



PRONÓSTICO DEL CONSUMO DE CONSERVAS DE PESCADO EN EL PERÚ PARA UN PROYECTO INDUSTRIAL PESQUERO UTILIZANDO MODELOS DE SERIES DE TIEMPO

Forecast of canned fish consumption in Peru for an industrial fisheries project using time series models

Christian René Ramos Ángeles^{1*} ; Gloria Esther Valdivia Camacho² 

¹ Facultad de Pesquería, Universidad Nacional Agraria La Molina, Lima, Perú. cramos@lamolina.edu.pe

² Facultad de Ingeniería Industrial y de Sistemas, Universidad Nacional de Ingeniería, Lima, Perú. gvaldivia@uni.edu.pe

*Email: cramos@lamolina.edu.pe

Recibido: 31/12/2022; Aceptado: 18/05/2023; Publicado: 14/06/2023

ABSTRACT

In the canned fish production program, it is very important to calculate its forecast through statistical models that minimize the error of the projections and that allow estimating the quantities to be produced. The objective of this research work is to select a forecast model for the consumption of canned fish in Peru for an industrial fishing project using time series models. Prediction models such as linear regression, time series decomposition and Winters' method were used. The input data was the monthly domestic sales of canned fish from the years 2011 to 2014. The prediction error measures such as the mean absolute deviation (MAD) and the mean absolute percentage error (MAPE) of the prediction of a company were compared for a year (2014), two years (2013-2014), three years (2012-2014) and four years (2011-2014) to validate with the prediction for the years 2015-2019. The prediction model selected is the seasonal additive time series decomposition with data from two years (2013-2014) because it obtained the lowest MAD = 588.0 and the lowest MAPE = 15.00%.

Keywords: Time series models | linear regression | time series decomposition | Winters method | forecast error measures.

Forma de citar el artículo(Formato APA):

Ramos, C., & Valdivia, G. (2023). Pronóstico del consumo de conservas de pescado en el Perú para un proyecto industrial pesquero utilizando modelos de series de tiempo. *Anales Científicos*. 84(1),20-34. <http://dx.doi.org/10.21704/ac.v84i1.1528>

Autor de correspondencia (*):Ramos, C. Email:cramos@lamolina.edu.pe

© Los autores,Publicado por la Universidad Nacional Agraria La Molina.

This is an open access article under the CC BY.

RESUMEN

En el programa de producción de conservas de pescado es muy importante calcular su pronóstico a través de modelos estadísticos que minimicen el error de las proyecciones y que permita estimar las cantidades a producir. El objetivo del presente trabajo de investigación es seleccionar un modelo de pronóstico para el consumo de conservas de pescado en el Perú para un proyecto industrial pesquero utilizando modelos de series de tiempo. Se utilizaron modelos de pronósticos como el de regresión lineal, descomposición de series de tiempo y el método de Winters. Los datos de entrada fueron las ventas internas mensuales de conservas de pescado de los años 2011 al 2014. Se compararon los indicadores del error del pronóstico como la desviación media absoluta (MAD) y el error porcentual absoluto medio (MAPE) de los pronósticos de un año (2014), dos años (2013-2014), tres años (2012-2014) y cuatro años (2011-2014) para validar con los pronósticos de los años 2015-2019. El modelo de pronóstico seleccionado fue el de descomposición de series de tiempo aditivo estacional con los datos de dos años (2013-2014) porque obtuvo el menor MAD = 588.0 y menor MAPE = 15.00%.

Palabras claves: Modelos de series de tiempo | regresión lineal | descomposición de series de tiempo | método de Winters | indicadores del error del pronóstico.

1. INTRODUCCIÓN

La industria pesquera peruana se divide en consumo humano directo (22.1%) y consumo humano indirecto (77.9%), aportando el 0.95% al producto bruto interno nacional (Ministerio de la Producción, 2022). En el 2021, las ventas internas totales del sector pesquero fue de 832 mil TMB, de los cuales el 8.9% fue de enlatados (Ministerio de la Producción, 2022). La utilización de modelos de pronóstico en la producción de productos pesqueros es muy importante para satisfacer la demanda de la población (Yadav et al., 2020).

La previsión de la demanda juega un papel fundamental en la logística y la gestión de la cadena de suministro (Merkuryeva et al., 2019), que también es aplicada para el almacenamiento de productos perecederos (Contreras et al., 2016). Se puede experimentar escenarios alternativos de pronóstico para los cálculos de la demanda utilizando el modelo de promedios móviles simples (Menacho, 2014), regresiones

lineales múltiples y regresión simbólica con programación genética (Merkuryeva et al., 2019).

La importancia de utilizar modelos de pronósticos como el de regresión lineal, descomposición de series de tiempo y el método de Winters, es que disminuyen el error del pronóstico. Los indicadores del error del pronóstico, como son la desviación media absoluta y el error porcentual absoluto medio, permiten también validar los modelos con los pronósticos futuros.

Las aplicaciones de los modelos de pronósticos son muy diversas, como los métodos de descomposición de la predicción de series de tiempo en sistemas eléctricos principalmente para la previsión de carga (Mbuli et al., 2020; Menacho, 2014), precio y generación distribuida (Mbuli et al., 2020) y en la producción de pozos de petróleo (Montes et al., 2016) en donde se incluyen la tendencia, los componentes cíclicos y estacionales. Los modelos de pronósticos de series de tiempo también se utilizan para

estimar el volumen de almacenamiento en una cámara frigorífica y determinar los requerimientos de instalaciones adicionales, personal y materiales necesarios para los productos lácteos, cárnicos y jugos (Contreras et al., 2016).

Otros modelos como el de regresión polinomial de segundo grado, promedio móvil, suavización exponencial simple y suavización exponencial doble y modelos de redes neuronales artificiales multicapa backpropagation (Menacho, 2014) se aplican en series de tiempo muy variados como en construcción, producción de electricidad, fabricación de papel y productos de papel, fabricación de productos textiles, producción minera e hidrocarburos, producción de madera y productos de madera, fabricación de prendas de vestir y producción del sector fabril (Menacho, 2014).

El objetivo del presente trabajo de investigación es seleccionar un modelo de pronóstico para el consumo de conservas de pescado en el Perú para un proyecto industrial pesquero utilizando modelos de series de tiempo.

