


UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE OBRAS CIVILES
VALPARAÍSO – CHILE



**SISTEMA DE MONITOREO PARA LA DETECCIÓN DE
FUGAS EN MATRIZ GRAN ALIMENTADORA,
VALPARAÍSO, CHILE.**

ÓSCAR SILVA SALDIVIA


Memoria para optar al Título de
Ingeniero Civil

Profesor Guía
Gonzalo Murillo V.

Profesora Correferente
Vivian Aranda N.

Julio de 2018

UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE OBRAS CIVILES
VALPARAÍSO – CHILE



**SISTEMA DE MONITOREO PARA LA DETECCIÓN DE
FUGAS EN MATRIZ GRAN ALIMENTADORA,
VALPARAÍSO, CHILE.**

ÓSCAR SILVA SALDIVIA
Memoria para optar al Título de
Ingeniero Civil

Profesor Guía
Gonzalo Murillo V.

Profesora Correferente
Vivian Aranda N.

Julio de 2018

Dedicatoria

Dedicado a todos quienes intentamos superar temores para desplazar nuestros límites.

Agradecimientos

Agradezco a mis padres, familia, pareja y amigos por incitarme a recorrer el camino más pedregoso y satisfactorio a la vez. Por ayudarme a entender que esta vía es la más adecuada para mi desarrollo espiritual, intelectual y emocional.

Un especial agradecimiento a mi “tata Tino” (Q.E.P.D) por sembrar la semilla de la duda y curiosidad.

Resumen

En Chile, el desarrollo del sector sanitario, regulado y fiscalizado por la Superintendencia de Servicios Sanitarios (SISS), ha permitido que en la actualidad la cobertura de agua potable urbana sea de un 99,9%, mientras que en alcantarillado alcance un 99,6% (Superintendencia de Servicios Sanitarios, 2016). Esta condición sumada a la coyuntura climática existente, reflejada en un periodo prolongado de sequía, necesariamente ha impulsado una reorientación en los esfuerzos y objetivos del sector sanitario, propiciando la sustentabilidad por medio de la eficiencia energética y optimización de los procesos de captación, producción y distribución del agua, principalmente.

En este contexto la empresa sanitaria Esva S.A. se ha propuesto impulsar las metodologías que permitan la gestión inteligente del recurso hídrico, tal como el presente proyecto de investigación, desarrollo e implementación que se enmarca en las nuevas metodologías de mantenimiento preventivo de redes de agua potable.

Particularmente se busca generar un sistema de monitoreo permanente para la detección de fugas en uno de los principales elementos hidráulicos de la red de distribución de agua potable de la ciudad de Valparaíso, denominado como “Matriz Gran Alimentadora”, cuya cobertura es de unos 15.000 clientes.

En vista de la envergadura y criticidad de esta tubería, toda herramienta que aporte a la continuidad en la distribución del suministro de agua potable es tomada como relevante, más aún si el citado sistema permite mejorar los tiempos de reacción

a la hora de incurrir en reparaciones menores producto de filtraciones que pudiesen provocarse, y con ello aminorar los impactos sobre sus usuarios.

El desarrollo conceptual de la herramienta en cuestión, está basado en el análisis del comportamiento de ruido en el tiempo. De este modo, cuando los patrones habituales se vean sobrepasados se genera una alerta de mantenimiento que pudiese decantar en una reparación.

Para la identificación de un evento catalogado como una fuga, se instalan sensores con registradores de datos a lo largo de la tubería, que a su vez se comunican diariamente con un servidor (Halma Water Management, 2016). Este sirve de visualizador y repositorio de información.

La configuración de alertas para cada punto monitoreado se basa en la comparación del registro actual contra un valor umbral, identificado por medio del análisis de la historia del mismo. Dicho análisis será efectuado utilizando modelos estadísticos tipo ARIMA para series temporales de registros de datos (Box & Jenkins, 1976), considerando un nivel de confianza del 95%.

Complementariamente, este sistema permitirá identificar los niveles de pérdida por filtraciones que pudiesen generarse en el tiempo, lo que posiciona a este desarrollo como una herramienta útil para la gestión inteligente del agua potable.

Abstract

In Chile, the development of the sanitary sector – strongly boosted by a State institutionally aimed to regulations and supervision – describes a current urban coverage of drinking water of a 99,9% in comparison to sewage services that reach a coverage of 99,6% (Superintendencia de Servicios Sanitarios, 2016). This situation – along with the climatic contingency defined by a long-standing drought – has encouraged a re-orientation of the sanitary sector's aims mainly towards optimising processes of gathering, production and distribution of water.

In this context – and as well as the sanitary firm Esval SA – the current research project proposes the reinforcement of the methodologies that allow a smart management of the hydric resource, its development and implementation circumscribed within the preventive maintenance of the water networks. More specifically, what is sought to generate is a permanent monitoring system for leakage in one of the main hydraulic elements of the drinking water distribution net in Valparaiso city, named as 'Matriz Gran Alimentadora' that embraces around 15.000 consumers. Considering the scale and relevance of this pipe, every tool that contributes to the continuous drinking water provision is seen as crucial, even more if they improve reaction times in minor reparations in case of leaks and thus, the amelioration of impacts.

The theoretical framework of the proposed tool is based on the analysis of the behaviour of the noise in time. So, when common patterns are detected beyond the proper range, then it generates an alert of maintenance that can derivate on timely

reparations. To identify an event as a ‘leak’, different sensors are installed along the pipe to record data that is daily delivered to a server (Halma Water Management, 2016) that works as a display service and data storage. The setting of alerts for each point is based on the comparison of current records with a threshold value identified through its own historical analysis. Such analysis will be developed using statistical models (ARIMA) for temporary series of data recording (Box & Jenkins, 1976) considering a confidence level of 95%.

Additionally, this system will allow controlling the wasting levels by leaks eventually generated over time, finally positioning this tool as a useful one for the smart management of the drinking water.

