



Memoria del proyecto para optar al Título de  
Ingeniero Civil Oceánico

**EVALUACIÓN DE UN MODELO DE PREDICCIÓN PARA  
ESTIMAR LAS HORAS DE CIERRE DE LA BAHÍA DE  
PUERTO CHACABUCO.**

**Michelle Gallardo Syriani**

Diciembre 2019

EVALUACIÓN DE UN MODELO DE PREDICCIÓN PARA ESTIMAR LAS HORAS  
DE CIERRE DE LA BAHÍA DE PUERTO CHACABUCO.

Michelle Gallardo Syriani

COMISIÓN REVISORA

NOTA

FIRMA

FELIPE CASELLI

Profesor guía

---

---

SERGIO BIDART

Revisor

---

---

JAIME LEYTON

Revisor

---

---

## Declaración

Este trabajo, o alguna de sus partes, no ha sido presentado anteriormente en la Universidad de Valparaíso, institución universitaria chilena o extranjera u organismo de carácter estatal, para evaluación, comercialización u otros propósitos. Salvo las referencias citadas en el texto, confirmo que el contenido intelectual de este Proyecto de Título es resultado exclusivamente de mis esfuerzos personales.

La Universidad de Valparaíso reconoce expresamente la propiedad intelectual del autor sobre esta Memoria de Titulación. Sin embargo, en caso de ser sometida a evaluación para los propósitos de obtención del Título Profesional de Ingeniero Civil Oceánico, el autor renuncia a los derechos legales sobre la misma y los cede a la Universidad de Valparaíso, la que estará facultada para utilizarla con fines exclusivamente académicos.

## Agradecimientos

En primer lugar, quiero agradecer a mis padres Norma y Daniel y a mi hermana Camila por el incondicional apoyo, comprensión y paciencia a lo largo de este proceso y durante toda mi vida.

Agradezco al profesor Felipe Caselli por guiarme y enseñarme siempre con la mejor disposición en el desarrollo de esta memoria y durante toda la carrera.

Quiero agradecer también a las personas que desinteresadamente aportaron con su granito de arena para que yo pudiera cumplir mis metas, a Stefani por acompañarme siempre, a Gonzalo por darme la palabra justa en el momento justo, a Enrique por sus enseñanzas, apoyo y comprensión, a Ignacio por su infinita motivación y a Enzo por aprender junto a mí desde lo más simple hasta lo más complejo.

Finalmente agradezco a la Dirección General de Territorio Marítimo y de Marina Mercante de la Armada de Chile por proporcionar la data utilizada para realizar este estudio.

## **TABLA DE CONTENIDO**

1	Introducción .....	1
2	Objetivos.....	2
3	Fundamento teórico.....	3
3.1	Estadística descriptiva .....	3
3.2	Análisis de series temporales .....	4
3.2.1	Descomposición de la serie temporal .....	5
3.2.2	Técnicas de suavizado .....	6
3.2.3	Modelos ARIMA.....	9
3.2.4	Medidas de precisión.....	11
4	Metodología.....	12
5	Resultados.....	14
5.1	Análisis estadístico .....	16
5.1.1	Parámetros estadísticos .....	16
5.1.2	Distribución anual de horas .....	18
5.2	Construcción del modelo .....	20
5.3	Predicción.....	24
6	Conclusiones .....	27
7	Referencias bibliográficas .....	29
8	Anexos .....	30

## **LISTA DE TABLAS**

Tabla 5-1: Parámetros estadísticos.....	16
Tabla 5-2: Cantidad de horas anuales .....	18
Tabla 5-3: Medidas de bondad de ajuste para ACN.....	20
Tabla 5-4: Medidas de bondad de ajuste para CNMF .....	20
Tabla 5-5: Medidas de bondad de ajuste para CNMFD .....	21
Tabla 5-6: Modelos seleccionados.....	21

## **LISTA DE ECUACIONES**

Ecuación 1: Coeficiente de autocorrelación .....	4
Ecuación 2: Modelo sumativo .....	5
Ecuación 3: Modelo multiplicativo .....	5
Ecuación 4: Promedio móvil.....	6
Ecuación 5: Suavizado exponencial simple .....	6
Ecuación 6: Suavizado lineal de Holt .....	7
Ecuación 7: Valor de la serie alisada .....	7
Ecuación 8: Valor del parámetro estimado.....	7
Ecuación 9: Suavizado estacional de Winters.....	8
Ecuación 10: Valor de la serie alisada .....	8
Ecuación 11: Valor del parámetro estimado.....	8
Ecuación 12: Factor de estacionalidad .....	8
Ecuación 13: Modelo ARIMA .....	9

## **LISTA DE FIGURAS**

Figura 1-1: Bahía de Puerto Chacabuco .....	1
Figura 5-1: Horas mensuales de cada estado entre 2009 y 2018. ....	14
Figura 5-2: Comportamiento mensual (entre 2009 y 2018) de cada serie .....	16
Figura 5-3: Proporción de horas por año.....	18
Figura 5-4: Comportamiento del modelo para ACN 2018.....	22
Figura 5-5: Comportamiento del modelo para CNMF 2018 .....	22
Figura 5-6: Comportamiento del modelo para CNMFD 2018 .....	23
Figura 5-7: Predicción de la serie ACN .....	24
Figura 5-8: Predicción de la serie CNMF .....	25
Figura 5-9: Predicción de la serie CNMFD .....	26

## **RESUMEN**

Puerto Chacabuco es considerado el puerto más importante de la región de Aysén, ya que cubre la necesidad de conectividad marítima de pasajeros y facilita el intercambio comercial de sectores económicos como: pesca, acuicultura, minería, industrial, forestal, agrario, turístico, entre otros.

Debido a lo anterior, se realizó este estudio que consiste en la evaluación de un modelo de predicción para estimar las horas de cierre de la bahía de Puerto Chacabuco, esto con el fin de dar respuesta al problema de planificación de las actividades del puerto a partir de las restricciones operacionales generadas por mal tiempo.

Para ello se realizó un análisis estadístico donde se identificaron las principales características de la serie temporal y su comportamiento a través de los últimos 10 años, luego se realizó un análisis de series temporales, donde se utilizaron distintos modelos para reproducir la serie temporal y se evaluó cuál de ellos presentó el mejor ajuste. Una vez seleccionado el modelo se realizó la predicción de la serie.

El resultado obtenido de este estudio fue una estimación del comportamiento de la variable estudiada (horas mensuales de cierre de la bahía) para los años 2019 y 2020, con el fin de facilitar la toma de decisiones en la planificación de actividades considerando condiciones futuras.



# **1 INTRODUCCIÓN**

Puerto Chacabuco es una localidad perteneciente a la XI Región de Aysén del General Carlos Ibáñez del Campo, región considerada como una zona geográficamente aislada (Subdere, 2011).

Actualmente existen dos formas de llegar a la ciudad de Puerto Chacabuco, una por vía terrestre desde Puerto Aysén y otra por vía marítima desde Puerto Montt, conectándose así con el resto del país. Debido a esto, Puerto Chacabuco es considerado el puerto más importante de la región, además, permite la conectividad marítima de pasajeros y el intercambio comercial de sectores económicos como: pesca, acuicultura, minería, industrial, forestal, agrario, turístico (entre otros), transformándolo en un punto estratégico para la región (Emporcha, 2017).

Por otro lado, la bahía de Puerto Chacabuco se ubica en una zona abrigada (Figura 1-1) favoreciendo la operación de embarcaciones y el proceso de transferencia de carga y pasajeros, sin embargo, se caracteriza por su alta pluviosidad y fuertes vientos.

Figura 1-1: Bahía de Puerto Chacabuco



Fuente: Google Earth.

La Dirección General del Territorio Marítimo y de Marina Mercante (Directemar) de la Armada de Chile es el organismo encargado de velar por la seguridad de las personas en las rutas de navegación, naves, puertos, (entre otros) que se encuentran dentro del área jurisdiccional de la Autoridad Marítima, por ello, a través de las capitanías de puerto, verifican constantemente las condiciones meteorológicas de las distintas zonas navales y establecen el estado de los puertos o su situación marítima portuaria (abierto, cerrado para naves menores, etc.). Si se decreta el cierre del puerto, se deben paralizar las labores que allí se realizan.