2. MATERIALES Y MÉTODOS

2.1. Método propuesto

En la Figura 1 se muestra el método propuesto en el presente trabajo de investigación. El método utilizado consistió en la adquisición de datos mensuales de ventas internas de conservas de pescado del Anuario Estadístico Pesquero y Acuícola del Perú de los años 2011 al 2019 (Ministerio de la Producción, 2011, 2012, 2013, 2014, 2015, 2016, 2017, 2018, 2019). Los datos mensuales de los años 2011 al 2014 sirvieron como base para utilizar los modelos de pronósticos de regresión lineal, descomposición de series de tiempo y el método de Winters para pronosticar los datos de esos años y también

de los años 2015 al 2019 para su validación con los indicadores de error del pronóstico, desviación media absoluta (MAD) y error porcentual absoluto medio (MAPE).

Se calcularon los pronósticos con datos mensuales de un año (2014), dos años (2013-2014), tres años (2012-2014) y cuatro años (2011-2014) para determinar con qué periodos anuales es mejor trabajar con los modelos de pronósticos propuestos.

De acuerdo a los datos mensuales de los años 2011-2014 sirvieron para obtener dos pronósticos, el de los años 2011-2014 y el de los años 2015-2019 con el fin de hacer la comparación de resultados.

2.2. Modelos de pronóstico

Los pronósticos se clasifican de acuerdo a su horizonte de tiempo futuro: pronóstico a corto plazo, mediano plazo y largo plazo (Heizer & Render, 2009). Los pronósticos a corto plazo, son de horizonte de tiempo menor a tres meses hasta un año. Los pronósticos a mediano plazo, son de horizonte de tiempo de tres meses hasta de tres años y los pronósticos a largo plazo, son de horizonte de tiempo de más de tres años. Los pronósticos a largo plazo se emplean en la planificación de la producción, capacidad de instalaciones, y para investigación y desarrollo (Heizer & Render, 2009).

Los métodos cuantitativos de pronóstico se clasifican en: (I) Modelos de series de tiempo, los cuales se subdividen en (a) enfoque intuitivo, (b) promedios móviles, (c) suavizamiento exponencial, y (d) proyección de tendencias; y (II) Modelo asociativo o causal, el cual incluye al modelo de regresión lineal (Heizer & Render, 2009). Los modelos utilizados a largo plazo son de regresión lineal, modelo de descomposición de series de tiempo y el método de Winters.

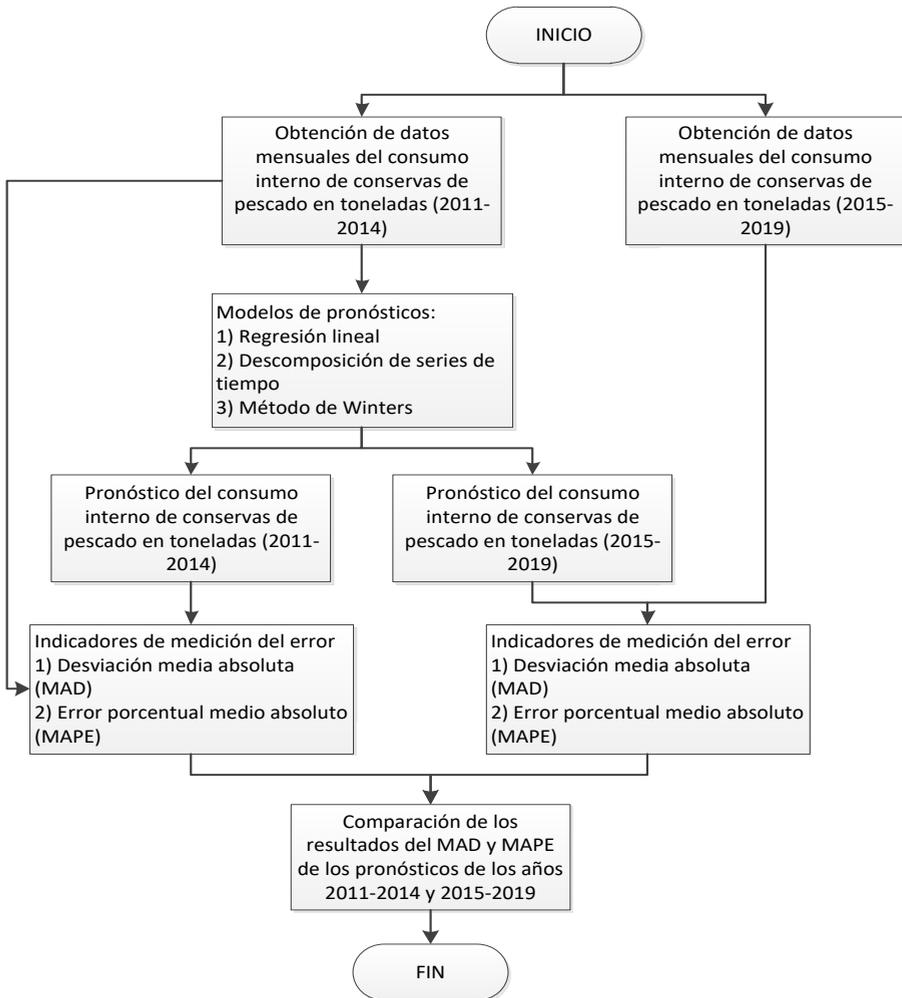


Figura 1. Método de pronóstico propuesto.

2.2.1. Regresión lineal

En la ecuación se presenta el modelo de regresión lineal, donde \hat{Y} es la variable respuesta y X es la variable independiente. El término b_0 es el intercepto con el eje Y , y el término b_1 es la pendiente (Hanke & Wichern, 2006).

$$\hat{Y} = b_0 + b_1X$$

Los valores de b_1 y b_0 se calculan en las siguientes ecuaciones (Hanke & Wichern, 2006).

$$b_1 = \frac{n \sum XY - \sum X \sum Y}{n \sum X^2 - (\sum X)^2} = \frac{\sum (X - \bar{X})(Y - \bar{Y})}{\sum (X - \bar{X})^2}$$

$$b_0 = \frac{\sum Y}{n} - \frac{b_1 \sum X}{n} = \bar{Y} - b_1 \bar{X}$$

2.2.2. Descomposición de series de tiempo

El modelo de descomposición de series de tiempo, el cual puede ser representado por un modelo multiplicativo o un modelo aditivo (Wilson & Keating, 2007). La variable Y es la que se pronostica y los componentes de los modelos multiplicativo y aditivo son el de tendencia T , estacional S , cíclico C y el irregular I (Wilson & Keating, 2007).

