futures>

<sup>44</sup> <http://www.indexmundi.com/commodities/>

<sup>45</sup> <https://www.ers.usda.gov/topics/farm-economy/commodity-outlook.aspx>

<sup>46</sup> Atlas.media.mit.edu, 2017

## Clima:

Interno: Se usaron los datos de las lluvias de las regiones más relevantes en cuanto a siembra de las materias primas en Chile según datos de COTRISA. En el caso del trigo se consideró la región de La Araucanía, y para el maíz la región del Libertador Bernardo O'Higgins, debido a que ambas producen la mayor parte del trigo y maíz a nivel nacional, respectivamente<sup>47</sup>. Las lluvias se obtuvieron desde las estaciones que tiene la Dirección Meteorológica de Chile (DMC) consultadas a través de la página web del Sistema Nacional de Información del Agua<sup>48</sup> (SNIA) en cada región, tomando las estaciones de Angol, Curacautín, y Villarica, para región de La Araucanía, y Coltauco, Litueche, Rengo, y San Fernando, para la región de O'Higgins.

Con esto se calculó el promedio histórico de los últimos 10 años, y se crearon variables dummy que dan cuenta de si las precipitaciones se desviaron más de dos desviaciones estándar del promedio, siendo alta o baja según corresponda. Estas hacen referencia a las lluvias o sequías en periodo de cosecha de cada materia prima; para el trigo se crearon para diciembre, enero, y febrero, y para el maíz marzo, abril, y mayo.

Externo: Para obtener información sobre el clima a nivel mundial se usó el TransOceanic Nino Index (TONI), que es publicado mensualmente por el Climate Prediction Center<sup>49</sup> (CPC) de Estados Unidos. En base a sus valores es posible analizar si es está frente al fenómeno del Niño o la Niña, de acuerdo con las condiciones históricas que se presentan cuando ocurre alguno de estos fenómenos.

La Niña por su parte, por lo general promueve corrientes cálidas y reducciones en precipitaciones, en cambio El Niño promueve temperaturas más heladas y aumento en las precipitaciones.

Recordando lo mencionado al inicio de este capítulo, para las variables climáticas se usaron valores observados en los "datos dentro de la muestra" y "fuera de la muestra" por las dificultades para encontrar pronósticos de estas variables en períodos anteriores. En caso de usar los modelos desarrollados en la vida real, sí existes proyecciones de cada una desde la Dirección Meteorológica de Chile<sup>50</sup> y el Climate Prediction Center de Estados Unidos, a 3 meses en el caso de las lluvias y a 9 meses para el TransOceanic Nino Index<sup>51</sup>.

---

<sup>47</sup> La región de La Araucanía entre 2005 y 2015 produjo el 41% del total nacional de trigo, y la región del Libertador Bernardo O'Higgins el 48% del total nacional de maíz en ese período.

<sup>48</sup> <http://snia.dga.cl/BNACconsultas/reportes>

<sup>49</sup> [http://www.cpc.ncep.noaa.gov/products/analysis\\_monitoring/ensostuff/ensoyears.shtml](http://www.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/ensoyears.shtml)

<sup>50</sup> <http://www.meteochile.gob.cl/PortalDMC-web/index.xhtml>

<sup>51</sup> <http://www.cpc.ncep.noaa.gov/products/CFSv2/CFSv2seasonal.shtml>

## Macroeconómico:

Cambios en impuestos a exportación de granos en Argentina: Argentina ha realizado cambios en su política de aranceles en los últimos años<sup>52</sup>, y debido a su cercanía nos impactan directamente. Desde la Bolsa de Rosario se obtuvieron las fechas en que ocurrieron<sup>53</sup>, creando variables dummies que representan cada uno de estos cambios (solo se usan para el trigo y maíz en los cuales Chile es el mercado local).

Estos cambios ocurrieron para el trigo y el maíz en noviembre de 2007 y diciembre de 2008 (Figura 7.5). En junio de 2008 se establece un régimen de impuestos variables, cuya duración es de tan solo un mes, volviendo en julio de ese año al régimen anterior (vigente en noviembre de 2007). Y posteriormente en diciembre se realiza el último cambio.

**Figura 7.5:** Cambios en impuestos a la exportación de trigo y maíz en Argentina. (Ítems máximo, mínimo, y último corresponden a los valores de los impuestos entre el 02-06-2008 y el 20-07-2008).

Fecha	Trigo	Maíz
06-04-2002	20%	20%
12-11-2007	28%	25%
02-06-2008	*	*
Máximo	28,80%	36,40%
Mínimo	26,20%	22,80%
Último	26,20%	26,20%
21-07-2008	28%	25%
23-12-2008	23%	20%

*Fuente: Elaboración propia en base a información de la Bolsa de Comercio de Rosario (BCR).*

El cambio que se realizó en junio no fue incluido porque al ser variable es muy incierto el efecto que tuvo y la cantidad de impuesto que pagó cada materia prima, ya que depende de la cantidad exportada.

## Productos relacionados:

Indicadores del etanol: Desde la Renewables Fuels Association<sup>54</sup> (RFA) se tiene la información de la producción del etanol en Estados Unidos, mayor productor de este combustible. Las variables obtenidas son producción anual, uso de maíz, precio etanol, ratio producción y capacidad instalada, ratio consumo y producción. Todas son anuales salvo el precio mensual promedio del etanol y el maíz usado para producir etanol. Como se menciona anteriormente, solo se

<sup>52</sup> Período agosto de 2006 hasta diciembre de 2014, durante el cual se calibró el modelo.

<sup>53</sup> Retenciones: Larga historia de tensiones, Guillermo Rossi, Bolsa de Cereales de Rosario, 2017.

<sup>54</sup> <http://www.ethanolrfa.org/resources/industry/statistics/>

consideran el precio mensual promedio del etanol y el maíz usado para producir etanol pues son de frecuencia mensual.

Indicadores del biodiesel: Se obtiene el precio promedio mensual, producción anual, ratio de producción vs capacidad, y capacidad instalada desde la Global Agricultural International Network<sup>55</sup> (GAIN) ya que no solo es producido en Estados Unidos, sino que en muchos países del mundo. Lamentablemente las 3 últimas variables tienen una frecuencia y análisis menores (anual), por lo que se descarta su uso en el trabajo, y solo se usa el precio promedio mensual del biodiesel.

Los precios históricos se obtienen en base a un estudio actualizado mensualmente por la Universidad de Iowa sobre los retornos de las plantas de biodiesel (“Monthly profitability of Biodiesel production”)<sup>56</sup>. En el caso del biodiesel no se usarán los futuros pues el volumen transando es muy pequeño.

Indicadores de la leche: Se usa el precio promedio mensual en Estados Unidos publicado periódicamente por el USDA, a través de la página web de la National Milk Producers Federation<sup>57</sup> (NMPF). Al igual que con el biodiesel, no se agregaron más variables que el precio debido a la frecuencia de publicación de las demás variables; stock, oferta, demanda, entre otros. El precio de la leche solo se incluye en el modelo de la soya, ya que es solo con esta materia prima con la que se ha observado relación.

#### **Retardo de cada variable con respecto al precio promedio mensual que se quiere predecir:**

Para la estimación de los modelos, las variables usadas presentan diferencias en cuanto a sus retardos, es decir, existen variables cuyo valor observado incluido en el modelo fue hace 2 meses, 3 meses, entre otros. Esto depende de la rapidez con que las agencias encargadas de monitorear las variables usadas publiquen los datos de las mismas.

Así, todas las variables de precios de materias primas a nivel internacional, nacional, y de productos correlacionados presentan un retardo de 2 meses con respecto del mes cuyo precio promedio se intenta predecir, es decir, para predecir el precio de enero se usan precios de noviembre. La única variable para la cual no se cumple esta regla es la variable dependiente de cada modelo, pues para hacer uso de los modelos no es posible no incluir el primer rezago.

Para solucionar esto, en este trabajo se usó el precio promedio del mes anterior de esta variable, no obstante, para realizar predicciones en la realidad se debe usar el precio promedio de las dos primeras semanas de cada mes (hasta el día 15), siendo una aproximación al precio promedio mensual que se necesita

---

<sup>55</sup> <https://gain.fas.usda.gov/Lists/Advanced%20Search/AllItems.aspx>

<sup>56</sup> <https://www.extension.iastate.edu/agdm/articles/hof/HofJan08.html>

<sup>57</sup> <http://www.nmpf.org/dairy-market-update/us-all-milk-prices>



agregar al modelo.

Estos 15 días que se deben esperar no se deben solo a lo anterior, sino que también a que existen variables cuyos valores se publican alrededor del día 10-15 de cada mes, como son las variables de oferta y demanda de materias primas que se obtienen desde el USDA.

Las variables de oferta y demanda también presentan un retardo de dos meses, pues los informes que se obtienen alrededor del 15 de cada mes presentan la información del mes anterior, con lo que para el mes que se intenta predecir presentarán un rezago de dos meses.

Los futuros de cada insumo no presentan ningún tipo de retardo pues como se mencionó anteriormente, se creó un índice mediante una interpolación inicial para tener el precio “futuro” del insumo.

Por último, las variables relativas a las importaciones desde Argentina a Chile, el mundo a Chile, y el mundo a China poseen un retardo de 3 meses. Los informes se publican 2 meses después de que toma lugar el valor de esas importaciones, por lo que al usar ese valor en el modelo se retrasa un mes más.

En los tests mostrados las variables presentan números de retardos distintos a los mencionados en este apartado. La razón es que se introdujeron en distintos órdenes en la base de datos, y, por ejemplo, las importaciones no aparecen con rezago, pues al agregarlas a la base ya se realizó el rezago correspondiente.

## 8 RESULTADOS

### 8.1 Introducción

En el siguiente capítulo se presentan los resultados obtenidos de la implementación de los modelos VECM (Modelo de Vector de Corrección de Errores) y Regresión Lineal en modelos de predicción con plazo de 1,3, y 6 meses de anticipación para cada materia prima. Se presenta en primera instancia, la manera en que se estiman estos modelos (estimación se refiere al proceso de realizar los tests necesarios para estudiar los supuestos que deben cumplir los modelos y calcular los coeficientes de cada variable del modelo).

Como se menciona al inicio del capítulo 7, dentro de cada categoría de modelos (VECM y regresión lineal), se prueba el uso de variables rezagadas y de futuros o predicciones realizadas por expertos, de las mismas variables para evaluar sus resultados. Esto es que, a modo de ejemplo, para algunos se usó el valor rezagado del precio promedio internacional del trigo, y para otros se usó el valor del futuro de trigo en base al índice creado para los futuros, según se describe en la sección 7.2.

Dentro de la sección 8.2, en el apartado Estimación (8.2.1) se muestran los resultados de los tests utilizados para estimar los modelos VECM, de manera de dar un mayor entendimiento de cómo se llegó a los modelos finales, y también, mostrar los supuestos que se cumplen, y cuáles no, en caso de que ocurriera.

Los test usados son: Test de raíces unitarias, Test de Granger, Test de rezagos, Test de autocorrelación, Test de normalidad, Test de heterocedasticidad, y Test de cointegración, ampliamente conocidos en la literatura, y tomados como un estándar a la hora de probar los supuestos subyacentes que deben cumplir estos modelos. Ya que el proceso de estimación sigue los mismos tests y criterios para todos los modelos, solo se muestra la estimación para el modelo de predicción del trigo a un plazo de 3 meses, pudiendo encontrar los resultados de este proceso para los demás modelos en Anexos Imágenes 2-57.

Luego, en la sección Predicciones (8.2.2) se muestran las predicciones de los modelos seleccionados para cada uno de los plazos de acuerdo con las métricas MAPE (Error porcentual medio absoluto) y RSME (Raíz del Error cuadrático medio). Adicionalmente se incluye el MPE (Error porcentual medio), cuya inclusión es meramente una referencia de cuán cercanos en promedio están las predicciones frente al valor real, como una forma de medir el “sesgo” del modelo, pero no se considera a la hora de juzgar los modelos. Por comodidad, se muestran en esta sección mediante gráficos sólo las predicciones a 3 meses de cada materia prima, estando disponibles los gráficos para 1 y 6 meses en Anexos Imágenes 58-63, y resultados numéricos en Anexos Imágenes 64-66.

La predicción a 3 meses presenta un performance “promedio” entre las predicciones a 1 y 6 meses, razón por la cual es el período elegido para mostrar, de manera de presentar al lector las bondades, pero también las limitaciones del modelo a un mayor plazo, ya que 1 mes de anticipación en estas materias primas no significa un gran cambio en los precios frente al período anterior.

Tal como se menciona en el capítulo Metodología (5), la forma en que serán usados los datos es la siguiente (para modelo VECM y regresión lineal), para la calibración de los modelos se usarán datos entre agosto de 2006 y diciembre de 2014, a lo cual se llamará “datos dentro de la muestra”. Y para la evaluación del rendimiento de los modelos propuestos anteriormente se usarán datos entre enero de 2015 y diciembre de 2016, lo cual se llamará “datos fuera de la muestra”.

Los “datos fuera de la muestra” consisten en observaciones que hubiera sido posible obtener en caso de haber estado usando el modelo en ese momento, razón por la cual se usan rezagos de las variables, encuestas de expectativas de expertos, proyecciones de organismos especialidades, entre otros, de manera de replicar con la mayor precisión posible la situación real. No obstante, los pronósticos en las fechas de predicción de lluvias y del Índice de la corriente del Niño (explicado en el Capítulo 7) no estaban disponibles, por lo que se usan datos observados, por lo que se usan datos observados y no rezagos ni estimaciones de esas variables.

Las predicciones a 1 mes se realizarán en cada uno de los meses de 2015 y 2016, es decir, en enero se realizará una predicción para el mes de febrero, y en febrero una para marzo, y así sucesivamente. En el caso de los modelos a 3 meses, se harán predicciones en el primer mes de cada trimestre cada año entre 2015 y 2016, por lo que los períodos de predicción serán enero-marzo, abril-junio, julio-septiembre, octubre-diciembre. Y para los modelos a 6 meses se realizará de manera análoga a los de 3 meses, pero tomando como mes de predicción el primer mes de cada semestre, es decir los períodos de predicción serán enero-junio, julio-diciembre para 2015 y 2016.

En cada uno de estos meses en que se hace la predicción, se usa información que hubiera sido posible conseguir en ese momento, salvo como se mencionó anteriormente, los valores para los pronósticos de lluvias y la corriente del Niño.

Se aclara que lo único que cambiará en los modelos al usar los “datos fuera de la muestra” son los valores que toman las variables, pues los coeficientes se mantendrán estáticos durante todo el período de evaluación (2015 y 2016), permaneciendo iguales a los que se obtuvieron al calibrar cada modelo con los datos “dentro de la muestra”.

Para los modelos de regresión lineal, en la sección 8.3, en el apartado Estimación (8.3.1) se revisan las variables más significativas, la magnitud y signo de sus coeficientes, y el impacto que suponen en el precio. Con esto se busca

mostrar las variables que los tomadores de decisiones deberían tomar en cuenta a la hora de establecer juicios sobre los precios futuros, proveyendo una guía simple para analizar las variables que influyen en las materias primas estudiadas. Los resultados de la calibración de las regresiones se pueden encontrar en Anexos Imágenes 67-69.

Cabe mencionar, que, debido a las dinámicas temporales existentes en el proceso de generación de precios, variables rezagadas, y dependencia del precio con la historia pasada, los coeficientes podrían entregar resultados que puede no ser los esperados en cuanto a los signos de las variables.

De la misma manera que con el modelo VECM, se presentan los resultados de acuerdo con las métricas MAPE y RSME para todos los períodos de predicción en la sección 8.3.2, y se muestran las predicciones de manera gráfica para las regresiones a 3 meses, estando disponibles los demás períodos para su revisión de manera gráfica en Anexos Imágenes 70-75, y de manera numérica en Anexos Imágenes 76-78.

Finalmente, se pasa a la programación de las compras (sección 8.4) en base a los datos proyectados, y al plan de producción de IANSA. Se muestra el plan de compras de acuerdo con el programa diseñado para este trabajo, tomando como demanda el promedio anual de compras en 2015 y 2016. Posteriormente, se muestran los beneficios o pérdidas que produce el plan de compras propuesto por los modelos frente a compras reales de IANSA en el periodo 2015 y 2016, y frente a una estrategia designada como “conservadora”, consistente en comprar solamente lo requerido para el próximo mes.

Para la programación de compras no se considera un modelo complejo de optimización debido a los supuestos de abastecimiento para el problema a resolver, sino que se utilizan reglas en base a los precios pronosticados para cada mes y la cantidad necesaria de materia prima para satisfacer cada período, lo cual será explicado en la sección 8.4.

Para esta evaluación no se considerarán cambios en las recetas de los productos, ya que para cada uno existe una receta específica, y en general, el cambio producto de variaciones en los precios es muy pequeño. También, la programación de compra se hace solo para el trimestre o semestre (según corresponda) que se está prediciendo, pues es en ese período en que se tiene certeza de los precios de acuerdo con los modelos desarrollados, por lo que no es posible extender más allá del período pronosticado la programación de compras sin que se realice otro pronóstico.

Para poner a prueba la consistencia de los beneficios o pérdidas frente a distintos escenarios de compra, y no solo el de la muestra se realizan simulaciones que recrean las compras posibles por parte de los compradores de la empresa a través de distribuciones estadísticas que se asimilen al comportamiento que han tenido entre 2013 y 2016. Con esto, se pasa a revisar

la probabilidad de obtener beneficios, y el beneficio promedio.

Y por último, en el subcapítulo Síntesis (8.5), se hace una breve recapitulación de los resultados obtenidos en el modelo VECM, regresión lineal, y programación de compras, proporcionando conclusiones especialmente para la programación de compras en cuanto a las materias primas en que es posible lograr mayor eficiencia, las distintas formas con que se puede operar el plan de compras (estrategias), y recomendaciones de cara a su implementación en la realidad.

## **8.2 Resultados del modelo VECM (Modelo de Vector de Corrección de Errores)**

### **8.2.1 Estimación**

A continuación, se presentarán los tests usados para analizar los supuestos que deben cumplir los modelos, y el modelo final resultante con los coeficientes de cada una de las variables y rezagos respectivos. A modo de ejemplo, se presenta el modelo de predicción para un período de 3 meses para el precio promedio mensual del trigo en Chile, (es un procedimiento estándar por lo que los demás modelos se pueden encontrar en Anexos Imágenes 2-57) junto con breves descripciones y análisis que se realizaron al momento de la estimación, de acuerdo con la metodología planteada en base a la literatura estudiada.

Se debe recordar que el número de períodos rezagados en las variables que se ven en las tablas a continuación, no necesariamente representa el rezago real de cada variable, pues depende de cómo fue insertado en la base de datos. Al final de la sección de Variables (7.2.2) se pueden encontrar las indicaciones sobre esto para cada variable.

El primer test es el de raíces unitarias en niveles y en diferencias (Figuras 8.1 y 8.2), donde se prueba si es que las variables poseen o no raíz unitaria. Para que puedan ser incluidas en el modelo VECM deben poseer un orden de integración de 1, es decir, que no posean raíces unitarias en los tests en nivel pero que sí se rechace esa hipótesis en el test en diferencias.

La mayoría de las variables cumple con la condición anterior al menos al 1% de significancia, salvo las importaciones desde argentina (IMP), la lluvia en La Araucanía (lluviaa), y la lluvia en el Bio Bío (lluviab). Por esto, estas variables no serán incluidas en el modelo. También, algunas de las variables presentes en la prueba no fueron usadas debido a que su frecuencia de actualización es mayor que un mes, como se explicó en la sección Variables (7.2).

**Figura 8.1:** Test de raíces unitarias (en niveles).

Null Hypothesis: Unit root (individual unit root process)  
 Series: CHI, DOLAR, FUTUROS, FUTUROSMAIZ, FUTUROSSOYA, IMP,  
 LLUVIAA, LLUVIAB, PETRO, PRODM, RATIO, RENDM, RENDN,  
 SIEMBRA, STOCK, TONI, USA  
 Date: 04/10/17 Time: 16:14  
 Sample: 2006M08 2016M12  
 Exogenous variables: Individual effects  
 User specified maximum lags  
 Automatic selection of lags based on SIC: 0 to 6  
 Total number of observations: 1678  
 Cross-sections included: 17

Method	Statistic	Prob.**
ADF - Fisher Chi-square	163.080	0.0000
ADF - Choi Z-stat	-7.01899	0.0000

\*\* Probabilities for Fisher tests are computed using an asymptotic Chi-square distribution. All other tests assume asymptotic normality.

Intermediate ADF test results UNTITLED

Series	Prob.	Lag	Max Lag	Obs
CHI	0.1183	1	12	99
DOLAR	0.1482	1	12	99
FUTUROS	0.0747	0	12	100
FUTUROSMAIZ	0.0212	0	12	100
FUTUROSSOYA	0.0400	0	12	100
IMP	0.0000	0	12	100
LLUVIAA	0.0000	6	12	94
LLUVIAB	0.0000	6	12	94
PETRO	0.0903	1	12	99
PRODM	0.5867	0	12	100
RATIO	0.6321	0	12	100
RENDM	0.7562	0	12	100
RENDN	0.3058	0	12	100
SIEMBRA	0.0881	0	12	100
STOCK	0.6954	0	12	100
TONI	0.0354	6	12	94
USA	0.0461	1	12	99

*Fuente: Elaboración propia.*

**Figura 8.2:** Test de raíces unitarias (en diferencias).

Null Hypothesis: Unit root (individual unit root process)  
 Series: CHI, DOLAR, FUTUROS, FUTUROSMAIZ, FUTUROSSOYA, IMP,  
 LLUVIAA, LLUVIAB, PETRO, PRODM, RATIO, RENDM, RENDN,  
 SIEMBRA, STOCK, TONI, USA  
 Date: 04/10/17 Time: 16:14  
 Sample: 2006M08 2016M12  
 Exogenous variables: Individual effects  
 User specified maximum lags  
 Automatic selection of lags based on SIC: 0 to 11  
 Total number of observations: 1656  
 Cross-sections included: 17

Method	Statistic	Prob.**
ADF - Fisher Chi-square	519.973	0.0000
ADF - Choi Z-stat	-20.4824	0.0000

\*\* Probabilities for Fisher tests are computed using an asymptotic Chi square distribution. All other tests assume asymptotic normality.

Intermediate ADF test results D(UNTITLED)

Series	Prob.	Lag	Max Lag	Obs
D(CHI)	0.0000	0	12	99
D(DOLAR)	0.0000	0	12	99
D(FUTUROS)	0.0000	0	12	99
D(FUTUROSMAIZ)	0.0000	0	12	99
D(FUTUROSSOYA )	0.0000	0	12	99
D(IMP)	0.0001	1	12	98
D(LLUVIAA)	0.0000	11	12	88
D(LLUVIAB)	0.0000	10	12	89
D(PETRO)	0.0000	0	12	99
D(PRODM)	0.0000	0	12	99
D(RATIO)	0.0000	0	12	99
D(RENDM)	0.0000	0	12	99
D(RENDN)	0.0000	0	12	99
D(SIEMBRA)	0.0000	0	12	99
D(STOCK)	0.0000	0	12	99
D(TONI)	0.0364	5	12	94
D(USA)	0.0000	0	12	99

*Fuente: Elaboración propia.*

Luego, se hace un test de selección de rezagos (Figura 8.3) para evaluar cuál es el número óptimo de acuerdo con el modelo, el cual indica que el número óptimo de rezagos está entre 1 y 2 (basado en cantidad de criterios que indican ese número de rezagos como el óptimo). Dado que la misma cantidad de criterios indican 1 y 2 rezagos como óptimos, se pasa al test de correlación para determinar el mejor número.

**Figura 8.3:** Test de selección de rezagos.

VAR Lag Order Selection Criteria

Endogenous variables: CHI USA(-3) ARG(-3) USAMAIZ(-3) USASOYA(-3)

Exogenous variables: C ESTAC NOV7 DIC8 DIC11 DOLARREAL(-4) PETRO(-2) RATIO(-2)

STOCKFINALM(-2) TONI IMPARG(-2) IMPMUNDO(-2) AEAD AEF AFAD ALTAD ALTAD ALTAFA ALTAFA

BAJAD BAJAE BAJAF

Date: 05/31/17 Time: 13:53

Sample: 2006M08 2014M12

Included observations: 90

Lag	LogL	LR	FPE	AIC	SC	HQ
0	524.1080	NA	6.48e-11	-9.313511	-6.397067	-8.137430
1	784.7847	370.7402	3.59e-13	-14.55077	-10.93994*	-13.09467*
2	819.9865	46.15347*	3.05e-13*	-14.77748	-10.47225	-13.04136
3	845.3965	30.49195	3.30e-13	-14.78659	-9.786969	-12.77045
4	876.1769	33.51642	3.29e-13	-14.91504	-9.221030	-12.61888
5	894.3537	17.77297	4.54e-13	-14.76342	-8.375014	-12.18724
6	934.4614	34.75999	4.07e-13	-15.09914	-8.016349	-12.24294
7	970.8731	27.51104	4.29e-13	-15.35274	-7.575550	-12.21652
8	1013.269	27.32191	4.38e-13	-15.73931*	-7.267737	-12.32308

\* indicates lag order selected by the criterion

LR: sequential modified LR test statistic (each test at 5% level)

FPE: Final prediction error

AIC: Akaike information criterion

SC: Schwarz information criterion

HQ: Hannan-Quinn information criterion

*Fuente: Elaboración propia.*

El test de correlación serial (Figura 8.4) muestra que para un modelo con 1 rezago no se puede concluir que no existe correlación al 5% de confianza, debiendo llegar al 1%. Se prefiere usar 2 rezagos para reducirla (la correlación), ya que con 2 rezagos se puede concluir con holgura que no existe correlación serial. Este test fue realizado para un modelo de 1 rezago, por lo que se debe realizar nuevamente para 2 rezagos y evaluar si se puede mantener la hipótesis de que no existe correlación.



**Figura 8.4:** Test de correlación serial en residuos (usando 1 rezago).

VAR Residual Serial Correlation LM Tests  
 Null Hypothesis: no serial correlation at lag  
 order h  
 Date: 05/31/17 Time: 13:54  
 Sample: 2006M08 2014M12  
 Included observations: 97

Lags	LM-Stat	Prob
1	42.98018	0.0141
2	31.79146	0.1641
3	27.19668	0.3461
4	20.39913	0.7256
5	13.80820	0.9650
6	46.48579	0.0056
7	25.91050	0.4124
8	61.81309	0.0001
9	34.77945	0.0923
10	18.62460	0.8148
11	18.16531	0.8353
12	30.65926	0.2006

Probs from chi-square with 25 df.

*Fuente: Elaboración propia.*

Efectivamente, para 2 rezagos (Figura 8.5) no existe correlación serial al 5%, por lo que se decide ocupar 2 rezagos dentro del modelo.

**Figura 8.5:** test de correlación serial en residuos (usando 2 rezagos).

VAR Residual Serial Correlation LM Tests  
 Null Hypothesis: no serial correlation at lag  
 order h  
 Date: 05/31/17 Time: 13:54  
 Sample: 2006M08 2014M12  
 Included observations: 96

Lags	LM-Stat	Prob
1	20.98466	0.6935
2	35.74820	0.0755
3	37.34949	0.0535
4	25.55373	0.4317
5	13.92288	0.9631
6	34.57176	0.0962
7	16.70691	0.8921
8	47.14216	0.0047
9	33.46167	0.1199
10	20.56060	0.7168
11	23.50073	0.5483
12	28.26717	0.2957

Probs from chi-square with 25 df.

*Fuente: Elaboración propia.*

**Figura 8.6:** Test de normalidad en residuos.

VAR Residual Normality Tests  
 Orthogonalization: Cholesky (Lutkepohl)  
 Null Hypothesis: residuals are multivariate normal  
 Date: 05/31/17 Time: 13:54  
 Sample: 2006M08 2014M12  
 Included observations: 96

Component	Skewness	Chi-sq	Df	Prob.
1	-0.019805	0.006276	1	0.9369
2	0.252095	1.016829	1	0.3133
3	0.311186	1.549392	1	0.2132
4	-0.229641	0.843761	1	0.3583
5	-0.170590	0.465616	1	0.4950
Joint		3.881874	5	0.5665

Component	Kurtosis	Chi-sq	Df	Prob.
1	2.025467	3.798860	1	0.0513
2	1.972809	4.220485	1	0.0399
3	2.331078	1.789825	1	0.1809
4	2.056795	3.558543	1	0.0592
5	1.607930	7.751434	1	0.0054
Joint		21.11915	5	0.0008

Component	Jarque-Bera	df	Prob.
1	3.805136	2	0.1492
2	5.237314	2	0.0729
3	3.339217	2	0.1883
4	4.402305	2	0.1107
5	8.217050	2	0.0164
Joint	25.00102	10	0.0053

*Fuente: Elaboración propia.*

En cuanto a la normalidad (Figura 8.6), el test de Jarque-Bera muestra que las series en conjunto no son normales, no obstante, de manera particular sí lo son al 1%. Así, de manera conjunta el modelo no cumple con el supuesto de normalidad.

**Figura 8.7:** Test de heterocedasticidad en residuos.

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Date: 05/31/17 Time: 13:55

Sample: 2006M08 2014M12

Included observations: 96

Joint test:					
Chi-sq	df	Prob.			
737.7370	720	0.3152			

Individual components:					
Dependent	R-squared	F(48,47)	Prob.	Chi-sq(48)	Prob.
res1*res1	0.460541	0.835922	0.7308	44.21190	0.6288
res2*res2	0.641125	1.749265	0.0286	61.54797	0.0906
res3*res3	0.689874	2.178157	0.0043	66.22795	0.0416
res4*res4	0.548622	1.190116	0.2759	52.66770	0.2983
res5*res5	0.666993	1.961212	0.0112	64.03132	0.0607
res2*res1	0.416990	0.700335	0.8887	40.03101	0.7865
res3*res1	0.509716	1.017975	0.4761	48.93274	0.4354
res3*res2	0.498142	0.971916	0.5393	47.82161	0.4801
res4*res1	0.454952	0.817313	0.7556	43.67544	0.6505
res4*res2	0.500853	0.982514	0.5245	48.08190	0.4695
res4*res3	0.628879	1.659237	0.0424	60.37239	0.1084
res5*res1	0.387051	0.618303	0.9498	37.15693	0.8715
res5*res2	0.510829	1.022519	0.4700	49.03958	0.4312
res5*res3	0.629680	1.664939	0.0413	60.44923	0.1072
res5*res4	0.554921	1.220816	0.2476	53.27239	0.2786

*Fuente: Elaboración propia.*

En el test de heterocedasticidad (Figura 8.7) se tiene que se logra cumplir este supuesto, confirmando que no hay presencia de heterocedasticidad en los residuos.

El próximo test por usar es el test de Johansen (Figura 8.8) que mide la cointegración entre las variables, de manera de revisar si es que es posible encontrar una relación lineal entre ellas y modelar el proceso como un VECM. Esta relación es una relación de largo plazo entre cada variable.

Sus resultados muestran que se logra encontrar al menos dos relaciones lineales entre las variables. Se tomará la primera, que presenta al precio chileno frente a las demás variables. Debido a que las variables están en logaritmos, sus coeficientes se pueden interpretar como cambios porcentuales.

Así, un incremento en 10% en el precio promedio mensual del trigo en la Bolsa de Chicago en Estados Unidos 3 meses atrás aumenta los precios en alrededor de un 2,6% (se usa el inverso aditivo debido a que es una ecuación), siendo un

proceso análogo para cada una de las variables de la ecuación.

No necesariamente todas las variables son significativas, lo que implica en esos casos que se debe eliminar esas variables de la ecuación. En el test presentado la variable USASOYA (que representa el precio promedio internacional mensual en la Bolsa de Chicago) no es significativa basado en su error estándar, ya que no se puede asegurar con 5% de confianza que sea distinto de 0.