Debido a la gran importancia que tiene la bahía de Puerto Chacabuco para la región de Aysén, fue necesario realizar este estudio, que permitió estimar las horas de cierre de la bahía, con el fin de facilitar la toma de decisiones al momento de planificar las actividades del puerto a partir de las restricciones operacionales generadas por mal tiempo.

## **2 OBJETIVOS**

### OBJETIVO GENERAL

Predecir las horas mensuales de cierre de la bahía de Puerto Chacabuco mediante un análisis de series temporales.

### OBJETIVOS ESPECÍFICOS

- Realizar un análisis de estadística descriptiva del cierre de puertos en la bahía de Puerto Chacabuco.
- Construir un modelo de series temporales que se ajuste de forma adecuada al conjunto de datos.
- Utilizar el modelo construido para realizar una predicción mensual de las horas de cierre de la bahía de Puerto Chacabuco.

### **3 FUNDAMENTO TEÓRICO**

En la actualidad, la estadística es una herramienta ampliamente utilizada para describir, comprender y analizar información de forma simplificada y también para estimar o predecir el comportamiento de variables en el tiempo, esto se puede realizar mediante el análisis de series temporales. Estos análisis pueden tener diversas aplicaciones como pronosticar el rendimiento de contenedores, (Chan, Xu, & Qi, 2019), el número de inspecciones de carga realizados en puertos (Ruiz, Turias, Moscoso, Jiménez, & Cerbán, 2017), la altura significativa de olas en la costa (Delicado & Justel, 1999), entre otras. A continuación, se describen los aspectos más relevantes de la estadística descriptiva y del análisis de series temporales que serán utilizados como marco teórico en este estudio.

#### **3.1 ESTADÍSTICA DESCRIPTIVA**

Técnica matemática que se utiliza para organizar, presentar y caracterizar el conjunto de datos a través de tablas y/o gráficos y calcular algunos parámetros estadísticos como medidas de centralización y dispersión con el fin de describir de forma resumida las características de ese conjunto (Webster, 2004).

##### **MEDIDAS DE CENTRALIZACIÓN**

Indican en torno a qué valor central se distribuyen los datos. Existen distintas medidas de centralización como la media, la mediana y la moda, entre otras.

##### **MEDIDAS DE DISPERSIÓN**

Indican qué tan alejados del centro se encuentran los datos de la distribución. Existen distintas medidas de dispersión como el recorrido, la desviación media, la varianza, la desviación estándar y el coeficiente de variación, entre otras.

## 3.2 ANÁLISIS DE SERIES TEMPORALES

Una serie temporal es un conjunto de observaciones de una variable, medidas de forma ordenada a lo largo del tiempo (Hanke & Reitsh, 2006). Existen algunas técnicas que permiten utilizar las series temporales para realizar estimaciones del comportamiento de una variable a futuro, basándose en su comportamiento pasado, con el fin de facilitar la toma de decisiones y poder planificar cómo enfrentar condiciones futuras (Montes, Calvete, & Mantilla, 2016).

Las técnicas o métodos utilizados para realizar las predicciones se denominan autoprojectivos, es decir, que permiten predecir o proyectar valores futuros de una variable, a partir de sus valores anteriores.

Para utilizar métodos autoprojectivos es necesario que exista autocorrelación en la serie temporal, es decir, que el valor que tome una variable en el tiempo dependa de los valores anteriores (Kirchgassner, Wolters, & Hassler, 2013).

El coeficiente de autocorrelación permite medir esta dependencia (Ecuación 1):

Ecuación 1: Coeficiente de autocorrelación

$$r_k = \frac{\sum_{t=1+k}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}$$

Donde:

$r_k$ : Coeficiente de autocorrelación

$n$ : Número de datos de la serie

$\bar{Y}$ : Media de los valores de la serie

$Y_t$ : Observación en el periodo de tiempo  $t$

$Y_{t-k}$ : Observación en  $k$  periodos anteriores

Algunos métodos autoproyectivos se presentan a continuación (según Pérez, 2005):

### 3.2.1 DESCOMPOSICIÓN DE LA SERIE TEMPORAL

Esta técnica considera que el comportamiento de una serie de tiempo puede ser descrito mediante la combinación de algunas de las cuatro componentes que se describen a continuación:

- Componente de tendencia: variación a largo plazo de la media, la variable crece o decrece a lo largo del tiempo.
- Componente estacional: patrón que se repite durante cierto período de tiempo, generalmente menor a un año.
- Componente cíclica: fluctuación en forma de onda alrededor de la tendencia a largo plazo, durante períodos de tiempo mayores a un año.
- Componente irregular: resultado de factores fortuitos o aleatorios que inciden de forma aislada en la serie de tiempo.

Se debe dividir la serie en sus componentes para predecir cada una de forma separada, luego se unen de manera sumativa o multiplicativa para dar como resultado valores cercanos a los observados en la serie original más una predicción de estos.

La Ecuación 2 denota la serie de tiempo en el instante  $t$  usando un modelo sumativo:

Ecuación 2: Modelo sumativo

$$Y_t = T_t + E_t + C_t + I_t$$

Donde:

$Y_t$ : Valor observado

$T_t$ : Componente de tendencia

$E_t$ : Componente estacional

$C_t$ : Componente cíclica

$I_t$ : Componente irregular

La Ecuación 3 denota la serie de tiempo en el instante  $t$  usando un modelo multiplicativo:

Ecuación 3: Modelo multiplicativo

$$Y_t = T_t \cdot E_t \cdot C_t \cdot I_t$$

Donde:

$Y_t$ : Valor observado

$T_t$ : Componente de tendencia

$E_t$ : Componente estacional

$C_t$ : Componente cíclica

$I_t$ : Componente irregular

### 3.2.2 TÉCNICAS DE SUAVIZADO

Las técnicas de suavizado o alisado se utilizan para reducir fluctuaciones aleatorias y cambios bruscos en la serie de tiempo, y así facilitar su predicción.

A continuación, se describen algunas de estas técnicas:

#### PROMEDIO MÓVIL

Esta técnica consiste en obtener una nueva serie sustituyendo los valores observados por nuevos valores calculados a partir de la media de subgrupos artificiales de observaciones inmediatamente anteriores. La forma de calcular un promedio móvil se describe en la Ecuación 4:

Ecuación 4: Promedio móvil

$$M_t = \hat{Y}_{t+1} = \frac{Y_t + Y_{t-1} + Y_{t-2} + \dots + Y_{t-n+1}}{n}$$

Donde:

$M_t$ : Promedio móvil en el periodo  $t$

$\hat{Y}_{t+1}$ : Valor de pronóstico para el siguiente periodo

$Y_t$ : Valor real en el periodo  $t$

$n$ : Número de términos en el promedio móvil

#### SUAVIZADO EXPONENCIAL SIMPLE

Obtiene predicciones de una serie temporal en función de las observaciones pasadas. Cada predicción se obtiene ponderando un parámetro de alisamiento por los valores observados de la variable, como se muestra en la Ecuación 5:

Ecuación 5: Suavizado exponencial simple

$$S_t(1) = aX_t + (1 - a) * S_{t-1}(1)$$

Donde:

$X_t$ : Valor observado de la serie temporal en el instante  $t$

$S_t(1)$ : Valor de pronóstico de  $X_t$  en el horizonte 1

$a$ : Parámetro de alisamiento (relacionado con la componente aleatoria)

## SUAIVIZADO LINEAL DE HOLT

Este método supone tendencia lineal para realizar predicciones, a diferencia del suavizado exponencial simple, utiliza dos parámetros de alisamiento, uno relacionado con la componente aleatoria y otro relacionado con la tendencia. La predicción se obtiene como indica la Ecuación 6:

$$F_t(1) = S_t + (b_t)1; t + 1 > 2 \quad \text{Ecuación 6: Suavizado lineal de Holt}$$

$$S_t = aX_t + (1 - a) * [S_{t-1} + b_{t-1}] \quad \text{Ecuación 7: Valor de la serie alisada}$$

$$b_t = b[S_t - S_{t-1}] + (1 - b)b_{t-1} \quad \text{Ecuación 8: Valor del parámetro estimado}$$

Los valores iniciales son  $S_1 = X_1$  y  $b_1 = X_2 - X_1$ .