$$Y=T \times S \times C \times I$$

$$Y=T+S+C+I$$

El promedio móvil para el periodo t (MA_t) para los datos trimestrales y mensuales se presentan en las ecuaciones (Wilson & Keating, 2007).

$$MA_t = \frac{(Y_{t-2} + Y_{t-1} + Y_t + Y_{t+1})}{4}$$

$$MA_t = \frac{(Y_{t-6} + Y_{t-5} + \dots + Y_t + Y_{t+1} + \dots + Y_{t+5})}{12}$$

El promedio móvil centrado CMA_t se muestra en la ecuación y es el promedio simple de los promedios móviles para el periodo t y $t + 1$ (Wilson & Keating, 2007).

$$CMA_t = \frac{(MA_t + MA_{t+1})}{2}$$

El factor estacional (SF_t) es la división entre el valor real Y_t y el promedio móvil centrado CMA_t (Wilson & Keating, 2007).

$$SF_t = \frac{Y_t}{CMA_t}$$

El índice estacional SI_i o media normalizada de los factores estacionales del periodo i (mes, bimestre, trimestre o semestre) es igual al cociente del sumatorio de los factores estacionales del periodo i de cada año j sobre k años (Wilson & Keating, 2007).

$$SI_i = \sum_{j=1}^k \frac{SF_{ij}}{k}$$

La tendencia a largo plazo se estima a partir de los datos desestacionalizados para la variable respuesta que va a pronosticarse (Wilson & Keating, 2007).

El modelo de regresión lineal para obtener el coeficiente de intercepto a y la pendiente b para cada valor de CMA_t , donde t es el tiempo que va desde $t = 1$ para el primer dato con incremento de uno para los siguientes (Wilson & Keating, 2007).

$$CMA_t = a + bt$$

Los coeficientes a y b calculados se utilizan para la tendencia del promedio móvil centrado ($CMAT_t$), donde t es el tiempo que va desde $t = 1$ para el primer dato con incremento de uno para los siguientes (Wilson & Keating, 2007).

$$CMAT_t = a + bt$$

El factor de ciclo (CF_t) es el cociente entre el CMA_t y el $CMAT_t$, tal como se presenta en la ecuación.

$$CF_t = CMA_t / CMAT_t$$

2.2.3. Método de Winters

El método de Winters, también conocido como de Holt-Winters (Bowerman et al., 2007) se subdivide en dos modelos: (a) multiplicativo y (b) aditivo. El método multiplicativo con la notación de Hanke y Wichern (2006) se muestran en las siguientes ecuaciones. El valor suavizado L_t está en función de la constante de suavización α ($0 \leq \alpha \leq 1$), el valor real actual Y_t , el estimado de la estacionalidad S_{t-s} , donde s es la longitud de la estacionalidad, el valor estimado del

periodo anterior L_{t-1} y el estimado de la tendencia en el periodo anterior T_{t-1} .

$$L_t = \alpha \left(\frac{Y_t}{S_{t-s}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

El estimado de la tendencia T_t , que está en función del coeficiente β ($0 \leq \beta \leq 1$), el valor suavizado L_t y L_{t-1} , y el estimado de la tendencia T_{t-1} .

$$T_t = \beta (L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$

El estimado de la estacionalidad S_t está en función del coeficiente γ ($0 \leq \gamma \leq 1$), el valor real Y_t , el valor suavizado L_t y el estimado estacional S_{t-s} .

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s}$$

El pronóstico \hat{Y}_{t+p} para p periodos en el futuro, que está en función del valor suavizado L_t , el estimado de la tendencia T_t y el estimado estacional S_{t-s+p} .

$$\hat{Y}_{t+p} = (L_t + pT_t)S_{t-s+p}$$

El método aditivo presentado por Bowerman et al. (2007) utilizando la notación de Hanke y Wichern (2006) se muestran en las siguientes ecuaciones.

$$L_t = \alpha (Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \beta (L_t - L_{t-1}) + (1 - \beta)T_{t-1}$$

$$S_t = \gamma (Y_t - L_t) + (1 - \gamma)S_{t-s}$$

$$\hat{Y}_{t+p} = (L_t + pT_t)S_{t-s+p}$$

2.3. Indicadores de error del pronóstico

2.3.1. Desviación media absoluta

La desviación media absoluta (MAD, mean absolute deviation) o error medio absoluto es igual al promedio de los n valores absolutos de las diferencias del dato real A_t y el pronóstico F_t (Wilson & Keating, 2007).

$$MAD = \frac{1}{n} \sum_{t=1}^n |ERROR_t| = \frac{1}{n} \sum_{t=1}^n |A_t - F_t|$$

2.3.1. Error porcentual absoluto medio

El error porcentual absoluto medio (MAPE, mean absolute percentage error) o error medio porcentual absoluto (Wilson & Keating, 2007) se presenta en la ecuación.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|ERROR_t|}{A_t} = \frac{1}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{A_t}$$

Se utilizó el programa Minitab 16 para el cálculo de las predicciones y de los indicadores de error del pronóstico.

3. RESULTADOS

En la Figura 2 se muestra la serie de tiempo mensual de las ventas internas de conservas de pescado desde el año 2011 al 2014. Estos datos se utilizaron para realizar los pronósticos con los modelos de regresión lineal, descomposición de series de tiempo y el método de Winters y luego se compararon con los datos mensuales de las ventas internas de conservas de pescado de los años 2015 al 2019 (Figura 3).

En la Figura 4 se presentan los pronósticos con los datos mensuales de un año (2014) utilizando el modelo de regresión lineal (a), el método de Winters multiplicativo (b) y el método de Winters aditivo (c). Como los datos mensuales eran de un año, no se implementó el método de descomposición de