Glosario

Aleatoria

Proceso cuyo resultado no es previsible más que en razón de la intervención del azar., 33, 68

Correlación

Indica la fuerza y la dirección de una relación lineal y proporcionalidad entre dos variables estadísticas. Se considera que dos variables cuantitativas están correlacionadas cuando los valores de una de ellas varían sistemáticamente con respecto a los valores homónimos de la otra, 35

Correlograma

Gráfico de los coeficientes de autocorrelación de orden “k” contra el retardo “k”, 34, 35, 36, 43, 50, 54, 60, 85, 87, 88, 89, 96, 102, 107

Corrosión

Deterioro de un material a consecuencia de un ataque electroquímico por su entorno. De manera más general, puede entenderse como la tendencia general que tienen los materiales a buscar su forma más estable o de menor energía interna., 24, 135

Datalogger

Dispositivo electrónico que registra datos en el tiempo, o en relación a la ubicación por medio de instrumentos y sensores propios o conectados externamente. Casi todos están basados en microcontroladores. Por lo general son pequeños, con pilas, portátiles, y equipados con un microprocesador y memoria interna para almacenamiento de datos., 4, 11, 17, 18, 27, 29, 120

Decibelios

Medida utilizada para expresar el nivel de potencia y el nivel de intensidad del ruido. Se utiliza una escala logarítmica porque la sensibilidad que presenta el oído humano a las variaciones de intensidad sonora sigue una escala aproximadamente logarítmica, no lineal., 4, 30, 32

Dispersión

Grado de distanciamiento de un conjunto de valores respecto a su valor medio, 4, 13, 29, 30, 31, 83, 84, 85, 108, 109, 115, 116, 117, 118, 119, 120, 122

Eficacia

Capacidad de alcanzar el efecto que espera o se desea tras la realización de una acción., 5, 32, 120

Esbeltez

Relación entre la sección transversal respecto a la longitudinal., 30

Estacionariedad

Carácterística de una serie de datos que corresponde a la evolución en torno a un valor contante de su media y varianza., 42

Hipótesis nula

Afirmación que no se rechaza a menos que los datos de la muestra parezcan evidenciar que es falsa. Para afirmar que la hipótesis nula es verdadera se requiere

estudiar a toda la población., 48, 49, 58, 59, 61, 62, 63, 88, 90, 95, 98, 99, 101, 104, 105

Histogramas

Representación gráfica de una variable en forma de barras, donde la superficie de cada barra es proporcional a la frecuencia de los valores representados., 10

Matriz

Tubería de gran envergadura para el transporte y distribución de agua potable., 3, 4, 5, 8, 9, 22, 23, 26, 108, 117, 120, 127, 128, 129, 130

Moda

En estadística, la moda es el valor con mayor frecuencia en una distribución de datos., 29

Nivel de significancia

Concepto estadístico asociado a la verificación de una hipótesis. En pocas palabras, se define como la probabilidad de tomar la decisión de rechazar la hipótesis nula cuando ésta es verdadera., 48, 49, 63, 101, 104, 105

Parsimonia

Sencillez de un modelo estadístico, en referencia a los términos que definen su estructura., 42

Patrones

Serie de variables constantes, identificables dentro de un conjunto mayor de datos., vi, 28

Predicciones

Acción de anunciar un hecho futuro., 33, 67, 72, 73, 110

Rango de no significancia

Límite probabilístico que define la relevancia de un término dentro de la estructura del modelo, en cuanto a la información explicativa que posea., 86, 89, 92

Ruido

Sonido inarticulado, sin ritmo ni armonía y confuso., vi, 2, 4, 9, 10, 13, 19, 29, 30, 32, 33, 43, 46, 60, 62, 77, 80, 82, 83, 84, 85, 104, 107, 108, 109, 112, 113, 114, 115, 116, 117, 118, 119, 120, 121, 122

Ruido blanco

Señal aleatoria que se caracteriza por el hecho de que sus valores de señal en dos tiempos diferentes no guardan correlación estadística, 43, 46, 60, 62, 80, 104, 107, 112

Sensor

Objeto capaz de detectar magnitudes físicas o químicas, llamadas variables de instrumentación, y transformarlas en variables eléctricas., 4, 5, 9, 10, 12, 13, 27, 30, 31, 32, 77, 82, 107, 108, 110, 111, 112, 115, 120, 121

Series

Conjunto de resultados observados, registrados como números para su análisis estadístico., vi, 32, 45, 77, 83, 112

Servidor

Aplicación en ejecución capaz de atender las peticiones de un cliente y devolverle una respuesta en concordancia., vi, 2, 11, 13, 30, 31, 115, 117, 120

Simcard

Tarjetas de datos móviles., 11, 14

Sistémica

Proceso que realiza un trabajo o una tarea ordenadamente, siguiendo un método o conjunto de reglas., 33

Socavón

Hundimiento que se produce en el suelo, generalmente por haber una corriente subterránea o algún espacio hueco bajo tierra., 3

Telemetría

Tecnología que permite la medición remota de magnitudes físicas y el posterior envío de la información hacia el operador del sistema., 4, 8, 113

Transductores

Dispositivos capaces de transformar o convertir una determinada manifestación de energía de entrada, en otra diferente a la salida, pero de valores muy pequeños en términos relativos con respecto a un generador., 20

Umbral

Valor límite, inferior y/o superior, según las necesidades del problema., vi, 4, 13, 31, 32, 109, 110, 111, 112, 119, 121

Glosario de siglas

ADF

Aumented Dickey Fuller. En español test Dickey Fuller aumentado, 49, 87, 88, 90, 91

AIC

Akaike Information Criterion, 64, 65, 111, 112

ANF

Agua No Facturada, 1, 7

AR

Modelo autorregresivo, 38, 45, 46, 49, 51, 54, 56, 57, 59, 61, 86, 91

ARIMA

Autoregressive Integrated Moving Average. En español modelo autorregresivo, integrado de media móvil, vi, viii, 5, 33, 34, 35, 36, 40, 41, 42, 45, 51, 52, 53, 54, 57, 76, 77, 78, 80, 81, 83, 88, 93, 95, 97, 99, 110, 111, 112, 120, 124, 126, 138, 141, 142, 143, 144, 145, 146, 147, 149, 150, 151, 152, 153, 154, 155, 156, 157, 158, 159, 160, 161, 162, 164