**Figura 8.8:** Test de cointegración de Johansen (Continúa en la página siguiente).

Date: 05/31/17 Time: 13:55  
 Sample (adjusted): 2007M02 2014M12  
 Included observations: 95 after adjustments  
 Trend assumption: Linear deterministic trend  
 Series: CHI USA(-3) ARG(-3) USAMAIZ(-3) USASOYA(-3)  
 Exogenous series: ESTAC NOV7 DIC8 DIC11 DOLARREAL(-4) PETRO(-2) RATIO(-2) STOCKFINALM(-2) TONI IMPARG(-2) IMPMUNDO(-2) AEAD AEF AFAD ALTAD  
 Warning: Critical values assume no exogenous series  
 Lags interval (in first differences): 1 to 2

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.375282	102.4414	69.81889	0.0000
At most 1 *	0.233037	57.74809	47.85613	0.0045
At most 2 *	0.173976	32.54299	29.79707	0.0236
At most 3	0.114414	14.38548	15.49471	0.0729
At most 4	0.029477	2.842415	3.841466	0.0918

Trace test indicates 3 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.375282	44.69327	33.87687	0.0018
At most 1	0.233037	25.20509	27.58434	0.0978
At most 2	0.173976	18.15751	21.13162	0.1241
At most 3	0.114414	11.54306	14.26460	0.1290
At most 4	0.029477	2.842415	3.841466	0.0918

Max-eigenvalue test indicates 1 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by  $b'S11*b=I$ ):

CHI	USA(-3)	ARG(-3)	USAMAIZ(-3)	USASOYA(-3)
4.898558	-12.43332	11.11771	4.782641	3.785197
-11.68688	0.917446	9.894229	7.851097	-7.948707
5.570267	-9.048907	-3.320089	2.775599	-8.723131
-4.852876	-10.74357	14.95456	-7.123218	3.101635
9.897500	6.613216	5.216742	-1.575491	-7.911476

Unrestricted Adjustment Coefficients (alpha):

D(CHI)	-0.011242	0.011292	0.005019	0.006338	-0.002715
D(USA(-3))	-0.009073	-0.022197	0.018354	0.003188	5.55E-05
D(ARG(-3))	-0.020798	-0.011105	-0.005824	-0.001780	-0.000937
D(USAMAIZ(-3))	-0.026258	-0.009738	0.002114	0.003361	0.005399
D(USASOYA(-3))	-0.024772	-0.004981	0.008500	-0.009711	0.002792

1 Cointegrating Equation(s):      Log likelihood      823.9203

Normalized cointegrating coefficients (standard error in parentheses)

CHI	USA(-3)	ARG(-3)	USAMAIZ(-3)	USASOYA(-3)
1.000000	-2.538160	2.269588	0.976337	0.772717
	(0.63593)	(0.67835)	(0.38031)	(0.47680)

Adjustment coefficients (standard error in parentheses)

D(CHI)	-0.055070	(0.02303)
D(USA(-3))	-0.044444	(0.03885)
D(ARG(-3))	-0.101878	(0.02302)
D(USAMAIZ(-3))	-0.128629	(0.03068)
D(USASOYA(-3))	-0.121348	(0.03048)

*Fuente: Elaboración propia.*

El último test que se debe realizar es el test de Granger (Figura 8.9), que mide la significancia de los rezagos del modelo para cada una de las variables, y de manera conjunta. En este caso, ninguno de los rezagos es significativo por lo que deben ser eliminados del modelo, quedando solamente las variables de la ecuación de cointegración, los rezagos de la variable dependiente, y las variables exógenas que fueron incluidas (sección 7.2).

**Figura 8.9:** Test de causalidad de Granger.

VEC Granger Causality/Block Exogeneity Wald Tests

Date: 05/31/17 Time: 13:56

Sample: 2006M08 2014M12

Included observations: 96

Dependent variable: D(CHI)

Excluded	Chi-sq	Df	Prob.
D(USA(-3))	0.567445	1	0.4513
D(ARG(-3))	2.536424	1	0.1112
D(USAMAIZ(-3))	0.591089	1	0.4420
D(USASOYA(-3))	3.99E-06	1	0.9984
All	4.036947	4	0.4010

*Fuente: Elaboración propia.*

Finalmente, se tiene el modelo VECM (Figura 8.10), el cual en este caso consiste en una ecuación de cointegración y variables exógenas debido a que los rezagos resultaron ser no significativos de acuerdo con el test de Granger. A diferencia de los coeficientes de la ecuación de cointegración, los coeficientes presentes en el modelo VECM para cada una de las variables no son posibles de interpretar, ni tampoco su p-valor.

Esto se debe a la presencia de correlación intrínseca de estos modelos, pues existen variables que presentan rezagos, y estos están relacionados entre sí, estando en este caso la variable del precio mensual del trigo en Chile rezagada en 1 período. Así, el modelo solo se puede usar para generar predicciones sobre precios, pero no para interpretar el efecto de las variables.

Existen métodos para estudiar la parte de la varianza que explica cada variable, o el efecto que tiene un shock en cada variable en la variable dependiente. En este trabajo, como se menciona en el capítulo Metodología (5), se usará una regresión lineal para explicar los efectos de las variables, y encontrar las más significativas, debido al uso práctica que se le quiere dar a los modelos estimados.

**Figura 8.10:** Modelo VECM completo estimado.

Dependent Variable: D(CHI)  
Method: Least Squares  
Date: 05/31/17 Time: 13:58  
Sample (adjusted): 2006M12 2014M12  
Included observations: 97 after adjustments

$$D(CHI) = C(1)*(-1.80680519639*CHI(-1) - 7.60811947088*USA(-4) + 14.7019708249*ARG(-4) + 5.52077681038*USAMAIZ(-4) - 62.271057281) + C(2)*D(CHI(-1)) + C(7) + C(8)*ESTAC + C(9)*NOV7 + C(10)*DIC8 + C(11)*DIC11 + C(12)*DOLARREAL(-4) + C(13)*PETRO(-2) + C(14)*RATIO(-2) + C(15)*STOCKFINALM(-2) + C(16)*TONI + C(17)*IMPARG(-2) + C(18)*IMPUNDO(-2) + C(19)*AEAD + C(20)*AEAF + C(21)*AFAD + C(22)*ALTAD + C(23)*ALTAF + C(24)*ALTAE + C(25)*BAJAD + C(26)*BAJAE + C(27)*BAJAF$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	-0.001230	0.003852	-0.319347	0.7504
C(2)	0.293453	0.105127	2.791415	0.0087
C(7)	2.137544	1.011023	2.114238	0.0379
C(8)	0.075060	0.120653	0.622113	0.5358
C(9)	-0.119899	0.056432	-2.124683	0.0370
C(10)	-0.083663	0.052623	-1.589862	0.1161
C(11)	-0.243748	0.049407	-4.933436	0.0000
C(12)	-0.256110	0.113234	-2.261770	0.0266
C(13)	-0.069301	0.048820	-1.419511	0.1599
C(14)	0.081009	0.103375	0.783641	0.4358
C(15)	-0.089023	0.107229	-0.830207	0.4091
C(16)	-0.000952	0.004436	-0.214676	0.8306
C(17)	-9.76E-05	0.001625	-0.060058	0.9523
C(18)	0.001013	0.009643	0.105003	0.9167
C(19)	-0.009620	0.062691	-0.153456	0.8785
C(20)	0.026258	0.072215	0.363611	0.7172
C(21)	0.021812	0.083352	0.344296	0.7316
C(22)	-0.022915	0.028925	-0.792204	0.4308
C(23)	-0.013212	0.052172	-0.253235	0.8008
C(24)	-0.004932	0.037707	-0.130789	0.8983
C(25)	0.000983	0.050108	0.019621	0.9844
C(26)	0.111664	0.052780	2.115674	0.0377
C(27)	0.046915	0.050793	0.923651	0.3587
R-squared	0.446765	Mean dependent var		0.000839
Adjusted R-squared	0.282290	S.D. dependent var		0.056656
S.E. of regression	0.047998	Akaike info criterion		-3.031739
Sum squared resid	0.170481	Schwarz criterion		-2.421241
Log likelihood	170.0394	Hannan-Quinn criter.		-2.784884
F-statistic	2.716307	Durbin-Watson stat		1.851040
Prob(F-statistic)	0.000730			

*Fuente: Elaboración propia.*

Se puede observar también, que posee 27 variables. Estas 27 variables incluyen también los rezagos de cada una de las variables incluidas en el modelo, como el rezago del precio promedio mensual en Chile. Por lo general, no se presenta esta ecuación que representa al modelo, ya que es muy complicada de entender por la gran cantidad de variables y distintos rezagos incluidos.

## 8.2.2 Predicciones

Luego de la estimación de los modelos, se procede a la generación de predicciones para el año 2015 y 2016. Como se menciona al principio de este capítulo, para la generación de las predicciones solo se tomaron valores de variables que hubieran estado disponibles si es que se hubiese estado usando estos modelos, de manera de asemejarse lo más posible a la realidad. No obstante, las variables dummies de lluvias (distintas a las presentes en los tests de raíces unitarias de la sección 8.2.1) y de la corriente del niño toman valores observados reales ya que no se encontraron pronósticos de estas variables para estos dos años de predicciones.

Tal como se menciona en capítulo 5, debido a que la información sobre algunas variables usadas en el modelo está disponible aproximadamente entre el 10-15 de cada mes, para la estimación del modelo y la generación de predicciones se considera que cada período (1 mes, 3 meses y 6 meses) inicia el día 15 mes del actual (considerando como actual, el mes en que se realizan las predicciones a futuro). Es en cada uno de estos meses en que se hace la predicción, que se usa información que hubiera sido posible conseguir en ese momento, salvo como se mencionó anteriormente, los valores para los pronósticos de lluvias y la corriente del Niño.

Se aclara que lo único que cambiará en los modelos al usar los “datos fuera de la muestra” son los valores que toman las variables, pues los coeficientes se mantendrán estáticos durante todo el período de evaluación (2015 y 2016), permaneciendo iguales a los que se obtuvieron al calibrar cada modelo con los datos “dentro de la muestra”.

En la Figura 8.11 se tienen los resultados de los mejores modelos para cada materia prima en cada uno de los horizontes (1,3, y 6 meses) de acuerdo con las métricas usadas para evaluarlos; MAPE y RSME. El trigo muestra el menor MAPE entre todas las materias primas para los modelos a 1 y 3 meses, y de manera general, las cuales, si son ordenadas por MAPE, el trigo es primero, seguido por el maíz, y, por último, la soya (El precio de la soya está en dólares, y no en CLP como el trigo y maíz).

Con el MAPE es posible comparar los distintos períodos y materias primas ya que es una medición porcentual, en cambio el RSME es una medición numérica, con lo que, si el precio de una materia prima es mayor que otra, esta métrica suele ser mayor, por lo que solo se usa para comparar entre distintos períodos de una misma materia prima. Un ejemplo concreto de esto se da con la soya, cuyo precio está en dólares, por lo que se puede ver un RSME muy menor al resto, pero si se analiza el MAPE, en promedio absoluto se tiene un peor rendimiento que en el resto de las materias primas.



**Figura 8.11:** Métricas de ajuste de modelos VECM a 1,3, y 6 meses de las materias primas estudiadas.

Trigo			
Métrica /Modelo	1 mes	3 meses	6 meses
RSME	7.391	12.151	18.233
MAPE (%)	3,17	6,1	7,64
MAE (%)	0,57	1,62	-6,9

Maíz			
Métrica /Modelo	1 mes	3 meses	6 meses
RSME	8.908	10.782	9.705
MAPE (%)	5,38	6,78	5,42
MAE (%)	4,4	4,88	-2,7

Soya			
Métrica /Modelo	1 mes	3 meses	6 meses
RSME	16,0	36,5	44,6
MAPE (%)	3,92	8,5	9,58
MAE (%)	3,92	-3,87	-1,98

*Fuente: Elaboración propia en base a registros de COTRISA.*


En general, se tienen errores absolutos (MAPE) menores al 10%, siendo los modelos más cercanos a este valor los que predicen el precio de la soya a 3 y 6 meses. Para el resto de las materias primas el mayor valor está entorno al 7%.

Cabe destacar, que no necesariamente al aumentar el plazo de predicción aumenta el RSME o el MAPE, puesto que cuando se usa un modelo que considera un mayor plazo de predicción los valores tienden a dibujar una curva que se va haciendo cada vez más recta y puede que ocurra que en promedio está más cerca que otro modelo, pero tiene menor capacidad para capturar las variaciones.

Para un análisis más detallado de las predicciones, se presentan las Figuras 8.12 a 8.14, donde se muestra predicción realizada por el mejor modelo de cada materia prima a un plazo de 3 meses (Los demás períodos están en Anexos Imágenes 58-63).


Al analizar detenidamente los gráficos (Figura 8.12 a 8.14) se puede dar cuenta de que el precio que se está prediciendo está bastante cerca de los precios reales, pero en algunos casos los modelos quedan desfasados, ocurriendo esto en momentos en que las tendencias al alza o baja se invierten. Lo más importante con respecto a las predicciones es capturar las tendencias de los precios, más allá de los valores exactos, ya que las predicciones se usarán para planificar las compras trimestral o semestralmente, en base a las diferencias existentes entre los precios proyectados para los meses que conforman cada período.

**Figura 8.12:** Gráfico de predicción del precio promedio mensual del trigo en Chile (en CLP) en base a modelo de predicción a 3 meses.




Fuente: Elaboración propia en base a registros de COTRISA.

**Figura 8.13:** Gráfico de predicción del precio promedio mensual del maíz en Chile (en CLP) en base a modelo de predicción a 3 meses.



Fuente: Elaboración propia en base a registros de COTRISA.

**Figura 8.14:** Gráfico de predicción del precio promedio mensual internacional de la soya (en USD) en base a modelo de predicción a 3 meses.



Fuente: *Elaboración propia en base a registros de INDEXMUNDI.*

Siguiendo lo expuesto anteriormente, se puede ver que los modelos no son capaces de anticipar todos los cambios en los precios. No obstante, claramente se logra capturar una parte importante del comportamiento futuro, y en algunos casos, describiendo de forma muy similar la trayectoria de los precios. A su vez, se debe considerar que la información usada para predecir está atrasada con respecto al mes que se predice (esto porque a modo de ejemplo, cuando se predice abril se está en marzo, y parte de la información es del mes de febrero).

Mediante inspección visual los mejores modelos son el trigo y el maíz. La soya también está cerca del precio real, pero muestra menor capacidad de predecir las tendencias, a modo general, lo que se condice con los resultados presentados en la Figura 8.11.

En Anexos Imágenes 64-66 se puede observar el valor de cada predicción y el valor real. El modelo a un mes es el con menor error en todas las métricas (Figura 8.11). Predicciones a más largo plazo tienden a tener menor capacidad predictiva, lo que se evidencia en las métricas. Por su parte, se recuerda que, si bien el modelo a 6 meses tiene mejores resultados que el a 3 meses, esto no significa que mes a mes sea mejor, pues el modelo arroja resultados más similares a una recta, por lo que en promedio podría estar más cerca pero no necesariamente explica mejor la dinámica del proceso.

## 8.3 Resultados del modelo de Regresión Lineal

### 8.3.1 Estimación

Tal como se detalla al principio de este capítulo (8.1), en esta sección se presentan los resultados de las estimaciones, poniendo énfasis en los coeficientes obtenidos y no en los tests usados, (el resultado final de la estimación de cada regresión se puede observar en Anexos Imágenes 67-69) debido a que el foco está en revisar las variables más importantes a modo de guía práctica, siendo estas variables las que se usaron para los modelos VECM (Modelo de Vector de Corrección de Errores).

En este caso, no se diferenciaron las regresiones por períodos pues no utilizan varios rezagos para cada variable en una misma regresión, sino que solo se incluye un valor por cada una, el cual está retrasado con respecto a la variable dependiente, como se detalla al final de la sección 7.2.

#### Estimación trigo:

En la Figura 8.15, se puede observar las variables que resultaron significativas para estimar la diferencia que se produce en cada periodo entre el precio del trigo con respecto a su valor en el período anterior.

El cambio de impuestos a las exportaciones en Argentina los redujo (los impuestos a las exportaciones) por lo que es esperable un signo negativo, ya que los productos del mercado argentino compiten con el chileno, y al ser commodities existe poca distinción entre productos (se puede distinguir por calidad y aporte nutricional), forzando a la baja el precio en el mercado local.

**Figura 8.15:** Coeficientes de variables más significativas para determinar la variación mensual del precio del trigo con respecto al período anterior.

Diferencia con precio del trigo en mes anterior	
Constante	-1,52
Cambios impuestos Argentina	-0,17
Promedio mensual dólar en Chile	0,15
Promedio mensual futuro de trigo	0,14
Ratio de stock final vs oferta en USA	0,03
LOG(ABS(Indice corriente del niño))	0,02

*Fuente: Elaboración propia.*

El dólar influye el precio debido a que alrededor del 40% del trigo consumido en Chile es importado (sección 1.2.1) por lo tanto se importa a mayor valor, y por tanto esto se traduce en precios más altos. Vale decir, que esta variable presenta el promedio del dólar observado sin rezagos, ya que para el período de predicción se usaron predicciones de expertos (Encuesta de expectativas

económicas del Banco Central). Esto se hizo para los modelos que usan futuros de las materias primas en vez del precio rezagado de la misma.

El precio promedio del futuro de trigo está calculado mediante una interpolación lineal, pues no existen futuros de trigo para todos los meses del año (sección 7.2, precios futuros de materias primas). El hecho de que cuando los futuros tienden a subir en los meses anteriores se relacionen con precios más altos en los precios siguientes se condice con la realidad, donde el precio de los futuros muestra tener alta correlación con los precios, si bien claramente pueden existir distorsiones en el mercado o cobros por riesgo.

En la variable que mide el ratio de stock final vs oferta de trigo en USA se tiene un signo no esperado, pues se esperaba que mientras mayor es el ratio existe menor demanda o mayor oferta, impulsando a la baja los precios, pero el signo positivo muestra lo contrario. Se cree que la razón del signo no esperado se debe al rezago con que se tienen los valores pues están retrasados en 2 meses en el caso del modelo a 1 mes, 4 meses para la predicción a 3 meses, y hasta 7 meses para la predicción a 6 meses. Con lo que cuando el ratio actual subió o bajó, el valor usado en el modelo aún no variaba y recién se notó esa variación cuando el precio ya había variado.

Para el índice de la corriente del niño, se probaron distintas transformaciones de la variable pues no se presentaba una relación lineal entre esta y el precio promedio mensual del trigo en Chile, resultando muy significativa el logaritmo del valor absoluto (se usa valor absoluto debido a que toma valores positivos y negativos), dando cuenta de que cuando este índice es lejano al cero (positivo o negativo) aumenta el precio. Un índice negativo se asocia con condiciones típicas de la corriente del Niño, es decir, mayores lluvias, y uno positivo con el fenómeno de la Niña, con efectos inversos. Se cree que más allá del signo, grandes valores generan mayor incertidumbre en el mercado de esta materia prima impulsando un alza en los precios por la mayor variabilidad que podrían presentar a futuro.

#### **Estimación maíz:**

En la Figura 8.16 se presentan las variables que resultaron significativas para estimar la diferencia que se produce en cada periodo en el precio del maíz con respecto al período anterior.

En el caso del maíz se puede observar que la estacionalidad (a diferencia del trigo) sí es una variable significativa, confirmando lo que se comenta en el capítulo 7 sobre las características estacionales de los precios de algunas materias primas agrícolas, por lo tanto para cada mes cuyo precio se intenta predecir se debe tomar en cuenta este factor, el cual en este caso corresponde a un índice base 100 que representa el promedio entre 2006 y 2014 de la relación entre el valor promedio de la materia prima en cada mes versus su valor en enero de cada año.

**Figura 8.16:** Coeficientes de variables más significativas para determinar la variación mensual del precio del maíz con respecto al período anterior.

Diferencia con precio del maíz en mes anterior	
Constante	1,86
Estacionalidad del maíz	0,48
Precio promedio del dólar (-2)	-0,29
Precio promedio maíz en Argentina (-2)	-0,10
Lluvia alta en abril	0,05

*Fuente: Elaboración propia.*

En este modelo la variable del dólar representa el valor del dólar rezagado en dos períodos, usando este mismo criterio para las predicciones. Se esperaba que el signo fuera positivo debido a que un alto valor del dólar aumenta el valor de las importaciones, y por ende el valor del producto en el mercado chileno. Esto mismo ocurre con el precio promedio del maíz en Argentina, que también presenta un rezago de dos meses y se esperaba un signo positivo. Se cree que la causa de esto es el retraso en las variables y que los precios no se ajustan automáticamente a los cambios, habiendo dinámicas temporales que no logran ser explicadas por medio de la regresión.

Por último, resulta ser significativa la variable que da cuenta de lluvias anormales (sobre dos desviaciones estándar del promedio de ese mes) en abril en la VI región. En abril se está en época de cosecha por lo que gran cantidad de lluvias podrían hacer este proceso más difícil complicando el uso de máquinas para la cosecha debido a la humedad del suelo, entre otros factores. Así, una cosecha más tardía o decididamente menor cantidad cosechada debiese aumentar los precios, lo cual es consistente con el signo positivo de la variable dummy de lluvias.

#### **Estimación soya:**

Al igual que con el maíz, en la Figura 8.17 se ve que la soya presenta estacionalidad significativa, siendo en este caso el coeficiente de esta variable mayor a uno por lo que el efecto en promedio en el precio es mayor a los valores del índice base 100 elaborado.

Con respecto a la variable que da cuenta del precio promedio del maíz en la Bolsa de Chicago de Estados Unidos, se tiene una relación positiva. El signo de este coeficiente es el esperado, ya que se ha documentado que la soya y el maíz poseen por lo general una correlación positiva donde el alza de alguno de estos productos provoca un alza en el otro.

La causa de lo anterior es que gran cantidad de agricultores deben decidir cada temporada si plantar maíz o soya, por lo que cuando el precio de alguno sube, aumenta el margen por tonelada vendida, haciéndola más atractiva, ya que el maíz y la soya son usados en gran medida para alimentación animal. Así, se

supone que más agricultores querrán plantar lo que a la postre aumentará la oferta y el mercado debería llevar esto a un equilibrio donde los márgenes de ambos productos sean similares en general, motivando que los precios mantengan una relación bastante estable durante el año.

**Figura 8.17:** Coeficientes de variables más significativas para determinar la variación mensual del precio de la soya con respecto al período anterior.

Diferencia con precio de la soya en mes anterior	
Constante	-1,55
Estacionalidad de la soya	1,11774
Precio promedio maíz internacional (-2)	0,08203
Stock final de la temporada en USA	0,04

*Fuente: Elaboración propia.*

En última instancia, al igual que en el trigo, ocurre que el stock estimado para el final de la temporada en USA tiene un signo no esperado (se esperaba negativo), a lo que se atribuye el hecho de que el valor de esta variable se conoce algunos meses después de su realización, por lo que al incluirla en el modelo muestra un comportamiento tardío donde el precio ya pudo haber subido o bajado, haciendo que el coeficiente de la variable tenga un signo distinto al esperado para la variable sin rezago.

### 8.3.2 Predicciones

A continuación, se presentan las predicciones realizadas usando modelos de regresión lineal con un período de predicción de 3 meses, mismo período que se muestra para el modelo VECM en la sección 8.3.1. (Los resultados de las predicciones a 1 y 6 meses están disponibles en gráficos en Anexos Imágenes 70-75 y en resultados numéricos en Anexos Imágenes 76-78).

De acuerdo con la Figura 8.18, la regresión lineal del trigo presenta los mejores resultados en términos de la métrica MAPE, incluso con menor error absoluto que el modelo VECM en 3 y 6 meses, lo cual está especialmente influenciado por los resultados en 2016, donde se puede observar en los gráficos de cada modelo a 3 meses en la materia prima del trigo, que la regresión presentó resultados bastante más cercanos a la realidad.

El maíz nuevamente se sitúa en una posición intermedia en cuanto al MAPE frente a los modelos de las demás materias primas. Y para esta materia prima, el modelo VECM mostró resultados superiores en MAPE y RSME en todos los períodos, salvo para la predicción a un mes, donde el MAPE y RSME fue ligeramente mayor en el VECM.

Como se mencionó anteriormente, mayor o menor MAPE y RSME no aseguran mejor predicción siempre, actúan como una referencia para evaluar los modelos, por lo tanto, no son 100% concluyentes. De todas formas, modelos que obtienen un MAPE o un RSME muy elevado suelen tener menor capacidad predictiva, como el caso de la regresión lineal de la soya, donde si se observa la Figura 8.21 se tiene que en pocas ocasiones pudo predecir la tendencia del precio internacional de la soya en la Bolsa de Chicago.

**Figura 8.18:** Métricas de ajuste de modelos de regresión lineal a 1,3, y 6 meses de las materias primas estudiadas.

Trigo			
Métrica /Modelo	1 mes	3 meses	6 meses
RSME	6.148	8.479	13.280
MAPE (%)	3,17	4,1	5,94

Maíz			
Métrica /Modelo	1 mes	3 meses	6 meses
RSME	7.245	11.732	19.585
MAPE (%)	4,53	7,01	10,92

Soya			
Métrica /Modelo	1 mes	3 meses	6 meses
RSME	34,6	63,3	86,9
MAPE (%)	8,4	14,16	20,41


*Fuente: Elaboración propia en base a registros de COTRISA.*

En línea con lo anterior, para la soya se tiene el modelo con el menor performance de acuerdo con las métricas usadas, con un MAPE entre 8 %y 20% en sus predicciones. Se cree que este modelo tiene difícil aplicación en la realidad debido a la poca precisión de sus predicciones, especialmente si se compara con el resto de los modelos usados en las otras materias primas.

Mediante una inspección gráfica de las Figuras 8.19 a 8.21 queda en evidencia lo expuesto en la Figura 8.16; el trigo presenta un gran ajuste a 3 meses, pudiendo predecir gran parte de las tendencias con exactitud. En cuanto al maíz se logra captar parte de las tendencias, pero existen períodos en que no se logra, como a partir de julio del año 2016. Y como se menciona antes para la soya, en muy pocos períodos se fue capaz de capturar las tendencias de los precios.




**Figura 8.19:** Gráfico de predicción del precio promedio mensual del trigo en Chile (en CLP) en base a modelo de predicción a 3 meses.




Fuente: Elaboración propia en base a registros de COTRISA.

**Figura 8.20:** Gráfico de predicción del precio promedio mensual del maíz en Chile (en CLP) en base a modelo de predicción a 3 meses.



Fuente: Elaboración propia en base a registros de COTRISA.

**Figura 8.21:** Gráfico de predicción del precio promedio mensual internacional de la soya (en USD) en base a modelo de predicción a 3 meses.



*Fuente: Elaboración propia en base a registros de INDEXMUNDI.*

Así, se puede concluir que en general las regresiones lineales mostrar un comportamiento similar, a veces mejor y a veces peor que el modelo de series de tiempo usado. En base a lo observado se puede decir que no necesariamente es mejor usar un VECM, no solo por presentar diferencias pequeñas con respecto de las regresiones, sino también por la complejidad de su implementación y uso frente a una regresión lineal, tal como se describe en la en el capítulo 5.

Se cree que hace falta un mayor horizonte de tiempo para hacer una conclusión definitiva al respecto, ya que los dos años usados para las predicciones podrían presentar situaciones particulares y no representar el comportamiento real de las materias primas. Con lo que se prefiere no descartar el uso del modelo VECM y usarlo de manera conjunta para poder tener un universo de datos más grande para comparar los modelos y comprobar los expuesto por la literatura, que muestra que los VECM suelen presentar un mejor performance que las regresiones lineales.


## 8.4 Programación de compras

### 8.4.1 Introducción

Una vez que ya se realizaron las estimaciones de precios con los modelos anteriormente presentados, se puede proceder a programar las compras en base a las diferencias de precios a lo largo del trimestre o semestre según corresponda, y comparar sus resultados contra distintas estrategias propuestas presentadas en la sección 8.4.2. Para predecir el afrechillo y triticale se usa el precio estimado del trigo como guía para evaluar su variación a lo largo de los meses, debido a que no se publican precios periódicamente de los primeros, y están muy relacionados con el trigo. Y para el maíz, se usa directamente el precio pronosticado para el maíz.

En la Figura 8.22 se puede ver el precio del afrechillo, triticale, y trigo en Chile en 2015 y 2016. Los precios del afrechillo y triticale equivalen a los precios pagados por IANSA en cada mes según sus registros, y el precio del trigo equivale al precio promedio mensual del trigo puesto en la región Metropolitana, como se describe en la sección 7.1. A partir de la Figura 8.22, se ve que el precio de ambos productos (afrechillo y triticale) sigue de manera bastante consistente la tendencia del trigo, si bien están a distintos niveles de precios.

**Figura 8.22:** Comparación de precio promedio mensual del trigo en Chile (en CLP) versus el precio pagado por las áreas de IANSA en afrechillo y triticale (en CLP).



Fuente: Elaboración propia en base a registros de IANSA y COTRISA.

Para este trabajo se tomará como demanda mensual, el promedio anual de toneladas registrado en las órdenes de compra de IANSA para cada uno de los insumos para los cuales se realizará la programación, es decir, si para el

afrechillo en Mascotas durante 2015 se registraron en total 120 mil toneladas al sumar las órdenes de compra de 2015 para ese insumo en esa área, para la programación de compras que realizará el modelo correspondiente, se tomará como que se necesitan 10 mil toneladas mensuales de producto para cubrir las necesidades de producción.

Los resultados de la programación de compras serán órdenes de compra recomendadas para satisfacer la demanda de producto, donde en cada una se negocia un precio y cantidad (En ocasiones para evitar repeticiones se habla de “compras”, esto se refiere a órdenes de compras). Los insumos negociados no son entregados inmediatamente, sino que en el próximo mes. Y en caso de que en la orden de compra se acuerde una cantidad para abastecer más de un mes, se entrega a principio de cada mes la cantidad necesaria para abastecer ese mes, cumpliendo los pagos esta misma condición, hasta que se ha entregado toda la carga que se pactó en la orden de compra.

Un aspecto muy relevante sobre la programación de compras es la temporalidad. Se usó una programación estática de la misma forma en que se realizaron las predicciones de los modelos. Esto significa que, para la programación de compras con un período de 3 meses, tengo los trimestres enero-marzo, abril-junio, julio-septiembre, octubre-diciembre, donde en el primer mes de cada uno se fijan las compras a realizar en cada mes de ese trimestre. Y, solo se puede pronosticar un período hacia adelante, por lo que no es posible predecir en este trabajo dos períodos de 3 meses hacia adelante y compararlos con un período de 6 meses.

También, si bien de secciones anteriores se puede notar que el modelo a 6 meses posee menor precisión que el modelo a 3 meses, podría ocurrir que los precios mantengan tendencias tales que se produzca un mayor ahorro a 6 meses. Un caso de esto es que ocurriera que el precio se mantiene al alza todo el segundo semestre, y el modelo a 6 meses logra captar esta tendencia, ocurriendo que recomiende comprar en el primer mes (más barato). En el fondo, esta ganancia en ahorros no estaría motivada por una mayor precisión (se muestra que a 6 meses es menor), sino por el hecho de existir un mayor horizonte de evaluación.

La manera de generar predicciones se puede explicar con el siguiente ejemplo, en el trimestre enero-marzo, desde el día 15 de diciembre (del año anterior, se define el día 15 como día en que se realizan las predicciones en el capítulo 5) se tienen las predicciones de precios para enero, febrero, y marzo, y se establecen las órdenes de compra para en enero, febrero, y marzo, para abastecer febrero, marzo, y abril. Esto supone que la cantidad de materias primas necesarias para abastecer enero fue fijada en diciembre, y no constituye parte de la programación del trimestre enero-marzo. Así, desde mediados del último mes del trimestre o semestre anterior según el modelo que se esté usando, se puede realizar el plan de compras.

En cada uno de estos meses en que se hace la predicción, se usa información que hubiera sido posible conseguir en ese momento, salvo como se mencionó anteriormente, los valores para los pronósticos de lluvias y la corriente del Niño.

Se aclara que lo único que cambiará en los modelos al usar los “datos fuera de la muestra” son los valores que toman las variables, pues los coeficientes se mantendrán estáticos durante todo el período de evaluación (2015 y 2016), permaneciendo iguales a los que se obtuvieron al calibrar cada modelo con los datos “dentro de la muestra”.

Una vez que se fijan las órdenes de compra (en el 1er mes de cada trimestre, o semestre si es programación a 6 meses plazo) permanecen así durante todo el semestre, por lo tanto, en la evaluación que se efectuará en la sección 8.4.3 no se considera la opción de corregir el plan de compras en el mes siguiente si es que los pronósticos de precios cambian.