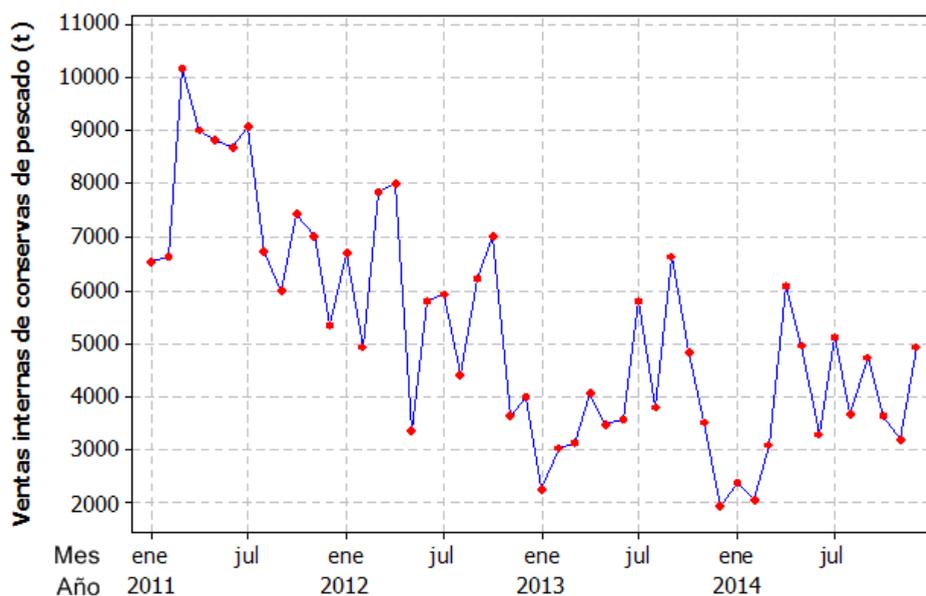


Figura 2. Ventas internas de conservas de pescado (2011-2014).

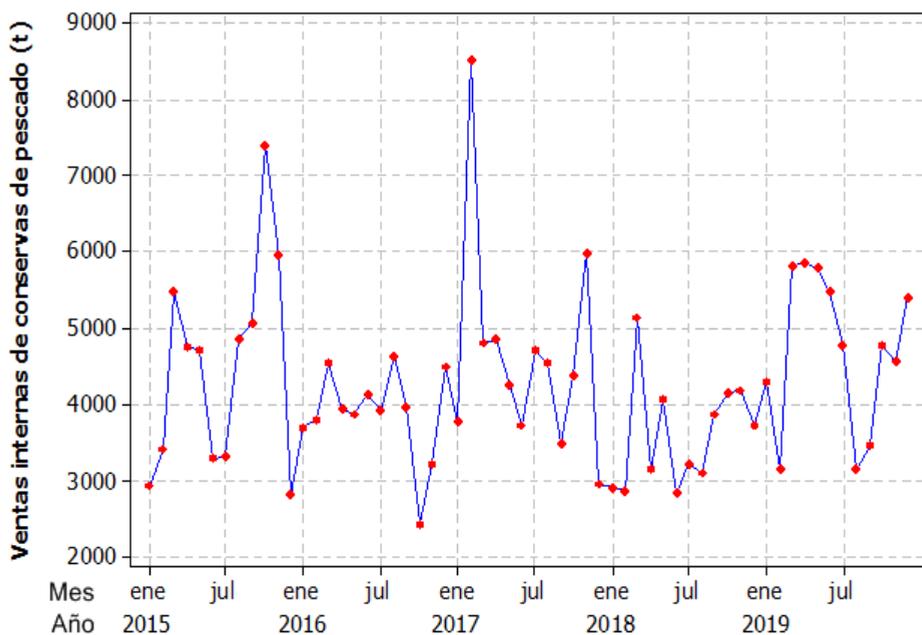


Figura 3. Ventas internas de conservas de pescado (2015-2019).

series de tiempo. Se observa una pendiente positiva en la Figura 4(a) la cual se mantiene en los pronósticos con el método de Winters multiplicativo de la Figura 4(b) y aditivo Figura 4(c).

En el método de Winters multiplicativo de la Figura 4(b) y el aditivo de la Figura 4(c) presentan los intervalos de predicción (PI, prediction interval) al 95%. Los PI nos brinda un intervalo en donde los pronósticos pueden estar dentro de los límites de confianza del 95%, existiendo un método de construcción de los PI para el método de Winters aditivo y multiplicativo (Chatfield & Yar, 1991).

De la Figura 5 a la Figura 7 se presentan los pronósticos mensuales de los años 2011 al 2019, con los datos mensuales de dos años, del 2013 al 2014 (Figura 5), tres años, del 2012 al 2014 (Figura 6) y cuatro años, del 2011 al 2014 (Figura 7) utilizando los modelos de regresión lineal, descomposición de series de tiempo y el método de Winters. En la Figura 4(a) y Figura 5(a) se observan la tendencia lineal creciente en los pronósticos y difiere al de la Figura 6(a) y Figura 7(a) que muestran una tendencia lineal decreciente.

En los modelos de descomposición de series de tiempo se utilizó una longitud estacional de 12 porque se utilizaron datos mensuales. Cuando se incluye el factor tendencia en el modelo de descomposición de series de tiempo multiplicativo estacional, se observa el efecto multiplicativo en los últimos periodos del pronóstico, como se presenta en la Figura 5(b), Figura 6(b) y Figura 7(b), el cual se ve en un aumento en el efecto estacional y son diferentes los pronósticos cada doce periodos mensuales. En el modelo estacional de descomposición de series de tiempo, al no contar con el efecto multiplicativo, se observa que los valores son los mismos cada doce periodos

mensuales tal como se muestra en la Figura 5(c), Figura 6(c) y Figura 7(c).

En la Figura 5(d), Figura 6(d) y Figura 7(d) se muestran los efectos de la tendencia en el modelo de descomposición estacional y tienen la misma pendiente que su respectivo modelo de regresión lineal, en cambio

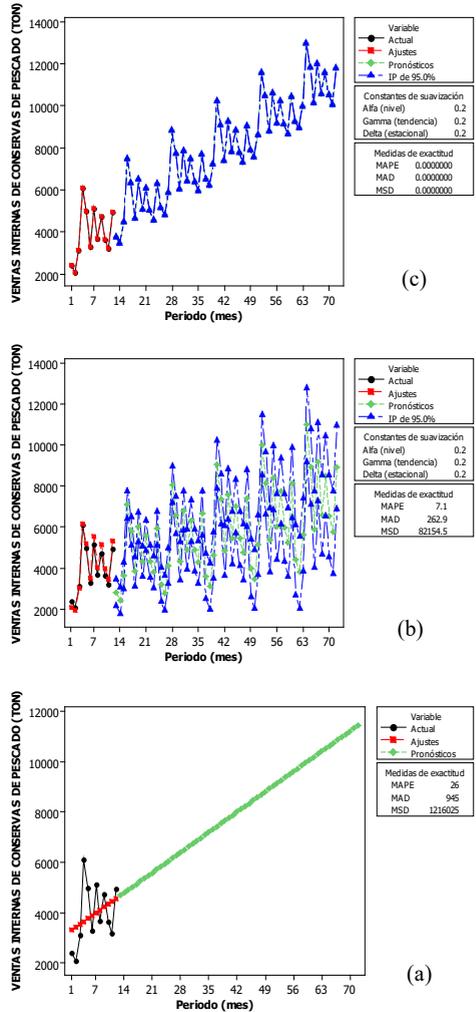


Figura 4. Pronósticos de las ventas internas de conservas de pescado (datos mensuales: 2014): (a) modelo de regresión lineal, (b) método de Winters multiplicativo y (c) método de Winters aditivo.

