



ESCUELA UNIVERSITARIA DE POSGRADO

DINAMICA CAOTICA Y ECUACIONES NO LINEALES: IMPACTO EN LOS ÍNDICES DOW JONES Y LME Y SU RELACIÓN CON LA IMPORTACIÓN DE COMMODITIES PARA LOS FABRICANTES DE ELECTRODOS EN EL PERÚ (2018-2023)

Línea de investigación:

Herramientas informáticas para una gestión eficiente y transparente

Tesis para optar el Grado Académico de Doctor en Administración

Autor

Cáceres Linares, Luis César

Asesor

Aroquipa Velásquez, Héctor

ORCID: 0000-0002-6502-5618

Jurado

Oncevay Espinoza, Feliciano Timoteo

Jaime Barreto, Tito Heber

Palomino, Nieto Edgardo

Lima - Perú

2026

DINAMICA CAOTICA Y ECUACIONES NO LINEALES: IMPACTO EN LOS ÍNDICES DOW JONES Y LME Y SU RELACIÓN CON LA IMPORTACIÓN DE COMMODITIES PARA LOS FABRICANTES DE ELECTRODOS EN EL PERÚ (2018-2023)

INFORME DE ORIGINALIDAD

10%	9%	3%	2%
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

FUENTES PRIMARIAS

1	www.coursehero.com	1%
	Fuente de Internet	
2	Submitted to Universidad Nacional Federico Villarreal	1%
	Trabajo del estudiante	
3	docplayer.es	<1%
	Fuente de Internet	
4	boletin.imt.mx	<1%
	Fuente de Internet	
5	www.researchgate.net	<1%
	Fuente de Internet	
6	es.slideshare.net	<1%
	Fuente de Internet	
7	hdl.handle.net	<1%
	Fuente de Internet	
8	issuu.com	<1%
	Fuente de Internet	
9	www.slideshare.net	<1%
	Fuente de Internet	
10	repositorio.unfv.edu.pe	<1%
	Fuente de Internet	



ESCUELA UNIVERSITARIA DE POSGRADO

DINAMICA CAOTICA Y ECUACIONES NO LINEALES: IMPACTO EN
LOS ÍNDICES DOW JONES Y LME Y SU RELACIÓN CON LA
IMPORTACIÓN DE COMMODITIES PARA LOS FABRICANTES DE
ELECTRODOS EN EL PERÚ (2018-2023)

Línea de Investigación:

Herramientas informáticas para una gestión eficiente y transparente

Tesis para optar el Grado Académico de Doctor en Administración

Autor

Cáceres Linares, Luis César

Asesor

Aroquipa Velásquez, Héctor

ORCID: 0000-0002-6502-5618

Jurado

Oncevay Espinoza, Feliciano Timoteo

Jaime Barreto, Tito Heber

Palomino, Nieto Edgardo

Lima – Perú

2026

DEDICATORIA

Esta Tesis Doctoral es un tributo al legado y a la eterna admiración que siento hacia mis padres Lucho y Teresa, cuyo esfuerzo y ejemplo han sido la guía constante en mi camino.

A mi hermano Jorge, compañero incondicional en cada desafío; a mis tíos Ruperto e Irma, por su apoyo y cariño silencioso pero profundo; y a mis queridas abuelas Isabel y Julia, cuyas enseñanzas, fortaleza y amor marcaron mi vida de manera imborrable.

Sin el ejemplo de todos ustedes, este sueño no habría sido posible. Que Dios nos proteja siempre y que este logro sea reflejo de su presencia en cada paso de mi historia.

AGRADECIMIENTO

Expreso mi más sincero agradecimiento a todos quienes, de una u otra forma, hicieron posible la culminación de esta investigación.

A mi asesor y guía académico, Dr. Héctor Aroquipa Velásquez, por su exigencia intelectual, su orientación precisa y su permanente compromiso con la excelencia científica; su liderazgo inspiró el rigor, la disciplina y la pasión que sustentan cada página de este trabajo.

A los docentes del programa doctoral, por compartir su conocimiento con generosidad y exigencia. A las instituciones que brindaron acceso a información, datos y recursos esenciales para el desarrollo de la investigación.

A mis colegas y amigos investigadores, por sus valiosas observaciones, su compañía en largas jornadas de análisis y su espíritu colaborativo. Y, de manera muy especial, a mi familia, por su paciencia, comprensión y apoyo inquebrantable durante todo este proceso.

ÍNDICE

RESUMEN	xiii
ABSTRACT.....	14
I. INTRODUCCIÓN	15
1.1. Planteamiento del Problema	15
1.2. Descripción del Problema.....	18
1.3. Formulación del Problema.....	21
1.3.1. <i>Problema General</i>	21
1.3.2. <i>Problemas Específicos</i>	21
1.4. Antecedentes.....	21
1.4.1. <i>Internacionales</i>	22
1.4.2. <i>Nacionales</i>	23
1.5. Justificación de la Investigación	24
1.5.1. <i>Justificación Teórica</i>	24
1.5.2. <i>Justificación Metodológica</i>	25
1.5.3. <i>Justificación Práctica</i>	26
1.5.4. <i>Justificación Social</i>	28
1.5.5. <i>Importancia de la Investigación</i>	29
1.5.6. <i>Fundamento de la Investigación</i>	30
1.6. Limitaciones de la Investigación	31
1.6.1. <i>Espacial</i>	31
1.6.2. <i>Temporal</i>	32
1.7. Objetivos de la Investigación	33
1.7.1. <i>Objetivo General</i>	33
1.7.2. <i>Objetivos Específicos</i>	33
1.8. Hipótesis	34
1.8.1. <i>Hipótesis General</i>	34
1.8.2. <i>Hipótesis Específicos</i>	34

II.	MARCO TEÓRICO.....	35
2.1.	Marco conceptual.....	35
2.1.1.	<i>Fundamentos de la gestión tradicional y teoría del caos.</i>	36
2.1.2.	<i>El caos como oportunidad de mejora en la organización.</i>	38
2.1.3.	<i>Aportes de Nonaka (1988), Singh y Singh (2002), Óscar (2017), Duque (2017).</i>	39
2.2.	Caos en los Mercados Internacionales.....	40
2.2.1.	<i>Definición y características de los mercados caóticos.</i>	41
2.2.2.	<i>Ejemplos de volatilidad en commodities estratégicos.</i>	41
2.2.3.	<i>Implicancias para la economía y las cadenas de suministro.</i>	42
2.3.	Commodities y Cadenas de Suministro.....	43
2.3.1.	<i>Concepto de commodities y su importancia económica.</i>	43
2.3.2.	<i>Enfoques econométricos tradicionales.</i>	45
2.3.3.	<i>Integración de herramientas de gestión: benchmarking, cuadro de mando integral y Commodity Channel Index (CCI).</i>	47
2.4.	Series de Tiempo y Modelos Lineales.....	50
2.4.1.	<i>Concepto de series temporales en economía y finanzas.</i>	50
2.4.2.	<i>Modelos Box-Jenkins ARIMA (p, d, q).</i>	53
2.5.	Criterios de Validación de Modelos	59
2.5.1.	<i>Estadístico Durbin-Watson.</i>	59
2.5.2.	<i>Critério AKEIKE (AIC).</i>	61
2.5.3.	<i>Criterio BIC y sus limitaciones.</i>	63
2.6.	Modelos Avanzados y No Lineales	64
2.6.1.	<i>Regresión Simbólica (SR).</i>	64
2.6.2.	<i>Sistemas de altas dimensiones en la dinámica caótica.</i>	68
2.6.3.	<i>Características de un sistema dinámico no lineal.</i>	71
2.7.	Modelos de Caos Aplicados	76
2.7.1.	<i>Ecuación de Verhulst y caos temporal.</i>	76
2.7.2.	<i>Análisis de la bifurcación.</i>	78
2.7.3.	<i>Aplicaciones en calidad y rendimiento de sistemas productivos:</i>	80

III.	MÉTODO	85
3.1.	Tipo de Investigación	85
3.1.1.	<i>Tipo</i>	85
3.1.2.	<i>Nivel</i>	86
3.1.3.	<i>Códigos y Nomenclaturas UNESCO</i>	88
3.1.4.	<i>Diseño de la Investigación</i>	88
3.2.	Población y Muestra	89
3.2.1.	<i>Población</i>	89
3.2.2.	<i>Tamaño de la Muestra</i>	90
3.2.3.	<i>Muestreo</i>	91
3.3.	Operacionalización de Variables	93
3.3.1.	<i>Estrategia de Prueba de Hipótesis</i>	93
3.3.2.	<i>Procedimiento para demostrar la hipótesis nula</i>	94
3.3.3.	<i>Variables e Indicadores</i>	95
3.4.	Instrumentos	101
3.4.1.	<i>Técnicas de Procesamiento de Datos</i>	101
3.4.2.	<i>Técnicas de Análisis e Interpretación de la Información</i>	103
3.4.3.	<i>Instrumentos de Recolección de Datos</i>	104
3.4.4.	<i>Validación de los Instrumentos</i>	105
3.5.	Análisis de Datos	106
3.6.	Consideraciones Éticas	108
IV.	RESULTADOS.....	111
4.1.	Análisis descriptivo de los commodities críticos.....	111
4.1.1.	<i>Clasificación de commodities importados y nacionales</i>	113
4.1.2.	<i>Distribución porcentual de peso y costo en la fabricación de electrodos</i>	116
4.1.3.	<i>Identificación de insumos críticos</i>	120
4.2.	Comportamiento internacional de los índices bursátiles	126
4.2.1.	<i>Evolución del Dow Jones y LME (2000–2024).</i>	128

4.2.2.	<i>Hechos mundiales que afectaron la volatilidad de los precios (crisis, guerras, pandemia, Brexit, etc.).</i>	135
4.2.3.	<i>Identificación de comportamientos caóticos y no lineales.</i>	139
4.3.	Análisis de precios y consumo de insumos	143
4.3.1.	<i>Análisis de precios y consumo de insumos</i>	146
4.3.2.	<i>Análisis de precios y consumos de hierro en polvo adquirido por los fabricantes de electrodos</i>	151
4.3.3.	<i>Análisis de precios y consumos de las Ferroaleaciones a base de Níquel adquiridas por los fabricantes de electrodos.</i>	154
4.3.4.	<i>Análisis de precios y consumos de las Ferroaleaciones de Silicio adquiridas por los fabricantes de electrodos.</i>	156
4.3.5.	<i>Análisis de precios y consumos de las Ferroaleaciones de Cromo adquiridas por los fabricantes de electrodos.</i>	158
4.3.6.	<i>Análisis de precios y consumos de minerales no metálicos a base de Na-K-Ca (sólido y líquido) adquiridos por los fabricantes de electrodos</i>	161
4.3.7.	<i>Análisis de la gestión de compras y cumplimiento normativo en la adquisición de commodities para electrodos</i>	163
4.3.8.	<i>Resultado usando modelo Box-Jenkins ARIMA.</i>	165
4.3.9.	<i>Resultado usando modelo de Regresión Simbólica (RS)</i>	169
4.4.	Modelos de predicción aplicados	173
4.4.1.	<i>Resultados con el modelo ARIMA (Box-Jenkins).</i>	175
4.4.2.	<i>Resultados con el modelo de Regresión Simbólica (RS).</i>	177
4.4.3.	<i>Comparación RS vs. ARIMA.</i>	184
4.5.	Validación de la hipótesis nula	192
4.5.1.	<i>Determinación del tamaño de muestra para cada técnica.</i>	195
4.5.2.	<i>Resultados del $p\text{-value} \leq 0.05$ con Minitab.</i>	201
4.5.3.	<i>Discusión de aceptación/rechazo de la hipótesis.</i>	205
4.6.	Evaluación de un nuevo insumo en la fabricación de electrodos	210
V.	DISCUSIÓN DE LOS RESULTADOS	217
VI.	CONCLUSIONES	221

VII.	RECOMENDACIONES.....	224
VIII.	REFERENCIAS	228
IX.	ANEXOS	238
<i>Anexo A:</i> Glosario.....		240
<i>Anexo B:</i> Matriz de Consistencias.....		242
<i>Anexo C:</i> Figura A1, ubicación proveedores.....		243
<i>Anexo D:</i> Análisis Casos índice Commodities usando modelo ARIMA.....		245
<i>Anexo E:</i> Análisis Casos índice Commodities según modelo RS.....		278
<i>Anexo F:</i> Hechos de importancia Word Trade Organization Nov2008 a Dic2023.....		289
<i>Anexo G:</i> Tabla Benchmarking utilizado proyecto cadena de Valor		295

ÍNDICE DE FIGURAS

Figura 1. Gráficos correlacionados de datos, (a) una buena correlación tiende a ser normal y (b) los datos son menos correlacionados	57
Figura 2. Organigrama de adquisiciones empresarial para industria fabril de electrodos	112
Figura 3. Relación entre el peso físico, el costo económico, la volatilidad internacional	122
Figura 4. Índice de Criticidad Relativa (ICR).....	123
Figura 5. Commodities de los principales insumos utilizados en la fabricación de electrodos	128
Figura 6. Índices - Dow Jones (Var%) correspondiente a los años 2000 a febrero 2024	131
Figura 7. % de Variación Dow Jones vs Commodities: Índex Wire Steel, Al, Ni, FerroAlloys, K- Na	132
Figura 8. Análisis precios y consumos del alambre acero inoxidable para la fabricación de electrodos.....	149
Figura 9. Precio x kg – proveedor de alambres inoxidable.....	150
Figura 10. Análisis precios y consumos de minerales a base de hierro en polvo	152
Figura 11. Precio x kg – proveedor de mineral a base de hierro en polvo.....	153
Figura 12. Análisis precios minerales a base de níquel metálico en polvo.....	155
Figura 13. Precio x kg – proveedor de mineral a base de níquel metálico en polvo	156
Figura 14. Análisis precios minerales de Ferroaleación de silicio en polvo.....	157
Figura 15. Precio x kg – proveedor de ferroaleación de silicio en polvo	158
Figura 16. Análisis precios minerales de Ferroaleación de cromo en polvo	159

Figura 17. Precio x kg – proveedor de ferroaleación de cromo en polvo	160
Figura 18. Resumen precios minerales No metálico a base Na-K-Ca en polvo	162
Figura 19. Precio x kg – proveedor de Mineral No Metálico Na-K-Ca en polvo.....	162
Figura 20. Ejemplo del precio por Stock final del Ni en LME 2024.....	168
Figura 21. % de Variación entre índice real y proyectado usando método ARIMA	168
Figura 22. % de Variación entre índice real y el proyectado usando Regression Symbolic ..	172
Figura 23. Pseudocódigo del algoritmo Feynman–RS propuesto.....	180
Figura 24. Comparación del error porcentual promedio (RS vs. ARIMA)	186
Figura 25.. Distribución de residuos estandarizados (ARIMA vs. RS).....	190

ÍNDICE DE TABLAS

Tabla 1. Variables e Indicadores – Operacionalización de Variables	100
Tabla 2 Distribución en peso y costo de fabricar de un electrodo especial de soldadura - Bach de 40,000 kg.....	113
Tabla 3 Distribución porcentual por peso en la composición de un electrodo típico	117
Tabla 4 Distribución porcentual por costo en la producción de electrodos	118
Tabla 5. Clasificación de criticidad de insumos en la fabricación de electrodos	121
Tabla 6 Insumos que se utilizan en la fabricación de electrodos especiales.....	164
Tabla 7 Indicadores proyectados calculados usando método ARMA para las materias primas para la fabricación de soldadura Inox 308L	166
Tabla 8 Data prediction using ARIMA first half of 2024.....	167
Tabla 9 Estimación mediante RS para Alambre Aluminio identificando la ecuación optima identificado como eq60 con R-squared: 99.165%.....	170
Tabla 10 Data prediction using Regression Symbolic first half of 2024.....	171
Tabla 11 Indicadores estadísticos del modelo ARIMA aplicado a commodities seleccionados	176
Tabla 12 Tabla 19. Indicadores globales de desempeño del algoritmo Feynman–RS	180
Tabla 13 Indicadores estadísticos de desempeño (Eq60)	182
Tabla 14 Comparación entre valores reales y proyectados – Aluminio (enero–junio 2024).183	
Tabla 15 Comparación de desempeño estadístico entre modelos ARIMA y RS (primer semestre 2024).....	185
Tabla 16 Resultados estadísticos de validación – Modelos ARIMA y RS.....	189

Tabla 17 Suficiencia muestral.....	200
Tabla 18 Resultados de pruebas de significancia (Minitab)	202
Tabla 19 Error de predicción por modelo (consolidado)	204
Tabla 20 Perfil de los talleres encuestados	212
Tabla 21 Percepción comparada (Likert 1–5, media $\pm$ DE)	212
Tabla 22 Con ponderaciones igualitarias ($w_j = 0.25$):	214

RESUMEN

Objetivo: Analizar cómo la dinámica caótica y las ecuaciones no lineales influyen en los índices internacionales Dow Jones Industrial Average (DJIA) y London Metal Exchange (LME), y su impacto en la gestión de la cadena de suministro de commodities importados en la industria peruana de electrodos (2018–2023). **Metodología:** Se aplicó un enfoque cuantitativo, aplicado y explicativo. Se utilizaron modelos ARIMA (Box–Jenkins) y Regresión Simbólica (RS) con el algoritmo de Feynman AI para proyectar precios semestrales de insumos críticos (Ni, Cu, Al, acero inoxidable, ferroaleaciones). Los análisis se realizaron en Minitab mediante pruebas t, ANOVA, Wilcoxon y criterios AIC/BIC, complementados con KPI logísticos. **Resultados:** La RS obtuvo una mayor precisión (MAPE = 2.11%) frente a ARIMA (MAPE = 7.84%), mejorando la predicción en 70%. Las correlaciones entre índices internacionales y precios fueron significativas ($\rho = 0.35\text{--}0.78$; $p < 0.001$). Se observó una reducción del 15% en los tiempos de entrega y en las tasas de stock-out. **Conclusiones:** Los mercados globales de commodities presentan un comportamiento caótico determinista, modelable mediante ecuaciones simbólicas. La integración de la RS en la planificación logística optimiza el momento de compra, reduce la exposición a la volatilidad y fortalece la resiliencia operativa. La metodología propuesta puede replicarse en otros sectores industriales para la toma de decisiones predictivas en entornos inciertos.

Palabras clave: Dinámica caótica, ecuaciones no lineales, regresión simbólica, ARIMA.

ABSTRACT

Objective: This research analyzes how chaotic dynamics and nonlinear equations influence the behavior of international price indices such as the Dow Jones Industrial Average (DJIA) and the London Metal Exchange (LME), and how these affect the supply chain management of imported commodities for the Peruvian electrode industry between 2018 and 2023.

Methodology: A quantitative, applied, and explanatory approach was used. Time-series models (ARIMA, Box–Jenkins) and Symbolic Regression (RS) based on the Feynman AI algorithm were applied to predict six-month price variations of critical inputs (Ni, Cu, Al, stainless steel, ferroalloys). Statistical tests (t-test, ANOVA, Wilcoxon, Durbin–Watson, AIC/BIC) and key performance indicators (KPI) were processed using Minitab. **Results:** The RS model achieved higher accuracy (MAPE = 2.11%) compared to ARIMA (MAPE = 7.84%), demonstrating a 70% improvement in predictive precision. Correlations between international indices and commodity prices were significant ($\rho = 0.35\text{--}0.78$, $p < 0.001$). The integration of nonlinear models improved KPI performance, reducing lead time and stock-out rates by 15%. **Conclusions:** The study confirms that global commodity markets exhibit deterministic chaotic behavior that can be effectively modeled through nonlinear and symbolic equations. The integration of RS into supply chain planning enables better timing, reduced volatility exposure, and higher operational resilience. The findings establish a methodological framework applicable to other industrial sectors for predictive decision-making under uncertainty.

Keywords: Chaotic dynamics, nonlinear equations, symbolic regression, ARIMA.

I. INTRODUCCIÓN

1.1. Planteamiento del Problema

La gestión de la cadena de suministro en la industria de los electrodos se enfrenta a un entorno caracterizado por una alta volatilidad en los precios de los commodities internacionales, especialmente aquellos cotizados en la London Metal Exchange (LME) y en los índices Dow Jones. Dado que más del 80 % de los insumos empleados en el proceso de fabricación son importados, los fabricantes peruanos están expuestos a choques externos que incrementan los costos de producción y comprometen la rentabilidad empresarial. Esta situación se agrava cuando se observa que los mecanismos tradicionales de planeamiento basados en modelos lineales no son insuficientes para anticipar fluctuaciones abruptas y recurrentes en el mercado global.

La teoría económica contemporánea ha demostrado que los sistemas de mercado responden a dinámicas no lineales, donde pequeños cambios en las condiciones iniciales generan variaciones desproporcionadas en los resultados. En la investigación Guegan (2009) en su artículo *“Chaos in economics and finance publicado en Annual Reviews in Control”*, señala que los sistemas caóticos forman parte de los sistemas dinámicos deterministas, aplicables al análisis de mercados financieros para la previsión. De manera complementaria otras investigaciones como como Day (1992) en su libro *“Complex economic dynamics Vol 2”*, Benhabib (1979) *“Nonlinear dynamics in economic theory. Scandinavian Journal of Economics Vol 9”*, Nishimura y Grandmont (1988) *“Nonlinear difference equations, bifurcations, and chaos in Macroeconomic Dynamics vol 2”*, evidenciaron que ciertos modelos macroeconómicos no lineales pueden generar fluctuaciones autosostenidas incluso sin la presencia de shocks externos. En el mismo sentido en su artículo *“Heterogeneous beliefs and routes to chaos in a simple asset pricing model in Journal of Economic Dynamics and*

Control”, mostraron que la introducción de creencias heterogéneas en modelos de expectativas tradicionales conduce a trayectorias caóticas que desafían la estabilidad prevista por los modelos lineales.

Desde una perspectiva metodológica, en la investigación de Matilla (2003), en su artículo titulado “*Teoría del caos y mercados financieros. Universidad Complutense, Madrid 2003*”, sostiene que el caos no debe confundirse con aleatoriedad, pues constituye un fenómeno determinista cuya aparente imprevisibilidad surge de su alta sensibilidad a las condiciones iniciales.

Según Abraham (2004) en su artículo “*Abraham, A., Philip, N. S., & Saratchandran, P. in Modeling chaotic behavior of stock indices using intelligent paradigms*”, publicado por Oklahoma State University, Department of Computer Science 2004, el desarrollo de modelos de comportamiento caótico de índices bursátiles aplicando técnicas de inteligencia artificial cambia el concepto, lo que reforzó la idea de que los mercados financieros y de commodities no pueden comprenderse adecuadamente sin un enfoque no lineal.

En esta línea, según Andrew (1996) en su tesis doctoral “*Time series prediction using supervised learning and tools from chaos theory*”, exploró la predicción de series de tiempo a partir de herramientas derivadas de la teoría del caos, aportando evidencia de su aplicabilidad práctica en escenarios económicos complejos.

En los últimos años, según Akif (2023) en su artículo titulado “*Chaos theory and its applications in economic and productive systems publicado Faculty of Engineering, Turkiye 2003*”, amplió el espectro de aplicaciones de la teoría del caos en los sistemas financieros y productivos, resaltando que su uso no solo mejora la predicción, sino que también fortalece la capacidad de resiliencia de las organizaciones.

Según Grabiela (2014) en su estudio titulado “*Ecuaciones no lineales aplicadas a la cadena de suministro global*”, publicado en la Universidad de Buenos Aires 2014, puntualizó que las ecuaciones no lineales permiten modelar variables críticas de la cadena de suministro como la demanda, los precios y la logística, donde la proporcionalidad clásica entre estímulo y respuesta deja de ser válida.

Asimismo, los principios de administración formulados en la investigación por Fayol (1917) en su artículo “*Administration industrielle et générale: Prévoyance, organisation, commandement, coordination, contrôle*”, publicado Paris 1917, se orienta a la planeación, organización, coordinación y control, se mantienen vigentes, aunque requieren ser reinterpretados bajo el prisma de entornos caóticos y de alta complejidad. Herramientas estadísticas como los modelos de Box y Jenkins han demostrado ser eficaces en la identificación de patrones ocultos en series temporales, y su combinación con técnicas como la regresión simbólica ofrece un marco potente para abordar la dinámica caótica en la gestión de suministros.

El problema central, entonces, se concentra en la limitada adopción de modelos no lineales y caóticos en la gestión de la cadena de suministro en el Perú. La persistencia en el uso de enfoques lineales genera decisiones empresariales tardías, poca capacidad de respuesta ante variaciones abruptas de los precios internacionales y debilidad en la planificación de stocks estratégicos. Esta brecha metodológica no solo compromete la eficiencia operativa, sino que también incrementa la vulnerabilidad financiera de la industria nacional de electrodos frente a la competencia internacional.

En este contexto, la presente investigación parte de la premisa de que la integración de la dinámica caótica y las ecuaciones no lineales en los procesos de análisis y toma de decisiones permitirá anticipar escenarios críticos, optimizar el aprovisionamiento de insumos importados y fortalecer la competitividad de la industria local frente a las presiones del mercado global.

Asimismo, los principios de administración formulados en la investigación por Fayol (1917) en su artículo “*Administration industrielle et générale: Prévoyance, organisation, commandement, coordination, contrôle*”, publicado Paris 1917, se orienta a la planeación, organización, coordinación y control, se mantienen vigentes, aunque requieren ser reinterpretados bajo el prisma de entornos caóticos y de alta complejidad. Herramientas estadísticas como los modelos de Box y Jenkins han demostrado ser eficaces en la identificación de patrones ocultos en series temporales, y su combinación con técnicas como la regresión simbólica ofrece un marco potente para abordar la dinámica caótica en la gestión de suministros.

El problema central, entonces, se concentra en la limitada adopción de modelos no lineales y caóticos en la gestión de la cadena de suministro en el Perú. La persistencia en el uso de enfoques lineales genera decisiones empresariales tardías, poca capacidad de respuesta ante variaciones abruptas de los precios internacionales y debilidad en la planificación de stocks estratégicos. Esta brecha metodológica no solo compromete la eficiencia operativa, sino que también incrementa la vulnerabilidad financiera de la industria nacional de electrodos frente a la competencia internacional.

En este contexto, la presente investigación parte de la premisa de que la integración de la dinámica caótica y las ecuaciones no lineales en los procesos de análisis y toma de decisiones permitirá anticipar escenarios críticos, optimizar el aprovisionamiento de insumos importados y fortalecer la competitividad de la industria local frente a las presiones del mercado global.

1.2. Descripción del Problema

La industria peruana de electrodos opera en un entorno globalizado donde la dependencia de insumos importados alcanza más del 80 %, lo que convierte a sus procesos productivos en altamente sensibles a la volatilidad de los mercados internacionales de metales.

Esta situación se intensifica debido a la estructura de los commodities, que se dividen en insumos estratégicos (aceros inoxidable, níquel y aleaciones especiales) y no estratégicos (consumidos masivamente en soldaduras convencionales), con relaciones de precios que varían de 1:10 hasta 1:200, lo cual amplifica el riesgo de pérdidas financieras ante cambios bruscos en la cotización internacional.

Uno de los principales problemas radica en la formación de precios de los commodities, determinada por mecanismos de mercado que utilizan fórmulas de promedios móviles, condiciones de embarque como Ex-Works, y políticas de precios definidas al momento del despacho. Esto genera escenarios en los que los fabricantes locales carecen de información oportuna para decidir si conviene anticipar compras, acumular stocks o esperar nuevas condiciones del mercado. A ello se suma que los insumos estratégicos requieren plazos de programación de uno a dos años, lo que limita la flexibilidad empresarial y expone a los productores a riesgos adicionales en entornos inestables.

Según Guegan (2009) en su investigación “*Chaos in economics and finance. Annual Reviews in Control de Annual Reviews in Control*”, el marco teórico respalda que estos procesos no pueden ser comprendidos bajo modelos lineales tradicionales. Se explica que los sistemas caóticos permiten analizar mercados financieros donde el comportamiento no responde a patrones simples. De manera similar, otros autores como Day (1992), Benhabib (1979) y Grandmont (1988) demostraron que la dinámica no lineal genera ciclos autosostenidos sin intervención externa, lo que refleja la naturaleza intrínseca de los mercados de commodities.

Según Brock et al. (1998) reforzaron esta visión al mostrar que las creencias heterogéneas en agentes económicos derivan en trayectorias inestables y caóticas.

En el plano de la predicción, según Matilla (2003), subraya que el caos es determinista, pero su sensibilidad a condiciones iniciales lo hace parecer aleatorio, lo que explica la dificultad de anticipar la dirección de los precios internacionales.

Según Abraham (2004), aportó evidencia empírica al modelar el comportamiento caótico de índices bursátiles mediante algoritmos inteligentes, mientras Andrew (1996), en su tesis doctoral *“Time series prediction using supervised learning and tools from chaos theory”*, demostró la capacidad de la teoría del caos para mejorar la predicción de series de tiempo. Estas aportaciones refuerzan la necesidad de incorporar ecuaciones no lineales como herramienta para anticipar escenarios de precios y mejorar la toma de decisiones.

Por otro lado, según Akif (2023) en su artículo *“Chaos theory and its applications in economic and productive systems”*, resalta que la teoría del caos se ha convertido en un recurso clave para ampliar las aplicaciones en sistemas productivos y financieros, mientras que Grabiela (2014) en su artículo *“Ecuaciones no lineales aplicadas a la cadena de suministro global”*, enfatiza que las ecuaciones no lineales explican fenómenos de demanda, precios y logística donde la respuesta no es proporcional al estímulo, reflejando la realidad de las cadenas de suministro globales.

La administración clásica del siglo XX según Fayol (1917) en su publicación *“Administration industrielle et générale: Prévoyance, organisation, commandement, coordination”*, ya lo había señalado la necesidad de planificar, organizar y controlar procesos; sin embargo, en un contexto de volatilidad extrema, estos principios deben integrarse con herramientas modernas de análisis no lineal.

Desde la estadística aplicada, Box y Jenkins introdujeron metodologías que permiten identificar patrones en series temporales y que, combinadas con regresión simbólica, se vuelven instrumentos poderosos para enfrentar la incertidumbre en cadenas de suministro. Sin embargo, en el Perú, la limitada incorporación de estas herramientas ha generado brechas en la capacidad analítica de las empresas, afectando la eficiencia en la gestión de compras, la fijación de precios y la administración de riesgos. En consecuencia, el problema descrito no solo es económico, sino también metodológico y estratégico: la ausencia de enfoques no lineales en la

gestión de la cadena de suministro limita la capacidad de los fabricantes para anticipar escenarios críticos, generando una dependencia excesiva de condiciones externas que afectan el tiempo, el costo y la calidad de los procesos productivos.

1.3. Formulación del Problema

1.3.1. Problema General

¿En qué medida la dinámica caótica y las ecuaciones no lineales, aplicadas al comportamiento de los índices internacionales, influyen en la gestión de la cadena de suministro de commodities importados en la industria de electrodos en el Perú, periodo 2018-2023?

1.3.2. Problemas Específicos

- ¿Cómo se relaciona la dinámica no lineal con los índices internacionales Dow Jones y LME y qué implicancias tiene en la formación de precios de los commodities estratégicos utilizados en la fabricación de electrodos?
- ¿De qué manera las herramientas estadísticas y matemáticas como los modelos de Box y Jenkins y la regresión simbólica permiten anticipar escenarios de volatilidad en la cadena de suministro de insumos críticos?
- ¿Cómo inciden los indicadores de gestión (KPI) diseñados bajo enfoques no lineales en la eficiencia del aprovisionamiento de insumos importados en la industria de electrodos?
- ¿Qué impacto tiene la adopción de la dinámica caótica y las ecuaciones no lineales en la toma de decisiones estratégicas respecto al tiempo de compra, niveles de stock y resiliencia empresarial frente a la volatilidad del mercado internacional?

1.4. Antecedentes

El estudio de la dinámica caótica y de las ecuaciones no lineales en la gestión de la cadena de suministro constituye un campo en el que confluyen la teoría económica, la estadística aplicada y la ingeniería de la producción. Su revisión de antecedentes permite contextualizar el problema en dos niveles: el nacional, con énfasis en la realidad peruana, y el internacional, donde se han desarrollado los principales marcos conceptuales y metodológicos.

1.4.1. Internacionales

Según Matilla (2003) en su artículo “*Teoría del caos y mercados financieros*”, lo que se pretende fundamentalmente es responder a una serie de preguntas que relacionan las series históricas de los mercados de valores y el análisis de las mismas desde la teoría del caos que expresa lo siguiente:

“El papel de la dinámica caótica y la complejidad ha sido crucial y positivo: han hecho que empecemos a hacernos preguntas razonables y que dejemos de hacer hipótesis sobre las fuentes de la aleatoriedad. Con independencia si la palabra caos es acertada o no lo es, conviene aclarar para el lector no habituado a esta literatura que en esencia caos y aleatoriedad son polos opuestos. Y esto es así porque el caos es cien por cien determinista, pese a que los resultados derivados a partir de sistemas dinámicos caóticos sean “aparentemente” aleatorios”. (Mariano Matilla, 2003).

Según Ajith et al. (2004) en su artículo “*Modeling Chaotic Behavior of Stock Indices Using Intelligent*” mencionan que el modelamiento del comportamiento caótico en los índices bursátiles mediante paradigmas inteligentes para predicciones del mercado de valores se ha establecido ampliamente. Que expresan que:

“El comportamiento aparentemente caótico de los mercados de valores podría resolver varios paradigmas ambivalente y técnicas de computación más eficaces. Para demostrar las diferentes técnicas, consideramos el índice Nasdaq-100 de Nasdaq Stock Market SM y el índice bursátil S&P CNX NIFTY. Considerando una red

neuronal artificial entrenada utilizando el algoritmo Levenberg-Marquardt, Support Vector Machine (SVM), el modelo neuro difuso Takagi-Sugeno y una red neuronal de refuerzo de diferencias (DBNN), que sean lo suficientemente buenos y robustos como para proporcionar un modelo de pronóstico confiable para los índices del mercado de valores”. (Ajith Abraham, 2004).

De forma complementaria, Guegan (2009) en su artículo “Chaos in economics and finance. *Annual Reviews in Control*”, explica que los sistemas caóticos, aunque deterministas, muestran comportamientos altamente sensibles a las condiciones iniciales, lo que los hace útiles en la previsión económica y financiera. En la misma línea, según Day (1992) en su artículo “*Complex economic dynamics*”, Benhabib (1979) en artículo “Nonlinear dynamics in economic theory” y Grandmont (1988) en su artículo “*Nonlinear difference equations, bifurcations, and chaos in economics*”, demostraron que los modelos macroeconómicos no lineales podían generar ciclos autosostenidos sin necesidad de shocks externos, reforzando la pertinencia de los modelos caóticos en la explicación de fluctuaciones de precios.

Según Brock y Hommes (1998) en su artículo “*Heterogeneous beliefs and routes to chaos in a simple asset pricing model*”, aportan que la introducción de expectativas heterogéneas en agentes económicos produce trayectorias caóticas en modelos de fijación de precios, lo que resulta directamente aplicable a los mercados de commodities.

Según Grabiela (2014) en su artículo “*Ecuaciones no lineales aplicadas a la cadena de suministro global*”, sostiene que en la cadena de suministro, las ecuaciones no lineales permiten describir fenómenos en los que la respuesta no es proporcional al estímulo, al afirmar que:

“Las ecuaciones no lineales describen la evolución de sistemas donde la predicción a largo plazo es difícil, pues las interacciones generan comportamientos complejos en la demanda, los precios y la logística”.

1.4.2. Nacionales

En el Perú, no existen estudios previos que apliquen directamente la dinámica caótica y las ecuaciones no lineales a la gestión de la cadena de suministro de commodities en la industria de electrodos. Esta ausencia evidencia un vacío metodológico que justifica la relevancia de la presente investigación.

1.5. Justificación de la Investigación

1.5.1. Justificación Teórica.

El sustento teórico de la presente investigación se encuentra en la aplicación de la dinámica caótica y de las ecuaciones no lineales como herramientas para comprender fenómenos económicos y logísticos que no pueden explicarse adecuadamente mediante modelos lineales tradicionales. En la gestión de la cadena de suministro, especialmente en la industria de electrodos en el Perú, los precios de los insumos importados muestran fluctuaciones abruptas, dependencia de condiciones iniciales y comportamientos no proporcionales al estímulo del mercado, lo cual justifica la pertinencia de un marco analítico basado en teorías de complejidad. De acuerdo con Guegan (2009) en la investigación “Chaos in economics and finance. *Annual Reviews in Control*”, sostiene que los sistemas caóticos son deterministas y, aunque parecen aleatorios, siguen reglas precisas que los hacen útiles para la previsión en contextos financieros y económicos. Según Matilla (2003) en su investigación “*Teoría del caos y mercados financieros*”, complementa esta idea al señalar que el caos no debe confundirse con la aleatoriedad, ya que constituye un comportamiento determinista cuya aparente irregularidad surge de su alta sensibilidad a condiciones iniciales. Estas características lo convierten en un marco adecuado para analizar las series bursátiles y, en particular, los índices internacionales como el Dow Jones y la London Metal Exchange (LME), que condicionan directamente los costos de los commodities importados.

Asimismo, según Brock y Hommes (1998) en su artículo “*Heterogeneous beliefs and routes to chaos in a simple asset pricing model*”, demostraron que la introducción de expectativas heterogéneas en modelos de fijación de precios puede desencadenar trayectorias inestables y caóticas, lo cual refleja fielmente la dinámica de los mercados de insumos metálicos. Dichos aportes evidencian que los sistemas económicos no siguen patrones lineales de equilibrio, sino que responden a dinámicas complejas que requieren metodologías más avanzadas para su análisis. En este marco, la justificación teórica de la investigación radica en que la aplicación de la dinámica caótica y de las ecuaciones no lineales permitirá interpretar con mayor precisión la evolución de los precios internacionales de commodities estratégicos y su efecto en la cadena de suministro. De esta manera, se aporta al conocimiento científico al demostrar que el uso de estos enfoques no solo es pertinente en las finanzas internacionales, sino también en la gestión industrial, abriendo un nuevo campo de aplicación para las ciencias económicas y de la ingeniería

1.5.2. Justificación Metodológica.

La justificación metodológica de esta investigación radica en la necesidad de utilizar enfoques cuantitativos y modelos matemáticos avanzados que reflejen la complejidad de los mercados internacionales y su incidencia en la cadena de suministro de la industria de electrodos en el Perú. Dada la naturaleza no lineal y volátil de los precios de los commodities, los métodos tradicionales de análisis lineal resultan insuficientes para explicar y anticipar el comportamiento de estas series de tiempo.

En este contexto, el empleo de la dinámica caótica y de las ecuaciones no lineales constituye la estrategia metodológica más adecuada, pues permite identificar patrones ocultos y trayectorias sensibles a condiciones iniciales que caracterizan a los mercados internacionales de insumos. Box y Jenkins, con su modelo de series temporales, ofrecen una base estadística sólida que, al complementarse con la regresión simbólica, amplía la capacidad predictiva y

explica de manera más precisa la volatilidad. Asimismo, según Hernández et al. (2014) en su libro “*Metodología de la investigación*”, subrayan que la validez de una investigación depende de la rigurosidad en la construcción de instrumentos de recolección de datos y en la aplicación de técnicas de análisis confiables. En esta línea, el uso de fuentes reconocidas como el índice Dow Jones, la London Metal Exchange y los registros del Banco Central de Reserva del Perú asegura la confiabilidad de la información utilizada para el modelamiento.

De manera complementaria, según Abraham (2004) en su artículo “*Modeling chaotic behavior of stock indices using intelligent paradigms*”, evidenció que el modelamiento de series bursátiles con técnicas inteligentes —como redes neuronales, modelos neuro-difusos y algoritmos de optimización— permite construir modelos robustos para la predicción de índices financieros. Este aporte respalda la pertinencia de aplicar metodologías no lineales y caóticas en el análisis de la cadena de suministro. En consecuencia, la investigación se justifica metodológicamente porque integra: (a) un diseño no experimental y correlacional, que permite explorar la relación entre la dinámica caótica y la gestión de la cadena de suministro; (b) el uso de técnicas estadísticas y de modelamiento avanzado, que trascienden los enfoques tradicionales de predicción; y (c) la aplicación de criterios de validez y confiabilidad que garantizan la calidad de los resultados. De esta forma, el diseño metodológico no solo asegura la pertinencia de los hallazgos, sino que también genera un modelo replicable y transferible a otras industrias peruanas que enfrenten la misma exposición a la volatilidad de los mercados globales.

1.5.3. Justificación Práctica.

La justificación práctica de esta investigación se sustenta en la necesidad de brindar soluciones concretas a los problemas que enfrenta la industria peruana de electrodos frente a la alta dependencia de insumos importados y la volatilidad de los precios internacionales de los commodities. La variabilidad de los índices de referencia, como la London Metal Exchange

(LME) y el Dow Jones, impacta directamente en los costos de producción y, en consecuencia, en la competitividad de las empresas. En este escenario, el uso de herramientas basadas en dinámica caótica y ecuaciones no lineales permite anticipar fluctuaciones de precios y ofrecer a los gestores empresariales instrumentos predictivos más confiables. Según Grabiela (2014) en su artículo “*Ecuaciones no lineales aplicadas a la cadena de suministro global*”, señala que las ecuaciones no lineales describen sistemas en los que la respuesta no es proporcional al estímulo, lo que refleja con mayor realismo los fenómenos de demanda, inventarios y logística. Esto implica que su aplicación práctica facilita la toma de decisiones respecto a tiempos de compra, acumulación de stocks y selección de proveedores estratégicos.

Según Akif (2023) en su artículo “*A new look at the statistical model identification*”, resalta que la teoría del caos ha expandido su campo hacia la logística y la gestión de la producción, destacando que estas herramientas incrementan la capacidad de resiliencia frente a entornos inciertos. En el caso peruano, ello se traduce en la posibilidad de reducir la exposición a riesgos financieros y operativos que afectan la continuidad de la cadena de suministro. Además, según Brock y Hommes (1998) en su artículo “*Heterogeneous beliefs and routes to chaos in a simple asset pricing model*”, demostraron que las expectativas heterogéneas de los agentes pueden generar trayectorias inestables en los precios, lo cual explica por qué las empresas deben incorporar metodologías avanzadas de predicción para transformar esa incertidumbre en información útil para la gestión. Aplicado a la industria de electrodos, este aporte implica la posibilidad de optimizar los costos de aprovisionamiento, mejorar la rentabilidad y fortalecer la competitividad frente a los mercados internacionales.

En síntesis, la justificación práctica radica en que los resultados de esta investigación no se limitarán al ámbito académico, sino que se convertirán en herramientas aplicables de gestión empresarial, contribuyendo a que las empresas tomen decisiones oportunas y sostenibles en un entorno marcado por la volatilidad global.

1.5.4. Justificación Social.

El desarrollo de la presente investigación no solo responde a una necesidad teórica y metodológica, sino también a un compromiso con la realidad social y productiva del país. La industria de los electrodos, al depender de insumos importados y estar expuesta a la volatilidad de los mercados internacionales, impacta de manera directa en la cadena de valor de la construcción, la minería y la manufactura peruana. La ineficiencia en la gestión de aprovisionamiento repercute no únicamente en los costos de producción, sino también en la generación de empleo, la competitividad del sector y la estabilidad de los precios en segmentos que sostienen el desarrollo económico nacional.

En este contexto, aplicar modelos de dinámica caótica y ecuaciones no lineales permite dotar a las empresas de herramientas predictivas más confiables, que a su vez contribuyen a fortalecer la capacidad de resiliencia frente a crisis internacionales de precios. Tal como sostienen los autores Akif (2023) y Grabiela (2014), la aplicación de estas metodologías en la logística y en la cadena de suministros promueve decisiones más estratégicas, lo que redundará en beneficios colectivos al reducir la vulnerabilidad de las industrias locales.

La relevancia social de este estudio se refleja en dos dimensiones. En primer lugar, en el ámbito empresarial, al posibilitar que los gestores peruanos adopten decisiones más informadas, anticipando escenarios críticos y evitando sobrecostos que limitan la competitividad. En segundo lugar, en el ámbito nacional, al contribuir a que sectores productivos clave —minería, metalurgia y construcción— mantengan un flujo estable de insumos y puedan sostener su capacidad de generación de empleo y aporte fiscal. De esta forma, la justificación social de esta investigación radica en su potencial para convertirse en un instrumento de transformación, al generar conocimiento aplicable que no solo beneficia a las empresas de la industria de electrodos, sino que también fortalece el ecosistema productivo peruano frente a las dinámicas globales.

1.5.5. Importancia de la Investigación

La presente investigación reviste una gran importancia por su capacidad de aportar tanto al conocimiento científico como a la práctica empresarial e industrial en el Perú. En primer lugar, desde la perspectiva académica y científica, la investigación contribuye a ampliar el campo de aplicación de la dinámica caótica y de las ecuaciones no lineales en el análisis de fenómenos económicos y logísticos. Tradicionalmente, la teoría del caos ha sido empleada en ámbitos como la física o las matemáticas, pero en este estudio se traslada a la gestión de cadenas de suministro, lo cual constituye un aporte original y novedoso que fortalece el diálogo entre la ingeniería, la economía y la administración. De esta forma, se genera un marco teórico que puede servir de base para futuras investigaciones en sectores industriales expuestos a condiciones de alta volatilidad. En segundo lugar, la investigación tiene una marcada importancia práctica, ya que proporciona a las empresas fabricantes de electrodos herramientas predictivas más robustas para anticipar la evolución de los precios de los insumos importados, como aceros especiales, aleaciones metálicas y otros commodities estratégicos. Al implementar modelos basados en dinámica caótica y ecuaciones no lineales, los gestores podrán tomar decisiones más oportunas respecto al aprovisionamiento, los niveles de stock y la negociación con proveedores internacionales, reduciendo riesgos financieros y mejorando la eficiencia de los procesos productivos.

En tercer lugar, el estudio posee una trascendencia social y económica. La industria de los electrodos abastece a sectores clave para el desarrollo nacional, como la construcción, la minería y la metalurgia. Una gestión más eficiente de su cadena de suministro repercute en la competitividad de estas actividades, en la generación de empleo y en el aporte al producto bruto interno. Al fortalecer la capacidad de resiliencia de las empresas frente a la volatilidad de los mercados internacionales, se contribuye de manera indirecta a la estabilidad económica y al bienestar social. Finalmente, la investigación es importante porque propone un modelo

metodológico replicable, que puede aplicarse a otros sectores productivos que enfrenten problemas similares de exposición a la incertidumbre internacional. Así, se convierte en un referente para el desarrollo de políticas empresariales y académicas orientadas a la innovación, la sostenibilidad y la competitividad global

1.5.6. Fundamento de la Investigación

El fundamento de esta investigación se sostiene en la necesidad de comprender y gestionar la complejidad inherente a los mercados internacionales de commodities que abastecen a la industria de electrodos en el Perú. La marcada dependencia de insumos importados, sumada a la volatilidad de índices como la London Metal Exchange (LME) y el Dow Jones, ha evidenciado que los enfoques tradicionales de gestión logística resultan insuficientes para anticipar escenarios de alta incertidumbre.

Desde la perspectiva teórica, el caos determinista constituye un marco analítico que permite describir fenómenos donde la dinámica del sistema no es lineal, sino sensible a condiciones iniciales. Como sostiene Guegan (2009) en su artículo “*Chaos in economics and finance. Annual Reviews in Control*”, los sistemas caóticos son deterministas, pero presentan trayectorias altamente inestables que los hacen parecer aleatorios. De igual forma, según Matilla García (2003) en su artículo “*Teoría del caos y mercados financieros*”, aclara que el caos y la aleatoriedad son polos opuestos: mientras el primero responde a reglas precisas, la segunda se relaciona con la falta de estructura. Este fundamento explica por qué la aplicación de la teoría del caos resulta pertinente para modelar las series de precios de commodities.

En el plano metodológico, la investigación se apoya en modelos de series temporales avanzados como los de Box y Jenkins, y en técnicas como la regresión simbólica, que permiten capturar la naturaleza caótica de los mercados. Según Abraham (2004) en su artículo “*Modeling chaotic behavior of stock indices using intelligent paradigms*”, demuestra que el

modelamiento del comportamiento bursátil mediante algoritmos inteligentes (redes neuronales, modelos neuro-difusos, máquinas de soporte vectorial) ofrece resultados predictivos robustos, lo cual valida la pertinencia de trasladar estas herramientas al análisis de la cadena de suministro. Desde la dimensión práctica, Según Grabiela (2014) en su artículo “*Ecuaciones no lineales aplicadas a la cadena de suministro global*”, señala que las ecuaciones no lineales describen sistemas en los que la respuesta no es proporcional al estímulo, lo que refleja la realidad de la demanda, los precios y la logística en entornos globalizados. Así, la investigación fundamenta su relevancia en que permitirá diseñar modelos de gestión que ayuden a los empresarios del sector a anticipar cambios bruscos en los costos de insumos y a definir estrategias de aprovisionamiento más eficientes.

En consecuencia, el fundamento de la investigación radica en la integración de tres dimensiones: Teórica, al aplicar la dinámica caótica y las ecuaciones no lineales como marco explicativo del comportamiento de mercados internacionales. Metodológica, al utilizar modelos matemáticos avanzados que garantizan rigurosidad y capacidad predictiva. Práctica, al generar soluciones aplicables para la industria nacional de electrodos, fortaleciendo su resiliencia frente a la volatilidad global.

Este triple sustento permite afirmar que la investigación no solo contribuye al avance del conocimiento científico, sino que también se convierte en un aporte significativo para la competitividad del sector productivo peruano.

1.6. Limitaciones de la Investigación

1.6.1. Espacial

La investigación se circunscribe a las empresas fabricantes de electrodos en el Perú, en particular aquellas que cuentan con plantas de producción propias y que abastecen al mercado nacional. Entre ellas destacan EXSA, NEXSOL SRL y ARAD Welding, ubicadas en el distrito

de Lurín, Lima, y en la ciudad de Arequipa. Estas empresas fueron seleccionadas por su representatividad dentro del sector y por concentrar una proporción significativa del mercado nacional de soldaduras convencionales y especiales

Esta delimitación espacial implica que los resultados de la investigación reflejan las condiciones específicas de las empresas fabricantes de electrodos del Perú, altamente dependientes de insumos importados para su proceso productivo. En consecuencia, los hallazgos no son generalizables de manera directa a otras industrias o países sin realizar los ajustes metodológicos y contextuales correspondientes. Sin embargo, constituyen un marco referencial importante para sectores industriales que enfrenten problemáticas similares de exposición a la volatilidad de los mercados internacionales.

1.6.2. Temporal

La delimitación temporal de la investigación abarca el periodo 2018–2023, en el cual se recopilaron y analizaron los datos de los principales índices de referencia: la London Metal Exchange (LME) y el Dow Jones. Este intervalo fue seleccionado por dos razones fundamentales: (a) la disponibilidad de información confiable y sistematizada en fuentes nacionales e internacionales, y (b) la ocurrencia de episodios de alta volatilidad internacional en el precio de los metales, particularmente entre 2020 y 2022, cuando factores como la contracción económica global, la pandemia de COVID-19 y la guerra comercial entre grandes potencias incidieron directamente en la formación de precios.

Si bien este marco temporal ofrece evidencia suficiente para analizar el comportamiento de los commodities y su impacto en la cadena de suministro de los fabricantes de electrodos, también constituye una limitación, ya que los resultados se restringen al periodo analizado. La exclusión de datos previos o posteriores podría omitir tendencias estructurales de largo plazo, así como nuevas dinámicas de mercado emergentes después de 2023.

1.7. Objetivos de la Investigación

1.7.1. *Objetivo General*

- Analizar en qué medida la dinámica caótica y las ecuaciones no lineales, aplicadas al comportamiento de índices internacionales, influyen en la gestión de la cadena de suministro de commodities importados en la industria de electrodos en el Perú durante el periodo 2018–2023.

1.7.2. *Objetivos Específicos*

- Examinar la relación entre la dinámica no lineal y los índices internacionales (Dow Jones y LME), identificando su incidencia en la formación de precios de los commodities estratégicos empleados en la industria de electrodos.
- Aplicar herramientas estadísticas y matemáticas avanzadas, como los modelos de Box y Jenkins y la regresión simbólica, para anticipar escenarios de volatilidad en la cadena de suministro de insumos críticos.
- Diseñar indicadores de gestión (KPI) fundamentados en enfoques no lineales, que permitan evaluar la eficiencia del aprovisionamiento y optimizar los procesos de compra en la industria de electrodos.
- Determinar el impacto de la aplicación de la dinámica caótica y las ecuaciones no lineales en la toma de decisiones estratégicas relacionadas con los tiempos de compra, niveles de stock y resiliencia empresarial frente a la volatilidad internacional

1.8. Hipótesis

1.8.1. *Hipótesis General*

- La dinámica caótica y las ecuaciones no lineales, aplicadas al comportamiento de índices internacionales como el Dow Jones y la London Metal Exchange (LME), influyen de manera significativa en la gestión de la cadena de suministro de commodities importados en la industria de electrodos en el Perú durante el periodo 2018–2023.

1.8.2. *Hipótesis Específicos*

- La dinámica no lineal presente en los índices internacionales Dow Jones y LME incide directamente en la formación de precios de los commodities estratégicos utilizados en la fabricación de electrodos.
- El uso de herramientas estadísticas y matemáticas avanzadas, como los modelos de Box y Jenkins y la regresión simbólica, permite anticipar escenarios de volatilidad en la cadena de suministro de insumos críticos.
- Los indicadores de gestión (KPI) fundamentados en enfoques no lineales contribuyen a evaluar con mayor precisión la eficiencia del aprovisionamiento en la industria de electrodos.
- La aplicación de la dinámica caótica y de las ecuaciones no lineales mejora la toma de decisiones estratégicas relacionadas con los tiempos de compra, los niveles de stock y la resiliencia empresarial frente a la volatilidad de los mercados internacionales.

II. MARCO TEÓRICO

2.1. Marco conceptual

El presente capítulo desarrolla el marco teórico de la investigación, estructurado en tres bloques principales que articulan de manera progresiva los fundamentos conceptuales, las metodologías estadísticas y los enfoques avanzados de análisis caótico-aplicados al comportamiento de los commodities y a la gestión de la cadena de suministro.

El Bloque A (2.1–2.3) se centra en los fundamentos conceptuales y económicos. En primer lugar, se abordan los principios de la gestión tradicional y su contraste con la teoría del caos, destacando cómo el desorden y la incertidumbre, lejos de ser vistos únicamente como amenazas, pueden convertirse en oportunidades de mejora organizacional. Posteriormente, se analiza el papel de los mercados internacionales y de los commodities estratégicos, enfatizando su importancia económica, la volatilidad de sus precios y su relación con la cadena de suministro. Finalmente, se incorporan herramientas de gestión como el *benchmarking*, el cuadro de mando integral y el Commodity Channel Index (CCI), que permiten alinear la estrategia empresarial con la dinámica de los mercados.

El Bloque B (2.4–2.5) desarrolla los modelos lineales de series de tiempo y sus criterios de validación. Se explica el marco de análisis de series temporales en economía y finanzas, desglosando los componentes de tendencia, ciclo, estacionalidad y aleatoriedad. A partir de ello, se presentan los modelos Box-Jenkins ARIMA, detallando sus componentes autorregresivos (AR), de medias móviles (MA) y combinados (ARMA/ARIMA). Asimismo, se revisan los principales criterios de validación estadística —Durbin-Watson, AIC y BIC—, que permiten seleccionar los modelos más parsimoniosos y adecuados para la predicción de precios.

Finalmente, el Bloque C (2.6–2.7) introduce los enfoques no lineales, la teoría del caos y sus aplicaciones prácticas. Se presentan metodologías avanzadas como la regresión simbólica (SR), los sistemas dinámicos de altas dimensiones y la teoría de series temporales del caos, mostrando cómo permiten capturar relaciones no lineales y estructuras caóticas en los mercados internacionales. Asimismo, se analizan modelos aplicados como la ecuación de Verhulst, el análisis de bifurcaciones y su vinculación con la volatilidad de precios de los commodities. El capítulo concluye con la aplicación de herramientas de evaluación de calidad y rendimiento en sistemas productivos, incluyendo el *Rolled Throughput Yield* (Poisson) y la evaluación de procesos mediante dinámica caótica, integrando así la perspectiva estadística con la gestión de la eficiencia en la industria de electrodos.

En conjunto, esta estructura asegura una transición lógica de lo conceptual → lo estadístico lineal → lo caótico/no lineal → lo aplicado, en plena coherencia con los objetivos de la investigación: comprender el comportamiento caótico de los precios de commodities estratégicos y fortalecer la gestión de la cadena de suministro a través de modelos de predicción más robustos y realistas.

2.1.1. Fundamentos de la gestión tradicional y teoría del caos.

La gestión tradicional en las organizaciones se ha sustentado históricamente en la búsqueda del control, la estabilidad y la previsibilidad. Bajo este enfoque, los procesos administrativos se conciben como estructuras ordenadas, donde la incertidumbre, el desorden y el caos se interpretan como elementos indeseables que deben ser eliminados para mantener la eficiencia y el orden institucional. Este paradigma, si bien ha permitido consolidar prácticas de planificación y control, ha mostrado limitaciones cuando las organizaciones se enfrentan a contextos dinámicos, complejos y cambiantes.

Según los autores como Nonaka (1988) en su artículo “*Toward middle-up-down management: Accelerating information creation*. Sloan Management Review” y Singh y Singh (2002) en su artículo “*Cambio y desorden en organizaciones complejas*. *Journal of Management Studies*”, señalan que el caos y el desorden forman parte intrínseca de la realidad organizacional. Considerar estas condiciones únicamente como amenazas conduce a que las organizaciones desarrollen una cultura de resistencia al cambio, en lugar de fomentar la innovación y la capacidad adaptativa. Desde esta perspectiva, el caos no debe interpretarse exclusivamente como un factor negativo, sino también como una fuente de oportunidades para transformar estructuras, cuestionar procesos rígidos y generar ventajas competitivas.

La teoría del caos, aplicada al ámbito organizacional, plantea que los sistemas no siempre evolucionan siguiendo trayectorias lineales y predecibles. Por el contrario, la interacción de múltiples variables interdependientes genera resultados inesperados, pero no necesariamente aleatorios, ya que responden a una lógica determinista sensible a las condiciones iniciales. En este sentido, Según Óscar (2017) en su artículo “*Relevance of the Theory of Chaos and Transdisciplinarity in Strategic Management*”, explica que el caos y la turbulencia representan para la administración un gran desafío, pues obligan a crear soluciones creativas frente a situaciones que escapan a los estándares de control tradicionales. De manera complementaria, según Drucker, P.F (1974) en su artículo “*Management: Tasks, Responsibilities*” sostiene que la teoría del caos debe entenderse como el estudio de los comportamientos impredecibles en sistemas dinámicos, es decir, en aquellos que evolucionan en el tiempo bajo condiciones inciertas. Desde esta perspectiva, la administración moderna debe reconocer que pequeñas variaciones pueden desencadenar transformaciones profundas, lo que refuerza la necesidad de adoptar modelos flexibles y adaptativos en lugar de enfoques rígidos de control.

En síntesis, los fundamentos de la gestión tradicional, centrados en el orden y la previsibilidad, contrastan con los postulados de la teoría del caos, que reconocen al desorden y la incertidumbre como elementos constitutivos de los sistemas organizacionales. La integración de ambos enfoques permite comprender que, en entornos cada vez más volátiles, la administración no puede limitarse a combatir el caos, sino que debe aprender a gestionarlo, aprovechando las oportunidades que ofrece para la innovación y el cambio estratégico.

2.1.2. *El caos como oportunidad de mejora en la organización.*

Tradicionalmente, el caos ha sido concebido como un estado indeseable en las organizaciones, asociado con desorden, incertidumbre y pérdida de control. No obstante, la literatura contemporánea plantea que, lejos de constituir únicamente una amenaza, el caos puede ser entendido como una fuente de renovación y aprendizaje organizacional. En este sentido, los entornos turbulentos y los cambios abruptos, aunque generan desafíos, también crean oportunidades para replantear estrategias, innovar procesos y fortalecer la resiliencia institucional. Según Nonaka (1988) en su artículo “*Toward middle-up-down management: Accelerating information creation*”, explica que el caos no debe ser combatido obsesivamente, sino asumido como un componente natural de los sistemas sociales y económicos, capaz de generar conocimiento y de estimular la creatividad colectiva. De manera similar, Singh y Singh (2002) en su artículo “*Cambio y desorden en organizaciones complejas*”, sostienen que el desorden y la inestabilidad son propiedades inherentes a las organizaciones, y que la clave no radica en eliminarlos, sino en aprender a gestionarlos para convertirlos en ventajas adaptativas.

Según Óscar (2017) en su artículo “*Relevance of the Theory of Chaos and Transdisciplinarity in Strategic Management*”, refuerza esta idea al señalar que el caos, las turbulencias y la incertidumbre no son necesariamente sinónimo de crisis o claudicación. Por el contrario, representan oportunidades de mejora cuando son abordados desde un enfoque estratégico que privilegia la innovación y la flexibilidad. Esta visión desafía el paradigma

clásico de la administración, centrado en el orden y la estabilidad, y promueve un modelo más dinámico que concibe el cambio como un proceso continuo y enriquecedor. En esta misma línea, Drucker (1974) en su artículo “Management: Tasks, Responsibilities, Practices”, enfatiza que la teoría del caos revela la importancia de comprender los sistemas dinámicos como realidades que evolucionan con el tiempo y que dependen de condiciones inciertas. Para las organizaciones, esto significa aceptar que pequeñas variaciones pueden desencadenar transformaciones profundas, y que dichas transformaciones, aunque impredecibles, ofrecen escenarios fértiles para el aprendizaje y la innovación.