Los planes de compras incluyen afrechillo y maíz para ambas áreas (Nutrición animal y Mascotas), y triticale solo para el área de Nutrición animal. Esto se debe a que las órdenes de compra de soya fueron por apenas 540 mil dólares en dos años (Figura 8.23), lo cual es muy inferior a las otras materias primas (5% de total de compras de las materias primas estudiadas), y a que el triticale en el caso de Mascotas se registraron órdenes de compra solo en un mes, no siendo posible generar una distribución que lo caracterice, y promediando entre 2015 y 2016 apenas 100 mil dólares en compras.

**Figura 8.23:** Valores promedio de órdenes de compra de cada insumo en el período 2015-2016.

Valores promedio de 2015 y 2016	Área	Nutrición Animal				Mascotas				Total
	Unidad	Afrechillo	Maíz	Triticale	Soya	Afrechillo	Maíz	Triticale	Soya	
Miles de Ton		25,1	10,2	12,9	0,1	6,5	8,8	0,7	1,2	65,5
Millones de USD		3,2	2,1	2,5	0,04	0,7	2,9	0,1	0,5	12,1

*Fuente: Elaboración propia en base a registros de IANSA.*

Existen ciertos supuestos y condiciones que fueron considerados al realizar la programación de compras:

- Lo que se acuerda a comprar en las órdenes de compra es posible de almacenar en bodegas de IANSA por lo que no se recurre al almacenamiento externo, además, la forma en que se negocian las compras suele incluir despachos mensuales o semanales de producto, con lo que basta tener capacidad de almacenamiento para ese período (la cual IANSA sí posee en ambas plantas (región Metropolitana y región de La Araucanía).
- Existe un plan de producción definido por el área de ventas (para la evaluación se toma como plan de producción los registros de órdenes de

- compra de cada área de IANSA).
- Existe un lead time de entrega de producto. No se usan semanas para la programación por lo que se supondrá que el proveedor siempre entrega la carga a principio del siguiente mes, no pagando almacenamiento extra en ese caso pues es considerado como lead time. Cuando la carga pasa a formar parte del stock pueden imputársele costos. Se usará el lead time para definir el stock de seguridad.
  - Se supondrá en el mes actual no existen quiebres de stock, es decir, el inventario inicial del mes actual es mayor o igual que la demanda de producción de ese mes.
  - Para el cálculo final del costo de la estrategia, se toma en cuenta el costo de capital de la empresa, pero no para comparar estrategias, debido a que siempre los pagos son realizados mes a mes de acuerdo a la demanda por materia prima desde las plantas, existiendo la misma demanda mensual en todas las estrategias y, por ende, el mismo inventario inmovilizado.
  - No se consideran diferencias o ajustes en los precios por establecer órdenes de compra para satisfacer 1 mes o varios meses (máximo 6), debido a que las condiciones son muy variables entre proveedores, dependiendo de la necesidad de capital de cada uno, cuanto insumo poseen actualmente, entre otros.
  - Una vez que se establece el plan de compras para un trimestre o semestre, no es posible cambiarlo en alguno de los meses siguientes.
  - Se considera como período de compra el trimestre o semestre (según corresponda) que se está prediciendo, pues es ese período en que se tiene certeza desde el punto de vista del modelo de los precios de las materias primas.

Debido a los supuestos y características del problema (no se arrienda almacenamiento externo, siempre se consideran pagos mensuales), la diferencia entre estrategias se basa en los precios pagados en cada mes por la materia prima, siendo esa la única posibilidad de ahorro de acuerdo con el modelo a resolver.

De esta forma, la manera en que se elige si comprar o no en un mes depende únicamente de si el precio del mes actual es más caro/barato que todos los anteriores y posteriores. En la sección 8.4.3 se observa la manera en que esto se realizó. Así, para el Afrechillo en el área Mascotas en el primer semestre de 2015 dado que los precios siempre fueron a la baja, nunca fue conveniente comprar para abastecer más que un mes. Pero, en octubre de ese año, el precio fue más bajo que en noviembre (175.216 CLP en octubre vs 175.380 CLP en noviembre), por lo que sí fue conveniente comprar con anticipación. No obstante, diciembre tuvo un menor precio que octubre (172.012 CLP en diciembre) por lo que no fue conveniente incluir el abastecimiento de diciembre en la compra de octubre.

En estricto rigor, hubiera sido más conveniente comprar todo al precio de diciembre pues fue el menor de todo este trimestre en esa materia prima, pero no se hubiera tenido el stock necesario para producir en octubre y noviembre por esperar la entrega de producto hasta enero (se entrega el primer día del mes siguiente al que se registra una orden de compra). Esta es una restricción necesaria para asegurar el abastecimiento de las plantas en este problema.

#### **8.4.2 Estrategias de compra usadas como escenario de comparación**

La última etapa consiste en comparar la programación de compras realizada en base a los modelos de predicción, frente a las 3 estrategias propuestas para el período 2015 y 2016; compras reales de IANSA en el período, compra mensual, y simulación de comportamiento de compras de IANSA.

La primera estrategia (compras reales de IANSA en el período) se refiere a las órdenes de compra que se registraron en las bases de datos de IANSA entre 2015 y 2016. Entonces, se compara el costo que realmente tuvo la empresa al abastecerse de productos, frente al costo que hubiera tenido si es que hubiera usado la programación de compras que se propone en este trabajo, comprando la misma cantidad de materias primas en cada año, tomando como cantidad necesaria para comprar cada mes, el promedio mensual de las órdenes de compra registradas en ese año como se menciona anteriormente, es decir, si en 2015 se registró un total de 120 mil toneladas de maíz en órdenes de compra, se toma que se necesitan 10 mil toneladas por mes. Por lo tanto, la compra no necesariamente es igual en cada mes, pero sí lo es al agregar de manera anual.

Es necesario considerar que para esta y las demás estrategias se utiliza como precio de mercado de las materias primas, el precio que está registrado en las órdenes de compra de IANSA en cada uno de los meses de 2015 y 2016. Así, el precio pronosticado por los modelos es usado para programar las compras, pero el precio que finalmente se considera como costo es el que pagó la empresa en ese mes pues refleja el costo real en el mercado, de manera de simular con la mayor precisión posible el escenario que enfrentaron los compradores de IANSA cuando realizaron las compras.

La estrategia de “compra mensual” refleja un escenario en que no existe ninguna anticipación en las compras por parte de la empresa, es decir, se compra solamente pensando en el próximo mes sin usar la experiencia o modelos para predecir precios, con lo que también se le llama “conservadora”. Para esto se usó como cantidad necesaria a comprar en cada mes, el promedio mensual de las órdenes de compra de cada año. Con lo que el plan de compras que sigue esta estrategia es igual en todos los meses de un mismo año. La idea de tomar este escenario es verificar si es que se está teniendo un ahorro realmente por anticiparse a los precios, y conocer su magnitud aproximada.

Y, como última estrategia a comparar se simula el comportamiento que han tenido los compradores de IANSA en los últimos años (2013 a 2016) al comprar cada uno de los insumos que se está evaluando. Esto se realizó ajustando las cantidades existentes en las órdenes de compra registradas a distribuciones estadísticas, una para cada insumo. Así, para el período 2015 y 2016 se simularon 1000 realizaciones aleatorias de cada distribución donde se tiene una cierta cantidad a comprar en cada mes y un precio (el que realmente pagó IANSA en ese mes).

Para comparar esta estrategia con la programación de compras obtenida en base a los modelos realizados en este trabajo, se calculó el promedio mensual de compras de cada año (un promedio para 2015 y otro para 2016), y se usó como cantidad necesaria a comprar para cada mes de 2015 y 2016, manteniendo la programación de compras, prácticamente lo mismo que se hizo anteriormente al tomar el promedio mensual de las órdenes de compra registradas en IANSA como cantidad necesaria en cada mes.

El fin de usar esta estrategia es extender lo revisado en la primera estrategia (compras reales de IANSA), para analizar si es que los resultados obtenidos se deben a condiciones particulares o si se pueden mantener de manera consistente al variar ciertos parámetros, como la cantidad establecida en las órdenes de compra en cada mes por los compradores de la empresa.

La programación de compras en base a los modelos se mantiene igual al comparar con cada estrategia, lo único que si se altera es la cantidad que se compra en toneladas de producto. En la figura 8.24 de la sección 8.4.3 se puede observar la programación de compras para períodos de 3 meses. Esta no indica la cantidad de insumo en toneladas que se debe comprar en cada mes, sino que los meses de medido que negociaré en cada mes, es decir, si es que en cierto mes compraré solo para el mes siguiente, o para los dos próximos debido a que luego el precio subirá, o no compraré debido a que a futuro bajará, entre otros casos posibles. Debido a lo anterior, la programación no se ve alterada al variar la cantidad mensual necesaria para cubrir la producción de las plantas de cada área entre estrategias.

La variación en las cantidades que se deben comprar cada mes se debe a que por ejemplo, en la primera estrategia (compras reales) se tiene un cierto promedio mensual de compras en cada año, que como ya se mencionó se usó como cantidad necesaria mensual a comprar. Pero, en la tercera estrategia al simular el comportamiento, la cantidad que se compró en cada mes y año varía respecto de los registrado en IANSA, ya que son simulaciones aleatorias del comportamiento.



### 8.4.3 Resultados

En la Figura 8.24 se puede observar el plan de compras a 3 meses recomendado por el modelo, donde el número en cada celda representa el número de meses por los que la orden de compra de ese mes cubrirá la demanda (por esa cantidad de meses se fija el precio con el proveedor), donde “nut” o “masc” hace referencia al área de Nutrición animal y Mascotas, respectivamente.

A modo de ejemplo, si en enero 2015 en el afrechillo apareciera un 2, significa que en enero se establece una orden de compra cuya cantidad satisface la demanda de 2 meses siguientes, es decir, febrero y marzo. Además, las entregas de producto y los pagos se harían efectivos a principios de cada uno de esos meses. En el caso de la programación a 6 meses, el plan de compras se encuentra en Anexos Imagen 79.

**Figura 8.24:** Plan de compras a 3 meses recomendado por los modelos en base a predicciones de precios.


Programación de compras					
Mes	Afrechillo Masc	Maiz Masc	Afrechillo Nut	Maiz Nut	Triticale Nut
ene-15	1	2	1	2	1
feb-15	1	-	1	-	1
mar-15	1	1	1	1	1
abr-15	1	2	1	2	1
may-15	1	-	1	-	1
jun-15	1	1	1	1	1
jul-15	1	3	1	3	1
ago-15	2	-	2	-	2
sept-15	-	-	-	-	-
oct-15	2	1	2	1	2
nov-15	-	2	-	2	-
dic-15	1	-	1	-	1
ene-16	2	1	2	1	2
feb-16	-	1	-	1	-
mar-16	1	1	1	1	1
abr-16	1	1	1	1	1
may-16	1	1	1	1	1
jun-16	1	1	1	1	1
jul-16	1	1	1	1	1
ago-16	1	1	1	1	1
sept-16	1	1	1	1	1
oct-16	1	1	1	1	1
nov-16	1	1	1	1	1
dic-16	1	1	1	1	1

*Fuente: Elaboración propia.*

El hecho de que en algún mes se recomiende establecer una orden de compra por la cantidad necesaria para satisfacer los próximos 3 meses, o para los próximos 2, o cualquier combinación que se presente, se debe a los pronósticos de los modelos del trigo y el maíz (Figura 8.25 y 8.26). Por ejemplo, si se predicen alzas durante todo el trimestre (o semestre si es modelo a 6 meses),

se recomendará comprar toda la materia prima necesaria para el período en estudio en el primer mes, pues será en este mes donde se encuentre el precio más bajo.

**Figura 8.25:** Gráfico de predicción del precio promedio mensual del trigo en Chile (en CLP) en base a modelo de predicción a 3 meses.




Fuente: Elaboración propia en base a registros de COTRISA.

En el caso del trigo, en la mayoría de los meses el precio va a la baja (Figura 8.25). Aunque, a veces se presentan alzas, las que se reflejan en el plan de compras, como las que ocurrieron en los meses posteriores (dentro de su mismo trimestre) a agosto 2015, octubre 2015, y enero 2016. Cabe recordar que las órdenes de compra abastecen los períodos enero-marzo, abril-junio, julio-septiembre, y octubre-diciembre.

Es por esto que en junio y septiembre de 2016 (meses previos a alzas según línea azul) no se recomienda comprar para varios meses, ya que el alza en los meses siguientes corresponde a predicciones realizadas para otros trimestres, con lo que no alcanza a ser tomado en cuenta (julio y octubre 2016).

**Figura 8.26:** Gráfico de predicción del precio promedio mensual del maíz en Chile (en CLP) en base a modelo de predicción a 3 meses.



Fuente: Elaboración propia en base a registros de COTRISA.

Con el maíz ocurre lo mismo (Figura 8.26), con la salvedad de que en este modelo se recomienda establecer órdenes de compra por hasta 3 meses (Julio 2015). Esto se explica por la sostenida alza que tuvo el maíz en este período.

### Comparación con órdenes de compra reales:

A partir del plan de compras presentado en la Figura 8.24, se compara el costo pagado por IANSA versus el costo que se hubiera obtenido con el plan de compras propuesto. Esto se puede observar en las Figuras 8.27 y 8.28, que muestran los resultados a 3 y 6 meses.

**Figura 8.27:** Comparación de costos de órdenes de compra (en MM CLP) en base a plan de compras a 3 meses recomendado por los modelos y órdenes de compra reales de IANSA entre 2015 y 2016.

Escenario	Mascotas		Nutrición Animal		
	Afrechillo (MM)	Maíz (MM)	Afrechillo (MM)	Triticale (MM)	Maíz (MM)
Simulado (MM)	985	3.811	4.275	3.401	2.910
Real (MM)	984	3.834	4.292	3.308	2.806
Ahorro individual (MM)	-1,3	23,2	17,5	-92,3	-104,1
Ahorro individual (%)	-0,1%	0,6%	0,4%	-2,8%	-3,7%
Ahorro (MM)	-157				
Ahorro (%)	-1,02%				

*Fuente: Elaboración propia en base a registros de IANSA.*

Se puede observar que en Mascotas el maíz, y en Nutrición animal el afrechillo son las materias primas en que se obtienen ahorros frente a la situación actual (en verde). Por su parte, el maíz y el triticale son aquellos que tienen mayores pérdidas, con lo que, si se aplica este plan, se produce un resultado negativo.

**Figura 8.28:** Comparación de costos de órdenes de compra (en MM CLP) en base a plan de compras a 6 meses recomendado por los modelos y órdenes de compra reales de IANSA entre 2015 y 2016.

Escenario	Mascotas		Nutrición Animal		
	Afrechillo (MM)	Maíz (MM)	Afrechillo (MM)	Triticale (MM)	Maíz (MM)
Simulado (MM)	974	3.761	4.249	3.379	2.873
Real (MM)	984	3.834	4.292	3.308	2.806
Ahorro individual (MM)	10,4	73,1	43,2	-71,1	-66,8
Ahorro individual (%)	1,1%	1,9%	1,0%	-2,1%	-2,4%
Ahorro (MM)	-11				
Ahorro (%)	-0,07%				

*Fuente: Elaboración propia en base a registros de IANSA.*

En la Figura 8.28, que muestra la comparación del plan de compras a 6 meses se tienen similares resultados, con la salvedad de que tienden a aumentar, lo que se ve reflejado en que el resultado total pasa de unos -150 a -11 MM CLP. El mayor ahorro se produce en el maíz de la unidad de Mascotas, con 23 y 73 millones, respectivamente, seguido del afrechillo de la unidad de Nutrición animal (en verde las materias primas que presentan ahorros). En las demás materias primas el ahorro es menos significativo o negativo, en el caso del triticale y maíz de Nutrición animal.

Con esos resultados se puede tener luces de las materias primas con las que se podría seguir las recomendaciones del plan de compras propuesta, y las con que por el momento no sería beneficioso, ya que no es obligatorio su uso para todos los insumos. Siendo el maíz en Mascotas, la materia prima candidata con mayores preferencias para seguir el plan recomendado. Y por otro lado, el triticale en Nutrición animal es el insumo menos recomendado para su uso (del plan de compras).

### Comparación con estrategia mensual:

En segundo lugar, se procede a comparar el plan de compras propuesto con la estrategia de “compra mensual”, la cual implica que solo se compran insumos para el próximo mes, sin que sea posible anticipar alzas de precios al establecer órdenes de compra para más de un mes. Debido a que se quiere probar si es que es posible generar ahorros al negociar con los proveedores para establecer órdenes de compra para varios meses de demanda, es relevante que al menos se pueda obtener algún ahorro frente a esta estrategia “conservadora”. No obstante, pudiese ocurrir que no existiera tal ahorro en alguna materia prima debido al comportamiento de precios, por ejemplo, si el precio ha estado constantemente a la baja nunca sería conveniente llegar a un acuerdo donde se fija a pagar por un determinado insumo por cierto número de meses.

En la Figura 8.29 se muestra la comparación entre el plan de compras propuesto por el modelo de cada materia prima, y la estrategia conservadora para un período de abastecimiento de 3 meses. Los cuadros en verde muestran ahorros de costos, los rojos sobrecostos, y los que vacíos muestran que ese trimestre el plan de compras propuesto siguió una estrategia de órdenes de compra mensual, es decir, el mismo comportamiento que la estrategia “conservadora”.

**Figura 8.29:** Comparación de costos de órdenes de compra (en MM CLP) en base a plan de compras a 3 meses recomendado por los modelos y estrategia conservadora entre 2015 y 2016.

Trimestre / MP	Afrechillo Masc (MM)	Maiz Masc (MM)	Afrechillo Nut (MM)	Maiz Nut (MM)	Triticale Nut (MM)
1	-	15,2	-	0,8	-
2	-	-1,9	-	2,5	-
3	-3,4	50,5	-6,7	3,0	-29,5
4	-5,7	0,8	-20,1	-1,7	5,9
5	-2,6	-0,0	1,2	-	2,4
6	-	-	-	-	-
7	-	-	-	-	-
8	-	-	-	-	-
<b>Total (MM)</b>	<b>-11,6</b>	<b>64,7</b>	<b>-25,7</b>	<b>4,7</b>	<b>-21,2</b>
<b>Total (%)</b>	<b>-1,2%</b>	<b>1,7%</b>	<b>-0,6%</b>	<b>0,2%</b>	<b>-0,6%</b>

Fuente: Elaboración propia en base a registros de IANSA.

Se observa que en el caso del maíz en Mascotas (“Masc”) y Nutrición animal (“Nut”) se tienen ahorros, siendo el mayor ahorro para el área Mascotas, con 65 MM CLP aproximadamente y un ahorro de casi el 2% del costo de compras de maíz. También, para ambas áreas se tienen sobrecostos en el caso del afrechillo (y triticale para Nutrición animal), siendo mayor en Nutrición animal con 26 MM CLP aproximadamente. En términos totales, la aplicación de este plan de compras a todas las materias primas tiene beneficios por alrededor de 11 MM CLP, siendo el maíz la principal fuente de ahorros.

**Figura 8.30:** Comparación de decisiones de órdenes de compra (en MM CLP) tomadas en el mes 1 de cada trimestre por el plan de compras recomendado entre 2015 y 2016.

Estrategia en mes 1	Cantidad	Beneficios (MM)	Maiz (MM)	Afrechillo (MM)	Triticale (MM)
Orden de compra por 3 meses	2	53,5	53,5	0	0
Orden de compra por 2 meses	10	-2,1	16,7	-27,2	8,3
Orden de compra por 1 mes con anticipación en mes 2	6	-40,5	-0,9	-10,2	-29,5

*Fuente: Elaboración propia.*

Para evaluar con mayor detalle el rendimiento del plan de compras propuesto, se muestra la Figura 8.30. En la columna “Estrategia en mes 1” se muestran las distintas decisiones que se pueden tomar en el primer mes del trimestre, recordando que una vez que se establece el plan de compras, no es posible cambiarlo en los próximos meses del trimestre (en este trabajo).

Es posible hacer una orden de compra en el primer mes para satisfacer todos los meses, hacer una orden de compra en el primer mes para satisfacer los dos primeros meses (y en los meses posteriores una por el resto), y hacer una orden de compra solo para el primer mes (considerando que en el segundo mes existe anticipación, es decir, en el segundo mes se compra para satisfacer 2 meses, de lo contrario sería una estrategia conservadora y no habría diferencias en costos).

Esto implica distintos niveles de riesgo, ya que si se llega a un acuerdo por un precio en el primer mes para satisfacer los 3 siguientes, puede que el precio luego suba y tenga un gran ahorro, o puede que baje y tenga sobrecostos. El riesgo es mayor si se fija el primer el precio de los 3 siguientes, que si se fija cada mes pues de la primera forma si es que el precio baja arrastra pérdidas durante todo el semestre.

Dicho lo anterior, en la Figura 8.30 se tiene que, fijar el precio en el primer mes para todo el trimestre (acuerdo a 3 meses), generó las mayores ganancias dentro del plan, con alrededor de 50 MM CLP. Y en el otro extremo, la estrategia en la cual en el primer mes se fija un solo mes y luego en el siguiente se fijan los dos restantes (última fila) tuvo las mayores pérdidas, con unos 40 MM CLP aproximadamente.

En la Figura 8.31 se muestra el mismo ejercicio anterior, pero para una programación de órdenes de compra semestral, es decir, en enero o julio de cada año (primer mes de cada semestre) se fijan las órdenes de compra para el resto del período sin posibilidad de cambios. Para 6 meses, ocurrió que el plan de compras para los subproductos del trigo (afrechillo y triticale) tuvo un comportamiento idéntico a la estrategia conservadora, por esto no se incluye en la Figura 8.31 ni en el análisis, ya que los costos fueron los mismos.

**Figura 8.31:** Comparación de costos de órdenes de compra (en MM CLP) en base a plan de compras a 6 meses recomendado por los modelos y estrategia conservadora entre 2015 y 2016.

Semestre / MP	Maiz Masc (MM)	Maiz Nut (MM)
1	11,8	-1,0
2	116,5	29,2
3	-22,1	-15,4
4	8,4	29,2
<b>Total (MM)</b>	<b>114,6</b>	<b>42,0</b>
<b>Total (%)</b>	<b>3,0%</b>	<b>1,4%</b>

*Fuente: Elaboración propia en base a registros de IANSA.*

Al igual que lo ocurrido en la programación a 3 meses, en la programación a 6 meses se observan importantes beneficios para el maíz en ambas áreas, obteniendo un beneficio total de unos 155 MM CLP aproximadamente. Una de las razones en los resultados del maíz, es que (como se vio en la sección 7.2) tiene estacionalidad. En 2015 y 2016, julio fue uno de los meses con menores precios en el segundo semestre de cada año, por lo que hubo gran conveniencia en fijar precios para todo el semestre, siendo más conveniente aún que fijarlos por solo 3 meses.

**Figura 8.32:** Comparación de decisiones de órdenes de compra (en MM CLP) tomadas en el mes 1 de cada semestre por el plan de compras recomendado entre 2015 y 2016.

Estrategia en mes 1	Cantidad	Beneficios (MM)
Orden de compra por 6 meses	4	183,4
Orden de compra por 5 meses	0	0
Orden de compra por 4 meses	2	-37,5
Orden de compra por 3 meses	0	0
Orden de compra por 2 meses	2	10,8
Orden de compra por 1 mes con anticipación en otro mes	0	0

*Fuente: Elaboración propia.*

Lo anterior se refleja en la Figura 8.32 donde la estrategia en la que en el mes 1 se establece una orden de compra para los 6 meses del semestre tuvo los mayores beneficios, unos 180 MM CLP.

Como se pudo ver en ambas programaciones, no es claro que el uso de modelos de predicción de precios para establecer un programa de compras genera ahorros en todas las materias primas. Esto depende de la precisión del modelo

y de factores como el comportamiento del precio durante del período analizado, y la estacionalidad del producto.

### Comparación con simulaciones de comportamiento de órdenes de compra reales:

La última parte de la evaluación del plan de compras para el maíz, afrechillo, y triticale propuesto por los modelos creados, consiste en compararlo con simulaciones de órdenes de compra obtenidas en base a distribuciones ajustadas de acuerdo con las compras entre 2013 y 2016 de cada materia prima, de manera de recrear el comportamiento de los compradores.

El fin de esto es evaluar si es que los beneficios obtenidos son un hecho aislado, y cambios en las cantidades fijadas en las órdenes de compra por parte de los compradores hubieran hecho que estos sean muy mínimos, o derechamente inexistentes, o es una modalidad que puede ser capaz de mostrar resultados favorables de manera consistente.

Así, la primera etapa consistió en ajustar las órdenes de compra registradas (2013-2016) a distribuciones estadísticas conocidas, cuyos detalles de se pueden encontrar en la Figura 8.33. En ella se muestra la distribución a la que se ajustó, y luego los parámetros de cada una.

Para casi todas materias primas se tuvo meses que en que no se registraron órdenes de compra (se hizo órdenes de compra por una cantidad mayor a la demanda del mes siguiente o no se necesitó más inventario que el existente en la planta) por lo que la distribución no tiene mínimo (un mínimo mayor a cero, la distribución por defecto toma como recorrido valores mayores a cero). Afrechillo en Nutrición animal tuvo órdenes de compra todos los meses, por lo que se estableció como nivel mínimo el mes con la orden de compras por menor cantidad en toneladas.

**Figura 8.33:** Distribuciones ajustadas para cada insumo según el comportamiento de las órdenes de compra registradas entre 2013-2016 de cada materia prima.

Parámetros de ajuste /Materia Prima	Afrechillo Mascotas	Maiz Mascotas	Afrechillo Nut Animal	Maiz Nut Animal	Triticale Nut Animal
Distribución	Beta	Beta	Beta	Beta	Beta
Alfa 1	1,72	1,11	1,36	0,90	0,51
Alfa 2	2,12	1,93	3,21	3,75	1,79
a	-	-	840	-	-
b	1.050	3.200	5.023	8.060	11.063

*Fuente: Elaboración propia en base a registros de IANSA.*

En base a la Figura 8.33 se realizaron mil simulaciones de órdenes de compra para cada una de las materias primas, tomando valores aleatorios dentro de cada una de las distribuciones de probabilidad. Para cada una se calculó el promedio de la cantidad establecida en las órdenes de compra en 2015 y 2016, y este se tomó como demanda mensual para el plan de compras propuesto, el cual es idéntico al de las secciones anteriores, salvo que varía la cantidad que se debe comprar cada mes según el promedio anual de cada simulación.

Posteriormente, se calculó la diferencia promedio entre el costo total de las órdenes de compra de cada simulación frente a las recomendadas por el plan de compras propuesto, para cada insumo en cada una de las mil simulaciones. También se pudo obtener la probabilidad de que el costo del plan de compras sea menor que la simulación correspondiente, lo cual se muestra en las Figuras 8.34 y 8.35, junto a los beneficios o pérdidas para cada insumo.

**Figura 8.34:** Comparación entre costos (en MM CLP) de plan de compras a 3 meses recomendado y simulaciones del comportamiento de IANSA entre 2015 y 2016.

ÁREA	MASCOTAS		NUT ANIMAL			Total
	AFRECHILLO	MAIZ	AFRECHILLO	MAIZ	TRITICALE	
MP						
Probabilidad de reducir costo	12%	97%	7%	53%	34%	40%
Ahorro promedio (MM)	-11,0	57,6	-29,2	4,6	-29,5	-7,5
Ahorro promedio (%)	-1,3%	1,5%	-0,6%	0,1%	-0,4%	-0,7%

*Fuente: Elaboración propia en base a registros de IANSA.*

**Figura 8.35:** Comparación entre costos (en MM CLP) de plan de compras a 3 meses recomendado y simulaciones del comportamiento de IANSA entre 2015 y 2016.

ÁREA	MASCOTAS		NUT ANIMAL			Total
	AFRECHILLO	MAIZ	AFRECHILLO	MAIZ	TRITICALE	
MP						
Probabilidad de reducir costo	50%	100%	50%	91%	47%	68%
Ahorro promedio (MM)	0,2	101,6	-0,5	85,0	-1,8	184,6
Ahorro promedio (%)	0,0%	2,6%	0,0%	1,6%	0,0%	0,8%

*Fuente: Elaboración propia en base a registros de IANSA.*

En ambas tablas se puede notar que el maíz en Mascotas y Nutrición animal presenta ahorros, siendo mayor el que se refiere a Mascotas. En el caso del afrechillo y el triticale, en general o se observan pérdidas (Figura 8.34), o beneficios muy pequeños (Figura 8.35). Esto sigue la tendencia mostrada en las evaluaciones anteriores, donde el maíz se posicionó como la fuente más importante de cara a posibles ahorros.

Se destaca que el maíz presenta muy altas probabilidades de ahorro, llegando al 100% en el caso de Mascotas y 91% en Nutrición animal (Figura 8.35), incrementándose de manera notable las probabilidades de ahorro en Nutrición animal con respecto al plan a 3 meses, desde 53% a 91%.

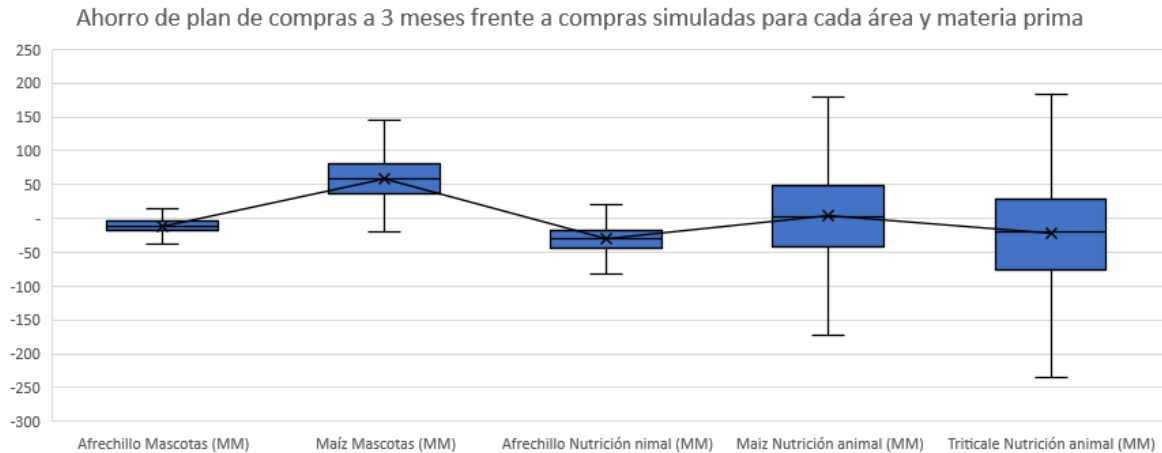
Para una mejor visualización de los resultados, en las Figuras 8.36 y 8.37 estos se muestran en la forma gráficos de caja y bigotes. Dentro de las cajas azules se ubican los datos entre el cuartil 2 y 3, es decir, sus miembros se ubican en un intervalo con el valor que cumple con ser mayor al 25% del universo, como límite inferior, y con el valor que cumple con ser mayor al 75% del universo como límite superior.

Sobre las cajas se ubican las realizaciones con resultados superiores al 75% del universo total, y bajo ellas las realizaciones con resultados menores al 75% del



universo de resultados. Y, por último, cada punto de la línea negra representa el promedio de las mil simulaciones para cada área y materia prima.

**Figura 8.36:** Beneficios o pérdidas (en MM CLP) obtenidas al comparar el plan de compras propuesto a 3 meses frente las simulaciones de órdenes de compra de IANSA. Las cajas azules representan los valores entre el segundo y tercer cuartil, y la línea negra el promedio de cada insumo.




*Fuente: Elaboración propia en base a registros de IANSA.*

En el primer gráfico se tiene que la mayoría de las realizaciones de compras de maíz en Mascotas tuvo ahorros frente a la simulación de compras de IANSA, reflejándose la alta probabilidad de ahorro que se obtuvo en la Figura 8.34, teniendo un promedio de alrededor de 60 MM CLP en ahorro. En tanto, el resto tuvo una media cercana a cero, estando el afrechillo en cada área bajo el cero en promedio, con algunas realizaciones con resultados positivos.