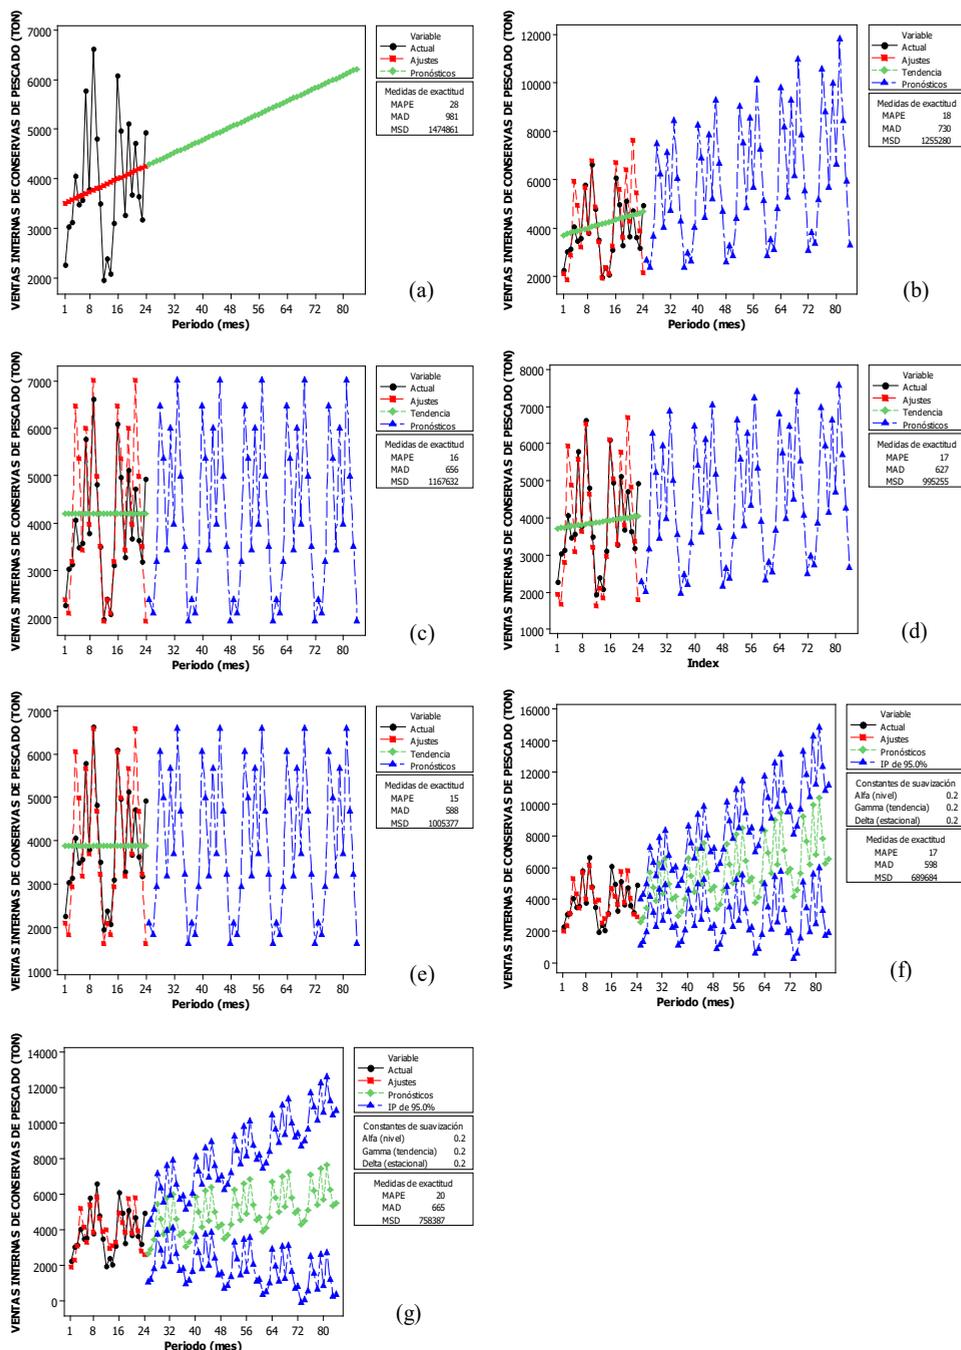


Figura 5. Pronósticos de las ventas internas de conservas de pescado (datos mensuales: 2013–2014): (a) modelo de regresión lineal, (b) descomposición de series de tiempo multiplicativo – tendencia y estacional, (c) descomposición de series de tiempo multiplicativo – estacional, (d) descomposición de series de tiempo aditivo – tendencia y estacional, (e) descomposición de series de tiempo aditivo – estacional, (f) método de Winters multiplicativo y (g) método de Winters aditivo.