Donde:

$F_t(1)$ : Predicción en el instante  $t$  a horizonte 1

$S_t$ : Valor  $t$  de la serie alisada (se obtiene mediante la Ecuación 7)

$X_t$ : Observación  $t$  de la serie temporal en estudio

$b_t$ : Valor del parámetro estimado del modelo en el instante  $t$  (se obtiene mediante la Ecuación 8)

$a$ : Primera constante de alisamiento (relacionado con la componente aleatoria)

$b$ : Segunda constante de alisamiento (relacionado con la tendencia)

## SUAVIZADO ESTACIONAL DE WINTERS

Este método es una forma generalizada del suavizado de Holt, supone estacionalidad para realizar predicciones, a diferencia de los anteriores, utiliza tres parámetros de alisamiento, uno relacionado con la componente aleatoria, otro relacionado con la tendencia y otro relacionado con la componente estacional.

La Ecuación 9 muestra cómo se obtiene la predicción:

$$F_t(1) = (S_t + 1(b_t)) * I_{t+1-L} \quad \text{Ecuación 9: Suavizado estacional de Winters}$$

$$S_t = \left( \frac{aX_t}{I_{t-L}} \right) + (1 - a) * [S_{t-1} + b_{t-1}] \quad \text{Ecuación 10: Valor de la serie alisada}$$

$$b_t = b(S_t - S_{t-1}) + (1 - b)b_{t-1} \quad \text{Ecuación 11: Valor del parámetro estimado}$$

$$I_t = \left( \frac{cX_t}{S_t} \right) + (1 - c) * I_{t-L} \quad \text{Ecuación 12: Factor de estacionalidad}$$

Los valores iniciales son  $S_1 = X_1$  y  $b_1 = X_2 - X_1$ .

Donde:

- $F_t(1)$ : Predicción en el instante  $t$  a horizonte 1
- $S_t$ : Valor  $t$  de la serie alisada (se obtiene mediante la Ecuación 10)
- $b_t$ : Valor del parámetro estimado del modelo en el instante  $t$  (se obtiene mediante la Ecuación 11)
- $I_t$ : Factor de estacionalidad (se obtiene mediante la Ecuación 12)
- $L$ : Número de observaciones anuales
- $X_t$ : Observación  $t$  de la serie temporal en estudio
- $a$ : Primera constante de alisamiento (relacionado con la componente aleatoria)
- $b$ : Segunda constante de alisamiento (relacionado con la tendencia)
- $c$ : Tercera constante de alisamiento (relacionado con la componente estacional)



### 3.2.3 MODELOS ARIMA

Los modelos ARIMA (Autorregresivo Integrado de Medias Móviles), también conocidos como modelos Box-Jenkins, son modelos estadísticos que buscan predecir o pronosticar mediante un modelo matemático el comportamiento de una serie temporal, basándose en valores históricos de ésta y sus errores. El principal requisito para poder modelar una serie temporal con este método es que la serie sea estacionaria (Box, Jenkins, & Reinsel, 2016; Jiménez, Gázquez, & Sánchez, 2006).

Una clasificación descriptiva de las series de tiempo está relacionada con la estacionariedad. Una serie estacionaria es aquella que se considera estable a lo largo del tiempo, es decir que su media y su varianza se mantienen constantes. Por otro lado, una serie no estacionaria es aquella que no es estable a lo largo del tiempo, los cambios en la media determinan una tendencia a crecer o decrecer durante largos períodos de tiempo, por lo que la serie no oscila en torno a un valor constante (Kirchgassner, Wolters, & Hassler, 2013).

La formulación general para un modelo ARIMA se describe en la Ecuación 13:

$$Y_t = \underbrace{\mu + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p}}_{\text{Parte autorregresiva (AR)}} + \underbrace{a_t + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q}}_{\text{Parte de medias móviles (MA)}}$$

Donde:

$Y_t$ : Serie temporal

$\mu$ : Valor medio de la serie

$\phi_1, \dots, \phi_p$ : Parámetros autorregresivos para estimar

$a_t, a_{t-1}, \dots, a_{t-q}$ : Errores aleatorios observados en los períodos  $t, \dots, t - q$

$\theta_1, \dots, \theta_q$ : Parámetros de medias móviles para estimar

Además, los modelos ARIMA pueden tener una parte estacional ( $s$ ), como se describe a continuación:

$$ARIMA(p, d, q) (P, D, Q)_s$$

Donde:

$p$ : Número de parámetros autorregresivos ( $AR$ )

$d$ : Número de diferenciaciones para que la serie sea estacionaria ( $I$ )

$q$ : Número de parámetros de medias móviles ( $MA$ )

$P$ : Número de parámetros autorregresivos de la parte estacional ( $AR_s$ )

$D$ : Número de diferenciaciones estacionales para que la serie sea estacionaria ( $I_s$ )

$Q$ : Número de parámetros de medias móviles para la parte estacional ( $MA_s$ )

En la mayoría de los casos, las series no cumplen con todos los requisitos necesarios para ser consideradas como estacionarias, por lo que se deben aplicar algunas funciones de transformación para que estos requisitos se cumplan. Estas transformaciones también se utilizan para reducir fluctuaciones aleatorias y cambios bruscos en la serie de tiempo, y así facilitar su predicción. Algunas de estas funciones se describen a continuación, según lo planteado por IBM Corporation, 2017:

- Diferencia: Diferencia no estacional entre valores sucesivos de la serie. El orden es el número de valores previos utilizados para calcular la diferencia. Dado que se pierde una observación para cada orden de diferencia, aparecerán valores perdidos del sistema al comienzo de la serie.
- Diferencia estacional: Diferencia los valores de la serie respecto a los valores de la propia serie distanciados un orden (un lapso) de valores constante. El orden se basa en la periodicidad definida actualmente. El orden es el número de períodos estacionales utilizados para calcular la diferencia. El número de casos con el valor perdido del sistema al comienzo de la serie es igual a la periodicidad multiplicada por el orden de la diferencia estacional. Por ejemplo, si la periodicidad actual es 12 y el orden es 2, los primeros 24 casos tendrán el valor perdido del sistema para la nueva variable.
- Media móvil centrada: Se utiliza el promedio de un rango de los valores de la serie, que rodean e incluyen al valor actual. La amplitud es el número de valores de la serie utilizados para calcular el promedio. Si la amplitud es par, la media móvil se calcula con el promedio de cada par de medias no centradas. Número de casos con el valor perdido del sistema al comienzo y al final de la serie para una amplitud de  $n$  es igual a  $n/2$  para los valores de la amplitud par y  $(n-1)/2$  para los valores de la amplitud impar.
- Media móvil anterior: Se utiliza el promedio de un rango de las observaciones precedentes. La amplitud es el número de valores precedentes de la serie utilizados para calcular el promedio. El número de casos con el valor perdido del sistema al comienzo de la serie es igual al valor de la amplitud.
- Medianas móviles: Se utiliza la mediana de un rango de los valores de la serie, que rodean e incluyen al valor actual. La amplitud es el número de valores de la serie utilizados para calcular la mediana. Si la amplitud es par, la mediana se calcula con el promedio de cada par de medianas no centradas. Número de casos con el valor perdido del sistema al comienzo y al final de la serie para una amplitud de  $n$  es igual a  $n/2$  para los valores de la amplitud par y  $(n-1)/2$  para los valores de la amplitud impar.
- Suma acumulada: Cada valor de la serie se sustituye por la suma acumulada de los valores precedentes, incluyendo el valor actual.
- Retardo: Cada valor de la serie se sustituye por el valor del caso precedente, en el orden especificado. El orden especifica a qué distancia se encuentra el caso precedente. El número de casos con el valor perdido del sistema al comienzo de la serie es igual al valor del orden.
- Adelanto: Cada valor de la serie se sustituye por el valor de un caso posterior, en el orden especificado. El orden especifica a qué distancia se encuentra el caso posterior. El número de casos con el valor perdido del sistema al final de la serie es igual al valor del orden.