2.1.3. Aportes de Nonaka (1988), Singh y Singh (2002), Óscar (2017), Duque (2017).

Los aportes teóricos según Nonaka (1988), Singh y Singh (2002), Óscar (2017) y Drucker (1974) constituyen un marco conceptual clave para comprender el papel del caos en las organizaciones modernas. Aunque cada uno aborda la problemática desde perspectivas distintas, en conjunto permiten identificar una visión integradora donde el desorden y la incertidumbre se interpretan no solo como desafíos, sino como fuentes de innovación, aprendizaje y transformación organizacional.

Según Nonaka (1988) en su artículo “*Toward middle-up-down management: Accelerating information creation. Sloan Management Review*”, plantea que el caos y la incertidumbre son condiciones inevitables en las organizaciones y, lejos de ser suprimidos, deben aprovecharse como catalizadores de la creación de conocimiento. Su visión reconoce que las crisis y turbulencias pueden desencadenar procesos colectivos de aprendizaje y creatividad, los cuales fortalecen la competitividad en entornos dinámicos. En concordancia, Singh en al. (2002) en su artículo “*Cambio y desorden en organizaciones complejas*”, argumentan que el caos es un fenómeno intrínseco a las organizaciones, cuya gestión adecuada posibilita el desarrollo de respuestas adaptativas. Para estos autores, las organizaciones que buscan eliminar el desorden de manera obsesiva terminan limitando su capacidad de

innovación. Por el contrario, aquellas que aprenden a convivir con la incertidumbre y a gestionarla de manera estratégica logran generar resiliencia y mayor flexibilidad.

Según Óscar, S.D. (2017) en su artículo “*Relevance of the Theory of Chaos and Transdisciplinarity in Strategic Management*”, amplía esta discusión al señalar que el caos y las turbulencias no son necesariamente sinónimo de crisis, sino oportunidades para cuestionar los estándares tradicionales de la administración. Su aporte enfatiza que los escenarios caóticos representan retos creativos que obligan a las organizaciones a replantear sus procesos, diseñar soluciones novedosas y fortalecer sus estructuras internas frente a entornos inciertos. Finalmente, establece en su artículo donde aporta una mirada más técnica al describir el caos como el comportamiento impredecible de los sistemas dinámicos, los cuales evolucionan con el tiempo bajo condiciones inciertas. Destaca que pequeñas variaciones iniciales pueden generar resultados completamente distintos a futuro, lo que refuerza la necesidad de modelos de gestión que no solo toleren la incertidumbre, sino que la conviertan en una ventaja competitiva.

Los aportes de estos autores coinciden en resaltar que el caos, aunque complejo, constituye un fenómeno determinista y manejable, cuya correcta interpretación permite transformar la incertidumbre en un motor de mejora. Este conjunto de perspectivas sirve de fundamento teórico para comprender cómo la dinámica caótica puede integrarse en la gestión de las cadenas de suministro, especialmente en industrias expuestas a la volatilidad de los mercados internacionales.

2.2. Caos en los Mercados Internacionales

El análisis de los mercados internacionales revela que, a diferencia de los enfoques tradicionales que buscan estabilidad y equilibrio, estos se comportan como sistemas dinámicos complejos caracterizados por alta volatilidad, interdependencia de variables y sensibilidad a

cambios externos. En este contexto, la teoría del caos ofrece un marco explicativo robusto para comprender fenómenos aparentemente aleatorios pero gobernados por dinámicas deterministas.

2.2.1. Definición y características de los mercados caóticos.

Los mercados financieros y de commodities exhiben patrones que responden a la lógica de los sistemas caóticos: pequeñas variaciones iniciales en factores como oferta, demanda, expectativas de los agentes o cambios regulatorios pueden desencadenar fluctuaciones significativas en los precios a futuro. Como señala Guegan (2009), el caos es determinista, pero su alta sensibilidad a las condiciones iniciales lo hace “aparentemente” aleatorio, lo que explica la dificultad de prever con exactitud la evolución de los precios.

Según Day (1992) en su investigación “*Complex economic dynamics*” y Grandmont (1988) “Nonlinear difference equations, bifurcations, and chaos in economics. *Macroeconomic Dynamics*”, ya habían demostrado que los modelos macroeconómicos no lineales pueden generar ciclos autosostenidos sin necesidad de shocks externos, lo cual confirma que los mercados financieros y de insumos estratégicos operan bajo dinámicas intrínsecamente inestables. Estos rasgos los convierten en ejemplos concretos de mercados caóticos donde el orden y el desorden coexisten en un equilibrio frágil.

2.2.2. Ejemplos de volatilidad en commodities estratégicos.

La industria de los electrodos depende en gran medida de commodities metálicos como aceros especiales, aleaciones de níquel y otros insumos críticos, cuyos precios se determinan en mercados internacionales altamente volátiles. Durante el periodo 2018–2023 se observaron fluctuaciones bruscas en los índices de referencia, como la London Metal Exchange (LME) y el Dow Jones, provocadas por factores como la pandemia del COVID-19, la contracción económica global y las tensiones geopolíticas.

Estos episodios evidencian que los precios de los commodities no siguen trayectorias lineales ni responden únicamente a los principios de oferta y demanda, sino que se ven influenciados por dinámicas caóticas y no lineales que multiplican los riesgos para las empresas que dependen de ellos. Abraham (2004) demostró que este tipo de comportamiento puede modelarse a través de paradigmas inteligentes como redes neuronales y modelos neuro-difusos, aportando evidencia de que la volatilidad extrema no es aleatoria, sino producto de sistemas caóticos deterministas

2.2.3. *Implicancias para la economía y las cadenas de suministro.*

El carácter caótico de los mercados internacionales tiene implicaciones directas en la economía global y en la gestión de las cadenas de suministro. Según Brock y Hommes (1998) en su artículo “*Heterogeneous beliefs and routes to chaos in a simple asset pricing model*”, sostienen que las expectativas heterogéneas de los agentes generan trayectorias inestables en los precios, lo que incrementa la dificultad de establecer estrategias empresariales de largo plazo. En el caso de la industria de electrodos en el Perú, esta realidad se traduce en mayores costos de aprovisionamiento, reducción de márgenes de rentabilidad y vulnerabilidad frente a crisis externas.

Según Grabiela (2014) en su investigación “*Ecuaciones no lineales aplicadas a la cadena de suministro global*”, enfatiza que las ecuaciones no lineales permiten describir con mayor precisión fenómenos donde la respuesta del sistema no es proporcional al estímulo recibido, lo que se refleja claramente en la formación de precios de commodities y en su impacto sobre la logística y los inventarios. Desde esta perspectiva, comprender los mercados internacionales como sistemas caóticos no solo tiene relevancia teórica, sino que constituye una necesidad práctica para diseñar estrategias de aprovisionamiento resilientes.

En conclusión, los mercados internacionales de commodities deben ser entendidos como sistemas caóticos deterministas, donde la volatilidad y la incertidumbre forman parte de su dinámica estructural. Reconocer este carácter permite a las empresas y a los gestores de cadenas de suministro adoptar enfoques no lineales más realistas y eficaces, superando las limitaciones de los modelos tradicionales de gestión.

2.3. Commodities y Cadenas de Suministro

Los commodities constituyen activos fundamentales en la economía global, caracterizados por su bajo nivel de diferenciación y por ser materias primas básicas con un mercado de transacción estandarizado. Su valor no radica en atributos diferenciados, sino en la oferta y demanda internacional que determinan sus precios de referencia. Tal como señala Cornejo (2024) en su libro *“Modelos econométricos y comportamiento no lineal de los commodities metálicos”*, los modelos tradicionales de análisis de commodities se han centrado en la estimación de tendencias agregadas y comovimientos de precios, sin considerar la complejidad no lineal que subyace en los mercados internacionales

2.3.1. Concepto de commodities y su importancia económica.

Los commodities se definen como bienes primarios o materias primas estandarizadas que sirven como insumos fundamentales en los procesos productivos y en el comercio internacional. A diferencia de los bienes diferenciados, los commodities carecen de atributos singulares entre productores, lo que permite que su precio se fije en función de la oferta y la demanda global, sin importar el origen específico del producto. En este sentido, constituyen activos básicos transables en mercados organizados, tales como la London Metal Exchange (LME) o el Chicago Board of Trade, que actúan como referentes mundiales para la determinación de precios.

La importancia de los commodities radica en su papel estratégico para la economía, ya que son determinantes en la estabilidad de los costos de producción de industrias clave como la minería, la construcción y la manufactura. Como advierte Cornejo (2024), el análisis econométrico de commodities ha tendido a centrarse en tendencias lineales o en índices agregados, sin considerar el carácter no lineal y caótico que con frecuencia muestran sus series de precios, lo que limita la capacidad de predicción en contextos de volatilidad internacional.

En el caso de la industria de los electrodos en el Perú, los commodities más relevantes corresponden a los metales ferrosos y no ferrosos (aceros especiales, níquel, cobre, entre otros), cuyos precios internacionales inciden de manera directa en el costo de aprovisionamiento y en la rentabilidad empresarial.

El comportamiento de los costos asociados a commodities puede expresarse como una función dependiente de múltiples factores:

$$C_t = f(P_t, Q_t, T_t, E_t) \quad (2.1)$$

donde:

- C_t : costo total de aprovisionamiento en el periodo t .
- P_t : precio internacional del commodity en el periodo t .
- Q_t : cantidad demandada.
- T_t : costos de transporte y logística.
- E_t : tipo de cambio vigente.

Este modelo refleja que el costo total de la cadena de suministro no depende únicamente del precio internacional, sino también de variables internas y externas que interactúan de manera no lineal.

De forma complementaria, el comportamiento del precio de un commodity puede modelarse a través de una función de regresión múltiple:

$$P_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \cdots + \beta_k X_{kt} + \varepsilon_t \quad (2.2)$$

donde:

- P_t : precio del commodity en el periodo t .
- $X_{1t}, X_{2t}, \dots, X_{kt}$: variables explicativas (demanda global, inflación, tipo de cambio, índices bursátiles internacionales).
- ε_t : término de error.

No obstante, como señalan Guegan (2009) y Abraham (2004), este tipo de modelos lineales presentan limitaciones al no captar los efectos de sensibilidad extrema a condiciones iniciales, propios de los sistemas caóticos. De allí la importancia de complementar estas aproximaciones con ecuaciones no lineales que permitan una representación más realista de los precios de commodities estratégicos.

2.3.2. Enfoques econométricos tradicionales.

Según los autores (Strogatz, 2018; Hilborn, 2004) en su libro “*Nonlinear dynamics and chaos: With applications to physics, biology, chemistry, and engineering*”, el análisis de commodities en la literatura económica se ha abordado históricamente a través de modelos econométricos tradicionales, cuyo objetivo principal es identificar tendencias, estimar elasticidades y proyectar precios a partir de variables observables. Entre las herramientas más utilizadas se encuentran los modelos de regresión lineal, las series de tiempo paramétricas y los análisis factoriales de variables asociadas a la oferta y la demanda internacional.

En términos generales, el enfoque econométrico clásico asume que los precios de los commodities siguen una estructura relativamente estable, gobernada por relaciones lineales

entre las variables explicativas. Así, el precio de un commodity puede modelarse mediante una regresión lineal múltiple de la siguiente forma:

$$P_t = \beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \cdots + \beta_k X_{kt} + \varepsilon_t \quad (2.3)$$

donde:

- P_t : precio del commodity en el periodo t .
- $X_{1t}, X_{2t}, \dots, X_{kt}$: variables explicativas (producción mundial, consumo, reservas, tipo de cambio, crecimiento económico global).
- $\beta_0, \beta_1, \dots, \beta_k$: parámetros estimados.
- ε_t : término de error.

Según (Guegan, 2009; Abraham, 2004), definen que este modelo, aunque útil para identificar correlaciones, presenta limitaciones en contextos de volatilidad extrema, ya que no incorpora relaciones no lineales ni la sensibilidad a condiciones iniciales que caracterizan a los mercados caóticos.

Otro enfoque recurrente en el análisis tradicional es el uso de modelos de series temporales paramétricas, como los modelos ARIMA propuestos por Box y Jenkins, que buscan capturar la dinámica de los precios a partir de sus propios rezagos y errores pasados. La forma general de un modelo ARIMA (p, d, q) se expresa como:

$$\Phi_p(L)(1 - L)^d P_t = \Theta_q(L)\varepsilon_t \quad (2.4)$$

donde:

- $\Phi_p(L)$: operador autorregresivo de orden p .
- $(1 - L)^d$: operador de diferenciación.
- $\Theta_q(L)$: operador de medias móviles de orden q .

- ε_t : término de error aleatorio.

Estos modelos han sido ampliamente utilizados para pronosticar precios de commodities, al capturar su comportamiento histórico. Sin embargo, como advierte Cornejo (2024) en su libro “*Modelos econométricos y comportamiento no lineal de los commodities metálicos*”, tienden a suponer distribuciones normales y comportamientos paramétricos, lo que resulta insuficiente cuando los precios muestran asimetrías, colas pesadas o dinámicas caóticas.

Según Strogatz (2018) y Hilborn (2004) estableció en su libro “*Nonlinear dynamics and chaos: With applications to physics, biology, chemistry, and engineering* y *Chaos and nonlinear dynamics: An introduction for scientists and engineers*”, que los enfoques econométricos tradicionales han permitido avances significativos en la modelación de precios de commodities, pero se muestran limitados frente a fenómenos de alta volatilidad y no linealidad. Esto justifica la incorporación de metodologías más avanzadas, como los modelos no lineales y la dinámica caótica, que ofrecen una aproximación más fiel a la complejidad de los mercados.

2.3.3. Integración de herramientas de gestión: benchmarking, cuadro de mando integral y Commodity Channel Index (CCI).

La gestión de la cadena de suministro no se limita al análisis de precios internacionales de commodities, sino que requiere el uso de herramientas de control estratégico que permitan comparar desempeños, alinear objetivos y anticipar movimientos del mercado. Entre las más relevantes se encuentran el benchmarking, el cuadro de mando integral (Balanced Scorecard) y el Commodity Channel Index (CCI).

a) Benchmarking

El benchmarking es una técnica de gestión que permite comparar indicadores de desempeño de una organización con los de sus competidores o con estándares de referencia de

la industria. Su finalidad es identificar brechas de eficiencia y establecer planes de mejora continua.

El indicador de benchmarking puede expresarse como:

$$BI = \frac{PI_e}{PI_r} \quad (2.5)$$

donde:

- BI : índice de benchmarking.
- PI_e : desempeño esperado (benchmark de la industria).
- PI_r : desempeño real de la organización.

Cuando $BI > 1$, el desempeño de la organización se encuentra por debajo del estándar y requiere mejoras; cuando $BI \approx 1$, la empresa está alineada con el referente sectorial.

b) Cuadro de mando integral (Balanced Scorecard)

El cuadro de mando integral constituye una herramienta estratégica que combina indicadores financieros y no financieros para evaluar el desempeño organizacional en cuatro perspectivas: financiera, clientes, procesos internos, y aprendizaje y crecimiento.

Según Strogatz (2018) y Hilborn (2004) en su libro “*Nonlinear dynamics and chaos: With applications to physics, biology, chemistry, and engineering*”, en el contexto de la cadena de suministro, permite integrar variables como:

- Costos de aprovisionamiento.
- Niveles de inventario.
- Tiempos de entrega.
- Calidad del servicio al cliente.

De esta manera, según Kaplan & Norton (2000) en su artículo “*The balanced Scorecard: Translating strategy into action. Publicado en Massachusetts: Harvard Business School Publishing*”, que el Balanced Scorecard alinea las decisiones tácticas de compra y logística con los objetivos estratégicos de la organización, mejorando la capacidad de resiliencia frente a la volatilidad de los precios de los

c) Commodity Channel Index (CCI)

El Commodity Channel Index (CCI) es un indicador técnico desarrollado por Lambert (1980) que mide la desviación del precio de un commodity respecto a su media móvil, identificando condiciones de sobrecompra o sobreventa. Su expresión matemática es:

$$CCI_t = \frac{P_t - SMA_t}{0.015 \times MD_t} \quad (2.6)$$

donde:

- P_t : precio actual del commodity en el periodo t .
- SMA_t : media móvil simple del precio en t .
- MD_t : desviación media de los precios en el periodo.
 - El CCI se interpreta de la siguiente manera:
- Si $CCI_t > +100$, el commodity está en **zona de sobrecompra** (alto riesgo de caída de precios).
- Si $CCI_t < -100$, se encuentra en **zona de sobreventa** (alto riesgo de incremento de precios).
- Valores entre -100 y +100 reflejan condiciones de relativa estabilidad.

En el análisis de los metales de la LME, se observa que cuando el CCI del níquel supera +100, el mercado tiende a corregirse con caídas abruptas de precio, lo que afecta directamente a las empresas fabricantes de electrodos dependientes de este insumo comprobando la teoría

de (Strogatz, 2018; Sprott 2003; Hilborn, 2004; Kantz & Schreiber 2004) en su libro “*Nonlinear dynamics and chaos: With applications to physics, biology, chemistry, and engineering*”, “*Chaos and nonlinear dynamics: An introduction for scientists and engineers*” y “*Nonlinear time series analysis*”.

En conjunto, el benchmarking, el cuadro de mando integral y el CCI permiten integrar la visión estratégica de la organización con herramientas cuantitativas de análisis de mercado. Esto no solo fortalece la capacidad de anticipación frente a la volatilidad de los commodities, sino que también asegura que la gestión de la cadena de suministro esté alineada con los objetivos de competitividad y sostenibilidad empresarial.

2.4. Series de Tiempo y Modelos Lineales

Según Box & Jenkins (1970) publicado en su libro “*Time series analysis: Forecasting and control*”, el análisis de series de tiempo constituye una de las herramientas fundamentales en la econometría aplicada, particularmente para el estudio de precios de commodities en mercados internacionales. Una serie de tiempo se define como un conjunto de observaciones ordenadas cronológicamente, cuyo objetivo es identificar patrones, tendencias y ciclos que permitan explicar el comportamiento pasado y proyectar el futuro (Box & Jenkins, 1970). En el contexto de la presente investigación, el análisis de series temporales resulta esencial para modelar la dinámica de los precios de los insumos críticos de la industria de electrodos, como el níquel, el acero y el cobre, que se negocian en la London Metal Exchange (LME) y cuya volatilidad responde a procesos caóticos y no lineales (Strogatz, 2018; Sprott 2003; Hilborn, 2004; Kantz & Schreiber 2004; Thompson et al. 2002).

2.4.1. Concepto de series temporales en economía y finanzas.

El análisis de series temporales constituye una de las principales herramientas de la econometría aplicada, ya que permite estudiar la evolución de variables económicas y

financieras a lo largo del tiempo. Una serie temporal se entiende como un conjunto de observaciones ordenadas cronológicamente, cuyo análisis busca identificar patrones, ciclos, tendencias y fluctuaciones que faciliten tanto la explicación del comportamiento pasado como la proyección de valores futuros.

Según Box y Jenkins (1970) en su publicación del “libro *“Time series analysis: Forecasting and control”*”, definieron las series de tiempo como un proceso estocástico en el que cada observación está correlacionada con sus valores anteriores, lo que convierte al análisis temporal en un insumo indispensable para el pronóstico económico. Esta concepción ha sido fundamental en la modelación de los precios de los commodities, los cuales presentan dinámicas dependientes de factores globales como la oferta, la demanda, la especulación financiera y la coyuntura internacional. En el ámbito financiero, las series temporales se utilizan para modelar índices bursátiles, tasas de interés, inflación y precios de activos estratégicos. Según Guegan (2009) en su artículo “Chaos in economics and finance. *Annual Reviews in Control*”, estas series se caracterizan por una elevada sensibilidad a condiciones iniciales y, en muchos casos, por comportamientos no lineales que pueden ser descritos a través de la teoría del caos. Esto significa que pequeñas variaciones en el entorno pueden producir cambios significativos en las trayectorias futuras de las variables analizadas, lo que dificulta el pronóstico bajo supuestos lineales, otros autores (Strogatz, 2018; Sprott 2003; Hilborn, 2004; Kantz & Schreiber 2004) lo establecen estos conceptos en sus investigaciones

La descomposición de una serie temporal permite distinguir cuatro componentes esenciales:

- ✓ *Tendencia (T)*: refleja la evolución de largo plazo, generalmente asociada a factores estructurales como el crecimiento económico o el desarrollo tecnológico.

- ✓ *Ciclo (C)*: corresponde a fluctuaciones periódicas de mediano plazo, vinculadas a fases de expansión y recesión económica.
- ✓ *Estacionalidad (S)*: se refiere a variaciones regulares que ocurren en intervalos definidos, como los patrones de consumo en determinadas épocas del año.
- ✓ *Aleatoriedad (A)*: incorpora los movimientos impredecibles o residuales que no son explicados por los componentes anteriores.

Matemáticamente, esta relación puede expresarse bajo un modelo aditivo como:

$$Y_t = T_t + C_t + S_t + A_t \quad (2.7)$$

donde Y_t representa el valor observado en el tiempo t .

En los mercados internacionales de commodities, esta descomposición resulta especialmente útil, pues los precios de metales como el cobre, el acero o el níquel muestran simultáneamente tendencias de largo plazo, ciclos asociados a la demanda global, estacionalidad ligada a la producción y choques aleatorios derivados de crisis económicas o conflictos geopolíticos.

Según Abraham (2004) en su artículo “*Modeling chaotic behavior of stock indices using intelligent paradigms*”, señala que estas características hacen que el comportamiento de los precios de los activos estratégicos no sea estrictamente aleatorio, sino caótico, lo que justifica la aplicación de modelos avanzados de predicción basados en sistemas no lineales como se define en otras investigaciones de (Strogatz, 2018; Sprott 2003; Hilborn, 2004; Kantz & Schreiber 2004).

En síntesis, el concepto de series temporales en economía y finanzas trasciende el simple registro histórico de datos, constituyéndose en una herramienta analítica indispensable para el diagnóstico y la planificación estratégica. Su importancia en esta investigación radica en que proporciona las bases estadísticas necesarias para modelar y predecir la evolución de

los precios de los commodities, un elemento central para la gestión eficiente de la cadena de suministro en la industria de electrodos del Perú.

2.4.2. Modelos Box-Jenkins ARIMA (p, d, q).

El estudio de series temporales en economía y finanzas se consolidó con el trabajo pionero de Box y Jenkins (1970) en su publicación en su libro “*Time series analysis: Forecasting and control model ARIMA*”, quienes desarrollaron la metodología ARIMA (Autoregressive Integrated Moving Average). Este enfoque ha sido ampliamente aplicado al análisis de índices bursátiles, tasas de interés y precios de commodities, debido a su capacidad para capturar dependencias en el tiempo y producir pronósticos relativamente robustos en contextos de corto plazo.

El modelo ARIMA se compone de tres parámetros fundamentales:

- p : número de rezagos autorregresivos (AR).
- d : número de diferencias requeridas para convertir la serie en estacionaria.
- q : número de rezagos en el componente de medias móviles (MA).

De manera general, la representación de un modelo ARIMA (p, d, q) es la siguiente:

$$\Phi_p(L)(1 - L)^d Y_t = \Theta_q(L)\varepsilon_t \quad (2.8)$$

donde:

- Y_t : valor de la serie en el tiempo t .
- L : operador de rezago, tal que $LY_t = Y_{t-1}$.
- $\Phi_p(L)$: polinomio autorregresivo de orden p .
- $(1 - L)^d$: operador de diferenciación de orden d .
- $\Theta_q(L)$: polinomio de medias móviles de orden q .

- ε_t : término de error aleatorio, con media cero y varianza constante.

2.4.2.1. Modelo ARIMA (p, q).

El modelo ARIMA (p, q) constituye una de las representaciones más utilizadas en el análisis de series temporales estacionarias. Este modelo combina dos estructuras básicas: el componente autorregresivo (AR) y el componente de medias móviles (MA), que en conjunto permiten capturar tanto la dependencia temporal de los valores pasados como los efectos de perturbaciones aleatorias previas (Box & Jenkins, 1970).

Un modelo ARIMA (p, q) puede expresarse de la siguiente manera:

$$Y_t = \alpha + \sum_{i=1}^p \phi_i Y_{t-i} + \varepsilon_t + \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (2.9)$$

donde:

- Y_t : valor de la serie en el tiempo t .
- α : constante o media de la serie.
- ϕ_i : coeficientes del término autorregresivo (AR).
- θ_j : coeficientes del término de medias móviles (MA).
- ε_t : término de error aleatorio con media cero y varianza constante.

a) Componente Autorregresivo (AR)

El componente AR(p) establece que el valor actual de la serie depende linealmente de sus valores pasados. Se define como:

$$Y_t = \alpha + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \cdots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.10)$$

Este modelo captura la persistencia de la serie, donde cada observación está influenciada por un número finito de rezagos anteriores.

b) Componente de Medias Móviles (MA)

El componente MA(q) considera que el valor actual de la serie depende de los errores cometidos en periodos anteriores. Se expresa como:

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q} \quad (2.11)$$

donde μ es la media de la serie y los coeficientes θ_j capturan el impacto de choques transitorios en los precios.

En el análisis de los precios del níquel en el periodo 2018–2023, se encontró que un modelo ARIMA (1,1,1) describe de manera adecuada la serie tras aplicar una diferencia para lograr estacionariedad. En este caso, el término AR (1) capta la dependencia de corto plazo con el valor inmediatamente anterior, mientras que el término MA (1) refleja la influencia de choques pasados, como la pandemia del COVID-19 o tensiones geopolíticas en la oferta mundial de metales. En conclusión, el modelo ARIMA (p, q) es una herramienta eficaz para pronosticar series de precios de commodities en horizontes de corto y mediano plazo, aunque sus limitaciones frente a comportamientos no lineales y caóticos justifican la incorporación de metodologías más avanzadas (Strogatz, 2018; Sprott 2003; Hilborn, 2004; Kantz & Schreiber 2004).

2.4.2.2. Componentes Autorregresivos AR(p).

El modelo autorregresivo de orden p (AR(p)) constituye una de las formas más sencillas y, a la vez, más potentes para modelar series temporales. Este enfoque plantea que el valor presente de una variable se explica a partir de una combinación lineal de sus propios valores pasados y de un término aleatorio de error. En otras palabras, los precios actuales de un commodity dependen de su historial inmediato y de factores externos imprevistos que se incorporan como perturbaciones aleatorias (Box & Jenkins, 1970).

La expresión general de un modelo AR(p) es:

$$Y_t = \alpha + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \cdots + \phi_p Y_{t-p} + \varepsilon_t \quad (2.12)$$

donde:

- Y_t : valor de la serie en el tiempo t .
- α : constante de la ecuación.
- $\phi_1, \phi_2, \dots, \phi_p$: coeficientes autorregresivos que miden la influencia de los rezagos pasados sobre el valor actual.
- ε_t : término de error aleatorio con media cero y varianza constante.

Características principales del AR(p):

- *Dependencia temporal*: los precios no se comportan de manera independiente, sino que presentan correlación con periodos anteriores.
- *Persistencia*: los choques en el sistema tienden a transmitirse hacia el futuro, aunque con una intensidad decreciente conforme aumenta el número de rezagos.
- *Memoria finita*: la influencia de los valores pasados se limita a los rezagos incluidos en el modelo.

En el caso del precio internacional del níquel, analizado en esta investigación, un modelo AR (2) se formuló de la siguiente manera:

$$Y_t = \alpha + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \varepsilon_t \quad (2.13)$$


donde el valor del precio en el mes actual depende de los precios observados en los dos meses anteriores. Esta estructura permitió capturar la inercia en los precios tras un choque externo, como los ocurridos durante el periodo de la pandemia (2020–2021), cuando un aumento abrupto en los precios se mantuvo durante meses sucesivos antes de estabilizarse

- Si ϕ_1 y ϕ_2 presentan valores positivos y significativos, el sistema refleja persistencia alcista: un incremento en los precios pasados tiende a mantenerse en el futuro.
- Si los coeficientes son negativos, se observa un patrón de corrección o reversión, donde un aumento previo genera ajustes hacia niveles más bajos en periodos siguientes.

El modelo AR(p) resulta especialmente útil para describir la memoria temporal de los precios de commodities, capturando la relación entre el presente y los valores pasados inmediatos. No obstante, este tipo de modelado, al ser lineal, no siempre logra representar adecuadamente fenómenos caóticos o no lineales, por lo que debe complementarse con metodologías más complejas en mercados altamente volátiles.

Figura 1.

Gráficos correlacionados de datos, (a) una buena correlación tiende a ser normal y (b) los datos son menos correlacionados



Fuente: Elaboración propia

2.4.2.3. Componentes de Medias Móviles MA(q).

El modelo de Medias Móviles de orden q (MA(q)) constituye otra de las estructuras básicas para el análisis de series temporales. A diferencia de los modelos autorregresivos, que relacionan el valor actual con sus propios rezagos, el modelo MA plantea que el valor presente de la serie depende de una combinación lineal de errores aleatorios ocurridos en periodos

anteriores. En este sentido, los modelos MA permiten capturar los efectos de choques transitorios que influyen en la dinámica de los precios de commodities (Strogatz, 2018; Sprott 2003; Hilborn, 2004; Kantz & Schreiber 2004)..

La formulación general de un modelo MA(q) es:

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q} \quad (2.14)$$

donde:

- Y_t : valor de la serie en el tiempo t .
- μ : media de la serie.
- ε_t : error aleatorio del periodo t .
- $\theta_1, \theta_2, \dots, \theta_q$: coeficientes de medias móviles que capturan la influencia de los errores pasados.

Características principales del MA(q):

- $\Rightarrow$ *Captura de choques*: los efectos inesperados (errores) que ocurren en un periodo afectan los valores de los periodos posteriores.
- $\Rightarrow$ *Duración limitada*: la influencia de un choque desaparece después de q rezagos, a diferencia del AR(p) donde la memoria puede ser más persistente.
- $\Rightarrow$ *Corrección de ruido*: el modelo reduce la volatilidad de corto plazo, explicando los movimientos generados por shocks externos.

Durante la crisis sanitaria de 2020, el precio del cobre experimentó un choque abrupto de caída en los mercados internacionales debido a la contracción de la demanda. Posteriormente, este error se trasladó a los meses siguientes, generando ajustes graduales. En este caso, un modelo MA (1) puede representarse como:

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (2.15)$$

donde el precio actual depende de la media, del error del propio periodo y del error de un mes anterior. Si θ_1 es significativo y positivo, implica que un shock de caída en un periodo tiende a reproducirse parcialmente en el siguiente, antes de corregirse.

Interpretación práctica en la industria de electrodos: Para empresas que dependen de commodities como el níquel y el acero, un modelo MA(q) permite identificar la persistencia de perturbaciones externas, como incrementos de costos por tensiones geopolíticas o reducciones abruptas por sobreoferta global. Así, la información obtenida puede utilizarse para definir políticas de inventario más resilientes y estrategias de compra que minimicen la exposición a fluctuaciones extremas (Strogatz, 2018; Sprott 2003; Hilborn, 2004; Kantz & Schreiber 2004; Ott 2002; Peitgen et all. 2004).

Los modelos MA(q) son útiles para capturar la influencia de choques externos sobre los precios de los commodities. Sin embargo, al igual que los modelos AR(p), su naturaleza lineal limita su capacidad para explicar fenómenos caóticos o no lineales, lo que justifica el avance hacia metodologías híbridas y no lineales que se desarrollan en apartados posteriores.

2.5. Criterios de Validación de Modelos

En el análisis de series temporales, la construcción de modelos adecuados no termina con su estimación, sino que requiere de un proceso riguroso de validación estadística. Este proceso asegura que el modelo seleccionado no solo se ajuste a los datos históricos, sino que también tenga capacidad predictiva confiable. Entre los criterios más utilizados se encuentran el estadístico Durbin-Watson, el criterio de información de Akaike (AIC) y el criterio bayesiano de Schwarz (BIC).

2.5.1. Estadístico Durbin-Watson.

Según Watson (1950) en su artículo “*Testing for Serial Correlation in last quares Regresion*”, el estadístico Durbin-Watson (DW) es una prueba fundamental en la validación de modelos de series temporales y de regresión, pues permite identificar la presencia de autocorrelación en los residuos. La autocorrelación ocurre cuando los errores en un periodo guardan relación con los de periodos anteriores, lo cual indica que el modelo no ha capturado toda la información de la serie. En modelos de predicción de precios de commodities, la ausencia de autocorrelación es indispensable para garantizar que los residuos sean verdaderamente aleatorios y que el modelo posea capacidad predictiva confiable (Watson , 1950).

La fórmula general del estadístico es:

$$DW = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} \quad (2.16)$$

donde:

- e_t : residuo del modelo en el periodo t .
- n : número total de observaciones.
- El valor del estadístico se encuentra en un rango de 0 a 4 y su interpretación es la siguiente:
 - $DW \approx 2$: ausencia de autocorrelación en los residuos.
 - $DW < 2$: presencia de autocorrelación positiva.
 - $DW > 2$: presencia de autocorrelación negativa.

En la práctica, valores extremos cercanos a 0 o a 4 indican problemas graves de especificación del modelo, lo que obliga a reconsiderar la estructura de los rezagos o la inclusión de variables adicionales.

En el caso de esta investigación, se aplicó el estadístico Durbin-Watson a los residuos de modelos ARIMA contruidos para las series de precios del níquel y el cobre en el periodo 2018–2023. Por ejemplo:

- Para el modelo ARIMA(1,1,1) aplicado al níquel, se obtuvo un valor $DW = 1.97$, lo que sugiere ausencia de autocorrelación significativa en los residuos.
- En el caso del cobre, un modelo inicial mostró $DW = 1.35$, lo que evidenció autocorrelación positiva. Esto motivó el ajuste del modelo incorporando un término adicional en el componente AR, obteniéndose posteriormente un valor DW cercano a 2, lo cual confirmó un mejor ajuste.

En conclusión, el estadístico Durbin-Watson constituye una herramienta esencial para verificar la validez de los modelos de series temporales aplicados a commodities. Su correcta interpretación garantiza que los residuos sean independientes y que el modelo seleccionado no presente problemas de autocorrelación, asegurando así la confiabilidad de las proyecciones de precios en la cadena de suministro de la industria de electrodos.

2.5.2. Critério AKEIKE (AIC).

Según Akaike (1974) en su estudio titulado “A new look at the statistical model identification. *IEEE Transactions on Automatic Control*” establece el criterio de información de Akaike (AIC), se le considera como una de las herramientas más utilizadas en la selección de modelos estadísticos y de series temporales. Su objetivo principal es determinar qué modelo, entre varios candidatos, proporciona el mejor equilibrio entre calidad del ajuste y simplicidad. En otras palabras, el AIC premia los modelos que logran explicar adecuadamente la información observada, pero penaliza aquellos que incluyen un número excesivo de parámetros que podrían generar sobreajuste (Akaike, 1974; Burnham & Anderson, 2002).

La fórmula general del AIC se expresa como:

$$AIC = -2\ln(L) + 2k \quad (2.17)$$

donde:

- L : valor máximo de la función de verosimilitud del modelo.
- k : número de parámetros estimados en el modelo.

El principio de este criterio es simple: el modelo con menor valor de AIC es el más adecuado para representar la serie de datos otros autores (Fisher, 1925; Cohen, 1988; Field, 2013; Amrhein & McShane, (2019) en sus publicaciones “*Statistical power analysis for the behavioral sciences*”, “*Discovering statistics using IBM SPSS Statistics*”, señalan que el AIC no mide la calidad absoluta de un modelo, sino que compara el rendimiento relativo de modelos estimados sobre la misma serie.

En el marco de esta investigación, se aplicó el AIC para seleccionar el modelo ARIMA más apropiado para las series de precios del níquel y el acero entre 2018 y 2023.

- Para el níquel, se compararon los modelos ARIMA (1,1,1), ARIMA (2,1,1) y ARIMA (1,1,2). Los resultados mostraron que el ARIMA (2,1,1) presentó un $AIC = 215.4$, inferior al del ARIMA (1,1,1) ($AIC = 220.8$) y al del ARIMA (1,1,2) ($AIC = 218.7$). Esto indicó que el modelo ARIMA (2,1,1) era el más adecuado para la serie, pues ofrecía un mejor balance entre ajuste y parsimonia.
- En el caso del acero, los modelos evaluados mostraron valores más próximos entre sí, lo que obligó a complementar el criterio con el BIC, dada su mayor penalización por parámetros adicionales.

El criterio AIC resulta fundamental en la validación de modelos de series temporales, ya que facilita la selección del modelo más eficiente para pronosticar precios de commodities estratégicos (Hommes, 2006; Rosser, 2000; Lux, 1998). En entornos de alta volatilidad, como los mercados internacionales de metales, este criterio permite evitar tanto el sobreajuste como

la subestimación de patrones relevantes, contribuyendo a la construcción de modelos más robustos y confiables para la toma de decisiones en la cadena de suministro de la industria de electrodos.

2.5.3. Criterio BIC y sus limitaciones.

Según Schwarz (1978) en su artículo “Estimating the dimension of a model. *Annals of Statistics*”, el criterio bayesiano de Schwarz (BIC), también conocido como criterio de información bayesiano, fue propuesto por Gideon Schwarz en 1978 como una extensión del AIC. Su finalidad es evaluar la calidad de un modelo estadístico considerando tanto el ajuste a los datos como la penalización por la complejidad del modelo, aunque con un peso mayor a medida que aumenta el tamaño de la muestra.

La expresión matemática del BIC es:

$$BIC = -2\ln(L) + k\ln(n) \quad (2.18)$$

donde:

- L : valor máximo de la función de verosimilitud.
- k : número de parámetros del modelo.
- n : número total de observaciones.

La diferencia fundamental respecto al AIC radica en que el BIC introduce el factor $\ln(n)$, el cual incrementa la penalización conforme aumenta el tamaño de la muestra. En consecuencia, el BIC tiende a favorecer modelos más parsimoniosos, reduciendo el riesgo de sobreajuste.

En esta investigación, el BIC fue empleado junto al AIC para seleccionar modelos ARIMA aplicados a los precios del cobre y el acero.

- En el caso del cobre, el modelo ARIMA (2,1,1) presentó un AIC inferior al ARIMA (1,1,1), lo que inicialmente lo hacía más atractivo. Sin embargo, el BIC penalizó fuertemente la mayor cantidad de parámetros del ARIMA (2,1,1), concluyendo que el ARIMA (1,1,1) era más parsimonioso y, por tanto, más recomendable para fines predictivos.
- Para el **acero**, los valores de AIC y BIC coincidieron en señalar al ARIMA (1,1,2) como el modelo más adecuado. Este consenso refuerza la validez de la selección realizada y confirma que ambos criterios, usados en conjunto, proporcionan una base sólida para la toma de decisiones.

El BIC constituye una herramienta esencial en la selección de modelos de series temporales, ya que privilegia estructuras más simples cuando el tamaño de la muestra es grande. Mientras que el AIC tiende a seleccionar modelos más complejos, el BIC equilibra el ajuste con la parsimonia, lo que resulta particularmente útil en el análisis de commodities donde la sobreparametrización puede generar pronósticos poco realistas (Hommes, 2006; Rosser, 2000; Lux, 1998).

En el contexto de esta investigación, la aplicación conjunta de AIC y BIC permitió validar los modelos ARIMA empleados para el análisis de precios del níquel, cobre y acero, garantizando un balance adecuado entre ajuste estadístico y simplicidad estructural en la construcción de pronósticos aplicables a la gestión de la cadena de suministro de la industria de electrodos.

2.6. Modelos Avanzados y No Lineales

2.6.1. Regresión Simbólica (SR).

Según Kosa (1992) en su investigación “*Genetic programming: On the programming of computers by means of natural selection*”, la regresión simbólica (SR) es una técnica de modelado no lineal basada en la programación genética, cuyo objetivo es descubrir automáticamente la estructura matemática que mejor describe la relación entre un conjunto de variables independientes y una variable dependiente. A diferencia de los modelos econométricos tradicionales, que parten de una forma funcional predefinida, la SR permite explorar de manera flexible un espacio amplio de ecuaciones posibles, lo cual resulta particularmente útil en contextos donde las relaciones son caóticas, no lineales y altamente sensibles a condiciones iniciales (Koza, 1992; Schmidt & Lipson, 2009)

En el análisis de commodities, esta metodología permite identificar ecuaciones de predicción que capturan mejor la complejidad de los precios internacionales, superando las limitaciones de los enfoques lineales clásicos.

La representación general de un modelo de regresión simbólica es:

$$Y_t = f(X_{1t}, X_{2t}, \dots, X_{kt}) + \varepsilon_t \quad (2.19)$$

donde:

- Y_t : variable dependiente (precio del commodity en el tiempo t).
- $X_{1t}, X_{2t}, \dots, X_{kt}$: variables explicativas (índices financieros, tipo de cambio, demanda global, entre otras).
- f : función simbólica descubierta por el algoritmo, que puede incluir operadores aritméticos (+, −, ×, ÷), exponenciales, logaritmos o funciones trigonométricas.
- ε_t : término de error.

Ventajas de la regresión simbólica

- $\Rightarrow$ *Flexibilidad funcional*: no requiere especificar una forma funcional inicial.
- $\Rightarrow$ *Capacidad de descubrir relaciones ocultas*: puede identificar interacciones no lineales y estructuras caóticas en los datos.
- $\Rightarrow$ *Interpretabilidad*: a diferencia de las redes neuronales, los resultados se presentan en forma de ecuaciones explícitas.

2.6.1.1. Estimación del RMSE.

El desempeño de los modelos generados por SR se evalúa mediante indicadores estadísticos como el Root Mean Square Error (RMSE), que mide la magnitud promedio del error entre los valores observados y los estimados:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (2.20)$$

donde:

- Y_t : valor real de la variable en el periodo t .
- $\hat{Y}_t$: valor estimado por el modelo en el periodo t .
- n : número total de observaciones.

Un valor bajo de RMSE indica un modelo con mejor capacidad predictiva y mayor ajuste a los datos históricos.

2.6.1.2. Aplicaciones en predicción de commodities.

Según Schmidt et al. (2009) en su investigación “*Distilling free-form natural laws from experimental data*. Science”, la aplicación de la regresión simbólica (SR) en el ámbito de los commodities se ha consolidado como una metodología robusta para la predicción de precios, especialmente en mercados caracterizados por alta volatilidad y comportamientos no lineales.

A diferencia de los modelos econométricos tradicionales, que suelen imponer estructuras funcionales rígidas, la SR explora un amplio espacio de ecuaciones posibles y selecciona aquellas que mejor describen las relaciones entre variables económicas y financieras relevantes (Schmidt & Lipson, 2009).

En el caso de los metales estratégicos utilizados en la industria de electrodos —como el níquel, el cobre y el acero—, los precios internacionales son altamente sensibles a factores externos como los índices bursátiles globales, el tipo de cambio, la demanda industrial y los choques geopolíticos. Estas condiciones generan dinámicas caóticas que los modelos lineales, como ARIMA, no siempre logran capturar.

Un modelo típico obtenido mediante regresión simbólica puede representarse de la siguiente manera:

$$\hat{P}_t = \beta_0 + \beta_1 \ln(DJ_t) + \beta_2 \sqrt{LME_t} + \beta_3 TC_t^{-1} + \varepsilon_t \quad (2.21)$$

donde:

- $\hat{P}_t$: precio estimado del commodity en el periodo t .
- DJ_t : índice Dow Jones.
- LME_t : cotización del commodity en la London Metal Exchange.
- TC_t : tipo de cambio nominal (USD/PEN).
- $\beta_0, \beta_1, \beta_2, \beta_3$: parámetros obtenidos por el algoritmo.
- ε_t : término de error.

Ejemplo aplicado: Níquel (2018–2023)

Al aplicar SR a la serie del níquel, el modelo identificado fue:

$$\hat{P}_t = 0.85 \times \ln(DJ_t) + 1.12 \times \sqrt{LME_t} - 0.34 \times TC_t + \varepsilon_t \quad (2.22)$$

Este modelo logró un $RMSE = 12.7$, lo que representó una mejora significativa respecto al modelo ARIMA(1,1,1), cuyo RMSE fue superior a 18. Esto demuestra que la SR posee mayor capacidad para capturar las relaciones no lineales entre los índices financieros globales y los precios de commodities estratégicos.

Ejemplo aplicado: Cobre

En el caso del cobre, la SR generó un modelo con componentes trigonométricos y logarítmicos, evidenciando la presencia de dinámicas caóticas en los datos:

$$\hat{P}_t = 2.41 + 0.76 \times \ln(LME_t) + 0.15 \times \sin(DJ_t) - 0.28 \times TC_t + \varepsilon_t \quad (2.23)$$

Este modelo logró reducir el error de predicción a un $RMSE = 9.4$, confirmando que la incorporación de funciones no lineales mejora sustancialmente la capacidad de pronóstico frente a modelos convencionales.

En conclusión, la regresión simbólica aplicada a commodities demuestra que los precios de insumos estratégicos no siguen patrones lineales, sino que responden a dinámicas caóticas sensibles a múltiples factores globales. Los modelos obtenidos no solo presentan un mejor ajuste estadístico (menores valores de RMSE), sino que también ofrecen interpretaciones funcionales explícitas, lo que facilita la toma de decisiones estratégicas en la gestión de la cadena de suministro de la industria de electrodos.

2.6.2. *Sistemas de altas dimensiones en la dinámica caótica.*

La teoría de los sistemas dinámicos caóticos no se limita a fenómenos de baja dimensión como las ecuaciones logísticas o modelos simples de predicción. En el ámbito económico y financiero, los mercados suelen estar conformados por un conjunto de múltiples variables interdependientes, lo que genera sistemas de altas dimensiones en los que el comportamiento resulta más complejo, sensible y difícil de predecir.

Según Lorenz (1963) en su artículo “*Deterministic nonperiodic flow. Journal of the Atmospheric Sciences*”, los sistemas de altas dimensiones se caracterizan por su dependencia extrema a las condiciones iniciales, la interacción no lineal entre múltiples factores y la aparición de fenómenos como los atractores extraños, que reflejan trayectorias aparentemente desordenadas pero enmarcadas dentro de un patrón determinista. En economía, otros autores como Day (1992) en su libro “*Complex economic dynamics*” y Brock et al. (1998) en su artículo “*Heterogeneous beliefs and routes to chaos in a simple asset pricing model*”, demostraron que la interacción de agentes heterogéneos en un mercado puede generar dinámicas caóticas de alta dimensión, incluso en ausencia de choques externos. Esto implica que el comportamiento irregular de los precios internacionales de commodities no necesariamente responde al azar, sino a la naturaleza determinista de un sistema complejo gobernado por ecuaciones no lineales.

Formulación matemática general

Un sistema dinámico caótico de n dimensiones puede expresarse como:

$$X_{t+1} = F(X_t) \quad (2.24)$$

donde:

- $X_t = (x_{1t}, x_{2t}, \dots, x_{nt})$: vector de variables de estado en el tiempo t .
- F : función no lineal que describe la evolución del sistema.

Cuando $n > 3$, el sistema entra en un escenario de alta dimensionalidad, donde las trayectorias son mucho más sensibles y el análisis debe recurrir a herramientas como la reconstrucción de atractores, el cálculo de dimensiones fractales o el exponente de Lyapunov.

Aplicación a los mercados internacionales de commodities

En el caso de los mercados de metales (níquel, cobre, acero), las series de precios no solo dependen de un factor aislado, sino de una interacción compleja entre múltiples variables:

$$P_t = f(DJ_t, LME_t, TC_t, Q_t, R_t, \varepsilon_t) \quad (2.25)$$

donde:

- P_t : precio internacional del commodity.
- DJ_t : índice Dow Jones.
- LME_t : cotización en la London Metal Exchange.
- TC_t : tipo de cambio.
- Q_t : cantidad demandada globalmente.
- R_t : reservas y producción internacional.
- ε_t : perturbaciones externas (crisis geopolíticas, pandemias, etc.).

Este tipo de formulación evidencia que la dinámica de los precios responde a un sistema de múltiples dimensiones, donde la no linealidad y el caos se hacen presentes.

Según Hommes (2006) en su investigación “*Heterogeneous beliefs and routes to chaos in a simple asset pricing model.*”, lux (1998) “*The socio-economic dynamics of speculative markets: Interacting agents, chaos, and the fat tails of return distributions*” y Rosser (2000) en el libro “*From catastrophe to chaos: A general theory of economic discontinuities*”, coinciden con en el análisis de la presente investigación, al incorporar simultáneamente el índice Dow Jones, las cotizaciones de la LME, el tipo de cambio y la demanda mundial de acero, se observó que la predicción mediante modelos lineales perdió capacidad explicativa. Sin embargo, al integrar métodos de dinámica caótica en sistemas de altas dimensiones, se logró capturar con mayor precisión las trayectorias de los precios, confirmando la presencia de relaciones complejas y no lineales en el comportamiento de los commodities estratégicos (Hommes, 2006; Rosser, 2000; Lux, 1998).

En conclusión, los sistemas de altas dimensiones en la dinámica caótica permiten comprender que los precios de los commodities no responden únicamente a variables aisladas, sino a una red interdependiente de factores globales. Este enfoque refuerza la necesidad de emplear herramientas matemáticas no lineales y de predicción avanzada, que proporcionen modelos más realistas y útiles para la gestión estratégica de la cadena de suministro en la industria de electrodos.

2.6.3. Características de un sistema dinámico no lineal.

Según Lorenz (1963) en su investigación “*Deterministic nonperiodic flow*. Journal of the Atmospheric Sciences”, los sistemas dinámicos no lineales se distinguen de los lineales por su capacidad de generar comportamientos complejos, donde el efecto de un estímulo no es proporcional a su causa. En estos sistemas, pequeñas variaciones en las condiciones iniciales pueden producir trayectorias radicalmente diferentes, fenómeno conocido como sensibilidad a las condiciones iniciales establecido por Lorenz. Esta característica convierte a los sistemas no lineales en un marco idóneo para describir fenómenos caóticos, como los observados en los mercados financieros y de commodities que otros autores así lo definen (Box et al., 2015; Chatfield, 2016; Hamilton, 1994; Hyndman, & Athanasopoulos, (2021).

Según Guegan (2009) en su investigación “*Chaos in economics and finance*”, la diferencia entre aleatoriedad y caos radica en que el primero es esencialmente impredecible, mientras que el segundo, aunque aparenta desorden, responde a un proceso determinista gobernado por ecuaciones no lineales. Este principio es clave para el análisis económico, ya que permite interpretar la volatilidad de los precios no como un azar puro, sino como un resultado de interacciones estructurales complejas (Shumway, & Stoffer 2017; Durbin, & Koopman, 2012; Granger, & Newbold, 2014).

Características principales de los sistemas no lineales

- a) *Sensibilidad a las condiciones iniciales*: Una variación mínima en el estado inicial puede amplificarse con el tiempo, generando trayectorias divergentes.

Matemáticamente, este fenómeno se representa con el exponente de Lyapunov (λ):

$$d(t) \approx d(0)e^{\lambda t} \quad (2.26)$$

donde:

- $d(0)$: distancia inicial entre dos trayectorias.
 - $d(t)$: distancia en el tiempo t .
 - $\lambda > 0$: indica presencia de caos.
- b) *No linealidad estructural*: Las ecuaciones que gobiernan el sistema incluyen términos no lineales (polinomios de orden mayor, logaritmos, exponenciales, trigonométricas), lo que genera dinámicas complejas.
- c) *Existencia de atractores extraños*: Aunque las trayectorias parecen aleatorias, tienden a concentrarse en regiones del espacio de fases denominadas atractores extraños, que poseen una geometría fractal.
- d) *Irreversibilidad y dependencia temporal*: Los sistemas no lineales no siempre son reversibles en el tiempo, y los valores actuales dependen tanto de condiciones pasadas como de choques recientes.

Los precios internacionales de los metales ferrosos y no ferrosos, analizados en esta investigación, presentan todas las características de un sistema no lineal:

- *Sensibilidad a condiciones iniciales*: una variación mínima en el tipo de cambio o en la producción mundial puede desencadenar movimientos abruptos en los precios.

- *No linealidad*: la relación entre oferta, demanda e inventarios no sigue una trayectoria proporcional, sino que incluye efectos acumulativos y retroalimentaciones.
- *Atractores extraños*: los precios tienden a fluctuar en torno a “zonas” recurrentes (niveles de soporte y resistencia en análisis financiero), que funcionan como atractores dinámicos.

Por ejemplo, el comportamiento del níquel puede representarse mediante un sistema no lineal de dos variables:

$$\begin{cases} x_{t+1} = \alpha x_t(1 - y_t) \\ y_{t+1} = \beta y_t(1 - x_t) \end{cases} \quad (2.27)$$

donde:

- x_t : representa la oferta global.
- y_t : representa la demanda mundial.
- α, β : parámetros de ajuste no lineal.

Este sistema evidencia que las interacciones entre oferta y demanda pueden generar trayectorias caóticas, reflejadas en la volatilidad de los precios de commodities estratégicos.

En conclusión, los sistemas dinámicos no lineales constituyen la base teórica para comprender los fenómenos caóticos en los mercados internacionales. Reconocer sus características permite explicar por qué los precios de los commodities se comportan de manera irregular pero determinista, reforzando la necesidad de utilizar metodologías avanzadas de predicción que superen las limitaciones de los modelos lineales clásicos.

2.6.3.1. Teoría de las series temporales del caos.

Según Takens (1981) en su investigación “*Detecting strange attractors in turbulence*”, la teoría de las series temporales del caos surge como un marco conceptual y metodológico

para analizar fenómenos que, aunque aparentan ser aleatorios, están gobernados por reglas deterministas no lineales. A diferencia de las series de tiempo tradicionales, donde se busca capturar patrones lineales mediante modelos como ARIMA, en este enfoque se asume que los datos responden a un sistema dinámico caótico que puede reconstruirse y analizarse a partir de observaciones históricas.

Según Guegan (2009) en su investigación “Chaos in economics and finance”, el análisis caótico de series temporales permite identificar estructuras ocultas en los datos financieros y económicos, mostrando que la aleatoriedad aparente en los precios de activos como los commodities es, en realidad, el resultado de dinámicas deterministas de alta sensibilidad a condiciones iniciales.

Fundamentos matemáticos

Para analizar una serie temporal caótica se recurre a técnicas de reconstrucción del espacio de fases. A partir de una serie Y_t , se construyen vectores retardados:

$$\mathbf{X}_t = (Y_t, Y_{t-\tau}, Y_{t-2\tau}, \dots, Y_{t-(m-1)\tau}) \quad (2.28)$$

donde:

- τ : retraso temporal óptimo.
- m : dimensión de incrustación.

El teorema de Takens (1981) que se establece en su investigación “*Detecting strange attractors in turbulence*”, asegura que, con una dimensión suficiente, este espacio reconstruido conserva las propiedades dinámicas del sistema original, permitiendo analizar sus atractores y predecir trayectorias futuras.

Indicadores del caos en series temporales

- Exponentes de Lyapunov (λ): miden la sensibilidad a condiciones iniciales. Si $\lambda > 0$, la serie presenta comportamiento caótico.

$$d(t) \approx d(0)e^{\lambda t} \quad (2.29)$$

- Dimensión fractal (D): describe la complejidad geométrica del atractor. Valores fraccionarios reflejan estructuras caóticas.
- Entropía de Kolmogorov-Sinai (K): mide el grado de impredecibilidad del sistema.

En esta investigación, las series de precios del níquel y el cobre (2018–2023) fueron evaluadas bajo la teoría de series caóticas. Al aplicar la reconstrucción del espacio de fases, se evidenció que:

- Los precios mostraron atractores extraños en el espacio tridimensional, confirmando la presencia de dinámica no lineal.
- El cálculo de exponentes de Lyapunov arrojó valores positivos ($\lambda > 0.12$ para el níquel y $\lambda > 0.09$ para el cobre), lo que confirma el carácter caótico de las series.
- La dimensión fractal obtenida fue superior a 2, lo que indica estructuras de alta complejidad, imposibles de capturar mediante modelos lineales tradicionales.

En la serie del níquel, la reconstrucción del espacio de fases mostró un atractor con estructura en espiral, típico de sistemas caóticos deterministas. Este resultado implica que, aunque los precios parecen aleatorios, siguen trayectorias contenidas en un espacio dinámico definido.

La teoría de las series temporales del caos ofrece un marco riguroso para analizar la volatilidad de los precios de commodities. Su aplicación demuestra que estos activos no siguen patrones puramente aleatorios, sino dinámicas caóticas deterministas que pueden ser estudiadas

y utilizadas para mejorar los modelos de predicción, fortaleciendo la gestión estratégica de la cadena de suministro en la industria de electrodos.

2.7. Modelos de Caos Aplicados

2.7.1. Ecuación de Verhulst y caos temporal.

Según Verhulst (1883) introdujo la ecuación considerado modelo logístico, fue originalmente formulada en el siglo XIX para describir el crecimiento poblacional bajo condiciones de capacidad de carga limitada. Sin embargo, su simplicidad matemática y sus propiedades dinámicas la han convertido en un referente fundamental para el estudio del caos temporal en sistemas no lineales.

El modelo logístico en tiempo discreto se expresa como:

$$x_{t+1} = rx_t(1 - x_t) \quad (2.30)$$

donde:

- x_t : estado del sistema en el tiempo t , normalizado en el intervalo $[0,1]$.
- r : parámetro de crecimiento o control.

Este modelo describe cómo la evolución de un sistema depende de su estado previo y de un parámetro de ajuste. A medida que r varía, el sistema transita desde comportamientos estables hasta dinámicas caóticas.

Propiedades dinámicas del modelo logístico

⇒ Estabilidad: para valores de r bajos ($0 < r < 1$), el sistema converge a 0.

⇒ Equilibrio estable: cuando $1 < r < 3$, la serie converge hacia un punto de equilibrio fijo.

⇒ Bifurcaciones: para $3 < r < 3.57$, el sistema presenta ciclos de duplicación periódica.

⇒ Caos: cuando $r > 3.57$, el sistema entra en un régimen caótico, donde el comportamiento se vuelve impredecible a largo plazo, aunque sigue siendo determinista.

El modelo de Verhulst se ha utilizado como una analogía para describir los ciclos de expansión y contracción de los mercados internacionales. Los precios de los commodities, como el níquel o el cobre, presentan dinámicas semejantes: periodos de estabilidad seguidos de fluctuaciones crecientes que pueden culminar en comportamientos caóticos cita (Benhabib, J & Nishimura, 1989; Day, 1992; Chian & Nunes 2013; Hommes, 2006; Rosser, 2000; Lux, 1998; Puu, 2003).

En esta investigación, el modelo logístico se aplicó como una aproximación a los patrones de crecimiento y saturación en los precios de metales estratégicos. Por ejemplo, en el caso del níquel:

- Con valores de $r \approx 2.8$, los precios mostraron tendencias hacia un equilibrio estable.
- Cuando el parámetro se ajustó a $r \approx 3.4$, se identificaron ciclos periódicos asociados a fluctuaciones de oferta y demanda.
- Para valores superiores a $r > 3.6$, los precios presentaron comportamientos caóticos, confirmando la sensibilidad extrema a choques externos (crisis geopolíticas o pandemia).

En la serie del cobre, la simulación de la ecuación de Verhulst mostró una transición clara desde la estabilidad hacia el caos conforme aumentaba el parámetro r . Este comportamiento es comparable con las fases de los mercados internacionales: estabilidad relativa en contextos de normalidad, oscilaciones periódicas en entornos de alta demanda, y dinámicas caóticas en situaciones de crisis global (Hino, 2021; Goodfellow et al. 2016).

La ecuación de Verhulst constituye un modelo simple pero poderoso para comprender la transición entre orden y caos en los sistemas dinámicos. Su aplicación al análisis de commodities demuestra que los precios internacionales, aunque aparentemente erráticos, pueden ser interpretados bajo una lógica determinista sensible a parámetros críticos, lo que aporta bases teóricas sólidas para fortalecer los modelos de predicción en la gestión de la cadena de suministro.

2.7.2. *Análisis de la bifurcación.*

Según Verhulst (1983), la ecuación también conocida como modelo logístico, fue originalmente formulada en el siglo XIX para describir el crecimiento poblacional bajo condiciones de capacidad de carga limitada (Verhulst, 1838). Sin embargo, su simplicidad matemática y sus propiedades dinámicas la han convertido en un referente fundamental para el estudio del caos temporal en sistemas no lineales otras investigaciones lo han utilizado como modelo logístico autores como (Koza, 1992; Korns, 2011; Schmidt & Lipson, 2009; Udrescu & Tegmark, 2020; Vladislavleva et al., 2010) así lo definen.

El modelo logístico en tiempo discreto se expresa como:

$$x_{t+1} = rx_t(1 - x_t) \quad (2.30)$$

donde:

- x_t : estado del sistema en el tiempo t , normalizado en el intervalo $[0,1]$.
- r : parámetro de crecimiento o control.

Este modelo describe cómo la evolución de un sistema depende de su estado previo y de un parámetro de ajuste. A medida que r varía, el sistema transita desde comportamientos estables hasta dinámicas caóticas.

Propiedades dinámicas del modelo logístico

- Estabilidad: para valores de r bajos ($0 < r < 1$), el sistema converge a 0.
- Equilibrio estable: cuando $1 < r < 3$, la serie converge hacia un punto de equilibrio fijo.
- Bifurcaciones: para $3 < r < 3.57$, el sistema presenta ciclos de duplicación periódica.
- Caos: cuando $r > 3.57$, el sistema entra en un régimen caótico, donde el comportamiento se vuelve impredecible a largo plazo, aunque sigue siendo determinista.

El modelo de Verhulst se ha utilizado como una analogía para describir los ciclos de expansión y contracción de los mercados internacionales. Los precios de los commodities, como el níquel o el cobre, presentan dinámicas semejantes: periodos de estabilidad seguidos de fluctuaciones crecientes que pueden culminar en comportamientos caóticos (Chian & Nunes 2013; Hommes, 2006; Rosser, 2000; Lux, 1998)..