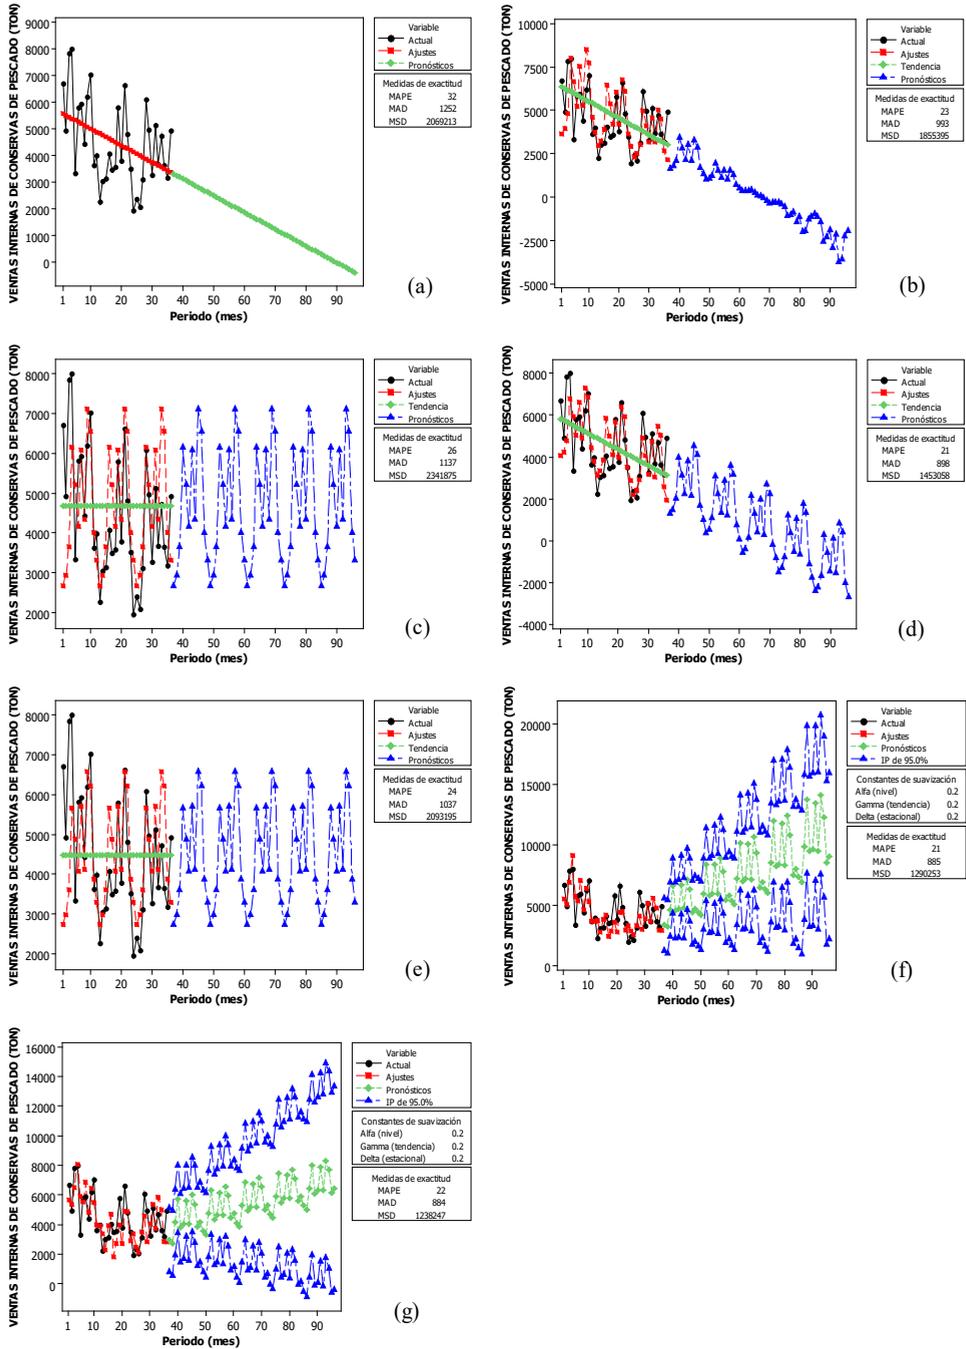


Figura 6. Pronósticos de las ventas internas de conservas de pescado (datos mensuales: 2012–2014): (a) modelo de regresión lineal, (b) descomposición de series de tiempo multiplicativo – tendencia y estacional, (c) descomposición de series de tiempo multiplicativo – estacional, (d) descomposición de series de tiempo aditivo – tendencia y estacional, (e) descomposición de series de tiempo aditivo – estacional, (f) método de Winters multiplicativo y (g) método de Winters aditivo.