- Suavizado: Los nuevos valores de la serie se basan en un suavizador de datos compuesto. El suavizador comienza con una mediana móvil de 4, que se centra por una mediana móvil de 2. A continuación, se vuelven a suavizar estos valores aplicando una mediana móvil de 5, una mediana móvil de 3 y los promedios ponderados móviles. Los residuos se calculan sustrayendo la serie suavizada de la serie original. Después se repite todo el proceso sobre los residuos calculados. Por último, los residuos suavizados se calculan sustrayendo los valores suavizados obtenidos la primera vez que se realizó el proceso.

### 3.2.4 MEDIDAS DE PRECISIÓN

Para evaluar el desempeño de cada modelo, se deben calcular medidas de precisión o de “bondad de ajuste”. Estas medidas se describen a continuación, en base a lo planteado por IBM Corporation, 2017:

- R cuadrado estacionaria: Compara la parte estacionaria del modelo con un modelo de promedio simple. Esta medida puede tomar valores entre infinito negativo y uno.
- R cuadrado: Estima el porcentaje de variabilidad en la serie que explica el modelo. Esta medida puede tomar valores entre infinito negativo y uno.
- RMSE (Root Mean Square Error): Es la raíz cuadrada de la media cuadrática de los errores. Mide cuánto se desvía la serie del nivel pronosticado por el modelo, medido en las mismas unidades que la serie.
- MAE (Mean Absolute Error): Media del error absoluto, mide la desviación de la serie del nivel pronosticado por el modelo, se expresa en las mismas unidades que la serie.
- BIC normalizado (Normalized Bayesian Information Criterion): Criterio de información bayesiano normalizado, medida general del ajuste global del modelo que intenta tener en cuenta su complejidad. Esta medida permite comparar entre distintos modelos para una misma serie.

## 4 METODOLOGÍA

Se recopiló la información sobre la situación marítima portuaria de los últimos 10 años en Puerto Chacabuco (2009-2018). Esta información es de uso público y fue proporcionada por la DIRECTEMAR (Anexo A).

Existen cinco posibles “estados” para la situación marítima portuaria, denominados de la siguiente forma:

- Abierto - Condiciones Normales
- Cerrado para Movimiento de Naves Mayores
- Cerrado para Naves Menores Fuera de la bahía
- Cerrado para Naves Menores Fuera y Dentro de la bahía
- Paralización de Actividad

Por lo tanto, la base de datos se dividió en cinco series temporales correspondientes a cada estado y el procedimiento descrito a continuación se aplicó por separado a cada una de las cinco series de tiempo. Las series Cerrado para Movimiento de Naves Menores y Paralización de Actividad no presentaron autocorrelación, por lo tanto, no fue posible predecirlas.

El procedimiento consistió en calcular parámetros estadísticos como el rango, media, mediana, desviación estándar, varianza (entre otros) con el fin de describir apropiadamente el conjunto de datos, analizando su dispersión y centralización. Además, se organizó, presentó y caracterizó el conjunto de datos a través de tablas y gráficos que permitieron analizar el comportamiento mensual y anual de los datos e identificar posibles tendencias y/o estacionalidad.

Para la construcción y posterior validación del modelo fue necesario dividir la serie de tiempo en un periodo histórico y un periodo de validación. El periodo histórico comprende los datos entre el año 2009 y el 2017 y fue utilizado en la elaboración del modelo. El periodo de validación comprende los datos del año 2018 y se utilizó para contrastar los datos modelados con los datos observados de la serie. Cabe destacar que para la etapa de predicción se utiliza la serie de tiempo completa (2009-2018).

El diseño o construcción del modelo es un proceso iterativo que consistió en utilizar diferentes modelos (estacionales y no estacionales) y estimar sus parámetros para reproducir la serie. Dependiendo del caso, se realizaron algunas transformaciones a las series para asegurar que se cumplan los supuestos que exige cada método.

Para evaluar el desempeño de cada modelo, se calcularon medidas de “precisión” o de “bondad de ajuste” y se evaluó su validez conjunta. En los casos donde las medidas de bondad ajuste no fueron buenas, se debieron modificar algunos parámetros de los modelos hasta obtener medidas de precisión aceptables.

Durante la parte iterativa del proceso fue fundamental poder graficar los resultados y observar cómo variaba la serie con las distintas modificaciones. Este análisis de sensibilidad dio luces de qué parámetros se debían modificar y redujo la cantidad de iteraciones necesarias para encontrar el mejor modelo.

Una vez identificado el modelo con el mejor ajuste, se contrastaron los datos obtenidos de la modelación para el año 2018 con los datos del periodo de validación para evaluar su comportamiento y adecuación. Finalmente, el modelo seleccionado y validado se utilizó para realizar la predicción de horas mensuales con un horizonte de dos años (2019-2020).

El software estadístico que se utilizó durante el procesamiento de los datos fue SPSS Statistics 25, que incluye los parámetros y ecuaciones descritas anteriormente en el fundamento teórico.

## 5 RESULTADOS

En este capítulo se presentan los resultados obtenidos mediante la metodología planteada en el capítulo anterior. Esta metodología se aplicó a cada una de las 5 series de tiempo, correspondientes a cada “estado” o situación marítima portuaria, las que en adelante serán abreviadas de la siguiente forma:

Abierto - Condiciones Normales: ACN

Cerrado para Movimiento de Naves Mayores: CMNM


Cerrado para Naves Menores Fuera de la bahía: CNMF


Cerrado para Naves Menores Fuera y Dentro de la bahía: CNMFD

Paralización de Actividad: PA

Cada serie está compuesta por 120 datos, que corresponden a un dato mensual, desde enero del 2009 hasta diciembre del 2018; cada dato mensual se obtiene sumando la cantidad de horas en las que se presentó cada estado durante ese mes. Esta información se presenta en la Figura 5-1.

Figura 5-1: Horas mensuales de cada estado entre 2009 y 2018.





Fuente: Elaboración propia.

## 5.1 ANÁLISIS ESTADÍSTICO

### 5.1.1 PARÁMETROS ESTADÍSTICOS


Con el objetivo de caracterizar el conjunto de datos, se presenta un resumen de los principales parámetros estadísticos de cada serie durante los 10 años analizados (Tabla 5-1). Por otro lado, en la Figura 5-2 se muestra de forma gráfica el comportamiento mensual de las horas de cada serie, indicando el máximo, mínimo y la mediana de cada mes durante los 10 años analizados. En términos generales, la serie que presenta los valores más altos de estos parámetros estadísticos es ACN, con una mediana de 524 horas y una desviación estándar de 88,2 horas, es decir que el 95% de los datos se concentra entre las 445 y 622 horas por mes, esta serie es la que presenta la mayor dispersión. Seguida de las series CNMF y CNMFD con medianas de 88 y 81 horas respectivamente y con desviaciones estándar de 77,7 y 60,3 horas. Finalmente, las series que presentan los valores más bajos de estos parámetros son CMNM y PA con medianas iguales a cero y desviaciones estándar de 2,5 y 25,7 horas respectivamente, siendo la serie CMNM la que presenta menor dispersión y sus valores se centralizan en cero.