CBS

Criterio de información Bayesiano de Schwarz, 66

CSQ

Cellular Signal Quality. En español calidad de señal celular, 16, 17, 18

DF

Test Dickey Fuller, 47, 88

FAC

Función de Auto Correlación, 57, 60

FACP

Función de Autocorrelación Parcial, 57, 59, 60, 91, 92

FAS

Función de Autocorrelación Simple, 85, 91, 92, 103, 106

GPRS

General Packet Radio Service, en español servicio general de paquetes vía radio, 4, 8, 10, 12, 14, 15, 16, 27, 110, 113, 115, 120

HQIC

Criterio de información Hannan Quin, 67

MA

Moving Average. En español promedio móvil, 38, 42, 49, 53, 54, 56, 57, 61, 86, 91, 92, 93, 95, 99, 102, 105

SARIMA

Seasonal Autoregressive Integrated Moving Average, 112, 139, 140, 163, 165, 166, 167, 168, 169, 170, 171, 172, 173, 174, 175, 176, 177, 178, 179, 180

Glosario de variables

- $\mathbf{a}_t$: Serie de errores de ajuste, o innovación.
- $\mathbf{a}_t^{(d)}$: Serie de errores de ajustes de la serie diferenciada “d” ocasiones consecutivas
- $\mathbf{a}_{t-1}$: Primer error de ajuste que se registra en tiempo pasado, $t - 1$, o primer retardo del modelo.
- $\mathbf{a}_{t-q}$: Último error de ajuste que se registra en tiempo pasado, $t - q$, o último retardo del modelo.
- $\mathbf{C}$: Valor constante a considerar, o no, en el modelo.
- $\mathbf{d}$: Orden de integración, o diferenciación, necesario para dar estacionariedad a la estructura regular de la serie temporal.
- $\mathbf{D}$: Orden de integración estacional. Representa el número de veces que debe ser diferenciada para volverla estacionaria.
- $\hat{\mathbf{f}}(\mathbf{m})$: Estimación máximo verosímil de un conjunto de parámetros.
- $\mathbf{H}_0$: Hipótesis nula para determinar la significancia de un término presente en el modelo.
- $\mathbf{H}_a$: Hipótesis alternativa para determinar la significancia de un término presente en el modelo.
- $\mathbf{j}$: Representa un día de la serie temporal
- $\mathbf{k}$: Retardo de una variable respecto a si misma.
- $\mathbf{L}$: Operador de retardo de primer orden, que retrasa la serie temporal en un momento.
- $\mathbf{L}^p$: Operador de retardo de orden “p”, que retrasa la serie temporal en “p” momentos.
- $\mathbf{L}^q$: Operador de retardo de orden “q”, que retrasa la serie de errores de ajuste en “q” momentos.
- $\mathbf{m}$: Número de parámetros independientes considerados en el modelo.
- $\mathbf{M}$: Último período en análisis, que a su vez determina el último coeficiente a incluir en la hipótesis de correlación serial.
- $\mathbf{n}$: Tamaño de la muestra.
- $\mathbf{p}$: Orden o grado de la estructura autorregresiva. Representa la cantidad de términos autorregresivos utilizados en el modelo
- $\mathbf{P}$: Orden o grado de la estructura autorregresiva estacional. Representa la cantidad de términos autorregresivos utilizados en el modelo
- $\mathbf{q}$: Orden o grado de la estructura media móvil. Representa la cantidad de términos de error de ajuste considerados en el modelo.
- $\mathbf{Q}$: Orden o grado de la estructura media móvil estacional. Representa la cantidad de términos de error de ajuste considerados en el modelo.

Q^* : Estadístico de Ljung – Box.
 t : corresponde a la observación, o registro, tiempo presente de la serie temporal.
 T : Número de observaciones de la serie de registros que definen la longitud de la serie original Y_t .
 T^* : Longitud de la serie estacionaria, es decir $T - d$.
 χ^2 : Distribución de probabilidad Chi – cuadrado
 Y_t : Representa cualquier serie de registros, cuyas observaciones estén consecutivamente ordenadas en el tiempo.
 $y_T^{(j)}$: Corresponde a la sub – serie del día “j” para un período “T”
 Y_{t-1} : Primera observación que se registra en tiempo pasado, $t - 1$, o primer retardo del modelo.
 Y_{t-p} : Última observación que se registra en tiempo pasado, $t - p$, o último retardo del modelo.
 $Y_t^{(d)}$: Serie diferenciada en “d” ocasiones sucesivas
 $\bar{Z}$: Media de la serie estacionaria.
 Z_t : Serie temporal resultante de un proceso de transformación, para el cual se aplicaron “d” procesos de diferenciación
 α : Nivel de confianza estipulado para la generación de modelos probabilísticos tipo ARIMA
 β : Corresponde a un término auxiliar que se construye para simplificar la prueba de hipótesis estadística.
 θ_1 : Coeficiente que pondera el primer término de la estructura media móvil regular del modelo.
 θ_q : Coeficiente que pondera el último término de la estructura media móvil regular del modelo.
 Θ_1 : Término que pondera el primer retardo de la estructura media móvil estacional para un modelo ARIMA (p, d, q) x (P, D, Q)
 Θ_q : Término que pondera el último retardo de la estructura media móvil estacional para un modelo ARIMA (p, d, q) x (P, D, Q)
 $\Theta_q(L)$: Polinomio de media móvil
 λ : Representa el parámetro de transformación Box – Cox
 $v_T^{(j)}$: Corresponde a la sub – serie de errores de ajuste del día “j” para un período “T”.
 ρ_{xy} : Coeficiente de correlación entre las variables conocidas x e y.
 $\hat{\sigma}$: Desviación estándar muestral.
 $\hat{\sigma}^2$: Estimador de máxima verosimilitud de la varianza de los errores de regresión.

ϕ_1 : Coeficiente que pondera el primer término de la estructura autorregresiva regular del modelo.

ϕ_p : Coeficiente que pondera el último término de la estructura autorregresiva regular del modelo.

Φ_1 : Término que pondera el primer retardo de la estructura autorregresiva estacional para un modelo ARIMA (p, d, q) x (P, D, Q)

Φ_p : Término que pondera el último retardo de la estructura autorregresiva estacional para un modelo ARIMA (p, d, q) x (P, D, Q)

$\Phi_p(L)$: Polinomio autorregresivo

ψ_i : Coeficiente que pondera la secuencia infinita de la estructura media móvil.