En el área de Nutrición animal, el maíz y triticale si bien tuvieron promedios de ahorro en torno a cero, tienen una gran dispersión, estando sus valores entre los 175 MM CLP y -170 MM CLP para el maíz, y 190 MM CLP y -240 MM CLP para el triticale.

**Figura 8.37:** Beneficios o pérdidas (en MM CLP) obtenidas al comparar el plan de compras propuesto a 6 meses frente las simulaciones de órdenes de compra de IANSA. Las cajas azules representan los valores entre el segundo y tercer cuartil, y la línea negra el promedio de cada insumo.



*Fuente: Elaboración propia en base a registros de IANSA.*

Para el plan de compras a 6 meses, como se pudo observar en la Figura 8.35, mejoran los resultados en todas las materias primas, teniendo importantes ahorros en maíz, especialmente en Mascotas. En este caso todas sus realizaciones fueron positivas, concentrándose fuertemente los resultados entorno a los 100 MM CLP.

El afrechillo en ambas áreas muestra resultados cercanos a cero, con muy poca dispersión entre realizaciones. Y al igual que en el gráfico del plan a 3 meses, el maíz y triticale en Nutrición animal presentan las mayores dispersiones, aumentando en este caso el maíz sus resultados con ahorros cercanos a los 70 MM CLP.

En base a este análisis se puede concluir que los beneficios obtenidos no se presentan en escenarios aislados, sino que de manera consistente al compararlos con distintas formas de establecer órdenes de compra para la compra de productos; compras reales de IANSA, compra mensual (“conservadora”), y simulación del comportamiento de las compras de IANSA.

También, la materia prima que presentó las mayores posibilidades de ahorro fue el maíz, especialmente en el área de Mascotas, donde se tienen reducciones que llegan hasta alrededor de 73 MM CLP en comparación con compras reales, 115 MM CLP frente a la compra “conservadora”, y 100 MM CLP en las simulaciones.

## 8.5 Síntesis

Las predicciones mensuales de precios obtenidas de los modelos para el período comprendido entre 2015 y 2016 muestran que en general se logra un nivel de predicción bastante cercano a la realidad que se está modelando. Un indicador de esto es el MAPE (Error absoluto porcentual promedio), el cual en todos los modelos en que se usó la técnica VECM (Modelo de vector de corrección de errores) tuvo un valor menor al 10%, y los gráficos de los valores pronosticados muestran en gran parte de los casos la capacidad de seguir las tendencias de los precios de las materias primas estudiadas.

Las regresiones por su parte presentan resultados variados, llegando a tener menor error absoluto (MAPE) que el modelo VECM en el caso del trigo, y mayores errores para el maíz y la soya. No obstante, los resultados no suelen estar muy lejos entre ambos modelos. Una de las ventajas del uso de regresiones es que permiten interpretar los coeficientes de sus variables, con lo que se pudo conocer cómo influye cada una en el precio, y revisar fácilmente cuales son las más significativas.

En ambos tipos de modelos, el trigo fue la materia prima con el menor MAPE, seguido del maíz, y, por último, la soya (El precio de la soya está en USD, y no en CLP como el trigo y maíz). La evaluación de los modelos se hizo no solo en base al MAPE, sino que también en base a RSME (Raíz del Error cuadrático medio). Para comparar entre modelos de una misma materia prima se usaron ambos indicadores, pero para comparar entre materias primas se usó solo el MAPE, pues los valores del RSME tienden a aumentar si es que se calcula para una materia prima cuyo precio es alto, como la soya. En cambio, el MAPE es un indicador porcentual, haciendo que no se tenga ese problema si es que se usa para comparar materias primas distintas.

Los coeficientes no siempre tuvieron el signo esperado, lo cual se cree es debido a que dado que se usó información que realmente hubiese estado disponible al momento de predecir los precios, los valores de algunas variables independientes están rezagados, por lo que cuando se calculan los coeficientes, el precio de la materia prima que se está prediciendo pudo ya haber cambiado y así alterar la relación.

Las variables que más se repitieron como variables significativas fueron el stock final estimado para fin de año en USA, el valor del dólar, la estacionalidad de la materia prima, y el precio internacional de la materia prima que se está intentando predecir, en la Bolsa de Chicago en Estados Unidos.

Por último, se procede a realizar de programación de compras donde en base a las predicciones de precios de trigo y maíz para plazos de 3 y 6 meses se hacen distintos planes de compras para cada insumo en las áreas Nutrición animal y Mascotas.

En la programación no se incluyó la soya en ninguna de las áreas, ni el triticale en el caso de Mascotas, debido a que en la soya el monto registrado en las órdenes de compra en 2015 y 2016 es muy bajo respecto de los otros insumos, dejando muy poco margen para posibles ahorros. Y en el triticale, solo se registró una orden de compra, por lo que se tienen muy pocos puntos para establecer una comparación robusta.

Se recuerda que el resultado de la programación es un plan de compras trimestral y semestral, que establece cuántos meses de demanda se deben acordar en cada orden de compra en cada mes entre 2015 y 2016 para cada insumo incluido en ese plan. A modo de ejemplo, si en enero el plan de compras tiene un valor de 2, significa que en enero se debe negociar una orden de compra con el proveedor por una cantidad en toneladas equivalente a la demanda de los próximos dos meses, pagando por la entrega de materia prima en esos dos meses el precio que se negoció en enero.

Los resultados de el plan de compras recomendado fueron evaluados de 3 formas distintas durante el período 2015 y 2016; comparando con el costo real de las órdenes de compra acordadas por IANSA, comparando con una estrategia donde todos los meses se negocian órdenes de compra para satisfacer solamente la cantidad necesaria para el próximo mes, y comparando con simulaciones del comportamiento de los compradores de IANSA en base a distribuciones estadísticas ajustadas a los registros de órdenes de compra entre 2013 y 2016.

De las evaluaciones, se concluye que el maíz es la materia prima con mayores posibilidades de ahorro según los precios observados durante 2015 y 2016, que el plan de compras a 6 meses alcanza los mayores beneficios, y que el área con mayores posibilidades de ahorro es Mascotas, llegando a los 70 MM CLP en total en el período 2015 y 2016.

Cuando se revisan los resultados de las simulaciones y de la comparación con la estrategia mensual, el maíz en ambas áreas presenta los mayores beneficios, teniendo en las simulaciones con el plan de compras a 6 meses ahorros por 180 MM CLP y una probabilidad de ahorro de 100% en Mascotas, y 91% en Nutrición animal. Esto equivale al 2,6% del total de compras de Mascotas y 1,6% de Nutrición animal. Con respecto a la estrategia mensual (“conservadora”) se tuvo beneficios por 115 MM CLP en Mascotas, y 40 MM CLP Nutrición animal, ambos para el maíz. En tanto, el afrechillo y triticale mostraron resultados negativos o alrededor de 0, por lo que no se consideran por lo momento como candidatos para usar el plan de compras propuesto.

Y cuando se compara con el comportamiento real de los compradores de IANSA, el maíz en Mascotas presenta el mayor beneficio (70 MM CLP), seguido por el afrechillo (40 MM CLP) en Nutrición animal, equivaliendo al 1,9% y 1% del total de compras de esos insumos, respectivamente. En esta evaluación, el maíz en Nutrición animal no sigue la tendencia mostrada en las simulaciones ni en la

comparación con la estrategia mensual, teniendo resultados negativos, al igual que el triticale en esa misma área, y afrechillo en el área Mascotas.

El afrechillo y triticale presentaron las menores posibilidades de ahorro, teniendo sobrecostos al usar el plan recomendado en varios trimestres y semestres debido a la continua baja en el precio de trigo.

En todos los resultados se puede observar que los mayores beneficios se tienen en el área Mascotas. Una de las razones es que como se pudo ver en la sección 2.1, las órdenes de compra en el maíz por parte de Mascotas son más parejas que las de Nutrición animal en cuanto a la participación de cada mes en los costos anuales de compra. Mascotas en ningún mes establece una orden de compra cuya cantidad sea mayor que el 30% de lo consumido en el año, en cambio en Nutrición animal, apenas en dos meses se registra más del 80% del consumo anual de maíz.

Esto hace que, dado que el maíz mostró una marcada estacionalidad entre 2015 y 2016, esta área no haya aprovechado esa tendencia para asegurar menores costos al establecer órdenes de compra por varios meses en el período abril-junio (época de precios bajos por el general en el maíz por ser época de cosecha). Y es justamente en esta materia prima donde se tuvieron los mayores ahorros en todas las evaluaciones.

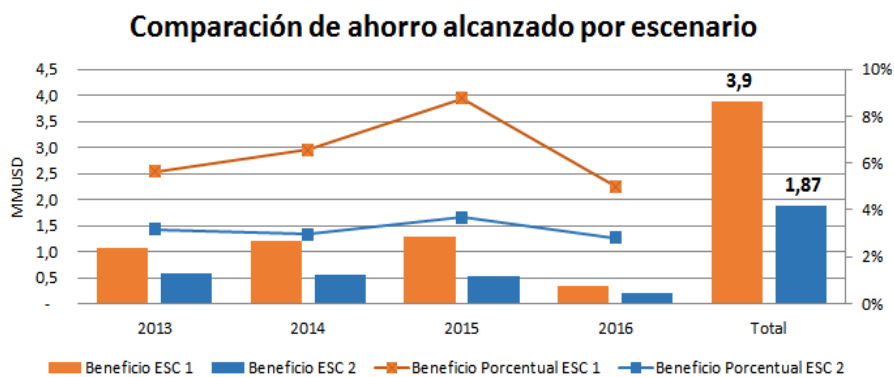
## 9 DISCUSIÓN, CONCLUSIONES, Y POSIBLES LINEAS DE INVESTIGACIÓN

### 9.1 Discusión

Realizar un estudio sobre la posibilidad de generar ahorros por cambiar la manera en que se compran materias primas que significan alto porcentaje del costo de producción (23% en 2015), como lo son el afrechillo, triticale, maíz, y soya resulta relevante tomando en cuenta los beneficios que se pueden llegar a generar. Para evaluar sus beneficios fueron usados dos escenarios de compra, es decir, dos formas en que se compran las materias primas. El primero establece que se tiene un modelo en que se puede saber con total precisión los precios del próximo semestre, y compro a los precios más bajos para abastecer esos meses. Y el segundo es análogo, pero para un trimestre.

Con estos escenarios, considerados como ideales, ya que se conocen con total precisión los precios del próximo período, de acuerdo con la Figura 9.1 se pudieron obtener ahorros cercanos a 4 MM USD y 2 MM USD para cada escenario respectivamente (“ESC 1 corresponde a compras semestrales, y “ESC 2 a compras trimestrales). Esto como ahorro total en el período evaluado, que comprendió todos los meses entre enero de 2013 y septiembre de 2016 (no considera el período octubre a diciembre 2016, pues la evaluación se realizó en octubre, teniendo datos hasta septiembre 2016 solamente).

**Figura 9.1:** Ahorro alcanzado por cada escenario evaluado en MM USD entre los años 2013 y 2016, en conjunto para las áreas Mascotas y Nutrición animal. El ahorro porcentual se calcula respecto del total de compras de materias primas de cualquier tipo. “ESC 1” corresponde a compras semestrales, y “ESC 2” a compras trimestrales.



Fuente: Elaboración propia en base información de compras de IANSA.

La idea de usar modelos de series de tiempo sigue la tendencia de la academia en cuanto a que son los modelos estadísticos por excelencia usados en este momento para predecir variables cuyo valor pasado tiene incidencia en los valores futuros.

Dentro de las series de tiempo se escogió el modelo VECM (Modelo de vector de corrección de errores), debido a su buen rendimiento de acuerdo con los estudios revisados en el capítulo 4, los cuales muestran que posee rendimientos superiores frente a otros modelos de series de tiempo multivariados, debiendo ser de este tipo ya que se quería estudiar la incidencia de más de una variable en los precios mensuales promedio del afrechillo, triticale, maíz, y soya.

En general, la estimación de cada uno de los modelos usados logra cumplir los supuestos necesarios para su uso, de acuerdo con los tests realizados. No obstante, no todos logran cumplir el supuesto de normalidad en los residuos, el cual se estudia mediante el test de Jaque-Bera.

Sumado a esto se realizaron regresiones lineales de manera de poder dar un significado a los coeficientes obtenidos, en cuanto a su signo y cómo influyen en los precios, ya que es sabido en los modelos de series de tiempo no es posible realizar lo anterior debido a la correlación existente por los rezagos de variables.

Se cree que los resultados obtenidos presentan un buen performance en cuanto al ajuste con la realidad, durante el período de evaluación (2015 y 2016). Esto se hace patente en los errores de cada modelo, teniendo un MAPE (Error absoluto porcentual promedio) bajo 10% en todos los modelos para todos los períodos (1,3, y 6 meses), lo cual muestra ser suficiente para interpretar de buena manera la evolución de los precios.

Aun así, no es posible anticipar todos los cambios de tendencia de las variables que se intenta predecir, por lo que no se puede confiar ciegamente en las predicciones y debe servir como guía, más que como una herramienta automática para la toma de decisiones.

Aun cuando no es posible predecir ni modelar con total exactitud la realidad, y es comprensible que existan períodos en los cuales el modelo comete errores, pudiera ser que existan variables omitidas que no fueron incluidas en este modelo, o que debieron ser consideradas como endógenas, cuando en este estudio fueron consideradas exógenas.

Resultó sorprendente la precisión obtenida en los modelos de regresión lineal, los cuales sin usar ningún tipo de rezagos, y con un número menor de variables (como resultado al final de la estimación, pues se descartan las no significativas) obtienen resultados muy parecidos, incluso mejores en algunos casos que los del VECM, de acuerdo con las métricas RSME (Raíz del Error Cuadrático Medio) y MAPE. Esto otorga un gran valor a estos modelos, ya que no solo permiten interpretar sus coeficientes, sino que presentan un ajuste similar a otros considerados por la literatura como superiores.

Estos resultados ponen en tela de juicio la real superioridad alcanzada por el modelo VECM frente a otros, específicamente para este estudio, frente a las regresiones lineales, ya que obtienen resultados parecidos. Para una decisión

determinante se necesita un mayor período de prueba de las predicciones de cada modelo, pero al menos, en los dos años de evaluación ya se cree que se puede vislumbrar parte de la tendencia, en cuanto a que no existen grandes diferencias.

Finalmente, en cada una de las evaluaciones que se realizaron; frente a compras de IANSA, frente a estrategia “conservadora” (solo para abastecer el mes siguiente), y frente a las simulaciones de comportamiento de los compradores de IANSA, se obtuvieron beneficios para al menos una materia prima en una de las áreas. Esto da cuenta de que efectivamente es posible realizar mejoras a la situación actual de la empresa. Se cree que los resultados son bastante robustos ya que se realizaron 3 maneras distintas, y en cada una se tuvo resultados similares, ubicándose dentro del intervalo de ahorro planteado en la evaluación inicial de beneficios posibles.

## **9.2 Conclusiones**

La comprensión de las dinámicas de precios y generación de predicciones resulta muy relevante en cualquier materia prima u otro tipo insumo, particularmente en las materias primas agrícolas en estudio; afrechillo, triticale, maíz y soya. En la literatura, existen múltiples modelos que intentan comprender los factores que afectan los precios agrícolas, pero en una cantidad reducida de trabajos se realizan predicciones, y en una cantidad aún menor, predicciones con información que no sea perfecta, es decir, que realmente se hubiera tenido al momento de estar usando el modelo.

Por esto, se cree que este trabajo aporta valor en ese sentido, dando una utilidad práctica a metodologías propuestas por la literatura en cuanto a modelos de predicción de precios, y evaluando el resultado frente a distintos escenarios que intentan representar la realidad, y estudiar la robustez de estos resultados.

Por medio de este trabajo se realizó un estudio del mercado del trigo, maíz, y soya, pudiendo comprender la manera en que funciona cada uno desde el punto de vista de los productores de la materia prima hasta los que compran estos insumos para luego procesarlos, y cómo dependiendo del uso que se le dará, se usan distintas variedades del mismo producto. Este mercado es bastante complejo pues es afectado por múltiples factores; climatológicos, políticos, ambientales, entre otros. Lo anterior permite comprender qué variables deben ser agregadas en los modelos para representar cada uno de los aspectos que generan variaciones en los precios.

El afrechillo y el triticale son productos relacionados con el trigo, de los cuales existe muy poca información respecto de su mercado. Y tampoco existe algún ente público o privado que publique sus precios periódicamente, a diferencia del trigo, cuyos precios son publicados semanalmente por COTRISA



(Comercializadora de trigo S.A), y del cual existen numerosos estudios. Por lo anterior, se usó predicciones de trigo predecir las variaciones de precios del afrechillo y triticale, y el mercado que se describió es el del trigo, el que de todas formas está conectado con el del afrechillo y triticale.

El interés se centró en la predicción de precios de trigo, maíz y soya, de manera de poder establecer estrategias de compra que permitan reducir los costos pagados por las áreas de Nutrición animal y Mascotas de la empresa IANSA al anticiparse a variaciones en los precios y estacionalidades, cuyas plantas están separadas geográficamente (región Metropolitana la de Mascotas, región de La Araucanía la de Nutrición animal), por lo que establecen órdenes de compra de manera individual.

En base a las predicciones de estas materias primas (trigo, maíz, y soya) se decide el plan de compras, que comprende la cantidad y precio por el cual se deben establecer órdenes de compra en cada mes para satisfacer la demanda de las plantas de cada área, por productos relacionados con el trigo (afrechillo y triticale), maíz y soya. Finalmente, si bien se realizaron predicciones para la soya, se decidió no proponer un plan de compras para la soya, ya que representa un porcentaje muy pequeño en comparación a las compras del resto de los insumos, ni tampoco para el triticale en el área Mascotas por la misma razón.

De acuerdo con la literatura existente, se hicieron dos tipos de modelo; VECM (Modelo de vector de corrección de errores) y regresiones lineales. El primero debido a la precisión que ha mostrado tener en sus predicciones, y el segundo, por la posibilidad de interpretar los coeficientes de cada variable de manera de establecer el efecto de cada una sobre la variable dependiente, y por la facilidad que significa su uso, ya que, se usan menos variables y no se necesita un programa estadístico especializado.

La calibración de los modelos se hizo en base a metodologías disponibles en la literatura, que son consideradas como estándar a la hora de usar estos modelos, en el sentido de que se usan tests tradicionales y presentes en una gran cantidad de trabajos de investigación relacionados.

Como se menciona anteriormente, el entendimiento del mercado de cada uno de los insumos cuyo precio se busca predecir, sumado con la revisión bibliográfica permitió identificar variables que pudieran tener incidencia en los precios del trigo, maíz, y soya. Con las variables ya identificadas se procedió a confeccionar la base de datos para calibrar los distintos modelos a usar. Esta tiene como origen el año 2006, puesto que los precios del mercado chileno del trigo y maíz estaban disponibles desde esa fecha en adelante.

Así, se usó como datos de calibración (descritos como “datos dentro de la muestra” en el trabajo) la información de las variables identificados como relevantes entre agosto de 2006 y diciembre de 2014. Y los datos entre enero de 2015 y diciembre de 2016 fueron usados para realizar predicciones a 1, 3, y

6 meses, y evaluar cada modelo (“datos fuera de la muestra”). Las evaluaciones se hicieron en base a las métricas MAPE (Error absoluto porcentual promedio) y RSME (Raíz del error cuadrático medio), eligiendo para cada materia prima y período (1, 3, y 6 meses) el mejor modelo.

Los modelos VECM mostraron un buen nivel de ajuste, obteniendo un MAPE de menos del 10% en todas las materias primas y períodos. Asimismo, las regresiones también mostraron un buen ajuste, a veces incluso mejor que los VECM en el caso del trigo, pero peor que este en el caso del maíz y la soya.

Por medio de las regresiones se pudo reducir a no más de seis las variables que ejercen influencias sobre los precios de cada una de las materias primas en estudio. Además, se hizo visible que la superioridad del VECM mostrada en los resultados de la literatura, sería relativamente pequeña frente a otros modelos según los resultados de este trabajo, aunque para comprobarlo es necesaria una evaluación con un mayor número de observaciones.

Con las predicciones de los modelos VECM para cada materia prima, se hizo un plan de compras a 3 y 6 meses, el cual se evaluó frente a compras reales de IANSA en el mismo período (2015 y 2016), una estrategia “conservadora” que establece órdenes de compra con una cantidad que solo abastece el próximo mes, y mil simulaciones del comportamiento de los compradores de IANSA para cada materia prima.

Se pudieron apreciar ahorros significativos en algunos insumos, como es el caso del maíz en el área Mascotas, donde obtuvo beneficios por más de 70 MM CLP en todas las evaluaciones, llegando hasta los 115 MM CLP frente a la estrategia “conservadora”, lo que corresponde a un ahorro porcentual en las compras de este insumo de 1,9% y 3%, respectivamente. Eso sí, para los insumos relacionados con el trigo (afrechillo y triticale) no fue conveniente usar el modelo, principalmente debido a que los precios se encontraron a la baja durante casi todo el período, por lo que hubo pocas posibilidades de ahorro.

Fue posible establecer distintas estrategias que pudieran tomar los compradores a la hora de negociar con los proveedores. En particular, la estrategia a 6 meses logró los mejores resultados, potenciada por el alza que tuvo el maíz en el segundo semestre de 2015 y 2016 producto de la estacionalidad que presenta esta materia prima, y de los distintos comportamientos de compras en cada área.

En Mascotas, en las compras de maíz no se negocian órdenes de compras grandes (mayores al 30% del consumo anual de maíz), por lo que es más difícil aprovechar las estacionalidades vistas en los años 2015 y 2016, a diferencia de lo realizado por Nutrición animal, donde se observó que entre abril y junio se establecen órdenes de compra que abastecen prácticamente todo el año, existiendo beneficios mucho menores para esta área en el maíz.

Por lo tanto, se concluye que a través del uso de modelos estadísticos de predicción de precios fue posible pronosticar con bastante precisión el precio de las materias primas agrícolas en estudio, y se pudo alcanzar ahorros en el proceso de compra de las mismas, a través de estrategias recomendadas en base a las predicciones de los modelos, que resultan factibles dentro de la dinámica que se produce entre los compradores de IANSA y sus proveedores.

### **9.3 Recomendaciones**

Los resultados de los modelos VECM entregan errores bastante pequeños (MAPE menor a 10% en todos los períodos y materias primas), por lo que muestra ser una metodología bastante confiable para usar. Eso sí, se debe tener presente que los resultados de la evaluación del plan de compras propuesto no muestran beneficios para todas las materias primas en las dos áreas. Y que además, puede ser que en la realidad no se logre mantener por varios meses el precio de mercado del momento al negociar con el proveedor una orden de compra que busca fijarlo.

Por lo anterior, en caso de hacer uso de las recomendaciones establecidas en el plan de compras del modelo, se recomienda iniciar por el maíz en el área de Mascotas, materia prima que tuvo los mayores beneficios en todos los tipos de evaluaciones, entre todas las materias primas. Donde logró alcanzar beneficios por 73 MM CLP frente a las compras reales del área (mascotas) entre 2015 y 2016, 115 MM CLP frente a la compra “conservadora” (compra de insumos solo para abastecer el mes siguiente, y 100 MM CLP frente a las mil simulaciones del comportamiento de los compradores de esa área de IANSA en el mismo período.

En esa misma línea, lo ahorros nombrados significan un 1,9%, 3%, y 2,6% en comparación con el gasto total en compras de maíz en Mascotas en cada una de las evaluaciones, respectivamente.

Estos resultados pueden variar significativamente si es que la información entregada a los modelos es errónea o no está actualizada, además de que la dificultad para actualizar los valores necesarios para usarlos aumenta a medida que no se actualiza la base de datos. Esto se debe a que los datos actuales se muestran en gran cantidad de páginas webs, pero datos antiguos quedan registrados en un número bastante reducido de bases de datos, cuyas fuentes se pueden encontrar en el capítulo 7, para cada una de las variables utilizadas.

Por lo tanto, se recomienda una actualización mensual de los datos de los modelos, de manera de poder usarlos continuamente y evitar errores por datos no disponibles. Los datos necesarios están disponibles, como se menciona en el capítulo 5, alrededor del 15 de cada mes.

La facilidad para manipular las regresiones lineales, en comparación con los modelos VECM hace que se recomiende el uso de las regresiones lineales en caso de hacer uso de los modelos planteados en el futuro. Se requiere un mucho menor tiempo para recolectar datos (la regresión con más variables tiene 6, el VECM posee alrededor de 30 incluyendo los rezagos), y es posible de hacer uso de ellas con programas estándar disponibles en cualquier lugar de trabajo como Microsoft Excel (Para los VECM se debe usar programas estadísticos especializados como EVIEWS).

Eso sí, también se recomienda que, de ser posible, se usen ambos tipos de modelos (VECM y regresiones) para comparar su funcionamiento en un período más extenso, para hacer contrastes más consistentes en este aspecto. Las predicciones de precios y el plan de compras propuesto se deben usar como una guía para los compradores. Esto puede contribuir a reducir la incertidumbre y especulación, pues se realizan predicciones en base a datos reales.

Además, provee una base para estimar los posibles costos que se podrían tener en cada período (semestre o trimestre). Para algunas modelos los precios en promedio están cierto porcentaje más arriba o más abajo en valor que los precios reales, para corregir esto de manera de presupuestar costos se puede utilizar la desviación media con respecto al valor real (no el absoluto).

El uso de las predicciones se recomienda también como una manera de revisar las decisiones que toman los compradores y verificar los criterios que han usado. Ya que, a modo de ejemplo, anteriormente no existía ningún método para contrastar los resultados, pero en caso de usar los modelos sí existiría un precio pronosticado, habiendo una mayor trazabilidad en las decisiones que han tomado, pues es posible revisar el precio y cantidad que decidieron comprar, y, por ende, la posibilidad de crear sistemas de incentivos en base a sus resultados.

#### **9.4 Posibles líneas de investigación**

Si bien la literatura recomienda y avala el uso del modelo VECM para la predicción de precios de commodities, existen otro tipo de modelos que están en auge que podrían ser probados para evaluar su rendimiento frente al VECM, y quizás obtener mejores predicciones, como las Redes Neuronales.

En un principio se planteó la idea de usar Redes Neuronales en este estudio para comparar su rendimiento frente al VECM, pero dado que no se tenía experiencia usándolas, ni conocimiento acabado en ese tema, resultó por desecharse esa idea. No obstante, como se menciona en el párrafo anterior, puede constituir una mejora en las predicciones.

También, en cuanto a los supuestos realizados en este estudio, se podría analizar a futuro la posibilidad de:

- a) Incluir el uso de almacenamiento externo si es que se logra definir con precisión las variables que definen su costo, ya que este varía bastante según las condiciones de cada proveedor. Esto es muy relevante, ya que conocer estas condiciones permite acercarse en mayor medida al precio que se terminará pagando realmente, por la posible existencia de sobrecostos de distinto tipo.
- b) Para los períodos de simulación trimestrales y semestrales realizar predicciones en cada uno de los meses del año, y no solo en el primer mes de cada trimestre o semestre, como se hizo en este estudio por temas de tiempo, y por ser una primera aproximación al tema. Este podría permitir mejorar las predicciones sobre la marcha y evaluar de una manera más realista la toma de decisiones. Y también, complementar las predicciones de los modelos a 3 y 6 meses de manera de mejorar el rendimiento.

Esto es que, por ejemplo, para una estrategia a 6 meses se podría tomar como predicción para los 3 primeros meses los resultados del modelo a 3 meses, y para los 3 posteriores el resultado del modelo a 6 meses. Así, se usaría la información más actualizada, pues para el modelo a 6 meses, el primer mes pronosticado usa información correspondiente a 6 meses anteriores, lo que implica que puede estar muy desactualizada, y claramente más desactualizada que el primer mes pronosticado por el modelo a 3 meses, que usa información de hace 3 meses.

- c) Realizar compras de manera conjunta para de ambas áreas (Nutrición animal y Mascotas), según los costos de transporte y toda la logística que esté involucrada. Además de estudiar la factibilidad de esa solución con los proveedores de los insumos a comprar.
- d) Aumentar el período de evaluación de las predicciones de manera de tener mayor certeza de sus resultados a futuro, y en qué casos pueden fallar.
- e) Por último, extender este estudio y la metodología utilizada a otras materias primas agrícolas relevantes de analizar. Se especifica materias primas agrícolas debido al tipo de variables utilizadas, como las climatológicas y otras relativas a cultivos, pero en realidad podría extenderse a cualquier otro commodity donde exista basta información pasada para obtener datos de muestra para calibrar los modelos, y datos de prueba para evaluar las predicciones de los mismos.

## 10 BIBLIOGRAFÍA

Memorias IANSA 2015, 2014, 2013, 2012.

Presentación de resultados 1er y 2do trimestre 2016 IANSA.

Historial de compras de maíz, trigo, afrechillo, triticale, y soya, IANSA, enero 2013 a agosto 2016.

“Agricultura chilena: Información social y productiva según tamaño del productor y localización geográfica”, ODEPA, mayo 2012.

“Situación mundial del maíz”, ODEPA, 2006.

“Boletín del mercado del maíz”, ODEPA, abril 2014, enero 2015, junio 2016.

“Boletín del mercado del trigo”, ODEPA, enero, febrero, y junio 2016.

“Estudio de un programa de apoyo a la comercialización de los pequeños productores de trigo”, COGNITUS CHILE, 2001.

Censo Agropecuario Nacional 2007, INE, 2007.

“Predicción de precios mediante modelización multivariada de series de tiempo. Una aplicación al sector lácteo argentino”, Vicentín Massaro, 2016.

“Prediciendo el precio del cobre: ¿Más allá del camino aleatorio?”, Engel & Valdés, 2001.

“Explaining Commodity Prices by a Cointegrated Time Series-Cross Section Model”, Ahumada & Cornejo, 2014.

“Modelos VAR y VECM para el Pronóstico de Corto Plazo de las Importaciones de Costa Rica (Documento de Trabajo No. 22)”, Arias & Torres, 2004.

“A combination method for interval forecasting of agricultural commodity futures prices”, Xiong, Li, Bao, & Zhang, 2015.

“Wheat Outlook”, “Oilcrops Outlook”, “Feed Outlook”, United States Department of Agriculture (USDA), 2006-2014.

“Resumen de época de siembra y cosecha de los principales cultivos a nivel nacional”, Laboratorio Suelo Agua Planta (SAP) Universidad de Chile, 2009.

“Market integration for Chilean wheat prices using Vector Error Correction Models (VECM), a cointegration analysis”, Valdés, Von Cramon-Taubadel, & Díaz, 2011.

“Influential factors in the economic modelling of the price of wheat in the United States of America”, Keatinge, 2015.

“Impacts of ethanol policy in corn prices: A review and meta-analysis of recent evidence”, Condon, Klemic, & Wolverton, 2013.

“The effect of ethanol production of the U.S national corn price”, Fortenbery & Park, 2008.

“USDA agricultural projections to 2025”, United States Department of Agriculture (USDA), 2016.

“Monthly profitability of ethanol production”, Iowa University, 2017.

“Una nueva visión para el sector triguero en Chile”, Fundación Chile, 2005.

“Price determination for corn and wheat: the role of market factors and government programs”, Wescott & Hoffman, 1999.

“Factors influencing price volatility on soybeans futures prices”, Gavilanez, 2012.

“Test de causalidad”, Montero, 2013.

“Análisis y evaluación de la competitividad y transparencia del mercado nacional del maíz”, Oficina de estudios y políticas agrarias (ODEPA), 2007.

WWF (World Wildlife Fund) (2017). *Soy facts & data*. Disponible en la página web: [http://wwf.panda.org/what\\_we\\_do/footprint/agriculture/soy/facts/](http://wwf.panda.org/what_we_do/footprint/agriculture/soy/facts/) [Revisado el 11 de julio de 2017].

Soyatech. (2017). Information About Soya, Soybeans. Disponible en la página web: <http://www.soyatech.com/info.php?id=175> [Revisado el 11 de julio de 2017].

Global soybean production. (2017). Soybean | Global Soybean Production 2017/2018. Disponible en la página web: <http://www.globalsoybeanproduction.com> [Revisado el 11 de julio de 2017].