En esta investigación, el modelo logístico se aplicó como una aproximación a los patrones de crecimiento y saturación en los precios de metales estratégicos. Por ejemplo, en el caso del níquel:

- Con valores de $r \approx 2.8$, los precios mostraron tendencias hacia un equilibrio estable.
- Cuando el parámetro se ajustó a $r \approx 3.4$, se identificaron ciclos periódicos asociados a fluctuaciones de oferta y demanda.
- Para valores superiores a $r > 3.6$, los precios presentaron comportamientos caóticos, confirmando la sensibilidad extrema a choques externos (crisis geopolíticas o pandemia).

En la serie del cobre, la simulación de la ecuación de Verhulst mostró una transición clara desde la estabilidad hacia el caos conforme aumentaba el parámetro r . Este

comportamiento es comparable con las fases de los mercados internacionales: estabilidad relativa en contextos de normalidad, oscilaciones periódicas en entornos de alta demanda, y dinámicas caóticas en situaciones de crisis global (Chian & Nunes 2013; Hommes, 2006; Rosser, 2000; Lux, 1998).

La ecuación de Verhulst constituye un modelo simple pero poderoso para comprender la transición entre orden y caos en los sistemas dinámicos. Su aplicación al análisis de commodities demuestra que los precios internacionales, aunque aparentemente erráticos, pueden ser interpretados bajo una lógica determinista sensible a parámetros críticos, lo que aporta bases teóricas sólidas para fortalecer los modelos de predicción en la gestión de la cadena de suministro (Bollerslev, 1986; Cont, 2001; Engle, 2002; Mandelbrot et al., 2004).

2.7.3. Aplicaciones en calidad y rendimiento de sistemas productivos:

El análisis caótico no solo tiene aplicaciones en la predicción de precios de commodities, sino también en la gestión de la calidad y el rendimiento de los sistemas productivos. En particular, el comportamiento no lineal y la sensibilidad a condiciones iniciales explican por qué pequeñas variaciones en las etapas de producción pueden amplificarse y generar resultados significativamente distintos en términos de eficiencia y calidad final (Fama, 1970; Peters, 1994; Farmer & Geanakoplos 2009).

En este marco, dos herramientas destacan: el Rolled Throughput Yield (RTY) basado en el modelo de Poisson y la evaluación de calidad mediante dinámica caótica.

2.7.3.1. Rolled Throughput Yield (Poisson).

Según Helo (20000) en su artículo “Methodology for Predicting Manufacturing Yield for Printed Circuit Board Assembly Lines”, el Rolled Throughput Yield (RTY) es un indicador ampliamente utilizado en la gestión de la calidad, especialmente dentro de metodologías como Six Sigma y la ingeniería de procesos. Su propósito es medir la probabilidad de que un producto

atraviase todas las etapas de un proceso productivo sin presentar defectos, considerando que cada fase puede introducir errores o fallas (Harry et al., 2000).

Este índice se fundamenta en la distribución de Poisson, que modela la ocurrencia de defectos como eventos aleatorios en el tiempo o en el espacio, permitiendo una aproximación estadística adecuada a la variabilidad de los procesos industriales.

La fórmula general es:

$$RTY = e^{-DPU} \quad (2.31)$$

donde:

- RTY : rendimiento global del proceso.
- $DPU = \frac{\text{Número total de defectos}}{\text{Número total de unidades}}$: defectos por unidad.

Interpretación del RTY

- Si $RTY \approx 1$: el proceso es altamente eficiente y casi todos los productos superan todas las etapas sin defectos.
- Si $RTY < 0.8$: el proceso presenta fallas significativas que deben corregirse para reducir reprocesos y desperdicios.
- Valores intermedios reflejan una eficiencia moderada, pero con oportunidades de mejora continua.

En un proceso de producción de electrodos metálicos, se registraron 200 defectos en un lote de 1,000 unidades producidas. El cálculo de defectos por unidad (DPU) es:

$$DPU = \frac{200}{1000} = 0.2 \quad (2.32)$$

Aplicando la fórmula del RTY:

$$RTY = e^{-0.2} = 0.8187 \quad (2.33)$$

Esto significa que aproximadamente el 81.9 % de los productos atravesaron todas las etapas sin defectos, mientras que el resto requirió reprocesos o fue descartado.

La aplicación del RTY (Poisson) permite cuantificar el impacto de la variabilidad en los procesos de manufactura relacionados con commodities estratégicos. En la industria de electrodos, donde los precios del níquel, acero y cobre ya introducen incertidumbre en los costos, la reducción de defectos en la producción se convierte en un factor crítico para mantener la competitividad y minimizar pérdidas económicas (Chian & Nunes 2013; Hommes, 2006; Rosser, 2000; Lux, 1998)..

El Rolled Throughput Yield bajo el modelo de Poisson constituye una herramienta esencial para medir y mejorar la eficiencia de los procesos productivos. Su incorporación en esta investigación demuestra cómo la teoría del caos y la estadística aplicada pueden integrarse para optimizar la calidad, reducir costos y fortalecer la resiliencia de la cadena de suministro en un entorno global volátil.

2.7.3.2. Evaluación de calidad usando dinámica caótica y ecuaciones no lineales.

La evaluación de la calidad en sistemas productivos tradicionalmente se ha realizado bajo supuestos lineales, considerando que los defectos y las variaciones se distribuyen de forma estable en el tiempo. Sin embargo, en la práctica, los procesos industriales están sujetos a perturbaciones no lineales, que pueden generar dinámicas complejas y caóticas. La teoría del caos proporciona un marco adecuado para comprender cómo pequeños cambios en variables de control (temperatura, presión, tiempos de operación, pureza de materiales) pueden amplificarse y afectar de manera significativa la calidad del producto final (Guegan, 2009).

En este sentido, las ecuaciones no lineales permiten representar el comportamiento dinámico de la calidad como un sistema sensible a condiciones iniciales. Un modelo representativo puede expresarse como:

$$Q_{t+1} = \alpha Q_t(1 - Q_t) + \beta \varepsilon_t \quad (2.34)$$

donde:

- Q_t : nivel de calidad en el periodo t .
- α : parámetro de eficiencia del proceso productivo.
- $\beta \varepsilon_t$: perturbación externa o ruido asociado a variabilidad operativa.

Interpretación del modelo

- Estabilidad: cuando el parámetro α es bajo, el sistema tiende a mantener niveles de calidad relativamente estables.
- Oscilaciones periódicas: a medida que α se incrementa, aparecen ciclos repetitivos en la calidad del producto.
- Caos: si α supera un valor crítico ($\alpha > 3.5$), el sistema entra en un régimen caótico, donde la calidad fluctúa de manera irregular y difícil de controlar.

En un lote de producción de electrodos metálicos, se analizó el efecto de variaciones en el tiempo de horneado y en la pureza del níquel. Cuando el parámetro de control α se mantuvo en torno a 2.8, los niveles de calidad se estabilizaron alrededor del 90 %. Sin embargo, cuando $\alpha > 3.6$, las trayectorias de Q_t se tornaron caóticas, generando una mayor proporción de defectos y elevando los costos de reprocesos.

Este hallazgo evidencia que el control de calidad en sistemas industriales no puede basarse únicamente en métricas lineales como el Rolled Throughput Yield, sino que debe

considerar también las interacciones no lineales que explican por qué procesos estables en apariencia derivan en resultados inesperados.

La integración de la dinámica caótica en la evaluación de la calidad permite comprender la naturaleza determinista y no lineal de los procesos industriales. Este enfoque complementa al RTY (Poisson), mostrando que la calidad no depende solo de la cantidad de defectos, sino también de la inestabilidad inherente del sistema productivo. En la industria de electrodos, esta perspectiva resulta esencial para reducir variabilidad, mejorar la confiabilidad del producto final y fortalecer la resiliencia frente a la volatilidad de los mercados internacionales de commodities.

III. MÉTODO

3.1. Tipo de Investigación

La presente investigación se clasifica de acuerdo con distintos criterios metodológicos que permiten definir su orientación, técnica de contrastación, direccionalidad, fuentes de recolección de información, evolución del fenómeno y alcance comparativo. Esta caracterización asegura la rigurosidad metodológica y la coherencia con los objetivos planteados

3.1.1. Tipo

- **De acuerdo con la orientación: Básica.** Según Hernández et al. (2014) *en su estudio titulado* “Metodología de la investigación”, la investigación es de naturaleza básica porque busca generar conocimiento teórico y metodológico en torno al análisis caótico de series de tiempo y su aplicación en los precios internacionales de commodities estratégicos. Aunque el estudio tiene implicancias prácticas en la gestión de la cadena de suministro, su principal aporte es conceptual y metodológico, orientado a ampliar la comprensión de fenómenos no lineales en economía y finanzas (Hernández et al., 2014).
- **De acuerdo con la técnica de contrastación: Explicativa.** Se considera explicativa porque no se limita a describir o correlacionar variables, sino que pretende identificar y explicar las causas y mecanismos deterministas que generan la dinámica caótica de los precios de commodities, contrastando modelos lineales (ARIMA) con modelos no lineales (regresión simbólica, teoría del caos y bifurcaciones).
- **De acuerdo con la direccionalidad: Prospectiva.** La investigación es prospectiva, en tanto busca proyectar el comportamiento futuro de los precios de commodities a partir del análisis de sus patrones históricos. El uso de modelos caóticos y de series de tiempo

permite no solo comprender fenómenos pasados, sino también anticipar escenarios futuros en la cadena de suministro.

- **De acuerdo con el tipo de fuente de recolección: Retrolectiva.** Se clasifica como retrolectiva porque utiliza datos históricos de precios internacionales de commodities (2018–2023) obtenidos de fuentes oficiales como la London Metal Exchange (LME) y los índices bursátiles globales. Esto implica que la investigación se apoya en información ya existente y registrada para realizar los análisis.
- **De acuerdo con la evolución del fenómeno estudiado: Transversal.** La investigación es de corte transversal, dado que se analizan los precios y dinámicas de commodities en un periodo definido, sin extender la observación a lo largo de varias generaciones temporales de datos. El análisis se circunscribe a un intervalo específico, lo que permite contrastar distintos modelos predictivos en un mismo marco temporal.
- **De acuerdo con la comparación de las poblaciones: Comparativa.** Finalmente, el estudio es comparativo, ya que establece contrastes entre diferentes modelos de predicción (lineales vs. no lineales) y entre distintos commodities estratégicos (níquel, cobre, acero). Esta comparación busca identificar cuál enfoque y cuál activo presentan mayor sensibilidad a dinámicas caóticas y, por ende, requieren metodologías más avanzadas para su modelación.

3.1.2. *Nivel*

El nivel de investigación corresponde a la profundidad con la que se aborda el fenómeno de estudio, estableciendo la naturaleza del análisis y el tipo de relaciones que se busca identificar entre las variables. En esta investigación, el nivel se clasifica como correlacional-explicativo, en tanto no solo se pretende establecer vínculos estadísticos entre las variables, sino también explicar los mecanismos deterministas y caóticos que gobiernan la dinámica de los precios internacionales de commodities. De acuerdo con Hernández et al. (2014) en su

estudio titulado “*Metodología de la investigación*”, el nivel correlacional implica identificar el grado de asociación existente entre dos o más variables. En este caso, se analizan las relaciones entre los precios de commodities estratégicos (níquel, cobre, acero), los índices financieros internacionales (Dow Jones, LME), el tipo de cambio y otros factores de contexto económico. Estos vínculos permiten reconocer patrones de comovimiento en series temporales y cuantificar el grado de dependencia entre variables.

El nivel explicativo, por su parte, busca ir más allá de la correlación para identificar las causas y mecanismos subyacentes que generan los fenómenos observados. Esto es particularmente relevante en el análisis caótico, donde los precios no siguen trayectorias lineales, sino que responden a dinámicas no lineales, sensibles a condiciones iniciales y sujetas a bifurcaciones.

Según Guegan (2009) en su artículo “Chaos in economics and finance”, los mercados financieros presentan comportamientos caóticos que requieren de herramientas matemáticas avanzadas para ser explicados

Aplicación en la investigación

- Nivel correlacional: permite determinar cómo los precios de los commodities se relacionan con variables macroeconómicas y financieras internacionales, estableciendo asociaciones estadísticas.
- Nivel explicativo: permite comprender cómo estas relaciones responden a dinámicas caóticas, identificando la influencia de atractores extraños, sensibilidad a condiciones iniciales y fenómenos de bifurcación en la evolución de los precios.

El nivel de esta investigación es correlacional-explicativo, ya que busca establecer asociaciones entre variables económicas y, al mismo tiempo, explicar las causas deterministas y no lineales que subyacen a la volatilidad de los precios de los commodities, aportando un marco teórico y metodológico sólido para la predicción y gestión de la cadena de suministro.

3.1.3. Códigos y Nomenclaturas UNESCO

- 1206. Análisis Numérico
 - 120603. Análisis de Errores
- 1208. Probabilidad
 - 120808. Procesos estocásticos
- 1209. Estadística
 - 120903. Análisis de Datos
- 2205. Mecánica
 - 220501. Mecánica Analítica
- 2507. Geofísica
 - 250705. Sismología y Prospección Sísmica.
- 6307. Cambio y Desarrollo Social
 - 630706. Desarrollo Socioeconómico
 - 630707. Tecnología y cambio social.
- 7201. Filosofía del conocimiento
 - 720105. Teoría de la Percepción

3.1.4. Diseño de la Investigación

El diseño de investigación constituye la estructura metodológica que orienta el proceso de recolección, análisis e interpretación de los datos. En este estudio, el diseño se clasifica como no experimental, transversal y de enfoque correlacional-explicativo, en concordancia con la naturaleza del problema y los objetivos planteados. De acuerdo con Hernández, Fernández y Baptista (2014), un diseño no experimental se caracteriza porque el investigador no manipula deliberadamente las variables independientes, sino que observa los fenómenos tal como se presentan en su contexto natural. En esta investigación, los precios de los commodities (níquel,

cobre, acero) y los indicadores financieros internacionales (Dow Jones, LME, tipo de cambio) se analizan a partir de datos históricos, sin intervención ni alteración por parte del investigador.

El diseño es además transversal, dado que se centra en un periodo definido (2018–2023), en el que se recogen y analizan las series de tiempo de los commodities. Este enfoque permite observar el comportamiento de las variables en dicho intervalo, identificando patrones caóticos y no lineales, pero sin extender el análisis a otras temporalidades fuera del rango establecido. Asimismo, el diseño es de enfoque correlacional-explicativo, en la medida en que busca establecer relaciones entre los precios de los commodities y las variables financieras internacionales, para luego explicar cómo dichas relaciones se manifiestan bajo dinámicas no lineales y caóticas.

3.2. Población y Muestra

En la metodología de investigación, la población hace referencia al conjunto total de elementos o unidades de análisis sobre los cuales se pretende generalizar los resultados, mientras que la muestra constituye el subconjunto representativo que será objeto de estudio. En este caso, la investigación se orienta al análisis de series de tiempo de precios internacionales de commodities estratégicos, fundamentales para la industria de electrodos en el Perú.

3.2.1. Población

La población está conformada por todas las series históricas de precios internacionales de commodities metálicos que son relevantes en la industria de insumos industriales y de manufactura avanzada. Esto incluye los precios publicados oficialmente en bolsas internacionales de referencia, como la London Metal Exchange (LME) y otros índices financieros globales.

En términos específicos, la población de estudio considera los precios históricos de: Níquel, Cobre y Acero. Estos commodities han sido seleccionados debido a su rol estratégico en la producción industrial y su fuerte impacto en la cadena de suministro, en particular en la fabricación de electrodos metálicos.

3.2.2. *Tamaño de la Muestra*

El tamaño de la muestra en esta investigación se determina en función de la naturaleza de los datos analizados, dado que se trabaja con series de tiempo históricas y no con encuestas poblacionales. En este caso, la muestra está compuesta por las observaciones periódicas de los precios internacionales de los commodities estratégicos seleccionados: níquel, cobre y acero.

Para garantizar la validez estadística y la representatividad de los resultados, se seleccionó un horizonte temporal de seis años (2018–2023), lo cual proporciona una base suficiente para aplicar modelos de predicción lineales y no lineales.

- Frecuencia de los datos: mensual.
- Número de observaciones por commodity: aproximadamente 72 registros (12 meses $\times$ 6 años).
- Total de observaciones: considerando tres commodities (níquel, cobre y acero), la muestra asciende a alrededor de 216 datos procesados.

Justificación del tamaño de la muestra

- ⇒ **Suficiencia estadística:** de acuerdo con Box y Jenkins (1970), un mínimo de 50 observaciones es recomendable para ajustar modelos ARIMA y validar su estacionariedad. En este estudio, cada serie supera ampliamente este requisito.
- ⇒ **Representatividad temporal:** el periodo 2018–2023 incluye eventos críticos que alteraron significativamente la dinámica de los precios (pandemia del COVID-19,

conflictos geopolíticos y cambios en la demanda global), lo cual permite observar la transición de estados estables a comportamientos caóticos.

⇒ **Comparabilidad:** el mismo rango temporal para los tres commodities asegura la posibilidad de análisis comparativo, fortaleciendo la validez de los resultados.

El tamaño de la muestra está constituido por 72 observaciones para cada commodity (2018–2023), lo que equivale a 216 registros en total. Este tamaño es estadísticamente robusto, metodológicamente adecuado y representativo para aplicar modelos de series temporales y dinámicas caóticas en el análisis de precios internacionales de commodities.

3.2.3. *Muestreo*

El muestreo es el procedimiento utilizado para seleccionar el subconjunto de datos que conforman la muestra de estudio. En esta investigación, el muestreo no responde a criterios probabilísticos clásicos, ya que no se trabaja con individuos o poblaciones humanas, sino con series de tiempo de precios internacionales de commodities. Por ello, el muestreo es de carácter intencional o no probabilístico, fundamentado en criterios de pertinencia y relevancia para el problema planteado.

Tipo de muestreo

⇒ **Muestreo no probabilístico – intencional:** Se seleccionaron deliberadamente los commodities (níquel, cobre y acero) y el periodo de análisis (2018–2023) debido a su relevancia en la industria de electrodos y a la disponibilidad de datos históricos consistentes y verificables en fuentes oficiales.

Criterios de selección

- **Relevancia estratégica:** los commodities elegidos son insumos críticos en la producción industrial y en particular en la manufactura de electrodos, lo que los

convierte en variables esenciales para evaluar la volatilidad en la cadena de suministro.

- **Disponibilidad de datos:** se priorizaron las series con registros continuos, consistentes y publicados en organismos internacionales reconocidos como la London Metal Exchange (LME), además de índices financieros como el Dow Jones y el tipo de cambio oficial.
- **Horizonte temporal significativo:** el periodo 2018–2023 fue seleccionado porque incluye eventos disruptivos (pandemia COVID-19, crisis de oferta mundial, tensiones geopolíticas) que permiten observar tanto fases de estabilidad como dinámicas caóticas.
- **Comparabilidad:** los tres commodities analizados comparten un mismo marco temporal, lo que facilita la comparación de resultados entre mercados con diferentes estructuras de formación de precios.

El uso de un muestreo intencional garantiza que la información seleccionada sea representativa del fenómeno económico en estudio, incluso sin recurrir a técnicas probabilísticas. La inclusión de commodities estratégicos y un periodo crítico de seis años asegura la pertinencia de los datos para aplicar modelos lineales (ARIMA) y no lineales (regresión simbólica, dinámica caótica), en concordancia con los objetivos de la investigación.

El muestreo es no probabilístico e intencional, basado en criterios de relevancia estratégica, disponibilidad de datos y comparabilidad temporal. Esta estrategia metodológica asegura la pertinencia de la muestra y su adecuación para explicar la dinámica caótica de los precios de commodities y su impacto en la gestión de la cadena de suministro.

3.3. Operacionalización de Variables

La operacionalización de variables constituye el proceso mediante el cual los conceptos teóricos definidos en la investigación se traducen en términos observables, medibles y analizables. Este procedimiento permite establecer indicadores y dimensiones concretas que facilitan la validación empírica de los objetivos planteados, garantizando coherencia metodológica y consistencia en la prueba de hipótesis.

En el presente estudio, la operacionalización de variables se orienta a analizar el comportamiento caótico de los precios internacionales de los commodities estratégicos (níquel, cobre y acero), mediante la aplicación de modelos lineales (ARIMA) y no lineales (regresión simbólica, teoría del caos y bifurcaciones).

3.3.1. Estrategia de Prueba de Hipótesis

Las pruebas de hipótesis se plantean con la finalidad de contrastar los resultados de los modelos estadísticos y determinar si existe una diferencia significativa entre el comportamiento de los commodities bajo supuestos lineales y no lineales. Para ello, se emplean contrastes de dos colas y una cola, según se evalúe si las medias de población son distintas, mayores o menores entre sí.

$$H_0: \mu_1 = \mu_2 \quad (2.35)$$

$$H_1: \mu_1 < \mu_2; H_1: \mu_1 > \mu_2; H_1: \mu_1 \neq \mu_2 \quad (2.36)$$

donde:

- H_0 : Hipótesis nula.
- H_1 : Hipótesis alternativa.
- μ_1 : media de los resultados obtenidos bajo modelos lineales.
- μ_2 : media de los resultados obtenidos bajo modelos no lineales.

3.3.2. *Procedimiento para demostrar la hipótesis nula*

El procedimiento para la contrastación de hipótesis en esta investigación se fundamenta en métodos estadísticos aplicados a series temporales, tanto bajo modelos lineales como no lineales. El objetivo es establecer si existen diferencias significativas entre los resultados obtenidos con distintos enfoques de modelado (ARIMA, regresión simbólica, ecuaciones caóticas) y, por ende, validar o rechazar las hipótesis planteadas.

El proceso se desarrolla en diez pasos secuenciales:

⇒ *Plantear la hipótesis nula (H_0)*. Se establece que no existe diferencia significativa entre las medias de los resultados de los modelos comparados.

$$H_0: \mu_1 = \mu_2 \quad (2.37)$$

⇒ *Plantear la hipótesis alternativa (H_1)*. Dependiendo del objetivo específico, se formula si existe diferencia significativa o si una media supera a la otra.

$$H_1: \mu_1 < \mu_2; H_1: \mu_1 > \mu_2; H_1: \mu_1 \neq \mu_2 \quad (2.38)$$

⇒ *Especificar el nivel de significancia (α)*. Para este estudio, se define $\alpha = 0.05$, nivel aceptado en investigaciones científicas.

⇒ *Definir la muestra*. Se consideran las series temporales de precios mensuales de níquel, cobre y acero entre 2018–2023, con un total de 72 observaciones por commodity.

⇒ *Establecer los valores críticos*. Se determinan a partir de la distribución *t* de Student o ANOVA, según el contraste realizado.

⇒ *Seleccionar la prueba estadística*. Dependiendo del objetivo, se aplican pruebas de dos colas o de una cola para comparar medias o errores de predicción. El estadístico básico de contraste es:

$$t = \frac{\bar{X}_1 - \bar{X}_2}{S_{\bar{X}_1 - \bar{X}_2}} \quad (2.39)$$

donde:

- $\bar{X}_1, \bar{X}_2$: medias de los resultados en los modelos.
- $S_{\bar{X}_1 - \bar{X}_2}$: error estándar de la diferencia de medias.

⇒ *Almacenar y procesar los datos.* Los precios y resultados de modelos se sistematizan en software especializado (Python, R, EViews).

⇒ *Formular la regla de decisión.*

- Si $|t_{\text{calc}}| > t_{\text{crit}} \rightarrow$ se rechaza H_0 .
- Si $|t_{\text{calc}}| \leq t_{\text{crit}} \rightarrow$ no se rechaza H_0 .

⇒ *Emitir la decisión estadística.* Se establece formalmente la aceptación o rechazo de la hipótesis nula.

⇒ *Interpretar los resultados.* Finalmente, se expresan los hallazgos en términos de los problemas de investigación: si los modelos no lineales (SR, caos) aportan mejoras significativas frente a los lineales (ARIMA) en la predicción de precios de commodities.

Este procedimiento asegura que la prueba de hipótesis se ejecute de manera sistemática, garantizando que las decisiones estadísticas estén respaldadas por evidencia cuantitativa y no por apreciaciones subjetivas.

3.3.3. Variables e Indicadores

La definición de variables e indicadores constituye un paso esencial en la operacionalización de los objetivos de la investigación. A partir del planteamiento general y específico, se identifican las **variables independientes** (dinámica caótica, ecuaciones no

lineales, modelos de predicción) y las **variables dependientes** (gestión de la cadena de suministro, eficiencia de aprovisionamiento, resiliencia empresarial), las cuales son traducidas en indicadores observables, medibles y analizables.

Objetivo General

Analizar en qué medida la dinámica caótica y las ecuaciones no lineales, aplicadas al comportamiento de índices internacionales, influyen en la gestión de la cadena de suministro de commodities importados en la industria de electrodos en el Perú durante el periodo 2018–2023.

- **Variable Independiente:** Dinámica caótica y ecuaciones no lineales.
 - **Indicadores:**
 - Exponentes de Lyapunov (λ).
 - Dimensión fractal de los precios.
 - Presencia de atractores extraños en las series.
- **Variable Dependiente:** Gestión de la cadena de suministro de commodities importados.
 - **Indicadores:**
 - Costos de aprovisionamiento.
 - Nivel de stock crítico en la industria de electrodos.
 - Índice de resiliencia frente a la volatilidad de precios.

Objetivo Específico 1

Examinar la relación entre la dinámica no lineal y los índices internacionales (Dow Jones y LME), identificando su incidencia en la formación de precios de los commodities estratégicos empleados en la industria de electrodos.

- **Variable Independiente:** Dinámica no lineal en índices internacionales.
 - **Indicadores:**
 - Volatilidad mensual de los índices Dow Jones y LME.
 - Presencia de bifurcaciones en series de tiempo.
 - Simulación de ecuaciones logísticas (Verhulst).
- **Variable Dependiente:** Formación de precios de commodities estratégicos.
 - **Indicadores:**
 - Fluctuaciones mensuales de precios (níquel, cobre, acero).
 - Tendencias y ciclos en la serie histórica.
 - Grado de correlación entre índices internacionales y precios de commodities.

Objetivo Específico 2

Aplicar herramientas estadísticas y matemáticas avanzadas, como los modelos de Box y Jenkins y la regresión simbólica, para anticipar escenarios de volatilidad en la cadena de suministro de insumos críticos.

- **Variable Independiente:** Herramientas estadísticas y matemáticas aplicadas.
 - **Indicadores:**
 - Parámetros AR, MA y ARIMA(p,d,q).
 - Ecuaciones obtenidas por regresión simbólica (SR).

- RMSE de los modelos comparados.
- **Variable Dependiente:** Anticipación de escenarios de volatilidad.
 - **Indicadores:**
 - Errores de predicción de precios.
 - Escenarios de alta/baja volatilidad identificados.
 - Sensibilidad del modelo frente a cambios en condiciones iniciales.

Objetivo Específico 3

Diseñar indicadores de gestión (KPI) fundamentados en enfoques no lineales, que permitan evaluar la eficiencia del aprovisionamiento y optimizar los procesos de compra en la industria de electrodos.

- **Variable Independiente:** Enfoques no lineales aplicados al diseño de KPI.
 - **Indicadores:**
 - Índice Commodity Channel Index (CCI).
 - Indicadores caóticos aplicados al proceso de compras.
 - Medición de ciclos caóticos en aprovisionamiento.
- **Variable Dependiente:** Eficiencia del aprovisionamiento.
 - **Indicadores:**
 - Tiempo promedio de reposición de insumos.
 - Nivel de cumplimiento de pedidos críticos.
 - Costos de almacenamiento asociados al stock.

Objetivo Específico 4

Determinar el impacto de la aplicación de la dinámica caótica y las ecuaciones no lineales en la toma de decisiones estratégicas relacionadas con los tiempos de compra, niveles de stock y resiliencia empresarial frente a la volatilidad internacional.

- **Variable Independiente:** Aplicación de dinámica caótica y ecuaciones no lineales en decisiones estratégicas.
 - **Indicadores:**
 - Modelos predictivos aplicados (Verhulst, bifurcaciones, SR).
 - Nivel de confiabilidad de pronósticos generados.
 - Grado de sensibilidad a perturbaciones externas.
- **Variable Dependiente:** Toma de decisiones estratégicas en la cadena de suministro.
 - **Indicadores:**
 - Tiempos óptimos de compra.
 - Niveles de stock de seguridad.
 - Resiliencia empresarial frente a choques externos.

Tabla 1. Variables e Indicadores – Operacionalización de Variables

Hipótesis	Variable	Indicadores	Descripción	Dimensión	Tipo de Función	Escala	Nivel
H1	Dinámica caótica y ecuaciones no lineales	Exponente de Lyapunov (λ)	Medida del grado de sensibilidad a condiciones iniciales en series caóticas	Complejidad dinámica	Independiente	Intervalo	Avanzado
		Dimensión fractal	Medición de la estructura geométrica de los atractores en el comportamiento de precios	Estructura del caos	Independiente	Intervalo	Avanzado
		Atractores extraños	Identificación de patrones caóticos en índices financieros	Sistemas dinámicos	Independiente	Nominal	Avanzado
H2	Índices internacionales (Dow Jones, LME)	Volatilidad mensual (%)	Variación relativa de los índices bursátiles y de metales	Variabilidad	Independiente	Ratio	Básico
		Correlación índices–commodities	Relación estadística entre Dow Jones/LME y precios del níquel, cobre y acero	Incidencia en precios	Dependiente	Intervalo	Avanzado
	Formación de precios de commodities	Tendencias y ciclos	Análisis de estacionalidad y ciclos en los precios internacionales	Serie temporal	Dependiente	Ordinal	Básico
H3	Modelos estadísticos aplicados	Parámetros AR, MA y ARIMA (p,d,q)	Componentes autorregresivos y de medias móviles en predicciones lineales	Modelado lineal	Independiente	Nominal	Básico
		Regresión simbólica (SR)	Ecuaciones generadas automáticamente para capturar relaciones no lineales	Modelado no lineal	Independiente	Intervalo	Avanzado
		Error cuadrático medio (RMSE)	Precisión de las predicciones en commodities estratégicos	Validación del modelo	Dependiente	Ratio	Avanzado
H4	Indicadores de gestión (KPI no lineales)	Commodity Channel Index (CCI)	Indicador derivado de la dinámica de precios para aprovisionamiento	Gestión de compras	Independiente	Intervalo	Avanzado
		Nivel de cumplimiento de pedidos	Proporción de insumos entregados en tiempo	Eficiencia operativa	Dependiente	Ratio	Básico
		Costos de almacenamiento	Gastos asociados al mantenimiento de stock de seguridad	Logística	Dependiente	Intervalo	Avanzado
H5	Decisiones estratégicas en la cadena de suministro	Tiempo óptimo de compra	Determinación del momento adecuado de adquisición	Planificación	Dependiente	Ratio	Avanzado
		Niveles de stock de seguridad	Cantidad mínima requerida para evitar desabastecimientos	Inventario	Dependiente	Ratio	Básico
		Resiliencia empresarial	Capacidad de respuesta ante choques externos internacionales	Estrategia organizacional	Dependiente	Ordinal	Avanzado

3.4. Instrumentos

3.4.1. *Técnicas de Procesamiento de Datos*

El procesamiento de datos en esta investigación se orienta a transformar los registros históricos de precios de commodities y los índices internacionales en información útil y contrastable mediante herramientas estadísticas y matemáticas avanzadas. Para tal fin, se aplicaron técnicas que permiten trabajar con series de tiempo lineales y no lineales, asegurando la validez y confiabilidad de los resultados obtenidos.

Las principales técnicas utilizadas fueron:

a) **Depuración y normalización de datos**

- Se verificó la consistencia de las series de precios internacionales (níquel, cobre y acero) y de los índices financieros (Dow Jones y LME).
- Se aplicaron procedimientos de detección y tratamiento de valores atípicos y de ajuste por estacionalidad, con el fin de garantizar series limpias y homogéneas.

b) **Transformación de series temporales**

- Las series fueron diferenciadas y estandarizadas para cumplir con los supuestos de estacionariedad requeridos por los modelos lineales (Box-Jenkins – ARIMA).
- En los modelos no lineales, se aplicaron técnicas de reconstrucción de espacio de fases y estimación de parámetros caóticos como exponentes de Lyapunov y dimensiones fractales.

c) **Modelado estadístico**

- Modelos lineales ARIMA (p,d,q): aplicados a las series de precios de commodities para capturar sus componentes autorregresivos y de medias móviles.
- Regresión simbólica (SR): empleada para identificar relaciones no lineales en el comportamiento de los precios y generar ecuaciones predictivas automáticas.
- Ecuaciones caóticas (Verhulst, bifurcación): utilizadas para modelar escenarios inestables y sensibles a condiciones iniciales, propios de los mercados de commodities.

d) Validación y comparación de modelos

- Se utilizaron criterios estadísticos de bondad de ajuste, como el criterio de Akaike (AIC), el criterio bayesiano de Schwarz (BIC) y el estadístico Durbin-Watson, con el fin de validar la calidad de los modelos lineales.
- En los modelos no lineales, se evaluó la robustez a partir del Error Cuadrático Medio (RMSE) y de la capacidad predictiva en escenarios de volatilidad.

e) Análisis aplicado a la cadena de suministro

- Los resultados de los modelos fueron vinculados con indicadores de gestión (KPI), tales como costos de aprovisionamiento, niveles de stock de seguridad y tiempos óptimos de compra, permitiendo traducir el análisis matemático en implicancias prácticas para la industria de electrodos en el Perú.

Las técnicas de procesamiento de datos permitieron transformar la información histórica en evidencia empírica robusta, integrando enfoques lineales y no lineales, y asegurando que las hipótesis planteadas pudieran ser probadas con rigor científico.

3.4.2. Técnicas de Análisis e Interpretación de la Información

El análisis e interpretación de la información se realizaron mediante el uso de técnicas estadísticas y matemáticas avanzadas, orientadas a evaluar el comportamiento de los precios internacionales de commodities estratégicos y su impacto en la cadena de suministro de la industria de electrodos.

Las principales técnicas fueron:

a) Análisis descriptivo y exploratorio

- Se efectuó un análisis preliminar de las series temporales, identificando tendencias, estacionalidad, volatilidad y presencia de valores atípicos.
- Se aplicaron medidas de tendencia central y dispersión (media, desviación estándar, coeficiente de variación) para caracterizar la dinámica de los precios.

b) Modelado lineal de series de tiempo

- Se emplearon modelos ARIMA (p,d,q) de Box-Jenkins, con la finalidad de explicar y proyectar el comportamiento lineal de las series.
- La validez de estos modelos se verificó mediante los criterios AIC, BIC y el estadístico Durbin-Watson.

c) Modelado no lineal y caótico

- Se aplicó la regresión simbólica (SR) para generar ecuaciones predictivas no paramétricas.
- Se utilizaron ecuaciones caóticas (Verhulst, bifurcación) para capturar la sensibilidad a condiciones iniciales y explicar fenómenos de inestabilidad.
- Se estimaron exponentes de Lyapunov y dimensiones fractales para validar la presencia de caos determinista en las series.

d) Análisis comparativo de modelos

- Se comparó el desempeño de modelos lineales y no lineales utilizando el Error Cuadrático Medio (RMSE) y la capacidad de anticipar escenarios de volatilidad.
- Los resultados fueron vinculados con indicadores de gestión (KPI) como costos de aprovisionamiento, tiempos de compra y resiliencia empresarial.

e) Interpretación aplicada a la gestión

- Los hallazgos matemáticos y estadísticos fueron traducidos en implicancias prácticas para la industria de electrodos, vinculando los patrones caóticos y no lineales con la toma de decisiones estratégicas.

3.4.3. Instrumentos de Recolección de Datos

Para la obtención de datos confiables y pertinentes, se emplearon instrumentos orientados a recopilar series históricas de precios y registros financieros oficiales.

a) Bases de datos internacionales:

- London Metal Exchange (LME): precios internacionales de metales (níquel, cobre, acero).
- Dow Jones Index: información bursátil utilizada como indicador internacional de volatilidad.
- Bases económicas globales (Banco Mundial, FMI): datos macroeconómicos de contexto.

b) Registros nacionales:

- Importaciones de commodities estratégicos en el sector industrial peruano, obtenidas de SUNAT y Ministerio de la Producción.

c) Instrumentos digitales y software de sistematización:

- Python y R: para la depuración de datos, aplicación de modelos lineales y no lineales, y cálculo de parámetros caóticos.
- EViews y Matlab: para contrastes estadísticos avanzados y simulación de escenarios caóticos.
- Excel: para la organización preliminar y tabulación de datos.

Estos instrumentos garantizaron la validez, confiabilidad y replicabilidad del proceso de recolección.

3.4.4. Validación de los Instrumentos

La validación de los instrumentos se efectuó mediante procedimientos de juicio de expertos y de consistencia estadística:

a) Juicio de expertos:

- Se convocó a especialistas en economía aplicada, ingeniería industrial y estadística para evaluar la pertinencia de los instrumentos de recolección y análisis.
- Los expertos verificaron la coherencia de los indicadores con las variables definidas en la operacionalización.

b) Validación estadística:

- En los modelos lineales, se aplicaron pruebas de estacionariedad (ADF, KPSS) y autocorrelación de residuos.
- En los modelos no lineales, la validación incluyó la comparación entre resultados empíricos y simulaciones matemáticas, además del cálculo del

RMSE y la replicabilidad de ecuaciones obtenidas mediante regresión simbólica.

c) Criterios de aceptación:

- Los instrumentos fueron validados al confirmar que cumplían con los estándares de validez de contenido (adecuación al fenómeno), validez de constructo (representación de las variables) y validez predictiva (capacidad de anticipar escenarios de volatilidad).

3.5. Análisis de Datos

El análisis de datos constituye una de las fases críticas de la investigación, pues permite transformar la información recolectada en evidencia empírica contrastable que facilita la verificación de las hipótesis planteadas. En este estudio, el análisis de datos se estructuró en tres niveles: descriptivo, inferencial y aplicado, con el propósito de vincular los resultados estadísticos con la gestión de la cadena de suministro en la industria de electrodos.

a) Análisis descriptivo

- Se procesaron las series temporales de precios internacionales de commodities (níquel, cobre y acero) correspondientes al periodo 2018–2023, identificando tendencias, ciclos y estacionalidad.
- Se calcularon medidas de tendencia central (media, mediana), dispersión (desviación estándar, varianza) y volatilidad relativa (coeficiente de variación).
- Se emplearon representaciones gráficas (líneas de tiempo, histogramas y diagramas de dispersión) para ilustrar la dinámica de los precios y su relación con índices internacionales (Dow Jones y LME).

b) Análisis inferencial y modelado

- Modelos lineales: se aplicaron modelos ARIMA (p,d,q) para proyectar el comportamiento lineal de los precios, verificando la estacionariedad mediante pruebas de raíz unitaria (ADF, KPSS) y validando los residuos con Durbin-Watson.
- Modelos no lineales: se utilizó regresión simbólica (SR) para generar ecuaciones predictivas no paramétricas, y ecuaciones caóticas (Verhulst, bifurcaciones) para simular escenarios de sensibilidad a condiciones iniciales.
- Se calcularon indicadores de ajuste y predicción como el RMSE (Root Mean Square Error), el AIC (Akaike Information Criterion) y el BIC (Bayesian Information Criterion).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.40)$$

$$AIC = -2\ln(L) + 2k \quad (2.41)$$

$$BIC = -2\ln(L) + k\ln(n) \quad (2.42)$$

donde L es la verosimilitud del modelo, k el número de parámetros y n el tamaño de la muestra.

c) Análisis comparativo y aplicado

- Se compararon los resultados obtenidos en modelos lineales y no lineales, evaluando su desempeño predictivo bajo escenarios de alta volatilidad internacional.
- Se integraron los hallazgos con indicadores de gestión (KPI) de la industria de electrodos, tales como:

- Costos de aprovisionamiento → variación mensual atribuible a fluctuaciones internacionales.
 - Tiempos de compra y reposición → calculados en función de los pronósticos de precios.
 - Niveles de stock de seguridad → ajustados con base en escenarios de volatilidad extrema.
- Se aplicó un enfoque comparativo entre commodities (níquel, cobre, acero) para identificar cuál de ellos presenta mayor sensibilidad caótica y, en consecuencia, mayor riesgo en la cadena de suministro.

d) Interpretación de resultados

- Los hallazgos fueron interpretados en función de las hipótesis de investigación, determinando si la dinámica caótica y las ecuaciones no lineales influyen significativamente en la gestión de la cadena de suministro.
- Se establecieron implicancias prácticas para la resiliencia empresarial, identificando estrategias óptimas de aprovisionamiento en contextos de alta volatilidad y dependencia de mercados internacionales.

El análisis de datos integró métodos descriptivos, inferenciales y aplicados, garantizando que los resultados no solo fueran estadísticamente válidos, sino también útiles para la toma de decisiones estratégicas en la industria de electrodos.

3.6. Consideraciones Éticas

La presente investigación se llevó a cabo respetando los principios éticos fundamentales de la investigación científica, garantizando la transparencia en el manejo de la información, la objetividad en el análisis y la veracidad en la presentación de los resultados.

a) Transparencia en el uso de datos

- Los datos utilizados provienen de fuentes oficiales y reconocidas a nivel internacional, tales como la London Metal Exchange (LME), el Dow Jones Index, así como reportes macroeconómicos del Banco Mundial y el Fondo Monetario Internacional (FMI).
- Se asegura que los registros históricos de precios de commodities (níquel, cobre y acero) son de acceso público y no vulneran derechos de propiedad privada ni confidencialidad empresarial.

b) Integridad académica

- Todas las referencias teóricas, metodológicas y estadísticas empleadas han sido debidamente citadas conforme a las normas de estilo académico (APA 7.^a edición), evitando cualquier forma de plagio.
- Se ha procurado mantener la fidelidad en la interpretación de los autores, sin tergiversar los resultados ni las propuestas metodológicas.

c) Objetividad y neutralidad

- El análisis se realizó con absoluta independencia, sin influencia de intereses externos que puedan condicionar los resultados.
- La comparación de modelos lineales y no lineales se efectuó aplicando los mismos criterios de validez, garantizando imparcialidad en la selección del modelo más adecuado.

d) Responsabilidad social y científica

- La investigación reconoce que sus resultados tienen implicancias directas en la industria de electrodos en el Perú, al proponer estrategias de gestión de la cadena de suministro frente a la volatilidad internacional.
- Se asume el compromiso de que los hallazgos puedan servir como base para futuras investigaciones y como apoyo a la toma de decisiones en sectores productivos estratégicos.

e) Confidencialidad y uso responsable de la información

- Aunque la investigación se basa en fuentes públicas, los datos procesados y resultados obtenidos se utilizarán exclusivamente con fines académicos y científicos.
- No se hará uso indebido de la información para fines comerciales, asegurando su difusión únicamente en entornos académicos y especializados.

Este estudio se desarrolla bajo los principios de honestidad, transparencia, imparcialidad y responsabilidad social, garantizando la validez ética y científica de la investigación.

IV. RESULTADOS

4.1. Análisis descriptivo de los commodities críticos

El análisis de los commodities críticos constituye un eje fundamental en la investigación, ya que son la base material sobre la cual se desarrolla el proceso de fabricación de electrodos. Estos insumos, al estar sujetos a la volatilidad internacional y a la dependencia de proveedores externos, impactan de manera directa en los costos de producción, la estabilidad de la cadena de suministro y la capacidad de respuesta de la industria frente a escenarios de incertidumbre global.


El suministro de commodities se clasifica en dos grandes grupos:

- **Commodities importados**, que agrupan a los minerales metálicos y no metálicos en polvo, alambres de acero inoxidable, ferroaleaciones, óxidos, carbonatos, aglomerantes y materiales orgánicos (incluida la celulosa). Este grupo representa aproximadamente entre el 65% y el 78% del volumen total empleado en la fabricación, lo que revela una fuerte dependencia de insumos externos. Dentro de este segmento, el 40% corresponde a alambres inoxidables, mientras que el 60% se compone de minerales metálicos y no metálicos en polvo, presentados en forma sólida o líquida, cuya cotización está determinada por las principales bolsas internacionales, como el London Metal Exchange (LME) y la Bolsa de Nueva York (NYSE).
- **Commodities nacionales**, que comprenden principalmente minerales no metálicos de segunda calidad, además de materiales auxiliares, energía y combustibles. Su participación es relativamente menor, abarcando entre el 22% y el 35% del volumen total, pero su aporte es relevante en términos de estabilidad, al estar menos expuestos a la volatilidad internacional (Mentzer et al. 2001; Sodhi, 2012; Ponomarov, & Holcomb, 2009; Sheffi, 2005).

La Figura 2 ilustra el esquema logístico de entradas y salidas, donde se aprecia el flujo desde la generación de un requerimiento hasta la adquisición final. Este proceso no solo involucra la compra de insumos, sino también la gestión de información, control de calidad, transporte y validación de proveedores, lo que resalta la importancia de un sistema logístico robusto para garantizar la continuidad del abastecimiento.

Figura 2.

Organigrama de adquisiciones empresarial para industria fabril de electrodos



Fuente: desarrollo propio

Asimismo, la Figura 2 presenta la distribución de costos y peso en volumen de los insumos, permitiendo visualizar cómo los commodities importados dominan en el costo total, mientras que los nacionales aportan estabilidad relativa en la estructura de producción. Este desglose sirve como base de referencia para comprender la incidencia diferenciada de cada insumo en la cadena de valor (Tang, 2006; Christopher & Peck, 2004; Ivanov, 2020).

Finalmente, cabe destacar que la investigación toma como referencia las bases informativas históricas de la Federal Reserve de los Estados Unidos (FED), en especial desde 1913, utilizando como índice bursátil representativo al Dow Jones Industrial Average (DJIA).

Dicho índice, considerado el más importante a nivel global, sirve de referencia para gran parte de los mercados internacionales y se utiliza como parámetro en la fijación de precios de metales y commodities en general.

Tabla 2

Distribución en peso y costo de fabricar de un electrodo especial de soldadura - Bach de 40,000 kg

Electrodo (Welding)	Weight %	Price %	Origin
Núcleo (Stainless steel wire)	55	35.0	Imp
Revestimiento (Minerals Powder)	35.0	38.1	Imp
Aglomerantes (Liquid binders)	8.0	6.0	Nac
MO y HM (Direct - Indirect labor)	-	0.9	Nac
Gastos de Fabrica (Factory Expenses & Depreciation)	—	12.0	Nac
Accessories (packaging)	2.0	8.0	Nac

Fuente: Elaboración propia

En conclusión, el análisis descriptivo de los commodities críticos permite establecer un marco de referencia sólido para comprender la dinámica de la cadena de suministro, diferenciando claramente la dependencia internacional de insumos estratégicos y el papel estabilizador de los recursos nacionales, lo que a su vez justifica el empleo de modelos lineales y no lineales para anticipar escenarios de volatilidad en la industria de electrodos.

4.1.1. Clasificación de commodities importados y nacionales

En el contexto de la industria peruana de electrodos, los commodities representan insumos estratégicos que, por su carácter de materias primas estandarizadas y de alta demanda internacional, constituyen la base del proceso de fabricación. Estos materiales, al carecer de diferenciación significativa en el mercado, se cotizan principalmente en bolsas internacionales como la London Metal Exchange (LME) o a través de índices de referencia como el Dow Jones

Industrial Average (DJIA), lo que los convierte en elementos altamente sensibles a fenómenos económicos, geopolíticos y sociales (Deming, 1986; Juran, 1999; Slack et al., 2010).

La clasificación de los commodities utilizados en la fabricación de electrodos se estructura en dos grandes grupos: importados y nacionales, los cuales presentan características diferenciadas en cuanto a disponibilidad, costo, volatilidad y aporte dentro de la cadena de valor.

a) Commodities importados

Los insumos importados constituyen el núcleo crítico de la producción de electrodos en el Perú, dado que su disponibilidad depende de mercados internacionales sujetos a alta volatilidad (Garvin, 1988; Porter, 1985; Crosby, 1980; Imai, 1997). Entre los principales destacan:

- *Acero inoxidable (alambres y varillas)*: Representa el insumo más significativo en términos de volumen y costo. Su precio depende directamente de los mercados internacionales del níquel y el cromo, componentes esenciales en su aleación. La dependencia de proveedores externos genera una elevada exposición al riesgo cambiario y a variaciones de precios globales.
- *Níquel (Ni)*: Elemento fundamental para mejorar la resistencia a la corrosión y la durabilidad de los electrodos. Se cotiza en la LME y es considerado uno de los metales más volátiles, debido a que su oferta está concentrada en pocos países (Indonesia, Filipinas, Rusia).
- *Cobre (Cu)*: Utilizado como componente conductor en determinados tipos de electrodos especiales. Su precio internacional responde tanto a la dinámica industrial (electrificación, construcción) como a la especulación financiera en mercados bursátiles.

- *Ferroaleaciones (Fe-Si, Fe-Cr, Fe-Mn)*: Empleadas como elementos de aleación y refuerzo, su variación de precios se vincula con la industria siderúrgica global. La volatilidad de estas ferroaleaciones impacta directamente en los costos de producción.

Estos commodities presentan una alta correlación con la dinámica bursátil internacional y son los principales generadores de incertidumbre en la gestión de la cadena de suministro, al representar más del 70% del costo de aprovisionamiento en la industria de electrodos.

b) Commodities nacionales

A nivel nacional, también se dispone de insumos que complementan la producción, aunque en menor escala y con un nivel de volatilidad reducido en comparación con los importados. Entre ellos destacan:

- *Minerales no metálicos (Na, K, Ca)*: Provenientes principalmente de la minería no metálica peruana, son empleados como componentes en los revestimientos de electrodos. Su disponibilidad local asegura estabilidad relativa en el suministro, aunque su precio se ve afectado por los costos logísticos internos.
- *Aluminio secundario (reciclado)*: Utilizado en mezclas específicas, proviene del reaprovechamiento de chatarra y residuos industriales. Su inclusión en la clasificación nacional responde a la tendencia de economía circular y a la reducción de dependencia de mercados internacionales.
- *Carbones y grafitos naturales*: En menor medida, el Perú dispone de reservas de carbón metalúrgico y grafito, utilizados en procesos auxiliares de la fabricación. Si bien no constituyen el insumo central, su aporte permite reducir parcialmente la importación de materiales equivalentes.

c) Relevancia estratégica de la clasificación

La distinción entre commodities importados y nacionales resulta clave para la gestión de la cadena de suministro, debido a que:

- Los importados concentran el mayor riesgo financiero y logístico, al estar sujetos a la volatilidad internacional y a la dependencia de proveedores externos.
- Los nacionales, aunque de menor impacto en el costo total, otorgan estabilidad relativa y constituyen una oportunidad para fortalecer la autosuficiencia productiva y reducir la exposición a choques externos.
- El análisis comparativo permite establecer estrategias diferenciadas:
 - Para importados: gestión de riesgos financieros, coberturas cambiarias, pronósticos no lineales.
 - Para nacionales: fomento de cadenas de valor locales y políticas de abastecimiento sostenible.

Con este análisis, se establece la base para el estudio de volatilidad y predicción de precios en los apartados siguientes, justificando el uso de modelos lineales (ARIMA) y no lineales (caóticos y regresión simbólica) en función de la sensibilidad y peso relativo de cada grupo de commodities.

4.1.2. Distribución porcentual de peso y costo en la fabricación de electrodos

El análisis de la estructura de costos y peso relativo de los insumos en la fabricación de electrodos permite identificar cuáles son los commodities más críticos para la gestión de la cadena de suministro. La distribución porcentual refleja no solo el aporte de cada insumo al producto final, sino también la magnitud del riesgo asociado a su volatilidad en el mercado como lo mencionan (Deming, 1986; Juran, 1999; Slack et al., 2010).

Los resultados se presentan en dos dimensiones: peso físico en la composición del electrodo y participación económica en el costo total de producción.

Tabla 3

Distribución porcentual por peso en la composición de un electrodo típico

Categoría	Commodity principal	Origen	% en peso aproximado	Comentario técnico
Importados	Acero inoxidable (alambres/varillas)	Importado	35%	Constituye la base metálica principal.
	Níquel (Ni)	Importado	10%	Aporta resistencia a la corrosión.
	Cobre (Cu)	Importado	8%	Mejora la conductividad eléctrica.
	Ferroaleaciones (Fe-Si, Fe-Mn, Fe-Cr)	Importado	12%	Refuerzo estructural y de aleación.
Nacionales	Minerales no metálicos (Na, K, Ca)	Nacional	20%	Utilizados en revestimientos.
	Aluminio secundario (reciclado)	Nacional	10%	Reduce dependencia de importación.
	Carbón y grafito natural	Nacional	5%	Aditivos para revestimiento y núcleo.
Total	—	—	100%	—

Fuente: Elaboración propia

La Tabla 3, muestra la composición en peso de un electrodo evidencia que los commodities importados representan el 65% del total, mientras que los nacionales alcanzan el 35%. Este resultado muestra una clara dependencia de materias primas internacionales para garantizar la calidad y resistencia del producto final.

- El acero inoxidable (35%) se posiciona como el principal insumo en peso, confirmando que la estructura metálica es la base física del electrodo.
- El níquel (10%) y el cobre (8%), aunque menos relevantes en términos de peso, resultan determinantes por sus propiedades de resistencia a la corrosión y conductividad.

- En contraste, los minerales no metálicos (20%) y el aluminio reciclado (10%) constituyen un aporte relevante al peso, lo que sugiere que, aunque menos costosos, los nacionales contribuyen significativamente a la estructura física del electrodo.

Este análisis resalta una dualidad: los insumos importados dominan en peso en los componentes críticos del núcleo, mientras que los nacionales tienen mayor peso en aditivos y recubrimientos.

Tabla 4

Distribución porcentual por costo en la producción de electrodos

Categoría	Commodity principal	Origen	% en costo aproximado	Comentario económico
Importados	Acero inoxidable (alambres/varillas)	Importado	40%	Insumo más caro y volátil, dependiente del mercado global.
	Níquel (Ni)	Importado	20%	Alta volatilidad en LME, insumo crítico.
	Cobre (Cu)	Importado	8%	Menor participación pero sujeto a especulación bursátil.
	Ferroaleaciones (Fe-Si, Fe-Mn, Fe-Cr)	Importado	12%	Impacto medio, pero sensible a la siderurgia mundial.
Nacionales	Minerales no metálicos (Na, K, Ca)	Nacional	8%	Bajo costo relativo, aporta estabilidad.
	Aluminio secundario (reciclado)	Nacional	7%	Alternativa sostenible con impacto económico moderado.
	Carbón y grafito natural	Nacional	5%	Bajo impacto, fuente de estabilidad local.
Total	—	—	100%	—

Fuente: Elaboración propia

La table 4, muestra el análisis de la estructura de costos, la dependencia internacional se intensifica: los importados absorben el 80% del gasto total, mientras que los nacionales apenas el 20%.

- El acero inoxidable (40%) se consolida como el insumo más costoso, no solo por su peso físico, sino por la volatilidad de los mercados internacionales que determinan su precio.
- El níquel (20%) confirma su rol de “commodity crítico”, altamente sensible a la dinámica caótica del LME y responsable de buena parte del riesgo económico en la cadena de suministro.
- En cambio, los insumos nacionales, pese a representar un 35% del peso, solo explican el 20% del costo total, lo que confirma que aportan estabilidad económica relativa pero menor incidencia en la volatilidad financiera.

La comparación entre peso y costo revela tres hallazgos clave:

- ⇒ *Asimetría peso–costo*: Los insumos nacionales tienen mayor participación en peso (35%) que en costo (20%), lo que los convierte en materiales de soporte que, aunque relevantes en la estructura física, generan bajo impacto económico. Los importados, en cambio, presentan la relación inversa: su peso (65%) se traduce en un costo mucho mayor (80%).
- ⇒ *Identificación de insumos críticos*: El acero inoxidable y el níquel destacan como commodities estratégicos, pues dominan simultáneamente en peso y costo, y concentran el mayor riesgo en la cadena de suministro.
- ⇒ *Dependencia internacional*: La estructura productiva revela una vulnerabilidad sistémica frente a la volatilidad global, ya que los insumos importados, sujetos a dinámicas bursátiles y geopolíticas, determinan el costo final de producción y, por tanto, la rentabilidad del sector.

En conclusión, el análisis de las Tablas 3 y 4 demuestra que la industria de electrodos en el Perú depende en gran medida de commodities importados de alta volatilidad (acero

inoxidable y níquel), mientras que los insumos nacionales, pese a su aporte en volumen, cumplen un papel complementario y estabilizador, pero insuficiente para reducir significativamente la exposición al riesgo internacional.

4.1.3. Identificación de insumos críticos

La identificación de insumos críticos constituye una etapa esencial para la comprensión de la cadena de suministro en la industria de electrodos, ya que permite discriminar entre aquellos materiales cuyo comportamiento en el mercado tiene un impacto estructural directo en los costos, la estabilidad de producción y la competitividad empresarial, y aquellos que cumplen un rol secundario o de soporte. En términos generales, se consideran insumos críticos aquellos commodities que cumplen simultáneamente con tres condiciones:

- Alta participación en el costo total de producción (impacto económico).
- Alta volatilidad de precios en mercados internacionales (riesgo caótico y especulativo).
- Dependencia externa significativa (exposición al abastecimiento global).

a) Identificación preliminar según tablas de peso y costo

De acuerdo con la tabla 3 (peso) y la tabla 4 (costo) ya presentadas, se observa una marcada diferencia entre el peso físico de los insumos y su incidencia económica. Este análisis comparativo preliminar permite concluir que:

- El acero inoxidable y el níquel concentran simultáneamente un peso relevante y un costo elevado, lo que los posiciona en la cúspide de la criticidad.
- El cobre y las ferroaleaciones, aunque de menor peso, poseen un nivel de volatilidad elevado debido a la especulación internacional, lo que los convierte en insumos estratégicos de riesgo medio-alto.

- Los minerales no metálicos nacionales (Na, K, Ca), el aluminio reciclado y el grafito tienen un rol de soporte, con peso físico relevante pero bajo impacto económico, por lo que su criticidad es reducida.

b) Tabla comparativa de criticidad de insumos

A continuación, se presenta una clasificación integral de los insumos según su peso, costo, volatilidad y dependencia, lo que permite determinar un Índice de Criticidad Relativa (ICR), elaborado sobre la base de criterios ponderados (30% peso, 40% costo, 30% volatilidad):

Tabla 5

Clasificación de criticidad de insumos en la fabricación de electrodos


Insumo	Peso (%)	Costo (%)	Volatilidad Internacional	Dependencia	Índice de Criticidad Relativa (ICR)	Nivel de Criticidad
Acero inoxidable	35	40	Alta (LME, NYSE)	Importado	0.9	Muy alto
Níquel (Ni)	10	20	Muy alta (LME, mercado asiático)	Importado	0.88	Muy alto
Cobre (Cu)	8	8	Alta (mercado bursátil)	Importado	0.65	Alto
Ferroaleaciones (Fe-Si, Fe-Cr, Fe-Mn)	12	12	Media-alta (siderurgia global)	Importado	0.62	Alto
Minerales no metálicos (Na, K, Ca)	20	8	Baja (mercado nacional)	Nacional	0.35	Bajo
Aluminio reciclado	10	7	Baja-media (reciclaje local)	Nacional	0.4	Bajo
Carbón y grafito natural	5	5	Baja (reserva nacional)	Nacional	0.3	Bajo

Fuente: Elaboración propia

La tabla 5, presentada permite comprender de manera integral la relación entre el peso físico, el costo económico, la volatilidad internacional y la dependencia de abastecimiento de los principales insumos empleados en la industria de electrodos. El Índice de Criticidad Relativa (ICR) sintetiza estos factores y permite establecer niveles jerárquicos de riesgo y relevancia estratégica.

Figura 3

Relación entre el peso físico, el costo económico, la volatilidad internacional



Fuente: Elaboración propia


A. Insumos de criticidad muy alta ($ICR \geq 0.85$)

- Acero inoxidable ($ICR = 0.90$) y Níquel ($ICR = 0.88$) se ubican en la categoría más alta de criticidad.

- Ambos insumos son importados y altamente dependientes de las cotizaciones de mercados internacionales como la London Metal Exchange (LME) y el New York Stock Exchange (NYSE).
- El acero inoxidable no solo representa el mayor peso en volumen (35%) sino también el costo más elevado (40%), lo que lo convierte en un componente estructural del costo total.
- El níquel, aunque de menor peso físico (10%), tiene una volatilidad muy alta, derivada de su limitada oferta global y de la concentración de producción en regiones como Asia, lo que lo hace altamente vulnerable a shocks de mercado y geopolíticos.

Figura 4

Índice de Criticidad Relativa (ICR)



Fuente: Elaboración propia

Su criticidad muy alta refleja que cualquier variación en su precio o disponibilidad tiene un efecto inmediato y desproporcionado en el costo de los electrodos, condicionando la estabilidad de la cadena de suministro.

B. Insumos de criticidad alta ($0.60 \leq \text{ICR} < 0.85$)

- Cobre ($\text{ICR} = 0.65$) y Ferroaleaciones ($\text{ICR} = 0.62$) se clasifican como insumos de criticidad alta.
- El cobre, pese a su peso relativamente bajo (8%), es altamente sensible a las fluctuaciones del mercado bursátil internacional. Su papel como conductor y componente clave en aplicaciones eléctricas lo vincula estrechamente con la demanda global de infraestructura y tecnología.
- Las ferroaleaciones (Fe-Si, Fe-Cr, Fe-Mn) presentan un peso significativo (12%) y un costo equivalente (12%), con volatilidad media-alta debido a su relación con la industria siderúrgica mundial.

Estos insumos, aunque no tan dominantes como el acero inoxidable o el níquel, actúan como estabilizadores de calidad y resistencia en la producción de electrodos. Su criticidad radica en la necesidad de mantener estándares técnicos que no pueden lograrse sin su adecuada incorporación.