Δ^d : Polinomio de integración de orden “d”, $(1 - L)^d$, que contiene un número de “d” raíces que son mayores a la unidad.

Tabla de Contenidos

Introducción.	1
Objetivos.	6
1 Descripción problemática existente y propuesta de solución preliminar..	7
1.1 Sensores (hardware).	10
1.2 Servidor web (software).	12
1.3 Sistema de comunicación.	14
1.4 Gestión de alertas.	19
1.5 Implementación en matriz Gran Alimentadora de Valparaíso.	21
2 Propuesta de solución definitiva.	28
2.1 Configuración estándar.	29
2.2 Uso de modelos predictivos para la reconfiguración.	31
3 Metodología de análisis Box – Jenkins para estructuras tipo ARIMA. ..	33
3.1 Expresión general de un modelo ARMA.	37
3.2 Expresión general de un modelo ARIMA.	41
3.3 Propiedades de un modelo ARIMA óptimo.	43
3.4 Proceso de Modelación.	44
4 Análisis y generación de modelos ARIMA para matriz Gran Alimentadora.	79
4.1 Caso: Modelamiento de locación Desagüe Santos Ossa.	84
5 Experiencia de uso del sistema de monitoreo reconfigurado.	116

5.1	Caso: Rotura en arranque, Av. José Tomás Ramos con calle Estanque, Valparaíso.....	117
5.2	Caso: Fugas en arranque provocadas por incendio.	119
5.3	Caso: Fuga en arranque mal sellado.....	120
	Conclusiones.	123
	Referencias.....	127
	Anexos.	130

Lista de tablas

Tabla 1: Velocidades de conexión de red móvil GPRS	16
Tabla 2: Composición por diámetro y material.....	22
Tabla 3: Comportamiento teórico de funciones de autocorrelación simple y parcial.	58
Tabla 4: Test ADF para estado de fuga en locación Desagüe Santos Ossa, sin incluir constante ni tendencia	89
Tabla 5: Test ADF para estado de fuga en locación Desagüe Santos Ossa, incluyendo constante.....	89
Tabla 6: Test ADF para estado de fuga en locación Desagüe Santos Ossa, incluyendo constante y tendencia	90
Tabla 7: Test ADF para $(1-L^7)$ (Estado de fuga) en locación Desagüe Santos Ossa, sin incluir constante ni tendencia.....	92
Tabla 8: Test ADF para $(1-L^7)$ (Estado de fuga) en locación Desagüe Santos Ossa, incluyendo constante.....	92
Tabla 9: Test ADF para $(1-L^7)$ (Estado de fuga) en locación Desagüe Santos Ossa, incluyendo constante y tendencia.....	93
Tabla 10: Parámetros del modelo ARIMA para la serie Y_t = (estado de fuga)	97
Tabla 11: Parámetros del modelo ARIMA para la serie Z_t = $(1-L^7)$ (estado de fuga)	101
Tabla 12: Raíces calculadas del polinomio de medias móviles para serie Y_t = (estado de fuga)	104
Tabla 13: Raíces calculadas del polinomio de medias móviles para serie $Z_t = (1-L^7)$ (estado de fuga).....	107

Tabla 14: Criterios de información para el modelo $Y_t = (\text{Estado de fuga})$	110
Tabla 16: Primer período pronosticado para serie de Desagüe Santos Ossa	113
Tabla 17: Modelos, resultado del análisis	114

Lista de figuras

<i>Figura 1:</i> Cobertura equipos de monitoreo Permalog + ...	10
<i>Figura 2:</i> Equipo Multilog LX GPRS y permalog plus (+).....	12
<i>Figura 3:</i> Captura del panel de control de sistema, alerta de fuga en sensor ubicado en Av. Alemania con Av. Francia.....	13
<i>Figura 4:</i> Serie de datos de locación Desagüe Santos Ossa. En rojo serie de datos de presión, en amarillo intensidad de ruido y en magenta dispersión de ruido.	13
<i>Figura 5:</i> Esquema de Sistema de Comunicación vía GPRS	14
<i>Figura 6:</i> Perforación en locación Av. Alemania con calle Alemania, datalogger N°29.	18
<i>Figura 7:</i> Notificación de alerta de fuga.....	20
<i>Figura 8:</i> Principio de correlación acústica.	21
<i>Figura 9:</i> Esquema de emplazamiento de Matriz Gran Alimentadora.	23
<i>Figura 10:</i> Cordón de soldadura en locación Anticlea	26
<i>Figura 11:</i> Instalación del sistema de monitoreo.....	27
<i>Figura 12:</i> Registro de un sensor PermaNet. Muestreo de 2.000 datos por cada 10 minutos.....	30
<i>Figura 13:</i> Registro de locación Desagüe Santos Ossa, muestra entre 01//09/2014 y 30/09/2014 para las variables de presión, intensidad y dispersión de ruido	31
<i>Figura 14:</i> Ejemplos de correlación	35
<i>Figura 15:</i> Ejemplificación de serie temporal y correlograma (a)	36
<i>Figura 16:</i> Ejemplificación serie temporal y correlograma (b)	36

<i>Figura 17: Ejemplificación serie temporal y correlograma (c)</i>	37
<i>Figura 18: Ejemplificación serie temporal y correlograma (d)</i>	37
<i>Figura 19: Correlograma de autocorrelación y autocorrelación parcial para un modelo AR (1) de forma regular</i>	52
<i>Figura 20: Correlograma de autocorrelación y autocorrelación parcial para un modelo AR (1) alternando valores positivos y negativos</i>	52
<i>Figura 21: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (2,0) con todos sus coeficientes positivos</i>	53
<i>Figura 22: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (2,0) con alternancia en el signo de sus coeficientes</i>	53
<i>Figura 23: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (2,0) con alternancia en sus dos primeros retornos y posterior decaimiento en forma sinusoidal</i>	53
<i>Figura 24: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (2,0) con sus dos primeros retardos negativos y posterior decaimiento en forma sinusoidal</i>	54
<i>Figura 25: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (0,2) con sus dos primeros retardos negativos y posterior decaimiento</i>	54
<i>Figura 26: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (0,2) con sus dos primeros retardos alternando y posterior decaimiento</i>	54