Tabla 5-1: Parámetros estadísticos


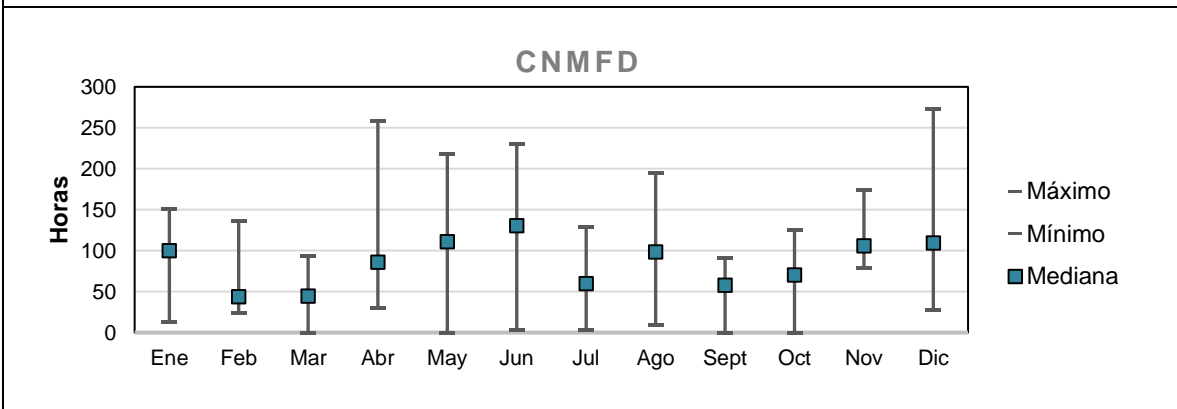

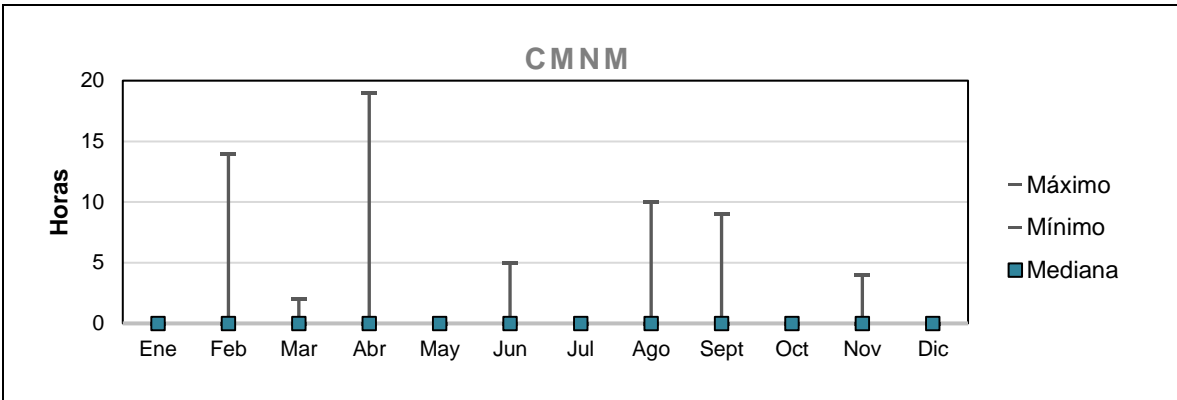
Estado	N	Rango	Mínimo	Máximo	Media	Mediana	Moda	Desv. Estándar	Varianza
ACN	120	398	346	744	533,4	524	486	88,2	7777,8
CMNM	120	19	0	19	0,6	0	0	2,5	6,4
CNMF	120	362	0	362	106,0	88	0	77,7	6035,4
CNMFD	120	273	0	273	86,0	81	0	60,3	3636,3
PA	120	199	0	199	4,5	0	0	25,7	659,1

Fuente: Elaboración propia.

Figura 5-2: Comportamiento mensual (entre 2009 y 2018) de cada serie







Fuente: Elaboración propia.

### 5.1.2 DISTRIBUCIÓN ANUAL DE HORAS

La Tabla 5-2 presenta un resumen de la cantidad de horas anuales en las que se presentó cada estado. Para visualizar esta información, la Figura 5-3 presenta gráficos circulares que muestran la proporción de horas de cada estado por año. Se puede observar que la mayor parte del tiempo (entre 65% y 83%) el puerto se encontró abierto bajo condiciones normales (ACN), siendo el año 2015 donde se presenta el máximo de horas para ese estado, seguido de los estados Cerrado para Naves Menores fuera de la bahía (CNMF) y Cerrado para Naves Menores fuera y dentro de la bahía (CNMFD), que sumados representan entre un 17% y 35% del total de horas por año.

Por otro lado, los estados Cerrado para Movimiento de Naves Mayores (CMNM) y Paralización de Actividad (PA) sumados representan menos del 1% del total de horas por año, excepto en el año 2012, donde el estado PA presentó un 5% del total de horas.


Las series Cerrado para Movimiento de Naves Menores y Paralización de Actividad no presentaron autocorrelación, esto dificulta la tarea de predecirlas de forma exitosa. Para efectos de esta investigación, se optó por predecir sólo las series ACN, CNMF y CNMFD ya que representan más de un 99% del total de horas analizadas.


Tabla 5-2: Cantidad de horas anuales

Estado	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	Total
ACN	6102	5728	6772	5849	6662	6608	7268	6897	5750	6372	<b>64008</b>
CMNM	0	14	0	0	0	0	0	4	24	24	<b>66</b>
CNMF	2033	2437	1246	1177	684	952	518	797	1725	1152	<b>12721</b>
CNMFD	625	581	728	1339	1414	1200	949	1069	1210	1200	<b>10315</b>
PA	0	0	14	419	0	0	25	17	51	12	<b>538</b>

Fuente: Elaboración propia.

Figura 5-3: Proporción de horas por año





Fuente: Elaboración propia

## 5.2 CONSTRUCCIÓN DEL MODELO

En esta etapa se realizó un proceso iterativo que consistió en utilizar diferentes modelos (estacionales y no estacionales) y estimar sus parámetros para reproducir las series temporales. Con el fin de evaluar el desempeño de cada modelo, se calcularon medidas de precisión, estas medidas permitieron identificar el modelo que presentó el mejor ajuste.

Para cada serie se probaron alrededor de diez modelos distintos, para efectos prácticos, en este capítulo se presentan resultados de cuatro de los diez modelos analizados. Los resultados de los diez modelos por cada serie temporal se encuentran en el Anexo B.

En la Tabla 5-3 se comparan las medidas de bondad de ajuste para los cuatro modelos que presentaron resultados más aceptables para la serie Abierto - Condiciones Normales.

Tabla 5-3: Medidas de bondad de ajuste para ACN

ACN	Suavizado exponencial	ARIMA		
	Estacional simple	(1,1,1) (0,1,1)	(1,1,2) (0,1,1)	(1,2,1) (0,1,1)
R cuadrado estacionaria	0,62	0,90	0,93	0,74
R cuadrado	0,88	0,97	0,98	0,97
RMSE	18,64	9,60	8,33	10,44
MAE	13,98	7,03	5,78	7,97
BIC normalizado	5,93	4,70	4,46	4,87

Fuente: Elaboración propia

En la Tabla 5-4 se comparan las medidas de bondad de ajuste para los cuatro modelos que presentaron resultados más aceptables para la serie Cerrado para Naves Menores Fuera de la bahía.

Tabla 5-4: Medidas de bondad de ajuste para CNMF

CNMF	Suavizado exponencial	ARIMA		
	Estacional simple	(1,1,1) (1,1,0)	(1,0,1) (1,1,0)	(2,0,1) (1,1,0)
R cuadrado estacionaria	0,64	0,76	0,91	0,92
R cuadrado	0,91	0,95	0,88	0,89
RMSE	18,77	12,77	20,07	19,17
MAE	13,37	7,67	10,38	8,27
BIC normalizado	5,95	5,27	6,17	6,12

Fuente: Elaboración propia

En la Tabla 5-5 se comparan las medidas de bondad de ajuste para los cuatro modelos que presentaron resultados más aceptables para la serie Cerrado para Naves Menores Fuera y Dentro de la bahía.