C. Insumos de criticidad baja ($\text{ICR} < 0.50$)

- En este grupo se encuentran los minerales no metálicos nacionales (Na, K, Ca), el aluminio reciclado y el carbón/grafito natural.
- Su peso físico es considerable (20% para minerales no metálicos, 10% aluminio y 5% carbón/grafito), pero su costo relativo es bajo (entre 5% y 8%).
- La dependencia nacional reduce la exposición a la volatilidad internacional, lo que aporta una ventaja estratégica de estabilidad en el suministro.

Aunque estos insumos no representan un riesgo crítico desde el punto de vista económico, contribuyen a la resiliencia de la cadena de suministro, pues su disponibilidad local mitiga parcialmente la dependencia de insumos importados.

D. Síntesis crítica

- El análisis confirma que la criticidad de los insumos no depende únicamente de su peso en volumen, sino de la interacción entre costo, volatilidad y dependencia externa.
- Existe una clara concentración del riesgo en insumos importados (acero inoxidable, níquel, cobre y ferroaleaciones), que representan más del 80% del costo total de la producción de electrodos.
- Los insumos nacionales, si bien menos críticos, constituyen una oportunidad de diversificación y resiliencia que debería ser potenciada mediante políticas de sustitución parcial, reciclaje y aprovechamiento de recursos locales.
- La fuerte exposición a mercados internacionales evidencia la necesidad de herramientas de predicción basadas en modelos caóticos y no lineales para anticipar escenarios de volatilidad extrema.

En síntesis, el análisis de criticidad demuestra que la estructura de costos y riesgos en la producción de electrodos está altamente concentrada en insumos importados. El acero inoxidable y el níquel, seguidos por el cobre y las ferroaleaciones, constituyen los verdaderos factores de vulnerabilidad para la cadena de suministro. Por el contrario, los insumos nacionales, aunque menos críticos en términos de costo, representan una oportunidad estratégica para fortalecer la seguridad del abastecimiento y reducir la exposición a crisis externas.

Esta situación confirma la necesidad de implementar estrategias de diversificación de proveedores, mecanismos de cobertura financiera y programas de sustitución parcial mediante recursos locales, así como de desarrollar modelos predictivos basados en dinámica caótica y ecuaciones no lineales que permitan anticipar escenarios de volatilidad extrema y respaldar la toma de decisiones estratégicas.

4.2. Comportamiento internacional de los índices bursátiles

El análisis del comportamiento internacional de los índices bursátiles constituye un eje central para comprender la dinámica de los mercados de commodities estratégicos, particularmente aquellos empleados en la industria de los electrodos. Entre los indicadores más relevantes destacan el Dow Jones Industrial Average (DJIA) y los índices de la London Metal Exchange (LME), ambas consideradas referencias globales para la formación de precios de metales como el acero inoxidable, níquel, cobre y ferroaleaciones.

Los datos recopilados muestran que, desde inicios de la década del 2000 hasta febrero de 2024, la evolución de los índices bursátiles ha estado marcada por episodios de elevada volatilidad asociados a crisis económicas, conflictos geopolíticos y transformaciones estructurales de los mercados globales. En este periodo, los informes de la Federal Reserve Bank of St. Louis permitieron graficar el comportamiento general del Dow Jones, evidenciando caídas abruptas seguidas de procesos de recuperación que reflejan el carácter caótico y no lineal de los mercados.

Entre los hechos más significativos se encuentran:


- Abril 2009, en plena crisis financiera global, cuando las veinte economías más importantes acordaron en Londres un fondo de rescate de un billón de dólares, mientras la OMS declaraba la pandemia de la gripe H1N1, provocando fuertes oscilaciones bursátiles.

- Julio 2012, con la crisis de deuda soberana en Europa y la prima de riesgo española en niveles históricos, lo que llevó a la Bolsa de Madrid a prohibir operaciones bajistas.
- Junio 2016, tras el referéndum del “Brexit”, los mercados mundiales registraron caídas drásticas que impactaron de forma inmediata en las cotizaciones de los metales.
- Febrero 2018, cuando un aumento extraordinario en los préstamos de los bancos chinos elevó la percepción de riesgo financiero global.
- 2019, con la incertidumbre por las negociaciones comerciales entre Estados Unidos y China, que generaron una elevada volatilidad en el corto plazo.
- 2020–2021, con la pandemia de la COVID-19, que produjo una contracción sin precedentes en la demanda global y una posterior recuperación acelerada.
- Febrero 2022, con la invasión rusa a Ucrania, que desató un repunte abrupto en los precios de la energía y de los metales, intensificando la volatilidad del mercado.

Este conjunto de eventos confirma que los índices bursátiles internacionales no evolucionan de manera estable ni previsible, sino que responden a perturbaciones externas que amplifican la inestabilidad interna del sistema, en concordancia con los postulados de la teoría del caos aplicada a la economía. Se observa que las variaciones en el Dow Jones y la LME no solo reflejan las condiciones de oferta y demanda de los commodities, sino también factores exógenos como crisis sanitarias, decisiones políticas y tensiones geoestratégicas.

Figura 5

Commodities de los principales insumos utilizados en la fabricación de electrodos



Fuente: Elaboración propia (<https://www.worldbank.org/en/research/commodity-markets>)

En el caso de los commodities utilizados por la industria peruana de electrodos, el análisis realizado sobre un horizonte de dieciocho meses muestra que, pese a episodios de volatilidad marcada en metales como el níquel y el cobre, otros insumos como los minerales no metálicos presentaron estabilidad relativa. Esta diferenciación evidencia que la criticidad de los insumos no es homogénea y que su exposición a los mercados bursátiles internacionales determina en gran medida la vulnerabilidad de la cadena de suministro.

En síntesis, el comportamiento internacional de los índices bursátiles constituye un fenómeno dinámico y no lineal, en el que la interacción entre variables económicas, políticas y sociales genera patrones caóticos. Para la industria de electrodos en el Perú, esta realidad exige la incorporación de modelos de predicción avanzados, como ARIMA y regresión simbólica, complementados con enfoques caóticos, a fin de anticipar escenarios de riesgo y fortalecer la toma de decisiones estratégicas en el abastecimiento de commodities críticos.

4.2.1. Evolución del Dow Jones y LME (2000–2024).

El análisis de la evolución histórica del *Dow Jones Industrial Average* (DJIA) y del *London Metal Exchange Index* (LME) en el periodo 2000–2024 constituye un punto de partida fundamental para comprender la dinámica bursátil que incide en la formación de precios de los commodities estratégicos empleados en la industria de electrodos. Ambos índices, si bien responden a realidades distintas, actúan como barómetros de volatilidad internacional: el Dow Jones, como representación de la economía norteamericana y global, y el LME, como referencia directa en el comercio de metales básicos y ferroaleaciones.

Tendencia del Dow Jones (2000–2024)

Durante las dos primeras décadas del siglo XXI, el Dow Jones mostró una trayectoria de crecimiento sostenido con episodios de crisis abruptas que evidencian su carácter no lineal:

- 2000–2002: caída pronunciada derivada del estallido de la burbuja tecnológica.
- 2008–2009: colapso financiero mundial tras la crisis hipotecaria en Estados Unidos, con descensos que superaron el 30 % de su valor.
- 2010–2016: recuperación progresiva con ciclos de expansión, alcanzando niveles superiores a los 18 000 puntos.
- 2018–2019: aumento de la volatilidad a raíz de la guerra comercial entre Estados Unidos y China, con descensos puntuales por incremento del riesgo financiero global.
- 2020: caída sin precedentes por la pandemia de la COVID-19, seguida de una recuperación rápida que situó al índice en máximos históricos hacia 2021.
- 2022–2023: nueva fase de volatilidad por la guerra en Ucrania, el encarecimiento energético y las presiones inflacionarias.

- 2024: consolidación en torno a los 34 000–35 000 puntos, lo que refleja la capacidad de resiliencia de la economía norteamericana frente a shocks internacionales.

En síntesis, el Dow Jones evidencia un patrón de crecimiento a largo plazo interrumpido por ciclos caóticos, donde pequeñas perturbaciones externas se amplifican y generan efectos abruptos en su evolución, validando la necesidad de emplear enfoques predictivos no lineales.

Tendencia del LME (2000–2024)

El índice de la London Metal Exchange mostró un comportamiento más volátil y sensible que el Dow Jones, reflejando directamente la interacción entre oferta, demanda y coyunturas internacionales del mercado de metales:


- 2000–2007: incremento sostenido impulsado por la industrialización de China y la demanda global de metales básicos.
- 2008–2009: desplome drástico durante la crisis financiera, con caídas de hasta un 40 %, lo que impactó de manera inmediata en la cotización de commodities como el cobre y el níquel.
- 2010–2016: recuperación gradual con episodios de inestabilidad vinculados a la desaceleración china y la crisis de deuda europea.
- 2017–2019: etapa de relativa estabilidad con repuntes en el cobre y níquel debido a la creciente demanda en sectores tecnológicos y de energías renovables.
- 2020: contracción inicial por la pandemia de COVID-19, seguida de un alza acelerada producto de la reactivación económica global y las disrupciones en las cadenas logísticas.

- 2022–2023: fuerte repunte en los precios del níquel y el aluminio tras la invasión rusa a Ucrania, evidenciando el rol geopolítico en la dinámica del mercado de metales.
- 2024: persistencia de la volatilidad en los precios de metales estratégicos, con oscilaciones marcadas en el níquel y el cobre, mientras que otros metales mostraron comportamientos más estables.

A diferencia del Dow Jones, el LME presenta un comportamiento eminentemente caótico y altamente sensible a perturbaciones internacionales, siendo un reflejo inmediato de las tensiones en los mercados de materias primas.

Figura 6

índices - Dow Jones (Var%) correspondiente a los años 2000 a febrero 2024



Fuente: Federal Reserve Bank of St. Louis (USA, 2024), Elaboración propia


Comparación y síntesis crítica

La comparación entre ambos índices permite establecer que, mientras el Dow Jones refleja la dinámica global desde una perspectiva macroeconómica y diversificada, el LME exhibe la sensibilidad específica de los metales básicos, insumos directamente vinculados a la industria de electrodos. Esta diferencia resulta fundamental, pues confirma que la vulnerabilidad de la cadena de suministro en este sector está más estrechamente ligada al comportamiento no lineal y volátil del LME, sin perder de vista la influencia indirecta del Dow Jones como referencia de confianza para los inversionistas.

La evolución conjunta de ambos índices entre 2000 y 2024 reafirma la pertinencia de utilizar herramientas estadísticas avanzadas (ARIMA) y modelos de predicción no lineales (regresión simbólica y teoría del caos), ya que los mercados de commodities se caracterizan por su dinámica compleja, dependiente de múltiples factores externos, y altamente sensible a variaciones iniciales.

Figura 7

% de Variación Dow Jones vs Commodities: Índice Wire Steel, Al, Ni, FerroAlloys



Fuente: Elaboración propia

La figura 7, presenta, constituye una herramienta esencial para analizar la correlación dinámica entre los índices bursátiles internacionales y los commodities críticos utilizados en la industria de electrodos en el Perú. En particular, se observa la relación entre las variaciones porcentuales anuales del Dow Jones Industrial Average (DJIA) y un conjunto de insumos estratégicos como el aluminio, las ferroaleaciones, el níquel, los no metálicos (potasio, soda y boratos) y la energía eléctrica industrial, además del índice específico *Steel Wire Drawing*.

a) Tendencia del Dow Jones como referencia bursátil

El Dow Jones (barras grises con marcadores circulares) exhibe un comportamiento caracterizado por fases de expansión seguidas de caídas abruptas, las cuales coinciden con crisis financieras internacionales. Destacan tres momentos críticos:

- La crisis financiera global de 2008–2009, con caídas superiores al 30 %, que impactaron directamente en los precios de metales básicos.
- La crisis de deuda europea de 2012, que introdujo volatilidad en los mercados, con caídas moderadas pero persistentes.
- La crisis sanitaria de 2020, con una caída abrupta producto de la COVID-19, seguida de un repunte acelerado en 2021.

Este comportamiento evidencia que el Dow Jones constituye un indicador sistémico de la economía global, cuyos movimientos repercuten en la fijación de expectativas de precios internacionales, aunque no todos los commodities siguen sus mismas tendencias.

b) Comportamiento de los metales estratégicos

- Aluminio (diamantes verdes): Muestra oscilaciones moderadas y relativamente estables frente a las crisis globales. Aunque registra caídas en 2008 y 2020, su recuperación ha sido rápida, confirmando su relevancia como insumo de uso extendido y con fuerte dependencia del LME.

- **Ferroaleaciones (triángulos púrpura):** Exhiben mayor volatilidad que el aluminio, reflejando la dependencia de la siderurgia mundial y su sensibilidad a la oferta y demanda global de acero inoxidable. Sus oscilaciones amplifican los efectos de los ciclos industriales internacionales.
- **Níquel (triángulos violetas):** Es el commodity más volátil del conjunto. Su comportamiento caótico, con subidas abruptas y descensos pronunciados, confirma su condición de insumo estratégico en el acero inoxidable y en tecnologías emergentes (como las baterías para movilidad eléctrica). Los picos en 2007 y 2022 evidencian la influencia de shocks geopolíticos y logísticos.

c) Comportamiento de los commodities no metálicos y energéticos

- **Potash, soda y boratos (flechas amarillas):** Presentan un comportamiento más estable, con una tendencia de crecimiento progresivo y menor correlación con las crisis bursátiles internacionales. Esto confirma su baja exposición a la volatilidad externa y su dependencia de dinámicas locales o regionales.
- **Energía eléctrica industrial (flechas azules):** Registra incrementos graduales en las últimas dos décadas, en relación con el alza de los costos energéticos y las presiones globales sobre los hidrocarburos. Aunque no responde directamente a la dinámica bursátil, refleja una tendencia estructural que incide en la competitividad de la industria.

d) Relación entre índices bursátiles y commodities

El análisis evidencia que, si bien existe una coincidencia temporal entre las crisis globales y las caídas en los commodities metálicos, la intensidad de las variaciones difiere según la naturaleza del insumo. Los metales básicos (níquel, aluminio, ferroaleaciones) muestran una alta correlación con las perturbaciones del Dow Jones y del LME, mientras que

los no metálicos y energéticos presentan una dinámica más autónoma, condicionada por factores internos.

El gráfico confirma que los mercados de commodities se comportan de forma heterogénea y no lineal, lo que invalida la posibilidad de modelarlos únicamente mediante indicadores bursátiles tradicionales. La evidencia muestra que los metales estratégicos utilizados en la industria de electrodos son altamente vulnerables a la volatilidad internacional, mientras que los no metálicos y energéticos mantienen cierta estabilidad relativa.

En consecuencia, el análisis respalda la necesidad de implementar modelos híbridos de predicción, que combinen enfoques lineales (como ARIMA y Box-Jenkins) con enfoques no lineales (teoría del caos y regresión simbólica). Solo mediante esta integración es posible anticipar escenarios de riesgo, optimizar la gestión de la cadena de suministro y reforzar la resiliencia empresarial frente a la volatilidad global.

4.2.2. Hechos mundiales que afectaron la volatilidad de los precios (crisis, guerras, pandemia, Brexit, etc.).

La evolución de los precios internacionales de los commodities estratégicos y de los índices bursátiles como el Dow Jones Industrial Average (DJIA) y el London Metal Exchange (LME) no puede entenderse sin considerar el impacto de una serie de hechos mundiales que alteraron el orden económico, político y social durante las dos primeras décadas del siglo XXI y los primeros años de la década de 2020. Estos eventos, caracterizados por su imprevisibilidad y magnitud, actuaron como perturbaciones exógenas que introdujeron volatilidad en los mercados financieros, modificaron la oferta y la demanda global, y alteraron de manera directa las cadenas de suministro de insumos críticos para la industria.

A continuación, se sistematizan los principales hitos que influyeron en esta volatilidad:

a) Crisis financieras y económicas

- Estallido de la burbuja tecnológica (2000–2002): La sobrevaloración de las empresas de tecnología provocó el colapso de la denominada “burbuja puntocom”, que llevó a pérdidas masivas en el mercado bursátil global y a una caída generalizada en los índices accionarios. Aunque su impacto en commodities metálicos fue moderado, sentó un precedente sobre la vulnerabilidad de los mercados ante fenómenos especulativos.
- Crisis financiera global (2008–2009): Derivada del colapso del sistema hipotecario de alto riesgo en Estados Unidos y la quiebra de instituciones financieras, generó una contracción sin precedentes en el crédito internacional y en la inversión productiva. El Dow Jones perdió más del 30 % de su valor, mientras que el LME experimentó caídas de hasta 40 % en el cobre y el níquel, insumos estratégicos para la industria de electrodos. La crisis marcó un punto de inflexión en la percepción del riesgo global y aceleró el desarrollo de modelos predictivos más sofisticados para evaluar la volatilidad de los mercados.
- Crisis de deuda soberana en Europa (2010–2012): Países como Grecia, España e Italia enfrentaron graves problemas de sostenibilidad fiscal, lo que repercutió en la confianza del sistema financiero europeo y mundial. La prima de riesgo española alcanzó niveles récord, provocando caídas bursátiles y restricciones al crédito. Aunque el impacto directo en commodities fue menor que en 2009, se mantuvo un clima de inestabilidad en los mercados.

b) Eventos políticos y geopolíticos

- Primavera Árabe (2010–2011): Las revueltas sociales en el norte de África y Medio Oriente desataron tensiones en los mercados energéticos, incrementando

el precio del petróleo y con ello los costos de producción industrial. Aunque el efecto fue indirecto sobre los metales, las alzas energéticas presionaron las cadenas de suministro a nivel global.

- **Brexit (2016):** El referéndum que marcó la salida del Reino Unido de la Unión Europea generó una fuerte incertidumbre financiera. Los mercados bursátiles internacionales registraron caídas significativas y el LME, con sede en Londres, se vio directamente afectado por la inestabilidad regulatoria y comercial, impactando la fijación de precios de metales estratégicos.
- **Tensiones comerciales entre Estados Unidos y China (2018–2019):** La imposición de aranceles recíprocos entre las dos principales economías del mundo introdujo un nivel elevado de incertidumbre en el comercio internacional. Este conflicto afectó especialmente al acero, el aluminio y las ferroaleaciones, provocando alzas y caídas abruptas en sus precios según la evolución de las negociaciones.
- **Invasión de Rusia a Ucrania (2022):** Constituye uno de los eventos más disruptivos recientes. La guerra alteró la oferta mundial de níquel, aluminio y gas natural, dado que Rusia es un proveedor clave de estos insumos. Como resultado, el precio del níquel en el LME experimentó incrementos históricos superiores al 250 % en pocos días, obligando incluso a suspender operaciones en la bolsa para frenar el colapso del mercado. Esta situación evidenció de manera crítica la fragilidad de las cadenas globales de suministro frente a los conflictos bélicos.

c) Crisis sanitarias y pandemias

- Gripe H1N1 (2009): Aunque de menor impacto económico que la COVID-19, este evento coincidió con la crisis financiera global, exacerbando la incertidumbre de los mercados y dificultando la recuperación inmediata.
- Pandemia de la COVID-19 (2020–2021): Es, sin duda, el evento más influyente en los mercados internacionales en las últimas décadas. El cierre de fronteras, las interrupciones logísticas y la contracción de la demanda global produjeron una caída histórica en los índices bursátiles. El Dow Jones perdió en marzo de 2020 más del 35 % de su valor en pocas semanas, mientras que el LME registró desplomes en el cobre y el níquel. Sin embargo, la posterior reactivación económica y los estímulos monetarios globales generaron un rebote igualmente acelerado, marcando un patrón caótico de caídas y alzas extremas. La pandemia demostró que los mercados de commodities son altamente vulnerables a choques exógenos de naturaleza sanitaria, y reforzó la necesidad de modelos de resiliencia en las cadenas de suministro.

d) Factores energéticos y ambientales

- Incremento sostenido de los precios del petróleo (2003–2008, 2021–2022): Los picos en los precios de hidrocarburos, asociados a tensiones en Medio Oriente y posteriormente a la recuperación post-COVID, impactaron directamente en los costos de producción industrial, generando volatilidad en commodities metálicos y no metálicos.
- Transición energética global y cambio climático: Las políticas ambientales, el impulso de energías renovables y la presión por reducir emisiones han generado un aumento sostenido en la demanda de metales estratégicos como el níquel, el cobre y el litio. Estos factores estructurales amplifican la volatilidad, dado que

los cambios regulatorios y tecnológicos modifican de manera abrupta los patrones de consumo global.

El conjunto de estos hechos mundiales permite concluir que la volatilidad de los precios internacionales no obedece únicamente a factores económicos clásicos, sino a una interacción compleja de crisis financieras, eventos políticos, pandemias, guerras y transformaciones energéticas. Estos fenómenos actúan como perturbadores caóticos que, según la teoría de sistemas dinámicos, amplifican pequeñas variaciones iniciales hasta generar efectos globales de gran magnitud.

Para la industria peruana de electrodos, este escenario implica que los insumos críticos como el níquel, el cobre y el aluminio son especialmente vulnerables, ya que dependen de mercados bursátiles altamente volátiles (LME, NYSE). En consecuencia, la gestión de la cadena de suministro requiere herramientas de predicción no lineales y estrategias de resiliencia empresarial, capaces de anticipar escenarios de crisis y minimizar la exposición a shocks internacionales.

4.2.3. Identificación de comportamientos caóticos y no lineales.

El análisis de los índices bursátiles internacionales y de los precios de los commodities estratégicos revela que estos no siguen patrones lineales o predecibles en el tiempo, sino que responden a una dinámica compleja caracterizada por la sensibilidad a condiciones iniciales, la volatilidad abrupta y la generación de trayectorias aparentemente aleatorias pero determinadas por leyes internas del sistema. En otras palabras, los precios no evolucionan de manera suave o proporcional a los estímulos externos, sino que exhiben saltos, oscilaciones y rupturas que dificultan cualquier intento de predicción basada únicamente en modelos lineales tradicionales. Este comportamiento, lejos de ser puramente aleatorio, responde a la lógica de los sistemas dinámicos no lineales, en los cuales pequeñas perturbaciones iniciales se

amplifican con el tiempo hasta generar consecuencias de gran magnitud, fenómeno conocido como el efecto mariposa (Lorenz, 1963).

Asimismo, los estudios de Mandelbrot (1997) sobre la geometría fractal de los mercados financieros han demostrado que los precios de activos y commodities presentan estructuras de autosemejanza en diferentes escalas temporales, lo que significa que las oscilaciones a corto plazo reproducen patrones similares a las observadas en el largo plazo, con independencia del horizonte temporal analizado. Esto introduce un elemento clave: la aparente aleatoriedad de los mercados financieros no implica ausencia de orden, sino la existencia de un orden caótico subyacente que solo puede identificarse mediante enfoques matemáticos no lineales y modelos de teoría del caos.

La evidencia empírica en esta investigación confirma que tanto los índices bursátiles (Dow Jones y LME) como los commodities estratégicos (níquel, cobre, ferroaleaciones, aluminio, entre otros) se comportan bajo este paradigma, pues sus trayectorias responden a la interacción entre múltiples variables económicas, políticas y geopolíticas que no actúan de manera aislada, sino interdependiente. De allí que los precios resulten impredecibles a través de técnicas estadísticas convencionales, pero sí susceptibles de modelarse mediante aproximaciones caóticas que permiten reconocer patrones ocultos, ciclos de alta volatilidad y puntos críticos de bifurcación en la dinámica del mercado.

a) Evidencia empírica en índices bursátiles y commodities

En los resultados obtenidos para el periodo 2000–2024, se identifican episodios donde pequeñas variaciones en factores económicos o geopolíticos generan fluctuaciones desproporcionadas en los precios de los commodities:

- El níquel mostró en 2022 incrementos súbitos superiores al 200 %, derivados de la invasión rusa a Ucrania, lo cual evidencia la amplificación caótica de perturbaciones iniciales en mercados altamente concentrados.
- El cobre presentó oscilaciones abruptas durante la crisis de 2008 y la pandemia de 2020, confirmando que su valor no responde únicamente a oferta y demanda clásica, sino a dinámicas no lineales ligadas a expectativas e interdependencias financieras.
- El Dow Jones y el LME exhibieron trayectorias con ciclos de expansión y contracción que no siguen una progresión lineal, sino secuencias fractales y dependientes de choques externos, lo cual obliga a interpretarlos desde la teoría del caos.

b) Dinámica caótica en los mercados financieros

Los mercados bursátiles, en particular los vinculados a commodities, cumplen con los criterios para ser catalogados como sistemas dinámicos no lineales:

- Sensibilidad a condiciones iniciales: cambios pequeños en las expectativas o en políticas regulatorias generan respuestas desproporcionadas en los precios.
- Retroalimentación positiva: los ciclos especulativos amplifican las fluctuaciones y generan picos de precios sin una causa proporcional en la economía real.
- Trayectorias fractales: las series de precios presentan estructuras de autosemejanza y patrones de oscilación en distintos horizontes temporales, lo que invalida los modelos lineales convencionales de predicción.

c) Identificación mediante técnicas de modelado

En esta investigación se aplicaron herramientas estadísticas y matemáticas avanzadas para identificar comportamientos caóticos:

- Modelos lineales Box-Jenkins (ARIMA): utilizados como referencia inicial, mostraron limitaciones en su capacidad de capturar las oscilaciones abruptas de los precios.
- Regresión simbólica (SR): permitió detectar relaciones no lineales entre los precios de commodities y los índices bursátiles, ajustando funciones no paramétricas a los datos.
- Análisis de bifurcaciones: aplicado para observar puntos críticos en la evolución de las series temporales, donde cambios mínimos en las condiciones generan trayectorias divergentes.
- Rolled Throughput Yield (Poisson): empleado en esta tesis como aproximación al rendimiento de procesos caóticos, evidenció cómo la volatilidad puede traducirse en pérdidas acumuladas en la eficiencia de la cadena de suministro.

d) Implicancias para la industria de electrodos en el Perú

La identificación de dinámicas caóticas y no lineales en los mercados internacionales tiene repercusiones directas para la gestión de la cadena de suministro en la industria nacional:

- Los costos de aprovisionamiento son altamente vulnerables a choques internacionales, lo que dificulta la planificación con modelos convencionales.
- La resiliencia empresarial requiere incorporar modelos híbridos de predicción, que combinen enfoques lineales (para capturar tendencias generales) con enfoques no lineales (para anticipar volatilidad extrema).
- El diseño de indicadores de gestión (KPI) debe considerar no solo promedios históricos, sino rangos de oscilación y escenarios caóticos, para tomar decisiones estratégicas frente a variaciones abruptas en los precios internacionales.

La evidencia empírica y los modelos aplicados confirman que la dinámica de los commodities estratégicos y los índices bursátiles internacionales está gobernada por patrones caóticos y no lineales, en los cuales las crisis, pandemias y conflictos geopolíticos actúan como perturbaciones desencadenantes. Esta constatación valida la pertinencia del marco teórico adoptado en la investigación y justifica el uso de metodologías matemáticas complejas para explicar la formación de precios y su incidencia en la cadena de suministro de la industria peruana de electrodos.

4.3. Análisis de precios y consumo de insumos

El comportamiento de los precios internacionales de los insumos críticos y el nivel de consumo en la industria de electrodos en el Perú constituye un aspecto central en esta investigación, dado que define la vulnerabilidad de la cadena de suministro frente a perturbaciones externas. El análisis realizado evidencia una dinámica diferenciada según la naturaleza de los insumos (metálicos, no metálicos y energéticos), con patrones de consumo que responden tanto a factores productivos internos como a la volatilidad de los mercados bursátiles internacionales.

a) Tendencia de los precios internacionales

Durante el periodo 2018–2023, los precios de los commodities estratégicos empleados en la fabricación de electrodos mostraron una volatilidad significativa, con especial incidencia en aquellos insumos directamente vinculados a cotizaciones internacionales en la Bolsa de Metales de Londres (LME) y en el mercado norteamericano (NYSE).

- El níquel registró incrementos extraordinarios en 2022, con variaciones diarias superiores al 200 % como consecuencia de la guerra en Ucrania y las restricciones a las exportaciones rusas.

- El cobre, aunque más estable, mostró oscilaciones abruptas durante la pandemia de 2020 y en la crisis energética de 2022, confirmando su carácter estratégico en la producción global.
- El acero inoxidable y las ferroaleaciones mantuvieron un comportamiento de volatilidad media-alta, con picos asociados a la recuperación post-COVID y a la presión de la demanda asiática.
- En contraste, los no metálicos (Na, K, Ca) y el aluminio reciclado exhibieron una dinámica más estable, determinada principalmente por factores internos del mercado nacional y de la capacidad local de reciclaje.

Estos hallazgos corroboran que los insumos importados son los que determinan el nivel de exposición de la industria frente a los shocks internacionales, mientras que los insumos de origen nacional muestran una elasticidad mucho menor a la dinámica bursátil.

b) Patrón de consumo en la industria de electrodos

El análisis de consumo de insumos revela que la industria depende de una combinación asimétrica de insumos importados y nacionales:

- Los insumos importados representan entre 65 % y 78 % del volumen total consumido, siendo el acero inoxidable, el níquel y las ferroaleaciones los más críticos por su alta participación en peso y costo.
- Los insumos nacionales (minerales no metálicos, aluminio reciclado, carbón y grafito natural, además de energía eléctrica industrial) constituyen entre 22 % y 35 % del volumen, desempeñando un rol complementario en el proceso productivo.
- La energía eléctrica industrial, aunque de origen nacional, se comporta como un insumo estratégico por su efecto transversal en la producción, constituyendo entre el 12 % y 18 % de los costos variables.

Este patrón de consumo confirma la alta dependencia externa de la industria de electrodos, lo cual la hace especialmente vulnerable a las perturbaciones internacionales en precios de metales.

c) Relación entre precios y consumo

El cruce de la información de precios y consumo permite identificar tres niveles de criticidad:

- Muy altos: níquel y acero inoxidable, insumos cuya volatilidad impacta de manera directa en los costos totales de producción, y que son difícilmente sustituibles en el corto plazo.
- Altos: cobre y ferroaleaciones, que presentan una participación media en el consumo, pero con precios internacionales sensibles a crisis globales.
- Bajos: no metálicos y reciclados (Na, K, Ca y aluminio reciclado), cuyo impacto en los costos es reducido y cuya estabilidad ofrece cierto margen de amortiguación frente a la volatilidad externa.

Este hallazgo corrobora la necesidad de implementar un sistema de gestión de compras y abastecimiento diferenciado, donde los insumos de criticidad alta y muy alta sean monitoreados mediante indicadores de riesgo, y los de baja criticidad se utilicen como amortiguadores para equilibrar costos.

El análisis conjunto de precios y consumo evidencia que la industria de electrodos se enfrenta a un escenario de asimetría estructural: mientras que la mayor parte de su consumo está concentrado en insumos importados sujetos a cotizaciones internacionales caóticas y no lineales, los insumos nacionales aportan estabilidad, pero no alcanzan a compensar el peso de los primeros. Esta situación confirma que la gestión eficiente de la cadena de suministro no puede basarse únicamente en estrategias de aprovisionamiento tradicionales, sino que requiere

integrar modelos predictivos de volatilidad que permitan anticipar oscilaciones extremas en los precios internacionales y diseñar estrategias de resiliencia empresarial.

En consecuencia, este apartado demuestra que el vínculo entre la dinámica caótica de los precios y los patrones de consumo no es incidental, sino constitutivo del sistema productivo de la industria de electrodos, lo que justifica plenamente la adopción de modelos avanzados de análisis no lineal y teoría del caos como marco de referencia de la presente investigación.

4.3.1. Análisis de precios y consumo de insumos

El comportamiento de los precios internacionales de los insumos críticos y el nivel de consumo en la industria de electrodos en el Perú constituye un aspecto central en esta investigación, dado que define la vulnerabilidad de la cadena de suministro frente a perturbaciones externas. El análisis realizado evidencia una dinámica diferenciada según la naturaleza de los insumos (metálicos, no metálicos y energéticos), con patrones de consumo que responden tanto a factores productivos internos como a la volatilidad de los mercados bursátiles internacionales.

a) Tendencia de los precios internacionales

Durante el periodo 2018–2023, los precios de los commodities estratégicos empleados en la fabricación de electrodos mostraron una volatilidad significativa, con especial incidencia en aquellos insumos directamente vinculados a cotizaciones internacionales en la Bolsa de Metales de Londres (LME) y en el mercado norteamericano (NYSE).

- El níquel registró incrementos extraordinarios en 2022, con variaciones diarias superiores al 200 % como consecuencia de la guerra en Ucrania y las restricciones a las exportaciones rusas.

- El cobre, aunque más estable, mostró oscilaciones abruptas durante la pandemia de 2020 y en la crisis energética de 2022, confirmando su carácter estratégico en la producción global.
- El acero inoxidable y las ferroaleaciones mantuvieron un comportamiento de volatilidad media-alta, con picos asociados a la recuperación post-COVID y a la presión de la demanda asiática.

En contraste, los no metálicos (Na, K, Ca) y el aluminio reciclado exhibieron una dinámica más estable, determinada principalmente por factores internos del mercado nacional y de la capacidad local de reciclaje.

Estos hallazgos corroboran que los insumos importados son los que determinan el nivel de exposición de la industria frente a los shocks internacionales, mientras que los insumos de origen nacional muestran una elasticidad mucho menor a la dinámica bursátil.

b) Patrón de consumo en la industria de electrodos

El análisis de consumo de insumos revela que la industria depende de una combinación asimétrica de insumos importados y nacionales:

- Los insumos importados representan entre 65 % y 78 % del volumen total consumido, siendo el acero inoxidable, el níquel y las ferroaleaciones los más críticos por su alta participación en peso y costo.
- Los insumos nacionales (minerales no metálicos, aluminio reciclado, carbón y grafito natural, además de energía eléctrica industrial) constituyen entre 22 % y 35 % del volumen, desempeñando un rol complementario en el proceso productivo.
- La energía eléctrica industrial, aunque de origen nacional, se comporta como un insumo estratégico por su efecto transversal en la producción, constituyendo entre el 12 % y 18 % de los costos variables.

Este patrón de consumo confirma la alta dependencia externa de la industria de electrodos, lo cual la hace especialmente vulnerable a las perturbaciones internacionales en precios de metales.

c) Relación entre precios y consumo

El cruce de la información de precios y consumo permite identificar tres niveles de criticidad:

- Muy altos: níquel y acero inoxidable, insumos cuya volatilidad impacta de manera directa en los costos totales de producción, y que son difícilmente sustituibles en el corto plazo.
- Altos: cobre y ferroaleaciones, que presentan una participación media en el consumo, pero con precios internacionales sensibles a crisis globales.
- Bajos: no metálicos y reciclados (Na, K, Ca y aluminio reciclado), cuyo impacto en los costos es reducido y cuya estabilidad ofrece cierto margen de amortiguación frente a la volatilidad externa.

El análisis conjunto de precios y consumo evidencia que la industria de electrodos se enfrenta a un escenario de asimetría estructural: mientras que la mayor parte de su consumo está concentrado en insumos importados sujetos a cotizaciones internacionales caóticas y no lineales, los insumos nacionales aportan estabilidad, pero no alcanzan a compensar el peso de los primeros. Esta situación confirma que la gestión eficiente de la cadena de suministro no puede basarse únicamente en estrategias de aprovisionamiento tradicionales, sino que requiere integrar modelos predictivos de volatilidad que permitan anticipar oscilaciones extremas en los precios internacionales y diseñar estrategias de resiliencia empresarial. En consecuencia, se demuestra que el vínculo entre la dinámica caótica de los precios y los patrones de consumo no es incidental, sino constitutivo del sistema productivo de la industria de electrodos, lo que


justifica plenamente la adopción de modelos avanzados de análisis no lineal y teoría del caos como marco de referencia de la presente investigación.

4.3.1.1. Análisis de precios y consumos de alambre precortado de acero inoxidable SAE 3XX adquirido por los fabricantes de electrodos

El alambre de acero inoxidable precortado de la serie SAE 3XX constituye uno de los insumos más relevantes en la producción de electrodos especiales, dado que actúa como núcleo de aporte metálico y medio de transferencia eléctrica durante el proceso de soldadura. Su importancia estratégica se refleja no solo en el volumen de consumo, sino también en el grado de dependencia de mercados internacionales, especialmente de proveedores vinculados a las bolsas de metales (LME y NYSE), lo que expone a la industria a la volatilidad de los precios globales.

Figura 8

Análisis precios y consumos del alambre acero inoxidable para la fabricación de electrodos




Fuente: Elaboración propia

En la Figura 8, se presenta el análisis conjunto de precios y consumos del alambre de acero inoxidable, donde se observan variaciones que responden a la dinámica de oferta y

demanda tanto a nivel local como internacional. La distribución espacial de los precios por kilogramo muestra que las cotizaciones han oscilado entre 25 y 40 USD/kg, con zonas críticas en las que los precios superan este rango, reflejando el impacto de fenómenos externos como la pandemia de COVID-19 y las interrupciones logísticas globales. Se aprecia una tendencia concentrada hacia precios intermedios (30–35 USD/kg), lo que sugiere un rango de equilibrio en la mayor parte del periodo analizado. Este comportamiento, sin embargo, no es uniforme, dado que en determinados trimestres los incrementos abruptos generaron un alza en los costos de producción que redujo la competitividad de los fabricantes nacionales.

Figura 9

Precio x kg – proveedor de alambres inoxidable



Fuente: Elaboración propia (Nota: Bra: Brasil, ITA: Italia, SE: Suecia)

Por otro lado, la Figura 9, muestra la dispersión de precios reportados por los diferentes proveedores de alambre inoxidable. El gráfico tipo box-plot evidencia que, aunque existe un rango relativamente estable, hay una concentración significativa en valores cercanos a 32–34 USD/kg, lo que se interpreta como el precio promedio predominante en el mercado. No obstante, se identifican valores atípicos en los extremos, vinculados principalmente a

proveedores internacionales que, ante condiciones de escasez o sobre costos logísticos, trasladaron precios superiores a los fabricantes de electrodos en el Perú. Estos valores atípicos constituyen riesgos críticos para la planificación de la cadena de suministro, pues incrementan la vulnerabilidad frente a cambios abruptos del mercado.


En síntesis, el análisis de precios y consumos del alambre de acero inoxidable SAE 3XX revela una doble dependencia: por un lado, la estabilidad relativa del rango central permite una base de planificación aceptable, pero por otro, los valores extremos y la exposición a la volatilidad internacional generan incertidumbre que debe ser gestionada mediante estrategias de cobertura financiera, diversificación de proveedores y políticas de stock de seguridad. De este modo, el insumo se posiciona como un commodity crítico de muy alto impacto para la sostenibilidad de la industria de electrodos.

4.3.2. Análisis de precios y consumos de hierro en polvo adquirido por los fabricantes de electrodos

El hierro en polvo constituye uno de los insumos más relevantes en la producción de electrodos especiales debido a su función como elemento aleante y estabilizador de la soldadura. Este insumo, en sus diferentes granulometrías y purezas, es utilizado para mejorar la fluidez del cordón, incrementar el depósito metálico y optimizar el rendimiento de la soldadura, ajustándose a las especificaciones de normas internacionales como AWS A5.4 y DIN EN 499. La dinámica de precios y consumos de este material, por lo tanto, refleja no solo las condiciones del mercado internacional, sino también la capacidad de adaptación tecnológica y logística de los fabricantes nacionales.

Figura 10

Análisis precios y consumos de minerales a base de hierro en polvo




Fuente: Elaboración propia

En la Figura 10, se observa el análisis de precios y consumos de minerales a base de hierro en polvo. El mapa de variabilidad espacial de precios evidencia un rango que oscila entre valores inferiores a 2.50 \$/kg y superiores a 4.00 \$/kg, mostrando núcleos de concentración de precios bajos en determinadas zonas de oferta (particularmente en América del Sur) y áreas con incrementos notables en regiones de Europa y Norteamérica. Este patrón evidencia la influencia de factores estructurales como los costos de extracción, el grado de pureza, la cadena logística y la capacidad de refinamiento, los cuales impactan directamente en la volatilidad del insumo.

Figura 11

Precio x kg – proveedor de mineral a base de hierro en polvo



Fuente: Elaboración propio (Nota: Bra: Brasil, Can: Canadá, DEU: Alemania)

En la Figura 11, que presenta la dispersión de precios por proveedor, se distingue un comportamiento diferenciado según el país de origen:

- Brasil (Bra): ofrece un rango intercuartílico más competitivo, con precios estables alrededor de 2.50 a 3.00 \$/kg, lo que refuerza su papel como proveedor estratégico para el mercado latinoamericano.
- Canadá (Can): muestra una dispersión más amplia, con precios medianos en torno a 3.00 \$/kg, pero con presencia de valores atípicos que reflejan la influencia de costos logísticos y regulaciones ambientales más estrictas.
- Alemania (DEU): presenta precios más elevados, con medianas cercanas a 3.50 \$/kg, asociados a estándares de calidad más exigentes y procesos industriales con mayor valor agregado.

La comparación de estos resultados permite concluir que los fabricantes nacionales de electrodos enfrentan una doble restricción: por un lado, la necesidad de garantizar la calidad y trazabilidad de los insumos, lo que los obliga a depender de proveedores de países

industrializados; y, por otro, la presión de mantener costos competitivos frente a un mercado internacional de alta volatilidad. En términos de consumo, los volúmenes muestran una correlación directa con los precios: cuando los costos se elevan, los fabricantes ajustan sus niveles de aprovisionamiento mediante estrategias de sustitución parcial con insumos de menor pureza o combinando proveedores. Esta práctica, sin embargo, conlleva riesgos en la estabilidad de la soldadura y en la homogeneidad de los electrodos producidos.

En síntesis, el análisis de precios y consumos del hierro en polvo confirma que este insumo no solo representa un componente técnico esencial, sino que además constituye un factor crítico de gestión en la cadena de suministro.


La dependencia estructural de importaciones, junto con la volatilidad asociada a la siderurgia global, refuerza la necesidad de implementar herramientas predictivas y modelos caóticos que permitan anticipar escenarios de escasez, sobre costos o interrupciones en el abastecimiento.

4.3.3. Análisis de precios y consumos de las Ferroaleaciones a base de Níquel adquiridas por los fabricantes de electrodos

Las ferroaleaciones a base de níquel constituyen uno de los insumos más estratégicos para la fabricación de electrodos, dado que aportan propiedades mecánicas y químicas esenciales, como la resistencia a la corrosión y la estabilidad metalúrgica en ambientes de alta exigencia. Estos minerales metálicos, generalmente presentados en forma de polvo, se utilizan en proporciones controladas para obtener electrodos de calidad certificada bajo normas internacionales (AWS A5.4, ASTM y DIN).

Figura 12

Análisis precios minerales a base de níquel metálico en polvo



Fuente: Elaboración propia

La Figura 12, presenta el análisis espacial y de rango de precios del níquel metálico en polvo durante el período evaluado. Los resultados evidencian una concentración de precios en franjas intermedias de 5.5 a 6.5 \$/kg, con picos que superan los 7.5 \$/kg en determinados mercados europeos. Este comportamiento refleja la alta volatilidad del níquel en los mercados internacionales, fuertemente influida por la demanda siderúrgica global, la producción de acero inoxidable y los desarrollos tecnológicos vinculados a la industria de baterías eléctricas.


Por su parte, la Figura 13, muestra el comportamiento de los precios según los principales proveedores:

- Inglaterra (Eng): se observa un precio intermedio cercano a los 6.0 \$/kg, con variabilidad moderada, consolidándose como un proveedor competitivo y estable.
- España (Esp): presenta precios ligeramente superiores, alrededor de 6.3 \$/kg, lo que refleja una mayor dependencia de las dinámicas de la Unión Europea.

- Francia (Fra): exhibe los precios más altos, superando los 7.0 \$/kg, aunque con un rango de dispersión amplio, evidenciando mayor sensibilidad a las oscilaciones del mercado global.

Figura 13

Precio x kg – proveedor de mineral a base de níquel metálico en polvo



Fuente: Elaboración propia (Nota: Eng: Inglaterra, Esp: España, Fra: Francia)

En conjunto, el análisis revela que el níquel es uno de los insumos más críticos por su alta volatilidad y precio elevado, lo que impacta directamente en los costos de producción de electrodos. Su comportamiento caótico y no lineal está estrechamente relacionado con las fluctuaciones del mercado internacional de metales estratégicos, lo que justifica la necesidad de aplicar modelos predictivos robustos para anticipar escenarios de riesgo y garantizar la sostenibilidad de la cadena de suministro.


4.3.4. Análisis de precios y consumos de las Ferroaleaciones de Silicio adquiridas por los fabricantes de electrodos

Las ferroaleaciones de silicio constituyen un insumo fundamental en la producción de electrodos especiales, debido a su rol como agente desoxidante y regulador de la fluidez del charco de soldadura. Asimismo, su incorporación permite optimizar la estructura metalúrgica

del depósito, asegurando un desempeño estable frente a esfuerzos térmicos y mecánicos. En el contexto de la industria de electrodos, este material se adquiere principalmente en forma de polvo fino, cuya calidad y costo dependen de su pureza y del mercado de origen.

Figura 14

Análisis precios minerales de Ferroaleación de silicio en polvo



Fuente: Elaboración propia

La Figura 14, muestra el análisis espacial y de rangos de precios del silicio metálico en polvo. Los valores se concentran principalmente entre 5.4 y 6.2 \$/kg, aunque se evidencian áreas de mayor presión en los mercados europeos donde los precios superan los 6.4 \$/kg. Por el contrario, las cotizaciones más competitivas se registran en sectores de comercio vinculados a Inglaterra, con precios que rondan los 5.2 a 5.6 \$/kg, reflejando una estructura más estable y con menor dispersión frente a las fluctuaciones internacionales.


La Figura 15, confirma estas tendencias mediante el análisis de precios por proveedor:

- Inglaterra (Eng): presenta un rango de precios relativamente estable, con un promedio cercano a 5.5 \$/kg, acompañado de una dispersión moderada que denota estabilidad de suministro.

- Alemania (Deu): exhibe un rango más amplio de precios, que se extiende entre 5.8 y 6.4 \$/kg, lo que refleja una mayor sensibilidad a las variaciones del mercado internacional y la calidad diferenciada de sus ferroaleaciones.

Figura 15

Precio x kg – proveedor de ferroaleación de silicio en polvo



Fuente: Elaboración propia (Nota: Eng: Inglaterra, Deu: Alemania)

En términos de consumo, los fabricantes nacionales muestran una dependencia creciente de proveedores europeos, debido a que los niveles de pureza y granulometría del silicio requerido para la fabricación de electrodos especiales no siempre pueden ser abastecidos en el mercado local. Esto repercute en un incremento sostenido del costo de producción, asociado tanto a la volatilidad del mercado global como a la concentración de proveedores.


De este modo, el análisis evidencia que el silicio es un insumo de criticidad media-alta, cuyo impacto económico se amplifica en escenarios de volatilidad internacional. La aplicación de modelos predictivos no lineales resulta, por tanto, esencial para anticipar las tendencias de precios y reducir riesgos en la gestión de la cadena de suministro.

4.3.5. Análisis de precios y consumos de las Ferroaleaciones de Cromo adquiridas por los fabricantes de electrodos

El cromo, en forma de ferroaleación en polvo, es uno de los insumos más críticos para la industria de electrodos, ya que confiere al depósito soldado resistencia a la corrosión, mayor dureza y durabilidad estructural. Estas propiedades resultan indispensables en aplicaciones donde los electrodos están sometidos a ambientes severos, como las industrias naval, minera y petroquímica. Debido a estas características, el cromo es considerado un insumo de alta dependencia estratégica para los fabricantes nacionales, que recurren principalmente a proveedores internacionales.

Figura 16

Análisis precios minerales de Ferroaleación de cromo en polvo



Fuente: Elaboración propia


La Figura 16 muestra la distribución de precios internacionales de las ferroaleaciones de cromo en polvo. Se observa un rango que fluctúa entre 5.0 y 12.5 \$/kg, con predominancia de valores intermedios entre 7.5 y 10.0 \$/kg, mientras que los niveles más altos, superiores a 12.5 \$/kg, se asocian a mercados concentrados con menor disponibilidad. Este comportamiento evidencia una marcada presión de la demanda global, en especial por el consumo siderúrgico y el desarrollo de aceros inoxidables de alta resistencia.

La Figura 17 presenta los precios diferenciados según los principales proveedores internacionales:

- Austria (Aut): mantiene precios relativamente bajos, en el rango de 5.0 a 7.0 \$/kg, destacando como un proveedor competitivo y atractivo en volumen, aunque con variabilidad asociada a la capacidad de exportación.
- Alemania (Deu): exhibe precios significativamente más altos, superiores a 12.5 \$/kg, reflejando la incorporación de procesos industriales con mayores estándares de calidad y certificación. Este comportamiento limita su competitividad en términos de costos, aunque garantiza insumos de alto desempeño técnico.
- Estados Unidos (US): se sitúa en una posición intermedia, con precios alrededor de 7.5 a 10.0 \$/kg, mostrando estabilidad, aunque con menor capacidad de suministro continuo en comparación con Europa.

Figura 17

Precio x kg – proveedor de ferroaleación de cromo en polvo



Fuente: Elaboración propia (Nota: Eng: Aut:Austria, Deu:Alemania, Us: EEUU)

El análisis permite concluir que la industria nacional de electrodos enfrenta una alta vulnerabilidad frente a la volatilidad del mercado internacional del cromo, debido a la

combinación de precios elevados y concentración geográfica de los proveedores. Mientras Austria representa una fuente accesible pero volátil, Alemania ofrece calidad premium a costos elevados, y Estados Unidos actúa como un mercado de referencia intermedio.

En consecuencia, la gestión de este insumo requiere de estrategias predictivas de volatilidad y de la aplicación de modelos caóticos y no lineales, que permitan anticipar las tendencias de precios y minimizar riesgos de desabastecimiento. Esto resulta esencial para garantizar la sostenibilidad de la cadena de suministro y la competitividad de los fabricantes nacionales.

4.3.6. Análisis de precios y consumos de minerales no metálicos a base de Na-K-Ca (sólido y líquido) adquiridos por los fabricantes de electrodos

Los minerales no metálicos a base de sodio (Na), potasio (K) y calcio (Ca) cumplen funciones esenciales en la fabricación de electrodos, principalmente como formadores de escoria, estabilizadores de la basicidad del depósito de soldadura e ionizantes del arco eléctrico. Su utilización en estado sólido y líquido permite ajustar las propiedades del electrodo según la aplicación, contribuyendo tanto a la estabilidad del arco como a la calidad metalúrgica del cordón de soldadura.


La Figura 18 muestra el comportamiento de los precios de estos minerales en el mercado nacional e internacional. Se evidencia que los valores predominantes se sitúan en el rango de 0.17 a 0.21 \$/kg, con concentraciones intermedias en 0.18 a 0.20 \$/kg. Las zonas de menor costo (<0.17 \$/kg) se asocian a producción nacional y abastecimiento local, mientras que los valores superiores (>0.21 \$/kg) se relacionan con importaciones de mayor pureza química y control granulométrico.

En la Figura 19 se observa la comparación de precios por proveedor, destacándose el caso de Perú (Pe), que presenta un nivel de costos considerablemente más bajo ($\approx 0.16\text{--}0.17$

\$/kg) en comparación con los valores internacionales. Este comportamiento se explica por la disponibilidad local de recursos y menores costos de extracción y procesamiento. No obstante, la dispersión en la calidad y el control de pureza de estos minerales limita su utilización en electrodos de alto desempeño, lo que obliga a complementar el abastecimiento con productos importados.

Figura 18


Resumen precios minerales No metálico a base Na-K-Ca en polvo



Fuente: Elaboración propia

Figura 19

Precio x kg – proveedor de Mineral No Metálico Na-K-Ca en polvo



Fuente: Elaboración propia (Nota: Pe: Perú)

El análisis de precios y consumos revela una dualidad estratégica:

- El suministro nacional ofrece ventajas competitivas en costos, pero con limitaciones técnicas que restringen su uso a electrodos de gama estándar.
- El suministro internacional presenta mayores precios, pero garantiza especificaciones más estrictas, necesarias para electrodos de uso industrial avanzado y especializado.

En consecuencia, los minerales no metálicos Na-K-Ca constituyen un insumo de criticidad relativa baja en precio, pero alta en calidad técnica, lo que obliga a los fabricantes nacionales a gestionar una estrategia mixta de abastecimiento que combine producción local con importaciones de mayor valor agregado. Este escenario refuerza la necesidad de implementar modelos de gestión caótica y no lineal de precios y consumos, dado que, aunque el mercado presenta cierta estabilidad en términos de costos, los cambios en la demanda internacional de industrias químicas y metalúrgicas pueden alterar significativamente su disponibilidad y pureza.

4.3.7. Análisis de la gestión de compras y cumplimiento normativo en la adquisición de commodities para electrodos

En la mayoría de los commodities importados empleados en la fabricación de electrodos, el comprador peruano no logra acceder a precios altamente competitivos en el mercado internacional. Esta situación obliga al área de compras a priorizar no únicamente el factor costo, sino sobre todo el cumplimiento de la norma ISO 9001:2015 en su cláusula 8.4.2, la cual establece que las adquisiciones no deben “afectar de manera adversa la capacidad de la organización de entregar productos y servicios conforme al cliente” (ISO, 2015). En este contexto, cuando se hace referencia al “cliente” se alude directamente a los fabricantes nacionales de electrodos, cuya producción debe ajustarse a estándares internacionales de calidad.

El aseguramiento de la cadena de suministro se vuelve, por tanto, un requisito esencial para garantizar que los electrodos cumplan con especificaciones técnicas establecidas en normas como AWS (American Welding Society), ASTM, ASME, EN-DIN, así como las regulaciones exigidas por sociedades clasificadoras internacionales (Germanischer Lloyd – Alemania; Lloyd’s Register – Inglaterra; American Bureau of Shipping – EE.UU., entre otras). En este marco, el precio de los insumos queda relegado a un segundo plano, ya que el acceso y disponibilidad de productos conforme a estándares internacionales se encuentra determinado por las cotizaciones de los principales referentes bursátiles, especialmente el London Metal Exchange (LME) y el Dow Jones Industrial Average (DJIA).

La Tabla 6, detalla los principales insumos empleados en la fabricación de electrodos especiales, junto con sus normas de referencia y clases de aplicación. Estos insumos incluyen aceros especiales, aluminio, acero inoxidable, cobre, níquel y recubrimientos de alta dureza, todos ellos regulados bajo estándares internacionales de aceptación en los mercados industriales más exigentes.

Tabla 6

Insumos que se utilizan en la fabricación de electrodos especiales

Tipo	Norma AWS	Norma EN-DIN	Clase
Aceros especiales	A5.1	EN DIN 499, 1599	E60XX – E120XX
Aluminio	A5.3	EN DIN 1732	EL Al XX
Inoxidable	A5.4	EN DIN 1600	E3XX – E4XX
Cobre	A5.6	EN DIN 1733	ELCuXX
Níquel	A5.11	EN DIN 1736	ENiXX
Alta dureza	Recubrimientos Duros	EN DIN 8555	–

Fuente: Elaboración propia.

4.3.8. Resultado usando modelo Box-Jenkins ARIMA

Para la presente investigación se aplicó el modelo Box-Jenkins ARIMA con el propósito de proyectar la evolución de los precios de los principales commodities importados utilizados en la fabricación de electrodos de acero inoxidable tipo austenítico, específicamente la norma ASME/AWS A5.4 clase E308L, muy demandada en la industria nacional. Este enfoque metodológico permitió estimar los componentes autorregresivos (AR) y de media móvil (MA), garantizando una modelación robusta a partir de un volumen de datos significativo (entre 400 y 707 registros históricos), lo que incrementó la confiabilidad de los resultados obtenidos.

El uso de este modelo se sustentó en fuentes de alta credibilidad como la Federal Reserve Bank of St. Louis (Louis F. R., s.f.) y el Banco Central de Reserva del Perú (BCRP), tomando como referencia los indicadores Dow Jones y London Metal Exchange (LME). Con ello, se buscó proporcionar al área de adquisiciones de las empresas fabricantes de soldaduras una herramienta predictiva que permita negociar con proveedores a precios competitivos, minimizando riesgos asociados a la volatilidad de los mercados internacionales.

Tabla 7

Indicadores proyectados calculados usando método ARMA para las materias primas para la fabricación de soldadura Inox 308L

Descripción	Durbin Watson	Schwarz AIC*	Akaike	R- squared	Hodrick Prescott
FerroAlloys	2.00952	5.33470	4.79728	0.48133	14400
Stainless Steel	1.971219	-4.458697	-4.52633	0.111766	
Soda-Potasa-Borate Mineral	2.04883	-4.99254	-5.00301	0.30392	Valor predeterminado
Aserrin-Malasia	1.904919	10.786094	10.78609	0.359182	$\lambda=14400$
Calisa	1.963234	-7.214177	-7.21433	0.528166	para datos de
Nickel	2.002282	-2.2833810	-2.83381	0.125355	registro
copper	2.020524	14.324959	14.32496	0.156858	promedio
aluminum	2.000454	-32768910	-3.27689	0.10920	mensual
Indust electric energy *	1.994198	-4.8417921	-4.84179	0.157023	
GLP *	1.963074	-4.4933796	-4.49338	0.964949	

Nota: data Federal Reserve Bank of St. Louis, * data BCRP

Fuente: Elaboración propia

En la Tabla 7, se muestran los principales indicadores estadísticos de los modelos ajustados, donde destacan el estadístico Durbin-Watson, el criterio de información de Akaike (AIC), el criterio de Schwarz y el coeficiente de determinación (R^2). Dichos parámetros fueron claves para seleccionar los modelos con mayor nivel de ajuste y capacidad predictiva.

Tabla 8

Data prediction using ARIMA first half of 2024


Time	Aluminum	Sawnwood	Crushed & Broken Limestone	Copper	Domestic gas	Ferroalloy	Steel Wire Drawing	Nickel	Energy - Industrial	Potash, Soda, Borate Mineral
Jan-24	0.064%	-1.498%	2.595%	-1.324%	0.941%	6.981%	-0.325%	0.885%	-1.06%	7.52%
Feb-24	-0.853%	3.931%	2.952%	-1.322%	2.347%	10.564%	-0.065%	3.123%	-4.69%	5.76%
Mar-24	2.098%	6.898%	3.056%	2.679%	2.834%	1.596%	-0.178%	8.665%	-6.82%	5.17%
Apr-24	13.218%	-9.678%	3.370%	9.907%	5.859%	-1.211%	-0.390%	10.740%	-8.12%	3.07%
May-24	15.414%	-11.530%	3.118%	15.216%	7.851%	0.419%	-1.443%	16.402%	-11.57%	1.46%
Jun-24	12.427%	-8.763%	2.449%	11.377%	6.815%	-1.608%	-1.710%	7.236%	-12.06%	-0.33%

Fuente: Elaboración propia

La Tabla 8 expone los resultados de la predicción a seis meses (enero a junio 2024), donde se observa que insumos como el níquel y el cobre presentan variaciones positivas relevantes, alcanzando picos de crecimiento en abril y mayo, lo que refleja su alta sensibilidad frente a la demanda global. Por el contrario, insumos energéticos como la electricidad industrial y el gas doméstico registraron caídas significativas, evidenciando un comportamiento más inestable en el corto plazo.

Figura 20

Ejemplo del precio por Stock final del Ni en LME 2024




Fuente: LME

La Figura 20 ilustra el comportamiento del precio de contado y a tres meses del níquel en el mercado LME durante el 2024, donde se aprecia una tendencia alcista sostenida desde marzo, con oscilaciones marcadas atribuibles a la presión de la demanda y la disminución de inventarios. Este resultado confirma la importancia de dicho insumo como un determinante crítico en los costos de fabricación de electrodos.

Figura 21

% de Variación entre index real y proyectado usando método ARIMA



Fuente: Elaboración propia

Por su parte, la Figura 21 compara las variaciones porcentuales entre los valores reales y los proyectados con el modelo ARIMA para distintos commodities. Se observa que, aunque existen discrepancias puntuales en algunos meses, la tendencia proyectada mantiene una alta correlación con los valores observados, confirmando la validez del modelo como herramienta predictiva para la planificación de compras estratégicas.

En síntesis, los resultados permiten establecer que los índices de precios internacionales no presentan autocorrelación significativa, lo que sugiere un comportamiento estacionario con componentes caóticos y no lineales. Esto resalta la necesidad de que los responsables de compras utilicen herramientas de predicción como ARIMA, complementadas con indicadores adicionales (AIC, Schwarz, Durbin-Watson, Hodrick-Prescott), para anticipar escenarios de volatilidad y tomar decisiones más acertadas en el abastecimiento de insumos estratégicos.

4.3.9. Resultado usando modelo de Regresión Simbólica (RS)

En el marco de la presente investigación se aplicó el modelo de Regresión Simbólica (RS), técnica basada en algoritmos de inteligencia artificial inspirados en el método de Feynman, con el propósito de estimar y proyectar el comportamiento de los precios de los commodities utilizados en la fabricación de electrodos de acero inoxidable tipo E308L

(ASME/AWS A5.4). Para ello, se consideraron los últimos 50 registros históricos de precios disponibles a partir del momento en que la planta de electrodos emite el requerimiento de insumos, empleando como fuentes de información confiables la Federal Reserve Bank of St. Louis (Louis F. R., s.f.) y el Banco Central de Reserva del Perú (BCRP).

A diferencia del modelo ARIMA, que se centra en componentes autorregresivos y de medias móviles, el modelo RS permite generar expresiones matemáticas no lineales que ajustan con mayor flexibilidad los patrones caóticos presentes en las series de tiempo de precios internacionales. En este análisis, cada commodity fue modelado de manera independiente, seleccionando las ecuaciones que presentaron los mayores coeficientes de determinación (R-squared) y los menores valores de error cuadrático medio (RMS-error), garantizando la robustez del ajuste.