<i>Figura 27: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (0,2) con sus dos primeros retardos positivos y posterior decaimiento de forma sinusoidal</i>	55
<i>Figura 28: Función de autocorrelación (Modelo tipo ARMA (2,1)).....</i>	58
<i>Figura 29: Función de autocorrelación parcial (Modelo tipo ARMA (2,1)).....</i>	58
<i>Figura 30: Diagrama de proceso para la Modelación Autorregresiva y de Medias Móviles (ARIMA).....</i>	78
<i>Figura 31: Serie de intensidad de ruido para locación Desagüe Santos Ossa</i>	86
<i>Figura 32: Serie de dispersión de ruido para locación Desagüe Santos Ossa</i>	86
<i>Figura 33: Serie de estado de fuga para locación Desagüe Santos Ossa.....</i>	87
<i>Figura 34: Función de autocorrelación para los primeros 30 retardos de serie estado de fuga en locación Desagüe Santos Ossa</i>	88
<i>Figura 35: Secuencia (1-L7) (Estado de fuga)</i>	91
<i>Figura 36: Función de autocorrelación (1-L7) (Estado de fuga).....</i>	92
<i>Figura 37: Función de autocorrelación para los primeros 30 retardos de serie estado de fuga en locación Desagüe Santos Ossa</i>	95
<i>Figura 38: Función de autocorrelación parcial para los primeros 30 retardos de serie estado de fuga en locación Desagüe Santos Ossa</i>	95
<i>Figura 39: Estadísticos principales de serie $Y_t =$ (estado de fuga).....</i>	96
<i>Figura 40: Función de autocorrelación para los primeros 30 retardos de serie (1-L⁷) (estado de fuga) en locación Desagüe Santos Ossa</i>	99

<i>Figura 41:</i> Función de autocorrelación parcial para los primeros 30 retardos de serie $(1-L^7)$ (estado de fuga) en locación Desagüe Santos Ossa.....	99
<i>Figura 42:</i> Estadísticos principales de serie $Z_t = (1-L^7)$ (estado de fuga)	100
<i>Figura 43:</i> Raíces del polinomio de medias móviles para serie $Y_t =$ (estado de fuga)	104
<i>Figura 44:</i> Secuencia de los residuos para $Y_t =$ (estado de fuga).....	105
<i>Figura 45:</i> Correlograma de FAS de los residuos para $Y_t =$ (estado de fuga), primeros 24 retardos.....	105
<i>Figura 46:</i> Raíces del polinomio de medias móviles para serie $Z_t = (1-L^7)$ (estado de fuga)	107
<i>Figura 47:</i> Secuencia de los residuos para $Z_t = (1-L^7)$ (estado de fuga)	108
<i>Figura 48:</i> Correlograma de FAS de los residuos para $Z_t = (1-L^7)$ (estado de fuga), primeros 24 retardos.....	108
<i>Figura 49:</i> Pronóstico para la serie correspondiente a locación Desagüe Santos Ossa	112
<i>Figura 50:</i> Umbral al 95% de confianza para la serie Desagüe Santos Ossa	113
<i>Figura 51:</i> Locación N° 36 Tomás Ramos con Miranda.....	117
<i>Figura 52:</i> Registros de presión, intensidad de ruido y dispersión de ruido para locación N°36, año 2014.	117
<i>Figura 53:</i> Registros de presión, intensidad de ruido y dispersión de ruido para locación N°36, después de reparación, año 2014.	118
<i>Figura 54:</i> Locación N° 11 Padre Febres	119

<i>Figura 55:</i> Registros de intensidad de ruido y dispersión de ruido para locación N°11, año 2014.....	119
<i>Figura 56:</i> Trabajos de reparación de fugas producto del incendio	120
<i>Figura 57:</i> Locación N° 61 Santa Teresa	121
<i>Figura 58:</i> Registros de intensidad de ruido y dispersión de ruido para locación N°16, año 2016.....	121
<i>Figura 59:</i> Fuga de arranque mal sellado.	122

Introducción.

La distribución de agua potable del país ha alcanzado una cobertura de un 100% a partir del año 2007 (SISS, 2016). Desde esa perspectiva, al superar este desafío histórico del sector sanitario, una de las nuevas demandas críticas apunta a optimizar el recurso hídrico, a través de sistemas que permitan monitorear eficientemente la red y, asimismo, efectuar el mantenimiento requerido por el deterioro, con el fin de evitar fugas que originan pérdidas significativas para el proceso de distribución de agua potable.

Actualmente los niveles de ineficiencia de las sanitarias se cuantifican mediante el índice Agua No Facturada (ANF), que es la relación porcentual entre el volumen de agua no facturada respecto al total producido. El escenario actual no es el mejor, ya que en promedio las empresas sanitarias chilenas presentan un ANF cercano al 35% (SISS, 2015), bastante lejano al establecido en el concepto de “empresa modelo”, definido en la Ley de Tarifas según D.F.L. N°70 de 1988 (SISS, 2016), donde la tolerancia de ineficiencia exigida es de un 15% para captaciones subterráneas, y de un 20% para las de tipo superficial (Ministerio de planificación y cooperación, 1997).

En lo específico, la ineficiencia del proceso se asocia a dos ámbitos: volúmenes de pérdida de tipo aparente y de tipo técnica. La primera se relaciona con los volúmenes no contabilizados, por efectos de hurto e ineficiencias en los medidores de agua de los clientes, mientras que la segunda se refiere a fugas en la red de distribución. Al respecto, como lo indica el Informe de Gestión del Sector Sanitario del año 2014 (SISS,

2014), se estima que a nivel nacional las pérdidas de índole aparente alcanzan un 24%, mientras que las de tipo técnica representan el 74% restante. Estas últimas se componen principalmente por fugas de tipo visible y no visible, razón por la cual esta problemática se ha posicionado como una oportunidad de desarrollo, orientada al monitoreo permanente y reparación oportuna de la red de distribución.