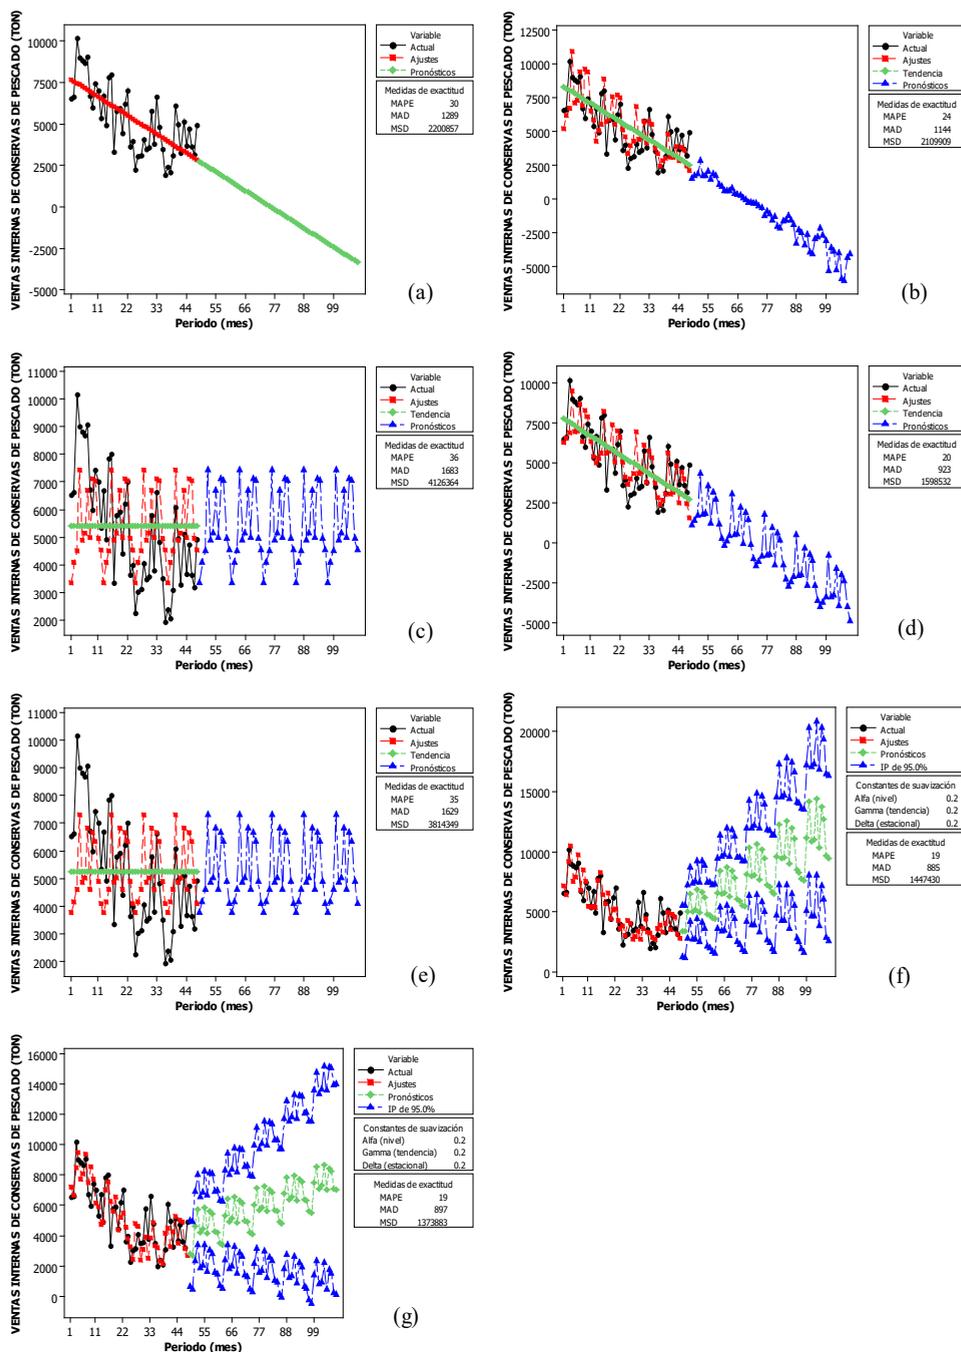


Figura 7. Pronósticos de las ventas internas de conservas de pescado (datos mensuales: 2011–2014): (a) modelo de regresión lineal, (b) descomposición de series de tiempo multiplicativo – tendencia y estacional, (c) descomposición de series de tiempo multiplicativo – estacional, (d) descomposición de series de tiempo aditivo – tendencia y estacional, (e) descomposición de series de tiempo aditivo – estacional, (f) método de Winters multiplicativo y (g) método de Winters aditivo.

en la Figura 5(e), Figura 6(e) y Figura 7(e) representan a los pronósticos con los modelos de descomposición de series de tiempo aditivo estacional sin el efecto de la tendencia.

En los pronósticos y los PI, utilizando el método de Winters multiplicativo, presentan mayor variabilidad, como se muestra en la Figura 5(f), Figura 6(f) y Figura 7(f), con respecto al método de Winters aditivo que se observa en la Figura 5(g), Figura 6(g) y Figura 7(g).

En la Tabla 1 y Tabla 2 se muestran las desviaciones medias absolutas (MAD) y los errores porcentuales absolutos medios

(MAPE) respectivamente, calculados con los datos mensuales A_t y pronósticos F_t entre los años 2010 al 2014. Se puede observar que los periodos de cálculo van de uno a cuatro años.

En la Tabla 3 y Tabla 4 se presentan los MAD y MAPE respectivamente calculados con los datos mensuales A_t y pronósticos F_t de los años 2015 al 2019. Se diferenció el MAD y el MAPE de los pronósticos entre los años 2011-2014 y de los años 2015-2019. Los pronósticos entre los años 2011-2014 son de los datos históricos para el proyecto, en cambio los pronósticos de los años 2015-2019 son para el horizonte de evaluación del proyecto.

Tabla 1. Desviación media absoluta (MAD) de los pronósticos entre los años 2011–2014.

Periodo	Regresión Lineal (RL)	Descomposición de series de tiempo				Método de Winters	
		Multiplicativo		Aditivo		Multiplicativo	Aditivo
		Tendencia y estacional	Estacional	Tendencia y estacional	Estacional		
01 año (2014)	945.0					262.9	0.0
02 años (2013-2014)	981.0	730.0	656.0	627.0	588.0	598.0	665.0
03 años (2012-2014)	1,252.0	993.0	1,137.0	898.0	1,037.0	885.0	884.0
04 años (2011-2014)	1,289.0	1,144.0	1,683.0	923.0	1,629.0	885.0	897.0

Tabla 2. Error porcentual absoluto medio (MAPE) de los pronósticos entre los años 2011–2014.

Periodo	Regresión Lineal (RL)	Descomposición de series de tiempo				Método de Winters	
		Multiplicativo		Aditivo		Multiplicativo	Aditivo
		Tendencia y estacional	Estacional	Tendencia y estacional	Estacional		
01 año (2014)	26.00					7.10	0.00
02 años (2013-2014)	28.00	18.00	16.00	17.00	15.00	17.00	20.00
03 años (2012-2014)	32.00	23.00	26.00	21.00	24.00	21.00	22.00
04 años (2011-2014)	30.00	24.00	36.00	20.00	35.00	19.00	19.00

Tabla 3. Desviación media absoluta (MAD) de los pronósticos de los años 2015–2019.

Periodo	Regresión Lineal (RL)	Descomposición de series de tiempo				Método de Winters	
		Multiplicativo		Aditivo		Multiplicativo	Aditivo
		Tendencia y estacional	Estacional	Tendencia y estacional	Estacional		
01 año (2014)	3,898.6					2,176.3	4,022.8
02 años (2013-2014)	1,341.6	2,446.8	1,633.6	1,592.5	1,619.4	1,946.8	1,425.8
03 años (2012-2014)	2,830.1	4,227.7	1,446.3	3,540.0	1,306.9	3,674.3	1,722.7
04 años (2011-2014)	4,578.9	5,566.6	1,589.0	4,823.7	1,465.6	4,056.2	2,044.7

Tabla 4. Error porcentual absoluto medio (MAPE) de los pronósticos de los años 2015–2019.

Periodo	Regresión Lineal (RL)	Descomposición de series de tiempo				Método de Winters	
		Multiplicativo		Aditivo		Multiplicativo	Aditivo
		Tendencia y estacional	Estacional	Tendencia y estacional	Estacional		
01 año (2014)	101.94					54.79	103.20
02 años (2013-2014)	36.23	61.27	38.98	38.50	38.28	44.71	36.42
03 años (2012-2014)	63.90	98.82	35.55	82.64	31.66	94.24	44.64
04 años (2011-2014)	107.20	131.86	41.55	114.01	38.30	103.59	52.86

4. DISCUSIÓN

En la determinación del mejor modelo de pronósticos se elige aquel que disminuya el error promedio entre el dato real y el valor pronosticado (Contreras et al., 2016; Menacho, 2014). En el presente trabajo fue posible diferenciar entre los indicadores de medición del error del pronóstico, MAD y MAPE, de los valores mensuales de los años 2011 al 2014 y de los años 2015 al 2019, considerando el supuesto que el de los años 2015 al 2019 no sería conocido por el formulador del proyecto de inversión.