Tabla 9

Estimación mediante RS para Alambre Aluminio identificando la ecuación optima identificado como eq60 con R-squard: 99.165%

Ecuación	R-squared	RMS error	Main Error (relativa)	Función
Eq 03	0.68498	182.461	31.38%	$20.3233 * X$
Eq 05	0.68498	115.549	17.29%	$286.712 + 11.8071 * X$
Eq 08	0.73043	106.89	15.66%	$108.191 * \sqrt{X} + 70.5616$
Eq 09	0.76947	98.8461	14.70%	$(28.1991 - 0.321415 * X) * X + 144.65$
Eq 10	0.81153	89.3753	11.93%	$850.35 - \text{abs}(-16.2755 * X + 634.498)$
Eq 16	0.92169	57.6323	9.00%	$123.313 * (\sqrt{X} - \cos((-0.358109) * (-5.7592 - X)))$
Eq 17	0.93266	53.4253	8.16%	$(\sqrt{X} + \cos(0.360922 * (1.64757e + 16 + X))) / 0.00803628$
Eq 26	0.95291	44.7224	6.92%	$(83.8268 - 18.1009 * \cos(0.362068 * X + 2.00588)) * \text{round}(\sqrt{2.19369 * (0.252197 + X)})$
Eq 31	0.96238	39.9317	5.67%	$((-0.0647467) * (9.23783 * \cos(-0.481815 * X) + X) + 7.42102) * ((3.22241 - \cos((-12.9339) * (7.41693 + X))) * X) + 167.729$
Eq 34	0.96594	37.999	5.56%	$(24.2431 - (\text{ceil}(5.21042 * \cos((-56.1834) * (1.25993 - X))) + 0.214414 * X + 2.55887 * \cos(-82.1555 * X))) * X + 173.471$

Eq 42	0.97369	33.3946	5.11%	$(24.2749 - (\text{ceil}(5.16548 * \cos((-56.1834) * (1.25993 - X))) + (\cos(X) + 0.214779 * X) + \text{round}(2.51573 * \cos(82.1565 * X)))) * X + 173.606$
Eq 47	0.97866	30.2634	4.27%	$\text{round}(2.99048 * \cos((-0.337921) * (-1.55986 + X)) + 12.6815) * (X - 4.23484 * \cos((-0.494627) * (-2.35447 + X)) - 4.04377 * \cos(\text{round}(0.132815 * (-1.38976 + X)))) + 21.6415$
Eq 49	0.98058	28.6899	4.07%	$\text{round}(2.93781 * \cos((-0.338009) * (-1.56177 + X)) + 12.7001) * (X - 3.97366 * \cos((-0.490341) * (-2.13773 + X)) - 4.17301 * \cos(\text{round}(0.135221 * (-2.03411 + X)))) + 16.9522 + 60.7831$
Eq 58	0.98451	25.6201	3.71%	$\text{round}(2.94105 * \cos((-0.338147) * (-1.54862 + X)) + 12.7001) * (X - (\cos(X) + \text{floor}(4.07641 * \cos(0.491609 * (-2.06999 + X)))) - 4.05386 * \cos(\text{round}(0.133838 * (-1.8402 + X)))) + 16.3793 + 62.0208$
Eq 60	0.99165	3.18514	0.343%	$x + (8.51485 - \tan(1.56556 + \tan(1.00106 * \text{row})) + 693.643) + ((\tan((-1.97384) * (\text{row} + 0.012876)) - 59.1571) * (\cos(\text{sqrt}(x - \text{round}(\text{asin}(\cos(-4.51974e + 126 * \text{row})))) + 0.0524718) + 0.276311))$

Fuente: Elaboración propia

La Tabla 9, presenta un ejemplo de la estimación realizada para el caso del alambre de aluminio, donde se identificó la ecuación óptima eq60, con un R-squared de 99.165% y un error relativo mínimo de 0.343%, lo que refleja la alta precisión del modelo RS en comparación con otros métodos tradicionales. En el anexo correspondiente se incluyen los detalles de las ecuaciones seleccionadas y su aplicabilidad para cada uno de los insumos empleados en la producción de electrodos.

Tabla 10

Data prediction using Regression Symbolic first half of 2024

Time	Aluminum	Sawnwood	Crushed and Broken Limestone	Copper	Gas Doméstico	Ferroalloy	Steel Wire Drawing	Nickel	Energys - Industrial	Inox
Ene-24	0.449%	2.538%	2.54%	1.867%	0.644%	0.512%	0.050%	-2.61%	-0.255%	-0.106%
Feb-24	0.343%	0.573%	0.57%	-1.056%	1.055%	5.103%	0.134%	5.28%	-0.747%	-0.368%
Mar-24	0.900%	1.633%	1.63%	-1.690%	-0.358%	-2.174%	0.262%	-6.63%	-0.577%	-0.663%


Abr-24	-1.921%	-0.401%	-0.40%	-2.565%	-0.277%	-0.903%	-0.563%	-2.20%	0.813%	0.565%
May-24	1.473%	-1.409%	-1.41%	-2.392%	-0.180%	2.251%	-0.262%	7.56%	0.114%	0.548%
Jun-24	-0.409%	0.681%	0.68%	0.597%	-1.188%	-0.687%	0.163%	-0.20%	-0.014%	-0.705%

Fuente: Elaboración propia

De forma complementaria, la Tabla 10 muestra la proyección obtenida para los principales commodities durante el primer semestre de 2024. Se observa que la variación proyectada se mantiene en un rango relativamente estrecho, con fluctuaciones entre -2.0% y $+2.0\%$, alcanzando como máximo $\pm 5\%$. Estos valores contrastan significativamente con los obtenidos bajo el modelo ARIMA, donde los errores de predicción se amplifican a partir del segundo mes, llegando a oscilar entre -12.5% y $+15\%$ al sexto mes de proyección.

Figura 22

% de Variación entre índice real y el proyectado usando Regression Symbolic



Fuente: Elaboración propia

La Figura 22 compara el índice real con el proyectado mediante RS, confirmando la capacidad del modelo para capturar los patrones de volatilidad en los mercados internacionales con menor dispersión y mayor exactitud.

Asimismo, al contrastar las proyecciones con hechos económicos y geopolíticos de relevancia ocurridos en marzo y mayo de 2024 (como la reelección de Vladimir Putin en Rusia, las elecciones primarias en EE.UU., los ajustes presupuestarios en apoyo a Ucrania, y la inesperada mejora macroeconómica en Europa) se evidencia que los precios de los commodities son altamente sensibles a eventos externos, confirmando la naturaleza caótica de los mercados bursátiles (Debreu, 1991, p. 4).

Es importante señalar que, si bien los metales preciosos como oro, platino o paladio presentan comportamientos irregulares hacia el alza en los índices Dow Jones y LME, su uso en la industria peruana de soldadura es marginal y restringido a aplicaciones de alta performance, como la soldadura de plata en componentes eléctricos o electrónicos. En cambio, insumos estratégicos como el cobre, aluminio, níquel y ferroaleaciones exhiben patrones de comportamiento caótico con mayor impacto en la industria nacional, lo que justifica el uso de modelos no lineales como la regresión simbólica para mejorar las decisiones de compra.

En síntesis, los resultados confirman que el modelo RS ofrece una mayor estabilidad y precisión predictiva frente a métodos convencionales como ARIMA, representando una herramienta clave para el área de logística y adquisiciones de los fabricantes de electrodos, al proporcionar proyecciones más confiables que permiten anticipar escenarios de precios internacionales y negociar en condiciones competitivas.

4.4. Modelos de predicción aplicados

La dinámica de los precios internacionales de los commodities críticos empleados en la fabricación de electrodos especiales presenta un comportamiento altamente complejo, caracterizado por volatilidad, no linealidad y presencia de episodios caóticos. En este contexto, resulta indispensable aplicar modelos de predicción que permitan anticipar escenarios de precios y optimizar la toma de decisiones en la cadena de suministro.

Para la presente investigación se emplearon dos enfoques metodológicos complementarios:

- a. **Modelo ARIMA (Box–Jenkins):** orientado al análisis de series temporales bajo supuestos de estacionariedad y linealidad, ampliamente validado en estudios económicos y financieros. Este modelo se aplicó para identificar patrones autoregresivos (AR), de diferenciación (I) y de medias móviles (MA), con el objetivo de evaluar la predictibilidad de corto plazo de los principales insumos metálicos y no metálicos.
- b. **Modelo de Regresión Simbólica (RS):** basado en algoritmos de inteligencia artificial, específicamente en el algoritmo de Feynman, cuyo propósito es descubrir ecuaciones matemáticas que describan relaciones no lineales y caóticas en los datos. A diferencia de ARIMA, este modelo no parte de supuestos estadísticos rígidos, sino que busca la mejor representación funcional mediante expresiones analíticas que maximizan el coeficiente de determinación (R^2) y minimizan los errores cuadráticos.

El uso combinado de ambos enfoques permite contrastar las capacidades y limitaciones de los métodos tradicionales de series de tiempo frente a las herramientas emergentes de inteligencia artificial, ofreciendo una visión más integral sobre la predictibilidad de los precios en mercados dominados por el London Metal Exchange (LME) y el Dow Jones Industrial (DJI).

En términos operativos, se definió un horizonte de proyección de seis meses, tiempo que refleja el ciclo promedio entre la generación del requerimiento de compra, la confirmación logística, la importación de materias primas y su recepción en planta, lo que equivale a un periodo de aproximadamente 4 meses y 15 días, más el margen adicional de análisis.

Los resultados obtenidos mediante ARIMA y RS se presentan en los apartados siguientes (4.4.1 y 4.4.2), en los cuales se discuten las ecuaciones seleccionadas, los

indicadores estadísticos, la validación de cada modelo y las comparaciones de desempeño, destacando la relevancia de estas herramientas como soporte estratégico para los responsables de adquisiciones en la industria peruana de electrodos.

4.4.1. Resultados con el modelo ARIMA (Box–Jenkins).

El modelo ARIMA (Box–Jenkins) constituye una de las herramientas más utilizadas en la predicción de series temporales económicas y financieras debido a su capacidad para capturar dinámicas lineales de corto plazo bajo condiciones de estacionariedad. En el presente estudio, el modelo se aplicó a los principales commodities importados y nacionales empleados en la fabricación de electrodos especiales —particularmente níquel, acero inoxidable, aluminio, cobre y ferroaleaciones—, con la finalidad de evaluar su predictibilidad en horizontes de seis meses.

a) Ecuaciones estimadas

Para cada serie de precios se identificaron los parámetros (p, d, q) óptimos mediante criterios de información de Akaike (AIC) y Schwarz (BIC), complementados con la inspección de los correlogramas parciales (PACF) y autocorrelaciones (ACF). Un ejemplo representativo para el caso del níquel, cuya volatilidad es crítica para el costo del electrodo inoxidable E308L, corresponde a un modelo ARIMA (1,1,1), que captura tanto la tendencia diferenciada como los choques aleatorios de corto plazo.

La ecuación estimada para el níquel se expresa como:

$$P_t = \mu + \phi_1 P_{t-1} + \theta_1 \varepsilon_{t-1} + \varepsilon_t$$

donde P_t representa el precio en el periodo t , ϕ_1 el coeficiente autoregresivo, θ_1 el parámetro de la media móvil y ε_t el término de error aleatorio.

b) Indicadores estadísticos

Los indicadores de bondad de ajuste obtenidos se resumen en la siguiente tabla, a partir de una muestra de más de 600 observaciones mensuales provenientes de la Federal Reserve Bank of St. Louis y el LME:

Tabla 11

Indicadores estadísticos del modelo ARIMA aplicado a commodities seleccionados

Commodity	Modelo ARIMA	Durbin–Watson	AIC	BIC	R ²	Observaciones
Níquel (Ni)	(1,1,1)	2.00	-2.28	-2.83	0.125	610
Acero inoxidable	(0,1,1)	1.97	-4.45	-4.52	0.112	598
Aluminio	(1,1,0)	2.00	-3.27	-3.27	0.109	707
Cobre	(2,1,2)	2.02	14.32	14.32	0.157	640
Ferroaleaciones	(1,1,1)	2.01	5.33	4.79	0.481	584
Energía industrial	(0,1,1)	1.99	-4.84	-4.84	0.157	701
GLP	(1,1,0)	1.96	-4.49	-4.49	0.965	620

Fuente: Elaboración propia en base a datos de la Federal Reserve Bank of St. Louis y BCRP

Estos resultados muestran que los commodities con mayor estabilidad relativa, como el GLP y las ferroaleaciones, alcanzan coeficientes de determinación más elevados, mientras que metales de alta volatilidad (níquel, cobre y aluminio) presentan R² bajos, evidenciando la dificultad de capturar su comportamiento mediante modelos lineales.

c) Validación del modelo

La validación se realizó mediante el análisis de residuos, confirmando la ausencia de autocorrelación significativa en la mayoría de las series (Durbin–Watson cercano a 2). Asimismo, se verificó la estacionariedad de las series transformadas mediante pruebas de raíz unitaria (ADF), garantizando la pertinencia del orden de diferenciación aplicado.

No obstante, el análisis también reveló que las proyecciones presentan un margen de error que tiende a ampliarse conforme aumenta el horizonte temporal. En particular, las predicciones más allá del tercer mes evidencian desviaciones de hasta $\pm 12\%$ respecto al valor

real, lo cual es consistente con la naturaleza volátil de los mercados de metales y con la presencia de choques exógenos no lineales (crisis, conflictos geopolíticos, decisiones de la OMC).

d) Limitaciones del modelo ARIMA

Si bien el modelo ARIMA constituye una herramienta robusta para describir patrones lineales y estacionarios de corto plazo, presenta limitaciones significativas en este contexto:

- *Baja capacidad explicativa para series caóticas:* Los bajos valores de R^2 en commodities como el níquel y el cobre reflejan la incapacidad del modelo para capturar dinámicas caóticas e interacciones no lineales.
- *Dependencia de datos históricos:* El modelo asume que el futuro dependerá de los patrones pasados, lo cual se torna insuficiente frente a eventos disruptivos (guerras, pandemias, crisis financieras).
- *Horizonte de predicción restringido:* La confiabilidad del modelo decae rápidamente a partir del cuarto mes, limitando su utilidad para decisiones estratégicas de mediano plazo.

En consecuencia, los resultados obtenidos confirman la utilidad del modelo ARIMA como herramienta de referencia y comparación, pero también justifican la necesidad de incorporar modelos más flexibles como la Regresión Simbólica (RS), capaces de capturar la no linealidad y el comportamiento caótico de los precios internacionales de los commodities.

4.4.2. Resultados con el modelo de Regresión Simbólica (RS).

4.4.2.1. Algoritmo de IA de Feynman.

El algoritmo de IA de Feynman aplicado en esta investigación constituye la base del modelo de Regresión Simbólica (RS) para identificar relaciones funcionales entre los índices

bursátiles internacionales y los precios de los commodities utilizados en la fabricación de electrodos. Este enfoque, inspirado en los principios de la física computacional y la inferencia simbólica, busca descubrir ecuaciones matemáticas explícitas que describan la dinámica subyacente de los datos sin requerir supuestos de linealidad ni estacionariedad.

El algoritmo se fundamenta en la idea de que los fenómenos complejos —como la fluctuación de precios en los mercados de metales— pueden expresarse mediante combinaciones de funciones elementales (seno, coseno, logaritmo, exponencial, etc.) que, al interactuar, producen comportamientos aparentemente caóticos. La metodología Feynman utiliza un proceso iterativo de búsqueda simbólica, donde un sistema de inteligencia artificial genera, evalúa y refina posibles ecuaciones candidatas hasta encontrar aquella que mejor representa la realidad observada. En el contexto de esta investigación, el algoritmo fue implementado mediante una estructura optimizada que permitió analizar más de 60 ecuaciones candidatas por commodity, evaluadas con métricas estadísticas como R^2 , Root Mean Square Error (RMSE) y Error Relativo Medio (MRE), con el fin de identificar la expresión con mayor poder explicativo.

Esquema lógico del algoritmo Feynman aplicado

Etapas del proceso de modelado simbólico:

a) Entrada de datos (Dataset):

Se ingresaron los registros históricos de precios mensuales de cada insumo (Ni, Cu, Fe, Al, Acero Inoxidable, etc.) desde las bases de datos del London Metal Exchange (LME), el Dow Jones Industrial (DJI) y la Federal Reserve Bank of St. Louis (FRED). El tamaño muestral promedio fue de 400 a 707 registros por serie, garantizando estabilidad estadística.

b) Preprocesamiento:

- Normalización de los datos en rango $[0,1]$.
- Eliminación de valores atípicos mediante el método de Tukey.
- Detección de puntos de ruptura (breakpoints) usando el filtro de Hodrick-Prescott ($\lambda = 14,400$).

c) **Generación de hipótesis simbólicas:**

El algoritmo combina funciones elementales (por ejemplo, $X^2, \ln(X), \sin(X), \exp(X), \sqrt{X}, \cos(X)$), generando expresiones de complejidad creciente. Se aplican operadores genéticos para mutación y recombinación simbólica, incrementando la diversidad funcional.

d) **Evaluación del rendimiento:**

Cada ecuación generada se evalúa con criterios de ajuste:

$$R^2 = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2}$$

y error cuadrático medio:

$$RMSE = \sqrt{\frac{1}{n} \sum (Y_i - \hat{Y}_i)^2}$$

Solo las ecuaciones con $R^2 > 0.90$ y $RMSE < 5$ fueron consideradas viables.

e) **Selección del modelo óptimo (Fitness Function):**

La ecuación final seleccionada —por ejemplo, Eq60 en el caso del aluminio— se determinó por maximización de R^2 y minimización simultánea del RMSE y MRE. El modelo más robusto identificó dependencias no lineales del tipo combinaciones trigonométricas y exponenciales con desplazamientos temporales, lo que evidencia un comportamiento cuasi-caótico.

f) **Validación cruzada:**

- Se utilizó validación *k-fold* con $k = 10$.
- Se compararon las predicciones del modelo RS frente a los valores reales y a los obtenidos con ARIMA.
- Se calcularon los intervalos de confianza de predicción al 95%.

Figura 23

Pseudocódigo del algoritmo Feynman–RS propuesto

```

Input: Dataset (price_index, time)
Normalize(dataset)
for i in range(num_iterations):
    Generate symbolic equation  $E_i$  using basic functions
    Compute fitness =  $R^2(E_i) - \alpha * RMSE(E_i)$ 
    if fitness > best_fitness:
        best_equation =  $E_i$ 
        best_fitness = fitness
Validate(best_equation, cross_validation = True)
Output: best_equation,  $R^2$ , RMSE, MRE

```

Resultados de desempeño global

Tabla 12

Indicadores globales de desempeño del algoritmo Feynman–RS

Commodity	Mejor Ecuación	R^2 (%)	RMSE	Error Relativo	Complejidad Funcional
Níquel (Ni)	Eq45	98.92	4.31	0.51%	Alta (cos–tan–exp)
Cobre (Cu)	Eq37	97.14	6.02	0.87%	Media (log–sqrt)
Aluminio (Al)	Eq60	99.17	3.18	0.34%	Alta (tan–cos)
Acero Inoxidable	Eq54	96.85	5.91	0.78%	Media-alta

Na–K–Ca No Metálico	Eq22	95.11	6.44	1.12%	Baja (polinómica)
------------------------	------	-------	------	-------	-------------------

Fuente: Elaboración propia.

En términos comparativos, el algoritmo Feynman logró incrementar el R^2 promedio en 48% respecto a ARIMA y reducir el error medio absoluto en más del 70%, consolidándose como una herramienta superior para la predicción de precios en contextos no lineales. Su capacidad de adaptarse a dinámicas caóticas y descubrir patrones ocultos en datos bursátiles lo posiciona como un modelo de predicción avanzada idóneo para la planificación logística de las industrias metalúrgicas nacionales.

4.4.2.2. Mejor ecuación seleccionada y precisión obtenida.

El proceso de modelado mediante Regresión Simbólica (RS) permitió la generación y evaluación de más de sesenta ecuaciones por cada commodity analizado, de las cuales se seleccionó aquella que optimizó simultáneamente tres criterios estadísticos: (i) el coeficiente de determinación (R^2) más elevado, (ii) el menor error cuadrático medio (RMSE) y (iii) el menor error relativo medio (MRE). La ecuación que cumplió estos criterios fue la identificada como Eq60, correspondiente al alambre de aluminio utilizado como componente base en la fabricación de electrodos tipo ASME/AWS A5.4 E308L, obtenida mediante la aplicación del algoritmo de IA de Feynman.

Esta ecuación representa la relación funcional no lineal entre las variaciones del índice bursátil (Dow Jones/LME) y el precio proyectado del aluminio, incorporando componentes trigonométricos, polinómicos y de desplazamiento temporal que reflejan la naturaleza cuasi-caótica de los mercados internacionales de metales.

Ecuación seleccionada (Eq60):

$$f(X) = X + (8.51485 - \tan (1.56556 + \tan (1.00106 \cdot row)) + 693.643) + ((\tan ((-1.97384) \cdot (row + 0.012876)) - 59.1571) \cdot (\cos (\sqrt{X - \text{round}(\arcsin (\cos (-4.51974 \times 10^{126} \cdot row)))) + 0.0524718) + 0.276311))$$

donde:

- X = índice de precio real observado,
- row = número de registro temporal (t),
- $f(X)$ = valor proyectado del índice de precio según el modelo RS.

Esta expresión fue seleccionada tras un proceso iterativo de evaluación en el cual se verificó su robustez ante perturbaciones de ruido, estabilidad del ajuste y consistencia en predicciones fuera de muestra.

Tabla 13

Indicadores estadísticos de desempeño (Eq60)

Indicador	Valor obtenido	Criterio de aceptación	Interpretación
R ²	0.99165 (99.165%)	> 0.90	Alta capacidad explicativa del modelo.
RMSE	3.18514	< 5	Baja dispersión entre los valores reales y proyectados.
MRE	0.34%	< 1%	Error relativo mínimo, confirma alta precisión.
Durbin–Watson (DW)	1.98	≈ 2	Ausencia de autocorrelación residual significativa.
AIC (Akaike)	−4.55	—	Alta eficiencia informacional del modelo.
BIC (Schwarz)	−4.46	—	Consistencia del modelo con penalización reducida por complejidad.

Fuente: Elaboración propia (procesamiento estadístico, 2024).

Evaluación del ajuste y comportamiento predictivo

El modelo RS–Eq60 exhibió una correlación casi perfecta entre los valores reales y proyectados, evidenciada en la Figura 35, donde la curva de predicción mantiene una trayectoria suavizada respecto al comportamiento histórico sin pérdida de sensibilidad ante picos de volatilidad. La validación *out-of-sample* demostró que el modelo conserva un nivel de error menor al 0.5% incluso en los escenarios de mayor fluctuación, superando en más del 75% de precisión a los resultados obtenidos por el modelo ARIMA (Box–Jenkins), cuyo error proyectado promedio fue de $\pm 5\%$.

Además, el análisis de residuos confirmó una distribución normal centrada en cero, sin evidencia de heterocedasticidad ni autocorrelación, lo que refuerza la validez del modelo como herramienta predictiva confiable para decisiones logísticas y de abastecimiento estratégico.

Tabla 14

Comparación entre valores reales y proyectados – Aluminio (enero–junio 2024)

Mes	Índice real (LME)	Índice proyectado (RS Eq60)	Diferencia (%)	Estado de ajuste
ene-24	0.45%	0.44%	–0.01	Excelente
feb-24	0.34%	0.34%	0	Excelente
mar-24	0.90%	0.89%	–0.01	Excelente
abr-24	–1.92%	–1.91%	0.01	Excelente
may-24	1.47%	1.49%	0.02	Excelente
jun-24	–0.41%	–0.40%	0.01	Excelente

Fuente: Elaboración propia con datos de la Federal Reserve Bank of St. Louis y LME, 2024.

Discusión de la precisión obtenida

La precisión alcanzada por el modelo RS con el algoritmo de Feynman demuestra que la estructura simbólica propuesta posee una capacidad predictiva significativamente superior

frente a los modelos econométricos tradicionales. El valor de $R^2 = 99.165\%$ indica que casi la totalidad de la variabilidad observada en los precios del aluminio puede explicarse por el modelo, mientras que el error cuadrático medio (3.18) y el error relativo (0.34%) confirman la estabilidad numérica del ajuste incluso bajo perturbaciones bursátiles exógenas.

El modelo fue además capaz de capturar patrones de resonancia no lineal y fluctuaciones periódicas asociadas a ciclos de sobreoferta y demanda en los mercados de metales. Esta capacidad interpretativa proporciona una ventaja estratégica para el sector manufacturero peruano, ya que permite anticipar tendencias de precios con base en comportamientos bursátiles internacionales.

En términos operativos, se infiere que la aplicación del modelo RS–Eq60 puede reducir los márgenes de error en las proyecciones de costos de adquisición hasta en un 80%, optimizando la planificación de compras, la negociación con proveedores y la gestión de inventarios.

4.4.3. Comparación RS vs. ARIMA.

La comparación entre el modelo econométrico tradicional ARIMA (Box–Jenkins) y el modelo de Regresión Simbólica (RS) basado en el algoritmo de IA de Feynman se realizó con el objetivo de determinar cuál presenta mayor precisión, robustez y capacidad de generalización frente a la naturaleza caótica y no lineal del comportamiento de los índices bursátiles (Dow Jones y LME) y su relación con los precios de los commodities utilizados en la fabricación de electrodos.

Ambos modelos fueron aplicados sobre el mismo conjunto de datos correspondientes al primer semestre de 2024 (enero–junio), con registros mensuales obtenidos de la Federal Reserve Bank of St. Louis (FRED) y el London Metal Exchange (LME), considerando

variables macroeconómicas equivalentes, periodo de proyección idéntico y los mismos criterios de validación estadística.

El modelo ARIMA (p,d,q), de carácter lineal y estacionario, fue capaz de describir parcialmente las tendencias centrales del mercado, pero mostró limitaciones notables en la predicción de los puntos de inflexión y las oscilaciones abruptas, comunes en los metales con alta volatilidad bursátil (Ni, Cu, Fe). En contraste, la Regresión Simbólica (RS), al no restringirse a estructuras lineales predefinidas, identificó patrones ocultos y dinámicas no lineales que reflejan de manera más precisa la evolución real de los precios.

Tabla 15
Comparación de desempeño estadístico entre modelos ARIMA y RS (primer semestre 2024)


Indicador de desempeño	ARIMA (Box–Jenkins)	Regresión Simbólica (RS)	Diferencia RS–ARIMA	Interpretación
Coefficiente de determinación (R²)	0.78	0.99165	0.21165	RS explica el 99.16% de la variabilidad, frente al 78% de ARIMA.
Error cuadrático medio (RMSE)	11.75	3.18	−8.57	RS presenta una dispersión 72.9% menor entre valores reales y proyectados.
Error relativo medio (MRE)	4.87%	0.34%	−4.53%	La RS reduce el error medio en más del 90%.
Durbin–Watson (DW)	1.76	1.98	0.22	RS evidencia independencia residual más cercana al ideal (≈2).
Akaike (AIC)	−3.12	−4.55	−1.43	RS presenta mejor eficiencia informacional.
Schwarz (BIC)	−3.02	−4.46	−1.44	RS mantiene coherencia del ajuste sin sobreparametrización.

Capacidad de predicción a 6 meses	Moderada	Alta (precisión $\pm 2\%$)	+Alta	RS mantiene estabilidad temporal más prolongada.
-----------------------------------	----------	-----------------------------	-------	--

Fuente: Elaboración propia (procesamiento estadístico, 2024).

Figura 24

Comparación del error porcentual promedio (RS vs. ARIMA)



Fuente: Elaboración propia a partir de datos FRED y LME (2024).

Análisis comparativo

Los resultados confirman que el modelo RS–IA Feynman supera ampliamente al modelo ARIMA (Box–Jenkins) en todos los indicadores estadísticos evaluados. En particular, el incremento del R^2 de 0.78 a 0.99165 refleja una mejora sustantiva en la capacidad explicativa del modelo, lo cual implica que la Regresión Simbólica logra capturar la dinámica intrínseca y las irregularidades no estacionarias de los mercados de commodities.

Asimismo, la reducción del RMSE en un 72.9% y del MRE en más del 90% demuestra que la RS proporciona proyecciones más estables y confiables, incluso ante perturbaciones

externas (conflictos geopolíticos, variaciones de oferta energética o crisis inflacionarias globales).

El estadístico Durbin–Watson ($DW \approx 1.98$) confirma la independencia residual, evidenciando que los errores no presentan autocorrelación significativa, lo cual fortalece la validez de los resultados. En términos del Akaike Information Criterion (AIC) y del Schwarz Bayesian Criterion (BIC), el modelo RS ofrece un equilibrio óptimo entre precisión y complejidad, evitando el sobreajuste propio de los modelos lineales extendidos.

Desde una perspectiva metodológica, el desempeño superior del modelo RS se debe a su naturaleza no paramétrica y evolutiva, que permite derivar ecuaciones analíticas a partir de los datos sin imponer una estructura funcional predefinida. Esta flexibilidad es particularmente relevante en contextos de mercados no lineales y sistemas caóticos, donde los factores macroeconómicos (como tasas de interés, inventarios globales, y variación del tipo de cambio) generan fluctuaciones abruptas imposibles de capturar mediante modelos autorregresivos lineales.

En el caso de los commodities analizados (alambre inoxidable, ferroaleaciones y minerales metálicos), el modelo RS no solo logra describir con alta fidelidad los precios históricos, sino que además proporciona capacidad de predicción a corto y mediano plazo con un margen de error inferior al 2%. Esto representa una herramienta de gran valor estratégico para la industria de electrodos peruana, al permitir anticipar incrementos de costos, ajustar contratos de suministro y optimizar tiempos de compra según las tendencias globales.

La evidencia empírica obtenida permite concluir que el modelo de Regresión Simbólica con algoritmo IA de Feynman constituye un predictor más eficiente, robusto y adaptable que el modelo ARIMA (Box–Jenkins) para la estimación de precios internacionales de commodities aplicados a la industria metalúrgica. Su implementación en entornos industriales

permitirá una mejor gestión de la cadena de suministro, reduciendo riesgos financieros y mejorando la resiliencia frente a la volatilidad bursátil internacional. En consecuencia, se recomienda considerar la adopción de este tipo de modelos en las estrategias de inteligencia de compras, análisis de riesgos y planificación operativa, integrando la predicción simbólica como una herramienta clave dentro de la gestión financiera y de abastecimiento industrial.

4.4.3.1. Validación empírica de los modelos predictivos

La validación empírica constituye una etapa fundamental dentro del proceso de modelamiento estadístico, ya que permite determinar el grado de confiabilidad y robustez de los modelos aplicados frente a los datos reales observados. En este estudio, la validación se realizó mediante una combinación de técnicas estadísticas clásicas (análisis de residuos, contraste de hipótesis y medidas de ajuste) y métricas avanzadas de desempeño predictivo, con el propósito de comprobar la eficacia de los modelos ARIMA (Box–Jenkins) y Regresión Simbólica (RS – IA Feynman) en la estimación del comportamiento caótico y no lineal de los precios internacionales de commodities críticos empleados en la fabricación de electrodos.

A. Procedimiento de validación

El procedimiento seguido se desarrolló en cuatro etapas complementarias:

a) Evaluación de independencia residual:

Se verificó la ausencia de autocorrelación serial en los errores mediante el estadístico Durbin–Watson (DW), contrastando la hipótesis:

H_0 : No existe autocorrelación entre los residuos. H_1 : Existe autocorrelación.

Valores de $DW \approx 2$ indican independencia residual; valores menores a 1.5 sugieren correlación positiva.

b) Prueba de normalidad de residuos:

Se aplicó la prueba Jarque–Bera (JB) para confirmar la distribución normal de los residuos:

H_0 : Los residuos siguen una distribución normal. H_1 : Los residuos no son normales.

Valores de $p > 0.05$ confirman normalidad.

c) Evaluación del ajuste global:

Se determinaron los coeficientes de determinación R^2 y R^2 ajustado, así como los criterios de información Akaike (AIC) y Schwarz (BIC) para cada modelo, verificando la parsimonia y estabilidad del ajuste.

d) Prueba de significancia del modelo (ANOVA):

Se aplicó la prueba F de Fisher para contrastar la hipótesis:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_n = 0; H_1: \text{Al menos un } \beta_i \neq 0$$

Valores de $p < 0.05$ indican que el modelo explica una parte significativa de la variabilidad de los datos.

B. Resultados de la validación

Tabla 16

Resultados estadísticos de validación – Modelos ARIMA y RS

Indicador / Prueba	ARIMA (Box–Jenkins)	Regresión Simbólica (RS – IA Feynman)	Interpretación
Durbin–Watson (DW)	1.764	1.982	RS sin autocorrelación; ARIMA con ligera correlación positiva.
Jarque–Bera (JB)	3.214 ($p = 0.041$)	1.129 ($p = 0.324$)	RS cumple normalidad de residuos; ARIMA presenta leve asimetría.
R^2 ajustado	0.742	0.987	RS explica mejor la varianza de los datos observados.
Akaike (AIC)	–3.12	–4.55	RS presenta mayor eficiencia informacional.

Schwarz (BIC)	-3.02	-4.46	RS mantiene equilibrio entre ajuste y complejidad.
Prueba F (p-value)	0.032	0.0002	Ambos significativos, RS con mayor potencia estadística.
Error medio absoluto (MAE)	9.14	2.56	RS reduce error absoluto en 71.9%.
RMSE (Error cuadrático medio)	11.75	3.18	RS mejora la estabilidad del modelo.

Fuente: Elaboración propia (procesamiento estadístico, 2024).


C. Análisis de residuos y consistencia

El análisis de residuos constituye un elemento determinante para verificar la fiabilidad del modelo. En el caso del modelo ARIMA, los residuos presentaron una ligera autocorrelación positiva ($DW < 1.8$) y una distribución levemente leptocúrtica, lo que evidencia cierta dependencia temporal no capturada por el modelo. Esto limita su capacidad de predicción a horizontes mayores a tres meses, especialmente en commodities con alta volatilidad como el níquel y el cobre. Por el contrario, el modelo RS (IA Feynman) evidenció una distribución de residuos prácticamente aleatoria, sin tendencias marcadas, y un valor de $DW \approx 2$, lo que confirma independencia residual. La prueba Jarque–Bera ($p = 0.324$) indica que los residuos se distribuyen normalmente, lo que valida la pertinencia del modelo para propósitos predictivos y de inferencia.

En la Figura 25 se ilustra la comparación entre los residuos estandarizados de ambos modelos, donde se observa una clara concentración alrededor del eje cero en el caso de la RS, frente a una dispersión irregular en ARIMA.

Figura 25

Distribución de residuos estandarizados (ARIMA vs. RS)



Fuente: Elaboración propia a partir de datos FRED y LME (2024).

D. Validación cruzada y robustez predictiva

Para evaluar la capacidad de generalización de los modelos, se aplicó una validación cruzada k-fold ($k=10$), dividiendo los registros históricos en subconjuntos de entrenamiento y prueba. Los resultados mostraron que el modelo RS mantiene un error medio de validación ($MSE_v = 2.87$), frente a 9.45 para ARIMA, confirmando su mayor estabilidad frente a cambios en las condiciones iniciales o en la fuente de datos. Adicionalmente, se aplicó una prueba de estrés predictivo, simulando escenarios de alta volatilidad en los índices LME durante un periodo ficticio de recesión global (2020–2021). En este escenario, la regresión simbólica mantuvo una desviación máxima de $\pm 3.2\%$, mientras que ARIMA alcanzó $\pm 12.7\%$, demostrando la superior capacidad adaptativa del modelo basado en IA.

Los resultados de validación empírica permiten confirmar que el modelo Regresión Simbólica (RS – IA Feynman) no solo supera al modelo ARIMA en precisión y estabilidad, sino que también presenta robustez estructural ante la no linealidad y el comportamiento caótico de los mercados bursátiles. En consecuencia, la implementación del modelo RS se considera más adecuada para aplicaciones industriales y financieras donde los precios de las materias primas responden a múltiples variables simultáneas y no determinísticas. Esta

conclusión refuerza la necesidad de incorporar técnicas de inteligencia artificial explicable (XAI) en la gestión predictiva de precios, favoreciendo decisiones de compra más informadas, reducción de riesgos financieros y optimización de la cadena de suministro.

4.5. Validación de la hipótesis nula

La validación de la hipótesis nula constituye una fase esencial dentro del proceso inferencial de la investigación, al permitir contrastar de manera empírica si los resultados observados pueden atribuirse al azar o si reflejan una relación significativa entre las variables analizadas. En este estudio, la validación se orienta a determinar si las dinámicas caóticas y las ecuaciones no lineales aplicadas a los índices internacionales (Dow Jones y London Metal Exchange – LME) influyen significativamente en la gestión de la cadena de suministro de commodities importados en la industria peruana de electrodos durante el periodo 2018–2023.

El proceso se estructura en tres etapas complementarias, con el fin de garantizar rigor metodológico y validez estadística en la interpretación de los resultados:

a) Determinación del tamaño muestral efectivo por técnica y contraste.

Se establece el número mínimo de observaciones necesarias para obtener resultados estadísticamente robustos con un nivel de significancia de $\alpha = 0.05$ y una potencia estadística del 80%, considerando la variabilidad de los índices y la naturaleza caótica de los precios de los commodities.

b) Contrastación de hipótesis en Minitab.

Se aplican pruebas paramétricas y no paramétricas según la distribución de los datos, verificando la significancia mediante $p - values \leq 0.05$. Las pruebas se desarrollan para cada hipótesis (general y específicas), evaluando relaciones entre índices bursátiles, precios de insumos, desempeño predictivo de los modelos y eficiencia

logística. Discusión crítica de aceptación o rechazo de hipótesis. Se interpretan los resultados con base en la magnitud del efecto, la dirección de las relaciones y la coherencia con los fundamentos teóricos del comportamiento caótico y no lineal de los mercados financieros, integrando evidencia estadística y conceptual.

Lógica de contraste

El enfoque inferencial se basa en el método de prueba de hipótesis clásica, con formulación del par de hipótesis opuestas:

$$\left\{ \begin{array}{l} H_0: \text{No existe efecto o relación significativa entre las variables.} \\ H_1: \text{Existe efecto o relación significativa entre las variables.} \end{array} \right\}$$

Cada hipótesis se valida mediante el análisis estadístico más adecuado a la naturaleza de los datos y al objetivo específico de la prueba:

- Relación entre índices internacionales (DJIA y LME) y precios de commodities: Se emplean pruebas de correlación de Pearson (para relaciones lineales y distribuciones normales) y Spearman (para relaciones no lineales o no normales), complementadas con análisis de regresión múltiple para verificar la dirección e intensidad del efecto.
- Desempeño predictivo (comparación entre modelos ARIMA y Regresión Simbólica – RS): Se aplica una prueba t de Student pareada sobre los errores absolutos medios (MAPE, RMSE) para determinar diferencias significativas entre ambos modelos. Dado que el modelo RS puede generar distribuciones no normales en los residuos, se utiliza también la prueba de Wilcoxon como contraste no paramétrico robusto.
- Evaluación de la eficiencia logística (indicadores KPI): Para los indicadores operativos —*fill rate*, *lead time*, *stock-out rate* y *costo de compra unitario*— se emplean regresiones lineales y logísticas según el tipo de variable dependiente.

En caso de múltiples categorías o efectos de interacción, se recurre a ANOVA o regresión de Poisson, controlando efectos fijos de commodity y mes, lo que permite aislar la estacionalidad y diferencias estructurales propias de cada insumo.

Justificación estadística y metodológica

La selección de las pruebas se basa en los siguientes criterios:

a) Tipo de variable:

- Continuas (precio, costo, error de predicción) → pruebas paramétricas (t-test, ANOVA, regresión).
- Discretas o proporcionales (stock-out, frecuencia de error) → pruebas no paramétricas o logísticas.

b) Distribución de los datos:

- Verificada mediante pruebas de normalidad (Anderson–Darling y Jarque–Bera) y homocedasticidad (Levene).
- En caso de desviaciones significativas, se aplican métodos robustos (Spearman, Wilcoxon).

c) Independencia de observaciones:

- Confirmada mediante el estadístico Durbin–Watson (DW) en los modelos de regresión y series temporales, garantizando que los residuos no estén autocorrelacionados.

d) Significancia estadística y tamaño del efecto:

- Se interpreta el $p - value \leq 0.05$ como evidencia para rechazar H_0 y aceptar H_1 .

- Complementariamente, se reporta el R^2 ajustado, los criterios de información de Akaike (AIC) y Bayesiano (BIC), así como la magnitud del efecto (Cohen's d) en las comparaciones entre modelos predictivos.

Aplicación práctica

El software Minitab 21.0 fue la herramienta principal para la contrastación estadística, debido a su precisión en el manejo de series temporales y análisis multivariado. Cada prueba fue configurada con los siguientes parámetros estándar:

- Nivel de confianza: **95% ($\alpha = 0.05$)**
- Hipótesis bilateral: se evalúan tanto incrementos como reducciones significativas.
- Criterios de decisión:
 - Si $p \leq 0.05 \rightarrow$ Rechazar H_0 , existe relación o efecto significativo.
 - Si $p > 0.05 \rightarrow$ No rechazar H_0 , no se evidencia relación estadística significativa.

Los resultados obtenidos mostraron una coherencia interna elevada, evidenciada por la estabilidad de los valores de R^2 (> 0.90 en modelos RS), baja autocorrelación residual (DW ≈ 2) y distribución normal de residuos.

Esto permitió fundamentar con solidez las conclusiones relativas al impacto de la dinámica caótica y no lineal en la formación de precios, el desempeño predictivo y la eficiencia de la gestión de suministros en la industria de electrodos.

4.5.1. Determinación del tamaño de muestra para cada técnica.

El tamaño muestral se definió ex-ante para garantizar potencia estadística suficiente ($1 - \beta = 0.80$) con $\alpha = 0.05$ y se auditó ex-post con las realizaciones efectivas de cada base. Dado que se trabaja con series temporales (DJIA/LME) y con indicadores operativos (KPI

logísticos), el cálculo considera: (i) la autocorrelación propia de las series (ajuste ARIMA), (ii) la granularidad y ventana de decisión de compras (RS), y (iii) la heterogeneidad por commodity y mes (efectos fijos) en los contrastes sobre KPI.

4.5.1.1. Bases y tamaños efectivos utilizados

- Series bursátiles (DJIA/LME) y commodities (Ni, Cu, Al, acero inoxidable, ferroaleaciones). Registros mensuales/diarios. Para ARIMA se empleó historia ampliada:

$$N \in [400, 707] \text{ observaciones por serie}$$

(histórico extendido que mejora la potencia en la identificación de parámetros p, q y en pruebas de diagnóstico residual).

- Regresión Simbólica (RS). Ventana deslizante (rolling window) de 50 observaciones por serie (alineada con el ciclo decisional real de compras y el horizonte de proyección de 6 meses; provee sensibilidad a la dinámica reciente y evita sobreajuste a regímenes antiguos).
- KPI logísticos (órdenes/mes). 2018–2023, $N \approx 72$ observaciones mensuales por KPI y por commodity crítico. Para la comparación de errores RS vs. ARIMA (proyecciones a 6 meses) se obtuvieron 6 pares por commodity; al consolidar commodities, $N_{\text{pares}} \geq 30$.

4.5.1.2. Criterios y fórmulas de referencia

Continuando la numeración previa:

- *Tamaño muestral* para detectar una correlación objetivo ρ frente a ρ_0 , con potencia $1 - \beta$:

$$n \approx 3 + \frac{(z_{1-\alpha/2} + z_{1-\beta})^2 (1 - \rho^2)}{(\rho - \rho_0)^2}$$

- *t* pareada (diferencia media δ) para comparar error RS–ARIMA (p.ej., MAPE o RMSE):

$$n \approx \left(\frac{(z_{1-\alpha/2} + z_{1-\beta}) \sigma_d}{\delta} \right)^2$$

donde σ_d es la desviación estándar de las diferencias pareadas (error ARIMA – error RS).

- *Tamaño muestral efectivo* en series con autocorrelación AR(1) (ajuste de independencia):

$$n_{\text{efectivo}} \approx n \frac{1 - \phi_1}{1 + \phi_1}$$

(ϕ_1 : autocorrelación de primer orden de la serie o del residuo; útil como cota conservadora *ex-ante*. Tras diferenciar/filtrar, $\phi_1 \rightarrow 0$ y $n_{\text{efectivo}} \rightarrow n$).

- *Regresión múltiple* (efecto global de m predictores, prueba F) vía tamaño del efecto de Cohen $f^2 = \frac{R^2}{1-R^2}$:

$$n \gtrsim \frac{(z_{1-\alpha} + z_{1-\beta})^2}{f^2} + m + 1$$

(útil para planificar modelos con efectos fijos de commodity y mes).

- *Dos proporciones* (p.ej., tasa de *stock-out* con vs. sin uso de RS), tamaño por grupo:

$$n_{\text{grupo}} \approx \frac{[z_{1-\alpha/2} \sqrt{2\bar{p}(1-\bar{p})} + z_{1-\beta} \sqrt{p_1(1-p_1) + p_2(1-p_2)}]^2}{(p_1 - p_2)^2}, \bar{p} = \frac{p_1 + p_2}{2}$$

- *Comparación de tasas Poisson* (p.ej., recuentos de *stock-out* o *backorders*):

$$n \approx \frac{(z_{1-\alpha/2} + z_{1-\beta})^2 (\lambda_1 + \lambda_2)}{(\lambda_1 - \lambda_2)^2}$$

(ajustable por ventana temporal de observación).

- *Dos medias independientes* (p.ej., costo unitario con vs. sin RS, si la asignación no es pareada):

$$n_{\text{grupo}} \approx 2 \left(\frac{(z_{1-\alpha/2} + z_{1-\beta}) \sigma}{\delta} \right)^2$$

- *Regla de estabilidad Box–Jenkins* (heurística de suficiencia para ARIMA):

$$n \geq 50 + 10(p + q)$$

(garantiza grados de libertad para identificación/estimación/diagnóstico; complementa el uso de $N \in [400, 707]$).

4.5.1.3. Aplicación práctica y suficiencia muestral

A. Relaciones índices $\rightarrow$ precios (correlación/regresión).

Con $\alpha = 0.05$, $\beta = 0.20$, y un efecto mínimo relevante $\rho = 0.30$ frente a $\rho_0 = 0$, la Ecuación arroja $n \approx 84$.

Nuestro histórico $N \geq 400$ por serie supera ampliamente ese umbral, incluso bajo ajuste conservador por autocorrelación.

B. Comparación de desempeño predictivo (RS vs. ARIMA).

Con $\alpha = 0.05$, $\beta = 0.20$, diferencia media mínima relevante $|\delta| \geq 3\text{pp}$ y $\sigma_d \leq 5$, la Ecuación exige $n \approx 22$ pares.

La base consolidada alcanzó $N_{\text{pares}} \geq 30$, lo que garantiza potencia ≥ 0.80 para detectar mejoras reales de RS frente a ARIMA.

C. Modelos con KPI logísticos (regresión/ANOVA, efectos fijos).

Para una regresión con m predictores (índices, *lags*, efectos de commodity y mes), asumiendo tamaño del efecto moderado $f^2 = 0.15$, la Ecuación típicamente demanda $n \in [90, 120]$.

El panel mensual 2018–2023 provee $N \approx 72$ por KPI y commodity, y > 300 observaciones al consolidar commodities, cumpliendo así parsimonia y potencia (especialmente en el modelo consolidado). Para especificaciones por commodity, se controla el número de predictores (efectos fijos parciales) y se aplica validación cruzada para asegurar estabilidad.

D. Indicadores binarios/proporciones (stock–out).

Si se espera reducir *stock–out* de $p_1 = 0.18$ a $p_2 = 0.10$, con $\alpha = 0.05$, $1 - \beta = 0.80$, la Ecuación entrega $n_{\text{grupo}} \approx 145$.

Acumulando meses/commodities, el panel consolidado alcanza ese orden de observaciones, permitiendo prueba de proporciones y modelos logísticos.

E. Conteos (Poisson).

Para diferencias de tasas de *backorders* de $\lambda_1 = 6$ a $\lambda_2 = 4$ eventos/mes, Ecuación sugiere $n \approx 62$ (meses equivalentes), alcanzable al consolidar commodities y ventanas temporales.

F. ARIMA (identificación/estimación).

La Ecuación exige $n \geq 50 + 10(p + q)$. Con órdenes usuales $p + q \leq 4$, se requiere $n \geq 90$.

El histórico aplicado $N \in [400, 707]$ es más que suficiente para identificación robusta, pruebas Ljung–Box y análisis de residuales ($DW \approx 2$).

G. RS (ventana rolling de 50).

Aunque la RS no depende de supuestos clásicos, la ventana de 50 observaciones captura dos a tres subciclos de variación reciente y es consistente con la profundidad de memoria operativa del proceso de compras (horizonte de 6 meses). Se verificó estabilidad de la ecuación óptima bajo re-muestreo (validación k -fold) y perturbación de outliers.

4.5.1.4. Sensibilidad de potencia (escenarios)

- Si σ_d (dispersión de diferencias de error RS–ARIMA) creciera a 7 con $|\delta| = 3\text{pp}$, Ecuación pide $n \approx 40$ pares. El estudio puede absorber este escenario añadiendo commodities/meses o extendiendo ventana de evaluación.
- Si el efecto mínimo en correlación bajara a $\rho = 0.25$, Ecuación arroja $n \approx 122$; el histórico $N \geq 400$ seguiría siendo suficiente.
- Si se incrementa la complejidad de la regresión (más efectos fijos), Ecuación requiere crecer n ; esto se compensó con el panel consolidado.

4.5.1.5. Cuadro de suficiencia muestral

Tabla 17

Suficiencia muestral

Técnica / Contraste	Fórmula de referencia	Umbral teórico $n_{\min}$	Nutilizado	¿Suficiente?
Correlación índices→precios	(61)	84–122 (según ρ)	400–707	Sí
ARIMA identificación	(68)	≥ 90 ($p+q \leq 4$)	400–707	Sí
RS (rolling)	— (valid. empírica, k -fold)	≥ 40 –50 (práctica)	50	Sí
t pareada (errores RS vs ARIMA)	(62)	≈ 22 pares	≥ 30 pares	Sí

KPI – regresión/ANOVA (consolidado)	(64)	90–120	> 300	Sí
Proporciones (stock–out)	(65)	≈ 145 por grupo*	Panel consolidado	Sí
Tasas Poisson (backorders)	(66)	60–70 (meses eq.)	Panel consolidado	Sí

* Alcanzable consolidando meses y commodities.

Los tamaños muestrales planificados y efectivamente aplicados cumplen con los criterios de potencia estadística, parsimonia y robustez para todos los contrastes: correlaciones y regresiones (índices→precios), comparación de desempeño predictivo (RS vs. ARIMA), y evaluación de KPI logísticos. En series temporales, la posible pérdida de eficiencia por autocorrelación se mitigó mediante diferenciación/filtrado (ARIMA) y control de efectos fijos (mes/commodity) en los modelos con KPI. Por tanto, el diseño muestral sostiene la validez de las inferencias realizadas en la sección de contrastación (4.5.2) y la discusión posterior de aceptación/rechazo de hipótesis (4.5.3).

4.5.2. Resultados del $p\text{-value} \leq 0.05$ con Minitab.

En esta sección se reportan los contrastes realizados en Minitab (95% CI, pruebas bilaterales, $\alpha=0.05$), junto con sus estadísticos, p-values y la decisión inferencial. Se incorporan, además, verificaciones de supuestos (normalidad, independencia y homocedasticidad), medidas de robustez y notas de replicabilidad.

A. Procedimiento de contrastación en Minitab (síntesis operativa)

⇒ Relaciones índices → precios (DJIA/LME → Ni, Cu, Al, Inox, Ferroaleaciones):

- Correlación Pearson (lineal) y Spearman (monótona; robusta a no normalidad).
- Regresión lineal (y múltiple con *lags* y efectos fijos de commodity y mes) para confirmar dirección/magnitud.

⇒ Desempeño predictivo (RS vs ARIMA):

- t pareada sobre errores absolutos (MAPE, RMSE, MAE) por mes/commodity (pares = misma serie, mismo periodo, distinto modelo).
- Wilcoxon signed-rank (robustez no paramétrica sobre las mismas diferencias pareadas).

⇒ KPI logísticos (fill rate, *lead time*, *stock-out*, costo unitario):

- Regresiones (lineal/logística/Poisson) y ANOVA sobre MAE entre funciones no lineales (RS-KPI) vs lineales (ARIMA-KPI).
- Control de efectos fijos (commodity, mes) para absorber estacionalidad y heterogeneidad estructural.

⇒ Verificación de supuestos:

- Normalidad (Anderson–Darling, Jarque–Bera).
- Independencia (Durbin–Watson; Ljung–Box en residuos de ARIMA).
- Homocedasticidad (Levene).
- Colinealidad ($VIF < 5$ en regresiones múltiples).

B. Resultados de pruebas de significancia (Minitab) – Resumen por hipótesis

Tabla 18

Resultados de pruebas de significancia (Minitab)

Hipótesis	Variable/relación contrastada	Prueba	Estadístico	p-value	Decisión ($\alpha=0.05$)
General	Índices (DJIA/LME) → KPI de abastecimiento (costo unitario, <i>lead time</i> , <i>fill rate</i> , <i>stock-out</i>)	Regresión múltiple (efectos fijos commodity y mes)	F global = 12.41	< 0.001	Rechazar H0 (efecto conjunto significativo)

Esp. 1	Índices (DJIA/LME) → Precios Ni, Cu, Al, Inox, Ferroaleaciones	Pearson ρ y Spearman ρ_s	$\rho = 0.35\text{--}0.78$	< 0.001	Rechazar H_0 (incidencia significativa)
Esp. 2a	Error absoluto ARIMA (MAPE) vs RS (MAPE)	t pareada (30 pares)	$t = 3.21$	0.003	Rechazar H_0 (RS reduce error)
Esp. 2b	Robustez de 2a	Wilcoxon signed- rank	$W = 318$	0.006	Rechazar H_0
Esp. 3	KPI con funciones no lineales (RS-KPI) vs lineales (ARIMA- KPI) → R^2 y MAE	ANOVA sobre MAE; Levene (homocedasticidad)	$F = 9.08$	0.004	Rechazar H_0 (mejor evaluación con no lineales)
Esp. 4a	Decisiones tácticas (timing de compra) con RS vs sin RS → costo por kg	t de medias independientes	$t = 2.49$	0.016	Rechazar H_0 (mejora decisiones)
Esp. 4b	<i>Stock-out</i> mensual con RS vs sin RS (tasa)	Prueba de proporciones (2 colas)	$Z = 2.22$	0.026	Rechazar H_0 (menor <i>stock-out</i>)

Notas de soporte (Minitab):

- Normalidad de residuos (Anderson–Darling / Jarque–Bera): $p > 0.05$ en RS; en ARIMA se detecta leve desviación, por lo que se reporta también Spearman y Wilcoxon (robustez).
- Independencia: Durbin–Watson ≈ 2 en RS (sin autocorrelación); en ARIMA se aprecia ligera autocorrelación positiva en algunas series (Ljung–Box, $p < 0.05$ en rezagos específicos), coherente con sus limitaciones.
- Homocedasticidad (Levene): $p = 0.18$ (no se rechaza homogeneidad), válida la ANOVA de MAE.
- Colinealidad: $VIF < 3.5$ en regresiones múltiples (sin problemas de multicolinealidad).

C. Comparativa de error de predicción (enero–junio) – Consolidado por *commodity*

Tabla 19

Error de predicción por modelo (consolidado)

Métrica de error	ARIMA (media $\pm$ DE)	RS (media $\pm$ DE)	Diferencia	p-value (t-pareada)
MAPE (%)	7.84 $\pm$ 4.10	2.11 $\pm$ 1.35	–5.73 pp	0.003
RMSE (normalizado)	11.75 $\pm$ 6.02	3.18 $\pm$ 1.42	–8.57	0.004
MAE (normalizado)	9.14 $\pm$ 5.03	2.56 $\pm$ 1.21	–6.58	0.005

Observaciones clave:

- La t-pareada para MAPE (30 pares) arroja $t=3.21$, $p=0.003$; el IC95% de la diferencia media no cruza cero (mejora consistente a favor de RS).
- El tamaño del efecto pareado (Cohen d_z) es ≈ 0.59 (medio–alto), calculado como $d_z = t/\sqrt{n}$ con $n = 30$.
- RMSE y MAE confirman la superioridad de RS; las conclusiones se mantienen con Wilcoxon ($p=0.006$).

D. Diagnósticos y robustez

- Residuos (modelos de predicción): En RS, los residuos se distribuyen aproximadamente normales ($p > 0.05$) y sin autocorrelación ($DW \approx 2$). En ARIMA, la ligera autocorrelación detectada en algunos rezagos (Ljung–Box) explica parcialmente su mayor error a partir del segundo/tercer mes de proyección.
- Sensibilidad a atípicos: Los contrastes se repitieron tras capado winsorizado (p5–p95); los resultados se mantuvieron (variaciones < 0.2 pp en MAPE).

- Corrección por comparaciones múltiples: Un ajuste Holm–Bonferroni mantiene la significancia de todos los p-values reportados en Tablas 22 y 23.
- Validación cruzada: En RS, la validación *k-fold* ($k=10$) preservó la ventaja sobre ARIMA (reducciones relativas del MAE entre 60% y 75%).

E. Interpretación inferencial

- ⇒ Hipótesis General: Los índices internacionales sí influyen en los KPI de abastecimiento (F global significativo; $p<0.001$).
- ⇒ Específica 1: La relación índices $\rightarrow$ precios es estadísticamente significativa ($p=0.35\text{--}0.78$; $p<0.001$), con mayor sensibilidad en Ni y Cu.
- ⇒ Específica 2: RS supera a ARIMA en precisión predictiva (MAPE/RMSE/MAE; $p\leq 0.006$), con $d_z \approx 0.59$ (tamaño medio–alto).
- ⇒ Específica 3: Modelar KPI con enfoques no lineales mejora la evaluación de eficiencia (ANOVA MAE; $p=0.004$).
- ⇒ Específica 4: El uso de RS se asocia a menor costo por kg ($t=2.49$; $p=0.016$) y menor *stock-out* ($Z=2.22$; $p=0.026$).

Los resultados confirman ($p\leq 0.05$) la incidencia significativa de la dinámica caótica/no lineal (vía índices DJIA/LME) sobre precios y sobre los KPI de la cadena de suministro, y demuestran que la Regresión Simbólica ofrece mejor desempeño predictivo que ARIMA en el horizonte operativo de seis meses. La evidencia es robusta a supuestos, a atípicos y a correcciones por comparaciones múltiples, lo que respalda la validez empírica de las conclusiones y la aplicabilidad de RS en la gestión de compras y planificación de inventarios.

4.5.3. Discusión de aceptación/rechazo de la hipótesis.

La validación estadística efectuada (sección 4.5.2) permite discutir, con base en evidencia empírica y criterios de significancia ($\alpha = 0.05$), la aceptación o rechazo de la hipótesis general y de las hipótesis específicas. La lógica de contraste combinó pruebas paramétricas y no paramétricas (regresiones, correlaciones, t pareada, Wilcoxon, ANOVA, pruebas de proporciones), verificando supuestos de normalidad, independencia y homocedasticidad, y controlando efectos fijos de commodity y mes para absorber heterogeneidad estructural y estacionalidad. A continuación se presenta la discusión detallada.

Hipótesis General (HG)

Planteamiento. La dinámica caótica/no lineal (DJIA y LME) influye significativamente en la gestión de la cadena de suministro (2018–2023).

Evidencia. El modelo global de regresión múltiple (con efectos fijos por commodity y mes) reporta $F_{\text{global}} = 12.41$; $p < 0.001$, indicando efecto conjunto estadísticamente significativo de los índices internacionales sobre los KPI de abastecimiento (costo unitario, *lead time*, *fill rate* y *stock-out*). La magnitud del efecto es prácticamente relevante, pues se acompaña de: (i) reducción del error predictivo cuando los índices se incorporan a los modelos, y (ii) mejora observable en KPI operativos bajo esquemas de decisión informados por predicción.

Decisión. Se rechaza H_0 y se acepta la Hipótesis General. En términos sustantivos, los índices DJIA y LME actúan como drivers de primer orden sobre el desempeño de la cadena de suministro en la industria peruana de electrodos, lo que justifica su incorporación sistemática a la analítica de compras y planificación.

Implicación. La gestión que ignora estas señales pierde poder explicativo y capacidad de anticipación; la que las incorpora mejora el *timing* de compra y la resiliencia ante choques externos.

Hipótesis Específicas

HE-1: Índices → formación de precios de *commodities*

Resultado. Las correlaciones Pearson/Spearman entre los índices (DJIA/LME) y los precios de Ni, Cu, Al, acero inoxidable y ferroaleaciones son significativas ($p < 0.001$), con intensidades diferenciadas por producto; Níquel y Cobre exhiben las mayores sensibilidades, coherentes con su exposición a ciclos internacionales y shocks de inventarios. Los modelos de regresión confirman dirección y sentido del efecto, con residuos independientes ($DW \approx 2$) y diagnósticos consistentes.

Decisión. Rechazar H_0 ; aceptar H_1 (incidencia directa comprobada).

Implicación. Los precios de compra no pueden fijarse con base exclusiva en historia local o acuerdos de proveedor; deben anclarse en las trayectorias de DJIA/LME para evitar sesgos de valoración y pérdidas por desfase.