Dentro de los mecanismos utilizados en la optimización del recurso, la detección de fugas por medios acústicos, gracias a su efectividad e implementación masiva en las redes de distribución, ha tenido una evolución sostenida en los últimos diez años. Por medio de sensores que registran el ruido que se propaga a través del cuerpo de la tubería, es posible identificar la presencia de filtraciones que, de no ser detectadas oportunamente, generarían roturas y cortes de suministro a la población. En sus inicios, un grupo de especialistas debía dirigirse a cada uno de los sensores desplegados en la red de distribución para recoger sus datos. Una vez analizados, recién podía ubicarse la presencia de una fuga, para luego continuar con la reparación de la infraestructura dañada. Sin embargo, el desarrollo tecnológico ha permitido que, en la actualidad, los registros sean transmitidos de manera automática a un concentrador de datos, visualizándolos por medio de un servidor web, que se traduce en una optimización en los tiempos de respuesta.

La experiencia mundial indica que una metodología de monitoreo permanente genera diversos beneficios operacionales. Frank Tantzky, ejecutivo de AlbstadtWerke, Alemania, señala que por medio de sensores acústicos ha sido posible reducir en un 98% los esfuerzos y costos de localización, llegando a tiempos de reparación del orden

de 1,5 días (Gutermann, 2016). Por su parte, Malcolm Hill, ingeniero de South East Water, Australia, propone que la inclusión de esta metodología, ha permitido identificar fugas antes de que afloren a la superficie, proporcionando una red de agua más inteligente (Gutermann, 2016).

La sanitaria Esval S.A. (en adelante Esval), que actualmente tiene la concesión de distribución y recolección de agua en la Región de Valparaíso –con excepción de Panquehue, Olmué, Juan Fernández, Santo Domingo e Isla de Pascua–, desde el año 2002 ha incorporado dentro de sus procedimientos de control de pérdidas, la utilización de sensores acústicos para optimizar las inversiones destinadas a la renovación de redes de agua potable. Sin embargo, previo a la emergencia vivida en Valparaíso el 14 de julio de 2013, detonada por la rotura de la matriz Gran Alimentadora, no se había planteado la necesidad de generar un sistema de monitoreo permanente. Dicha rotura se originó en el sector de la escala Llanos del cerro Ramaditas, y provocó un caudal de hasta 1.300 [l/s], generando un socavón que arrastró cerca de 150 toneladas de escombros y barro por las calles Federico Costa y Santa Elena, ocasionando daños a viviendas, automóviles e infraestructura vial dejando, además, cerca de 15.000 clientes con el suministro de agua potable interrumpido.

Ante la emergencia, Esval decidió renovar el tramo más vulnerable de la red, surgiendo también la necesidad de generar un sistema de monitoreo, que permita identificar tempranamente filtraciones que pudiesen transformarse en una rotura de mayor envergadura.

El presente trabajo aborda este complejo escenario, donde se propone no sólo el desarrollo, sino también la implementación, de un sistema de monitoreo permanente de fugas basado en métodos acústicos, para la matriz Gran Alimentadora de la ciudad de Valparaíso. Por medio del sensor Permalog +, que registra el ruido, y el *datalogger* Multilog, que permite transferir datos vía telemetría GPRS, es posible obtener de forma diaria los datos asociados a la intensidad y dispersión de ruido, ambos medidos en decibelios. Con ambos indicadores, se compone una tercera variable denominada “estado de fuga”, que corresponde a la resta del primero con el segundo. Así, cuando el resultado de esta diferencia sobrepase un valor umbral de 15 decibelios, definido por el fabricante, el sensor pierde su condición de normalidad generando una alerta de fuga.

No obstante, lo que transforma a este proyecto en una innovación a nivel nacional, y un aporte a la ingeniería, es la utilización de modelos estadísticos contemporáneos que permitan identificar correctamente los umbrales de ruido existentes en cada locación, ya que la calibración estándar (de fábrica) puede entregar falsos positivos, al verse influenciada por diversos factores ambientales no contemplados. Por tanto, el objetivo general de este proyecto es la conceptualización e implementación de un sistema de monitoreo permanente que permita identificar eficazmente la existencia de una fuga, mediante el control de los niveles de ruido que experimente La Gran Alimentadora.

Entonces, basándose en las mejores prácticas utilizadas en la actualidad para el monitoreo de fugas existentes en las redes de distribución de agua potable, esta investigación presenta el desarrollo metodológico y la implementación del sistema de

monitoreo permanente de fugas asociado a la matriz Gran Alimentadora, con el que será posible identificar de maneja temprana, y reparar de forma oportuna, las fallas en la infraestructura de este elemento hidráulico, fundamental en el proceso de distribución de agua potable en Valparaíso.

Objetivos.

Para el desarrollo e implementación del proyecto, se contemplan cuatro objetivos específicos. En primer lugar, se deberá conocer en terreno el emplazamiento de la tubería, que comienza a los pies del estanque Lyon, en Rodelillo, y finaliza en Avenida Pacífico, Playa Ancha, con una extensión total de 10.200 [m]. Como segundo objetivo, se evaluará la factibilidad de instalar sensores acústicos que, gracias a una conexión magnética, se adosan al cuerpo de la matriz.

En tercer lugar, como el sistema propuesto transmite los datos a través de internet, se deberá tener en cuenta la conectividad para cada locación, sujeta a la disponibilidad del proveedor del servicio de telecomunicaciones en el sector, y las condiciones de hermeticidad de las cámaras.

Y, por último, a través de modelos paramétricos tipo ARIMA (Arce & Mahia, 2001), utilizados generalmente en la modelación de fenómenos macroeconómicos, se analizará la información histórica producida para cada sensor. Esta modelación permitirá extraer la estructura intrínseca de la serie de datos para generar un proceso matemático que signifique su innovación en el presente y futuro, con un alto grado de fiabilidad.

De esta manera, es posible un ajuste probabilístico de un 95%, para evaluar la existencia de una fuga en la red de distribución, lo que representa una evolución en la metodología de sistemas de monitoreo permanente, traducido en tiempos de respuesta más breves, y un alto grado de eficacia, puesto que, como veremos, no se producirán falsos positivos.