Tabla 5-5: Medidas de bondad de ajuste para CNMFD

CNMFD	Suavizado exponencial	ARIMA		
	Estacional simple	(1,0,1) (1,0,1)	(1,0,1) (2,0,1)	(1,0,1) (1,0,2)
R cuadrado estacionaria	0,54	0,95	0,95	0,95
R cuadrado	0,89	0,95	0,95	0,95
RMSE	13,64	9,80	9,77	9,34
MAE	10,58	6,53	6,37	6,07
BIC normalizado	5,31	4,76	4,80	4,71

Fuente: Elaboración propia

Los criterios utilizados para seleccionar el mejor modelo consistieron en analizar los valores de R cuadrado estacionaria y R cuadrado y escoger los más cercanos a uno. En este caso, los modelos seleccionados para las tres series presentaron valores cercanos y/o superiores a 0,9, es decir que, cerca del 90% de los datos se explican a través del modelo.

Respecto a los valores de RMSE (raíz cuadrada de la media cuadrática de los errores), MAE (Media del error absoluto) y BIC normalizado (Criterio de información bayesiano), se seleccionó el modelo que presentó el menor valor de estos parámetros, es decir, el modelo que menos se desvió de la serie.

Es importante destacar que cada parámetro por sí solo no es suficiente para la elección del modelo, por lo que se utilizan diferentes parámetros y se evalúa su validez conjunta.

Además de calcular medidas de precisión, es necesario validar el modelo contrastando los datos obtenidos de las modelaciones con los datos observados durante el año 2018 (periodo de validación) para evaluar su adecuación y comportamiento (Figura 5-4, Figura 5-5 y Figura 5-6).

Los modelos seleccionados para realizar los pronósticos de cada serie temporal se muestran en la Tabla 5-6.

Tabla 5-6: Modelos seleccionados


Serie temporal	Modelo Seleccionado
ACN	ARIMA (1,1,2) (0,1,1)
CNMF	ARIMA (2,0,1) (1,1,0)
CNMFD	ARIMA (1,0,1) (1,0,2)

Fuente: Elaboración propia.

Los parámetros estimados para cada modelo ARIMA seleccionado se encuentran en el Anexo C.

La Figura 5-4 muestra una comparación entre los datos observados y los datos modelados durante el periodo de enero a diciembre del año 2018 para la serie Abierto - Condiciones Normales. Se puede apreciar que el modelo sigue el comportamiento de los datos observados, siendo octubre el mes que presenta el mejor ajuste y julio el mes que muestra la mayor diferencia con los datos, mes donde el modelo tiende a subestimar las horas en las que estará abierta la bahía.

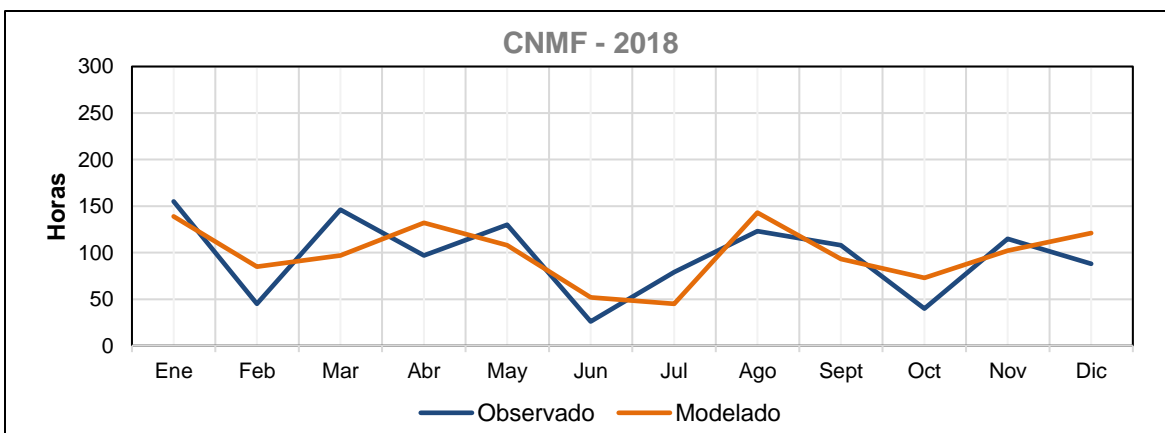
Figura 5-4: Comportamiento del modelo para ACN 2018



Fuente: Elaboración propia.

La Figura 5-5 muestra una comparación entre los datos observados y los datos modelados durante el periodo de enero a diciembre del año 2018 para la serie Cerrado para Naves Menores Fuera de la bahía. Se puede observar que el modelo presenta un leve desfase respecto al comportamiento de los datos observados, siendo enero, septiembre y noviembre los meses que presentaron el mejor ajuste y marzo el mes que muestra la mayor diferencia con los datos, mes donde el modelo tiende a subestimar las horas correspondientes al cierre para naves menores fuera de la bahía.


Figura 5-5: Comportamiento del modelo para CNMF 2018



Fuente: Elaboración propia.

La Figura 5-6 muestra una comparación entre los datos observados y los datos modelados durante el periodo de enero a diciembre del año 2018 para la serie Cerrado para Naves Menores Fuera y Dentro de la bahía. Se puede observar que el comportamiento del modelo en general se condice con el de los datos observados. Los meses de febrero, marzo, y agosto presentaron un muy buen ajuste, por otro lado, el mes de diciembre es el que presenta la mayor diferencia con los datos, mes donde el modelo, al igual que en el caso anterior, subestima las horas correspondientes al cierre para naves menores fuera y dentro de la bahía.

Figura 5-6: Comportamiento del modelo para CNMFD 2018



Fuente: Elaboración propia.


### 5.3 PREDICCIÓN

Utilizando los modelos seleccionados en el capítulo anterior, se realiza la predicción para cada serie temporal con un horizonte de dos años (2019 – 2020). El Anexo D contiene los datos de la predicción para las tres series pronosticadas.

La Figura 5-7 muestra la serie Abierto – Condiciones Normales (2009 – 2018) y la predicción de la serie realizada mediante un modelo ARIMA (1,1,2) (0,1,1). Durante el periodo observado se registra un máximo de 744 horas que equivale a 31 días durante el mes de octubre del 2015, es decir que ese mes el puerto no registró horas de cierre, por otro lado, durante junio del 2010 se registra un mínimo de 346 horas, equivalente a la mitad del mes aproximadamente.

Si se analiza la predicción, esta presenta un máximo de 558 horas durante septiembre del 2019, que equivale a 23 días y un mínimo de 403 horas durante junio del 2020, que corresponden a 17 días aproximadamente. y agregar el total de días por año que estará cerrado o abierto. Se puede observar que los valores predichos por el modelo ARIMA se asemejan más a los años inmediatamente anteriores al periodo de predicción, que a los años más lejanos al periodo de predicción.

Figura 5-7: Predicción de la serie ACN




Fuente: Elaboración propia.



La Figura 5-8 muestra la serie Cerrado para Naves Menores Fuera de la bahía (2009 – 2018) y la predicción de la serie realizada mediante un modelo ARIMA (2,0,1) (1,1,0). Durante el periodo observado se registra un máximo de 362 horas que equivale a 15 días durante el mes de junio del 2010, es decir que el puerto estuvo cerrado durante la mitad del mes para naves menores fuera de la bahía, por otro lado, se registraron varios mínimos de 0 horas durante ene-09, abr-12, sept-12, mar-13, sept-15 y oct-15.

Si se analiza la predicción, esta presenta un máximo de 190 horas durante agosto del 2019, equivalentes a 8 días aproximadamente y un mínimo de 34 horas durante febrero del 2020, que corresponden a un día y 10 horas. Se puede observar que los valores predichos por el modelo ARIMA se asemejan más a los años inmediatamente anteriores al periodo de predicción, que a los años más lejanos al periodo de predicción.

Figura 5-8: Predicción de la serie CNMF




Fuente: Elaboración propia.