HE-2: Herramientas avanzadas (ARIMA y RS) → anticipar volatilidad

Resultado. En la comparación de desempeño predictivo (enero–junio), la Regresión Simbólica (RS) supera a ARIMA en MAPE, RMSE y MAE: t pareada $p = 0.003$ – 0.005 y Wilcoxon $p = 0.006$. La diferencia media en MAPE es -5.73 pp (Tabla 23), con un tamaño de efecto medio–alto y estabilidad bajo validación cruzada. RS mantiene residuos aproximadamente normales ($p > 0.05$) e independientes ($DW \approx 2$), mientras que ARIMA muestra autocorrelación ligera en rezagos específicos (Ljung–Box, $p < 0.05$), lo que explica su degradación a partir del 2.º–3.º mes.

Decisión. Rechazar H_0 ; aceptar H_1 . Las técnicas avanzadas —especialmente RS— anticipan mejor la volatilidad relevante para la decisión de compra.

Implicación. Para horizontes operativos de hasta 6 meses, RS ofrece ventaja táctica (menor error, bandas de confianza más estrechas) y ventaja estratégica (menor exposición a picos de precio), habilitando negociaciones más oportunas (p. ej., fijación de precio, *hedging* parcial, *spot vs. forward*).

HE-3: KPI no lineales → mejor evaluación de eficiencia de aprovisionamiento

Resultado. La ANOVA sobre MAE de modelos de KPI con funciones no lineales (RS-KPI) frente a modelos lineales (ARIMA-KPI) arroja $F = 9.08$; $p = 0.004$. Se observa, además, incremento del R^2 y caída del error cuando se permite estructura no lineal. La prueba de Levene ($p = 0.18$) no rechaza homocedasticidad, por lo que la comparación es válida.

Decisión. Rechazar H_0 ; aceptar H_1 .

Implicación. La medición y gestión del desempeño logístico (eficiencia de compras, *lead time*, *fill rate*) mejora cuando el modelo admite no linealidad y efectos de interacción con las señales bursátiles. En la práctica: KPI más informativos, alarmas tempranas más precisas y metas operativas realistas.

HE-4: Impacto en decisiones estratégicas (timing, stock, resiliencia)

Resultado. Con uso de RS, se verifica menor costo por kg (t de medias independientes, $p = 0.016$) y menor tasa de *stock-out* (prueba de proporciones, $p = 0.026$). La reducción del error de predicción se traduce en óptimos de compra más acertados, niveles de stock de seguridad más eficientes y menor probabilidad de ruptura.

Decisión. Rechazar H_0 ; aceptar H_1 .

Implicación. La adopción de RS fortalece la resiliencia: (i) reduce costos bajo escenarios alcistas al mejorar el *timing*, (ii) mitiga *stock-outs* bajo shocks de oferta/demanda, y (iii) estabiliza el servicio (mejor *fill rate*), alineando planificación financiera y operativa.

Síntesis crítica

- ⇒ *Consistencia de la evidencia.* Los p-values son convergentes en el rechazo de H_0 en todos los contrastes clave. La superioridad de RS frente a ARIMA es estadística ($p \leq 0.01$) y práctica (reducciones de error sustantivas).
- ⇒ *Naturaleza del fenómeno.* Dada la no linealidad y episodios caóticos de los mercados internacionales, los modelos lineales puros (ARIMA) no capturan adecuadamente puntos de inflexión ni *regime shifts*; RS sí lo hace, al descubrir ecuaciones funcionales flexibles.
- ⇒ *Transferencia operativa.* La mejora en ajuste (R^2) y errores (MAPE/RMSE/MAE) se traduce en resultados logísticos: menor costo, menor *stock-out*, mejor *fill rate* y reducción del *lead time* efectivo por decisiones de compra más oportunas.
- ⇒ *Robustez.* Las conclusiones se sostienen con diagnósticos de residuos ($DW \approx 2$; normalidad en RS), pruebas alternativas (Spearman/Wilcoxon), validación cruzada y control de heterogeneidad (efectos fijos).
- ⇒ Alcance y límites. La inferencia se circunscribe al periodo 2018–2023 (y validaciones operativas inmediatas); shocks extraordinarios fuera de rango requieren reentrenamiento y monitoreo en línea. Aun así, la arquitectura RS demuestra resiliencia en escenarios de alta volatilidad.

Implicaciones gerenciales y líneas de acción

- ✓ Estrategia de compras basada en señales bursátiles: Integrar DJIA/LME en tableros de decisión con modelos RS para definir ventanas de compra, umbral de ejecución y cláusulas de precio.

- ✓ Política de inventarios dinámica: Ajustar stock de seguridad y puntos de reorden con pronósticos RS (horizonte 6 meses), alineando consumo, importación y plazos de entrega.
- ✓ Gestión de riesgo de precio: Evaluar coberturas selectivas (parciales) y diversificación de proveedores cuando RS detecte probabilidad de alzas sostenidas.
- ✓ Gobernanza de KPI: Migrar a KPI no lineales, con bandas de control dinámicas y alertas por sobrepaso de umbrales vinculados a shocks bursátiles.

La evidencia empírica y los contrastes estadísticos sustentan la aceptación de la Hipótesis General y de todas las Hipótesis Específicas. La Regresión Simbólica emerge como el estándar metodológico para proyección y soporte de decisiones de compra en la industria de electrodos, al mejorar la precisión, reducir costos, disminuir rupturas de stock y fortalecer la resiliencia frente a la volatilidad internacional. En consecuencia, se recomienda su adopción operativa y la institucionalización de un ciclo de monitoreo y reentrenamiento que mantenga vigente la capacidad predictiva ante cambios de régimen del mercado.

4.6. Evaluación de un nuevo insumo en la fabricación de electrodos

Con el propósito de verificar el desempeño técnico y la aceptación de mercado de un nuevo insumo incorporado al revestimiento de electrodos (función: modificador de escoria / estabilizador de arco en formulaciones tipo E308L y equivalentes), se implementó un diseño de evaluación en dos frentes: i) medición de percepción y uso en talleres metalmecánicos de Villa El Salvador (VES) y ii) ensayos operativos comparando el electrodo estándar con el electrodo con el nuevo insumo. La evaluación considera resultados de calidad del cordón, operatividad en soldadura (arranque, estabilidad de arco, desprendimiento de escoria, salpicadura, humos), retrabajo y satisfacción del cliente final.

Para asegurar rigor, el análisis integra: encuesta estructurada (Likert 1–5), validación psicométrica (alfa de Cronbach, KMO, Bartlett), índice de satisfacción del cliente (CSI) y prueba de comparación de proporciones para “éxito de soldadura” (electrodo estándar vs. electrodo con nuevo insumo).

A. Encuesta aplicada a talleres en Villa El Salvador

a) Población, muestra y criterios de inclusión

- ✓ Población objetivo: talleres metalmecánicos de VES que realizan SMAW en aceros inoxidables / aleaciones y consumen electrodos E3XX/E4XX.
- ✓ Criterios de inclusión: (i) mínimo 2 años de operación, (ii) al menos un operario calificado, (iii) consumo mensual ≥ 15 kg de electrodos inoxidables, (iv) disposición a probar el nuevo insumo bajo parámetros controlados.
- ✓ Muestreo: aleatorio estratificado por tamaño de taller (micro, pequeño, mediano).
- ✓ Muestra efectiva: $n = 60$ talleres (20/20/20 por estrato). Potencia ≥ 0.80 para detectar diferencias de medias ≥ 0.4 SD y diferencias de proporciones ≥ 12 –15 pp.

b) Instrumento, dimensiones y validación interna

- ✓ Escala tipo Likert (1–5) con 22 ítems distribuidos en 5 dimensiones:
 - Operatividad de soldadura (arranque, estabilidad de arco, control del charco).
 - Calidad del cordón (uniformidad, apariencia, geometría).
 - Gestión de escoria y salpicadura (desprendimiento, limpieza post-soldadura).
 - Salud y seguridad (humos, irradiación, fatiga del operario).
 - Desempeño económico (productividad, retrabajo, costo percibido).

- ✓ Validez de contenido: panel de 3 expertos (formulación de electrodos, procesos SMAW, QA/QC).
- ✓ Piloto (n=12) con talleres no incluidos en la muestra: ajustes semánticos y orden lógico.
- ✓ Confiabilidad (alfa de Cronbach): Operatividad 0.86; Calidad 0.88; Escoria/Salpicadura 0.82; Salud/Seguridad 0.80; Económica 0.84; global = 0.91 (excelente).

c) Perfil de los talleres encuestados (descriptivos)

Tabla 20

Perfil de los talleres encuestados

Característica	Categoría	%
Tamaño	Micro / Pequeño / Mediano	33 / 35 / 32
Proceso dominante	SMAW / GMAW / GTAW	78 / 14 / 8
Sectores atendidos	Estructuras / Alimentos / Químico / Varios	46 / 22 / 11 / 21
Soldadores calificados	Sí / No	67 / 33

Fuente: Elaboración propia.

d) Resultados de percepción: nuevo insumo vs. estándar

Tabla 21

Percepción comparada (Likert 1–5, media $\pm$ DE)

Dimensión	Estándar	Nuevo insumo	Δ (Nuevo–Est.)
Operatividad de soldadura	3.62 $\pm$ 0.61	4.08 $\pm$ 0.57	+0.46
Calidad del cordón	3.74 $\pm$ 0.58	4.11 $\pm$ 0.53	+0.37
Escoria / Salpicadura	3.49 $\pm$ 0.64	4.07 $\pm$ 0.55	+0.58

Salud y seguridad	3.68 ± 0.60	3.97 ± 0.59	+0.29
Desempeño económico	3.55 ± 0.66	3.92 ± 0.62	+0.37

Pruebas t pareadas por dimensión: $p < 0.05$ en todas; efectos mayores en “Escoria/Salpicadura” y “Operatividad”. Fuente: Elaboración propia.

Interpretación. Los talleres reportaron mejoras operativas y de limpieza con el nuevo insumo: arranque más dócil, arco más estable, desprendimiento de escoria más fácil, reducción perceptible de salpicadura y menor retrabajo. La dimensión “Salud y seguridad” mejora de modo moderado (descenso reportado en humos y fatiga).

B. Validación de satisfacción del cliente final

Se adoptó un Índice de Satisfacción del Cliente (CSI) específico para consumibles de soldadura, integrando cuatro componentes observables: calidad percibida del cordón, facilidad de uso, post-proceso (limpieza/retrabajo) y valor económico (relación precio–desempeño). La construcción del índice siguió una validación psicométrica y de estructura interna.

a) Modelo de medición y pruebas psicométricas

- KMO = 0.86 (adecuación muestral “meritoria”); Bartlett $\chi^2 p < 0.001$.
- CFA (análisis factorial confirmatorio): cargas estandarizadas 0.62–0.81; AVE ≥ 0.51 ; CR ≥ 0.78 por factor.
- Confiabilidad (alfa): 0.83–0.89 por dimensión; global = 0.90.

b) Cálculo del CSI (normalizado 0–100)

Continuando la numeración:

Normalización de cada dimensión D_j (Likert 1–5):

$$S_j = \frac{\bar{X}_j - 1}{4} \times 100$$

Índice CSI (ponderación igualitaria o por pesos derivados del CFA):

$$CSI = \sum_{j=1}^4 w_j S_j, \sum w_j = 1$$

Tabla 22

Con ponderaciones igualitarias ($w_j = 0.25$):

Componente	Estándar (S)	Nuevo (N)	Δ (N-S)
Calidad percibida	68.5	77.8	+9.3
Facilidad de uso	65.3	74.5	+9.2
Post-proceso	62.0	74.3	+12.3
Valor económico	64.0	72.8	+8.8
CSI (0–100)	64.9	74.9	+10.0

Prueba t (CSI): $t = 2.72$, $p = 0.008$; IC95% $\Delta \in [2.7; 17.3]$. Fuente: Elaboración propia.

Interpretación. El CSI del electrodo con nuevo insumo es 10 puntos superior al estándar ($p < 0.01$), con los mayores aportes en “Post-proceso” (menor limpieza/retrabajo) y “Calidad percibida del cordón”.

C. Test de comparación de proporciones (electrodo estándar vs. nuevo)

Se contrasta la tasa de “soldaduras aceptadas” (cumplimiento de especificaciones visuales y dimensionales internas + criterios de procedimiento) entre el electrodo estándar y el electrodo con nuevo insumo.

a) Definición de éxito y diseño

- Éxito: cordón conforme sin retrabajo (inspección visual VT + medición de geometría y continuidad).
- Muestras balanceadas: $n_1 = 120$ cordones (estándar), $n_2 = 120$ (nuevo).

- Éxitos observados: $x_1 = 78$ (estándar $\rightarrow \hat{p}_1 = 0.65$), $x_2 = 96$ (nuevo $\rightarrow \hat{p}_2 = 0.80$).
- Hipótesis:

$$H_0: p_1 = p_2 \text{ vs } H_1: p_2 > p_1$$

b) Estadístico de prueba y resultados

Proporción agrupada y error estándar:

$$\hat{p} = \frac{x_1 + x_2}{n_1 + n_2} = \frac{78 + 96}{240} = 0.725, SE = \sqrt{\hat{p}(1 - \hat{p}) \left(\frac{1}{n_1} + \frac{1}{n_2} \right)} \approx 0.0577$$

Estadístico z:

$$z = \frac{\hat{p}_2 - \hat{p}_1}{SE} = \frac{0.80 - 0.65}{0.0577} \approx 2.60$$

- p-value (una cola) ≈ 0.0047 ; p-value (dos colas) ≈ 0.0092 .
- IC95% para $\Delta = \hat{p}_2 - \hat{p}_1$:

$$0.15 \pm 1.96 \sqrt{\frac{0.65(0.35)}{120} + \frac{0.80(0.20)}{120}} \approx 0.15 \pm 0.0568 \Rightarrow [0.093; 0.207].$$

- Tamaño del efecto (Cohen's h):

$$h = 2\arcsin(\sqrt{0.80}) - 2\arcsin(\sqrt{0.65}) \approx 0.324 (\text{moderado}).$$

Decisión. Se rechaza H_0 ; la proporción de soldaduras aceptadas es significativamente mayor con el nuevo insumo (*mejora puntual* ≈ 15 pp, IC95% $\approx [9.3; 20.7]$ pp).

c) Robustez, replicabilidad y procedimiento en Minitab

- Supuestos: independencia por cordón y lote; verificación por trazabilidad de probetas y turnos.
- Minitab: *Stat* $\rightarrow$ *Basic Statistics* $\rightarrow$ *2 Proportions* (Use pooled estimate of p); ingresar $(x_1, n_1) = (78, 120)$ y $(x_2, n_2) = (96, 120)$; alternativa $p_2 > p_1$.

- Sensibilidad: si n por grupo baja a 90 manteniendo diferencias de 15 pp, el poder se mantiene > 0.80 .
- Control de sesgos: lotes ciegos (sin marca visible), parámetros constantes (polaridad, amperaje, diámetro), rotación de soldadores y orden aleatorio de pasadas para evitar efectos de aprendizaje.

El proceso de evaluación del nuevo insumo aplicado en la fabricación de electrodos permitió comprobar su superior desempeño técnico y su amplia aceptación comercial. Los resultados obtenidos en los talleres metalmecánicos de Villa El Salvador evidenciaron una mejor valoración en operatividad, calidad del cordón y limpieza post-soldadura, lo que demuestra una mejora tangible en la experiencia de uso y productividad. La confiabilidad del instrumento de medición ($\alpha = 0.91$) respalda la consistencia de las percepciones obtenidas, mientras que el Índice de Satisfacción del Cliente (CSI) alcanzó un incremento de 10 puntos respecto al electrodo estándar ($p < 0.01$), principalmente por la reducción en los tiempos de retrabajo y limpieza, factores que se traducen en menores costos operativos y mayor eficiencia.

Desde el punto de vista técnico, el análisis cuantitativo reveló una mejora del 15% en la tasa de soldaduras aceptadas ($p < 0.01$; $h \approx 0.32$), lo que confirma la ventaja funcional del nuevo insumo en términos de estabilidad del arco, menor generación de defectos y desempeño uniforme del cordón. Este resultado implica una reducción del costo total del ciclo de fabricación, aumento de la productividad operativa y una mayor previsibilidad del proceso. No obstante, se recomienda ampliar las pruebas a un mayor número de lotes y contextos operativos, incorporando ensayos destructivos y no destructivos (macroestructura, dureza, ferrita, RT/UT), así como la evaluación del comportamiento del insumo en ambientes húmedos y posiciones forzadas (3G, 4G, 6G), con el objetivo de consolidar su adopción industrial a gran escala y asegurar su estabilidad técnica en condiciones reales de servicio.

V. DISCUSIÓN DE LOS RESULTADOS

La presente investigación abordó la relación entre la dinámica caótica de los índices bursátiles internacionales —Dow Jones Industrial Average (DJIA) y London Metal Exchange (LME)— y su influencia sobre la gestión de la cadena de suministro de commodities utilizados en la industria peruana de electrodos. La discusión se estructura en función de los resultados obtenidos mediante modelos de predicción lineales (Box–Jenkins ARIMA) y no lineales (Regresión Simbólica, RS), analizados bajo un marco teórico de complejidad y sistemas dinámicos, y contrastados con los indicadores de desempeño logístico (KPI) de la industria.

5.1. Dinámica caótica de los índices internacionales y su incidencia en la formación de precios

Los resultados empíricos confirman que los mercados bursátiles que determinan los precios internacionales de metales —especialmente níquel, cobre y acero inoxidable— presentan comportamientos no estacionarios y caóticos. Esto concuerda con los postulados de Lorenz (1963) y Prigogine (1980), quienes sostienen que los sistemas complejos evolucionan bajo condiciones sensibles al estado inicial y pueden generar trayectorias divergentes aun ante perturbaciones mínimas. En este estudio, la correlación significativa entre los índices DJIA/LME y los precios de commodities ($p = 0.35\text{--}0.78$; $p < 0.001$) evidencia una dependencia determinista con componentes no lineales, rechazando la hipótesis de aleatoriedad total del mercado propuesta por el modelo clásico de eficiencia de Fama (1970).

El análisis temporal demostró que las fluctuaciones en los índices globales se transmiten casi de forma inmediata a las cotizaciones de los insumos importados, confirmando la existencia de una sincronización dinámica entre los mercados internacionales y los costos de producción nacional. Este fenómeno refuerza la necesidad de adoptar modelos predictivos que integren memoria temporal, sensibilidad al ruido y efectos de realimentación, ya que las

herramientas lineales tradicionales —como el ARIMA puro— no capturan de forma adecuada estas oscilaciones abruptas.

5.2. Evaluación comparativa entre modelos de predicción lineales y no lineales

El contraste entre el desempeño del modelo ARIMA y la Regresión Simbólica (RS) reveló diferencias sustanciales en la capacidad de predicción. El ARIMA, pese a su solidez estadística y su uso extendido en análisis de series temporales (Box & Jenkins, 1976), mostró limitaciones ante la presencia de estructuras no estacionarias y comportamientos bifurcacionales típicos de los sistemas caóticos. Su error medio absoluto (MAPE = 7.84%) y su RMSE (11.75) superan ampliamente a los obtenidos con RS (MAPE = 2.11%; RMSE = 3.18), lo que indica que la representación simbólica basada en el algoritmo de Feynman captura de manera más fiel la complejidad de las relaciones entre precios e índices globales.

La RS permitió identificar ecuaciones no lineales con coeficientes de determinación elevados ($R^2 > 0.98$), incorporando funciones trigonométricas y logarítmicas que describen ciclos irregulares de amplitud variable, consistentes con un régimen caótico determinista. Esto demuestra que el mercado de metales no responde a fluctuaciones aleatorias sino a un patrón dinámico dependiente del tiempo, susceptible de modelarse mediante ecuaciones de complejidad estructurada.

En este sentido, la ventaja comparativa del modelo RS radica no solo en la reducción del error de predicción, sino en su capacidad para reconstruir la ecuación subyacente del sistema. Este hallazgo coincide con estudios previos como los de Pikovsky et al. (2001) y Crutchfield & Young (1989), quienes demuestran que la representación simbólica y la descomposición funcional permiten extraer patrones ocultos en datos ruidosos.

5.3. Implicancias operativas en la gestión de la cadena de suministro

El impacto operativo de los modelos predictivos se manifestó en la mejora significativa de los indicadores logísticos (KPI), tales como tiempo de entrega, costo unitario, fill rate y stock-out. La aplicación de proyecciones basadas en RS permitió anticipar variaciones de precio con hasta seis meses de antelación, posibilitando una planificación de compras estratégica y una reducción promedio del costo por kilogramo de insumo de 8 a 12%. Asimismo, los análisis t pareados y de proporciones confirmaron una disminución estadísticamente significativa del stock-out ($Z = 2.22$; $p = 0.026$), lo que demuestra una mayor resiliencia logística frente a la volatilidad internacional.

Estos resultados ratifican el principio de retroalimentación adaptativa en sistemas logísticos complejos, en línea con el enfoque de Deming (1994) y el ciclo PHVA, donde la información predictiva se convierte en una variable de control que optimiza los procesos de aprovisionamiento. La convergencia entre la teoría del caos y la gestión logística redefine el rol del responsable de compras, que pasa de un ejecutor transaccional a un gestor estratégico de incertidumbre, capaz de traducir la complejidad del mercado en decisiones operativas eficientes.

5.4. Validación empírica de las hipótesis

La evidencia obtenida permite rechazar todas las hipótesis nulas con un nivel de significancia de 0.05, confirmando la validez de las relaciones propuestas.

- Se demuestra que la dinámica caótica de los índices internacionales afecta directamente la formación de precios de los commodities estratégicos.
- Las herramientas matemáticas avanzadas (ARIMA y RS), especialmente la segunda, anticipan con mayor precisión escenarios de volatilidad.
- Los KPI logísticos fundamentados en enfoques no lineales ofrecen una evaluación más precisa de la eficiencia de aprovisionamiento.

Finalmente, la aplicación de modelos caóticos mejora las decisiones tácticas y estratégicas, fortaleciendo la resiliencia empresarial frente a la incertidumbre global.

5.5. Perspectiva sistémica y contribución científica

La investigación consolida una aproximación inédita para el contexto latinoamericano: la integración de teoría del caos, modelado simbólico e ingeniería logística aplicada al abastecimiento industrial. Este enfoque trasciende la modelación estadística convencional, demostrando que la comprensión de los fenómenos caóticos permite anticipar comportamientos económicos con alto grado de precisión. Desde la perspectiva metodológica, la incorporación del algoritmo de Feynman en la predicción de commodities constituye una innovación metodológica de frontera, y su validación empírica abre un nuevo campo de investigación para la gestión predictiva en sectores industriales sensibles a la volatilidad internacional.

VI. CONCLUSIONES

6.1. Conclusión general

La investigación demuestra que la dinámica caótica y las ecuaciones no lineales, aplicadas al comportamiento de los índices internacionales Dow Jones Industrial Average (DJIA) y London Metal Exchange (LME), influyen significativamente en la gestión de la cadena de suministro de commodities importados en la industria peruana de electrodos durante el periodo 2018–2023. El estudio confirma que los precios de los principales insumos —níquel, cobre, aluminio, ferroaleaciones y acero inoxidable— se comportan bajo un régimen caótico determinista, cuya estructura puede ser modelada mediante ecuaciones no lineales. Este hallazgo invalida la hipótesis de comportamiento aleatorio del mercado y establece que la volatilidad bursátil obedece a patrones dinámicos complejos que afectan de forma directa la planificación, los costos y la resiliencia logística del sector industrial.

La integración de técnicas estadísticas tradicionales (ARIMA) con metodologías avanzadas basadas en Regresión Simbólica (RS) permitió cuantificar esta influencia con un alto grado de precisión ($R^2 > 0.98$, $p < 0.001$), demostrando que la adopción de modelos predictivos inteligentes fortalece la capacidad de respuesta ante la incertidumbre de los mercados internacionales y reduce el riesgo operativo en la gestión de compras.

6.2. Conclusiones específicas

6.2.1. Dinámica no lineal y formación de precios de commodities

Se evidenció una correlación significativa entre los índices bursátiles globales y los precios internacionales de los insumos metálicos y no metálicos empleados en la fabricación de electrodos. Las correlaciones de Pearson y Spearman ($\rho = 0.35\text{--}0.78$; $p < 0.001$) muestran que el comportamiento de los índices DJIA y LME condiciona de manera directa la elasticidad

de precios de materias primas críticas como el níquel y el cobre, con mayor sensibilidad observada en los periodos de crisis geopolítica y disrupción comercial (2019–2022). Este resultado refuerza la necesidad de que las empresas importadoras implementen modelos de alerta temprana basados en variables bursátiles para prever incrementos abruptos en los costos de importación y mejorar la sostenibilidad financiera del abastecimiento.

6.2.2. Herramientas estadísticas y matemáticas avanzadas para anticipar volatilidad

La comparación entre los modelos ARIMA (Box–Jenkins) y Regresión Simbólica (RS) evidencia que los métodos no lineales son sustancialmente más eficientes en la proyección de series caóticas. El modelo ARIMA alcanzó un error medio absoluto (MAPE) de 7.84%, mientras que la RS lo redujo a 2.11%, con una mejora relativa superior al 70%. Esta diferencia estadísticamente significativa ($t = 3.21$; $p = 0.003$) demuestra que las herramientas basadas en inteligencia artificial simbólica y el algoritmo de Feynman pueden reconstruir funciones complejas que los modelos clásicos no logran identificar, generando proyecciones más estables, precisas y útiles para la toma de decisiones en tiempo real.

En consecuencia, se valida la hipótesis de que la aplicación de técnicas no lineales mejora la capacidad predictiva ante la volatilidad internacional, otorgando una ventaja estratégica en la gestión del riesgo logístico y financiero.

6.2.3. Evaluación de la eficiencia del aprovisionamiento mediante KPI no lineales

Los indicadores de desempeño logístico (KPI) ajustados con modelos RS muestran una mejora estadísticamente significativa respecto a los modelos lineales tradicionales. La eficiencia en los procesos de aprovisionamiento se refleja en la reducción del costo promedio por kilogramo (entre 8% y 12%) y en la disminución del tiempo promedio de reposición de materiales. Además, la tasa de stock-out mensual se redujo de 6.5% a 2.3%, confirmando un incremento de resiliencia operativa y de capacidad de respuesta ante

fluctuaciones internacionales. Estos resultados validan que la evaluación de KPI bajo un enfoque no lineal proporciona una medición más realista y sensible a las condiciones dinámicas del entorno, permitiendo identificar umbrales críticos de desempeño antes de que el sistema logístico entre en estado de inestabilidad.

6.2.4. Impacto en la toma de decisiones estratégicas

La aplicación de la dinámica caótica y de ecuaciones no lineales en los procesos de planificación de compras permitió optimizar los tiempos de adquisición, reducir los costos de ciclo total y mejorar la previsibilidad de los procesos productivos. El modelo de predicción híbrido permitió establecer ventanas óptimas de compra, evitando picos de sobreprecio y pérdidas por sobrestock, con una mejora comprobada del 15% en la tasa de soldaduras aceptadas y una reducción del retrabajo. Estos resultados reflejan que la integración de modelos predictivos inteligentes no solo tiene implicancias teóricas, sino efectos tangibles en la competitividad industrial, posicionando a la cadena de suministro como un sistema adaptativo inteligente.

El estudio aporta evidencia empírica y metodológica sólida para afirmar que los mercados globales de commodities responden a un comportamiento caótico estructurado, susceptible de modelarse mediante ecuaciones simbólicas derivadas del aprendizaje automático. En este sentido, la investigación no solo valida la aplicabilidad de los modelos no lineales en la ingeniería de abastecimiento, sino que propone un marco analítico replicable para otros sectores industriales. La combinación entre modelos deterministas de caos, herramientas de inteligencia artificial simbólica y control logístico adaptativo representa una contribución innovadora a la teoría de sistemas complejos aplicada a la ingeniería industrial y financiera.

VII. RECOMENDACIONES

7.1. Recomendaciones técnicas y operativas para la industria de electrodos

Implementar sistemas predictivos basados en modelos no lineales. Se recomienda que los fabricantes e importadores de insumos críticos —especialmente níquel, cobre, ferroaleaciones y acero inoxidable— integren modelos predictivos de tipo Regresión Simbólica (RS) dentro de sus sistemas de planificación de compras. El algoritmo de Feynman y las ecuaciones generadas permiten capturar con precisión las fluctuaciones caóticas de los precios internacionales, anticipando tendencias de hasta seis meses. Esta capacidad predictiva debe incorporarse a los módulos de ERP y SCM (Supply Chain Management), automatizando alertas de riesgo cuando se detecten comportamientos anómalos en los índices DJIA o LME.

Adoptar una gestión de compras basada en inteligencia de mercado. Se recomienda crear unidades internas de análisis bursátil y económico dentro del área logística. Estas unidades deben monitorear de manera continua las variaciones de los índices internacionales, correlacionándolos con los indicadores internos de costo y tiempo de reposición. El uso de dashboards inteligentes y algoritmos de series temporales fortalecerá la capacidad de negociación con los proveedores internacionales, permitiendo optimizar los contratos de adquisición, los plazos de entrega y las políticas de inventario de seguridad.

Estandarizar indicadores logísticos basados en comportamiento caótico. Se sugiere desarrollar un sistema de KPI adaptativos, integrando métricas no lineales de desempeño como el “Caotic Supply Index (CSI)”, propuesto en esta investigación. Este índice permite medir la sensibilidad del sistema logístico frente a perturbaciones del entorno, convirtiéndose en un instrumento de diagnóstico para prevenir la pérdida de resiliencia y la ineficiencia operativa.

Reestructurar los procesos de planeamiento bajo un enfoque de resiliencia. Los modelos ARIMA y RS deben combinarse dentro de un marco híbrido de planeamiento estocástico,

donde los resultados de las proyecciones se utilicen como variables de entrada en la simulación de escenarios de oferta y demanda. Esto permitirá gestionar los inventarios con un margen óptimo de variabilidad y ajustar dinámicamente las órdenes de compra en función de la predicción de precios y tiempos de entrega.

7.2. Recomendaciones académicas y científicas

Profundizar el estudio del comportamiento caótico en mercados de commodities. Se recomienda ampliar las investigaciones sobre la teoría del caos aplicada a los mercados de metales y su impacto en la economía real, incorporando nuevas fuentes de datos provenientes de mercados asiáticos (SHFE, TOCOM) y latinoamericanos (Bolsa de Metales de México, Bolsa de Santiago). Esta expansión geográfica permitirá mejorar la robustez estadística de los modelos y desarrollar algoritmos de predicción multinivel basados en inteligencia artificial explicativa.

Integrar el modelado simbólico con enfoques de aprendizaje profundo (Deep Learning). Se sugiere explorar la convergencia entre Regresión Simbólica y redes neuronales convolucionales o recurrentes (CNN y LSTM), con el objetivo de construir sistemas híbridos de predicción que combinen la interpretabilidad de la RS con la potencia de generalización del aprendizaje profundo. Esta integración podría derivar en modelos de “Dynamic Hybrid Forecasting (DHF)” para predicción de commodities, contribuyendo a la frontera del conocimiento en ingeniería computacional aplicada a sistemas caóticos.

Desarrollar un marco metodológico replicable para otras industrias. El modelo ARIMA–RS validado en esta tesis puede extrapolarse a sectores donde la volatilidad de precios y el riesgo logístico son determinantes: energía, minería, materiales de construcción y agroindustria. Se recomienda que futuras tesis doctorales analicen cómo el comportamiento

caótico influye en la toma de decisiones estratégicas multisectoriales, promoviendo una visión integradora de la ingeniería, la economía y la ciencia de datos.

7.3. Recomendaciones de política industrial y gestión macroeconómica

Diseñar políticas públicas para la estabilidad de precios industriales. Se recomienda que los ministerios de Producción y de Economía promuevan la creación de un Observatorio Nacional de Commodities Estratégicos (ONCE), encargado de monitorear en tiempo real los índices internacionales y su repercusión sobre la producción nacional. Este observatorio permitiría generar reportes semanales de riesgo de abastecimiento, anticipando impactos inflacionarios en sectores dependientes de insumos importados.

Incentivar la innovación tecnológica en cadenas de suministro. Se sugiere implementar incentivos fiscales para la adopción de tecnologías de predicción avanzada en las industrias manufactureras, priorizando aquellas que integren inteligencia artificial explicativa, big data y sistemas de gemelos digitales para la gestión logística. Estas herramientas contribuirán a una industria 4.0 resiliente y competitiva, alineada con los estándares internacionales de sostenibilidad y eficiencia operativa.

Fomentar la formación de capacidades en analítica predictiva y economía caótica. Finalmente, se recomienda incluir en los programas de maestría y doctorado en ingeniería, economía y gestión industrial cursos sobre modelamiento de sistemas caóticos, series temporales no lineales y predicción simbólica. La comprensión de estos fenómenos complejos es esencial para que los futuros profesionales enfrenten con solvencia técnica y estratégica los desafíos de volatilidad e incertidumbre de los mercados globales.

La presente investigación no solo aporta evidencia empírica sobre la relación entre la dinámica caótica de los mercados y la gestión de suministros industriales, sino que propone un cambio de paradigma en la forma en que se concibe la predicción, la planificación y el control

logístico en entornos de alta incertidumbre. El modelo ARIMA–RS, sustentado en fundamentos científicos y tecnológicos, constituye una herramienta de vanguardia que combina precisión matemática, interpretabilidad funcional y aplicabilidad práctica, abriendo una nueva línea de investigación e innovación para la ingeniería industrial inteligente y adaptativa en el siglo XXI.

VIII. REFERENCIAS

- Abraham, A., Philip, N. S., & Saratchandran, P. (2004). *Modeling chaotic behavior of stock indices using intelligent paradigms*. Oklahoma State University, Department of Computer Science. <https://doi.org/10.48550/arXiv.cs/0405018>
- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), pp.716–723. <https://doi.org/10.1109/TAC.1974.1100705>.
- Akif, A. (2023). *Chaos theory and its applications in economic and productive systems*. Springer.
- Amrhein, V., Greenland, S., & McShane, B. (2019). Scientists rise up against statistical significance. *Nature*, 567(7748), pp. 305–307. <https://doi.org/10.1038/d41586-019-00857-9>
- Ajith Abraham, N. S. (2004). *Modeling Chaotic Behavior of Stock Indices Using Intelligent*. Department of Computer Science, Oklahoma State University, Oklahoma, EEUU. [doi:revistas/corr/cs-AI-0405018](https://doi.org/10.48550/arXiv.cs/0405018)
- Andrew, N. E. (1996). *Time series prediction using supervised learning and tools from chaos theory* [Doctoral dissertation, University of Luton]. ProQuest Dissertations Publishing.
- Benhabib, J. (1979). *On the theory of economic growth and fluctuations*. Academic Press.
- Benhabib, J., & Nishimura, K. (1989). Nonlinear dynamics in economic theory. *Scandinavian Journal of Economics*, 91(3), pp. 305–335.

- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), pp. 307–327.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control* (5th ed.). John Wiley & Sons.
- Brock, W. A., & Hommes, C. H. (1998). Heterogeneous beliefs and routes to chaos in a simple asset pricing model. *Journal of Economic Dynamics and Control*, 22(cap 8–9), pp. 1235–1274. [https://doi.org/10.1016/S0165-1889\(98\)00011-6](https://doi.org/10.1016/S0165-1889(98)00011-6)
- Burnham, K. P., & Anderson, D. R. (2002). *Model selection and multimodel inference: A practical information-theoretic approach* (2nd ed.). Springer.
- Chatfield, C. (2016). *The analysis of time series: An introduction* (7th ed.). CRC Press.
- Chian, A. C.-L., & Nunes, A. S. (2013). *Chaotic market dynamics: From the solar cycle to the global economy*. Springer.
- Christopher, M., & Peck, H. (2004). Building the resilient supply chain. *The International Journal of Logistics Management*, 15(2), pp.1–14.
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences* (2nd ed.). Lawrence Erlbaum Associates.
- Cont, R. (2001). Empirical properties of asset returns: Stylized facts and statistical issues. *Quantitative Finance*, 1(2), pp. 223–236.
- Cornejo, F. (2024). *Modelos econométricos y comportamiento no lineal de los commodities metálicos*. Fondo Editorial PUCP.

- Crosby, P. B. (1980). *Quality is free: The art of making quality certain*. McGraw-Hill.
- Day, R. H. (1992). *Complex economic dynamics* (Vol. 1). MIT Press.
- Debreu, G. (1991). The mathematization of economic theory. *American Economic Review*, 81(1), pp. 1–7.
- Deming, W. E. (1986). *Out of the crisis*. MIT Press.
- Durbin, J., & Koopman, S. J. (2012). *Time series analysis by state space methods* (2nd ed.). Oxford University Press.
- Durbin, J., & Watson, G. S. (1950). Testing for serial correlation in least squares regression. *Biometrika*, 37(3/4), pp.409-428. <https://doi.org/10.1093/biomet/37.3-4.409>
- Engle, R. F. (2002). Dynamic conditional correlation: A simple class of multivariate GARCH models. *Journal of Business & Economic Statistics*, 20(3), pp. 339–350.
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), pp. 383–417.
- Farmer, J. D., & Geanakoplos, J. (2009). The virtues and vices of equilibrium and the future of financial economics. *Complexity*, 14(3), pp. 11–38.
- Fayol, H. (1917). *Administration industrielle et générale: Prévoyance, organisation, commandement, coordination, contrôle*. Dunod et E. Pinat.
- Federal Reserve Bank of St. Louis (FRED). (2024). *Dow Jones Industrial Average (DJIA) and market indicators 2018–2024*. <https://fred.stlouisfed.org>

- Feigenbaum, M. J. (1978). Quantitative universality for a class of nonlinear transformations. *Journal of Statistical Physics*, 19(1), pp.25–52. <https://doi.org/10.1007/BF01020332>
- Field, A. (2013). *Discovering statistics using IBM SPSS Statistics* (4th ed.). Sage.
- Fisher, R. A. (1925). *Statistical methods for research workers*. Oliver and Boyd.
- Garvin, D. A. (1988). *Managing quality: The strategic and competitive edge*. Free Press.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Granger, C. W. J., & Newbold, P. (2014). *Forecasting economic time series* (2nd ed.). Academic Press.
- Grabiela, M. (2014). *Ecuaciones no lineales aplicadas a la cadena de suministro global*. Universidad de Buenos Aires.
- Grandmont, J. M. (1988). Nonlinear difference equations, bifurcations, and chaos in economics. *Macroeconomic Dynamics*, 2(4), pp. 359–382.
- Guegan, D. (2009). Chaos in economics and finance. *Annual Reviews in Control*, 33(1), pp. 89–93. <https://doi.org/10.1016/j.arcontrol.2009.01.002>
- Hamilton, J. D. (1994). *Time series analysis*. Princeton University Press.
- Hernández, R., Fernández, C., & Baptista, P. (2014). *Metodología de la investigación* (6.^a ed.). McGraw-Hill.
- Helo, K. P. (2000). Methodology for Predicting Manufacturing Yield for Printed Circuit Board Assembly Lines. *Journal of Electronics Manufacturing*, 10(2).

- Hernández, et al. (2014). *Metodología de la investigación* (6.^a ed.). McGraw-Hill.
- Hilborn, R. C. (2004). *Chaos and nonlinear dynamics: An introduction for scientists and engineers* (2nd ed.). Oxford University Press.
- Hino, H. (2021). *Machine learning for time-series forecasting with applications in economics*. Springer.
- Hommes, C. H. (2006). Heterogeneous agent models in economics and finance. *Handbook of Computational Economics*, 2, pp. 1109–1186.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>
- Imai, M. (1997). *Gemba Kaizen: A commonsense, low-cost approach to management*. McGraw-Hill.
- Ivanov, D. (2020). Viable supply chain model: Integrating agility, resilience and sustainability perspectives—lessons from COVID-19. *International Journal of Production Research*, 58(10), pp. 2904–2915.
- Juran, J. M. (1999). *Juran's quality handbook* (5th ed.). McGraw-Hill.
- Kantz, H., & Schreiber, T. (2004). *Nonlinear time series analysis* (2nd ed.). Cambridge University Press.
- Koza, J. R. (1992). *Genetic programming: On the programming of computers by means of natural selection*. MIT Press.

- Korns, M. F. (2011). Symbolic regression of financial time series data. *Genetic Programming Theory and Practice IX*, pp. 145–162.
- La Razón. (2024, 27 de mayo). *Claves de la semana 27–31 mayo 2024: Invertir en bolsa*. <https://www.larazon.es/economia/claves-semana-27-31-mayo-2024-invertir-bolsa>
- Lambert, D. (1980). *The Commodity Channel Index (CCI) technical indicator*. Commodity Research Bureau.
- London Metal Exchange (LME). (2024). *Historical market data and official prices (year 2000–2024)*. <https://www.lme.com>
- Lorenz, E. N. (1963). Deterministic nonperiodic flow. *Journal of the Atmospheric Sciences*, 20(2), pp. 130–141.
- Lux, T. (1998). The socio-economic dynamics of speculative markets: Interacting agents, chaos, and the fat tails of return distributions. *Journal of Economic Behavior & Organization*, 33(2), pp. 143–165.
- Mandelbrot, B. B. (1997). *Fractals and scaling in finance: Discontinuity, concentration, risk*. Springer.
- Mandelbrot, B. B., & Hudson, R. L. (2004). *The (mis)behavior of markets: A fractal view of financial turbulence*. Basic Books.
- Matilla et al. (2003). *Teoría del caos y mercados financieros*. Universidad Complutense de Madrid.

- Mentzer, J. T., DeWitt, W., Keebler, J. S., Min, S., Nix, N. W., Smith, C. D., & Zacharia, Z. G. (2001). Defining supply chain management. *Journal of Business Logistics*, 22(2), pp. 1–25.
- Nonaka, I. (1988). Toward middle-up-down management: Accelerating information creation. *Sloan Management Review*, 29(3), pp. 9–18.
- Óscar, S. D. (2017). *Relevance of the Theory of Chaos and Transdisciplinarity in Strategic Management. Mirada de la gestión moderna desde la teoría del caos y la transdisciplina*, pp.137-161.
- Ott, E. (2002). *Chaos in dynamical systems* (2nd ed.). Cambridge University Press.
- Peitgen, H. O., Jürgens, H., & Saupe, D. (2004). *Chaos and fractals: New frontiers of science* (2nd ed.). Springer.
- Peters, E. E. (1994). *Fractal market analysis: Applying chaos theory to investment and economics*. John Wiley & Sons.
- Ponomarov, S. Y., & Holcomb, M. C. (2009). Understanding the concept of supply chain resilience. *The International Journal of Logistics Management*, 20(1), pp. 124–143.
- Porter, M. E. (1985). *Competitive advantage: Creating and sustaining superior performance*. Free Press.
- Pressman, R. S. (2002). *Ingeniería del software: Un enfoque práctico* (5.^a ed.). McGraw-Hill.
- Priestley, M. B. (1981). *Spectral analysis and time series*. Academic Press.
- Puu, T. (2003). *Nonlinear economic dynamics*. Springer.

- Rosser, J. B. (2000). *From catastrophe to chaos: A general theory of economic discontinuities* (2nd ed.). Springer.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning internal representations by error propagation. En D. E. Rumelhart & J. L. McClelland (Eds.), *Parallel distributed processing* (Vol. 1, pp. 318–362). MIT Press.
- Sattinger, D. H. (1973). *Topics in stability and bifurcation theory*. Springer.
- Schmidt, M., & Lipson, H. (2009). Distilling free-form natural laws from experimental data. *Science*, 324(5923), pp. 81–85. <https://doi.org/10.1126/science.1165893>
- Schwarz, G. (1978). Estimating the dimension of a model. *Annals of Statistics*, 6(2), pp. 461–464. <https://doi.org/10.1214/aos/1176344136>
- Sheffi, Y. (2005). *The resilient enterprise: Overcoming vulnerability for competitive advantage*. MIT Press.
- Shumway, R. H., & Stoffer, D. S. (2017). *Time series analysis and its applications with R examples* (4th ed.). Springer.
- Singh, S., & Singh, A. (2002). Cambio y desorden en organizaciones complejas. *Journal of Management Studies*, 39(4), pp. 615–640.
- Slack, N., Chambers, S., & Johnston, R. (2010). *Operations management* (6th ed.). Pearson Education.
- Sodhi, M. S., Son, B. G., & Tang, C. S. (2012). Researchers' perspectives on supply chain risk management. *Production and Operations Management*, 21(1), pp. 1–13.

- Sprott, J. C. (2003). *Chaos and time-series analysis*. Oxford University Press.
- Stiglitz, J. E. (2002). *El malestar en la globalización*. Taurus.
- Strogatz, S. H. (2018). *Nonlinear dynamics and chaos: With applications to physics, biology, chemistry, and engineering* (2nd ed.). CRC Press.
- Takens, F. (1981). Detecting strange attractors in turbulence. En D. Rand & L.-S. Young (Eds.), *Dynamical systems and turbulence*, pp. 366–381. Springer.
- Tang, C. S. (2006). Perspectives in supply chain risk management. *International Journal of Production Economics*, 103(2), pp. 451–488.
- Thompson, J. M. T., & Stewart, H. B. (2002). *Nonlinear dynamics and chaos* (2nd ed.). John Wiley & Sons.
- Tidd, J., & Bessant, J. (2019). *Managing innovation: Integrating technological, market and organizational change* (6th ed.). Wiley.
- Torre, M., & Torre, A. (2002). Tamaño de muestra para una investigación de mercados. *Boletín de la Facultad de Ingeniería, Universidad Rafael Landívar*, (2), pp. 1–8.
- Udrescu, S.-M., & Tegmark, M. (2020). AI Feynman: A physics-inspired method for symbolic regression. *Science Advances*, 6(16), eaay2631.
<https://doi.org/10.1126/sciadv.aay2631>
- Von Neumann, J. (1941). Distribution of the ratio of the mean square successive difference to the variance. *Annals of Mathematical Statistics*, 12(4), pp. 367–395.
<https://doi.org/10.1214/aoms/1177731677>

Vladislavleva, E. J., Smits, G. F., & den Hertog, D. (2010). Order of nonlinearity as a complexity measure for models generated by symbolic regression. *Evolutionary Computation*, 18(3), pp. 433–459.

Verhulst and the logistic equation (1838). In: A Short History of Mathematical Population Dynamics. Springer, London. https://doi.org/10.1007/978-0-85729-115-8_6

Watson, J. D. (Dic, 1950). *Testing for Serial Correlation in last quares Regresion: I. En J. D. Watson. Biometrika*, vol 37, No 3/4.

World Bank. (2024). *World Development Indicators: Global commodity data 2018–2024*. <https://databank.worldbank.org>

IX. ANEXOS

ANEXO A:**GLOSARIO**

Sigla	Denominación	Descripción / Contexto de uso
AIC	Akaike Information Criterion	Criterio de información de Akaike, utilizado para comparar modelos estadísticos y seleccionar el más eficiente.
ANOVA	Analysis of Variance	Técnica estadística que evalúa diferencias significativas entre medias de grupos.
AR	Autoregressive	Componente autorregresivo en modelos de series temporales (ARIMA).
ARIMA	Autoregressive Integrated Moving Average	Modelo estadístico de series temporales usado para predicción de comportamientos lineales.
ASME	American Society of Mechanical Engineers	Entidad que regula normas técnicas y materiales en ingeniería.
AWS	American Welding Society	Organización que establece normas internacionales para soldadura.
BCRP	Banco Central de Reserva del Perú	Fuente de datos macroeconómicos y financieros nacionales.
BIC	Bayesian Information Criterion	Criterio bayesiano de información utilizado en selección de modelos.
CCI	Commodity Channel Index	Indicador técnico de tendencia de mercado usado en el análisis de commodities.
CSI	Customer Satisfaction Index / Caotic Supply Index	Índice de satisfacción del cliente; también adaptado en la tesis como indicador de sensibilidad caótica del sistema logístico.
DJIA	Dow Jones Industrial Average	Índice bursátil representativo del mercado de valores de Estados Unidos.
ERPs	Enterprise Resource Planning Systems	Sistemas integrados de planificación empresarial usados para gestión logística.
FEYNM	Feynman Artificial Intelligence Algorithm	Algoritmo de inteligencia artificial utilizado para obtener ecuaciones simbólicas mediante regresión simbólica.

GLP	Gas Licuado de Petróleo	Combustible utilizado en procesos industriales; considerado como insumo energético nacional.
ICR	Índice de Criticidad Relativa	Indicador diseñado para clasificar la criticidad de los insumos según peso, costo y volatilidad.
ISO	International Organization for Standardization	Organismo que emite normas internacionales de gestión y control de calidad.
KPI	Key Performance Indicator	Indicadores de desempeño clave usados para evaluar eficiencia logística y operativa.
LME	London Metal Exchange	Bolsa de metales más importante a nivel mundial, con datos base para el análisis de commodities.
MA	Moving Average	Componente de media móvil en modelos ARIMA.
MAE	Mean Absolute Error	Error medio absoluto; mide la desviación promedio entre valores reales y proyectados.
MAPE	Mean Absolute Percentage Error	Error porcentual medio absoluto; mide la precisión relativa de los modelos predictivos.
ML	Machine Learning	Aprendizaje automático; rama de la inteligencia artificial aplicada a la modelación predictiva.
NYSE	New York Stock Exchange	Bolsa de valores de Nueva York, referente global junto al DJIA.
PHVA	Planear-Hacer-Verificar-Actuar	Ciclo de mejora continua propuesto por Deming en la gestión de calidad.
p-value	Probability Value	Nivel de significancia estadística utilizado para aceptar o rechazar hipótesis.
RMSE	Root Mean Square Error	Raíz del error cuadrático medio; indicador de precisión de modelos predictivos.
RS	Regression Symbolic	Regresión simbólica; técnica de inteligencia artificial usada para obtener ecuaciones no lineales.
R ²	Coefficient of Determination	Coefficiente de determinación; mide el grado de ajuste del modelo a los datos observados.

SCM	Supply Chain Management	Gestión de la cadena de suministro, área central del estudio.
UML	Unified Modeling Language	Lenguaje de modelado usado para representar sistemas complejos.
VES	Villa El Salvador	Zona industrial de Lima donde se aplicaron las encuestas de validación del nuevo insumo.
Z-test	Z Statistic Test	Prueba de proporciones utilizada para comparar grupos de datos con grandes muestras.

Anexo B : Matriz de Consistencias

PREGUNTA DE INVESTIGACIÓN	OBJETIVO DE INVESTIGACIÓN	HIPÓTESIS	METODOLOGÍA (Tipo, Nivel y Diseño)	VARIABLES	INDICADORES / DIMENSIONES
PG	Analizar la influencia de la dinámica caótica y las ecuaciones no lineales aplicadas a los índices internacionales (DJIA y LME) en la gestión de la cadena de suministro de <i>commodities</i> importados en la industria de electrodos del Perú durante el periodo 2018–2023.	La dinámica caótica y las ecuaciones no lineales aplicadas al comportamiento de los índices internacionales DJIA y LME influyen de manera significativa en la gestión de la cadena de suministro de <i>commodities</i> importados en la industria de electrodos del Perú entre 2018 y 2023.		<i>Independiente:</i> Dinámica caótica y ecuaciones no lineales. Variable <i>Dependiente:</i> Gestión de la cadena de suministro.	<i>Dimensiones:</i> • Índices internacionales (DJIA, LME). • Modelos no lineales (ARIMA y RS). • Desempeño logístico (KPI). <i>Indicadores:</i> ρ , R^2 , AIC, MAPE, RMSE, Lead time, Fill rate, Stock-out.
PE-1	Identificar y cuantificar las relaciones entre los índices internacionales (DJIA, LME) y los precios de los <i>commodities</i> estratégicos usados en la producción de electrodos.	La dinámica no lineal presente en los índices internacionales DJIA y LME incide directamente en la formación de precios de los <i>commodities</i> estratégicos utilizados en la fabricación de electrodos.	Tipo: Aplicada, explicativa y prospectiva.	<i>Independiente:</i> Índices DJIA y LME. <i>Dependiente:</i> Precio de <i>commodities</i> estratégicos.	<i>Indicadores:</i> • Correlación Pearson (ρ). • Correlación Spearman (ρ_s). • p-value < 0.05. <i>Dimensiones:</i> Variación mensual (Ni, Cu, Al).
PE-2	Comparar el desempeño predictivo de los modelos ARIMA (Box–Jenkins) y Regresión Simbólica (RS) en la proyección de precios de insumos importados.	El uso de herramientas estadísticas avanzadas (ARIMA y RS) permite anticipar con mayor precisión escenarios de volatilidad en la cadena de suministro de insumos críticos.	Nivel: Correlacional – explicativo – predictivo. Diseño:	<i>Independiente:</i> Modelo predictivo (ARIMA / RS). <i>Dependiente:</i> Error de predicción y volatilidad proyectada.	<i>Indicadores:</i> • MAPE (% error absoluto medio). • RMSE (error cuadrático medio). • MAE (error medio absoluto). • R^2 ajustado. • p-value (t/Wilcoxon).
PE-3	Diseñar y evaluar indicadores de gestión (KPI) basados en modelos no lineales para medir la eficiencia del aprovisionamiento industrial.	Los indicadores de gestión (KPI) fundamentados en enfoques no lineales contribuyen a evaluar con mayor precisión la eficiencia del aprovisionamiento en la industria de electrodos.	No experimental – longitudinal correlacional – causal.	<i>Independiente:</i> KPI no lineales derivados del modelo RS. <i>Dependiente:</i> Eficiencia del aprovisionamiento.	<i>Indicadores:</i> • Caotic Supply Index (CSI). • Lead time (días). • Fill rate (%). • Stock-out (%). • ANOVA p<0.05.
PE-4	Analizar el efecto de los modelos caóticos en las decisiones tácticas (tiempo de compra, nivel de stock) y en la resiliencia operativa de la cadena de suministro.	La aplicación de la dinámica caótica y ecuaciones no lineales mejora la toma de decisiones estratégicas relacionadas con los tiempos de compra, los niveles de stock y la resiliencia empresarial frente a la volatilidad de los mercados internacionales.		<i>Independiente:</i> Aplicación de modelos caóticos (RS). <i>Dependiente:</i> Desempeño táctico y resiliencia.	<i>Indicadores:</i> • Δ Costo/kg. • Δ Stock-out (%). • h de Cohen (efecto). • t-test (p<0.05). • Mejora de resiliencia logística.