1 Descripción problemática existente y propuesta de solución preliminar.

Según la SISS, las fugas de agua potable representan alrededor del 74% del agua no facturada (ANF). Si bien el desarrollo metodológico, para resolver este importante problema, contempla soluciones que van desde sensores acústicos hasta la utilización de gas helio, no todas permiten resolver la necesidad de monitorear permanentemente la red de distribución. Por ejemplo, la utilización de gas helio, como trazador para la detección, es un método de mantenimiento correctivo, que se utiliza para acotar el área de afloramiento, pero no es factible implementarlo de manera permanente y continua, ya que depende del cierre (acuartelamiento) de un determinado sector de la red de distribución. Por otro lado, son de uso común metodologías basadas en balance oferta-demanda, que utilizan instrumentos de medición de caudal; sin embargo, las fugas que pudiesen desencadenar una rotura son prácticamente imperceptibles para los sensores de flujo. Dado lo anterior, la tecnología que cumple con las condiciones de permanencia, continuidad y precisión para la detección de filtraciones, se basa fundamentalmente en métodos acústicos.

De manera paulatina, y en base a la experiencia, la industria sanitaria ha entendido que, en la medida que los procesos de detección de fugas sean permanentes en el tiempo, existe una oportunidad real de mantener y controlar los niveles de pérdida. En la actualidad las empresas sanitarias nacionales utilizan métodos acústicos para precisar zonas con altos niveles de pérdida, para luego renovar parcial o totalmente la red de distribución; no obstante, esta metodología no asegura, en lo absoluto, una proyección del control de los niveles de fuga en el tiempo. De hecho, esta condición de

uso sintetiza la relevancia de implementar sistemas de monitoreo permanente para la correcta identificación de sectores, o tramos de la red, que presenten fugas de agua.

En conocimiento del aporte real de los sistemas de detección por medios acústicos, ha de tenerse en cuenta el objetivo específico de prevenir un evento de rotura, en una de las conducciones críticas del sistema de distribución de agua potable de Valparaíso, matriz conocida como Gran Alimentadora. La historia de esta tubería ha estado cargada de acontecimientos, que no pudieron ser anticipados por las maniobras habituales de mantenimiento preventivo de Esval. Por la operatividad crítica de este elemento hidráulico, los infortunados eventos están en la memoria de la comunidad, por lo que la implementación de un sistema que permita acotar los tiempos de reacción ante una eventual rotura, han decantado en la implementación de un sistema de monitoreo permanente para la detección de fugas no visibles.

En esta memoria se expone una solución para el mantenimiento preventivo de la matriz, monitoreándola completa y permanentemente a través de sensores acústicos, capaces de transmitir sus registros periódicamente por medio de telemetría GPRS.¹ Para ello, se instrumentarán las cámaras que permiten tener un acceso directo al cuerpo

1 El servicio general de paquetes vía radio, en inglés: General Packet Radio Service (GPRS), fue creado en el año 1980. Es una extensión del "Sistema Global para comunicaciones Móviles" (Global System for Mobile Communications o GSM) para la transmisión de datos mediante conmutación de paquetes.

de la tubería, para adosar la sección imantada de los sensores a las válvulas de corte, ventosas, desagües y ramales de distribución.

La secuencia de instalación de los equipos se realizará por etapas, priorizando los tramos con mayor probabilidad de rotura, según registro histórico de intervenciones sobre la matriz, calidad de la infraestructura (espesor) y contingencia según últimos episodios de fallas. Con base en esta priorización se detectan tres tramos de interés. El primero comienza a la salida del estanque Lyon (km 0,0) y termina en la cámara de desagüe ubicada en calle Anticlea (km 2,65). El segundo, entre el kilometraje 2,875 y 5,370 cuya renovación fue realizada el año 2005. Finalmente, el tercer tramo que comprende la cámara de ventosa ubicada en Av. Alemania con Ferrari (km 5,49) y Av. Pacífico con Aguayo (km 10,15)

Gracias a la materialidad de la tubería, compuesta de acero, será posible ocupar el sensor a su máxima capacidad, estandarizada en 200 [m] lineales, tanto aguas arriba como aguas abajo desde su fijación al cuerpo de la Matriz Gran Alimentadora. En la figura 1 se presenta esquemáticamente la disposición y cobertura de los 40 equipos sobre la conducción de agua potable.

Es importante mencionar, que los sensores acústicos registran el ruido que experimenta la tubería en 200 [m] lineales desde su punto de fijación; por tanto, si algún ramal de distribución, que dependa directa o indirectamente de la matriz principal, se encuentra dentro del campo de cobertura, también será monitoreado por esta solución.




Figura 1: Cobertura equipos de monitoreo Permalog +
Fuente: Conducción Gran Alimentadora de Valparaíso, Análisis de Vulnerabilidad. Empresa IFARLE.

1.1 Sensores (hardware).

El sensor acústico utilizado para implementar el sistema de monitoreo es Permalog +, equipo diseñado por Halma Water Management (UK). Las primeras versiones de este dispositivo datan de 1999, convirtiéndose en el primer registrador de ruido patrullado por radio y adoptado ampliamente por las empresas sanitarias del Reino Unido. En las versiones posteriores se mejoró la robustez y alcance de su radio frecuencia, motivado por un despliegue masivo de sensores, para monitorear sectores amplios con niveles altos de pérdida de agua potable. Finalmente, en el año 2007 se realiza la última actualización del equipo que adoptó nuevos formatos de comunicación (SMS y GPRS), memoria interna, y la posibilidad de realizar histogramas de frecuencia, para mejorar la interpretación de la información.

La alta competitividad y versatilidad de esta tecnología ha permitido su uso en importantes empresas sanitarias (Mejoras Energéticas, 2016). Por ejemplo:

- Beijing Water Group, China: Los sensores permalog + se utilizaron para monitorizar el centro de Beijing, las principales sedes de los Juegos Olímpicos y las regiones de Tiananmen, Zhongnanhai y Wangfujing. La implementación costó de 3.500 sensores desplegados durante el año 2007.
- Distrito de Aguas del Valle de las Vegas, Estados Unidos: Desde el año 2004 se han instalado cerca de 8.000 equipos. Se estima que desde la implementación de esta tecnología de monitoreo se han recuperado 1.000 [Mm³].
- Scottish Water, Escocia: Desde la implementación de sensores, la sanitaria declara que actualmente se recuperan 2 [Mm³/día]. De hecho, en el año 2009, período donde aumentaron las inversiones para el control de pérdidas, ya recuperaban 1,8 [Mm³/día].