La selección del mejor método de pronóstico debe enfocarse en el MAD y MAPE de los pronósticos entre los años 2011 y 2014 porque se asume que se desconocen los datos reales de los años 2015 al 2019. El mejor método de pronóstico seleccionado es el de descomposición de series de tiempo aditivo estacional con los datos de dos años (2013-2014) porque es el que obtuvo el menor MAD = 588.0 (Tabla 1) y menor MAPE = 15.00% (Tabla 2).

Sin embargo, el MAD = 1,341.6 y MAPE = 36.23% del modelo de regresión lineal para los pronósticos de los años 2015 al 2019 resultaron mejores al compararlos con el MAD = 1,619.4 y MAPE = 38.28% del modelo de descomposición de series de tiempo aditivo estacional (Tabla 3 y Tabla 4) con una diferencia en el MAD de 277. 8 y del MAPE de 2.05%.

En la práctica, un formulador y evaluador de proyectos desconocen los valores reales de las ventas internas de conservas de pescado de los años proyectados a futuro (años 2015 al 2019), por lo que se basará su elección del mejor modelo de pronóstico del procesamiento de los datos históricos con el que cuente (años 2011 al 2014).

5. CONCLUSIONES

En este trabajo de investigación el mejor modelo de pronósticos utilizando los datos mensuales de las ventas internas de conservas de pescado de los años 2011 al 2014 es el método de descomposición de series de tiempo aditivo estacional porque al compararlo con el MAD y MAPE de los otros modelos resultó dando menores valores en los indicadores de medición del error. El que el modelo de regresión lineal haya obtenido mejores indicadores de error del pronóstico entre los años 2015 al 2019, no significa que se elija este modelo, porque en un proyecto de inversión se debe tomar la decisión de elegir el mejor modelo de pronóstico con el supuesto de desconocer los datos mensuales proyectados de los años futuros de evaluación, en este caso de los años 2015 al 2019. Sin embargo, los indicadores de medición del error de los años 2015 al 2019 podrían validar al mejor modelo de pronósticos comparando con el MAD y MAPE de los pronósticos de los años 2011 al 2014.

Agradecimientos

Los autores agradecen a todas las personas e instituciones que colaboraron directamente o indirectamente con la realización de este trabajo de investigación.

Conflictos de intereses

Los autores firmantes del presente trabajo de investigación declaran no tener ningún potencial conflicto de interés personal o económico con otras personas u organizaciones que puedan influir indebidamente con el presente manuscrito.

Contribuciones de los autores

Preparación y ejecución: CRRA; Desarrollo de la metodología: CRRA; Concepción y diseño: CRRA; Edición del artículo: CRRA; Supervisión del estudio: GEVC.

6. REFERENCIAS

- Bowerman, B. L., O'Connell, R. T., & Koehler, A. B. (2007). *Pronósticos, series de tiempo y regresión* (Cuarta Ed). Thomson.
- Chatfield, C., & Yar, M. (1991). Prediction intervals for multiplicative Holt-Winters. *International Journal of Forecasting*, 7(1), 31–37. [https://doi.org/10.1016/0169-2070\(91\)90030-Y](https://doi.org/10.1016/0169-2070(91)90030-Y)
- Contreras, A., Atziry Zuñiga, C., Martínez Flores, J. L., & Sánchez Partida, D. (2016). *Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos*. 32, 387–396. <https://doi.org/http://dx.doi.org/10.1016/j.estger.2016.11.002>
- Hanke, J. E., & Wichern, D. W. (2006). *Pronósticos en los negocios* (Octava Ed). Pearson Educación.
- Heizer, J., & Render, B. (2009). Principios de Administración de Operaciones. In *Pearson Educación* (Séptima Ed). Pearson Educación.
- Mbuli, N., Mathonsi, M., Seitshiro, M., & Pretorius, J. H. C. (2020). Decomposition forecasting methods: A review of applications in power systems. *Energy Reports*, 6(2020), 298–306. <https://doi.org/10.1016/j.egy.2020.11.238>
- Menacho, C. H. (2014). Comparación de los métodos de series de tiempo y redes neuronales. *Anales Científicos*, 75(2), 245. <https://doi.org/10.21704/ac.v75i2.960>
- Merkuryeva, G., Valberga, A., & Smirnov, A. (2019). Demand forecasting in pharmaceutical supply chains: A case study. *Procedia Computer Science*, 149, 3–10. <https://doi.org/10.1016/j.procs.2019.01.100>
- Ministerio de la Producción. (2011). *Anuario Estadístico del Sector Producción 2011*. PRODUCE.
- Ministerio de la Producción. (2012). *Anuario Estadístico Pesquero y Acuicola 2012*. PRODUCE.
- Ministerio de la Producción. (2013). *Anuario Estadístico Pesquero y Acuicola 2013*. PRODUCE.
- Ministerio de la Producción. (2014). *Anuario Estadístico Pesquero y Acuicola 2014*. PRODUCE.
- Ministerio de la Producción. (2015). *Anuario Estadístico Pesquero y Acuicola 2015*. PRODUCE.
- Ministerio de la Producción. (2016). *Anuario Estadístico Pesquero y Acuicola 2016*. PRODUCE.
- Ministerio de la Producción. (2017). *Anuario Estadístico Pesquero y Acuicola 2017*. PRODUCE.
- Ministerio de la Producción. (2018). *Anuario Estadístico Pesquero y Acuicola 2018*. PRODUCE.
- Ministerio de la Producción. (2019). *Anuario Estadístico Pesquero y Acuicola 2019*. PRODUCE.
- Ministerio de la Producción. (2022).

Anuario Estadístico Pesquero y Acuicola 2022. PRODUCE.

- Montes, E. G., Calvete González, F. E., & Mantilla Duarte, C. A. (2016). Aplicación De Series De Tiempo En La Realización De Pronósticos De Producción. *Revista Fuentes El Reventón Energético*, 14(1), 79–88. <https://doi.org/10.18273/revfue.v14n1-2016007>
- Wilson, J. H., & Keating, B. (2007). *Pronósticos en los negocios* (Quinta Ed.). McGraw-Hill.
- Yadav, A. K., Das, K. K., Das, P., Raman, R. K., Kumar, J., & Das, B. K. (2020). Growth trends and forecasting of fish production in assam, india using arima model. *Journal of Applied and Natural Science*, 12(3), 415–421. <https://doi.org/10.31018/jans.v12i3.2353>