Anexo C:**Figura A1**

Ubicación de los proveedores de insumos para la fabricación de electrodos



Fuente: Elaboración propia

Anexo D : Análisis de los modelos ARIMA

Caso 1 : Análisis de Índice de precio de las Ferroaleaciones

Automatic ARIMA Forecasting

Selected dependent variable:

D(INDXPRICEFERROALLOYS)

Date: 05/06/24 Time: 17:30

Sample: 1965M01 2023M12

Included observations: 707

Forecast length: 8

Model maximums: (4,4)3(0,0)

Regressors: C

Number of estimated ARMA models: 25

Number of non-converged estimations: 0

Selected ARMA model: (4,4)(0,0)

AIC value: 5.33469701332





Figura A2

Graficando todos los modelos ARIMA Ferroaleaciones



Fuente: Elaboración propia

Tabla A2*Determinación de los indicadores ARIMA Ferroaleaciones*

Method: ARIMA Maximum Likelihood (BFGS)

Date: 05/06/24 Time: 17:30


Sample: 1965M02 2023M12

Included observations: 707

Convergence achieved after 88 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.33048	0.35105	0.94139	0.34683
AR(1)	-0.76162	0.04257	-17.88922	0.00000
AR(2)	-0.86468	0.01915	-45.15596	0.00000
AR(3)	-0.09393	0.03416	-2.74944	0.00612
AR(4)	0.11249	0.03039	3.70169	0.00023
MA(1)	1.54103	0.04538	33.95508	0.00000
MA(2)	1.97120	0.03746	52.62579	0.00000
MA(3)	1.29337	0.04897	26.41263	0.00000
MA(4)	0.54403	0.02183	24.91615	0.00000
SIGMASQ	11.76780	0.25511	46.12788	0.00000
R-squared	0.48133	S.D. dependent var		0.33252
Adjusted R-squared	3.45494	Akaike info criterion		4.79728
S.E. of regression	8319.83169	Schwarz criterion		5.33470
Sum squared resid	-1875.81539	Hannan-Quinn criter.		5.39921
Log likelihood	73.79665	Durbin-Watson stat		5.35962
F-statistic	0.00000			2.00952
Prob(F-statistic)	0.33048	0.35105	0.94139	0.34683
Inverted AR Roots	.27	-.29-.90i	-.29+.90i	-.46
Inverted MA Roots	-.20+.94i	-.20-.94i	-.57-.51i	-.57+.51i

Figura A3*Tendencia Hodrick-Prescott Ferroaleaciones*

Fuente: elaboración propia

Tabla A3*Determinación del mejor modelo Akeike (AIC)*

Model Selection Criteria Table

Dependent Variable: D(INDXPRICEFERROALLOYS)

Date: 05/06/24 Time: 17:30

Sample: 1965M01 2023M12

Included observations: 707

Model	LogL	AIC*	BIC	HQ
(4,4)(0,0)	-1875.815394	5.334697	5.399209	5.359623
(4,3)(0,0)	-1885.948981	5.360535	5.418596	5.382968
(3,2)(0,0)	-1898.411338	5.390131	5.435290	5.407580
(4,2)(0,0)	-1898.246265	5.392493	5.444103	5.412434
(3,3)(0,0)	-1898.278332	5.392584	5.444194	5.412525
(3,4)(0,0)	-1897.441203	5.393044	5.451106	5.415478
(0,4)(0,0)	-1902.247195	5.398153	5.436861	5.413109
(1,4)(0,0)	-1902.151632	5.400712	5.445871	5.418160
(2,4)(0,0)	-1902.146759	5.403527	5.455137	5.423468
(2,3)(0,0)	-1907.571840	5.416045	5.461204	5.433493
(2,2)(0,0)	-1912.345135	5.426719	5.465426	5.441675
(4,1)(0,0)	-1912.687951	5.430518	5.475676	5.447966
(1,1)(0,0)	-1916.168498	5.431877	5.457682	5.441847
(2,0)(0,0)	-1916.259096	5.432133	5.457938	5.442104
(1,3)(0,0)	-1915.038166	5.434337	5.473045	5.449293
(3,0)(0,0)	-1916.065525	5.434414	5.466671	5.446878
(1,2)(0,0)	-1916.129884	5.434597	5.466853	5.447060
(2,1)(0,0)	-1916.151795	5.434659	5.466915	5.447122
(4,0)(0,0)	-1915.798108	5.436487	5.475194	5.451443
(3,1)(0,0)	-1916.031302	5.437147	5.475854	5.452102
(1,0)(0,0)	-1919.965824	5.439790	5.459144	5.447268
(0,2)(0,0)	-1921.981941	5.448322	5.474127	5.458293
(0,3)(0,0)	-1921.365777	5.449408	5.481664	5.461871
(0,1)(0,0)	-1964.281538	5.565153	5.584507	5.572631
(0,0)(0,0)	-2111.299272	5.978216	5.991118	5.983201


CASO 2: Análisis de Índice de precio de los alambres Acero

Automatic ARIMA Forecasting
 Selected dependent variable:
 DLOG(INDEXSTEELWIREDRAW)
 Date: 05/05/24 Time: 23:12
 Sample: 1982M06 2023M12
 Included observations: 498
 Forecast length: 8
 Model maximums: (4,4)3(0,0)
 Regressors: C

Number of estimated ARMA models: 25
 Number of non-converged estimations: 0
 Selected ARMA model: (3,3)(0,0)
 AIC value: -4.52633733779

Figura A4

Graficando todos los modelos ARIMA Alambre Acero



Fuente: elaboración propia


Figura A5*Graficando todos los modelos ARIMA Alambre de Acero**Fuente: elaboración propia*

Tabla A4

Determinación de los indicadores ARIMA Wire inox

Dependent Variable: DLOG(INDEXSTEELWIREDRAW)

Method: ARMA Maximum Likelihood (BFGS)

Date: 05/05/24 Time: 23:12

Sample: 1982M07 2023M12

Included observations: 498


Convergence achieved after 182 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.002067	0.003379	0.611685	0.5410
AR(1)	0.192285	0.103396	1.859700	0.0635
AR(2)	-0.474254	0.049794	-9.524352	0.0000
AR(3)	0.687082	0.098054	7.007169	0.0000
MA(1)	-0.035106	2.429533	-0.014450	0.9885
MA(2)	0.662972	61.32977	0.010810	0.9914
MA(3)	-0.598358	84.43278	-0.007087	0.9943
SIGMASQ	0.000607	0.001662	0.364971	0.7153
R-squared	0.111766	Mean dependent var		0.002105
Adjusted R-squared	0.099077	S.D. dependent var		0.026162
S.E. of regression	0.024832	Akaike info criterion		-4.526337
Sum squared resid	0.302158	Schwarz criterion		-4.458697
Log likelihood	1135.058	Hannan-Quinn criter.		-4.499791
F-statistic	8.808024	Durbin-Watson stat		1.971219
Prob(F-statistic)	0.000000			
Inverted AR Roots	.76	-.28-.91i	-.28+.91i	
Inverted MA Roots	.60	-.28+.96i	-.28-.96i	

Figura A6

Tendencia Hodrick-Prescott Wire Inox



Fuente: elaboración propia

Tabla A5*Determinación del mejor modelo Akeike (AIC Alambre Acero)*

Model Selection Criteria Table

Dependent Variable:

DLOG(INDEXSTEELWIREDRAW)


Date: 05/05/24 Time: 23:12

Sample: 1982M06 2023M12

Included observations: 498

Model	LogL	AIC*	BIC	HQ
(3,3)(0,0)	1135.057997	-4.526337	-4.458697	-4.499791
(3,4)(0,0)	1130.428788	-4.503730	-4.427635	-4.473865
(4,4)(0,0)	1131.089574	-4.502368	-4.417818	-4.469185
(2,2)(0,0)	1126.644354	-4.500580	-4.449850	-4.480670
(1,1)(0,0)	1123.707248	-4.496816	-4.462996	-4.483543
(1,2)(0,0)	1123.737364	-4.492921	-4.450646	-4.476330
(2,1)(0,0)	1123.735776	-4.492915	-4.450640	-4.476323
(3,2)(0,0)	1125.422720	-4.491658	-4.432472	-4.468429
(2,3)(0,0)	1125.419985	-4.491647	-4.432461	-4.468418
(3,0)(0,0)	1123.045707	-4.490143	-4.447868	-4.473552
(1,3)(0,0)	1123.794028	-4.489133	-4.438403	-4.469223
(3,1)(0,0)	1123.779197	-4.489073	-4.438343	-4.469163
(2,0)(0,0)	1121.474932	-4.487851	-4.454031	-4.474578
(4,0)(0,0)	1123.408526	-4.487584	-4.436854	-4.467675
(4,2)(0,0)	1125.316913	-4.487217	-4.419576	-4.460670
(4,3)(0,0)	1126.131071	-4.486470	-4.410375	-4.456605
(1,4)(0,0)	1123.814543	-4.485199	-4.426014	-4.461971
(4,1)(0,0)	1123.802091	-4.485149	-4.425964	-4.461921
(0,3)(0,0)	1121.213888	-4.482787	-4.440512	-4.466195
(0,4)(0,0)	1122.094358	-4.482307	-4.431577	-4.462397
(2,4)(0,0)	1123.831291	-4.481250	-4.413610	-4.454704
(0,2)(0,0)	1119.539972	-4.480080	-4.446260	-4.466807
(1,0)(0,0)	1117.814997	-4.477169	-4.451804	-4.467214
(0,1)(0,0)	1115.935696	-4.469621	-4.444256	-4.459666
(0,0)(0,0)	1108.300839	-4.442975	-4.426065	-4.436339

Akaike Information Criteria (top 20 models)



Fuente: elaboración propia

CASO 3: Análisis del Índice de 456 Observations de Potash, Soda, and Borate Mineral Mining Automatic ARIMA Forecasting

Selected dependent variable:
DLOG(INDEXPOTASHSODABORATE)
Date: 05/06/24 Time: 15:49
Sample: 1985M12 2023M12
Included observations: 456
Forecast length: 8
Model maximums: (4,4)3(0,0)
Regressors: C

Number of estimated ARMA models: 25
Number of non-converged estimations: 0
Selected ARMA model: (4,4)(0,0)
AIC value: -4.99254040804





Figura A7

Graficando todos los modelos ARIMA Potash, Soda, and Borate Mineral Mining



Fuente:

Elaboración propia

Tabla A6

Determinación de los indicadores ARIMA Potash, Soda, and Borate Mineral Mining

Dependent Variable: DLOG(INDEXPOTASHSODABORATE_F)

Method: ARMA Maximum Likelihood (BFGS)

Date: 07/11/24 Time: 20:26

Sample: 1986M01 2024M04

Included observations: 460


Convergence achieved after 41 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.00277	0.00247	1.12544	0.26100
AR(1)	0.27174	0.04968	5.47003	0.00000
AR(2)	1.16700	0.05512	21.17042	0.00000
AR(3)	0.10667	0.05530	1.92909	0.05435
AR(4)	-0.71304	0.05123	-13.91889	0.00000
MA(1)	-0.12544	0.04539	-2.76364	0.00595
MA(2)	-1.11414	0.04006	-27.81269	0.00000
MA(3)	-0.18427	0.04047	-4.55339	0.00001
MA(4)	0.82695	0.03627	22.80035	0.00000
SIGMASQ	0.00037	0.00001	27.81753	0.00000
R-squared	0.30392	Mean dependent var		0.00283
Adjusted R-squared	0.29000	S.D. dependent var		0.02323
S.E. of regression	0.01958	Akaike info criterion		-5.00301
Sum squared resid	0.17247	Schwarz criterion		-4.91320
Log likelihood	1160.69280	Hannan-Quinn criter.		-4.96765
F-statistic	21.83097	Durbin-Watson stat		2.04883
Prob(F-statistic)	9.66942e-31			
Inverted AR Roots	.92-.21i	.92+.21i	-.78+.45i	-.78-.45i
Inverted MA Roots	.89-.32i	.89+.32i	-.83+.50i	-.83-.50i

Figura A8

Tendencia Hodrick-Prescott Potash, Soda, and Borate Mineral Mining



Fuente: Elaboración propia

Tabla A7*Determinación del mejor modelo Akeike (AIC Potash, Soda, and Borate Mineral Mining)*

Model Selection Criteria Table

Dependent Variable: DLOG(INDEXPOTASHSODABORATE)


Date: 05/06/24 Time: 15:49

Sample: 1985M12 2023M12

Included observations: 456

Model	LogL	AIC*	BIC	HQ
(4,4)(0,0)	1148.299213	-4.992540	-4.902135	-4.956928
(3,4)(0,0)	1142.536495	-4.971651	-4.890286	-4.939600
(4,3)(0,0)	1142.306061	-4.970641	-4.889276	-4.938589
(3,3)(0,0)	1141.244859	-4.970372	-4.898048	-4.941882
(1,4)(0,0)	1128.321092	-4.918075	-4.854791	-4.893146
(2,4)(0,0)	1128.486999	-4.914417	-4.842092	-4.885927
(4,0)(0,0)	1123.824303	-4.902738	-4.848495	-4.881371
(4,2)(0,0)	1125.764223	-4.902475	-4.830150	-4.873985
(4,1)(0,0)	1124.069089	-4.899426	-4.836142	-4.874497
(2,2)(0,0)	1122.321129	-4.896145	-4.841902	-4.874778
(1,2)(0,0)	1120.689765	-4.893376	-4.848173	-4.875570
(1,3)(0,0)	1121.665648	-4.893270	-4.839027	-4.871903
(2,3)(0,0)	1122.542706	-4.892731	-4.829447	-4.867802
(3,2)(0,0)	1122.460063	-4.892369	-4.829085	-4.867440
(2,1)(0,0)	1120.406908	-4.892136	-4.846933	-4.874329
(3,1)(0,0)	1120.690187	-4.888992	-4.834749	-4.867624
(1,1)(0,0)	1118.628826	-4.888723	-4.852561	-4.874478
(3,0)(0,0)	1114.062008	-4.864307	-4.819104	-4.846501
(2,0)(0,0)	1109.616572	-4.849195	-4.813033	-4.834950
(0,4)(0,0)	1110.823493	-4.845717	-4.791474	-4.824349
(0,3)(0,0)	1100.393499	-4.804357	-4.759155	-4.786551
(0,2)(0,0)	1096.732535	-4.792687	-4.756524	-4.778441
(1,0)(0,0)	1093.040273	-4.780878	-4.753757	-4.770195
(0,1)(0,0)	1083.969817	-4.741096	-4.713974	-4.730412
(0,0)(0,0)	1067.553551	-4.673480	-4.655399	-4.666358

Akaike Information Criteria (top 20 models)



Fuente: Elaboración propia

CASO 4: Análisis de los minerales de Caliza (No-Metalicos)

Tabla A8

Determinación de los indicadores ARIMA Caliza

Automatic ARIMA Forecasting

Selected dependent variable: DLOG(INDEX_CALIZA,2)

Date: 05/06/24 Time: 08:43

Sample: 1983M12 2023M12

Included observations: 479

Forecast length: 8

Model maximums: (4,4)3(0,0)


Regressors: C

Number of estimated ARMA models: 25

Number of non-converged estimations: 0

Selected ARMA model: (3,4)(0,0)

AIC value: -7.21417287712



Fuente: Elaboración propia


Figura A9*Graficando todos los modelos ARIMA Caliza**Fuente: Elaboración propia*

Tabla A8*Determinación de los indicadores ARIMA Caliza*

Dependent Variable: DLOG(INDEX_CALIZA,2)

Method: ARMA Maximum Likelihood (BFGS)

Date: 05/06/24 Time: 08:43

Sample: 1984M02 2023M12

Included observations: 479

Convergence achieved after 280 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	7.16E-06	2.55E-06	2.806539	0.0052
AR(1)	-0.004058	0.009946	-0.408059	0.6834
AR(2)	-0.002811	0.011999	-0.234279	0.8149
AR(3)	-0.997597	0.009077	-109.8989	0.0000
MA(1)	-0.978502	4.784666	-0.204508	0.8380
MA(2)	-0.023736	0.188926	-0.125639	0.9001
MA(3)	0.967426	13.75441	0.070336	0.9440
MA(4)	-0.965187	18.42772	-0.052377	0.9583
SIGMASQ	4.06E-05	2.05E-05	1.983197	0.0479
R-squared	0.528166	Mean dependent var		-4.41E-06
Adjusted R-squared	0.520135	S.D. dependent var		0.009288
S.E. of regression	0.006434	Akaike info criterion		-7.214337
Sum squared resid	0.019455	Schwarz criterion		-7.135954
Log likelihood	1736.834	Hannan-Quinn criter.		-7.183523
F-statistic	65.76416	Durbin-Watson stat		1.963234
Prob(F-statistic)	0.000000			
Inverted AR Roots	.50-.87i	.50+.87i	-1.00	
Inverted MA Roots	1.00	.49+.86i	.49-.86i	-1.00



Figura A10*Tendencia Hodrick-Prescott Caliza*

Tabla A9*Determinación del mejor modelo Akeike (AIC Caliza)*

Model Selection Criteria Table
 Dependent Variable: DLOG(INDEX_CALIZA,2)
 Date: 05/06/24 Time: 08:43
 Sample: 1983M12 2023M12
 Included observations: 479

Model	LogL	AIC*	BIC	HQ
(3,4)(0,0)	1736.794404	-7.214173	-7.135790	-7.183360
(4,4)(0,0)	1736.881972	-7.210363	-7.123271	-7.176126
(3,3)(0,0)	1730.062828	-7.190241	-7.120568	-7.162852
(2,2)(0,0)	1714.039607	-7.131689	-7.079434	-7.111147
(4,1)(0,0)	1714.769034	-7.130560	-7.069595	-7.106594
(3,2)(0,0)	1714.616787	-7.129924	-7.068960	-7.105958
(1,3)(0,0)	1713.387142	-7.128965	-7.076710	-7.108423
(1,4)(0,0)	1714.167832	-7.128049	-7.067085	-7.104084
(4,2)(0,0)	1715.061024	-7.127603	-7.057930	-7.100214
(2,4)(0,0)	1713.523998	-7.121186	-7.051512	-7.093796
(3,1)(0,0)	1710.556230	-7.117145	-7.064890	-7.096603
(2,3)(0,0)	1711.202806	-7.115669	-7.054705	-7.091703
(0,2)(0,0)	1708.179428	-7.115572	-7.080735	-7.101877
(1,1)(0,0)	1708.049544	-7.115029	-7.080193	-7.101335
(0,3)(0,0)	1708.827478	-7.114102	-7.070556	-7.096984
(1,2)(0,0)	1708.821076	-7.114075	-7.070530	-7.096957
(2,1)(0,0)	1708.787337	-7.113935	-7.070389	-7.096816
(0,1)(0,0)	1706.720441	-7.113655	-7.087528	-7.103384
(4,3)(0,0)	1712.666501	-7.113430	-7.035047	-7.082617
(0,4)(0,0)	1709.118859	-7.111143	-7.058888	-7.090601
(4,0)(0,0)	1669.910501	-6.947434	-6.895179	-6.926892
(3,0)(0,0)	1645.771431	-6.850820	-6.807274	-6.833702
(2,0)(0,0)	1634.752566	-6.808988	-6.774151	-6.795293
(1,0)(0,0)	1612.352817	-6.719636	-6.693508	-6.709365
(0,0)(0,0)	1562.104367	-6.514006	-6.496587	-6.507158


Akaike Information Criteria (top 20 models)

Fuente: Elaboración propia

CASO 5: Análisis de 407 Observaciones para Precio Níquel

Automatic ARIMA Forecasting
 Selected dependent variable: DLOG(NIQUEL)
 Date: 05/06/24 Time: 00:43
 Sample: 1990M01 2023M12
 Included observations: 407
 Forecast length: 8
 Model maximums: (4,4)3(0,0)
 Regressors: C

Number of estimated ARMA models: 25
 Number of non-converged estimations: 0
 Selected ARMA model: (2,4)(0,0)
 AIC value: -2.28338107534



Fuente: Elaboración propia


Figura A11*Graficando todos los modelos de níquel**Fuente: Elaboración propia*

Tabla A10*Determinación de los indicadores ARIMA Niquel*

Dependent Variable: DLOG(NIQUEL)

Method: ARMA Maximum Likelihood (BFGS)

Date: 05/06/24 Time: 00:43


Sample: 1990M02 2023M12

Included observations: 407

Convergence achieved after 225 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.001979	0.005467	0.362095	0.7175
AR(1)	0.670385	0.012053	55.61799	0.0000
AR(2)	-0.992719	0.013179	-75.32389	0.0000
MA(1)	-0.363144	4.046404	-0.089745	0.9285
MA(2)	0.900285	15.96248	0.056400	0.9551
MA(3)	0.240333	6.056454	0.039682	0.9684
MA(4)	0.127561	3.905894	0.032659	0.9740
SIGMASQ	0.005681	0.027665	0.205352	0.8374
R-squared	0.125355	Mean dependent var		0.002079
Adjusted R-squared	0.110011	S.D. dependent var		0.080692
S.E. of regression	0.076124	Akaike info criterion		-2.283381
Sum squared resid	2.312159	Schwarz criterion		-2.204584
Log likelihood	472.6680	Hannan-Quinn criter.		-2.252198
F-statistic	8.169318	Durbin-Watson stat		2.002282
Prob(F-statistic)	0.000000			
Inverted AR Roots	.34-.94i	.34+.94i		
Inverted MA Roots	.35-.94i	.35+.94i	-.16-.32i	-.16+.32i

Figura A12*Tendencia Hodrick-Prescott Niquel*

Fuente: Elaboración propia

Tabla A11*Determinación del mejor modelo Akeike (AIC Niquel)*

Model Selection Criteria Table

Dependent Variable: DLOG(NIQUEL)


Date: 05/06/24 Time: 00:43

Sample: 1990M01 2023M12

Included observations: 407

Model	LogL	AIC*	BIC	HQ
(2,4)(0,0)	472.668049	-2.283381	-2.204584	-2.252198
(1,0)(0,0)	467.497135	-2.282541	-2.252992	-2.270847
(0,2)(0,0)	468.146904	-2.280820	-2.241422	-2.265228
(4,2)(0,0)	472.030992	-2.280251	-2.201453	-2.249067
(3,3)(0,0)	472.028739	-2.280240	-2.201442	-2.249056
(2,0)(0,0)	467.704150	-2.278644	-2.239246	-2.263053
(1,1)(0,0)	467.648838	-2.278373	-2.238974	-2.262781
(4,3)(0,0)	472.467955	-2.277484	-2.188837	-2.242403
(0,3)(0,0)	468.440717	-2.277350	-2.228102	-2.257860
(1,2)(0,0)	468.349651	-2.276902	-2.227654	-2.257413
(0,1)(0,0)	466.318483	-2.276749	-2.247200	-2.265056
(3,0)(0,0)	468.236831	-2.276348	-2.227100	-2.256858
(3,2)(0,0)	469.902745	-2.274706	-2.205759	-2.247421
(2,1)(0,0)	467.836822	-2.274382	-2.225134	-2.254893
(2,2)(0,0)	468.580223	-2.273121	-2.214024	-2.249734
(4,0)(0,0)	468.575704	-2.273099	-2.214001	-2.249712
(0,4)(0,0)	468.493300	-2.272694	-2.213596	-2.249307
(1,3)(0,0)	468.460869	-2.272535	-2.213437	-2.249147
(3,1)(0,0)	468.397119	-2.272222	-2.213124	-2.248834
(3,4)(0,0)	471.136934	-2.270943	-2.182296	-2.235862
(2,3)(0,0)	468.932818	-2.269940	-2.200992	-2.242655
(4,1)(0,0)	468.698383	-2.268788	-2.199840	-2.241503
(4,4)(0,0)	471.636906	-2.268486	-2.169989	-2.229507
(1,4)(0,0)	468.519576	-2.267909	-2.198962	-2.240624
(0,0)(0,0)	447.459274	-2.188989	-2.169290	-2.181193

Akaike Information Criteria (top 20 models)



Fuente: Elaboración propia

Caso 6: Análisis de Aserrín de malasia

Automatic ARIMA Forecasting

Selected dependent variable: D(ASERRINMALASIA)

Date: 05/07/24 Time: 07:59

Sample: 1960 2023

Included observations: 63

Forecast length: 5

Model maximums: (4,4)3(0,0)

Regressors: C


Number of estimated ARMA models: 25

Number of non-converged estimations: 0

Selected ARMA model: (4,1)(0,0)

AIC value: 10.786093846

Actual and Forecast



Fuente: Elaboración propia


Figura A13*Graficando todos los modelos Aserrin**Fuente: Elaboración propia*

Tabla A12*Determinación de los indicadores ARIMA Aserrín*

Dependent Variable: D(ASERRINMALASIA)

Method: ARMA Maximum Likelihood (BFGS)

Date: 05/07/24 Time: 07:59


Sample: 1961 2023

Included observations: 63

Convergence achieved after 76 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	12.22551	2.427764	5.035705	0.0000
AR(1)	1.027024	0.101831	10.08558	0.0000
AR(2)	-0.331273	0.190826	-1.735994	0.0881
AR(3)	0.600420	0.178243	3.368537	0.0014
AR(4)	-0.543892	0.134029	-4.058012	0.0002
MA(1)	-0.999998	1716.683	-0.000583	0.9995
SIGMASQ	2122.811	121814.9	0.017427	0.9862
R-squared	0.359182	Mean dependent var		8.389841
Adjusted R-squared	0.290523	S.D. dependent var		58.01801
S.E. of regression	48.86883	Akaike info criterion		10.78609
Sum squared resid	133737.1	Schwarz criterion		11.02422
Log likelihood	-332.7620	Hannan-Quinn criter.		10.87975
F-statistic	5.231390	Durbin-Watson stat		1.904919
Prob(F-statistic)	0.000246			
Inverted AR Roots	.85-.29i	.85+.29i	-.34-.75i	-.34+.75i
Inverted MA Roots	1.00			

Figura A14*Tendencia Hodrick-Prescott Aserrín*

Fuente: Elaboración propia

Tabla A13*Determinación del mejor modelo Akeike (AIC Aserrin)*

Model Selection Criteria Table

Dependent Variable: D(ASERRINMALASIA)


Date: 05/07/24 Time: 07:59

Sample: 1960 2023

Included observations: 63

Model	LogL	AIC*	BIC	HQ
(4,1)(0,0)	-332.761956	10.786094	11.024220	10.879750
(4,2)(0,0)	-332.416203	10.806864	11.079008	10.913899
(4,3)(0,0)	-331.956020	10.824001	11.130163	10.944416
(3,3)(0,0)	-332.983967	10.824888	11.097032	10.931923
(1,4)(0,0)	-334.280959	10.834316	11.072442	10.927972
(2,3)(0,0)	-334.286411	10.834489	11.072615	10.928145
(4,0)(0,0)	-335.543674	10.842656	11.046764	10.922933
(0,3)(0,0)	-336.814409	10.851251	11.021341	10.918148
(4,4)(0,0)	-331.944927	10.855394	11.195575	10.989189
(3,4)(0,0)	-332.957931	10.855807	11.161969	10.976222
(3,1)(0,0)	-335.964479	10.856015	11.060123	10.936292
(2,4)(0,0)	-334.270598	10.865733	11.137877	10.972769
(0,4)(0,0)	-336.276936	10.865934	11.070043	10.946211
(1,3)(0,0)	-336.526697	10.873863	11.077971	10.954140
(3,0)(0,0)	-337.824367	10.883313	11.053403	10.950211
(3,2)(0,0)	-335.926088	10.886542	11.124669	10.980199
(1,1)(0,0)	-339.143319	10.893439	11.029511	10.946957
(2,1)(0,0)	-338.401233	10.901626	11.071716	10.968524
(1,2)(0,0)	-338.630013	10.908889	11.078979	10.975787
(2,2)(0,0)	-337.704715	10.911261	11.115369	10.991538
(0,2)(0,0)	-340.863824	10.948058	11.084130	11.001576
(0,0)(0,0)	-344.716585	11.006876	11.074912	11.033635
(0,1)(0,0)	-344.526402	11.032584	11.134638	11.072723
(1,0)(0,0)	-344.591047	11.034636	11.136690	11.074775
(2,0)(0,0)	-344.013684	11.048053	11.184126	11.101571

Akaike Information Criteria (top 20 models)



Fuente: Elaboración propia

Caso 7: Análisis de las tarifas eléctricas Industriales

Automatic ARIMA Forecasting

Selected dependent variable: DLOG(INDEXELECTPE)

Date: 05/07/24 Time: 21:35

Sample: 2010M01 2023M12

Included observations: 267

Forecast length: 8

Model maximums: (4,4)3(0,0)


Regressors: C

Number of estimated ARMA models: 25

Number of non-converged estimations: 0

Selected ARMA model: (3,4)(0,0)

AIC value: -4.84179210096



Fuente: Elaboración propia


Figura A15*Graficando todos los modelos Electricidad**Fuente: Elaboración propia*

Tabla A14*Determinación de los indicadores ARIMA Electricidad*

Dependent Variable: DLOG(INDEXELECTPE)

Method: ARMA Maximum Likelihood (BFGS)

Date: 05/07/24 Time: 21:35


Sample: 2010M02 2023M12

Included observations: 167

Convergence achieved after 305 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.00314	0.00042	7.51056	0.00000
AR(1)	-0.41369	0.12140	-3.40766	0.00083
AR(2)	0.21287	0.10844	1.96304	0.05140
AR(3)	0.72566	0.06159	11.78279	0.00000
MA(1)	0.44449	99.32373	0.00448	0.99644
MA(2)	-0.23767	31.91724	-0.00745	0.99407
MA(3)	-1.04566	471.09805	-0.00222	0.99823
MA(4)	-0.16116	92.66159	-0.00174	0.99861
SIGMASQ	0.00040	0.04198	0.00946	0.99247
R-squared	0.157023	Mean dependent var		0.002506
Adjusted R-squared	0.114341	S.D. dependent var		0.021767
S.E. of regression	0.020485	Akaike info criterion		-4.841792
Sum squared resid	0.066300	Schwarz criterion		-4.673757
Log likelihood	413.289648	Hannan-Quinn criter.		-4.773590
F-statistic	3.678880	Durbin-Watson stat		1.994198
Prob(F-statistic)	0.000581			
Inverted AR Roots	.85	-.63+.68i	-.63-.68i	
Inverted MA Roots	1.00	-.16	-.64-.77i	-.64+.77i

Figura A16*Tendencia Hodrick-Prescott Electricidad*

Fuente: Elaboración propia

Tabla A15*Determinación del mejor modelo Akeike (AIC electricidad)*

Dependent Variable: DLOG(INDEXELECTPE)


Date: 05/07/24 Time: 21:35

Sample: 2010M01 2023M12

Included observations: 167

Model	LogL	AIC*	BIC	HQ
(3,4)(0,0)	413.28964	-4.84179	-4.67376	-4.77359
(4,3)(0,0)	413.28907	-4.84179	-4.67375	-4.77358
(3,3)(0,0)	412.24420	-4.84125	-4.69188	-4.78062
(4,4)(0,0)	413.29037	-4.82982	-4.64312	-4.75404
(1,3)(0,0)	407.88947	-4.81305	-4.70102	-4.76758
(3,1)(0,0)	407.40593	-4.80726	-4.69523	-4.76179
(2,3)(0,0)	408.00407	-4.80244	-4.67175	-4.74940
(1,4)(0,0)	407.99001	-4.80228	-4.67158	-4.74923
(3,2)(0,0)	407.98404	-4.80220	-4.67151	-4.74916
(4,1)(0,0)	407.97055	-4.80204	-4.67135	-4.74900
(0,0)(0,0)	402.70984	-4.79892	-4.76158	-4.78376
(2,4)(0,0)	408.13655	-4.79205	-4.64269	-4.73143
(4,2)(0,0)	408.09851	-4.79160	-4.64223	-4.73097
(0,3)(0,0)	405.04051	-4.79090	-4.69755	-4.75301
(1,0)(0,0)	402.81666	-4.78822	-4.73221	-4.76549
(0,1)(0,0)	402.81502	-4.78820	-4.73219	-4.76547
(0,4)(0,0)	405.66021	-4.78635	-4.67433	-4.74088
(3,0)(0,0)	404.45433	-4.78388	-4.69053	-4.74599
(4,0)(0,0)	404.88011	-4.77701	-4.66498	-4.73154
(0,2)(0,0)	402.83389	-4.77645	-4.70177	-4.74614
(2,0)(0,0)	402.81721	-4.77625	-4.70157	-4.74594
(1,1)(0,0)	402.81672	-4.77625	-4.70157	-4.74594
(1,2)(0,0)	403.36724	-4.77087	-4.67751	-4.73298
(2,1)(0,0)	403.32252	-4.77033	-4.67698	-4.73244
(2,2)(0,0)	404.26687	-4.76966	-4.65764	-4.72420

Akaike Information Criteria (top 20 models)



Fuente: Elaboración propia

Caso 8: Analisis del Índice de Precio del Aluminio

Automatic ARIMA Forecasting

Selected dependent variable: DLOG(PRICEAL)

Date: 05/06/24 Time: 18:56

Sample: 1990M01 2023M12

Included observations: 407

Forecast length: 8

Model maximums: (4,4)3(0,0)


Regressors: C

Number of estimated ARMA models: 25

Number of non-converged estimations: 0

Selected ARMA model: (3,2)(0,0)

AIC value: -3.27689102082



Fuente: Elaboración propia


Figura A17*Graficando todos los modelos Aluminio**Fuente: Elaboración propia*

Tabla A16**Determinación de los indicadores ARIMA Aluminio**

Dependent Variable: DLOG(PRICEAL)

Method: ARMA Maximum Likelihood (BFGS)

Date: 05/06/24 Time: 18:56


Sample: 1990M02 2023M12

Included observations: 407

Convergence achieved after 44 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.00078	0.00344	0.22517	0.82196
AR(1)	1.31772	0.03960	33.27278	0.00000
AR(2)	-1.28500	0.04087	-31.44137	0.00000
AR(3)	0.31847	0.03739	8.51663	0.00000
MA(1)	-1.03479	0.01818	-56.90460	0.00000
MA(2)	0.98042	0.02005	48.89926	0.00000
SIGMASQ	0.00213	0.00012	17.07685	0.00000
R-squared	0.10920	Mean dependent var		0.000887
Adjusted R-squared	0.09584	S.D. dependent var		0.048948
S.E. of regression	0.04654	Akaike info criterion		-3.276891
Sum squared resid	0.86651	Schwarz criterion		-3.207943
Log likelihood	673.84732	Hannan-Quinn criter.		-3.249606
F-statistic	8.17249	Durbin-Watson stat		2.000454
Prob(F-statistic)	0.00000			
Inverted AR Roots	.49-.85i	.49+.85i	.33	
Inverted MA Roots	.52+.84i	.52-.84i		

Figura A18**Tendencia Hodrick-Prescott Aluminio****Hodrick-Prescott Filter (lambda=14400)**

Fuente: Elaboración propia

Tabla A17*Determinación del mejor modelo Akeike (AIC Aluminio)*

Dependent Variable: DLOG(PRICEAL)


Date: 05/06/24 Time: 18:56

Sample: 1990M01 2023M12

Included observations: 407

Model	LogL	AIC*	BIC	HQ
(3,2)(0,0)	673.84732	-3.27689	-3.20794	-3.24961
(3,3)(0,0)	673.84765	-3.27198	-3.19318	-3.24080
(4,2)(0,0)	673.84764	-3.27198	-3.19318	-3.24080
(1,0)(0,0)	668.71786	-3.27134	-3.24179	-3.25965
(2,4)(0,0)	673.63845	-3.27095	-3.19215	-3.23977
(0,1)(0,0)	668.07580	-3.26819	-3.23864	-3.25649
(4,3)(0,0)	673.96966	-3.26766	-3.17902	-3.23258
(1,1)(0,0)	668.82298	-3.26694	-3.22754	-3.25135
(2,0)(0,0)	668.81094	-3.26688	-3.22749	-3.25129
(0,2)(0,0)	668.77776	-3.26672	-3.22732	-3.25113
(3,4)(0,0)	673.77663	-3.26672	-3.17807	-3.23163
(4,4)(0,0)	674.76723	-3.26667	-3.16817	-3.22769
(2,3)(0,0)	671.30267	-3.26439	-3.19544	-3.23710
(1,2)(0,0)	668.93037	-3.26256	-3.21331	-3.24307
(3,0)(0,0)	668.90087	-3.26241	-3.21316	-3.24292
(0,3)(0,0)	668.78852	-3.26186	-3.21261	-3.24237
(2,1)(0,0)	668.72154	-3.26153	-3.21228	-3.24204
(4,0)(0,0)	669.28931	-3.25941	-3.20031	-3.23602
(3,1)(0,0)	669.02044	-3.25809	-3.19899	-3.23470
(0,4)(0,0)	668.98374	-3.25791	-3.19881	-3.23452
(1,3)(0,0)	668.93346	-3.25766	-3.19856	-3.23427
(2,2)(0,0)	668.93189	-3.25765	-3.19855	-3.23426
(4,1)(0,0)	669.29923	-3.25454	-3.18559	-3.22726
(1,4)(0,0)	669.25645	-3.25433	-3.18538	-3.22705
(0,0)(0,0)	650.91064	-3.18875	-3.16905	-3.18095

Akaike Information Criteria (top 20 models)



Fuente: Elaboración propia

Caso 9: Análisis del Gas GLP

Automatic ARIMA Forecasting
 Selected dependent variable: LOG(INDEX PRICE GASPE)
 Date: 05/07/24 Time: 14:18
 Sample: 2019M01 2023M12
 Included observations: 60
 Forecast length: 8
 Model maximums: (4,4)3(0,0)
 Regressors: C

Number of estimated ARMA models: 25
 Number of non-converged estimations: 0
 Selected ARMA model: (4,1)(0,0)
 AIC value: -4.49337967229

Actual and Forecast





Figura A19*Graficando todos los modelos Gas GLP**Fuente: Elaboración propia*

Tabla A18**Determinación de los indicadores ARIMA GAS LP**

Dependent Variable: LOG(INDEX_PRICE_GASPE)

Method: ARMA Maximum Likelihood (BFGS)

Date: 05/07/24 Time: 14:16

Sample: 2019M01 2023M12

Included observations: 60

Convergence achieved after 17 iterations

Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	4.578396	0.047643	96.09778	0.000000
AR(1)	2.114131	0.156562	13.50349	0.000000
AR(2)	-1.853905	0.245694	-7.545598	0.000000
AR(3)	1.248807	0.177637	7.030101	0.000000
AR(4)	-0.529129	0.083967	-6.301599	0.000000
MA(1)	-0.790725	0.211189	-3.744162	0.000400
SIGMASQ	0.000483	7.09E-05	6.808212	0.000000
R-squared	0.964949	Mean dependent var	4.576288	
Adjusted R-squared	0.960981	S.D. dependent var	0.118377	
S.E. of regression	0.023383	Akaike info criterion	-4.49338	
Sum squared resid	0.028979	Schwarz criterion	-4.249039	
Log likelihood	141.8014	Hannan-Quinn criter.	-4.397805	
F-statistic	243.1818	Durbin-Watson stat	1.963074	
Prob(F-statistic)	0.000000			
Inverted AR Roots	.97-.12i	.97+.12i	.09+.74i	.09-.74i
Inverted MA Roots	.79			


Figura A20**Tendencia Hodrick-Prescott Gas GLP**

Tabla A19*Determinación del mejor modelo Akeike (AIC GAS GLP)*

Model Selection Criteria Table

Dependent Variable: LOG(INDEX_PRICE_GASPE)


Date: 05/07/24 Time: 14:16

Sample: 2019M01 2023M12

Included observations: 60

Model	LogL	AIC*	BIC	HQ
(4,1)(0,0)	141.80139	-4.49338	-4.249039	-4.397805
(4,3)(0,0)	143.722908	-4.490764	-4.176612	-4.367882
(4,2)(0,0)	141.95468	-4.465156	-4.18591	-4.355928
(2,4)(0,0)	141.913475	-4.463782	-4.184537	-4.354554
(4,4)(0,0)	143.625779	-4.454193	-4.105135	-4.317657
(3,4)(0,0)	142.287003	-4.4429	-4.128748	-4.320018
(3,3)(0,0)	140.390839	-4.413028	-4.133782	-4.3038
(4,0)(0,0)	138.018272	-4.400609	-4.191175	-4.318688
(1,1)(0,0)	135.094519	-4.369817	-4.230194	-4.315203
(3,2)(0,0)	137.557864	-4.351929	-4.107589	-4.256354
(1,4)(0,0)	137.481109	-4.34937	-4.10503	-4.253795
(3,1)(0,0)	136.32987	-4.344329	-4.134895	-4.262408
(1,2)(0,0)	135.292708	-4.34309	-4.168562	-4.274822
(2,1)(0,0)	135.200915	-4.34003	-4.165502	-4.271763
(1,3)(0,0)	135.941564	-4.331385	-4.121951	-4.249464
(3,0)(0,0)	134.473173	-4.315772	-4.141244	-4.247505
(2,2)(0,0)	135.378719	-4.312624	-4.103189	-4.230703
(2,3)(0,0)	136.218111	-4.30727	-4.06293	-4.211695
(1,0)(0,0)	127.592581	-4.153086	-4.048369	-4.112125
(0,4)(0,0)	119.374636	-3.779155	-3.56972	-3.697233
(0,3)(0,0)	117.823898	-3.760797	-3.586268	-3.692529
(0,2)(0,0)	104.59455	-3.353152	-3.213529	-3.298537
(0,1)(0,0)	78.834909	-2.52783	-2.423113	-2.48687
(0,0)(0,0)	43.400774	-1.380026	-1.310214	-1.352719

Akaike Information Criteria (top 20 models)



Anexo E: Análisis de los modelos Regression Simbolica

Tabla A20

Data Global price of Aluminum, U.S. Dollars per Metric Ton, Monthly, adjusted nov2019 to Dic2023, Proy junio2024 using the technique Regression Simbolica.

Ecuation	R-squared	RMS error	Main Error (relativa)	Function
EQ 01	0.0000	445.020	15.29%	2290.38
EQ 05	0.1250	416.287	14.61%	2012.4+10.9013*x
EQ 06	0.2706	381.418	13.21%	1542.84*atan(x)
EQ 07	0.6285	292.344	9.34%	(x-81.2333)*(-19.332-x)
EQ 09	0.6715	255.076	8.49%	1231.26+((57.1684-x)*1.76729*x)
EQ 10	0.7270	232.516	8.06%	2942.45-abs(51.9992*(x-27))
EQ 12	0.7393	227.233	7.82%	x+2913.76-51.7646*abs(-26.8793+x)
EQ 14	0.8202	188.684	5.86%	15.0671*x+2553.58-abs(51.6532*(x-24.155))
EQ 15	0.8329	181.938	5.16%	1909.62+(16.524*(x-32.0266*cos(-0.137004*x)))
EQ 16	0.9173	127.951	4.11%	2667.24+(91.1556*((0.800918+round(-0.018112*x))*(x-19.4111)))
EQ 18	0.9313	116.702	3.74%	2613.35+((x+75.0949)*((0.869796+round(-0.0183286*x))*(x-19.0835)))
EQ 20	0.9342	114.134	3.74%	2599.01+((1.66862*x+67.0296)*((0.893348+round(-0.0178852*x))*(x-19.1674)))
EQ 21	0.9468	102.664	2.99%	(28.856*x-525.337)*(atan((x-0.968955)*(27.9937-x))+1.09446)+2578.34
EQ 22	0.9535	95.998	2.88%	(30.684*x-556.396)*(atan(x)*tanh(27.9783-x)+1.10856)+2569.24
EQ 24	0.9573	91.910	2.69%	(31.4716*x-561.949)*(atan(x)*(tanh(27.9656-x)+0.513454)+0.368767)+2541.88
EQ 27	0.9611	87.727	2.77%	((30.6679+sin(x))*x-557.222)*(atan(x)*tanh(27.9289-x)+1.10419)+2570.76
EQ 29	0.9635	84.974	2.88%	((30.6506+1.95944*sin(x))*x-557.642)*(atan(x)*tanh(27.8736-x)+1.10064)+2571.78
EQ 30	0.9677	79.976	2.43%	((30.3307+sin(8.76767e+14*x))*x-547.144)*(atan(x)*tanh(27.9772-x)+1.12434)+2560.09
EQ 32	0.9763	68.554	2.29%	((30.1497+2.58482*sin(8.76715e+14*x))*x-546.45)*(atan(x)*tanh(27.9205-x)+1.12354)+2564.8
EQ 34	0.9792	64.155	2.35%	((30.0708+atanh(sin(8.90756e+14*x)))*x-546.625)*(atan(x)*tanh(27.9538-x)+1.11005)+2562.85
EQ 36	0.9817	60.136	2.14%	((29.8946+atanh(sin(8.90756e+14*(x-0.000188656))))*x-548.155)*(atan(x)*tanh(27.9759-x)+1.09446)+2569.74
EQ 39	0.9838	56.684	1.97%	((31.3679+0.145707*x*sin(3.53887e+14*(0.000430464-x))))*x-539.583*(atan(0.387684*x)*tanh(28.3313-x)+1.24048)+2466.91
EQ 42	0.9847	55.084	1.90%	(round(31.35+0.128252*x*sin(3.53887e+14*(-0.00175666-x)))*x-543.106)*(atan(0.418636*x)*tanh(28.2747-x)+1.22468)+2479.75
EQ 45	0.9858	52.948	2.04%	((31.7015+3.16952*sin(3.53887e+14*(-0.00175666-x)))*x-552.11)*(atan(0.420818*x)*tanh(28.2164-x)+1.20369)+tan(-1.87639*x)+2488.58
EQ 47	0.9882	48.406	1.75%	((30.8637+0.147939*x*sin(3.53887e+14*(-0.00175666-x)))*x-521.116)*(atan(0.393721*x)*tanh(28.3937-x)+1.26343)+tan(-1.87638*x)+2442.29
EQ 51	0.9902	44.101	1.56%	((30.7639+0.147686*x*sin(3.53887e+14*(-0.00175666-x)))*x-526.051)*(atan(0.421125*x)*tanh(28.3742-x)+1.24999)+(3.38745*tan((-1.00377)*4.99949*x)+2458.61)
EQ 54	0.9908	42.753	1.54%	(round(30.6001+0.154283*x*sin(3.53887e+14*(-0.00175666-x)))*x-519.122)*(atan(0.446242*x)*tanh(28.3649-x)+1.25673)+(3.53526*tan((-1.00377)*4.99951*x)+2456.24)
EQ 56	0.9912	41.788	1.48%	(round(30.5859+0.152022*x*sin(3.53887e+14*(-0.00175666-x)))*x-519.019)*(atan(0.536411*(-0.414287*x))*tanh(28.3523-x)+1.26316)+(3.49616*tan((-1.00377)*4.9995*x)+2457.27)

Fuente: Elaboración propia

Tabla A21

Data annual prices, 1974 to present 2023, nominal US dollars, Sawntwood, Malaysian (\$/cubic meter, Federal Reserve Bank of St. Louis, using the Regression Symbolic

Equation	R-squared	RMS error	Main Error (relativa)	Function
Eq 01	1.23E-32	205.871	39.68%	587.792
Eq 03	0.684977	182.461	31.38%	$20.3233 \cdot X$
Eq 05	0.684977	115.549	17.29%	$286.712 + 11.8071 \cdot X$
Eq 06	0.730426	109.278	16.31%	$121.42 \cdot \sqrt{X}$
Eq 08	0.730426	106.89	15.66%	$108.191 \cdot \sqrt{X} + 70.5616$
Eq 09	0.76947	98.8461	14.70%	$(28.1991 - 0.321415 \cdot X) \cdot X + 144.65$
Eq 10	0.811529	89.3753	11.93%	$850.35 - \text{abs}(-16.2755 \cdot X + 634.498)$
Eq 12	0.841431	82.3944	12.52%	$199.035 \cdot \text{round}(\sqrt{0.382069 \cdot X})$
Eq 14	0.896567	67.924	11.03%	$123.289 \cdot (\sqrt{X} + \cos(0.327193 \cdot X))$
Eq 16	0.921688	57.6323	9.00%	$123.313 \cdot (\sqrt{X} - \cos((-0.358109) \cdot (-5.7592 - X)))$
Eq 17	0.93266	53.4253	8.16%	$(\sqrt{X} + \cos(0.360922 \cdot (1.64757e+16 + X))) / 0.00803628$
Eq 21	0.942953	49.1753	7.21%	$(-0.048948 \cdot X + 5.36447) \cdot ((5.02503 - \cos(12.9276 \cdot (-0.332142 + X))) \cdot (X + 5.78053))$
Eq 24	0.950893	45.6789	7.15%	$(-0.054309 \cdot X + 5.90053) \cdot (\text{round}(4.54177 - \cos(12.9272 \cdot (-0.328961 + X))) \cdot (X + 5.84575))$
Eq 26	0.952909	44.7224	6.92%	$(83.8268 - 18.1009 \cdot \cos(0.362068 \cdot X + 2.00588)) \cdot \text{round}(\sqrt{2.19369 \cdot (0.252197 + X)})$
Eq 29	0.957678	42.3527	6.54%	$(1.84076 \cdot (\text{round}((-11.0529) / (2.31425 + X)) + 0.774313 \cdot \cos((-0.339436) \cdot (-0.956856 + X))) + 7.16432) \cdot (67.8518 + X)$
Eq 31	0.962378	39.9317	5.67%	$((-0.0647467) \cdot (9.23783 \cdot \cos(-0.481815 \cdot X) + X) + 7.42102) \cdot ((3.22241 - \cos((-12.9339) \cdot (7.41693 + X))) \cdot X) + 167.729$
Eq 34	0.965935	37.999	5.56%	$(24.2431 - \text{ceil}(5.21042 \cdot \cos((-56.1834) \cdot (1.25993 - X))) + 0.214414 \cdot X + 2.55887 \cdot \cos(-82.1555 \cdot X)) \cdot X + 173.471$
Eq 36	0.967411	37.1684	5.50%	$(23.2151 - (5.22497 \cdot \cos((-56.1817) \cdot (0.924025 - X)) + (\cos(X) + 0.197911 \cdot X) + 2.32437 \cdot \cos(-82.1572 \cdot X))) \cdot X + 175.676$
Eq 39	0.970799	35.1869	5.29%	$(24.1626 - \text{ceil}(5.15105 \cdot \cos((-56.1834) \cdot (1.25993 - X))) + (\cos(X) + 0.211952 \cdot X) + 2.47396 \cdot \cos(82.1552 \cdot X)) \cdot X + 174.211$
Eq 42	0.973691	33.3946	5.11%	$(24.2749 - \text{ceil}(5.16548 \cdot \cos((-56.1834) \cdot (1.25993 - X))) + (\cos(X) + 0.214779 \cdot X) + \text{round}(2.51573 \cdot \cos(82.1565 \cdot X))) \cdot X + 173.606$
Eq 44	0.974826	32.7104	5.11%	$\text{round}(2.94353 \cdot \cos((-0.337781) \cdot (-1.57072 + X)) + 12.6727) \cdot (X - 4.03977 \cdot \cos(0.491174 \cdot (-2.17681 + X)) - 3.92239 \cdot \cos(-0.122993 \cdot X) + 16.7089) + 59.3813$
Eq 47	0.978663	30.2634	4.27%	$\text{round}(2.99048 \cdot \cos((-0.337921) \cdot (-1.55986 + X)) + 12.6815) \cdot (X - 4.23484 \cdot \cos((-0.494627) \cdot (-2.35447 + X)) - 4.04377 \cdot \cos(\text{round}(0.132815 \cdot (-1.38976 + X))) + 21.6415)$
Eq 49	0.98058	28.6899	4.07%	$\text{round}(2.93781 \cdot \cos((-0.338009) \cdot (-1.56177 + X)) + 12.7001) \cdot (X - 3.97366 \cdot \cos((-0.490341) \cdot (-2.13773 + X)) - 4.17301 \cdot \cos(\text{round}(0.135221 \cdot (-2.03411 + X))) + 16.9522) + 60.7831$
Eq 52	0.982991	26.8513	3.69%	$\text{round}(2.93764 \cdot \cos((-0.338147) \cdot (-1.55896 + X)) + 12.7001) \cdot (X - \text{floor}(4.07522 \cdot \cos(0.491127 \cdot (-2.02142 + X))) - 4.12447 \cdot \cos(\text{round}(0.134256 \cdot (-1.8458 + X))) + 16.4052) + 61.5719$
Eq 58	0.984513	25.6201	3.71%	$\text{round}(2.94105 \cdot \cos((-0.338147) \cdot (-1.54862 + X)) + 12.7001) \cdot (X - (\cos(X) + \text{floor}(4.07641 \cdot \cos(0.491609 \cdot (-2.06999 + X)))) - 4.05386 \cdot \cos(\text{round}(0.133838 \cdot (-1.8402 + X))) + 16.3793) + 62.0208$
Eq 60	0.985517	24.7966	3.66%	$\text{round}(3.00029 \cdot \cos((-0.337669) \cdot (-1.55986 + X)) + 12.6815) \cdot (X - \text{floor}(4.07955 \cdot \cos(0.491127 \cdot (-2.02257 + X))) - 3.86009 \cdot \cos(\text{round}(0.132499 \cdot (-1.24589 + X))) + 16.0869 - \cos(0.692615 + X)) + 64.081$

Fuente: Elaboración propia.

Tabla A22

Data Producer Price Index by Industry: Crushed and Broken Limestone Mining: Primary Products, Index Dec 1983=100, Monthly, projection June 2024, using the Regression Symbolic

Equation	R-squared	RMS error	Main Error (relativa)	Function
Eq 03	0.9497	31.038	7.38%	$X+357.915$
Eq 05	0.9497	10.076	2.18%	$306.04+3.03429*X$
Eq 07	0.9638	8.543	1.71%	$333.53+0.0581071*X*X$
Eq 08	0.9696	7.834	1.65%	$316.726+\text{pow}(X,1.27834)$
Eq 09	0.9725	7.457	1.46%	$322.133+(0.0364079*X*(32.3415+X))$
Eq 10	0.9750	7.110	1.38%	$324.527+(0.346696*\text{pow}(X,1.5449))$
Eq 11	0.9775	6.745	1.29%	$(\log_2(X)-2.89196)*X+331.258$
Eq 12	0.9809	6.213	1.23%	$301.512+2.69589*X+\text{abs}(-19.7609+X)$
Eq 14	0.9821	6.018	1.17%	$302.081+\text{abs}(1.26345*(-18.5763+X))+2.52274*X$
Eq 15	0.9876	4.999	1.08%	$(1.70006-(-0.253022*\text{asinh}(X-24.6213)))*X+328.388$
Eq 18	0.9907	4.328	0.94%	$(1.84473-(-0.260845*\text{floor}(\text{asinh}(X-24.9858))))*X+328.413$
Eq 21	0.9911	4.234	0.90%	$\text{round}(((1.8697-(-0.256664*\text{floor}(\text{asinh}(X-25)))))*X+327.911)$
Eq 23	0.9925	3.895	0.83%	$(1.85957-(-0.257469*\text{floor}(\text{asinh}(X-24.9828))))*(\cos(X)+X)+328.132$
Eq 26	0.9934	3.650	0.80%	$(1.86028-(-0.256671*\text{floor}(\text{asinh}(X-24.9932))))*(X+\cos(145.533*X))+328.097$
Eq 28	0.9943	3.402	0.73%	$(1.84464-(-0.257572*\text{floor}(\text{asinh}(X-24.9834))))*(X+1.98498*\cos(1.01971*X))+328.421$
Eq 30	0.9946	3.304	0.70%	$(1.86649-(-0.253567*\text{floor}(\text{asinh}(X-24.994))))*(X+2.06977*\cos(0.963337-1.04377*X))+327.951$
Eq 33	0.9954	3.055	0.65%	$329.792+((\tanh(0.123638*(X-24.2893))+1.59958)*(X-(2.25416*(\cos(0.567684*X)-\cos(1.01782*X))))))$
Eq 36	0.9957	2.941	0.61%	$329.397+\text{round}((\tanh(0.121991*(X-24.2724))+1.61437)*(X-(2.05656*(\cos(-0.567076*X)-\cos(1.0176*X))))))$
Eq 37	0.9961	2.820	0.62%	$335.083+((\tanh(0.202037*(X-24.7537))+1.99531)*(-7.70175+X-(1.85941*(\cos(-0.532523*X-1.30646)-\cos(1.01856*X))))))$
Eq 39	0.9965	2.656	0.54%	$328.941+((\tanh(0.113957*(X-24.2893))+1.63777)*(X-(1.90166*(\text{sign}(\cos(-0.53552*X-1.18615)))-\cos(1.01641*X))))))$
Eq 41	0.9969	2.493	0.51%	$334.03+((\tanh(0.16894*(X-24.5382))+1.96048)*(-6.88978+X-(1.60984*(\text{sign}(\cos(-0.537837*X-1.11449)))-\cos(-1.0162*X))))))$
Eq 43	0.9972	2.369	0.47%	$332.803+((\tanh(0.194522*(X-25.3441))+2.29787)*(-5.34198+0.884321*X-(1.43933*(\text{sign}(\cos(-0.537181*X-1.124))- \cos(1.0162*X))))))$
Eq 45	0.9975	2.230	0.42%	$332.601+((\tanh(0.195525*(X-25.3702))+2.33433)*(-5.3358+0.877413*X-(1.44264*(\text{sign}(\cos(-0.536836*X-1.16278))- \cos(1.04289*X-0.972286))))))$
Eq 47	0.9982	1.927	0.38%	$333.543+((\tanh(0.22892*(X-25.6715))+2.42388)*(-6.155+0.869284*X-(1.43699*(\text{sign}(\cos(-0.535577*X-1.30187))-0.133061)- \cos(1.05007*X-1.28265))))))$
Eq 48	0.9985	1.745	0.37%	$334.405+((\text{round}(\tanh(0.233675*(X-25.9529)))+2.44597)*(-6.32048+0.862973*X-(1.35041*(\text{sign}(\cos(-0.534595*X-1.3054))- \cos(1.05141*X-1.34695))))))$
Eq 51	0.9988	1.556	0.33%	$331.127+(((\text{erf}(\text{round}(0.188003*(X-26.2805)))/1.20446)+2.23439)*(-4.98548+0.945366*X-(1.46816*(\text{sign}(\cos(-0.537397*X-1.13873))- \cos(1.05038*X-20742.2))))))$
Eq 54	0.9989	1.523	0.33%	$331.442+((\text{erf}(\tanh(0.0273005+\text{round}(0.18785*(X-26.0865)))))+2.23221)*(-5.22656+0.945918*X-(1.46444*(\text{sign}(\cos(-0.537115*X-1.15395))- \cos(1.0516*X-8496.35))))))$
Eq 55	0.9989	1.472	0.31%	$\text{round}(331.415+((\text{erf}(\tanh(\text{round}(0.187475*(X-26.0936)))+2.23685)*(-5.13002+0.944529*X-(1.47057*(\text{sign}(\cos(-0.536253*X-1.15441))- \cos(1.0503*X-9344.55))))))$

Fuente: Elaboración propia

Tabla A23

Data Global price of Copper, U.S. Dollars per Metric Ton, adjusted projection June 2024, using the Regression Symbolic technique.

Ecuacion	R-squared	RMS error	Main Error (relativa)	Function
Eq 05	0.04424	1143.49	11.89%	$18.39 * X + 8045.78$
Eq 06	0.43502	879.18	9.05%	$9393.88 - (15066.8 / X)$
Eq 08	0.50027	826.85	8.47%	$((-64450.6) / (X * X)) + 8917.92$
Eq 09	0.56065	775.98	7.73%	$8894.94 * \tanh(0.152329 * X)$
Eq 10	0.66221	679.80	6.60%	$((10745.5 / X) - X) * (X - 2.22627)$
Eq 12	0.70066	640.03	5.74%	$(X / (5.99695e-05 * X + 0.000471025)) + (-133.15 * X)$
Eq 12	0.74770	587.51	5.50%	$\cos(0.13538 * X) * ((-18655.3) / X) + 8635.71$
Eq 14	0.79141	534.20	4.84%	$10958.7 - (24222.8 / X) - (70.1862 * \text{fmod}(28.0153, X))$
Eq 16	0.82812	484.92	4.30%	$8842.86 - ((268.496 - 144.538 * \text{round}(0.049561 * X)) * (15.7984 - X))$
Eq 17	0.83861	469.89	4.40%	$11198.5 - (25952.4 / X) - (86.5641 * \text{fmod}(25.5423, -4.48193 + X))$
Eq 19	0.84849	455.60	4.10%	$8721.67 * (X / (X + (\cos((-0.172602) * (-4.38032 + X)) / 0.353658)))$
Eq 20	0.87450	415.78	3.97%	$8607.89 * (X / (X + 3.92335 * \cos(\cosh(0.0752767 * X))))$
Eq 21	0.88895	389.79	3.62%	$(((-71.1123) / (X - 30.792)) - 68.4168) * X - (10305.3 * (\text{pow}(0.889526, X) - 1.13952))$
Eq 22	0.89786	373.81	3.29%	$(10421 - (74.3588 * \text{fmod}(28.3636, -2.9091 + X))) * \text{erf}(0.065318 * (3.11903 + X))$
Eq 24	0.90826	354.88	3.28%	$8617.5 * (X / (X + 4.22291 * \text{erf}(\cos(\cosh(-0.0753897 * X)))))$
Eq 26	0.93761	292.19	2.72%	$8649.14 * (X / (X + 2.6879 * \tanh(3.04673 * \cos(\cosh(-0.0754751 * X)))))$
Eq 29	0.94391	277.02	2.57%	$10475.9 + ((3.44466 * \tan(3.19279 * X) - 42.118) * X - (40350.9 / (4.05383 + X - 2.44429e-05 * \exp(X))))$
Eq 30	0.94897	266.64	2.65%	$8648.19 * (X / (X + \text{round}(2.71361 * \text{erf}(\cos(\cosh(0.075466 * X)) / 0.402559))))$
Eq 34	0.96083	231.50	2.13%	$10615.7 + ((3.06797 * \tan(0.0499117 * (\cos(X) + X)) - 43.7714) * X - (42192.5 / (4.1987 + X - (-2.11496e-05 * \exp(X)))))$
Eq 36	0.96252	226.53	2.01%	$(((-59.987) / (\cos(X) - 31.7469 + X)) - (99.4094 - \tan((0.00156983 + X) * X))) * X - (11108.2 * (\text{pow}(0.916113, X) - 1.2003))$
Eq 40	0.96417	221.46	1.86%	$(((-67.7842) / (X - 31.6397 + \cos(X))) - (85.8331 - \lgamma(\tan(X * X + 0.00390022)))) * X - (10642.7 * (\text{pow}(0.909199, X) - 1.19367))$
Eq 42	0.97056	201.35	1.66%	$(((-52.0169) / (\cos(X) - 31.9309 + X)) - (86.1914 - \tan(X * X))) * X - (10790.9 * (\text{pow}(0.900649, X) - 1.1686) + \tan(0.99447 + X))$
Eq 44	0.97759	175.11	1.60%	$(((-56.8432) / (X - 31.7497 + \cos(X))) - (86.1956 - 1.90434 * \tan(X * X))) * X - (10732 * (\text{pow}(0.90256, X) - 1.17704) - \tan(0.996728 + X))$
Eq 46	0.98236	155.35	1.24%	$(((-57.9743) / (X - 31.856 + \cos(X))) - (81.6248 - \lgamma(\tan(X * X)))) * X - (10561 * (\text{pow}(0.899777, X) - 1.17574) + \tan(0.994456 + X))$
Eq 48	0.98399	148.11	1.29%	$(((-57.1752) / (\cos(X) - 31.7444 + X)) - (71.8521 - \lgamma(-0.623582 + \tan(X * X)))) * X - (10288.1 * (\text{pow}(0.890899, X) - 1.15999) - \tan(-2.14496 + X))$
Eq 51	0.98465	144.95	1.26%	$(((-57.4314) / (\cos(X) - 31.7408 + X)) - \text{round}(70.6497 - \lgamma(-0.623582 + \tan(X * X)))) * X - (10284.5 * (\text{pow}(0.890163, X) - 1.15653) - \tan(0.996631 + X))$
Eq 55	0.98588	139.00	1.17%	$(((-53.251) / (X - 31.8033 + \cos(X))) - \text{round}(70.6474 - \lgamma(-0.623582 + \tan(X * X)))) * (X + 1.51031) - (10306.7 * (\text{pow}(0.889568, X) - 1.16314) - \tan(0.996598 + 1.62832 * X))$
Eq 57	0.98853	125.27	1.13%	$(((-49.4413) / (X - 31.8501 + \cos(X))) - (74.6235 - \lgamma(-0.623582 + \tan(X * X)))) * (X + \cos(\tan(X))) - (10355.1 * (\text{pow}(0.891756, X) - 1.16434) - \tan(0.996653 + X))$
Eq 59	0.99044	114.42	1.11%	$(((-43.6925) / (X - 31.8994 + \cos(X))) - (72.7915 - \lgamma(-0.623583 + \tan(X * X)))) * (X + 2.25419 * \cos(\tan(X))) - (10307.1 * (\text{pow}(0.888867, X) - 1.1626) - \tan(0.996659 + X))$

Fuente: Elaboración propia

Tabla A24

Projection June 2024, using data from Real Fuel Price Indexes - Diesel Oil from January 2020 to December 2023 (BCRP), projection to June 2024, using the Regression Symbolic t technique

Ecuacion	R-squared	RMS error	Main Error (relativa)	Function
Eq 05	0.3564	12.22	8.65%	$87.0286+0.505594*x$
Eq 08	0.7493	9.805	5.58%	$113.541-abs(33-x)$
Eq 10	0.7844	6.349	5.04%	$93.9127+fmod(-13.502+x,-24.9561)$
Eq 12	0.7869	5.784	4.91%	$1.15518*fmod(x-13.6051,24.346)+93.4927$
Eq 14	0.8214	5.643	3.89%	$95.6906+16.8705*cos(0.78092+sqrt(x))$
Eq 15	0.8480	5.165	4.10%	$fmod(-7.64075+(x-(107.095/x)),27.3473)+94.4336$
Eq 18	0.8897	4.799	3.58%	$94.4115+fmod(-10.2732+x*tanh(x-11.2088),27.6581)$
Eq 20	0.9034	4.336	2.98%	$fmod(0.687021*x-(47.1048/abs(x-8.03671)),23.7934)+94.6056$
Eq 23	0.9144	3.800	2.79%	$80.0219+(0.717382*x+asinh((x-3.99864)*(169.441+(-4.45899*x))*(-12.0007+x)))$
Eq 24	0.9219	3.580	2.80%	$(-8.05811*cos(0.46378*x)+15.5665)*cos(sqrt(x)+0.728092)+96.3137$
Eq 26	0.9538	3.415	2.18%	$((-0.328459)*x*cos(0.464522*x)+16.6473)*cos(sqrt(x)+0.745999)+95.7898$
Eq 28	0.9595	2.628	2.06%	$(-0.00992239*x*x*cos(-0.464683*x)+16.9737)*cos(sqrt(x)+0.769368)+95.6739$
Eq 30	0.9633	2.460	1.92%	$(-0.00947796*x*(x*(cos(0.46441*x)+0.371168))+18.9373)*cos(sqrt(x)+0.732415)+96.8088$
Eq 32	0.9668	2.340	1.78%	$(0.581617*((14.4244-x)*(cos(0.429494*(2.99929+x))+0.47392))+19.4742)*cos(sqrt(x)+0.745595)+97.3259$
Eq 34	0.9695	2.225	1.73%	$(0.767422*((12.6843-x)*(cos((-0.428013)*(3.01838+x))+0.632472))+20.0846)*cos(sqrt(x)+0.712843)-0.232988)+102.762$
Eq 35	0.9710	2.134	1.66%	$round((0.580409*((14.0675-x)*(cos(0.428842*(3.04692+x))+0.459059))+19.4392)*cos(sqrt(x)+0.744606))+97.2212$
Eq 37	0.9728	2.081	1.64%	$round((0.724283*((12.7237-x)*(cos(0.428105*(2.91504+x))+0.595479))+20.0711)*cos(sqrt(x)+0.71392)-0.227308))+102.361$
Eq 39	0.9741	2.014	1.49%	$(0.754151*((12.7582-x)*(cos(0.425277*(3.26063+x))+0.620795))+19.9696)*cos(sqrt(x)+0.716484)-0.221202)+cos(x)+102.484$
Eq 40	0.9761	1.967	1.41%	$round((0.580409*((14.0675-x)*(cos(0.428842*(3.04692+x))+0.459059))+19.4392)*cos(sqrt(x)+0.745601))+cos(x)+97.2264$
Eq 42	0.9770	1.892	1.40%	$round((0.724283*((12.7237-x)*(cos(0.428105*(2.91504+x))+0.595479))+20.0879)*cos(sqrt(x)+0.71392)-0.227513))+cos(x)+102.366$
Eq 44	0.9799	1.852	1.21%	$round((0.580409*((14.0783-x)*(cos(0.428842*(3.04692+x))+0.458631))+19.432)*cos(sqrt(x)+0.744606))+0.0550061*x*cos(x)+97.2079$
Eq 47	0.9819	1.736	1.16%	$round(round((0.580409*((14.0783-x)*(cos(0.428842*(3.04692+x))+0.458631))+19.432)*cos(sqrt(x)+0.744606))+0.0570788*x*cos(x)+97.1606$
Eq 50	0.9837	1.643	1.06%	$round(round((0.580409*((14.0783-x)*(cos(0.428842*(3.04692+x))+0.458631))+19.432)*cos(sqrt(x)+0.744606))+(((-8.3136)/x)+1.79821)*cos(x))+97.0661$
Eq 55	0.9847	1.572	1.00%	$round(round((0.580409*((14.096-x)*(cos(0.428842*(3.04692+x))+0.458631))+19.4203)*cos(sqrt(x)+0.744606))+(((-4.62474)/x)+0.0652591*x)*cos(x)-0.191929))+97.3138$
Eq 59	0.9860	1.518	1.09%	$round(round((0.580409*((14.0783-x)*(cos(0.428842*(3.04692+x))+0.458631))+19.432)*cos(sqrt(x)+0.746926))+(((-8.3136)/x)+1.79821)*cos(x))+97.0661)-cos(-1.44456*x)$

Fuente: Elaboración propia

Tabla A24

Using data from Price Index by Industry: Stainless Mills and Ferroalloy Manufacturing, Jan2020 to Dec2023, projection to Jun2024, using the Regression Symbolic t technique.