La Tercera Edición Impresa. (2017). Las tres empresas que concentran más del 90% de la industria del pollo en el país - Edición Impresa. Disponible en la página web: <http://diario.latercera.com/edicionimpresa/las-tres-empresas-que-concentran-mas-del-90-de-la-industria-del-pollo-en-el-pais/> [Revisado el 11 de julio de 2017].

Guillermo Rossi, Bolsa de Cereales de Rosario. (2017). Retenciones: Larga historia de tensiones. Disponible en la página web: <https://www.bcr.com.ar/Pages/Publicaciones/infoboletinsemanal.aspx?IdArticulo=1681> [Revisado el 10 de julio de 2017].

COTRISA. (2017). COTRISA | Comercializadora de trigo S.A. Disponible en la página web: <https://www.cotrisa.cl/empresa/mision.php> [Revisado el 10 de julio de 2017].

Suralim. (2017). *Iansa Nutrición Animal, Quiénes somos*. Disponible en la página web: <http://www.suralim.cl/quienes-somos> [Revisado el 10 de julio 2017].

Renewable Fuels Association. (2017). *Industry Statistics*. Disponible en la página web: <http://www.ethanolrfa.org/resources/industry/statistics/#1454099103927-61e598f7-7643> [Revisado el 10 de julio de 2017].

Observatory of Economic Complexity. (2017). OEC - Soybeans (HS92: 1201) Product Trade, Exporters and Importers. Disponible en la página web: <http://atlas.media.mit.edu/en/profile/hs92/1201/#Importers> [Revisada el 10 de julio de 2017].



## 11 ANEXOS

Imagen 1: Distribución de las operaciones de IANSA en Chile y el Exterior.



Fuente: Memorias IANSA 2015.

**Imagen 2: test de rezagos VECM a 1 mes trigo.**

VAR Lag Order Selection Criteria

Endogenous variables: CHI USA(-1) ARG(-1) USAMAIZ(-1) USASOYA(-1)

Exogenous variables: C ESTAC NOV7 DIC8 DIC11 DOLARREAL(-2) PETRO RATIO STOCKFINALM TONI  
IMPARG IMPMUNDO AEAD AEF AFAD ALTAD ALTAD ALTA ALTA BAJAD BAJAE BAJAF

Date: 05/31/17 Time: 12:55

Sample: 2006M08 2014M12

Included observations: 94

Lag	LogL	LR	FPE	AIC	SC	HQ
0	519.9468	NA	1.05e-10	-8.828655	-5.987741	-7.681134
1	817.4162	430.3812	3.29e-13	-14.62588	-11.10855*	-13.20513*
2	848.7466	41.99614*	3.04e-13*	-14.76057*	-10.56684	-13.06661
3	868.2926	24.12060	3.69e-13	-14.64452	-9.774384	-12.67734
4	883.0255	16.61366	5.11e-13	-14.42607	-8.879527	-12.18567
5	901.1254	18.48509	6.85e-13	-14.27926	-8.056310	-11.76565
6	937.3580	33.14893	6.54e-13	-14.51826	-7.618892	-11.73142

\* indicates lag order selected by the criterion

LR: sequential modified LR test statistic (each test at 5% level)

FPE: Final prediction error

AIC: Akaike information criterion

SC: Schwarz information criterion

HQ: Hannan-Quinn information criterion

*Fuente: Elaboración propia.*

**Imagen 3: test correlación serial en residuos VECM a 1 mes trigo.**

VAR Residual Serial Correlation LM Tests

Null Hypothesis: no serial correlation at lag order h

Date: 05/31/17 Time: 12:56

Sample: 2006M08 2014M12

Included observations: 98

Lags	LM-Stat	Prob
1	32.52069	0.1435
2	19.90557	0.7518
3	35.52142	0.0792
4	25.99219	0.4080
5	22.47548	0.6082
6	35.10648	0.0863
7	25.66433	0.4257
8	29.10137	0.2597
9	28.50646	0.2851
10	17.60142	0.8588
11	26.78926	0.3665
12	28.17453	0.2999

Probs from chi-square with 25 df.

*Fuente: Elaboración propia.*

**Imagen 4:** test de normalidad VECM a 1 mes trigo.

VAR Residual Normality Tests

Orthogonalization: Cholesky (Lutkepohl)

Null Hypothesis: residuals are multivariate normal

Date: 05/31/17 Time: 12:56

Sample: 2006M08 2014M12

Included observations: 98

---

---

Component	Skewness	Chi-sq	df	Prob.
1	0.018618	0.005662	1	0.9400
2	0.205436	0.689328	1	0.4064
3	0.175580	0.503531	1	0.4780
4	-0.182075	0.541473	1	0.4618
5	-0.024700	0.009965	1	0.9205
Joint		1.749959	5	0.8825

---

---

---

---

Component	Kurtosis	Chi-sq	df	Prob.
1	1.534015	8.775539	1	0.0031
2	1.824919	5.638329	1	0.0176
3	1.622363	7.749689	1	0.0054
4	1.603782	7.960156	1	0.0048
5	1.740068	6.482002	1	0.0109
Joint		36.60572	5	0.0000

---

---

---

---

Component	Jarque-Bera	df	Prob.
1	8.781201	2	0.0124
2	6.327657	2	0.0423
3	8.253221	2	0.0161
4	8.501629	2	0.0143
5	6.491967	2	0.0389
Joint	38.35567	10	0.0000

---

---

*Fuente: Elaboración propia.*

**Imagen 5: test de heterocedasticidad en residuos VECM 1 mes trigo.**

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Date: 05/31/17 Time: 12:56

Sample: 2006M08 2014M12

Included observations: 98

Joint test:					
Chi-sq	df	Prob.			
699.3741	735	0.8231			

Individual components:					
Dependent	R-squared	F(49,48)	Prob.	Chi-sq(49)	Prob.
res1*res1	0.480907	0.907532	0.6320	47.12893	0.5493
res2*res2	0.563684	1.265552	0.2080	55.24105	0.2507
res3*res3	0.414214	0.692677	0.8980	40.59295	0.7981
res4*res4	0.483563	0.917236	0.6180	47.38918	0.5386
res5*res5	0.612859	1.550734	0.0653	60.06022	0.1337
res2*res1	0.430430	0.740288	0.8511	42.18216	0.7439
res3*res1	0.480319	0.905396	0.6350	47.07130	0.5516
res3*res2	0.506854	1.006821	0.4910	49.67168	0.4464
res4*res1	0.421172	0.712781	0.8794	41.27490	0.7756
res4*res2	0.496240	0.964968	0.5495	48.63150	0.4880
res4*res3	0.449365	0.799429	0.7811	44.03774	0.6741
res5*res1	0.486446	0.927885	0.6027	47.67174	0.5270
res5*res2	0.472025	0.875784	0.6774	46.25846	0.5849
res5*res3	0.436050	0.757428	0.8321	42.73292	0.7238
res5*res4	0.538458	1.142842	0.3223	52.76891	0.3306

*Fuente: Elaboración propia.*

**Imagen 6: test de Johansen VECM 1 mes trigo.**

Date: 05/31/17 Time: 12:56

Sample (adjusted): 2006M11 2014M12

Included observations: 98 after adjustments

Trend assumption: Linear deterministic trend

Series: CHI USA(-1) ARG(-1) USAMAIZ(-1) USASOYA(-1)

Exogenous series: ESTAC NOV7 DIC8 DIC11 DOLARREAL(-2) PETRO RATIO STOCKFINALM TONI

IMPARG IMPMUNDO AEAD AEF AFAD ALTAD ALTAF ALTAE BAJAD

Warning: Critical values assume no exogenous series

Lags interval (in first differences): 1 to 1

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.369145	116.7679	69.81889	0.0000
At most 1 *	0.307837	71.62143	47.85613	0.0001
At most 2 *	0.182075	35.56386	29.79707	0.0097

At most 3 *	0.143604	15.86737	15.49471	0.0439
At most 4	0.006866	0.675220	3.841466	0.4112

Trace test indicates 4 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.369145	45.14652	33.87687	0.0015
At most 1 *	0.307837	36.05757	27.58434	0.0032
At most 2	0.182075	19.69649	21.13162	0.0784
At most 3 *	0.143604	15.19215	14.26460	0.0356
At most 4	0.006866	0.675220	3.841466	0.4112

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b'\*S11\*b=I):

CHI	USA(-1)	ARG(-1)	USAMAIZ(-1)	USASOYA(-1)
-7.200439	3.524808	4.975850	-5.400501	-3.085594
-1.378250	5.196466	-17.72256	-3.025225	6.350732
-12.79996	-1.193705	7.754299	3.542277	6.035572
-2.960926	-1.070829	-4.209037	7.758914	-9.420507
-4.309268	18.23005	-5.084988	4.346130	-4.025700

Unrestricted Adjustment Coefficients (alpha):

D(CHI)	0.015107	0.002947	0.008563	0.010138	-0.000821
D(USA(-1))	0.019014	0.017746	-0.014794	0.012772	-0.002622
D(ARG(-1))	0.010226	0.021211	0.001912	-0.001861	0.000630
D(USAMAIZ(-1))	0.035598	0.005915	-0.011766	0.001860	0.000757
D(USASOYA(-1))	0.015989	0.010943	-0.009549	0.011685	0.002297

1 Cointegrating Equation(s):                      Log likelihood                      836.1319

Normalized cointegrating coefficients (standard error in parentheses)

CHI	USA(-1)	ARG(-1)	USAMAIZ(-1)	USASOYA(-1)
1.000000	-0.489527	-0.691048	0.750024	0.428529
	(0.39141)	(0.43486)	(0.23476)	(0.29277)

Adjustment coefficients (standard error in parentheses)

D(CHI)	-0.108776
	(0.03408)
D(USA(-1))	-0.136910
	(0.05947)
D(ARG(-1))	-0.073635
	(0.03518)
D(USAMAIZ(-1))	-0.256324

	(0.04728)
D(USASOYA(-1))	-0.115128 (0.04651)

*Fuente: Elaboración propia.*

**Imagen 7: test de Granger VECM 1 mes trigo.**

VEC Granger Causality/Block Exogeneity Wald Tests

Date: 05/31/17 Time: 12:57

Sample: 2006M08 2014M12

Included observations: 98

Dependent variable: D(CHI)

Excluded	Chi-sq	df	Prob.
D(USA(-1))	0.000164	1	0.9898
D(ARG(-1))	2.263256	1	0.1325
D(USAMAIZ(-1))	0.076000	1	0.7828
D(USASOYA(-1))	3.223919	1	0.0726
All	4.773832	4	0.3113

*Fuente: Elaboración propia.*

**Imagen 8: VECM a 1 mes trigo.**

Dependent Variable: D(CHI)

Method: Least Squares

Date: 05/31/17 Time: 12:57

Sample (adjusted): 2006M11 2014M12

Included observations: 98 after adjustments

$$D(CHI) = C(1)*(-4.50660061508*CHI(-1) - 6.93214846717*USAMAIZ(-2) + 46.1189647849) + C(2)*D(CHI(-1)) + C(6)*D(USASOYA(-2)) + C(7) + C(8)*ESTAC + C(9)*NOV7 + C(10)*DIC8 + C(11)*DIC11 + C(12)*DOLARREAL(-2) + C(13)*PETRO + C(14)*RATIO + C(15)*STOCKFINALM + C(16)*TONI + C(17)*IMPARG + C(18)*IMPMUNDO + C(19)*AEAD + C(20)*AEAF + C(21)*AFAD + C(22)*ALTAD + C(23)*ALTA + C(24)*ALTAE + C(25)*BAJAD + C(26)*BAJAE + C(27)*BAJAF$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.011777	0.005004	2.353707	0.0212
C(2)	0.230182	0.108758	2.116452	0.0377
C(6)	0.131072	0.086485	1.515540	0.1339
C(7)	0.205221	1.023467	0.200516	0.8416
C(8)	0.140790	0.115760	1.216223	0.2278
C(9)	-0.128578	0.058094	-2.213271	0.0300
C(10)	-0.061587	0.057653	-1.068233	0.2889
C(11)	-0.183586	0.050838	-3.611222	0.0006

C(12)	-0.140978	0.121807	-1.157390	0.2508
C(13)	0.031178	0.042716	0.729889	0.4678
C(14)	-0.147657	0.111027	-1.329915	0.1876
C(15)	0.140129	0.113338	1.236379	0.2202
C(16)	-0.000657	0.004415	-0.148858	0.8821
C(17)	0.001919	0.001670	1.149148	0.2542
C(18)	-0.003681	0.009224	-0.399021	0.6910
C(19)	-0.028882	0.062073	-0.465300	0.6431
C(20)	0.057318	0.071802	0.798287	0.4273
C(21)	0.055004	0.061480	0.894652	0.3739
C(22)	-0.023636	0.028947	-0.816545	0.4168
C(23)	-0.025330	0.050837	-0.498251	0.6198
C(24)	0.004026	0.037174	0.108295	0.9141
C(25)	-0.016597	0.049647	-0.334306	0.7391
C(26)	0.106985	0.055955	1.912004	0.0597
C(27)	0.038049	0.050110	0.759311	0.4501
<hr/>				
R-squared	0.470930	Mean dependent var	0.001526	
Adjusted R-squared	0.306490	S.D. dependent var	0.056773	
S.E. of regression	0.047279	Akaike info criterion	-3.056617	
Sum squared resid	0.165411	Schwarz criterion	-2.423564	
Log likelihood	173.7742	Hannan-Quinn criter.	-2.800560	
F-statistic	2.863833	Durbin-Watson stat	1.935819	
Prob(F-statistic)	0.000336			

*Fuente: Elaboración propia.*

### Imagen 9: test de rezagos VECM 6 meses trigo.

VAR Lag Order Selection Criteria

Endogenous variables: CHI USA(-6) ARG(-6) USAMAIZ(-6) USASOYA(-6)

Exogenous variables: C ESTAC NOV7 DIC8 DIC11 DOLARREAL(-7) PETRO(-5) RATIO(-5)

STOCKFINALM(-5) TONI IMPARG(-5) IMPMUNDO(-5) AEAD AEAF AFAD ALTAD ALTAJ ALTAJ BAJAD

BAJAE BAJAF

Date: 05/31/17 Time: 14:32

Sample: 2006M08 2014M12

Included observations: 89

Lag	LogL	LR	FPE	AIC	SC	HQ
0	527.0739	NA	5.47e-11	-9.484807	-6.548776	-8.301377
1	758.7793	328.0324	5.48e-13	-14.12987	-10.49479*	-12.66467*
2	785.3508	34.63243	5.65e-13	-14.16519	-9.831044	-12.41822
3	821.3353	42.85797*	4.84e-13*	-14.41203	-9.378832	-12.38329
4	847.9958	28.75738	5.31e-13	-14.44934	-8.717091	-12.13884
5	863.3361	14.82325	7.88e-13	-14.23227	-7.800965	-11.64000
6	901.2365	32.36439	7.48e-13	-14.52217*	-7.391806	-11.64812

\* indicates lag order selected by the criterion

LR: sequential modified LR test statistic (each test at 5% level)

FPE: Final prediction error

AIC: Akaike information criterion

SC: Schwarz information criterion

HQ: Hannan-Quinn information criterion

*Fuente: Elaboración propia.*

**Imagen 10:** test de correlación serial en residuos VECM 6 meses trigo.

VAR Residual Serial Correlation LM Tests  
 Null Hypothesis: no serial correlation at lag order h  
 Date: 05/31/17 Time: 14:33  
 Sample: 2006M08 2014M12  
 Included observations: 92

Lags	LM-Stat	Prob
1	33.24042	0.1252
2	31.82286	0.1632
3	29.76595	0.2332
4	19.91229	0.7514
5	28.43898	0.2880
6	37.25110	0.0546
7	20.48791	0.7208
8	18.46562	0.8220
9	33.44390	0.1203
10	33.00302	0.1310
11	27.06019	0.3529
12	27.37893	0.3372

Probs from chi-square with 25 df.

*Fuente: Elaboración propia.*

**Imagen 11:** test normalidad VECM 6 meses trigo.

VAR Residual Normality Tests  
 Orthogonalization: Cholesky (Lutkepohl)  
 Null Hypothesis: residuals are multivariate normal  
 Date: 05/31/17 Time: 14:33  
 Sample: 2006M08 2014M12  
 Included observations: 92

Component	Skewness	Chi-sq	df	Prob.
1	0.124876	0.239109	1	0.6249
2	-0.001385	2.94E-05	1	0.9957
3	0.072670	0.080974	1	0.7760
4	0.110033	0.185645	1	0.6666
5	-0.140181	0.301310	1	0.5831
Joint		0.807066	5	0.9766

Component	Kurtosis	Chi-sq	df	Prob.
1	1.098271	13.86354	1	0.0002
2	1.237967	11.90158	1	0.0006
3	1.383304	10.01920	1	0.0015
4	1.388289	9.957514	1	0.0016
5	1.106874	13.73839	1	0.0002



Joint	59.48022	5	0.0000
Component	Jarque-Bera	Df	Prob.
1	14.10264	2	0.0009
2	11.90161	2	0.0026
3	10.10017	2	0.0064
4	10.14316	2	0.0063
5	14.03970	2	0.0009
Joint	60.28728	10	0.0000

*Fuente: Elaboración propia.*

**Imagen 12:** test heterocedasticidad en residuos VECM 6 meses trigo.

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Date: 05/31/17 Time: 14:33

Sample: 2006M08 2014M12

Included observations: 92

Joint test:

Chi-sq	df	Prob.
861.6877	870	0.5730

Individual components:

Dependent	R-squared	F(58,33)	Prob.	Chi-sq(58)	Prob.
res1*res1	0.683794	1.230384	0.2632	62.90902	0.3068
res2*res2	0.742206	1.638086	0.0641	68.28292	0.1674
res3*res3	0.595753	0.838504	0.7259	54.80926	0.5947
res4*res4	0.627756	0.959508	0.5643	57.75353	0.4844
res5*res5	0.681679	1.218430	0.2734	62.71446	0.3128
res2*res1	0.640033	1.011641	0.4964	58.88308	0.4430
res3*res1	0.552761	0.703208	0.8809	50.85401	0.7357
res3*res2	0.469311	0.503161	0.9891	43.17663	0.9267
res4*res1	0.645319	1.035194	0.4669	59.36932	0.4254
res4*res2	0.514715	0.603469	0.9542	47.35374	0.8398
res4*res3	0.505025	0.580518	0.9653	46.46230	0.8619
res5*res1	0.473756	0.512216	0.9872	43.58553	0.9200
res5*res2	0.516822	0.608584	0.9514	47.54767	0.8347
res5*res3	0.622447	0.938016	0.5930	57.26512	0.5026
res5*res4	0.612682	0.900022	0.6441	56.36673	0.5363

*Fuente: Elaboración propia.*

**Imagen 13: test Johansen VECM 6 meses trigo.**

Date: 05/31/17 Time: 14:34

Sample (adjusted): 2007M03 2014M12

Included observations: 94 after adjustments

Trend assumption: Linear deterministic trend

Series: CHI USA(-6) ARG(-6) USAMAIZ(-6) USASOYA(-6)

Exogenous series: ESTAC NOV7 DIC8 DIC11 DOLARREAL(-7) PETRO(-5) RATIO(-5) STOCKFINALM(-5) TONI IMPARG(-5) IMPMUNDO(-5) AEAD AEF AFAD ALTAD

Warning: Critical values assume no exogenous series

Lags interval (in first differences): No lags

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.423725	103.4318	69.81889	0.0000
At most 1 *	0.240255	51.62184	47.85613	0.0212
At most 2	0.177965	25.79318	29.79707	0.1350
At most 3	0.070140	7.371754	15.49471	0.5348
At most 4	0.005686	0.535967	3.841466	0.4641

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.423725	51.80996	33.87687	0.0002
At most 1	0.240255	25.82866	27.58434	0.0824
At most 2	0.177965	18.42142	21.13162	0.1149
At most 3	0.070140	6.835787	14.26460	0.5087
At most 4	0.005686	0.535967	3.841466	0.4641

Max-eigenvalue test indicates 1 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b\*S11\*b=I):

	CHI	USA(-6)	ARG(-6)	USAMAIZ(-6)	USASOYA(-6)
	1.790078	7.317131	-9.504947	-6.034675	1.613329
	-4.745477	12.35115	3.525665	1.377177	-2.072307
	3.135396	-0.417680	-1.452840	-1.650715	10.45442
	-5.410711	-5.021765	9.179827	-7.246904	4.693227
	-8.664677	0.210252	-11.82147	1.650207	1.885023

Unrestricted Adjustment Coefficients (alpha):

	D(CHI)	D(USA(-6))	D(ARG(-6))	D(USAMAIZ(-6))	D(USASOYA(-6))
	0.004308	0.008809	-0.008189	-0.001954	-0.002293
	0.025102	-0.027496	-0.015446	-0.003284	-0.001913
	0.038690	0.001266	0.003016	-0.003177	0.000113
	0.027348	-0.002811	-0.019458	0.003159	0.001352

D(USASOYA(-6))	0.018273	-0.002626	-0.014481	-0.009688	0.001313
<hr/>					
1 Cointegrating Equation(s):	Log likelihood	744.0657			
<hr/>					
Normalized cointegrating coefficients (standard error in parentheses)					
CHI	USA(-6)	ARG(-6)	USAMAIZ(-6)	USASOYA(-6)	
1.000000	4.087606	-5.309796	-3.371181	0.901262	
	(1.12162)	(1.34338)	(0.72833)	(0.88368)	
<hr/>					
Adjustment coefficients (standard error in parentheses)					
D(CHI)	0.007712				
	(0.00842)				
D(USA(-6))	0.044935				
	(0.01599)				
D(ARG(-6))	0.069258				
	(0.00965)				
D(USAMAIZ(-6))	0.048955				
	(0.01231)				
D(USASOYA(-6))	0.032711				
	(0.01172)				
<hr/>					

*Fuente: Elaboración propia.*

**Imagen 14:** test Granger VECM 6 meses trigo.

VEC Granger Causality/Block Exogeneity Wald Tests

Date: 05/31/17 Time: 14:34

Sample: 2006M08 2014M12

Included observations: 92

Dependent variable: D(CHI)

Excluded	Chi-sq	df	Prob.
D(USA(-6))	2.254549	2	0.3239
D(ARG(-6))	0.524921	2	0.7692
D(USAMAIZ(-6))	1.849296	2	0.3967
D(USASOYA(-6))	0.751719	2	0.6867
All	9.602216	8	0.2941

*Fuente: Elaboración propia.*

### Imagen 15: VECM 6 meses trigo.

Dependent Variable: D(CHI)

Method: Least Squares

Date: 05/31/17 Time: 14:35

Sample (adjusted): 2007M03 2014M12

Included observations: 94 after adjustments

$$D(CHI) = C(1) * (7.34336683978 * CHI(-1) + 3.19406498044 * USA(-7) - 13.4592264668 * ARG(-7) - 4.17410509836 * USAMAIZ(-7) + 37.076370175) + C(2) * D(CHI(-1)) + C(3) * D(CHI(-2)) + C(12) + C(13) * ESTAC + C(14) * NOV7 + C(15) * DIC8 + C(16) * DIC11 + C(17) * DOLARREAL(-7) + C(18) * PETRO(-5) + C(19) * RATIO(-5) + C(20) * STOCKFINALM(-5) + C(21) * TONI + C(22) * IMPARG(-5) + C(23) * IMPMUNDO(-5) + C(24) * AEAD + C(25) * AEF + C(26) * AFAD + C(27) * ALTAD + C(28) * ALTAF + C(29) * ALTAE + C(30) * BAJAD + C(31) * BAJAE + C(32) * BAJAF$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	-0.000906	0.004691	-0.193228	0.8473
C(2)	0.170302	0.117749	1.446316	0.1526
C(3)	-0.004274	0.116669	-0.036634	0.9709
C(12)	0.322879	1.050753	0.307284	0.7595
C(13)	0.102640	0.125024	0.820958	0.4145
C(14)	-0.132636	0.058791	-2.256053	0.0272
C(15)	-0.126826	0.052622	-2.410114	0.0186
C(16)	-0.184530	0.053256	-3.464940	0.0009
C(17)	-0.021411	0.123648	-0.173161	0.8630
C(18)	0.008952	0.048826	0.183339	0.8551
C(19)	0.221751	0.109836	2.018931	0.0473
C(20)	-0.203163	0.116596	-1.742448	0.0858
C(21)	0.001550	0.004209	0.368348	0.7137
C(22)	-0.001140	0.001681	-0.678123	0.4999
C(23)	0.022445	0.010562	2.125082	0.0371
C(24)	0.001539	0.063947	0.024073	0.9809
C(25)	0.053311	0.076195	0.699668	0.4865
C(26)	0.045244	0.069887	0.647389	0.5195
C(27)	0.007405	0.035242	0.210103	0.8342
C(28)	-0.028656	0.049954	-0.573638	0.5681
C(29)	-0.019163	0.039002	-0.491324	0.6247
C(30)	-0.021447	0.049462	-0.433605	0.6659
C(31)	0.058802	0.055772	1.054332	0.2954
C(32)	0.027633	0.050283	0.549548	0.5844
R-squared	0.490818	Mean dependent var		0.001778
Adjusted R-squared	0.323516	S.D. dependent var		0.056795
S.E. of regression	0.046714	Akaike info criterion		-3.073726
Sum squared resid	0.152751	Schwarz criterion		-2.424375
Log likelihood	168.4651	Hannan-Quinn criter.		-2.811436
F-statistic	2.933715	Durbin-Watson stat		1.885444
Prob(F-statistic)	0.000289			

Fuente: Elaboración propia.

**Imagen 16:** test de rezagos VECM 1 mes maíz.

VAR Lag Order Selection Criteria

Endogenous variables: CHI FUTUROSMAIZ ARG(-1) FUTUROSTRIGO FUTUROSSOYA  
FUTUROSETH

Exogenous variables: C ESTAC NOV7 DIC8 DIC11 DOLAR FUTUROSPETRO RATIO STOCK TONI  
IMPARG IMPMUNDO MAIZETH AMR AAB AMY ABAMYA MRAMYA

Date: 06/02/17 Time: 12:44

Sample: 2006M08 2014M12

Included observations: 94

Lag	LogL	LR	FPE	AIC	SC	HQ
0	543.7293	NA	3.90e-12	-9.270836	-6.348752	-8.090528
1	757.9332	319.0272	9.17e-14*	-13.06241	-9.166298*	-11.48867*
2	781.9808	32.74564	1.27e-13	-12.80810	-7.937963	-10.84092
3	816.0030	41.98479	1.47e-13	-12.76602	-6.921854	-10.40540
4	860.9402	49.71778	1.43e-13	-12.95617	-6.137980	-10.20212
5	913.5833	51.52303	1.26e-13	-13.31028	-5.518060	-10.16280
6	974.8552	52.14630*	1.01e-13	-13.84798*	-5.081733	-10.30706

\* indicates lag order selected by the criterion

LR: sequential modified LR test statistic (each test at 5% level)

FPE: Final prediction error

AIC: Akaike information criterion

SC: Schwarz information criterion

HQ: Hannan-Quinn information criterion

*Fuente: Elaboración propia.*

**Imagen 17:** test de correlación serial en residuos VECM1 mes maíz.

VAR Residual Serial Correlation LM Tests

Null Hypothesis: no serial correlation at lag  
order h

Date: 06/02/17 Time: 12:45

Sample: 2006M08 2014M12

Included observations: 99

Lags	LM-Stat	Prob
1	43.34554	0.1866
2	26.20291	0.8848
3	44.19005	0.1641
4	38.72972	0.3475
5	39.61897	0.3117
6	47.89977	0.0887
7	24.48696	0.9272
8	51.15201	0.0485
9	41.75708	0.2348
10	31.15559	0.6982
11	19.85731	0.9866
12	70.88485	0.0005

Probs from chi-square with 36 df.