La Figura 5-9 muestra la serie Cerrado para Naves Menores Fuera y Dentro de la bahía (2009 – 2018) y la predicción de la serie realizada mediante un modelo ARIMA (1,0,1) (1,0,2). Durante el periodo observado se registra un máximo de 273 horas que equivalen aproximadamente a 11 días durante el mes de diciembre del 2016, por otro lado, se registraron varios mínimos de 0 horas durante sept-09, mar-10, oct-11, oct-15, may-16 y sept-16.

Si se analiza la predicción, esta presenta un máximo de 113 horas durante enero del 2019, equivalentes a 5 días aproximadamente y un mínimo de 65 horas durante marzo del 2020, que corresponden a tres días aproximadamente. Se puede observar que los valores predichos por el modelo ARIMA se asemejan más a los años inmediatamente anteriores al periodo de predicción, que a los años más lejanos al periodo de predicción.

Figura 5-9: Predicción de la serie CNMFD



Fuente: Elaboración propia.

## **6 CONCLUSIONES**

Puerto Chacabuco constituye uno de los pilares fundamentales para el desarrollo de la región de Aysén ya que actúa como una puerta de entrada que permite conectar a las localidades situadas en la zona insular de la región con el resto del país a través de los terminales de Puerto Montt y Punta Arenas.

En este estudio se llevó a cabo un análisis estadístico para las distintas situaciones marítimas portuarias que se dan en la bahía de Puerto Chacabuco. De este análisis se obtiene que el 73% del tiempo el puerto se encuentra en la situación Abierto – Condiciones normales (ACN), un 26% del tiempo el puerto se encuentra cerrado para naves menores (CNMF y CNMFD) y menos del 1% del tiempo el puerto se encuentra Cerrado para movimiento de naves mayores o en paralización de actividad. Según el Estudio Nacional de Desarrollo Portuario (Subsecretaría de Transportes, 2013), Puerto Chacabuco atiende mayoritariamente naves menores, por lo que una predicción de las horas de cierre, principalmente para naves menores será de gran utilidad al momento de planificar las actividades en el puerto.

Respecto a la paralización de actividad (PA) y al cierre para movimiento de naves mayores (CMNM), se observó que estas series presentaron valores muy bajos y en la gran mayoría de los casos, valores iguales a cero, en base a esto, se infiere que hay una baja ocurrencia de eventos climáticos mayores en la zona, que obliguen a paralizar las actividades o impidan el movimiento de naves mayores en la bahía de Puerto Chacabuco.

Al analizar el comportamiento de las predicciones para el año 2019 se puede concluir que el puerto estará cerrado para naves menores fuera de la bahía (CNMF) durante un total de 1.327 horas, que equivalen a 55 días del año, es decir que el puerto estará cerrado 2 meses aproximadamente. Además, estará cerrado para naves menores dentro y fuera de la bahía (CNMFD) durante un total de 1.138 horas, que equivalen a 47 días del año, es decir que el puerto estará cerrado cerca de 1,5 meses. Esto quiere decir que, en total, durante el año 2019, el puerto estará cerrado para naves menores durante 3,5 meses aproximadamente.

De las predicciones para el año 2020 se concluye que el puerto estará cerrado para naves menores fuera de la bahía (CNMF) durante un total de 1.076 horas, que equivalen a 45 días del año, es decir que el puerto estará cerrado 1,5 meses aproximadamente. Además, estará cerrado para naves menores dentro y fuera de la bahía (CNMFD) durante un total de 1.063 horas, equivalentes a 44 días del año, es decir que el puerto estará cerrado cerca de 1,5 meses. Esto quiere decir que, en total, para el año 2020, se pronostica el cierre para naves menores durante 3 meses aproximadamente.

Por otro lado, el comportamiento mensual de la predicción para naves menores fuera de la bahía indica que los meses de febrero 2019, febrero, junio y octubre 2020 serán los meses en los que se presentará la menor cantidad de horas de cierre, con un promedio de 45 horas mensuales, lo que equivale a 2 días de cierre por mes aproximadamente. A su vez, el comportamiento mensual de la predicción para naves menores fuera y dentro de la bahía indica que los meses de marzo, julio y septiembre, tanto para el 2019 como para el 2020, en los que se presentará la menor cantidad de horas de cierre, con un promedio de 72 horas

mensuales, equivalentes a 3 días de cierre por mes por lo que se recomienda planificar las actividades más importantes durante esos meses.

Por otro lado, el comportamiento mensual de la predicción para naves menores fuera de la bahía indica que los meses de enero, julio, agosto y diciembre del 2019 y enero y agosto del 2020 serán los meses en los que se presentará la mayor cantidad de horas de cierre, con un promedio de 147 horas mensuales, lo que equivale a 6 días de cierre por mes aproximadamente. A su vez, el comportamiento mensual de la predicción para naves menores fuera y dentro de la bahía indica que los meses de enero, noviembre y diciembre del 2019 y noviembre y diciembre del 2020, en los que se presentará la mayor cantidad de horas de cierre, con un promedio de 113 horas mensuales, equivalentes a 5 días de cierre por mes aproximadamente, por lo que se recomienda planificar las actividades menos importantes y/o urgentes durante esos meses.

En términos generales, los modelos ARIMA presentaron un mejor ajuste que los demás modelos utilizados. Los modelos ARIMA, a diferencia de otros modelos, no solo utilizan valores históricos para pronosticar los valores futuros, también consideran los errores históricos dentro del cálculo del pronóstico, se infiere que esto podría generar una ventaja en términos de precisión. También es importante mencionar que los modelos ARIMA tienen una mayor influencia de los valores históricos inmediatamente anteriores al periodo de predicción, por lo que es natural que la predicción se asemeje más a los años cercanos al 2019 y no se asemeje tanto a los años cercanos al 2009.

Finalmente se concluye que es posible predecir las horas de cierre de una bahía mediante el análisis de series de temporales, siempre que se cuente con la información histórica necesaria y un ingeniero civil oceánico está capacitado para realizar este tipo de estudios.

## **7 REFERENCIAS BIBLIOGRÁFICAS**

- Box, G., Jenkins, G., & Reinsel, G. (2016). *Time series analysis, forecasting and control. Fifth edition*. Wiley.
- Chan, H. K., Xu, S., & Qi, X. (2019). A comparison of time series methods for forecasting container throughput. *International Journal of Logistics Research and Applications*, 22:3, pp 294-303.
- Delicado, P., & Justel, A. (1999). Forecasting with Missing Data: Application to Coastal Wave Heights. *Journal of forecasting*, 18, pp. 285-298.
- Emporcha. (2017). *Plan Maestro Empresa Portuaria Chacabuco*. Puerto Chacabuco.
- Hanke, J., & Reitsh, A. (2006). *Pronósticos en los negocios. 8va Edición*. Pearson.
- IBM Corporation. (2017). *Guía del usuario de IBM SPSS Statistics 25 Core System*.
- Jiménez, J. F., Gázquez, J. C., & Sánchez, R. (2006). La capacidad predictiva en los métodos Box-Jenkins y Holt-Winters: una aplicación al sector turístico. *Revista Europea de Dirección y Economía de la Empresa*, vol. 15, núm. 3, pp. 185-198.
- Kirchgassner, G., Wolters, J., & Hassler, U. (2013). *Introduction to modern time series analysis. Second edition*. Berlín: Springer.
- Montes, E., Calvete, F., & Mantilla, C. (2016). Aplicación de series de tiempo en la realización de pronósticos de producción. *Revista Fuentes: El Reventón Energético*, vol. 14, núm 1, pp. 79-88.
- Pérez, C. (2005). *Técnicas estadísticas con SPSS 12. Aplicaciones al análisis de datos*. Madrid: Pearson.
- Ruiz, J., Turias, I., Moscoso, J., Jiménez, M., & Cerbán, M. (2017). Efficient goods inspection demand at ports: a comparative forecasting approach. *International transactions inoperational research*, pp. 1-29.
- SUBDERE. (2011). *Estudio Identificación de Territorios Aislados*. Subsecretaría de Desarrollo Regional y Administrativo.
- Subsecretaría de Transportes. (2013). *Estudio Nacional de Desarrollo Portuario*.
- Webster, A. (2004). *Estadística aplicada a los negocios y la economía. 3ra Edición*. Bogotá: McGraw-Hill.