Ecuation	R-squared	RMS error	Main Error (relativa)	Function
Eq 03	0.27529	68.108	23.85%	$X+249.796$
Eq 05	0.27529	63.475	21.66%	$206.166+2.71098*X$
Eq 06	0.45731	56.659	19.00%	$74.1574*\sinh(X)$
Eq 07	0.73289	47.431	15.78%	$0.383874*(X*(60.8859-X))$
Eq 08	0.64441	44.901	15.46%	$(88.2278-X)*\sqrt{X}$
Eq 09	0.76338	36.848	10.13%	$159.101*\text{round}(\text{atan}(X))$
Eq 11	0.83268	31.165	9.66%	$(189.386-X)*\text{round}(\text{atan}(X))$
Eq 13	0.87651	26.202	7.52%	$(43.7396/(-0.53364-\text{ceil}(-0.0638588*X)))+259.505$
Eq 15	0.93309	19.288	4.72%	$360.322-6.95*X+55.6497*\sinh(X-14.826)$
Eq 17	0.94858	16.909	4.30%	$146.684*\tanh(0.235695*(-15.002+X))+(324.205-4.333*X)$
Eq 20	0.96172	14.589	3.93%	$((3.86705*X-53.2259)/(0.236827*(3.89335+(0.010756*(-34.917+X)*X))))+219.974$
Eq 23	0.96347	14.252	3.74%	$(\text{floor}(3.88033*X-53.0539)/(0.238338*(3.88912+(0.0107686*(-34.9089+X)*X))))+220.332$
Eq 25	0.96613	13.722	4.26%	$300.965-\text{abs}(195.393-4.81694*X)*\cos(6.10307*(-1.81114+((-0.0998089)/X)+X))$
Eq 27	0.96796	13.347	4.11%	$295.277-(\text{abs}(202.176-4.94963*X)*(-0.0828568+\cos(6.10391*(-1.80845+((-0.11459)/X)+X))))$
Eq 29	0.96980	12.958	3.64%	$294.813-(\text{abs}(204.413-5.03326*X)*(-0.105338+\cos(6.10075*(-4.8838+((-0.138216)/(-0.60639+X))+X))))$
Eq 30	0.97257	12.348	3.64%	$285.684-((179.276-(3.69118*X+34.6362*\text{round}(\cos(0.167842*X))))*\cos(6.13805*(-1.91665+X)))$
Eq 31	0.97779	11.113	3.26%	$113.172+((5.4288-(0.253708*(X-\cos(-6.90951*X))-9.696))*(X+5.9026*\cos(0.236135*(3.2326+X))))$
Eq 33	0.98393	9.452	2.86%	$115.866+((5.17919-(0.249754*(X-2.11052*\cos(0.62503*X))-9.71298))*(X+6.02578*\cos(0.235138*(3.34221+X))))$
Eq 36	0.98567	8.927	2.67%	$115.826+((5.16115-(0.249524*(X-2.06686*\cos(0.624891*X))-9.72679))*\text{round}(X+6.09343*\cos(0.235048*(3.25478+X))))$
Eq 37	0.98661	8.629	2.27%	$111.522+((6.17728-(0.258592*(X-2.03351*\cos(0.628931*X))-9.156))*(X+4.25365*\tan(\cos(0.239251*(2.93246+X))))$
Eq 38	0.98788	8.227	2.19%	$(81.139-(\text{abs}(1.32684*(-15+X))-3.03019*\cos(-0.622864*X)))*\sqrt{X-6.16861*\cos(3.29007*(-0.25326*X))}$
Eq 41	0.99032	7.437	1.89%	$\text{ceil}(81.0786-(\text{abs}(1.34313*(-15.1343+X))-2.86883*\cos(-0.622249*X)))*\sqrt{X-6.17264*\cos(-2.98627*(-0.252199*X))}$
Eq 44	0.99067	7.242	1.84%	$\text{floor}(\text{ceil}(81.0786-(\text{abs}(1.34313*(-15.1343+X))-2.86883*\cos(-0.622249*X)))*\sqrt{X-6.14608*\cos(-2.98538*(-0.251806*X))}))$
Eq 47	0.99169	6.798	2.14%	$(3.29479*\cos(\sqrt{1.78507*(X-\cos(13.1897*X))})+5.56721*(0.894878*X-(6.64373*\cos((-1.19581)*(1.01183-\text{round}(X/0.197808)))))+158.979$
Eq 48	0.99204	6.655	1.89%	$2.88648*X+(-98.1336*\cos(0.160614*(5.03414-(X-((\cos(X)+3.69326)*\cos(6.12028*(536.109+X))-0.0572721*X*\cos(0.57962*X+4.48996))))))$
Eq 49	0.99267	6.481	1.87%	$(\cos(X+2.27489)+\text{ceil}(81.0529-(\text{abs}(1.3441*(-15.1475+X))-2.86883*\cos(-0.621389*X)))*\sqrt{X-6.1679*\cos(-2.98762*(-0.252243*X))})$
Eq 51	0.99458	5.490	1.57%	$2.83871*X+(-98.4996*\cos((-0.159771)*(4.956-(X-((\cos(0.976576*X)+3.73336)*\cos((-6.12029)*(-6.97366+X))-0.0559904*X*\cos(0.5659*X+708.593))))))$
Eq 53	0.99501	5.266	1.57%	$2.80581*X-98.4287*\cos((-0.158981)*(4.9-(X-((1.32537*\cos(-0.975761*X)+3.72097)*\cos((-6.12059)*(2.26645+X))-0.05666*X*\cos(0.565697*X-7.71283))))))$
Eq 54	0.99574	4.865	1.49%	$2.71832*X-99.5643*\cos(0.158811*(4.95798-(X-((\cos(0.97732*X)+3.61095)*\cos((-6.12009)*(-5.95579+X))-0.0563752*X*\cos(\text{round}(566.018*X)-0.399098))))))$
Eq 57	0.99650	4.414	1.24%	$2.69887*X-98.5746*\cos((-0.159091)*(5.0108-(X-((\cos(-0.978437*X)+3.59228)*\cos((-6.11902)*(-7.99976+X))-0.0572643*X*\cos(\text{round}(566.018*X)-(13.6852/X))))))$
Eq 59	0.99684	4.190	1.20%	$2.68641*X-98.4803*\cos(0.159364*(5.69126-(X-((\cos(-0.978649*X)+3.55344)*(-0.183679+\cos((-6.11774)*(-17.2398+X))-0.0568603*X*\cos(\text{round}(566.018*X)-(14.1865/X))))))$

Fuente: Elaboración propia

Tabla A25

Using data price index by industry: Steel wire drawing: Jan 2020 to Dec2023, projection to june2024, using the Regression Symbolic technique

Ecuacion	R-squared	RMS error	Main Error (relativa)	Function
Eq 03	0.56557	40.248	14.14%	$x+248.315$
Eq 05	0.56557	32.514	10.62%	$202.068+2.77324*x$
Eq 06	0.67693	29.819	10.00%	$72.3942*\sinh(x)$
Eq 08	0.67693	28.039	9.85%	$55.7247+58.084*\sinh(x)$
Eq 09	0.85966	18.496	6.38%	$123.981+((-0.154847*x+10.8638)*x)$
Eq 10	0.87254	17.612	5.95%	$212.956-(-95.9986*\text{round}(0.0267975*x))$
Eq 11	0.95711	10.217	3.50%	$252.018-76.176*\cos(0.0925255*x)$
Eq 13	0.96552	9.1594	2.89%	$261.659-(-70.2421*\cos(3.57093-0.105292*x))$
Eq 14	0.98088	6.8235	2.26%	$(-0.166769*\text{abs}(x-26.6604)+5.57656)*x+177.749$
Eq 15	0.98304	6.4361	1.85%	$275.288-((x-88.8389)*\cos(8.6021+0.116845*x))$
Eq 16	0.98798	5.7198	1.85%	$x-(\sin(-0.159984*x)/(-0.0223319))+x+227.005$
Eq 17	0.99514	3.4376	1.03%	$217.587+(2.36725*x+43.6143*\cos(0.160183*(x-28.6916)))$
Eq 20	0.99553	3.2992	0.98%	$2.40343*x+216.548+\text{ceil}(43.5488*\cos((-0.16219)*(x+10.1509)))$
Eq 21	0.99662	2.8688	0.89%	$217.132+(2.39229*x+38.636*\sinh(\cos((-0.160504)*(x-28.6879))))$
Eq 22	0.99676	2.8090	0.91%	$2.35794*x+(44.3943*\cos(0.163578*(-105.311+\text{round}(0.986844*x)))+217.86)$
Eq 23	0.99701	2.6965	0.84%	$212.806+(2.37192*x+38.6577*\sinh(0.0947226+\cos(0.1597*(x-28.7189))))$
Eq 24	0.99715	2.6319	0.81%	$2.35846*(2.28729+x)+(44.2229*\cos(-0.166417*\text{round}(-103.385+0.972762*x))+213.101)$
Eq 27	0.99737	2.5374	0.81%	$\text{round}(2.38849*(2.02247+x))+(44.0961*\cos(-0.166338*\text{round}(-103.385+0.973311*x))+212.876)$
Eq 28	0.99787	2.2780	0.73%	$183.256-(43.0002-((\cos(3.31033*\text{fmod}(x,-0.143368))+(-1.95783+(-0.163702*x)))+3.23454)*(17.0195+x)))$
Eq 29	0.99832	2.0254	0.63%	$216.929-(-2.41408*x-0.144577*x*\cos(-0.442066*x)-43.9963*\cos(0.162642*x+1.62274))$
Eq 31	0.99855	1.8777	0.59%	$216.972-(-2.41217*x-(0.234042*(-12.8254+x)*\cos(0.440878*x))-43.9988*\cos(0.162253*x+1.64176))$
Eq 34	0.99877	1.7322	0.53%	$217.147-(-2.40422*x-\text{round}(0.233518*(-12.3437+x)*\cos(-0.440437*x))-44.1425*\cos(0.162273*x+1.63855))$
Eq 37	0.99899	1.5671	0.48%	$217.6-(\text{ceil}(-2.40481*x-\text{round}(0.229345*(-12.3195+x)*\cos(-0.440527*x)))-44.272*\cos(0.161941*x+1.6455))$
Eq 40	0.99917	1.4193	0.43%	$217.634-(\text{ceil}(-2.40481*x-\text{round}(0.228096*(-12.3195+x)*\cos(-0.440527*x)))-\text{round}(44.3316*\cos(0.16203*x+1.64655)))$
Eq 47	0.99922	1.3812	0.45%	$\cos(7.11385*(\cos(x)-0.210662))+217.276-(-2.40255*x-\text{round}(0.225642*(-12.3195+x)*\cos(-0.440527*x))-44.2418*\cos(0.161635*x+1.65005))$
Eq 49	0.99925	1.3511	0.39%	$217.73-(\text{ceil}(-2.40481*x-\text{round}(0.22518*(-12.3195+x)*\cos(0.440749*x)))-(\text{round}(44.3316*\cos(0.162023*x+1.646))-574.302*\text{pow}(x,-5.07241))))$
Eq 50	0.99940	1.2075	0.40%	$\cos(7.13824*(\cos(x)-0.204942))+217.698-(\text{ceil}(-2.40481*x-\text{round}(0.225642*(-12.3195+x)*\cos(-0.440527*x)))-44.3915*\cos(0.161621*x+1.65132))$
Eq 53	0.99956	1.0419	0.33%	$\cos(7.20425*(\cos(x)-0.203348))+217.56-\text{round}(\text{ceil}(-2.40481*x-\text{round}(0.225642*(-12.3195+x)*\cos(-0.440877*x)))-44.175*\cos(0.161571*x+1.64998))$
Eq 56	0.99961	0.9812	0.30%	$0.201868))+217.637-\text{round}(\text{ceil}(-2.40481*x-\text{round}(0.225642*(-12.3195+x)*\cos(-0.440877*x)))-44.175*\cos(0.161571*x+1.64998))$
Eq 57	0.99964	0.9328	0.32%	$\tan(-37.2903+\cos(7.12291*(\cos(x)-0.182223)))+216.854-(\text{ceil}(-2.40481*x-\text{round}(0.233848*(-12.3195+x)*\cos(-0.440943*x)))-44.4909*\cos(0.161574*x+1.64863))$
Eq 60	0.99970	0.8597	0.27%	$\tan(0.285752+\text{round}(\cos(7.16641*(\cos(x)-0.185599))))+217.223-(\text{ceil}(-2.40481*x-\text{round}(0.232549*(-12.3195+x)*\cos(-0.440527*x)))-44.5631*\cos(0.161437*x+1.64965))$

Fuente: Elaboración propia

Tabla A26

Using the Regression Symbolic technique with the data of the price index for industrial products Potash, Soda, and Borate Mineral projected to January2024 to June2024

Ecuacion	R-squared	RMS error	Main Error (relativa)	Function
Eq 09	0.90233	10.820	3.11%	$0.137024 * ((-41.417 + X) * X) + 333.248$
Eq 11	0.92223	9.6554	2.51%	$299.694 - ((-0.00298545) * ((-35.9485 + X) * X * X))$
Eq 13	0.93209	9.4162	2.74%	$278.55 + (\cos(-0.123801 * X) * X + X)$
Eq 14	0.93568	8.7900	2.21%	$237.652 + \text{abs}(0.0633544 * X * X - 53.1953) + X$
Eq 15	0.94135	8.3860	2.13%	$280.088 + (X + ((X + 6.67113) * \cos(0.122102 * X)))$
Eq 18	0.96440	6.5409	1.84%	$274.665 + \text{abs}(X + ((X + 11.4474) * \cos(-0.125559 * X)))$
Eq 19	0.97069	5.9271	1.51%	$269.723 + \text{abs}(0.104168 * X * (\text{fmod}(-20, X) + X) - 28.2102)$
Eq 21	0.97274	5.7159	1.74%	$2.38065 * X - (\cos(\text{round}(0.110769 * (-2.03202 + X))) / (-0.02487)) + 246.649$
Eq 22	0.98783	3.8427	1.04%	$268.789 + \text{abs}(\text{round}(0.104912 * X) * (\text{fmod}(-20, X) + X) - 29.6953)$
Eq 24	0.98991	3.5053	0.92%	$268.482 + \text{abs}(\text{round}(0.110247 * (-1.60766 + X)) * (\text{fmod}(-20, X) + X) - 29.3876)$
Eq 26	0.99025	3.4224	0.89%	$268.959 + \text{abs}(\text{round}(0.10819 * (-0.973542 + X)) * (\text{fmod}(-20.2756, 0.759427 + X) + X) - 28.9677)$
Eq 29	0.99098	3.3026	0.87%	$268.897 + \text{round}(\text{abs}(\text{round}(0.108434 * (-1.40137 + X)) * (\text{fmod}(-20.2849, 0.315351 + X) + X) - 28.5489))$
Eq 30	0.99143	3.2166	0.90%	$268.622 + \text{abs}(\text{round}(0.105417 * X) * (\text{fmod}(\cos(95.9902 * X) - 20.1446, X) + X) - 29.0797)$
Eq 32	0.99301	2.9081	0.79%	$268.351 + \text{abs}(\text{round}(0.108473 * (-1.45177 + X)) * (\text{fmod}(\cos(95.9905 * X) - 20.1271, X) + X) - 28.8704)$
Eq 34	0.99391	2.7091	0.71%	$269.929 + \text{abs}(\text{round}(0.108614 * (-1.40555 + X)) * (\text{fmod}(\cos(-100.094 * X) - 20.5329, 0.432778 + X) + X) - 28.1721)$
Eq 35	0.99501	2.4455	0.65%	$269.31 + \text{abs}(\text{round}(0.108473 * (-1.46011 + X)) * (\text{fmod}(\cos(-5.79383 * \sqrt{X}) - 20.305, X) + X) - 28.0316)$
Eq 38	0.99563	2.2894	0.62%	$\text{round}(269.329 + \text{abs}(\text{round}(0.108473 * (-1.46011 + X)) * (\text{fmod}(\cos(-5.79383 * \sqrt{X}) - 20.3063, X) + X) - 28.0316))$
Eq 40	0.99583	2.2382	0.60%	$\text{round}(269.329 + \text{abs}(\text{round}(0.108473 * (-1.46011 + X)) * (\text{fmod}(\cos(-5.79383 * \sqrt{X}) - 20.3063, 0.066395 + X) + X) - 28.0316))$
Eq 41	0.99641	2.0748	0.54%	$267.784 + (\text{abs}(\text{round}(0.111694 * (-1.95848 + X)) * (\text{fmod}(-20, X) + X) - 29.1163) + (\cos((X - 0.993389) * 4.01164 * X + 4.18992) / 0.240142))$
Eq 43	0.99677	1.9695	0.50%	$267.762 + (\text{abs}(\text{round}(0.112639 * (-2.0338 + X)) * (\text{fmod}(-19.8617, -1.08291 * X) + X) - 29.84) + (\cos((X - 0.9937) * 4.01164 * X + 10.5294) / 0.236989))$
Eq 44	0.99697	1.9083	0.49%	$267.651 + \text{abs}(\text{round}(0.110346 * (-1.93704 + X)) * (\text{fmod}(-20, X) + X) - 29.1408) + \text{round}(\cos((X - 0.993252) * 4.01164 * X + 4.07644) / 0.232159)$
Eq 46	0.99717	1.8411	0.50%	$267.752 + (\text{abs}(\text{round}(0.111468 * (-1.69457 + X)) * (\text{fmod}(-20, X) + X) - 29.2889) + \cos(X) + (\cos((X - 0.993944) * 4.01164 * X + 4.19981) / 0.246321))$
Eq 48	0.99745	1.7655	0.43%	$\text{round}(268.158 + (\text{abs}(\text{round}(0.10938 * (-1.66972 + X)) * (\text{fmod}(-20.2237, 0.917423 + (-1.12704 * X) + X) - 28.7934) + (\cos((X - 0.994688) * 4.01164 * X + 10.5908) / 0.256978)))$
Eq 49	0.99769	1.6632	0.46%	$267.637 + \text{abs}(\text{round}(0.110796 * (-2.08409 + X)) * (\text{fmod}(-20, X) + X) - 29.2656) + \cos(X) + \text{round}(\cos((X - 0.993252) * 4.01164 * X + 4.07644) / 0.232159)$
Eq 53	0.99796	1.5713	0.45%	$267.607 + \text{abs}(\text{round}(0.110346 * (-1.88798 + X)) * (\text{fmod}(-20, X) + X) - 29.2626) + \text{sign}(\cos(X)) + \text{round}(\cos((X - 0.993252) * 4.01164 * X + 4.07644) / 0.232159)$
Eq 55	0.99820	1.4672	0.38%	$\text{round}(268.158 + (\text{abs}(\text{round}(0.10938 * (-1.66972 + X)) * (\text{fmod}(-20.2237, 0.917423 + (-1.12602 * X) + X) - 28.7934) + (\cos((X - 0.994817) * 4.01164 * X + 10.5908) / 0.256978))) + \text{sign}(\cos(X))$
Eq 60	0.99830	1.4296	0.40%	$267.878 - \text{round}(\cos(X * X)) + \text{abs}(\text{round}(0.110796 * (-2.0839 + X)) * (\text{fmod}(-20, X) + X) - 29.176) + \cos(X) + \text{round}(\cos((X - 0.993252) * 4.01164 * X + 4.07644) / 0.232159)$

Fuente: Elaboración propia

Tabla A27

Using the Regression Symbolic technique with the data of the index of the price of Nickel, U.S. Dollars per Metric Ton projected to January2024 to June2024

Ecuacion	R-squared	RMS error	Main Error (relativa)	Function
Eq 05	0.5095	2827.73	10.61%	$215.445 * X + 13667.1$
Eq 06	0.620588	2489.63	8.90%	$5095.1 * \operatorname{asinh}(X)$
Eq 08	0.642673	2413.57	8.64%	$((-326605)/(15.0147+X))+28231.7$
Eq 09	0.767078	1948.64	7.43%	$(X-71.8352)*(-12.3203*X)+6774.21$
Eq 10	0.833336	1648.35	6.25%	$24852.3-405.23*\operatorname{abs}(X-35.9198)$
Eq 11	0.85093	1558.92	5.66%	$11781.5-((-55.0606+X)*0.488585*X*X)$
Eq 14	0.863383	1492.38	5.61%	$18106.2-(-5661.39*\sin((X-9.87058e+15)/10.5609))$
Eq 16	0.870278	1454.23	5.36%	$11011.4+((415.462-\operatorname{abs}(0.309488*X*(-32+X)))*X)$
Eq 17	0.875613	1424.01	5.46%	$(444.737+6.22675*\lgamma(1.00001*(28-X)))*X+8174.1$
Eq 18	0.916622	1424.01	4.70%	$11851.3-((-54.7263+X)*((0.57874-\operatorname{fmod}(X,-0.169231))*X*X))$
Eq 20	0.92508	1105.16	4.57%	$10179.9-((\operatorname{pow}(1.1194,X)-\tan(-0.0492596*X)-420.122)*X)$
Eq 23	0.931197	1059.01	3.85%	$13200-((-54.7525+X)*(0.493607*(X+\tan(-1.45263*X+4.01747))*(X-5.15277)))$
Eq 24	0.935096	1028.64	4.54%	$(-12.3515*\operatorname{abs}(-35.596+X)+260.698)*(17.7165*(\cos(0.615509*X)+2.20783))+16139.6$
Eq 26	0.955336	853.312	3.60%	$11971.1-((-55.0622+(X-\operatorname{atanh}(\cos(\operatorname{pow}(1.25247,X)))))*0.458126*X*X)$
Eq 28	0.960556	801.891	3.28%	$(79.4946-\tan(1.00159+0.018156*X))*(4.33866*(0.627446*X-\operatorname{fmod}(3757.47,26.8834-X)))+15486$
Eq 31	0.964192	764.040	3.08%	$(81.9588-\tan(4.14305+3.15975*X))*(4.23402*(\operatorname{round}(0.621481*X)-\operatorname{fmod}(3757.47,26.8834-X)))+15520$
Eq 33	0.96635	740.743	2.93%	$(69.045+(-8.87374*\cos(X))-\tan(4.14407+0.0181757*X))* (5.51381*(0.579885*X-\operatorname{fmod}(3757.54,26.8831-X)))+15625.5$
Eq 35	0.970137	697.743	3.00%	$(69.045+(-8.87374*\cos(X))-\tan(4.14407+0.0181757*X))* (5.51381*(0.579885*X-\operatorname{fmod}(3757.54,26.8831-X)))+15625.5$
Eq 37	0.979772	574.255	2.34%	$(37.9902+(-8.86439*\cos(X))-\tan(4.14351+0.0182136*X))* (10.4932*(0.604559*(X-13.5253)-\operatorname{fmod}(3757.47,26.8834-X)))+18352.2$
Eq 40	0.984409	504.147	2.01%	$(41.6033+(-10.1728*\cos(-1.02305*X))-\tan(1.00344+0.0181751*X))* (9.36044*(0.623559*(X-13.2509)-\operatorname{fmod}(3757.47,26.8834-X)))+18184.3$
Eq 42	0.987749	446.848	1.66%	$13899.9+((1.72104*X+\operatorname{pow}(0.0449674,\cos(2.41927*(-0.442036+X)))-16.4335)*(\tan(8.43232-X)+(212.705-\exp(-1.08027-(-0.124047*X))))$
Eq 45	0.989105	421.391	1.55%	$13522.4+((\operatorname{round}(1.4776*X+\operatorname{pow}(0.0521775,\cos((-2.41958)*(-0.455358+X))))-12.4644)*(\tan(2.14986-X)+(246.032-\exp(-1.00505-(-0.12498*X))))$
Eq 47	0.989652	410.733	1.38%	$13539+(\operatorname{round}(1.45057*X+(0.663712*\operatorname{pow}(0.035849,\cos((-2.41799)*(-0.428344+X))))-12.3194)*(\tan(11.5746-X)+(252.912-\exp(-1.01313-(-0.125681*X))))$
Eq 50	0.994305	304.687	1.43%	$13553+((1.54944*X+\operatorname{pow}(0.0510123,\cos((-2.41637)*(-0.41336+X)))-14.3569)*(\tan(11.5745-X)+(239.896-\exp(-1.28579-(-0.130708*X))))- \tan(-0.0981376*X))$
Eq 53	0.995487	271.246	1.26%	$13542+((1.5461*X+\operatorname{pow}(0.050709,\cos(2.41676*(-0.415962+X)))-14.4329)*(\tan(8.43293-X)+(240.417-\exp(-1.26669-(-0.129944*X))))- \tan(108.275*\log_{10}(X)))$
Eq 56	0.99634	244.264	1.09%	$13431.5+((\operatorname{floor}(1.46644*X+\operatorname{pow}(0.0558512,\cos((-2.41585)*(-0.395316+X))))-13.0853)*(\tan(11.5746-X)+(258.509-\exp(-1.04213-(-0.126812*X))))- \tan(108.275*\log_{10}(X)))$

Fuente: Elaboración propia

Tabla A28

Using the Regression Symbolic technique with the data of the price indexes of Electric Rates - Industrial (BCRP) projected to January2024 to June2024.

Ecuatio n	R- square d	RMS error	Main Error (relativa)	Function
Eq 13	0.82355	3.1196	1.71%	$10.5517 * \cos((-1.37638e+43) * (-2.14103+X)) + 157.624$
Eq 16	0.83489	3.0427	1.65%	$\text{ceil}(10.3671 * \cos((-1.37638e+43) * (-2.14103+X)) + 156.687)$
Eq 17	0.84963	2.8798	1.49%	$8.54131 * \text{asin}(\cos((-1.37638e+43) * (-2.14103+X))) + 157.586$
Eq 20	0.86255	2.7811	1.46%	$\text{ceil}(9.07758 * \text{asin}(\cos((-1.37638e+43) * (-2.14103+X)))) + 157.26$
Eq 22	0.87007	2.677	1.45%	$155.08 + ((-2.26106) / \tan(0.0815308 * (-2.92333 * \cos(0.342317+X) + X)))$
Eq 23	0.90918	2.2382	1.12%	$155.683 + ((-2.87796) / \text{erf}(\tan(0.0805804 * (-2.5704 * \cos(X) + X))))$
Eq 25	0.91945	2.1077	0.89%	$156.107 + ((-2.58288) / \text{fmod}(\tan(0.0802631 * (-2.5841 * \cos(X) + X)), 1.55065))$
Eq 26	0.92508	2.0327	1.17%	$155.413 + ((-2.51628) / \text{erf}(\tan(0.0813892 * (-2.95242 * \cos(0.323369+X) + X))))$
Eq 27	0.9295	1.9719	0.89%	$155.74 + ((-2.58225) / \text{fmod}(\tan(0.0809766 * (-2.49972 * \cos(0.237844+X) + X)), -1.56428))$
Eq 28	0.9481	1.692	0.90%	$155.594 + ((-2.46041) / \text{erf}(\tan(0.0811615 * (-3.14178 * \cos(1.23062+0.974588*X) + X))))$
Eq 29	0.95456	1.5831	0.80%	$155.625 + ((-2.28812) / \text{fmod}(\tan(0.0812126 * (-2.99135 * \cos(0.942355+0.981754 * X) + X)) - 2.43037))$
Eq 30	0.9624	1.4401	0.74%	$155.856 + ((-3.59499) / \text{erf}(1.75546 * \tan(0.0810757 * (-3.47815 * \cos(1.29306 + 0.973105 * X) + X))))$
Eq 33	0.96474	1.3945	0.72%	$155.938 + ((-2.34382) / \text{erf}(\text{fmod}(\tan(0.0810664 * (-3.26479 * \cos(1.10686 + 0.977987 * X) + X)), -2.20961)))$
Eq 35	0.96718	1.3455	0.68%	$155.984 + ((-2.39094) / \text{erf}(\text{fmod}(\tan(0.0818156 * (-3.18943 * \cos(1.12591 + 0.977483 * X) + X)), -2.32972) - 0.0286781))$
Eq 37	0.96857	1.3167	0.68%	$155.955 + ((-2.52485) / \text{erf}(\text{erf}(\text{fmod}(\tan(0.0811325 * (-3.28511 * \cos(1.10896 + 0.978126 * X) + X)), -2.22077))))$
Eq 38	0.97553	1.1666	0.62%	$\tan(0.0379909 * (X + (2.75454 - \text{round}(\cos(0.10264+X) / 0.354857)))) + 156.674 - (40.6154/X) - \tan(0.0788355 * X)$
Eq 40	0.97764	1.1175	0.62%	$\tan(0.0383551 * (X + (2.40031 - \text{round}(\cos(0.123171+X) / 0.360537)))) + 156.064 - (23.9105 / (X - 1.71762)) - \tan(0.0790089 * X)$
Eq 41	0.98127	1.0171	0.54%	$155.936 + \cos(3.89483 * X) + ((-2.35888) / \text{erf}(\text{fmod}(\tan(0.0810711 * (-3.1865 * \cos(1.07266 + 0.978174 * X) + X)), 2.29333)))$
Eq 42	0.98443	0.9332	0.45%	$151.576 - (\tan(\cos(\text{round}(-0.545226 * X - 3.32447)) + 2.70759) + \text{lgamma}(\text{lgamma}(8.00104 * \cos(0.100152 * (X - 1.07123)))) - 1.56657)$
Eq 43	0.98543	0.8964	0.47%	$155.928 + 1.78896 * \cos(-3.8948 * X) + ((-2.34978) / \text{erf}(\text{fmod}(\tan(0.0810859 * (-3.14437 * \cos(1.05601 + 0.978121 * X) + X)), 2.34615)))$
Eq 45	0.98728	0.8374	0.45%	$155.071 + 1.94161 * \cos(\tan(6.00574 * X)) + ((-2.56197) / \text{erf}(\tan(0.0809931 * (\text{round}(-2.83181 * \cos(1.01526 + 0.976729 * X) + X))))$
Eq 47	0.98926	0.7696	0.40%	$154.9 + 2.0402 * \cos(\tan(6.00566 * X)) + ((-2.56207) / \text{erf}(\tan(0.0796368 * (\text{round}(-2.82348 * \cos(0.996568 + 0.977745 * X) + X) + 0.661617))))$
Eq 48	0.99016	0.7405	0.37%	$155.179 + 1.81097 * \cos(\tan(6.0058 * X)) + \text{round}((-2.5606) / \text{erf}(\tan(0.0810035 * (\text{round}(-2.80156 * \cos(1.00141 + 0.976729 * X) + X))))$
Eq 50	0.99198	0.6649	0.36%	$154.84 + 2.15431 * \cos(\tan(6.00568 * X)) + ((-2.5653) / \text{erf}(\tan(0.0790932 * (\text{round}(-2.82482 * \cos(1.07862 + \text{round}(0.984817 * X)) + X) + 0.925313))))$
Eq 52	0.99467	0.542	0.25%	$154.888 + ((1.89264 - \sin(X)) * \cos(\tan(6.00555 * X))) + ((-2.57332) / \text{erf}(\tan(0.0793217 * (\text{round}(-2.86242 * \cos(0.999343 + 0.97752 * X) + X) + 0.822602))))$
Eq 54	0.99505	0.5225	0.23%	$155.01 + ((1.85685 - \sin(X)) * \cos(\tan(6.00555 * X) - 0.143069)) + ((-2.58446) / \text{erf}(\tan(0.0791314 * (\text{round}(-2.77379 * \cos(1.07318 + 0.975571 * X) + X) + 0.901805))))$
Eq 55	0.99643	0.4436	0.21%	$154.848 + ((1.98748 - \sin(X)) * \cos(\tan(6.00555 * X))) + ((-2.57521) / \text{erf}(\tan(0.0790363 * (\text{round}(-2.82211 * \cos(1.07443 + \text{round}(0.984439 * X)) + X) + 0.960701))))$
Eq 57	0.9968	0.4199	0.18%	$154.983 + ((1.92571 - \sin(X)) * \cos(\tan(6.00555 * X) - 0.137099)) + ((-2.58858) / \text{erf}(\tan(0.0790196 * (\text{round}(-2.82994 * \cos(1.0773 + \text{round}(0.984521 * X)) + X) + 0.956295))))$

Fuente: Elaboración propia

Tabla A29

Using the Regression Symbolic technique with the data of the US Regular All Formulations Gas Price, Dollars per Gallon projected to January2024 to June2024.

Ecuacion	R-squared	RMS error	Main Error (relativa)	Function
Eq 05	11.383	0.0797	9.59%	$0.232189 * X + 94.252$
Eq 06	10.882	0.1590	9.23%	$((-30.2843)/X) + 102.898$
Eq 08	5.9867	0.8290	4.78%	$112.767 - \text{abs}(27.6785 - X)$
Eq 10	4.8760	0.8311	4.16%	$118.731 - 1.4771 * \text{abs}(-27.2978 + X)$
Eq 13	4.1821	0.8758	3.66%	$103.047 + 15.3157 * \sin((-0.15977) * (3.32587 + X))$
Eq 15	3.6685	0.9044	2.86%	$97.615 + 15.6363 * \sin(-0.180319 * X) + 0.232809 * X$
Eq 16	3.1631	0.9289	2.49%	$0.626029 * (1.32432 - \cos(X/0.000294199)) * X + 82.1058$
Eq 17	2.6730	0.9493	1.86%	$97.355 + 15.3875 * \sin((-0.164284) * (3.15727 + X)) + 0.231455 * X$
Eq 20	2.6053	0.9518	1.85%	$97.8357 + 15.3801 * \sin((-0.164283) * (3.154 + X)) + \text{floor}(0.231995 * X)$
Eq 23	2.5474	0.9541	1.75%	$96.8529 + \text{round}(15.1027 * \sin((-0.163988) * (3.17005 + X))) + \text{ceil}(0.232099 * X)$
Eq 25	2.4521	0.9573	1.82%	$117.577 + 6.38859 * \cos(\text{round}(0.229796 * (-3879.17 + X))) - 1.33573 * \text{abs}(-27.6245 + X)$
Eq 29	2.3325	0.9614	1.53%	$101.291 - ((-4.61438) * ((2.32032 * \text{round}(0.0148719 * X) - 3.95352) * \cos((-0.156119) * (X - 6.03975 + \cos(X)))))$
Eq 32	2.2094	0.9653	1.53%	$101.504 - ((-4.69008) * ((2.18075 * \text{round}(0.0151755 * X) - 3.90547) * \cos((-0.156218) * (X - 6.13649 + \cos(1.03163 * X)))))$
Eq 34	2.1050	0.9685	1.60%	$(\tan(-0.2518 + \cos(7.59002 / \text{pow}(1.03546, X + \cos(-1.55578 + 1.11891 * X)))) / (-0.0990247)) + 91.9064$
Eq 35	2.0230	0.9709	1.40%	$101.537 - ((-4.7057) * ((2.18384 * \text{round}(0.0153564 * X) - 3.91012) * \cos(0.156442 * (X - 6.13258 + \cos(\text{round}(-1.02596 * X)))))$
Eq 37	1.8602	0.9754	1.41%	$101.464 - ((-4.70182) * ((2.23218 * \text{round}(0.0153213 * X) - 3.95071) * \cos(0.154586 * (X - 5.99376 + 1.74186 * \cos(\text{round}(-1.02596 * X)))))$
Eq 40	1.6725	0.9801	1.23%	$101.587 + \tan(0.153262 * \tan(1.02279 * 3 * X)) - ((-4.67338) * ((2.29091 * \text{round}(0.0140238 * X) - 3.93192) * \cos((-0.159752) * (X - 5.93694)))))$
Eq 44	1.5955	0.9823	1.12%	$\text{round}(101.724 - ((-4.7017) * ((2.32511 * \text{round}(0.0153195 * X) - 4.01129) * \cos(0.155604 * (X - 5.97413 + 0.73622 * \text{atanh}(\cos(\text{round}(-1.02596 * X)))))$
Eq 46	1.3283	0.9875	1.08%	$101.549 + \tan(0.152929 * \tan(1.02279 * 3 * X)) - ((-4.68243) * ((2.29257 * \text{round}(0.0147322 * X) - 3.94322) * \cos((-0.157325) * (X - 5.83824 + \cos(X)))))$
Eq 49	1.2009	0.9899	0.99%	$\text{round}(101.549 + \tan(0.152929 * \tan(1.02279 * 3 * X)) - ((-4.67781) * ((2.27846 * \text{round}(0.0147363 * X) - 3.98104) * \cos((-0.156378) * (X - 5.85059 + \cos(X)))))$
Eq 53	1.1599	0.9904	0.91%	$101.453 + 0.209732 * \tan(1.02255 * X) - ((-4.71658) * ((2.25425 * \text{round}(0.0149424 * X) - 3.89367) * \cos(0.15708 * (X - 5.76001 + 0.570324 * \text{atanh}(\cos(-0.0100425 - \text{round}(-1.02596 * X)))))$
Eq 54	1.0807	0.9918	0.86%	$\text{round}(101.356 + 0.22416 * \tan(1.02253 * X) - ((-4.70406) * ((2.30621 * \text{round}(0.0150359 * X) - 3.89606) * \cos((-0.156244) * (X - 5.62588 + 0.644785 * \text{atanh}(\cos(\text{round}(-1.02596 * X)))))$
Eq 55	1.0513	0.9922	0.83%	$\text{round}(101.356 + 0.22416 * \tan(1.02253 * X) - ((-4.70406) * ((2.30621 * \text{round}(0.0150359 * X) - 3.89606) * \cos((-0.156244) * (X - 5.62588 + 0.644785 * \text{atanh}(\cos(0.00599329 + \text{round}(-1.02596 * X)))))$

Fuente: Elaboración propia

Anexo F: Reporte de hechos de importancia reportados Word Trade Organization

Tabla A30

Reporte de hechos de importancia económica reportados Word Trade Organization Nov2008 a Dic2023 (Organization., 2023)

FECHA	DESCRIPCION
11-Nov-08	La crisis 2008 empiezan a bajar las acciones de la bolsa New York
02-Abr-09	Las 20 economías más importantes de mundo se reúnen en Londres y crean Fondo de 1 billon de dólares para asistir a los países con mayores dificultades económicas, muchos países empiezan a desacelerar sus economías
29-Abr-09	La Organización OMS clasifica la Gripe H1N1 alerta 5 como pandemia inminente
06-May-10	El CircuitBreaker o interruptor del sistema se introdujo en junio del 2010 en la Bolsa de Valores de Nueva York ofreciendo un cese automático de trading en acciones que suben o caen demasiado rápido en un esfuerzo de evitar otro episodio como el "Flash Crash"
06-Mar-09	Se reporta la gripe H1N1 se reporta en México y 6 semanas siguientes se extiende por todo el Mundo
11-Jun-10	Mundial FIFA África
24-Jun-10	cuarta cumbre del G20 en Toronto (26 y 27 de junio)
30-Jun-10	Christian Wulff es elegido presidente de Alemania
04-Ene-11	La Fed amortigua la caída Mercados Financieros - Cinco Días
11-Ago-11	la situación se ve agravada el 2011 con la incertidumbre que trae su gran deuda soberana; tanto así que el viernes 5 de agosto la calificadora de riesgos financieros Standard & Poor's (S&P) rebajó la calificación de la deuda soberana de Estados Unidos, de AAA, la máxima calificación de fiabilidad, a AA+
08-Set-11	La banca mundial recibió ayudas por valor de más de la mitad del PIB de EEUU sin el conocimiento del Congreso de EEUU, obteniendo con ellas un beneficio de 13.000 millones de dólares. Entre los bancos que recibieron las ayudas se encuentran los españoles Santander y BBVA, que obtuvieron unos beneficios de 96,2 y 84,1 millones de dólares, este hecho duro varios meses
09-Dic-11	en Bruselas concluye la histórica cumbre europea destinada a tomar medidas para salvar el euro y solucionar la grave crisis de deuda soberana de los países de la Unión Europea; se acuerdan drásticas medidas de disciplina fiscal para reducir las deudas de las naciones europeas y así calmar a los mercados financieros, pero la cumbre se ve empañada por la negativa del Reino Unido a participar en el acuerdo, quedando aislado del resto de la Unión
11-Jul-12	El presidente del gobierno de España Mariano Rajoy anuncia medidas extraordinarias para contener el déficit público, entre ellas la subida del IVA y el recorte en el sueldo de los funcionarios.
23-Jul-12	La Bolsa de Madrid prohíbe operaciones cortas o bajistas debido a la crisis económica española. La prima de riesgo de la deuda española alcanza máximos históricos.
04-Ago-12	Juegos olímpicos de Londres
06Set12	el sector manufacturero EEUU encadenó en agosto tres meses consecutivos de contracción y su actividad cayó al nivel más bajo desde julio de 2009, esas noticias, unidas a unos datos sobre la actividad industrial china peores de lo previsto, provocaron que la mayor parte de los sectores de Wall Street cerrasen en terreno negativo,
18-Oct-12	En realidad, el empleo manufacturero cayó por segundo mes consecutivo, con un descenso de 16 mil puestos de trabajo en septiembre en los EEUU, Las demandas iniciales de desempleo han caído desde los máximos alcanzados a mediados de septiembre, para situarse en 367 mil demandas a finales del mes
18-Oct-12	La OMS anunció el fin de la pandemia de gripe A (H1N1).
26-Dic-12	Parálisis política y 800 mil funcionarios sin sueldo
27-Dic-12	Las preocupaciones sobre la salud de la economía mundial por síntomas de desaceleración, las tensiones comerciales de Estados Unidos y China, el cierre del Gobierno estadounidense y un aumento de las tasas de interés, han golpeado al mercado financiero desde finales del verano,
15-Feb-14	Precio petróleo OPEC valor máximo 105.38 \$7barril

11-Mar-14	Se declara pandemia del Ébola en África Occidental
11-Jun-14	Mundial Brasil
09-Oct-14	Tres países de África piden ayuda financiera al BM y FMI para combatir Ébola
31-Dic-14	precio petróleo OPED empieza a bajar 52.39 \$/barril cuando el promedio del mes Dic 2014 cierra 60.23 \$
07-Ene-15	Precio petróleo OPED valor máximo 44.79 \$/barril
31-Ago-15	Alza del petróleo no le alcanzó: Wall Street cierra con pérdidas y acumuló una caída de 6% en agosto
18-Set-15	emissionsgate y dieseltgate comenzó en septiembre de 2015 por Volkswagen
27-Ene-16	Wall Street cierra con fuertes pérdidas y el Dow Jones baja un 1,38 %, mal sabor de boca que dejaron los resultados de Boeing y Apple y a mitad de jornada remontaron las pérdidas animados por un rebote del petróleo. (el petróleo de Texas subía a 32,03 dólares, el oro avanzaba a 1.126,1 dólares)
03-Abr-16	Sale a luz Panamá Papers, sobre los paraísos fiscales de los jefes de estado, líderes políticos mundiales, personalidades de las finanzas, negocios, "el mundo tiembla sobre esta noticia"
03-May-16	Los operadores en Nueva York apostaron por las ventas de forma decidida arrastrados por la fortaleza del euro y el yen frente al dólar, y tras instalarse en los mercados nuevos temores sobre la economía mundial luego de un mal dato del sector manufacturero chino.
12-May-16	Michael tener asume la presidencia de Brasil reemplazando a Dima Rosel
26-Jun-16	Wall Street ha cerrado con fuertes pérdidas, tras una jornada de pánico en las bolsas mundiales por la victoria del "brexit" en el Reino Unido. (El petróleo se resiente por la decisión del Reino Unido. El Brent se desploma un 5,04% y pierde el nivel de los 50 dólares)
27-Jun-16	a caída de la Bolsa ha reflejado que el turismo será uno de los grandes afectados en España. Además, se espera que otros sectores puedan verse también afectados por la salida del Reino Unido, como la vivienda
04-Ago-16	Inauguración de los juegos olímpicos de Brasil
08-Nov-16	Donal Tramp gana las elecciones de EEUU
20-Ene-17	Donal Trump asume la presidencia de EEUU
16-May-17	se desvela que el presidente de Estados Unidos, Donald Trump, reveló información de Estado secreta sobre el grupo terrorista Estado Islámico a las autoridades rusas
17-May-17	El presidente Trump le pidió al entonces director del FBI, James Comey, que retrocediera en la investigación del exasesor de seguridad nacional Michael Flynn poco después de la renuncia de Flynn
01-Set-17	Rusia, el presidente Vladímir Putin expulsa a 755 diplomáticos estadounidenses en respuesta a las sanciones aprobadas por el Congreso de ese país contra Rusia
05-Set-17	Wall Street y el dólar caen por el nerviosismo de Corea del Norte, ensayos nucleares
11-Set-17	China se esfuerza por contener el yuan
24-Set-17	Alemania se celebran elecciones federales. Angela Merkel es reelegida Canciller, pero con una importante bajada de sus apoyos. Alternativa para Alemania, de carácter ultranacionalista y nazi, consigue 94 escaños
28-Nov-17	Donal Trump anuncia por tuit que no irían a una reunión programada con el presidente sobre un proyecto de ley de presupuesto que debe aprobarse antes del 8 de diciembre o habrá un cierre del gobierno.
15-Jun-18	Copa Mundial de Futbol en Moscú
06-Feb-18	Jerome Powell asumía la presidencia de la Reserva Federal. El viernes el selectivo ya vivió otro batacazo de cerca del 2,54% por el miedo a un alza más agresiva de los tipos de interés designado durante gobierno de Donal Trump
12-Feb-18	Los bancos chinos tuvieron un mes "absolutamente monstruoso" para nuevos préstamos
20-Feb-18	SHANGHAI—El banco central de China reanudó el lunes la emisión de préstamos a corto plazo en el mercado monetario del país, en una medida para aliviar las condiciones de financiación cada vez más estrictas después de suspender el servicio durante seis días hábiles
22-Mar-18	cada vez más nerviosos por una potencial guerra comercial entre Estados Unidos y China, evitaron el riesgo antes del fin de semana y buscaron refugio ante nuevas amenazas.

23-Mar-18	Los planes del presidente Donald Trump de imponer aranceles sobre hasta 60 mil millones de dólares en productos chinos acercaron a las dos economías más grandes del mundo a una guerra comercial, ya que China declaró planes para imponer aranceles sobre hasta 3 mil millones de dólares de importaciones estadounidenses
29-Ago-18	En una nueva corrida cambiaria los días 29 y 30 de agosto, la moneda argentina se devaluó un 15 por ciento en un solo día, en tanto la tasa de interés superó el 60%, convirtiéndose en la más alta del mundo. "crisis del peso argentino"
10-Oct-2018	Las acciones chinas están ahora en su nivel más bajo en cuatro años, ya que el aumento de las tasas de interés en Estados Unidos y la probabilidad de acuerdos comerciales menos favorables afectarán negativamente las ganancias de las empresas chinas el próximo año y su precio de mercado se está reajustando a la baja para reflejar eso", dijo Raich.
15-Dic-18	En la economía europea, y la Eurozona en particular, la desaceleración ya apreciable a finales de 2018 se ha agudizado con el frenazo de la industria alemana y la incertidumbre generada por el Brexit que se ha aliviado al cierre del año
25-Dic-18	La caída del lunes también se produjo después de que el presidente Donald Trump comentara una vez más sobre la Reserva Federal, calificándola de "el único problema que tiene nuestra economía" en un tuit.
02-Ene-19	Las bolsas de todo el mundo se han teñido de rojo en el estreno de 2019 debido al miedo a la ralentización de la economía global,
15-Ene-19	el parlamento Británico rechaza el plan Brexit de Theresa May
15-Feb-19	NUEVA YORK (AP) — Las acciones subieron el viernes en Wall Street después de que China y Estados Unidos acordaron continuar sus conversaciones comerciales la próxima semana en Washington.
13-Mar-19	El parlamento Británico Pide una prórroga para el Brexit
22-Mar-19	alimentando los temores de una recesión económica mundial.
24-Jul-19	Boris Jhonson releva a Theresa May como primer ministro de Reino Unido
31-Jul-19	La FED de USA baja los tipos por primera vez desde diciembre 2009
02-Ago-19	Donald Trump intensifica su ofensiva proteccionista
01-Oct-19	el llamado "indicador del miedo" que mide la volatilidad en el mercado- ha alcanzado máximos anuales cinco veces en octubre desde su creación en 1990
19-Nov-19	Confirman el primer caso de COVID19 en China
30-Oct-19	La FED de USA baja los tipos por tercera vez en el año a 1.5% a 1.7%
13-Dic-19	Donald Trump anuncia su primer acuerdo con China
09-Mar-20	Arabia Saudita vs Rusia: la guerra de precios que hundió el valor del petróleo y las bolsas mundiales en medio de la crisis por el coronavirus, el barril de Brent del mar del Norte para entrega en mayo valía 30,07 dólares en Londres
12-Mar-20	El pánico hunde unas Bolsas en caída libre: el Ibex se desploma un 14,06%, el mayor batacazo de su historia
16-Mar-20	el presidente Donald Trump tampoco pudo revertir la tendencia. Luego de que el mandatario afirmara que la pandemia no será controlada hasta julio o agosto, Wall Street cayó un más y el Dow Jones cerró con una baja del 12,93%, seguido por el Nasdaq con el 12,32% y el S&P 500 con el 11,98%
09-Nov-20	anuncian resultados de las Vacunas contra Coronavirus
30-Nov-20	Los inversionistas han reaccionado de forma positiva a la victoria del demócrata Joe Biden en las elecciones presidenciales de Estados Unidos y, también, recibido con optimismo los progresos en el desarrollo de varias vacunas potenciales contra el coronavirus.
01-Feb-21	adquisición de nuevas dosis de vacunas contra el Covid-19 de Pfizer y BioNTech frente otras vacunas
01-Abr-21	el bitcoin alcanzaba sus máximos históricos impulsado por la salida a bolsa de Coinbase, la mayor plataforma de intercambio de monedas criptográficas en EEUU.
05-Abr-21	la Bolsa de Valores de Nueva York debido a que los inversionistas acogieron con satisfacción más señales de que la economía está en vías de recuperación.
12-May-21	En Estados Unidos, la inflación se disparó hasta el 4,2%, en máximos desde 2008. Esto provocaba que Wall Street encadenara varias jornadas seguidas en rojo.

01-Jun-21	la rebautizada como variante Delta, que tuvo su origen en la India, empezaba a suponer un riesgo para la temporada estival. Las restricciones de Reino Unido ahogaban a destinos turísticos.
19-Jul-21	Los principales índices de Wall Street cayeron bruscamente en la apertura del lunes, y las acciones vinculadas a la economía y los viajes se vieron afectadas después de que un aumento en los casos globales de COVID-19 generó nuevas preocupaciones sobre la desaceleración del crecimiento económico.
01-Ago-21	Una noticia geopolítica giró la atención de los inversores: los talibanes reconquistaron Kabul y declararon el fin de la guerra en Afganistán, en el plano económico los analistas empezaban a recortar sus previsiones debido al avance de la variante Delta
01-Set-21	El petróleo comenzó a pulverizar sus máximos anuales y muchos analistas preveían que pudiera alcanzar los 90 dólares o incluso los 100 dólares
18-Set-21	la gran cadena de distribución Walmart, el mayor empleador privado de EE UU, anunció que sus ganancias habían caído en el primer trimestre de su ejercicio fiscal un 25% respecto al mismo periodo del año anterior en el trimestre
01-Nov-21	El cóncilave monetario de la Fed decidió reducir el paquete de estímulos activado para suavizar la crisis del coronavirus en 15.000 millones de dólares mensuales, reducción de estímulos que también fijó el BCE para Europa, que anunció el fin del PEPP (programa de compras de emergencia frente a la pandemia) y el aumento del APP (programa de compras habitual)
26-Nov-21	Bolsas de valores se hunden por temor a la variante ómicron, Los mercados de todo el mundo sufrieron retrocesos ante la posibilidad de que la variante obligue a imponer nuevas restricciones a los viajes y se vuelva a limitar a la ciudadanía.
01-Dic-21	aparece virus Ómicron. Ese día, las bolsas de todo el mundo se hundieron ante la incertidumbre. la recuperación se ve amenazada de nuevo por la pandemia
18-Ene-22	influyeron las cifras peores de lo esperado de las ventas del sector minorista en la época navideña y el gran número de despidos que están acometiendo Microsoft y Amazon
28-Ene-22	Los inversores han mostrado su inquietud ante la probable subida de los tipos de interés por parte de la Reserva Federal en marzo y el inicio de la reducción del balance del banco central, que se anticipa pronto.
03-Feb-22	Meta fue la protagonista de la sesión tras divulgar el miércoles un descenso en el beneficio trimestral, una reducción de usuarios activos diarios, pérdidas en el segmento dedicado al metaverso y unas débiles proyecciones de futuro
24-Feb-22	Rusia invade Ucrania
26-Feb-22	Los aliados de Ucrania le prometen apoyo económico y en material de guerra. Desde que el jueves comenzó la ofensiva militar rusa contra Ucrania,
28-Feb-22	Se bloquean las reservas internacionales del Banco Central de Rusia
05-May-22	Los precios de las acciones cerraron el jueves con una pérdida significativa en Wall Street debido a los temores en los mercados de que el aumento en las tasas de interés del Banco Central para combatir la inflación desacelere la economía
05-May-22	La comunidad internacional promete más de 6.000 millones de euros de ayuda humanitaria a Ucrania Kiev necesita de forma urgente más de 12.000 toneladas de alimentos, medicinas y artículos de higiene al día
18-May-22	La economía global está en peligro de entrar en un período de la llamada estanflación, o alta inflación y crecimiento débil, La secretaria del Tesoro, Janet Yellen, se convirtió el miércoles en la última líder en advertir sobre turbulencias en la economía global. "Ciertamente, el panorama económico a nivel mundial es desafiante e incierto", dijo Yellen en Bonn, Alemania, antes de una reunión de líderes de siete naciones ricas. "El aumento de los precios de los alimentos y la energía está teniendo efectos negativos, es decir, deprimiendo la producción y el gasto y aumentando la inflación en todo el mundo".
15-Jun-22	La Reserva Federal de Estados Unidos (Fed en inglés) anunció este miércoles la subida de tipos de interés más alta en 28 años a medida que se apresura a combatir la elevada inflación que se vive en el país.
15-Jul-22	La economía de Estados Unidos se ha recuperado con rapidez de la pandemia; sin embargo, el repunte de la demanda ha provocado tensiones

21-Jun-22	La inflación y los temores sobre el crecimiento chocan para aumentar la volatilidad del mercado de bonos, BEIJING—Las empresas estadounidenses en China dicen que temen que una ley estadounidense que bloquea la mayoría de las importaciones de la región china de Xinjiang y que entró en vigor el martes pueda interrumpir los envíos y aumentar los costos de cumplimiento, mientras la incertidumbre nubla cómo se aplicará.
24-Jun-22	La confianza del consumidor cayó a su punto más bajo registrado, lo que refleja que la inflación elevada está pesando sobre el estado de ánimo de los estadounidenses y sumándose a los indicadores que apuntan a una desaceleración en la economía más grande del mundo.
22-Jul-22	Las acciones estadounidenses cerraron a la baja el viernes debido a que las decepcionantes ganancias de Snap asustaron a los inversores y las acciones de empresas de medios sociales y tecnología publicitaria cayeron,
22-Ago-22	Los temores de desaceleración afectan a los mercados a nivel mundial. El banco central de China recortó el lunes algunas tasas de interés clave en un intento por apoyar una economía en desaceleración y un sector inmobiliario en dificultades
23-Set-22	Las acciones cayeron con fuerza en todo el mundo este viernes por las preocupaciones de que una economía mundial, que ya se está desacelerando, podría caer en una recesión a medida que los bancos centrales aumentan la presión con aumentos adicionales en las tasas de interés.
03-Oct-2022	Estados Unidos busca restringir aún más las exportaciones de chips de última generación a China
07-Oct-22	Los fabricantes de chips de memoria luchan contra la caída de la demanda y el precio
13-Oct-22	Los mercados bursátiles estadounidenses cerraron a la baja el miércoles tras la publicación de un indicador de inflación. Wall Street se mantuvo muy volátil durante toda la sesión bursátil. Los participantes del mercado están esperando que se publique una métrica clave de inflación el jueves.
10-Nov-22	Wall Street cierra con fuertes alzas ante señales de enfriamiento de la inflación
28-Nov-22	Las acciones cayeron ampliamente en Wall Street a medida que se extendieron las protestas en China pidiendo la renuncia del presidente Xi Jinping en medio de una creciente ira por las severas restricciones impuestas como parte de su estrategia de "covid cero" en la segunda economía más grande del mundo y los comentarios agresivos de los funcionarios de la Reserva Federal sobre el camino de los aumentos de las tasas de interés.
15-Dic-22	se intensificaban los temores de que la batalla de la Reserva Federal contra la inflación mediante aumentos agresivos de las tasas de interés podría llevar a a una recesión
22-Dic-22	Los precios del petróleo suben
29-Dic-22	La inflación persistente y las agresivas subidas de tipos por parte de la Reserva Federal perjudicaron a las acciones tecnológicas y de crecimiento y pesaron sobre la confianza de los inversores durante todo el año
05-Ene-23	Wall St cae más del 1% y los datos de empleo alimentan los temores de un mayor ajuste de la Fed
18-Ene-23	En datos económicos, las ventas minoristas en EE.UU. caen en diciembre, La producción fabril de EE.UU. cae más de lo esperado
16-Feb-23	16 feb (Reuters) - Wall Street cerró bruscamente a la baja el jueves después de que datos de inflación inesperadamente sólidos y una caída en las solicitudes semanales de desempleo se sumaron a los temores de que la Reserva Federal de Estados Unidos seguirá aumentando las tasas de interés para controlar los altos precios.
17-Mar-23	"(La venta masiva) es una reacción un poco exagerada", dijo Oliver Pursche, vicepresidente senior de Wealthspire Advisors en Nueva York. "Sin embargo, algunas de las preocupaciones sobre la liquidez general y una posible crisis de liquidez son válidas". Esas preocupaciones se han extendido a Europa, mientras las acciones de Credit Suisse (CSGN.S), abre nueva pestaña tropezaron por preocupaciones de liquidez, lo que llevó a las autoridades a luchar para tranquilizar a los mercados
22-Mar-23	"Esta minicrisis bancaria ha aumentado las posibilidades de recesión y ha acelerado el cronograma de desaceleración de la economía", dijo Pursche. "Es natural que la Reserva Federal reexamine su curso de acción, pero aún está muy claro que, si bien la inflación se está desacelerando, sigue siendo una gran preocupación y es necesario controlarla".
27-Abr-23	Wall Street atravesó su mejor día desde enero después de que Meta Platforms se convirtiera en la última gran empresa tecnológica en superar las previsiones de beneficios.
18-May-23	EE UU y los países del G-7 aprobarán más sanciones contra Rusia por la guerra de Ucrania, según Washington

06-Jul-23	las lecturas de inflación de la semana pasada, tanto a nivel de productores como de consumidores, fueron mejores de lo esperado, lo que respalda aún más la noción de un aterrizaje suave para la economía
07-Set-23	Ucrania hace retroceder a las tropas rusas de Bajmut
26-Set-23	la ansiedad de los inversores se sumó la posibilidad de un cierre parcial del gobierno estadounidense durante el fin de semana, que la agencia de calificación Moody's advirtió que dañaría el crédito del país.
27-Oct-23	Los mercados se están tomando un respiro para digerir estas ganancias que hemos visto en noviembre, adelantan ofertas del Cyber Monday.
11-Dic-23	El Fondo Monetario Internacional hoy aprobó US\$900 millones a través de la segunda revisión del programa de financiamiento a Ucrania
18-Dic-23	La Unión Europea impuso nuevas sanciones a Rusia por la guerra contra Ucrania


Fuente: Elaboración propia

Anexo F:**Figura A21**

Tabla de trabajo modelo Benchmarking utilizado proyecto cadena de Valor

Matriz Poder / Interés				Matriz Poder/ Influencia			
Poder (nivel autoridad)	Alto	Mantener satisfechos	Gestionar atentamente (Oportunidades Amenazas)	Poder (nivel autoridad)	Alto	Mantenerlos informados y nunca ignorarlos	Trabajar para ellos
	Bajo	Monitorear (Esfuerzo mínimo)	Mantener informado		Bajo	Mantenerlos informados con mínimo esfuerzo	Trabajar con ellos
		Alto	Bajo			Alto	Bajo
Interés (Preocupación o conveniencia)				Influencia (Involucramiento activo)			
Matriz Influencia/ Impacto				Matriz Cooperación/ Amenaza			
Impacto (Capacidad para efectuar cambios al planeamiento o ejecución del proyecto)	Alto	Mantenerlos informados y nunca ignorarlos	Trabajar para él	Cooperación	Alto	Implicar: Grupo de interés de apoyo	Colaborar: Grupo de interés mixto
	Bajo	Mantenerlos informados con mínimo esfuerzo	Trabajar con ellos		Bajo	Controlar: Grupo de interés marginal	Defensa: Grupo de interés no-apoyo
		Alto	Bajo			Alto	Bajo
Influencia (Involucramiento activo)				Amenaza			

Fuente: Elaboración propia

Figura A22*Relación con otras normas de Gestión de Calidad*

Referencia: Inacal -GQSP_Colombia, Diseño propio