*Fuente: Elaboración propia.*

**Imagen 18:** test normalidad VECM 1 mes maíz.

VAR Residual Normality Tests  
 Orthogonalization: Cholesky (Lutkepohl)  
 Null Hypothesis: residuals are multivariate normal  
 Date: 06/02/17 Time: 12:45  
 Sample: 2006M08 2014M12  
 Included observations: 99

Component	Skewness	Chi-sq	df	Prob.
1	-0.307704	1.562245	1	0.2113
2	0.255452	1.076721	1	0.2994
3	0.263521	1.145814	1	0.2844
4	-0.081284	0.109016	1	0.7413
5	0.199604	0.657391	1	0.4175
6	-0.028505	0.013406	1	0.9078
Joint		4.564594	6	0.6007

Component	Kurtosis	Chi-sq	df	Prob.
1	2.952259	0.009402	1	0.9228
2	3.544260	1.221902	1	0.2690
3	1.943184	4.607049	1	0.0318
4	1.551282	8.657488	1	0.0033
5	2.074249	3.535188	1	0.0601
6	2.597576	0.668024	1	0.4137
Joint		18.69905	6	0.0047

Component	Jarque-Bera	df	Prob.
1	1.571647	2	0.4557
2	2.298624	2	0.3169
3	5.752863	2	0.0563
4	8.766504	2	0.0125
5	4.192579	2	0.1229
6	0.681430	2	0.7113
Joint	23.26365	12	0.0256

*Fuente: Elaboración propia.*

**Imagen 18:** test heterocedasticidad en residuos VECM 1 mes maíz.

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Date: 06/02/17 Time: 12:45

Sample: 2006M08 2014M12

Included observations: 99

Joint test:

Chi-sq	df	Prob.
757.2764	798	0.8462

Individual components:

Dependent	R-squared	F(38,60)	Prob.	Chi-sq(38)	Prob.
res1*res1	0.346722	0.838013	0.7168	34.32547	0.6401
res2*res2	0.604229	2.410605	0.0011	59.81871	0.0135
res3*res3	0.420462	1.145546	0.3138	41.62573	0.3158
res4*res4	0.339754	0.812504	0.7506	33.63561	0.6714
res5*res5	0.548884	1.921143	0.0115	54.33950	0.0416
res6*res6	0.338836	0.809185	0.7549	33.54474	0.6755
res2*res1	0.269564	0.582702	0.9612	26.68680	0.9156
res3*res1	0.348010	0.842787	0.7103	34.45295	0.6342
res3*res2	0.493547	1.538712	0.0665	48.86117	0.1115
res4*res1	0.365063	0.907831	0.6198	36.14125	0.5556
res4*res2	0.515864	1.682423	0.0350	51.07051	0.0764
res4*res3	0.348893	0.846071	0.7059	34.54038	0.6302
res5*res1	0.265118	0.569625	0.9669	26.24666	0.9252
res5*res2	0.552346	1.948215	0.0101	54.68228	0.0390
res5*res3	0.401663	1.059947	0.4130	39.76467	0.3914
res5*res4	0.500450	1.581795	0.0550	49.54459	0.0995
res6*res1	0.343337	0.825555	0.7335	33.99038	0.6554
res6*res2	0.254977	0.540380	0.9775	25.24273	0.9441
res6*res3	0.440718	1.244219	0.2210	43.63104	0.2444
res6*res4	0.366633	0.913994	0.6110	36.29664	0.5484
res6*res5	0.371164	0.931956	0.5857	36.74520	0.5274

*Fuente: Elaboración propia.*

**Imagen 19: test Johansen VECM 1 mes maíz.**

Date: 06/02/17 Time: 12:45

Sample (adjusted): 2006M10 2014M12

Included observations: 99 after adjustments

Trend assumption: Linear deterministic trend

Series: CHI FUTUROSMAIZ ARG(-1) FUTUROSTRIGO FUTUROSSOYA

FUTUROSETH

Exogenous series: ESTAC NOV7 DIC8 DIC11 DOLAR FUTUROSPETRO RATIO STOCK TONI IMPARG IMPMUNDO

MAIZETH AMR AAB AMY ABAMYA

Warning: Critical values assume no exogenous series

Lags interval (in first differences): No lags

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.514502	212.8275	95.75366	0.0000
At most 1 *	0.413514	141.2921	69.81889	0.0000
At most 2 *	0.364261	88.46499	47.85613	0.0000
At most 3 *	0.222808	43.62121	29.79707	0.0007
At most 4 *	0.133656	18.66644	15.49471	0.0161
At most 5 *	0.044076	4.462629	3.841466	0.0346

Trace test indicates 6 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.514502	71.53538	40.07757	0.0000
At most 1 *	0.413514	52.82710	33.87687	0.0001
At most 2 *	0.364261	44.84378	27.58434	0.0001
At most 3 *	0.222808	24.95478	21.13162	0.0138
At most 4	0.133656	14.20381	14.26460	0.0511
At most 5 *	0.044076	4.462629	3.841466	0.0346

Max-eigenvalue test indicates 4 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b\*S11\*b=I):

	CHI	FUTUROSMAIZ	ARG(-1)	FUTUROSTRIG O	FUTUROSSOYA	FUTUROSETH
	13.72320	1.789907	-11.07683	-0.535948	-2.677480	3.673885
	-4.143203	-0.874326	5.193464	4.131180	-5.166765	5.290029
	-12.53652	1.443640	-1.689693	2.823195	-1.448267	0.793384
	-0.896031	4.076274	3.431192	2.078109	-9.779890	-5.584085
	-0.187876	-3.084890	-1.383166	7.400978	-0.647664	-4.803225
	0.343949	4.479408	5.431753	3.554219	-2.849888	-0.122282

Unrestricted Adjustment Coefficients (alpha):



D(CHI)	-0.007957	0.008176	0.020727	-0.004325	-4.96E-05	-0.002021
D(FUTUROSMAI Z)	0.014452	0.034578	-0.022969	0.008708	-0.000633	-0.028348
D(ARG(-1))	0.047706	-0.010201	0.006680	-0.000925	0.000670	-0.001893
D(FUTUROSTRIG GO)	-0.020167	-0.036399	0.005916	0.002215	-0.024345	-0.009304
D(FUTUROSSO YA)	0.008421	0.028045	-0.005042	0.027236	-0.013168	-0.013773
D(FUTUROSET H)	-0.012381	-0.049207	0.005526	0.029126	0.011394	-0.008050

1 Cointegrating Equation(s):      Log likelihood      695.1941

Normalized cointegrating coefficients (standard error in parentheses)

	CHI	FUTUROSMAIZ	ARG(-1)	FUTUROSTRIG O	FUTUROSSOYA	FUTUROSETH
	1.000000	0.130429 (0.05674)	-0.807161 (0.09005)	-0.039054 (0.07316)	-0.195106 (0.09301)	0.267713 (0.07655)

Adjustment coefficients (standard error in parentheses)

D(CHI)	-0.109194 (0.06056)
D(FUTUROSMAI Z)	0.198323 (0.23181)
D(ARG(-1))	0.654679 (0.07790)
D(FUTUROSTRIG GO)	-0.276753 (0.15327)
D(FUTUROSSO YA)	0.115564 (0.15970)
D(FUTUROSET H)	-0.169912 (0.16933)

*Fuente: Elaboración propia.*

### Imagen 21: VECM 1 mes maíz.

Dependent Variable: D(CHI)

Method: Least Squares

Date: 06/02/17 Time: 12:46

Sample (adjusted): 2006M10 2014M12

Included observations: 99 after adjustments

$$\begin{aligned}
 D(CHI) = & C(1)*(13.0797587372*CHI(-1) + 1.82729647402*FUTUROSMAIZ(-1) - 10.2882417725*ARG(-2) - 3.72982973938*FUTUROSSOYA(-1) + \\
 & 3.98706048025*FUTUROSETH(-1) - 3.53687358743) + C(2) + C(3) \\
 & *ESTAC + C(4)*NOV7 + C(5)*DIC8 + C(6)*DIC11 + C(7)*DOLAR + C(8) \\
 & *FUTUROSPETRO + C(9)*RATIO + C(10)*STOCK + C(11)*TONI + \\
 & C(12)*IMPARG + C(13)*IMPMUNDO + C(14)*MAIZETH + C(15)*AMR + \\
 & C(16)*AAB + C(17)*AMY + C(18)*ABAMYA + C(19)*MRAMYA
 \end{aligned}$$

Coefficient	Std. Error	t-Statistic	Prob.
-------------	------------	-------------	-------

C(1)	-0.006962	0.004457	-1.562023	0.1222
C(2)	-0.817738	0.935405	-0.874207	0.3846
C(3)	0.588679	0.229224	2.568136	0.0121
C(4)	0.009019	0.045994	0.196097	0.8450
C(5)	0.000931	0.048036	0.019386	0.9846
C(6)	-0.008532	0.047867	-0.178254	0.8590
C(7)	-0.058309	0.108497	-0.537427	0.5925
C(8)	0.036975	0.038182	0.968392	0.3358
C(9)	-0.023743	0.008298	-2.861358	0.0054
C(10)	0.238968	0.075738	3.155174	0.0023
C(11)	0.002956	0.003935	0.751246	0.4547
C(12)	-0.003264	0.002720	-1.199728	0.2338
C(13)	-0.001064	0.004212	-0.252610	0.8012
C(14)	-0.077058	0.026417	-2.917003	0.0046
C(15)	-0.015771	0.024788	-0.636233	0.5264
C(16)	0.027021	0.029644	0.911506	0.3648
C(17)	0.016777	0.025248	0.664476	0.5083
C(18)	-0.044831	0.058074	-0.771961	0.4424
C(19)	0.024950	0.051944	0.480326	0.6323
<hr/>				
R-squared	0.311617	Mean dependent var	0.001805	
Adjusted R-squared	0.156731	S.D. dependent var	0.048238	
S.E. of regression	0.044296	Akaike info criterion	-3.225081	
Sum squared resid	0.156974	Schwarz criterion	-2.727027	
Log likelihood	178.6415	Hannan-Quinn criter.	-3.023568	
F-statistic	2.011914	Durbin-Watson stat	1.589361	
Prob(F-statistic)	0.018087			

*Fuente: Elaboración propia.*

**Imagen 22:** test de rezagos VECM 3 meses maíz.

VAR Lag Order Selection Criteria

Endogenous variables: CHI USA(-3) ARG(-3) USATRIGO(-3) USASOYA(-3) PRECIOETH(-3)

Exogenous variables: C ESTAC NOV7 DIC8 DIC11 DOLARREAL(-4) PETRO(-3) RATIO(-2) STOCK(-2) TONI(-2) IMPARG(-2) IMPMUNDO(-2) MAIZETH(-2) AMR AAB AMY ABAMYA MRAMYA

Date: 05/31/17 Time: 13:23

Sample: 2006M08 2014M12

Included observations: 92

Lag	LogL	LR	FPE	AIC	SC	HQ
0	676.9264	NA	1.77e-13	-12.36797	-9.407605	-11.17314
1	935.9895	382.9628	1.45e-15	-17.21716	-13.27002*	-15.62406
2	1003.560	91.07375*	7.84e-16*	-17.90349	-12.96955	-15.91211*
3	1041.018	45.60104	8.53e-16	-17.93518	-12.01446	-15.54553
4	1080.329	42.72912	9.43e-16	-18.00716	-11.09965	-15.21923
5	1126.479	44.14330	9.68e-16	-18.22780	-10.33351	-15.04160
6	1185.816	49.01782	8.26e-16	-18.73514*	-9.854056	-15.15066

*Fuente: Elaboración propia.*

**Imagen 23:** test de correlación serial en residuos VECM 3 meses maíz.

VAR Residual Serial Correlation LM Tests  
 Null Hypothesis: no serial correlation at lag order h  
 Date: 05/31/17 Time: 13:23  
 Sample: 2006M08 2014M12  
 Included observations: 96

Lags	LM-Stat	Prob
1	46.32812	0.1162
2	51.15264	0.0485
3	40.65545	0.2728
4	31.00250	0.7051
5	30.21403	0.7397
6	44.07456	0.1671
7	26.64275	0.8719
8	27.54958	0.8429
9	32.28426	0.6460
10	31.96131	0.6611
11	32.68524	0.6270
12	28.82908	0.7964

Probs from chi-square with 36 df.

*Fuente: Elaboración propia.*

**Imagen 24:** test normalidad VECM 3 meses maíz.

VAR Residual Normality Tests  
 Orthogonalization: Cholesky (Lutkepohl)  
 Null Hypothesis: residuals are multivariate normal  
 Date: 05/31/17 Time: 13:24  
 Sample: 2006M08 2014M12  
 Included observations: 96

Component	Skewness	Chi-sq	df	Prob.
1	-0.120575	0.232612	1	0.6296
2	0.016645	0.004433	1	0.9469
3	0.016935	0.004589	1	0.9460
4	-0.040722	0.026533	1	0.8706
5	-0.118029	0.222894	1	0.6368
6	0.758295	9.200173	1	0.0024
Joint		9.691233	6	0.1383

Component	Kurtosis	Chi-sq	df	Prob.
1	1.976106	4.193433	1	0.0406
2	1.896544	4.870458	1	0.0273
3	1.321419	11.27053	1	0.0008
4	1.553045	8.374716	1	0.0038

5	1.311399	11.40550	1	0.0007
6	3.665093	1.769395	1	0.1835
Joint		41.88403	6	0.0000

Component	Jarque-Bera	df	Prob.	
1	4.426045	2	0.1094	
2	4.874891	2	0.0874	
3	11.27512	2	0.0036	
4	8.401249	2	0.0150	
5	11.62839	2	0.0030	
6	10.96957	2	0.0041	
Joint		51.57526	12	0.0000

*Fuente: Elaboración propia.*

**Imagen 25:** test heterocedasticidad en residuos VECM 3 meses maíz.

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Date: 05/31/17 Time: 13:24

Sample: 2006M08 2014M12

Included observations: 96

Joint test:

Chi-sq	df	Prob.
1030.993	1050	0.6564

Individual components:

Dependent	R-squared	F(50,45)	Prob.	Chi-sq(50)	Prob.
res1*res1	0.438867	0.703898	0.8864	42.13125	0.7778
res2*res2	0.674905	1.868424	0.0176	64.79091	0.0779
res3*res3	0.524160	0.991391	0.5138	50.31934	0.4607
res4*res4	0.627643	1.517035	0.0791	60.25373	0.1519
res5*res5	0.661904	1.761963	0.0279	63.54275	0.0945
res6*res6	0.455095	0.751664	0.8372	43.68911	0.7232
res2*res1	0.546719	1.085522	0.3914	52.48500	0.3779
res3*res1	0.447177	0.728006	0.8627	42.92896	0.7505
res3*res2	0.505926	0.921590	0.6121	48.56890	0.5309
res4*res1	0.631793	1.544275	0.0706	60.65209	0.1438
res4*res2	0.634952	1.565426	0.0647	60.95535	0.1379
res4*res3	0.576600	1.225648	0.2452	55.35357	0.2798
res5*res1	0.594110	1.317349	0.1750	57.03454	0.2300
res5*res2	0.632332	1.547859	0.0696	60.70385	0.1428
res5*res3	0.575220	1.218744	0.2513	55.22112	0.2840
res5*res4	0.665482	1.790438	0.0247	63.88627	0.0897
res6*res1	0.584628	1.266734	0.2114	56.12432	0.2562

res6*res2	0.560686	1.148648	0.3197	53.82584	0.3301
res6*res3	0.496597	0.887833	0.6601	47.67334	0.5673
res6*res4	0.611372	1.415839	0.1193	58.69171	0.1870
res6*res5	0.518690	0.969898	0.5437	49.79427	0.4816

*Fuente: Elaboración propia.*

**Imagen 26:** test Johansen VECM 3 meses maíz.

Date: 05/31/17 Time: 13:25  
Sample (adjusted): 2007M01 2014M12  
Included observations: 96 after adjustments  
Trend assumption: Linear deterministic trend  
Series: CHI USA(-3) ARG(-3) USATRIGO(-3) USASOYA(-3) PRECIOETH(-3)  
Exogenous series: ESTAC NOV7 DIC8 DIC11 DOLARREAL(-4) PETRO(-3) RATIO(-2) STOCK(-2) TONI(-2) IMPARG(-2)  
IMPMUNDO(-2) MAIZETH(-2) AMR AAB AMY  
Warning: Critical values assume no exogenous series  
Lags interval (in first differences): 1 to 1

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.606493	226.7417	95.75366	0.0000
At most 1 *	0.443770	137.2067	69.81889	0.0000
At most 2 *	0.333653	80.89556	47.85613	0.0000
At most 3 *	0.206277	41.92481	29.79707	0.0013
At most 4 *	0.133328	19.74680	15.49471	0.0107
At most 5 *	0.060682	6.009730	3.841466	0.0142

Trace test indicates 6 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.606493	89.53508	40.07757	0.0000
At most 1 *	0.443770	56.31110	33.87687	0.0000
At most 2 *	0.333653	38.97075	27.58434	0.0011
At most 3 *	0.206277	22.17801	21.13162	0.0355
At most 4 *	0.133328	13.73707	14.26460	0.0604
At most 5 *	0.060682	6.009730	3.841466	0.0142

Max-eigenvalue test indicates 4 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b\*S11\*b=I):

CHI	USA(-3)	ARG(-3)	USATRIGO(-3)	USASOYA(-3)	PRECIOETH(-3)
25.79648	-4.384245	-4.425380	-5.028518	0.079838	3.337176

7.522398	-17.80165	24.42709	-3.901405	5.721941	-7.427934
-6.236889	13.11845	1.409298	-0.300556	-0.454125	-3.279640
0.805667	9.804744	-5.499711	7.156374	-8.961493	-8.609289
0.504371	-3.890346	11.71873	0.732378	-10.59181	3.652466
2.071736	-9.351593	6.228592	7.713231	1.623443	5.016006

---



---

Unrestricted Adjustment Coefficients (alpha):

---



---

D(CHI)	-0.020401	0.001743	-0.009987	-0.003349	0.002091	-0.005525
D(USA(-3))	0.023719	0.002932	-0.026940	0.010535	0.007231	-0.002002
D(ARG(-3))	0.001471	-0.016185	-0.002853	0.002415	-0.008794	-0.002384
D(USATRIGO(-3))	0.033528	0.004062	-0.009698	7.16E-05	0.008032	-0.013286
D(USASOYA(-3))	0.009682	-0.008483	-0.006583	0.017949	0.012982	-0.003945
D(PRECIOETH(-3))	0.015219	0.042039	-0.013125	0.027526	-0.007334	-0.008707

---



---

1 Cointegrating Equation(s):      Log likelihood      931.3865

---



---

Normalized cointegrating coefficients (standard error in parentheses)

CHI	USA(-3)	ARG(-3)	USATRIGO(-3)	USASOYA(-3)	PRECIOETH(-3)
1.000000	-0.169955	-0.171550	-0.194930	0.003095	0.129366
	(0.08602)	(0.10448)	(0.04135)	(0.05496)	(0.04979)

Adjustment coefficients (standard error in parentheses)

D(CHI)	-0.526278
	(0.10310)
D(USA(-3))	0.611877
	(0.18004)
D(ARG(-3))	0.037954
	(0.10962)
D(USATRIGO(-3))	0.864916
	(0.20121)
D(USASOYA(-3))	0.249759
	(0.17696)
D(PRECIOETH(-3))	0.392590
	(0.30155)

---



---

*Fuente: Elaboración propia.*

**Imagen 27: test Granger VECM 3 meses maíz.**

VEC Granger Causality/Block Exogeneity Wald Tests

Date: 05/31/17 Time: 13:25

Sample: 2006M08 2014M12

Included observations: 96

Dependent variable: D(CHI)

Excluded	Chi-sq	df	Prob.
D(USA(-3))	0.488593	1	0.4846
D(ARG(-3))	0.984327	1	0.3211
D(USATRIGO(-3))	0.038486	1	0.8445
D(USASOYA(-3))	0.033813	1	0.8541
D(PRECIOETH(-3))	0.479221	1	0.4888
All	2.902117	5	0.7151

*Fuente: Elaboración propia.*

**Imagen 28: VECM 3 meses maíz.**

Dependent Variable: D(CHI)

Method: Least Squares

Date: 05/31/17 Time: 13:26

Sample (adjusted): 2006M12 2014M12

Included observations: 97 after adjustments

$D(CHI) = C(1) * ( 18.2893646035 * CHI(-1) - 4.52554349986 * USATRIGO(-4) + 0.032512381821 * PRECIOETH(-4) - 76.3672576971 ) + C(2) * D(CHI(-1)) + C(8) + C(9) * ESTAC + C(10) * NOV7 + C(11) * DIC8 + C(12) * DIC11 + C(13) * DOLARREAL(-4) + C(14) * PETRO(-3) + C(15) * RATIO(-2) + C(16) * STOCK(-2) + C(17) * TONI(-2) + C(18) * IMPARG(-2) + C(19) * IMPMUNDO(-2) + C(20) * MAIZETH(-2) + C(21) * AMR + C(22) * AAB + C(23) * AMY + C(24) * ABAMYA + C(25) * MRAMYA$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	-0.024788	0.004360	-5.685868	0.0000
C(2)	0.213565	0.105534	2.023662	0.0465
C(8)	-0.640701	0.624083	-1.026628	0.3078
C(9)	0.945600	0.223993	4.221563	0.0001
C(10)	0.033030	0.039063	0.845552	0.4004
C(11)	-0.006327	0.040077	-0.157873	0.8750
C(12)	-0.045219	0.039075	-1.157248	0.2507
C(13)	-0.080636	0.073042	-1.103958	0.2730
C(14)	-0.000282	0.028374	-0.009940	0.9921
C(15)	-0.008990	0.007037	-1.277614	0.2052
C(16)	0.056316	0.060972	0.923637	0.3586
C(17)	0.015322	0.003920	3.908293	0.0002
C(18)	0.001259	0.002279	0.552456	0.5822
C(19)	0.001463	0.003834	0.381579	0.7038

C(20)	-0.009956	0.018190	-0.547356	0.5857
C(21)	-0.015861	0.020781	-0.763229	0.4477
C(22)	0.051157	0.024345	2.101323	0.0389
C(23)	0.006937	0.022002	0.315307	0.7534
C(24)	-0.013054	0.052916	-0.246699	0.8058
C(25)	0.058521	0.044868	1.304299	0.1960
<hr/>				
R-squared	0.428759	Mean dependent var	-0.000944	
Adjusted R-squared	0.287804	S.D. dependent var	0.044567	
S.E. of regression	0.037611	Akaike info criterion	-3.541570	
Sum squared resid	0.108924	Schwarz criterion	-3.010702	
Log likelihood	191.7661	Hannan-Quinn criter.	-3.326913	
F-statistic	3.041804	Durbin-Watson stat	1.956195	
Prob(F-statistic)	0.000297			

*Fuente: Elaboración propia.*

**Imagen 29:** test de rezagos VECM 6 meses maíz.

VAR Lag Order Selection Criteria  
 Endogenous variables: CHI USA(-6) ARG(-6) USATRIGO(-6) USASOYA(-6) PRECIOETH(-6)  
 Exogenous variables: C ESTAC NOV7 DIC8 DIC11 DOLARREAL(-7) PETRO(-5) RATIO(-5) STOCK(-5) TONI IMPARG(-5) IMPMUNDO(-5) MAIZETH(-5) AMR AAB AMY ABAMYA MRAMYA  
 Date: 05/31/17 Time: 16:09  
 Sample: 2006M08 2014M12  
 Included observations: 92

Lag	LogL	LR	FPE	AIC	SC	HQ
0	649.6912	NA	3.19e-13	-11.77589	-8.815534	-10.58107
1	906.3185	379.3622	2.76e-15	-16.57214	-12.62499*	-14.97904
2	967.0688	81.88087*	1.73e-15*	-17.11019*	-12.17626	-15.11881*
3	996.2262	35.49595	2.26e-15	-16.96144	-11.04072	-14.57179

\* indicates lag order selected by the criterion  
 LR: sequential modified LR test statistic (each test at 5% level)  
 FPE: Final prediction error  
 AIC: Akaike information criterion  
 SC: Schwarz information criterion  
 HQ: Hannan-Quinn information criterion

*Fuente: Elaboración propia.*

**Imagen 30:** test de correlación serial en residuos VECM 6 meses maíz.

VAR Residual Serial Correlation LM Tests  
 Null Hypothesis: no serial correlation at lag order h  
 Date: 05/31/17 Time: 16:09  
 Sample: 2006M08 2014M12  
 Included observations: 93

Lags	LM-Stat	Prob
1	44.93692	0.1459



2	31.85023	0.6663
3	29.09148	0.7861
4	33.30621	0.5974
5	52.39260	0.0380
6	30.28418	0.7367
7	24.39992	0.9290
8	38.76298	0.3461
9	40.92119	0.2633
10	39.19508	0.3285
11	47.31263	0.0983
12	32.08051	0.6556

Probs from chi-square with 36 df.

*Fuente: Elaboración propia.*

**Imagen 31:** test normalidad VECM 6 meses maíz.

VAR Residual Normality Tests  
 Orthogonalization: Cholesky (Lutkepohl)  
 Null Hypothesis: residuals are multivariate normal  
 Date: 05/31/17 Time: 16:09  
 Sample: 2006M08 2014M12  
 Included observations: 93

Component	Skewness	Chi-sq	df	Prob.
1	0.143764	0.320357	1	0.5714
2	0.006773	0.000711	1	0.9787
3	-0.063826	0.063144	1	0.8016
4	-0.029855	0.013816	1	0.9064
5	-0.152240	0.359243	1	0.5489
6	0.632420	6.199307	1	0.0128
Joint		6.956578	6	0.3249

Component	Kurtosis	Chi-sq	df	Prob.
1	2.158471	2.744163	1	0.0976
2	1.735730	6.193719	1	0.0128
3	1.566350	7.964493	1	0.0048
4	1.423981	9.624869	1	0.0019
5	1.551834	8.126585	1	0.0044
6	3.248419	0.239133	1	0.6248
Joint		34.89296	6	0.0000

Component	Jarque-Bera	df	Prob.
1	3.064520	2	0.2160
2	6.194430	2	0.0452
3	8.027637	2	0.0181
4	9.638684	2	0.0081

5	8.485829	2	0.0144
6	6.438440	2	0.0400
Joint	41.84954	12	0.0000

*Fuente: Elaboración propia.*

**Imagen 32:** test de heterocedasticidad en residuos VECM 6 meses maíz.

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Date: 05/31/17 Time: 16:10

Sample: 2006M08 2014M12

Included observations: 93

Joint test:

Chi-sq	df	Prob.
1085.042	1050	0.2204

Individual components:

Dependent	R-squared	F(50,42)	Prob.	Chi-sq(50)	Prob.
res1*res1	0.526763	0.935008	0.5927	48.98893	0.5139
res2*res2	0.608438	1.305253	0.1890	56.58471	0.2427
res3*res3	0.594306	1.230527	0.2465	55.27048	0.2824
res4*res4	0.567465	1.102041	0.3755	52.77428	0.3673
res5*res5	0.641878	1.505567	0.0879	59.69463	0.1638
res6*res6	0.491073	0.810532	0.7630	45.66982	0.6476
res2*res1	0.486826	0.796871	0.7803	45.27479	0.6631
res3*res1	0.674235	1.738547	0.0341	62.70387	0.1072
res3*res2	0.508072	0.867567	0.6868	47.25070	0.5844
res4*res1	0.597636	1.247660	0.2322	55.58012	0.2727
res4*res2	0.593995	1.228939	0.2478	55.24152	0.2833
res4*res3	0.630776	1.435039	0.1159	58.66213	0.1877
res5*res1	0.588896	1.203278	0.2706	54.76732	0.2985
res5*res2	0.569175	1.109748	0.3667	52.93328	0.3616
res5*res3	0.575833	1.140352	0.3330	53.55247	0.3396
res5*res4	0.593164	1.224716	0.2515	55.16429	0.2858
res6*res1	0.479249	0.773055	0.8094	44.57016	0.6903
res6*res2	0.522408	0.918823	0.6154	48.58392	0.5303
res6*res3	0.547533	1.016489	0.4815	50.92057	0.4372
res6*res4	0.553639	1.041886	0.4486	51.48846	0.4153
res6*res5	0.455019	0.701339	0.8856	42.31681	0.7716

*Fuente: Elaboración propia.*

### Imagen 33: test Johansen VECM 6 meses maíz.

Date: 05/31/17 Time: 16:10

Sample (adjusted): 2007M05 2014M12

Included observations: 92 after adjustments

Trend assumption: Linear deterministic trend

Series: CHI USA(-6) ARG(-6) USATRIGO(-6) USASOYA(-6) PRECIOETH(-6)

Exogenous series: ESTAC NOV7 DIC8 DIC11 DOLARREAL(-7) PETRO(-5) RATIO(-5) STOCK(-5) TONI IMPARG(-5)

IMPMUNDO(-5) MAIZETH(-5) AMR AAB AMY ABAMYA

Warning: Critical values assume no exogenous series

Lags interval (in first differences): 1 to 2

#### Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.558618	189.4803	95.75366	0.0000
At most 1 *	0.474815	114.2387	69.81889	0.0000
At most 2 *	0.258954	54.99029	47.85613	0.0092
At most 3	0.142709	27.41855	29.79707	0.0918
At most 4	0.097265	13.25257	15.49471	0.1059
At most 5	0.040865	3.838521	3.841466	0.0501

Trace test indicates 3 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

#### Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.558618	75.24161	40.07757	0.0000
At most 1 *	0.474815	59.24837	33.87687	0.0000
At most 2	0.258954	27.57174	27.58434	0.0502
At most 3	0.142709	14.16598	21.13162	0.3516
At most 4	0.097265	9.414047	14.26460	0.2533
At most 5	0.040865	3.838521	3.841466	0.0501

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

#### Unrestricted Cointegrating Coefficients (normalized by b\*S11\*b=I):

	CHI	USA(-6)	ARG(-6)	USATRIGO(-6)	USASOYA(-6)	PRECIOETH(-6)
	-4.498220	17.65338	-20.15555	10.48315	-16.61567	-0.396608
	-12.95851	-12.14629	28.54536	3.491978	-1.056471	-11.69468
	-16.14275	5.453092	-3.997602	-5.236472	8.707664	5.173221
	-6.860611	3.133913	-7.132442	-9.069694	5.167733	-4.018895
	-7.077499	-3.915296	-3.664794	6.476548	8.250659	-3.691838
	-4.347032	19.30686	-7.530832	-2.947878	-0.126927	-11.04866

#### Unrestricted Adjustment Coefficients (alpha):

D(CHI)	0.019746	0.014259	0.001705	0.004830	-0.000646	-0.001012
D(USA(-6))	0.008443	-0.006226	-0.024359	-0.002400	0.000202	-0.005419
D(ARG(-6))	0.011352	-0.017572	-0.001479	0.005427	0.002162	0.001913
D(USATRIGO(-6))	-0.003282	-0.009468	-0.026006	0.006574	-0.013901	0.000193
D(USASOYA(-6))	0.018657	-0.002100	-0.017344	-0.009755	-0.005735	0.000322
D(PRECIOETH(-6))	-0.010588	0.012369	-0.042060	0.008012	0.008515	0.005235

1 Cointegrating Equation(s):      Log likelihood      931.1038

Normalized cointegrating coefficients (standard error in parentheses)

CHI	USA(-6)	ARG(-6)	USATRIGO(-6)	USASOYA(-6)	PRECIOETH(-6)
1.000000	-3.924525 (0.74159)	4.480783 (0.91792)	-2.330511 (0.42114)	3.693832 (0.50839)	0.088170 (0.40733)

Adjustment coefficients (standard error in parentheses)

D(CHI)	-0.088823 (0.01752)
D(USA(-6))	-0.037978 (0.03226)
D(ARG(-6))	-0.051065 (0.01899)
D(USATRIGO(-6))	0.014761 (0.04079)
D(USASOYA(-6))	-0.083923 (0.02830)
D(PRECIOETH(-6))	0.047629 (0.05452)

*Fuente: Elaboración propia.*

### Imagen 34: test Granger VECM 6 meses maíz.

VEC Granger Causality/Block Exogeneity Wald Tests

Date: 05/31/17 Time: 16:12

Sample: 2006M08 2014M12

Included observations: 93

Dependent variable: D(CHI)

Excluded	Chi-sq	df	Prob.
D(USA(-6))	0.216617	1	0.6416
D(ARG(-6))	1.029911	1	0.3102
D(USATRIGO(-6))	0.089978	1	0.7642
D(USASOYA(-6))	3.623579	1	0.0570
D(PRECIOETH(-6))	9.415574	1	0.0022

All	20.10666	5	0.0012
-----	----------	---	--------

*Fuente: Elaboración propia.*

**Imagen 36: VECM 6 meses maíz.**

Date: 05/31/17 Time: 16:13

Sample (adjusted): 2007M04 2014M12

Included observations: 93 after adjustments

$D(\text{CHI}) = C(1) * (\text{CHI}(-1) + 0.700267471934 * \text{USA}(-7) - 1.80982904959$   
 $* \text{ARG}(-7) - 0.258175319068 * \text{USATRIGO}(-7) + 0.0912451266117$   
 $* \text{USASOYA}(-7) + 0.864072393764 * \text{PRECIOETH}(-7) + 2.52927429206)$   
 $+ C(2) * D(\text{CHI}(-1)) + C(6) * D(\text{USASOYA}(-7)) + C(7) * D(\text{PRECIOETH}(-7)) +$   
 $C(8) + C(9) * \text{ESTAC} + C(10) * \text{NOV7} + C(11) * \text{DIC8} + C(12) * \text{DIC11} +$   
 $C(13) * \text{DOLARREAL}(-7) + C(14) * \text{PETRO}(-5) + C(15) * \text{RATIO}(-5) + C(16)$   
 $* \text{STOCK}(-5) + C(17) * \text{TONI} + C(18) * \text{IMPARG}(-5) + C(19) * \text{IMPMUNDO}(-5)$   
 $+ C(20) * \text{MAIZETH}(-5) + C(21) * \text{AMR} + C(22) * \text{AAB} + C(23) * \text{AMY} + C(24)$   
 $* \text{ABAMYA} + C(25) * \text{MRAMYA}$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	-0.161595	0.038383	-4.210104	0.0001
C(2)	0.223814	0.121677	1.839407	0.0700
C(6)	0.223865	0.084325	2.654779	0.0098
C(7)	0.135993	0.043956	3.093822	0.0028
C(8)	-0.321771	0.773023	-0.416250	0.6785
C(9)	0.407625	0.220408	1.849409	0.0686
C(10)	0.048146	0.042785	1.125299	0.2643
C(11)	-0.007613	0.042881	-0.177528	0.8596
C(12)	-0.054464	0.044523	-1.223284	0.2253
C(13)	0.034816	0.094766	0.367389	0.7144
C(14)	-0.003949	0.034771	-0.113564	0.9099
C(15)	-0.004907	0.007316	-0.670802	0.5045
C(16)	0.067212	0.067788	0.991494	0.3248
C(17)	0.004749	0.003651	1.300736	0.1976
C(18)	0.000767	0.002599	0.295077	0.7688
C(19)	-0.004249	0.004809	-0.883516	0.3799
C(20)	-0.052698	0.022698	-2.321687	0.0231
C(21)	-0.008729	0.026065	-0.334899	0.7387
C(22)	0.027249	0.027180	1.002529	0.3195
C(23)	0.024985	0.025792	0.968709	0.3360
C(24)	-0.090790	0.060087	-1.510978	0.1352
C(25)	0.066965	0.050729	1.320067	0.1911
R-squared	0.365101	Mean dependent var		-0.000950
Adjusted R-squared	0.177315	S.D. dependent var		0.044325
S.E. of regression	0.040203	Akaike info criterion		-3.386537
Sum squared resid	0.114758	Schwarz criterion		-2.787428
Log likelihood	179.4740	Hannan-Quinn criter.		-3.144634
F-statistic	1.944233	Durbin-Watson stat		2.007837
Prob(F-statistic)	0.020206			

*Fuente: Elaboración propia.*

**Imagen 37:** test de rezagos VECM 1 mes soya.

VAR Lag Order Selection Criteria

Endogenous variables: USA USATRIGO(-1) USAMAIZ(-1) PRECIOBIO(-1)  
PRECIOLECHE(-1)

Exogenous variables: C ESTAC NOV7 DIC8 DIC11 USINDEX PETRO RATIO STOCK TONI IMPCHINA

Date: 06/02/17 Time: 15:06

Sample: 2006M08 2014M12

Included observations: 92

Lag	LogL	LR	FPE	AIC	SC	HQ
0	110.6216	NA	2.07e-07	-1.209166	0.298425	-0.600689
1	462.4510	581.2832	1.72e-10	-8.314152	-6.121292	-7.429095
2	533.7163	109.9965*	6.42e-11*	-9.319919	-6.441791*	-8.158282*
3	555.7855	31.66445	7.11e-11	-9.256206	-5.692809	-7.817988
4	571.0483	20.23989	9.31e-11	-9.044529	-4.795863	-7.329731
5	600.7283	36.13212	9.14e-11	-9.146267	-4.212333	-7.154889
6	632.6155	35.35324	8.84e-11	-9.295989	-3.676787	-7.028031
7	659.2322	26.61669	9.98e-11	-9.331135	-3.026663	-6.786597
8	684.7626	22.75536	1.22e-10	-9.342665*	-2.352925	-6.521547

\* indicates lag order selected by the criterion

*Fuente: Elaboración propia.*

**Imagen 38:** test de correlación serial en residuos VECM 1 mes soya.

VAR Residual Serial Correlation LM Tests

Null Hypothesis: no serial correlation at lag order h

Date: 06/02/17 Time: 16:30

Sample: 2006M08 2014M12

Included observations: 93

Lags	LM-Stat	Prob
1	35.32588	0.0825
2	21.06849	0.6888
3	29.55051	0.2416
4	34.25078	0.1027
5	35.29944	0.0829
6	16.84469	0.8873
7	28.13015	0.3019
8	32.03799	0.1569
9	30.83056	0.1947
10	30.06878	0.2217
11	23.38097	0.5553
12	20.88575	0.6990

Probs from chi-square with 25 df.