## 8 ANEXOS

Anexo A: Correo de Directemar que proporciona la base de datos.

Correo de Universidad de Valparaíso - Da respuesta a solicitud Oirs Directemar N° 13107.



MICHELLE DOMINIQUE GALLARDO <michelle.gallardos@alumnos.uv.cl>

---

**Da respuesta a solicitud Oirs Directemar N° 13107.**

---

**Oswaldo Castro Escobar** <ocastro@dgtm.cl> 12 de marzo de 2019, 12:28  
Para: michelle.gallardos@alumnos.uv.cl

**SOLICITUD N° 13107**

**SEÑORITA  
MICHELLE DOMINIQUE GALLARDO SYRIANI  
PRESENTE**

Junto con saludarla, y en relación a su solicitud N° 13107, remito a Ud. un archivo en formato "excel" (Oirs 13107) conteniendo la condición de puerto o "Situación Marítima Portuaria" del Puerto de Chacabuco entre los años 2009 al 2018.

Saluda atentamente a Ud.,

Oswaldo Castro Escobar  
Capitán de Navío LT  
Encargado Oficina Transparencia/OIRS  
Directemar

12.Marzo.2019.

---

 **Oirs 13107.xlsx**  
149K

Anexo B: Resultados de todos los modelos analizados.

Comparación de modelos de suavizado exponencial analizados para la serie ACN:

ACN	Suavizado exponencial						
	No Estacional				Estacional		
	Simple	Tendencia Lineal de Holt	Tendencia Lineal de Brown	Tendencia Amortiguada	Estacional simple	Aditivo de Winters	Multiplicativo de Winters
R cuadrado estacionaria	0,00	0,00	0,00	0,58	0,62	0,61	0,39
R cuadrado	0,87	0,94	0,94	0,95	0,88	0,88	0,83
RMSE	19,49	13,45	13,39	12,69	18,64	18,86	22,64
MAE	14,39	10,03	10,03	9,36	13,98	14,08	17,75
BIC normalizado	5,98	5,28	5,23	5,20	5,93	5,99	6,36

Comparación de modelos de ARIMA analizados para la serie ACN:

ACN	ARIMA		
	(1,1,1)(0,1,1)	(1,1,2)(0,1,1)	(1,2,1)(0,1,1)
R cuadrado estacionaria	0,90	0,93	0,74
R cuadrado	0,97	0,98	0,97
RMSE	9,60	8,33	10,44
MAE	7,03	5,78	7,97
BIC normalizado	4,70	4,46	4,87

Comparación de modelos de suavizado exponencial analizados para la serie CNMF:

CNMF	Suavizado exponencial						
	No Estacional				Estacional		
	Simple	Tendencia Lineal de Holt	Tendencia Lineal de Brown	Tendencia Amortiguada	Estacional simple	Aditivo de Winters	Multiplicativo de Winters
R cuadrado estacionaria	0,00	0,00	0,00	0,70	0,64	0,62	-
R cuadrado	0,89	0,96	0,96	0,97	0,91	0,91	-
RMSE	20,97	12,21	12,15	11,65	18,77	19,30	-
MAE	13,25	8,87	8,87	8,49	13,37	13,76	-
BIC normalizado	6,13	5,08	5,04	5,03	5,95	6,04	-

Comparación de modelos de ARIMA analizados para la serie CNMF:

CNMF	ARIMA		
	(1,1,1)(1,1,0)	(1,0,1)(1,1,0)	(2,0,1)(1,1,0)
R cuadrado estacionaria	0,76	0,91	0,92
R cuadrado	0,95	0,88	0,89
RMSE	12,77	20,07	19,17
MAE	7,67	10,38	8,27
BIC normalizado	5,27	6,17	6,12



Comparación de modelos de suavizado exponencial analizados para la serie CNMFD:

CNMFD	Suavizado exponencial						
	No Estacional				Estacional		
	Simple	Tendencia Lineal de Holt	Tendencia Lineal de Brown	Tendencia Amortiguada	Estacional simple	Aditivo de Winters	Multiplicativo de Winters
R cuadrado estacionaria	0,00	-0,01	0,00	0,62	0,54	0,51	-0,96
R cuadrado	0,87	0,95	0,95	0,95	0,89	0,89	0,62
RMSE	14,84	9,68	9,63	9,29	13,64	13,58	25,58
MAE	10,62	7,35	7,35	6,87	10,58	11,08	19,49
BIC normalizado	5,43	4,62	4,57	4,58	5,31	5,34	6,60

Comparación de modelos de ARIMA analizados para la serie CNMF:

CNMFD	ARIMA		
	(1,0,1)(1,0,1)	(1,0,1)(2,0,1)	(1,0,1)(1,0,2)
R cuadrado estacionaria	0,95	0,95	0,95
R cuadrado	0,95	0,95	0,95
RMSE	9,80	9,77	9,34
MAE	6,53	6,37	6,07
BIC normalizado	4,76	4,80	4,71

Anexo C: Parámetros de los modelos ARIMA utilizados en la predicción.

Parámetros del modelo ARIMA (1,1,2) (0,1,1) utilizado para predecir la serie ACN:

<b>Parámetros del modelo ARIMA (1,1,2) (0,1,1)</b>					
ACN		Estimación	SE	t	Sig.
Constante		-0,438	0,283	-1,550	0,124
AR	Retardo 1	0,745	0,250	2,973	0,004
Diferencia		1	-	-	-
MA	Retardo 1	1,510	5,278	0,286	0,775
	Retardo 2	-0,510	2,766	-0,185	0,854
Diferencia estacional		1	-	-	-
MA, estacional	Retardo 1	0,996	5,883	0,169	0,866

Parámetros del modelo ARIMA (2,0,1) (1,1,0) utilizado para predecir la serie CNMF:

<b>Parámetros del modelo ARIMA (2,0,1) (1,1,0)</b>					
CNMF		Estimación	SE	t	Sig.
Constante		-6,867	14,384	-0,477	0,634
AR	Retardo 1	1,003	0,214	4,686	0,000
	Retardo 2	-0,087	0,152	-0,571	0,569
MA	Retardo 1	0,716	0,180	3,980	0,000
AR, estacional	Retardo 1	-0,610	0,082	-7,472	0,000
Diferencia estacional		1	-	-	-

Parámetros del modelo ARIMA (1,0,1) (1,0,2) utilizado para predecir la serie CNMFD:

<b>Parámetros del modelo ARIMA (1,0,1) (1,0,2)</b>					
CNMFD		Estimación	SE	t	Sig.
Constante		86,946	16,178	5,374	0,000
AR	Retardo 1	0,712	0,180	3,967	0,000
MA	Retardo 1	0,458	0,226	2,022	0,046
AR, estacional	Retardo 1	0,973	0,178	5,462	0,000
MA, estacional	Retardo 1	0,930	0,326	2,851	0,005
	Retardo 2	-0,032	0,122	-0,265	0,792

Anexo D: Predicción 2019-2020 para cada situación marítima portuaria.

Fecha	ACN	CNMF	CNMFD
Ene-19	524	141	113
Feb-19	506	50	92
Mar-19	550	95	75
Abr-19	475	97	102
May-19	483	105	105
Jun-19	431	90	105
Jul-19	518	141	77
Ago-19	448	190	97
Sept-19	558	88	66
Oct-19	521	115	79
Nov-19	443	79	109
Dic-19	459	136	118
Ene-20	501	137	90
Feb-20	482	34	75
Mar-20	525	114	65
Abr-20	449	85	94
May-20	456	108	97
Jun-20	403	39	102
Jul-20	490	91	73
Ago-20	419	137	95
Sept-20	529	89	66
Oct-20	491	58	79
Nov-20	413	89	108
Dic-20	429	95	119