*Fuente: Elaboración propia.*

**Imagen 39:** test normalidad VECM 1 mes soya.

VAR Residual Normality Tests  
 Orthogonalization: Cholesky (Lutkepohl)  
 Null Hypothesis: residuals are multivariate normal  
 Date: 06/02/17 Time: 16:30  
 Sample: 2006M08 2014M12  
 Included observations: 93

Component	Skewness	Chi-sq	df	Prob.
1	-0.055848	0.048344	1	0.8260
2	-0.045509	0.032102	1	0.8578
3	0.140877	0.307620	1	0.5791
4	-0.155145	0.373084	1	0.5413
5	0.111349	0.192180	1	0.6611
Joint		0.953329	5	0.9662

Component	Kurtosis	Chi-sq	df	Prob.
1	0.622741	21.89902	1	0.0000
2	0.743631	19.72841	1	0.0000
3	0.739680	19.79755	1	0.0000
4	0.971489	15.94507	1	0.0001
5	0.673069	20.98161	1	0.0000
Joint		98.35166	5	0.0000

Component	Jarque-Bera	df	Prob.
1	21.94736	2	0.0000
2	19.76051	2	0.0001
3	20.10517	2	0.0000
4	16.31816	2	0.0003
5	21.17379	2	0.0000
Joint	99.30499	10	0.0000

*Fuente: Elaboración propia.*

**Imagen 40:** test de heterocedasticidad en residuos VECM 1 mes soya.

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Date: 06/02/17 Time: 16:31

Sample: 2006M08 2014M12

Included observations: 93

Joint test:					
Chi-sq	df	Prob.			
1324.086	1305	0.3502			

Individual components:					
Dependent	R-squared	F(87,5)	Prob.	Chi-sq(87)	Prob.
res1*res1	0.978474	2.612372	0.1407	90.99807	0.3636
res2*res2	0.977784	2.529444	0.1492	90.93390	0.3653
res3*res3	0.969866	1.849704	0.2550	90.19752	0.3859
res4*res4	0.828976	0.278571	0.9947	77.09476	0.7674
res5*res5	0.979724	2.777015	0.1256	91.11436	0.3604
res2*res1	0.866702	0.373676	0.9732	80.60325	0.6724
res3*res1	0.926494	0.724389	0.7605	86.16396	0.5052
res3*res2	0.936479	0.847284	0.6745	87.09252	0.4770
res4*res1	0.926033	0.719512	0.7640	86.12105	0.5065
res4*res2	0.951670	1.131667	0.5043	88.50529	0.4349
res4*res3	0.879836	0.420802	0.9547	81.82475	0.6367
res5*res1	0.973181	2.085421	0.2094	90.50579	0.3773
res5*res2	0.939966	0.899836	0.6396	87.41681	0.4673
res5*res3	0.918772	0.650063	0.8137	85.44584	0.5271
res5*res4	0.932041	0.788201	0.7153	86.67979	0.4895

*Fuente: Elaboración propia.*

**Imagen 41:** test Johansen VECM 1 mes soya.

Date: 06/02/17 Time: 16:31

Sample (adjusted): 2007M03 2014M12

Included observations: 94 after adjustments

Trend assumption: Linear deterministic trend

Series: USA USATRIGO(-1) USAMAIZ(-1) PRECIOBIO(-1) PRECIOLECHE(-1)

Exogenous series: ESTAC NOV7 DIC8 DIC11 USINDEX PETRO RATIO STOCK TONI IMPCHINA

Warning: Critical values assume no exogenous series

Lags interval (in first differences): 1 to 5

Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.403154	127.7079	69.81889	0.0000
At most 1 *	0.369991	79.19487	47.85613	0.0000



At most 2 *	0.218207	35.76484	29.79707	0.0091
At most 3	0.109655	12.62530	15.49471	0.1293
At most 4	0.018002	1.707587	3.841466	0.1913

Trace test indicates 3 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.403154	48.51300	33.87687	0.0005
At most 1 *	0.369991	43.43003	27.58434	0.0002
At most 2 *	0.218207	23.13954	21.13162	0.0257
At most 3	0.109655	10.91771	14.26460	0.1584
At most 4	0.018002	1.707587	3.841466	0.1913

Max-eigenvalue test indicates 3 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

Unrestricted Cointegrating Coefficients (normalized by b\*S11\*b=I):

USA	USATRIGO(-1)	USAMAIZ(-1)	PRECIOBIO(-1)	PRECIOLECHE(-1)
14.81644	-15.57478	-12.16407	10.71022	0.238114
1.022699	9.949653	2.331787	-15.71129	-0.115432
-4.776733	-5.996730	6.765990	-5.805903	0.628785
-6.575483	12.01612	-9.351172	10.65358	-0.064747
-23.03610	1.684051	8.049450	-9.820351	-0.065882

Unrestricted Adjustment Coefficients (alpha):

D(USA)	-0.018029	-0.010276	-0.009151	0.007087	0.002983
D(USATRIGO(-1))	0.006323	-0.006197	4.98E-05	-0.006234	0.006266
D(USAMAIZ(-1))	0.010425	0.014017	-0.007552	0.004715	0.003137
D(PRECIOBIO(-1))	-0.012557	0.014185	0.002783	-0.003550	0.000628
D(PRECIOLECHE(-1))	0.045125	0.015699	-0.251255	-0.060666	-0.005601

1 Cointegrating Equation(s): Log likelihood 599.6385

Normalized cointegrating coefficients (standard error in parentheses)

USA	USATRIGO(-1)	USAMAIZ(-1)	PRECIOBIO(-1)	PRECIOLECHE(-1)
1.000000	-1.051182	-0.820985	0.722860	0.016071
	(0.21954)	(0.15943)	(0.23700)	(0.00743)

Adjustment coefficients (standard error in parentheses)

D(USA)	-0.267133
	(0.08999)
D(USATRIGO(-1))	0.093683

1))	(0.10194)
D(USAMAIZ(-1))	0.154459 (0.08098)
D(PRECIOBIO(-1))	-0.186057 (0.06048)
D(PRECIOLECHE(-1))	0.668592 (1.12445)

*Fuente: Elaboración propia.*

**Imagen 42: test Granger VECM 1 mes soya.**

VEC Granger Causality/Block Exogeneity Wald Tests

Date: 06/02/17 Time: 16:32

Sample: 2006M08 2014M12

Included observations: 93

Dependent variable: D(USA)

Excluded	Chi-sq	df	Prob.
D(USATRIGO(-1))	5.810525	6	0.4447
D(USAMAIZ(-1))	3.481541	6	0.7464
D(PRECIOBIO(-1))	3.013172	6	0.8072
D(PRECIOLECHE(-1))	5.422570	6	0.4909
All	24.85327	24	0.4138

*Fuente: Elaboración propia.*

**Imagen 43: VECM 1 mes soya.**

Dependent Variable: D(USA)

Method: Least Squares

Date: 06/02/17 Time: 16:32

Sample (adjusted): 2007M03 2014M12

Included observations: 94 after adjustments

$$D(USA) = C(1)*(USA(-1) - 1.71733987631*USATRIGO(-2) - 0.942162255602*USAMAIZ(-2) + 1.54400326367*PRECIOBIO(-2) + 0.0247781409806*PRECIOLECHE(-2) + 2.07564401768) + C(2)*D(USA(-1)) + C(3)*D(USA(-2)) + C(4)*D(USA(-3)) + C(5)*D(USA(-4)) + C(6)*D(USA(-5)) + C(7)*D(USA(-6)) + C(32) + C(33)*ESTAC + C(34)*NOV7 + C(35)*DIC8 + C(36)*DIC11 + C(37)*USINDEX + C(38)*PETRO + C(39)*RATIO + C(40)*STOCK + C(41)*TONI + C(42)*IMPCHINA$$

Coefficient	Std. Error	t-Statistic	Prob.
-------------	------------	-------------	-------

C(1)	-0.095638	0.032008	-2.987949	0.0038
C(2)	0.046136	0.109014	0.423214	0.6733
C(3)	-0.063692	0.119319	-0.533791	0.5950
C(4)	-0.191109	0.108697	-1.758176	0.0827
C(5)	-0.006484	0.111108	-0.058359	0.9536
C(6)	0.023718	0.107815	0.219985	0.8265
C(7)	-0.103435	0.115134	-0.898389	0.3718
C(32)	-3.179657	1.354566	-2.347363	0.0215
C(33)	1.384835	0.608560	2.275593	0.0257
C(34)	0.052466	0.071852	0.730192	0.4675
C(35)	0.020679	0.077254	0.267681	0.7897
C(36)	0.021031	0.066520	0.316167	0.7527
C(37)	0.290231	0.251316	1.154843	0.2518
C(38)	0.014036	0.052335	0.268202	0.7893
C(39)	-0.015513	0.008042	-1.929014	0.0575
C(40)	0.166658	0.069400	2.401408	0.0188
C(41)	0.002817	0.005430	0.518793	0.6054
C(42)	-0.039159	0.027074	-1.446337	0.1522
R-squared	0.299583	Mean dependent var	0.000172	
Adjusted R-squared	0.142911	S.D. dependent var	0.069366	
S.E. of regression	0.064218	Akaike info criterion	-2.482634	
Sum squared resid	0.313425	Schwarz criterion	-1.995621	
Log likelihood	134.6838	Hannan-Quinn criter.	-2.285916	
F-statistic	1.912164	Durbin-Watson stat	1.865732	
Prob(F-statistic)	0.029356			

*Fuente: Elaboración propia.*

**Imagen 44:** test de rezagos VECM 3 meses soya.

VAR Lag Order Selection Criteria

Endogenous variables: USA USATRIGO(-3) USAMAIZ(-3) PRECIOBIO(-3)  
PRECIOLECHE(-3)

Exogenous variables: C ESTAC USINDEX(-2) PETRO(-2) RATIO(-2) STOCK(-2) TONI IMPCHINA(-2)

Date: 06/15/17 Time: 15:39

Sample: 2006M08 2014M12

Included observations: 90

Lag	LogL	LR	FPE	AIC	SC	HQ
0	73.19042	NA	3.30e-07	-0.737565	0.373462	-0.289534
1	438.2781	624.7056	1.74e-10	-8.295069	-6.489651*	-7.567018*
2	470.2409	51.14049	1.51e-10	-8.449798	-5.949988	-7.441728
3	502.4021	47.88451	1.33e-10	-8.608937	-5.414735	-7.320847
4	546.7345	61.08006*	9.09e-11*	-9.038543*	-5.149951	-7.470434
5	561.3620	18.52817	1.23e-10	-8.808043	-4.225059	-6.959915
6	586.8176	29.41540	1.35e-10	-8.818169	-3.540793	-6.690020
7	613.8780	28.26310	1.49e-10	-8.863956	-2.892188	-6.455788
8	643.4460	27.59680	1.63e-10	-8.965467	-2.299308	-6.277280

*Fuente: Elaboración propia.*

**Imagen 45:** test de correlación serial en residuos VECM 3 meses soya.

VAR Residual Serial Correlation LM Tests  
 Null Hypothesis: no serial correlation at lag order h  
 Date: 06/15/17 Time: 15:40  
 Sample: 2006M08 2014M12  
 Included observations: 94

Lags	LM-Stat	Prob
1	24.73838	0.4771
2	26.70172	0.3709
3	31.58417	0.1704
4	40.08989	0.0286
5	30.96944	0.1900
6	24.61332	0.4842
7	37.07317	0.0568
8	25.52057	0.4335
9	37.00601	0.0577
10	26.28785	0.3924
11	20.00476	0.7466
12	22.34055	0.6160

Probs from chi-square with 25 df.

*Fuente: Elaboración propia.*

**Imagen 46:** test normalidad VECM 3 meses soya.

VAR Residual Normality Tests  
 Orthogonalization: Cholesky (Lutkepohl)  
 Null Hypothesis: residuals are multivariate normal  
 Date: 06/15/17 Time: 15:40  
 Sample: 2006M08 2014M12  
 Included observations: 94

Component	Skewness	Chi-sq	df	Prob.
1	-0.302123	1.430031	1	0.2318
2	0.155018	0.376478	1	0.5395
3	-0.003888	0.000237	1	0.9877
4	0.087274	0.119330	1	0.7298
5	0.170846	0.457284	1	0.4989
Joint		2.383360	5	0.7939

Component	Kurtosis	Chi-sq	df	Prob.
1	1.473682	9.124451	1	0.0025
2	1.377189	10.31461	1	0.0013
3	1.521399	8.562855	1	0.0034
4	1.626871	7.384812	1	0.0066
5	1.676136	6.864409	1	0.0088

Joint	42.25113	5	0.0000
Component	Jarque-Bera	df	Prob.
1	10.55448	2	0.0051
2	10.69108	2	0.0048
3	8.563092	2	0.0138
4	7.504142	2	0.0235
5	7.321694	2	0.0257
Joint	44.63449	10	0.0000

*Fuente: Elaboración propia.*

**Imagen 47:** test de heterocedasticidad en residuos VECM 3 meses soya.

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Date: 06/15/17 Time: 15:40

Sample: 2006M08 2014M12

Included observations: 94

Joint test:

Chi-sq	df	Prob.
798.3881	810	0.6077

Individual components:

Dependent	R-squared	F(54,39)	Prob.	Chi-sq(54)	Prob.
res1*res1	0.562318	0.927886	0.6053	52.85791	0.5185
res2*res2	0.669273	1.461516	0.1079	62.91162	0.1900
res3*res3	0.651666	1.351140	0.1632	61.25663	0.2319
res4*res4	0.533711	0.826650	0.7441	50.16881	0.6229
res5*res5	0.469857	0.640093	0.9359	44.16654	0.8278
res2*res1	0.564263	0.935250	0.5950	53.04071	0.5114
res3*res1	0.672914	1.485829	0.0983	63.25393	0.1821
res3*res2	0.525387	0.799486	0.7790	49.38639	0.6527
res4*res1	0.563145	0.931009	0.6009	52.93563	0.5155
res4*res2	0.716347	1.823924	0.0256	67.33661	0.1050
res4*res3	0.604344	1.103157	0.3777	56.80834	0.3708
res5*res1	0.596219	1.066424	0.4212	56.04454	0.3981
res5*res2	0.449449	0.589596	0.9640	42.24824	0.8769
res5*res3	0.562978	0.930375	0.6018	52.91989	0.5161
res5*res4	0.571272	0.962346	0.5575	53.69952	0.4859

*Fuente: Elaboración propia.*

### Imagen 48: test Johansen VECM 3 meses soya.

Date: 06/15/17 Time: 15:41

Sample (adjusted): 2007M02 2014M12

Included observations: 95 after adjustments

Trend assumption: Linear deterministic trend

Series: USA USATRIGO(-3) USAMAIZ(-3) PRECIOBIO(-3) PRECIOLECHE(-3)

Exogenous series: ESTAC USINDEX(-2) PETRO(-2) RATIO(-2) STOCK(-2) TONI IMPCHINA(-2)

Warning: Critical values assume no exogenous series

Lags interval (in first differences): 1 to 2

#### Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.340693	89.83385	69.81889	0.0006
At most 1 *	0.307091	50.26007	47.85613	0.0292
At most 2	0.115265	15.40867	29.79707	0.7530
At most 3	0.035339	3.774293	15.49471	0.9209
At most 4	0.003743	0.356297	3.841466	0.5506

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

#### Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.340693	39.57378	33.87687	0.0094
At most 1 *	0.307091	34.85140	27.58434	0.0049
At most 2	0.115265	11.63437	21.13162	0.5840
At most 3	0.035339	3.417996	14.26460	0.9151
At most 4	0.003743	0.356297	3.841466	0.5506

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

#### Unrestricted Cointegrating Coefficients (normalized by b'S11\*b=l):

	USA	USATRIGO(-3)	USAMAIZ(-3)	PRECIOBIO(-3)	PRECIOLECHE(-3)
	14.43212	-3.665794	-7.055655	2.839783	0.018619
	-0.294534	9.527528	3.818797	-8.323596	-0.167633
	-3.634969	7.063296	-6.358660	5.252474	-0.370058
	2.308346	4.064450	-5.307257	11.63054	0.124199
	-2.983000	1.899854	-4.301988	-0.589648	0.249788

#### Unrestricted Adjustment Coefficients (alpha):

	D(USA)	D(USATRIGO(-3))	D(USAMAIZ(-3))	D(PRECIOBIO(-3))	D(PRECIOLECHE(-3))
	-0.012582	-0.002010	0.008007	0.001817	-0.002630
	0.024876	-0.017767	-0.004848	-0.001462	-0.002931

D(USAMAIZ(-3))	0.032701	0.005883	0.008660	0.002116	-0.000737
D(PRECIOBIO(-3))	0.016237	0.017810	-0.005837	-0.001249	-0.001327
D(PRECIOLECHE(-3))	0.066620	-0.000331	0.127977	-0.083810	-0.000171

1 Cointegrating Equation(s):      Log likelihood      499.2237

Normalized cointegrating coefficients (standard error in parentheses)

USA	USATRIGO(-3)	USAMAIZ(-3)	PRECIOBIO(-3)	PRECIOLECHE(-3)
1.000000	-0.254003 (0.13480)	-0.488886 (0.12354)	0.196768 (0.16719)	0.001290 (0.00538)

Adjustment coefficients (standard error in parentheses)

D(USA)	-0.181590 (0.08787)
D(USATRIGO(-3))	0.359015 (0.11451)
D(USAMAIZ(-3))	0.471946 (0.09224)
D(PRECIOBIO(-3))	0.234339 (0.08030)
D(PRECIOLECHE(-3))	0.961470 (0.97862)

#### Vector Error Correction Estimates

Date: 06/15/17 Time: 15:42

Sample (adjusted): 2007M03 2014M12

Included observations: 94 after adjustments

Standard errors in ( ) & t-statistics in [ ]

Cointegration Restrictions:

B(1,2)=0, B(1,4)=0, B(1,5)=0

Convergence achieved after 12 iterations.

Not all cointegrating vectors are identified

LR test for binding restrictions (rank = 1):

Chi-square(3)                      23.04941

Probability                            0.000039

Cointegrating Eq:	CointEq1
USA(-1)	2.374966
USATRIGO(-4)	0.000000
USAMAIZ(-4)	-2.461130
PRECIOBIO(-4)	0.000000
PRECIOLECHE(-4)	0.000000

C

-1.363008

Error Correction:	D(USA)	D(USATRIGO(-3))	D(USAMAIZ(-3))	D(PRECIOBIO(-3))	D(PRECIOLECHE(-3))
CointEq1	-0.027189 (0.02155) [-1.26178]	0.022341 (0.02491) [ 0.89701]	0.051399 (0.01814) [ 2.83395]	0.008680 (0.01511) [ 0.57437]	0.317955 (0.23860) [ 1.33261]
D(USA(-1))	0.026141 (0.12197) [ 0.21432]	0.097341 (0.14098) [ 0.69047]	0.014124 (0.10266) [ 0.13757]	0.022619 (0.08555) [ 0.26440]	0.686497 (1.35056) [ 0.50830]
D(USA(-2))	0.011441 (0.11447) [ 0.09994]	-0.023564 (0.13231) [-0.17810]	-0.002420 (0.09635) [-0.02512]	-0.079380 (0.08029) [-0.98869]	0.545810 (1.26752) [ 0.43061]
D(USA(-3))	-0.069295 (0.11260) [-0.61544]	0.593549 (0.13014) [ 4.56091]	0.658947 (0.09477) [ 6.95325]	0.571139 (0.07897) [ 7.23243]	0.083309 (1.24671) [ 0.06682]
D(USATRIGO(-4))	0.084198 (0.09861) [ 0.85385]	0.058440 (0.11397) [ 0.51275]	-0.018888 (0.08300) [-0.22758]	-0.099797 (0.06916) [-1.44298]	0.581930 (1.09186) [ 0.53297]
D(USATRIGO(-5))	0.335553 (0.09778) [ 3.43158]	-0.130034 (0.11302) [-1.15055]	0.031105 (0.08230) [ 0.37793]	-0.020358 (0.06858) [-0.29685]	0.789145 (1.08272) [ 0.72886]
D(USATRIGO(-6))	0.111919 (0.10147) [ 1.10299]	-0.205381 (0.11728) [-1.75123]	-0.062291 (0.08540) [-0.72937]	-0.083102 (0.07117) [-1.16772]	0.015946 (1.12352) [ 0.01419]
D(USAMAIZ(-4))	-0.263984 (0.12122) [-2.17777]	-0.297159 (0.14010) [-2.12099]	-0.029388 (0.10203) [-0.28805]	0.090026 (0.08502) [ 1.05893]	0.360407 (1.34218) [ 0.26852]
D(USAMAIZ(-5))	-0.238411 (0.12433) [-1.91759]	0.035012 (0.14370) [ 0.24365]	-0.074347 (0.10464) [-0.71047]	0.050191 (0.08720) [ 0.57559]	-0.184241 (1.37663) [-0.13383]
D(USAMAIZ(-6))	-0.220590 (0.12524) [-1.76130]	-0.133904 (0.14476) [-0.92502]	0.057585 (0.10541) [ 0.54627]	0.020973 (0.08784) [ 0.23877]	1.351617 (1.38676) [ 0.97466]
D(PRECIOBIO(-4))	0.233136 (0.14911) [ 1.56355]	0.297582 (0.17234) [ 1.72672]	0.113722 (0.12550) [ 0.90616]	0.270381 (0.10458) [ 2.58547]	-0.044607 (1.65099) [-0.02702]
D(PRECIOBIO(-5))	-0.268323 (0.15249) [-1.75966]	-0.038446 (0.17624) [-0.21814]	0.047904 (0.12834) [ 0.37325]	0.041660 (0.10695) [ 0.38954]	1.186091 (1.68840) [ 0.70250]
D(PRECIOBIO(-6))	0.010455 (0.15225) [ 0.06867]	0.195802 (0.17597) [ 1.11268]	0.115663 (0.12815) [ 0.90258]	0.260994 (0.10678) [ 2.44417]	-1.165776 (1.68581) [-0.69152]



D(PRECIOLECHE(-4))	0.003983 (0.01130) [ 0.35245]	0.022245 (0.01306) [ 1.70305]	0.002450 (0.00951) [ 0.25761]	0.004104 (0.00793) [ 0.51781]	0.574109 (0.12513) [ 4.58806]
D(PRECIOLECHE(-5))	-0.008763 (0.01228) [-0.71386]	0.010777 (0.01419) [ 0.75954]	0.013130 (0.01033) [ 1.27077]	-0.000803 (0.00861) [-0.09330]	-0.356909 (0.13592) [-2.62578]
D(PRECIOLECHE(-6))	0.005755 (0.01078) [ 0.53377]	0.024268 (0.01246) [ 1.94737]	-0.002953 (0.00907) [-0.32543]	0.009247 (0.00756) [ 1.22282]	-0.098111 (0.11938) [-0.82181]
C	-1.262798 (1.53509) [-0.82262]	-1.731214 (1.77427) [-0.97573]	1.978652 (1.29204) [ 1.53141]	-0.953585 (1.07665) [-0.88570]	19.28028 (16.9973) [ 1.13431]
ESTAC	1.143464 (0.58789) [ 1.94504]	-0.797232 (0.67948) [-1.17329]	0.008052 (0.49481) [ 0.01627]	0.650713 (0.41232) [ 1.57818]	-11.20985 (6.50939) [-1.72210]
USINDEX(-2)	-0.009795 (0.26594) [-0.03683]	0.632966 (0.30738) [ 2.05922]	-0.307157 (0.22384) [-1.37223]	0.034306 (0.18652) [ 0.18392]	-2.024435 (2.94468) [-0.68749]
PETRO(-2)	-0.017707 (0.04875) [-0.36320]	-0.041053 (0.05635) [-0.72856]	-0.067440 (0.04103) [-1.64354]	-0.032856 (0.03419) [-0.96090]	0.784131 (0.53981) [ 1.45261]
RATIO(-2)	-0.001468 (0.00887) [-0.16558]	0.002237 (0.01025) [ 0.21828]	0.015666 (0.00746) [ 2.09902]	-0.003387 (0.00622) [-0.54467]	0.184504 (0.09819) [ 1.87910]
STOCK(-2)	0.058653 (0.07350) [ 0.79804]	-0.036181 (0.08495) [-0.42593]	-0.140874 (0.06186) [-2.27733]	0.026141 (0.05155) [ 0.50713]	-1.381176 (0.81378) [-1.69723]
TONI	0.008985 (0.00687) [ 1.30721]	0.014734 (0.00794) [ 1.85459]	0.010620 (0.00579) [ 1.83557]	-0.000201 (0.00482) [-0.04171]	-0.228896 (0.07611) [-3.00744]
IMPCHINA(-2)	-0.007147 (0.02570) [-0.27806]	0.015128 (0.02971) [ 0.50925]	0.037268 (0.02163) [ 1.72273]	0.022071 (0.01803) [ 1.22435]	0.393800 (0.28459) [ 1.38375]
R-squared	0.414064	0.527009	0.625364	0.628046	0.592331
Adj. R-squared	0.221542	0.371597	0.502269	0.505833	0.458383
Sum sq. resids	0.259360	0.346475	0.183734	0.127579	31.79764
S.E. equation	0.060870	0.070354	0.051232	0.042691	0.673982
F-statistic	2.150734	3.391057	5.080352	5.138935	4.422088
Log likelihood	143.5830	129.9720	159.7853	176.9286	-82.43680
Akaike AIC	-2.544319	-2.254723	-2.889048	-3.253801	2.264613
Schwarz SC	-1.894967	-1.605371	-2.239696	-2.604449	2.913965
Mean dependent	0.000892	-0.002633	-0.003231	-0.002988	0.125532
S.D. dependent	0.068990	0.088750	0.072619	0.060730	0.915803
Determinant resid covariance (dof adj.)		2.91E-11			
Determinant resid covariance		6.65E-12			

Log likelihood	542.6845
Akaike information criterion	-8.886904
Schwarz criterion	-5.504863

*Fuente: Elaboración propia.*

**Imagen 49: test Granger VECM 3 meses soya.**

VEC Granger Causality/Block Exogeneity Wald Tests  
 Date: 06/15/17 Time: 15:42  
 Sample: 2006M08 2014M12  
 Included observations: 94

Dependent variable: D(USA)

Excluded	Chi-sq	df	Prob.
D(USATRIGO(-3))	16.44924	3	0.0009
D(USAMAIZ(-3))	11.32044	3	0.0101
D(PRECIOBIO(-3))	4.831157	3	0.1846
D(PRECIOLECHE(-3))	0.543641	3	0.9092
All	28.81490	12	0.0042

*Fuente: Elaboración propia.*

**Imagen 50: VECM 3 meses soya.**

Dependent Variable: D(USA)  
 Method: Least Squares  
 Date: 06/15/17 Time: 15:43  
 Sample (adjusted): 2007M03 2014M12  
 Included observations: 94 after adjustments

$$D(USA) = C(1) * ( 2.3749659566 * USA(-1) - 2.46112956118 * USAMAIZ(-4) - 1.36300825215 ) + C(2) * D(USA(-1)) + C(3) * D(USA(-2)) + C(4) * D(USA(-3)) + C(5) * D(USATRIGO(-4)) + C(6) * D(USATRIGO(-5)) + C(7) * D(USATRIGO(-6)) + C(8) * D(USAMAIZ(-4)) + C(9) * D(USAMAIZ(-5)) + C(10) * D(USAMAIZ(-6)) + C(17) + C(18) * ESTAC + C(19) * USINDEX(-2) + C(20) * PETRO(-2) + C(21) * RATIO(-2) + C(22) * STOCK(-2) + C(23) * TONI + C(24) * IMPCHINA(-2)$$

	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	-0.028191	0.021067	-1.338199	0.1848
C(2)	-0.018886	0.116523	-0.162083	0.8717
C(3)	0.021670	0.111302	0.194694	0.8462
C(4)	-0.091639	0.109814	-0.834488	0.4066
C(5)	0.116705	0.089111	1.309664	0.1943
C(6)	0.290408	0.089824	3.233091	0.0018

C(7)	0.144427	0.093536	1.544078	0.1267
C(8)	-0.181916	0.107171	-1.697438	0.0937
C(9)	-0.278108	0.108212	-2.570033	0.0121
C(10)	-0.252359	0.111808	-2.257079	0.0269
C(17)	-1.615611	1.429821	-1.129940	0.2621
C(18)	1.355231	0.547795	2.473973	0.0156
C(19)	0.024018	0.247892	0.096890	0.9231
C(20)	-0.022489	0.046501	-0.483632	0.6300
C(21)	-0.002093	0.008368	-0.250057	0.8032
C(22)	0.064389	0.069677	0.924101	0.3584
C(23)	0.009026	0.005313	1.698841	0.0934
C(24)	-0.008552	0.024692	-0.346322	0.7301
<hr/>				
R-squared	0.371552	Mean dependent var	0.000892	
Adjusted R-squared	0.230978	S.D. dependent var	0.068990	
S.E. of regression	0.060500	Akaike info criterion	-2.601936	
Sum squared resid	0.278177	Schwarz criterion	-2.114922	
Log likelihood	140.2910	Hannan-Quinn criter.	-2.405218	
F-statistic	2.643103	Durbin-Watson stat	2.006856	
Prob(F-statistic)	0.002041			

*Fuente: Elaboración propia.*

### Imagen 51: test de rezagos VECM 6 meses soya.

VAR Lag Order Selection Criteria

Endogenous variables: USA USATRIGO(-6) USAMAIZ(-6) PRECIOBIO(-6)

PRECIOLECHE(-6)

Exogenous variables: C ESTAC NOV7 DIC8 DIC11 USINDEX(-5) PETRO(-5) RATIO(-5) STOCK(-5) TONI IMPCHINA(-5)

Date: 06/02/17 Time: 15:58

Sample: 2006M08 2014M12

Included observations: 87

Lag	LogL	LR	FPE	AIC	SC	HQ
0	77.39701	NA	4.14e-07	-0.514874	1.044034	0.112850
1	430.4303	576.2153	2.23e-10	-8.055869	-5.788367*	-7.142816
2	472.3888	63.66110	1.55e-10	-8.445719	-5.469623	-7.247336*
3	496.8919	34.36079	1.64e-10	-8.434297	-4.749607	-6.950586
4	524.1974	35.15187	1.67e-10	-8.487297	-4.094012	-6.718256
5	571.5091	55.46885	1.11e-10	-9.000209	-3.898330	-6.945839
6	618.6629	49.86377	7.64e-11	-9.509491	-3.699018	-7.169793
7	658.9480	37.96994*	6.52e-11*	-9.860874	-3.341807	-7.235847
8	687.0748	23.27733	7.87e-11	-9.932754*	-2.705092	-7.022398

\* indicates lag order selected by the criterion

LR: sequential modified LR test statistic (each test at 5% level)

FPE: Final prediction error

AIC: Akaike information criterion

SC: Schwarz information criterion

HQ: Hannan-Quinn information criterion

*Fuente: Elaboración propia.*

**Imagen 52:** test de correlación serial en residuos VECM 6 meses soya.

VAR Residual Serial Correlation LM Tests  
 Null Hypothesis: no serial correlation at lag order h  
 Date: 06/02/17 Time: 15:59  
 Sample: 2006M08 2014M12  
 Included observations: 89

Lags	LM-Stat	Prob
1	37.62176	0.0503
2	40.49242	0.0259
3	33.23680	0.1253
4	36.55534	0.0636
5	38.03026	0.0459
6	27.57207	0.3279
7	26.75164	0.3684
8	28.38324	0.2905
9	19.70611	0.7621
10	27.14829	0.3485
11	28.66599	0.2781
12	23.89259	0.5256

Probs from chi-square with 25 df.

*Fuente: Elaboración propia.*

**Imagen 53:** test normalidad VECM 6 meses soya.

VAR Residual Normality Tests  
 Orthogonalization: Cholesky (Lutkepohl)  
 Null Hypothesis: residuals are multivariate normal  
 Date: 06/02/17 Time: 15:59  
 Sample: 2006M08 2014M12  
 Included observations: 89

Component	Skewness	Chi-sq	df	Prob.
1	-0.025564	0.009694	1	0.9216
2	0.117793	0.205814	1	0.6501
3	0.063489	0.059792	1	0.8068
4	-0.043770	0.028418	1	0.8661
5	0.217659	0.702737	1	0.4019
Joint		1.006454	5	0.9620

Component	Kurtosis	Chi-sq	df	Prob.
1	0.927714	15.92495	1	0.0001
2	0.985708	15.04610	1	0.0001
3	0.847689	17.17865	1	0.0000
4	0.904894	16.27761	1	0.0001
5	1.349458	10.10257	1	0.0015

Joint	74.52988	5	0.0000
Component	Jarque-Bera	df	Prob.
1	15.93465	2	0.0003
2	15.25191	2	0.0005
3	17.23844	2	0.0002
4	16.30603	2	0.0003
5	10.80530	2	0.0045
Joint	75.53633	10	0.0000

*Fuente: Elaboración propia.*

**Imagen 54:** test de heterocedasticidad en residuos VECM 6 meses soya.

VAR Residual Heteroskedasticity Tests: No Cross Terms (only levels and squares)

Date: 06/02/17 Time: 15:59

Sample: 2006M08 2014M12

Included observations: 89

Joint test:

Chi-sq	df	Prob.
1143.407	1155	0.5902

Individual components:

Dependent	R-squared	F(77,11)	Prob.	Chi-sq(77)	Prob.
res1*res1	0.847263	0.792455	0.7374	75.40637	0.5301
res2*res2	0.883797	1.086515	0.4745	78.65790	0.4261
res3*res3	0.914190	1.521951	0.2260	81.36291	0.3451
res4*res4	0.842416	0.763692	0.7645	74.97507	0.5441
res5*res5	0.812854	0.620487	0.8879	72.34397	0.6289
res2*res1	0.955574	3.072765	0.0221	85.04609	0.2481
res3*res1	0.798536	0.566237	0.9252	71.06967	0.6688
res3*res2	0.843051	0.767354	0.7610	75.03150	0.5423
res4*res1	0.916467	1.567323	0.2092	81.56553	0.3393
res4*res2	0.838319	0.740716	0.7858	74.61037	0.5559
res4*res3	0.853893	0.834898	0.6970	75.99645	0.5109
res5*res1	0.865328	0.917920	0.6190	77.01417	0.4781
res5*res2	0.866353	0.926058	0.6115	77.10543	0.4752
res5*res3	0.755074	0.440410	0.9814	67.20160	0.7798
res5*res4	0.873015	0.982137	0.5612	77.69835	0.4563

*Fuente: Elaboración propia.*

### Imagen 55: test Johansen VECM 6 meses soya.

Date: 06/02/17 Time: 16:00

Sample (adjusted): 2007M05 2014M12

Included observations: 92 after adjustments

Trend assumption: Linear deterministic trend

Series: USA USATRIGO(-6) USAMAIZ(-6) PRECIOBIO(-6) PRECIOLECHE(-6)

Exogenous series: ESTAC NOV7 DIC8 DIC11 USINDEX(-5) PETRO(-5) RATIO(-5) STOCK(-5) TONI

IMPCHINA(-5)

Warning: Critical values assume no exogenous series

Lags interval (in first differences): 1 to 2

#### Unrestricted Cointegration Rank Test (Trace)

Hypothesized No. of CE(s)	Eigenvalue	Trace Statistic	0.05 Critical Value	Prob.**
None *	0.454030	108.1150	69.81889	0.0000
At most 1 *	0.279971	52.43752	47.85613	0.0175
At most 2	0.152184	22.21889	29.79707	0.2865
At most 3	0.072764	7.030497	15.49471	0.5741
At most 4	0.000871	0.080140	3.841466	0.7771

Trace test indicates 2 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

#### Unrestricted Cointegration Rank Test (Maximum Eigenvalue)

Hypothesized No. of CE(s)	Eigenvalue	Max-Eigen Statistic	0.05 Critical Value	Prob.**
None *	0.454030	55.67752	33.87687	0.0000
At most 1 *	0.279971	30.21863	27.58434	0.0224
At most 2	0.152184	15.18840	21.13162	0.2759
At most 3	0.072764	6.950357	14.26460	0.4950
At most 4	0.000871	0.080140	3.841466	0.7771

Max-eigenvalue test indicates 2 cointegrating eqn(s) at the 0.05 level

\* denotes rejection of the hypothesis at the 0.05 level

\*\*MacKinnon-Haug-Michelis (1999) p-values

#### Unrestricted Cointegrating Coefficients (normalized by b\*S11\*b=I):

	USA	USATRIGO(-6)	USAMAIZ(-6)	PRECIOBIO(-6)	PRECIOLECHE(-6)
	-6.889315	8.909811	5.284536	-6.599256	0.044163
	-6.735781	-5.206093	5.576489	-1.038417	0.039266
	2.982483	-4.900092	-1.318819	6.095279	0.484226
	-3.863130	6.940553	-8.031249	13.04267	-0.127127
	-2.151324	-0.607365	-5.239830	-0.619952	0.226789

#### Unrestricted Adjustment Coefficients (alpha):

	D(USA)	D(USATRIGO(-			
	-0.002715	0.026113	-0.004986	-0.002397	-0.000817
	-0.032407	-0.011396	0.004281	-0.011647	-0.000437

6))					
D(USAMAIZ(-6))	-0.011631	-0.023999	-0.007526	-0.000315	-0.001006
D(PRECIOBIO(-6))	0.010476	-0.012358	-0.003872	-0.009865	-0.000411
D(PRECIOLECHE(-6))	-0.161366	-0.020490	-0.158989	0.002965	0.009079

1 Cointegrating Equation(s):      Log likelihood      498.9947

Normalized cointegrating coefficients (standard error in parentheses)

	USA	USATRIGO(-6)	USAMAIZ(-6)	PRECIOBIO(-6)	PRECIOLECHE(-6)
	1.000000	-1.293280 (0.22722)	-0.767063 (0.22692)	0.957897 (0.29986)	-0.006410 (0.01041)

Adjustment coefficients (standard error in parentheses)

D(USA)	0.018706 (0.04839)
D(USATRIGO(-6))	0.223260 (0.05162)
D(USAMAIZ(-6))	0.080127 (0.05046)
D(PRECIOBIO(-6))	-0.072171 (0.03955)
D(PRECIOLECHE(-6))	1.111703 (0.44625)

*Fuente: Elaboración propia.*

**Imagen 56: test Granger VECM 6 meses soya.**

VEC Granger Causality/Block Exogeneity Wald Tests

Date: 06/02/17 Time: 16:00

Sample: 2006M08 2014M12

Included observations: 89

Dependent variable: D(USA)

Excluded	Chi-sq	df	Prob.
D(USATRIGO(-6))	5.245685	5	0.3866
D(USAMAIZ(-6))	12.92534	5	0.0241
D(PRECIOBIO(-6))	6.580015	5	0.2538
D(PRECIOLECHE(-6))	7.564935	5	0.1819
All	22.03403	20	0.3387

*Fuente: Elaboración propia.*

**Imagen 57: VECM 6 meses soya.**

Dependent Variable: D(USA)

Method: Least Squares

Date: 06/02/17 Time: 16:02

Sample (adjusted): 2007M08 2014M12

Included observations: 89 after adjustments

$$D(USA) = C(1)*(-26.4034498316*USA(-1) + 4.02679005267*USATRIGO(-7) + 12.9103019531*USAMAIZ(-7) - 7.27995724396*PRECIOBIO(-7) + 60.2873623377) + C(2)*D(USA(-1)) + C(3)*D(USA(-2)) + C(4)*D(USA(-3)) + C(5)*D(USA(-4)) + C(6)*D(USA(-5)) + C(12)*D(USAMAIZ(-7)) + C(13)*D(USAMAIZ(-8)) + C(14)*D(USAMAIZ(-9)) + C(15)*D(USAMAIZ(-10)) + C(16)*D(USAMAIZ(-11)) + C(27) + C(28)*ESTAC + C(29)*NOV7 + C(30)*DIC8 + C(31)*DIC11 + C(32)*USINDEX(-5) + C(33)*PETRO(-5) + C(34)*RATIO(-5) + C(35)*STOCK(-5) + C(36)*TONI + C(37)*IMPCHINA(-5)$$


	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	0.010811	0.004292	2.518554	0.0142
C(2)	0.219124	0.150068	1.460166	0.1489
C(3)	0.101529	0.163704	0.620196	0.5372
C(4)	-0.000677	0.138109	-0.004904	0.9961
C(5)	0.065795	0.150239	0.437938	0.6628
C(6)	0.174733	0.143058	1.221413	0.2262
C(12)	-0.085433	0.105382	-0.810693	0.4204
C(13)	-0.218747	0.106639	-2.051284	0.0442
C(14)	-0.056119	0.105576	-0.531547	0.5968
C(15)	-0.056596	0.104488	-0.541653	0.5899
C(16)	0.179907	0.105218	1.709851	0.0919
C(27)	-2.586182	1.604140	-1.612191	0.1116
C(28)	1.115889	0.602022	1.853569	0.0682
C(29)	0.087015	0.069502	1.251979	0.2149
C(30)	-0.037408	0.079180	-0.472448	0.6381
C(31)	-0.002008	0.068250	-0.029424	0.9766
C(32)	0.176698	0.268292	0.658603	0.5124
C(33)	0.041225	0.056141	0.734308	0.4653
C(34)	0.000126	0.009223	0.013697	0.9891
C(35)	0.050959	0.073798	0.690528	0.4922
C(36)	0.010899	0.006765	1.611060	0.1119
C(37)	0.027985	0.027373	1.022334	0.3103
R-squared	0.368869	Mean dependent var		-0.000406
Adjusted R-squared	0.171051	S.D. dependent var		0.070250
S.E. of regression	0.063960	Akaike info criterion		-2.450679
Sum squared resid	0.274089	Schwarz criterion		-1.835510
Log likelihood	131.0552	Hannan-Quinn criter.		-2.202722
F-statistic	1.864695	Durbin-Watson stat		1.903348
Prob(F-statistic)	0.028730			

*Fuente: Elaboración propia.*



**Imagen 58:** Gráfico predicciones VECM 6 meses trigo (en CLP).


Precio promedio mensual internacional vs Precio proyectado entre 2015 y 2016



Fuente: Elaboración propia en base a registros de COTRISA.


**Imagen 59:** Gráfico predicciones VECM 6 meses maíz (en CLP).

Precio promedio mensual internacional vs Precio proyectado entre 2015 y 2016




Fuente: Elaboración propia en base a registros de COTRISA.

**Imagen 60:** Gráfico predicciones VECM 6 meses soya (en USD).



Fuente: Elaboración propia en base a registros de INDEXMUNDI.


**Imagen 61:** Gráfico predicciones VECM 1 mes trigo (en CLP).



Fuente: Elaboración propia en base a registros de COTRISA.

**Imagen 62:** Gráfico predicciones VECM 1 mes maíz (en CLP).


Precio promedio mensual en Chile vs Precio proyectado entre 2015 y 2016



Fuente: Elaboración propia en base a registros de COTRISA.

**Imagen 63:** Gráfico predicciones VECM 1 mes soya (en USD).

Precio promedio mensual de USA vs Precio proyectado entre 2015 y 2016



Fuente: Elaboración propia en base a registros de INDEXMUNDI.

**Imagen 64:** Resumen de resultados predicciones VECM trigo a 1, 3, y 6 meses (en CLP).

Mes	Chile	Modelo 1 mes	Modelo 3 meses	Modelo 6 meses	Error 1 mes	Error 3 meses	Error 6 meses
ene-15	186.164	213.123	202.099	196.475	-26.959	-15.936	-10.312
feb-15	181.563	185.141	195.482	191.258	-3.578	-13.919	-9.695
mar-15	177.219	174.116	186.226	188.217	3.102	-9.008	-10.999
abr-15	174.692	172.196	173.986	178.774	2.496	706	-4.082
may-15	172.125	169.567	171.150	174.686	2.557	975	-2.561
jun-15	172.412	169.677	164.275	174.323	2.735	8.137	-1.911
jul-15	179.406	171.411	168.306	162.284	7.995	11.100	17.122
ago-15	174.476	181.446	164.545	156.721	-6.970	9.932	17.756
sept-15	172.546	172.824	165.378	151.200	-279	7.167	21.346
oct-15	175.216	167.368	174.092	146.849	7.848	1.124	28.367
nov-15	175.380	169.660	175.707	143.755	5.720	-327	31.625
dic-15	172.012	166.604	170.328	136.091	5.408	1.683	35.921
ene-16	156.379	159.797	166.105	151.890	-3.417	-9.725	4.490
feb-16	152.459	151.311	170.242	137.244	1.148	-17.782	15.216
mar-16	143.670	141.249	162.996	130.715	2.420	-19.327	12.955
abr-16	144.679	133.248	137.182	126.428	11.432	7.497	18.251
may-16	144.130	140.631	130.342	120.709	3.498	13.788	23.421
jun-16	149.330	142.093	120.887	119.335	7.237	28.442	29.995
jul-16	150.859	146.466	143.808	138.843	4.394	7.051	12.017
ago-16	154.369	150.020	136.711	135.262	4.349	17.658	19.107
sept-16	154.000	154.533	134.094	133.328	-533	19.906	20.672
oct-16	150.829	153.294	152.118	125.865	-2.465	-1.288	24.964
nov-16	149.089	153.158	147.809	119.995	-4.068	1.281	29.094
dic-16	147.770	153.262	139.456	116.403	-5.492	8.313	31.367
<b>Error Máximo</b>					<b>26.959</b>	<b>28.442</b>	<b>35.921</b>
<b>Promedio</b>					<b>774</b>	<b>2.394</b>	<b>14.755</b>
<b>Promedio absoluto</b>					<b>5.254</b>	<b>9.670</b>	<b>18.052</b>

*Fuente: Elaboración propia en base a registros de COTRISA.*

**Imagen 65:** Resumen de resultados predicciones VECM maíz a 1, 3, y 6 meses (en CLP).

Mes /Precio	Chile	Modelo 1 mes	Modelo 3 me	Modelo 6 meses	Error 1 mes	Error 3 meses	Error 6 meses
ene-15	131.753	129.408	135.308	135.822	2.345	-3.554	-4.068
feb-15	131.753	129.634	136.367	136.335	2.120	-4.614	-4.581
mar-15	138.645	128.331	132.546	130.826	10.313	6.098	7.819
abr-15	127.604	130.759	132.148	120.273	-3.155	-4.544	7.332
may-15	121.843	126.006	130.520	126.702	-4.164	-8.677	-4.859
jun-15	121.422	117.950	122.558	125.152	3.472	-1.136	-3.730
jul-15	135.779	119.729	121.455	120.549	16.050	14.324	15.230
ago-15	138.131	131.239	124.537	129.106	6.892	13.594	9.025
sept-15	138.131	134.395	127.017	141.444	3.736	11.114	-3.313
oct-15	140.185	134.509	135.752	147.728	5.676	4.433	-7.543
nov-15	142.629	137.495	135.123	148.267	5.134	7.506	-5.638
dic-15	147.374	138.980	136.119	151.027	8.394	11.255	-3.653
ene-16	143.500	139.212	140.816	150.195	4.288	2.684	-6.696
feb-16	143.500	139.088	139.093	155.612	4.412	4.407	-12.113
mar-16	137.890	136.449	135.370	158.051	1.441	2.519	-20.162
abr-16	125.710	126.464	132.063	155.248	-754	-6.353	-29.539
may-16	129.670	115.355	119.504	139.026	14.315	10.166	-9.356
jun-16	135.260	119.571	112.447	130.531	15.689	22.813	4.728
jul-16	136.810	126.886	126.874	137.081	9.924	9.936	-272
ago-16	136.330	128.593	121.774	137.497	7.737	14.556	-1.168
sept-16	138.040	134.582	120.229	139.397	3.457	17.810	-1.357
oct-16	139.670	133.319	130.570	142.525	6.351	9.099	-2.855
nov-16	140.130	132.881	125.952	144.409	7.249	14.177	-4.279
dic-16	142.250	127.768	125.018	148.104	14.481	17.232	-5.855
<b>Error Máximo</b>					<b>16.050</b>	<b>22.813</b>	<b>29.539</b>
<b>Promedio</b>					<b>6.058</b>	<b>6.869</b>	<b>-3.621</b>
<b>Promedio absoluto</b>					<b>6.731</b>	<b>9.275</b>	<b>7.299</b>

*Fuente: Elaboración propia en base a registros de COTRISA.*

**Imagen 66:** Resumen de resultados predicciones VECM soya a 1, 3, y 6 meses (en USD).

Mes /Precio	USA	Modelo 1 mes	Modelo 3 meses	Modelo 6 meses	Error 1 mes	Error 3 meses	Error 6 meses
ene-15	377	366	410	403	12	-32	-25
feb-15	375	360	410	409	15	-36	-35
mar-15	369	364	424	415	5	-55	-45
abr-15	367	366	386	427	1	-20	-61
may-15	361	393	401	433	-31	-40	-72
jun-15	364	392	408	435	-27	-44	-71
jul-15	382	358	374	356	24	8	26
ago-15	356	383	375	345	-26	-19	11
sept-15	332	363	370	334	-31	-38	-1
oct-15	336	310	324	316	26	12	20
nov-15	328	323	326	305	5	2	22
dic-15	332	360	326	304	-28	6	28
ene-16	323	312	331	332	11	-8	-9
feb-16	320	295	343	326	25	-23	-6
mar-16	327	305	357	326	22	-30	1
abr-16	354	304	340	322	50	14	32
may-16	389	314	353	316	74	36	72
jun-16	421	355	371	313	67	50	109
jul-16	390	366	441	425	25	-50	-34
ago-16	370	367	439	416	3	-69	-45
sept-16	356	361	429	404	-5	-73	-48
oct-16	358	360	345	393	-2	13	-34
nov-16	368	384	339	390	-16	29	-22
dic-16	375	406	335	388	-31	40	-13
				<b>Error Máximo</b>	<b>74,1</b>	<b>72,9</b>	<b>108,7</b>
				<b>Promedio</b>	<b>7,0</b>	<b>-13,5</b>	<b>-8,3</b>
				<b>Promedio absoluto</b>	<b>23,4</b>	<b>31,0</b>	<b>35,2</b>

Fuente: Elaboración propia en base a registros de INDEXMUNDI.

**Imagen 67:** Estimación de regresión lineal del trigo.

Dependent Variable: DCHI  
 Method: Least Squares  
 Date: 06/17/17 Time: 14:54  
 Sample (adjusted): 2006M10 2014M12  
 Included observations: 99 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	-1.515566	0.548697	-2.762120	0.0069
FUTUROS(-1)	0.141761	0.031341	4.523200	0.0000
DIC8	-0.173446	0.050975	-3.402552	0.0010
DOLAR	0.152112	0.075476	2.015357	0.0468
RATIO	0.029255	0.017177	1.703149	0.0919
LOG(ABS(TONI))	0.017254	0.005926	2.911505	0.0045
ALTAD	-0.050222	0.025622	-1.960123	0.0530
R-squared	0.299446	Mean dependent var		0.002009
Adjusted R-squared	0.253758	S.D. dependent var		0.056687
S.E. of regression	0.048969	Akaike info criterion		-3.127182
Sum squared resid	0.220611	Schwarz criterion		-2.943688
Log likelihood	161.7955	Hannan-Quinn criter.		-3.052940
Durbin-Watson stat	1.752588			

Fuente: Elaboración propia.

**Imagen 68:** Estimación de regresión lineal del maíz.

Dependent Variable: D(CHI)  
 Method: Least Squares  
 Date: 06/17/17 Time: 18:24  
 Sample (adjusted): 2006M10 2014M12  
 Included observations: 99 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C(1)	1.858744	0.651583	2.852658	0.0053
ARG(-2)	-0.099559	0.029804	-3.340435	0.0012
ESTAC	0.479192	0.179907	2.663548	0.0091
DOLARREAL(-2)	-0.285331	0.080207	-3.557423	0.0006
AAB	0.048889	0.026849	1.820895	0.0718
R-squared	0.195314	Mean dependent var		0.001805
Adjusted R-squared	0.161072	S.D. dependent var		0.048238
S.E. of regression	0.044182	Akaike info criterion		-3.351801
Sum squared resid	0.183495	Schwarz criterion		-3.220735
Log likelihood	170.9142	Hannan-Quinn criter.		-3.298772
Durbin-Watson stat	1.725582			

*Fuente: Elaboración propia.*

**Imagen 69:** Estimación de regresión lineal de la soya.


Dependent Variable: D(USA)  
 Method: Least Squares  
 Date: 06/17/17 Time: 19:28  
 Sample (adjusted): 2006M09 2014M12  
 Included observations: 100 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
USAMAIZ(-2)	0.082028	0.031262	2.623915	0.0101
ESTAC	1.117742	0.489220	2.284744	0.0245
STOCK	0.060541	0.016174	3.743227	0.0003
C	-1.713219	0.524324	-3.267479	0.0015
R-squared	0.162273	Mean dependent var		0.002546
Adjusted R-squared	0.136094	S.D. dependent var		0.069303
S.E. of regression	0.064414	Akaike info criterion		-2.607783
Sum squared resid	0.398324	Schwarz criterion		-2.503576
Log likelihood	134.3891	Hannan-Quinn criter.		-2.565608
F-statistic	6.198615	Durbin-Watson stat		1.590285
Prob(F-statistic)	0.000679			

*Fuente: Elaboración propia.*

**Imagen 70:** Gráfico predicciones regresión lineal a 1 mes trigo (en CLP).


Precio promedio mensual de Chile vs Precio proyectado entre 2015 y 2016



Fuente: Elaboración propia en base a registros de COTRISA.

**Imagen 71:** Gráfico predicciones regresión lineal a 1 mes maíz (en CLP).

Precio promedio mensual de Chile vs Precio proyectado entre 2015 y 2016




Fuente: Elaboración propia en base a registros de COTRISA.



**Imagen 72:** Gráfico predicciones regresión lineal a 1 mes soya (en USD).


Precio promedio mensual de Chile vs Precio proyectado entre 2015 y 2016



Fuente: Elaboración propia en base a registros de INDEXMUNDI.

**Imagen 73:** Gráfico predicciones regresión lineal a 6 meses trigo (en CLP).


Precio promedio mensual de Chile vs Precio proyectado entre 2015 y 2016



Fuente: Elaboración propia en base a registros de COTRISA.

**Imagen 74:** Gráfico predicciones regresión lineal a 6 meses maíz (en CLP).


Precio promedio mensual de Chile vs Precio proyectado entre 2015 y 2016



Fuente: Elaboración propia en base a registros de COTRISA.

**Imagen 75:** Gráfico predicciones regresión lineal a 6 meses soya (en USD).

Precio promedio mensual de Chile vs Precio proyectado entre 2015 y 2016



Fuente: Elaboración propia en base a registros de INDEXMUNDI.

**Imagen 76:** Resumen de resultados predicciones Regresión lineal trigo a 1, 3, y 6 meses (en CLP).

Mes	Chile	Modelo 1 mes	Modelo 3 meses	Modelo 6 meses	Error 1 mes	Error 3 meses	Error 6 meses
ene-15	186.164	195.654	185.425	184.727	-9.491	738	1.437
feb-15	181.563	187.165	188.171	188.303	-5.602	-6.608	-6.741
mar-15	177.219	180.671	191.966	193.090	-3.453	-14.747	-15.871
abr-15	174.692	176.826	177.663	197.612	-2.134	-2.971	-22.920
may-15	172.125	175.668	179.355	199.962	-3.544	-7.231	-27.837
jun-15	172.412	169.655	179.659	200.397	2.757	-7.247	-27.985
jul-15	179.406	169.877	176.282	178.706	9.529	3.124	700
ago-15	174.476	179.626	170.648	175.206	-5.150	3.829	-730
sept-15	172.546	168.350	164.825	171.659	4.195	7.720	886
oct-15	175.216	164.272	168.131	163.871	10.944	7.085	11.345
nov-15	175.380	169.790	161.751	156.909	5.590	13.629	18.471
dic-15	172.012	171.021	158.723	153.757	991	13.289	18.254
ene-16	156.379	168.079	154.663	155.358	-11.700	1.717	1.021
feb-16	152.459	155.248	154.276	156.164	-2.789	-1.816	-3.704
mar-16	143.670	153.247	154.642	158.742	-9.578	-10.973	-15.073
abr-16	144.679	144.174	144.368	159.963	505	311	-15.283
may-16	144.130	145.817	143.895	161.608	-1.687	234	-17.478
jun-16	149.330	145.120	143.616	163.413	4.209	5.714	-14.084
jul-16	150.859	151.240	149.438	152.760	-381	1.421	-1.901
ago-16	154.369	149.626	147.350	154.303	4.744	7.020	66
sept-16	154.000	151.692	144.636	153.947	2.308	9.363	52
oct-16	150.829	147.946	147.041	151.233	2.883	3.789	-403
nov-16	149.089	144.713	139.601	144.563	4.376	9.489	4.527
dic-16	147.770	139.661	135.014	141.307	8.109	12.755	6.463
				<b>Error Máximo</b>	<b>11.700</b>	<b>14.747</b>	<b>27.985</b>
				<b>Promedio</b>	<b>235</b>	<b>2.068</b>	<b>-4.450</b>
				<b>Promedio absoluto</b>	<b>4.860</b>	<b>6.367</b>	<b>9.718</b>

*Fuente: Elaboración propia en base a registros de COTRISA.*

**Imagen 77:** Resumen de resultados predicciones Regresión lineal maíz a 1, 3, y 6 meses (en CLP).

Mes /Precio	Chile	Modelo 1 mes	Modelo 3 me	Modelo 6 meses	Error 1 mes	Error 3 meses	Error 6 meses
ene-15	131.753	136.775	135.512	135.436	-5.022	-3.759	-3.683
feb-15	131.753	131.019	136.977	136.250	734	-5.224	-4.497
mar-15	138.645	128.156	136.882	135.227	10.489	1.763	3.417
abr-15	127.604	131.647	133.434	130.912	-4.042	-5.829	-3.308
may-15	121.843	121.785	126.575	127.732	58	-4.732	-5.889
jun-15	121.422	117.664	119.990	124.605	3.758	1.432	-3.183
jul-15	135.779	119.303	117.410	118.086	16.476	18.369	17.694
ago-15	138.131	132.922	115.578	114.298	5.209	22.553	23.833
sept-15	138.131	134.855	115.135	111.189	3.276	22.996	26.942
oct-15	140.185	132.587	136.423	109.241	7.598	3.762	30.944
nov-15	142.629	136.096	133.855	108.798	6.534	8.774	33.832
dic-15	147.374	139.020	129.000	109.052	8.354	18.374	38.322
ene-16	143.500	141.162	141.963	144.831	2.338	1.537	-1.332
feb-16	143.500	138.668	138.693	142.605	4.831	4.806	895
mar-16	137.890	136.501	132.985	136.346	1.389	4.904	1.544
abr-16	125.710	135.955	135.419	134.998	-10.246	-9.710	-9.289
may-16	129.670	118.443	125.623	127.308	11.226	4.047	2.362
jun-16	135.260	123.293	117.758	119.164	11.966	17.501	16.096
jul-16	136.810	128.827	129.119	127.827	7.982	7.691	8.983
ago-16	136.330	130.468	125.146	120.997	5.862	11.183	15.333
sept-16	138.040	131.359	120.847	116.391	6.681	17.193	21.648
oct-16	139.670	134.470	132.808	112.890	5.199	6.862	26.779
nov-16	140.130	136.036	128.607	110.701	4.094	11.523	29.429
dic-16	142.250	137.470	125.785	107.560	4.779	16.465	34.690
<b>Error Máximo</b>					<b>16.476</b>	<b>22.996</b>	<b>38.322</b>
<b>Promedio</b>					<b>4.563</b>	<b>7.187</b>	<b>12.565</b>
<b>Promedio absoluto</b>					<b>6.173</b>	<b>9.625</b>	<b>15.163</b>

*Fuente: Elaboración propia en base a registros de COTRISA.*

**Imagen 78:** Resumen de resultados predicciones Regresión lineal soya a 1, 3, y 6 meses (en USD).

Mes /Precio	USA	Modelo 1 mes	Modelo 3 meses	Modelo 6 meses	Error 1 mes	Error 3 meses	Error 6 meses
ene-15	377	411	407	408	-34	-30	-30
feb-15	375	394	423	418	-20	-49	-44
mar-15	369	390	446	438	-21	-76	-68
abr-15	367	394	398	467	-27	-32	-101
may-15	361	399	435	514	-38	-74	-152
jun-15	364	408	494	590	-44	-129	-225
jul-15	382	410	413	419	-28	-30	-36
ago-15	356	395	420	429	-38	-64	-72
sept-15	332	356	411	424	-24	-79	-91
oct-15	336	313	316	398	24	20	-62
nov-15	328	327	309	384	1	18	-56
dic-15	332	324	304	374	8	28	-42
ene-16	323	333	335	337	-10	-12	-13
feb-16	320	335	348	352	-15	-28	-32
mar-16	327	333	362	365	-6	-35	-38
abr-16	354	347	350	391	7	4	-37
may-16	389	385	382	429	3	7	-41
jun-16	421	441	431	486	-20	-10	-65
jul-16	390	479	477	480	-88	-86	-90
ago-16	370	393	488	491	-22	-118	-121
sept-16	356	353	483	483	3	-127	-127
oct-16	358	324	330	454	34	28	-96
nov-16	368	337	308	439	31	60	-71
dic-16	375	356	293	433	19	82	-58
				<b>Error Máximo</b>	<b>88,5</b>	<b>129,4</b>	<b>225,3</b>
				<b>Promedio</b>	<b>-12,7</b>	<b>-30,4</b>	<b>-73,7</b>
				<b>Promedio absoluto</b>	<b>23,5</b>	<b>51,1</b>	<b>73,7</b>

Fuente: Elaboración propia en base a registros de INDEXMUNDI.

**Imagen 79:** Plan de compras a 6 meses recomendado por los modelos en base a predicciones de precios.

Programación de compras					
Mes	Afrechillo Masc	Maiz Masc	Afrechillo Nut	Maiz Nut	Triticale Nut
ene-15	1	2	1	2	1
feb-15	1	-	1	-	1
mar-15	1	1	1	1	1
abr-15	1	3	1	3	1
may-15	1	-	1	-	1
jun-15	1	-	1	-	1
jul-15	1	6	1	6	1
ago-15	1	-	1	-	1
sept-15	1	-	1	-	1
oct-15	1	-	1	-	1
nov-15	1	-	1	-	1
dic-15	1	-	1	-	1
ene-16	1	4	1	4	1
feb-16	1	-	1	-	1
mar-16	1	-	1	-	1
abr-16	1	-	1	-	1
may-16	1	1	1	1	1
jun-16	1	1	1	1	1
jul-16	1	6	1	6	1
ago-16	1	-	1	-	1
sept-16	1	-	1	-	1
oct-16	1	-	1	-	1
nov-16	1	-	1	-	1
dic-16	1	-	1	-	1

*Fuente: Elaboración propia.*