El sistema de monitoreo presentado en este trabajo utiliza la última versión de los sensores Permalog, denominado Permalog +, ya que permite disponer de la información prácticamente en tiempo real. El pre – localizador Permalog+ se conecta por un cable al datalogger Multilog LX, que posee una tarjeta de datos móviles (simcard) para enviar datos al servidor tres veces al día, en horarios definidos por el usuario. El proveedor recomienda esta modalidad para mantener la vida útil de las baterías, que podría alcanzar cinco años.

En la figura 2 se muestra el dispositivo. A la izquierda y en color amarillo el equipo permalog+, a la derecha y en color azul, *datalogger* Multilog LX.



*Figura 2: Equipo Multilog LX GPRS y permalog plus (+).
Fuente: Empresa DNK Water SpA.*

1.2 Servidor web (software).

Para la gestión de la información se utiliza una plataforma web, que permite visualizar la ubicación geográfica de los sensores, así como su estado representado en colores. El azul indica una situación de normalidad y el rojo una condición de fuga, mientras que el amarillo da cuenta de una falla en la transmisión del paquete de datos. A su vez, es posible encontrar detalles de cada sensor al posicionarse sobre su ubicación en el mapa (Google Maps). En la figura 3 se presenta el panel de control utilizado en el sistema de monitoreo implementado en Valparaíso.

Además, es posible visualizar los registros históricos de cada uno de los sensores. La figura 4 muestra la serie de datos del sensor ubicado en el desagüe Santos Ossa,

recogidos entre el 25 de octubre y 22 de noviembre de 2015. En este caso existe registro de presión, intensidad de ruido y dispersión de ruido.




Figura 3: Captura del panel de control de sistema, alerta de fuga en sensor ubicado en Av. Alemania con Av. Francia
Fuente: Servidor Empresa Halma Water Management




Figura 4: Serie de datos de locación Desagüe Santos Ossa. En rojo serie de datos de presión, en amarillo intensidad de ruido y en magenta dispersión de ruido.
Fuente: Servidor Empresa Halma Water Management

Por último, si fuese necesario, el servidor web permite comunicarse remotamente con el sensor para cambiar parámetros de su configuración inicial, inclusive el umbral que cambia el estado del sensor para indicar la existencia o no de fuga.

1.3 Sistema de comunicación.

La plataforma de comunicación se denomina GPRS (Servicio General de Paquetes vía Radio) y permite enviar y recibir paquetes de datos a través de la red de telefonía móvil. GPRS corresponde a una mejora sustancial respecto a su antecesor – la comunicación a través de GSM o 2G, que estaba orientado específicamente a la transmisión de voz–, puesto que, se orientó a suplir las falencias del envío de datos. El traspaso de información se produce a través de una comunicación Full-Dúplex (bilateral y simultánea), que permite que, mediante una tarjeta con datos móviles (*simcard*), sea posible interactuar con Internet. La figura 5 muestra la interacción entre las etapas del sistema de comunicación.



Figura 5: Esquema de Sistema de Comunicación vía GPRS
Fuente: Elaboración propia

Las principales características del sistema de comunicación se detallan a continuación:

1.3.1 *Plataforma GPRS.*

La transmisión a través de redes móviles es limitada en cuanto al envío de datos, ya que las velocidades de transmisión de archivos son muy bajas, por ello los paquetes de datos de gran tamaño simplemente no es posible transmitirlos. Por necesidad surgen sucesores como E-GPRS (EDGE, 2.75G), 3G, 4G (Lo más reciente en comunicaciones de redes móviles)

En el caso específico de *dataloggers*, los paquetes de datos son tan pequeños que considerando tres envíos diarios, se genera un consumo de datos de 11 [kB] mensuales, lo que representa alrededor de 90 envíos al mes, con un tamaño de 122,2 Bytes cada uno.²

Desde el punto de vista del consumo de energía, una conexión por GPRS es económica, ya que la información no se transmite de manera continua, sino de forma programada por el usuario. En resumen, por las características de velocidad, tiempo requerido para la transmisión, consumo de datos y eficiencia energética, la transmisión de información vía paquetes de datos es óptima para este tipo de aplicaciones.

² Si se considera que la transmisión vía GPRS tiene una tasa de transmisión que fluctúa entre 7 a 14.25 [kB/s], transmitir un paquete de 122,2 Bytes tardará máximo 17 [ms]

1.3.2 Cobertura.

La cobertura está condicionada al nivel de servicio de la empresa proveedora de redes móviles. Estando dentro del radio de envío y recepción, la velocidad de comunicación estará dada por los modos de comunicación, ordenados de menor a mayor, en la tabla 1.

Los niveles de servicio de los proveedores están relacionados directamente con la demanda particular de las personas, es decir, la infraestructura se adecúa según la expansión demográfica y no, necesariamente, al requerimiento industrial. Este motivo, sumado a la compleja topografía de la ciudad, con fuerte presencia de quebradas y cerros, genera vulnerabilidad en la estabilidad de la transferencia de información.

Tabla 1: Velocidades de conexión de red móvil GPRS

Simbología	Método	Generación
G	GPRS	2,5 G
E	E-GPRS o EDGE	2,75 G
3G	UTMS	3 G
H	HSDPA	3,5 G
H+	HDUPA	3,75 G
4G	4G LTE	4 G

Fuente: Comunicación de dataloggers a través de GPRS, Empresa DNK Water SpA.

1.3.3 Conectividad.

La intensidad de señal (CSQ) es un valor adimensional (medido en una escala de 0 a 30) que permite representar el nivel de señal existente en un lugar determinado. La experiencia ha permitido definir que debe ser mayor o igual a diez para mantener las condiciones de trabajo permanentes del equipo. De este modo se puede garantizar la transmisión de datos a través de GPRS con un consumo de batería adecuado.

Si el parámetro CSQ es menor a diez, es posible que el equipo no sea capaz de conectarse a la red móvil para enviar los datos. Pese a que en algunas ocasiones el equipo logre transmitir, no será un comportamiento constante, lo que provoca intermitencias en la transmisión y un consumo de energía mayor al normal.

Cuando falla un envío de datos, el equipo lo intenta nuevamente, y si vuelve a fallar, intenta una tercera y última vez. En este escenario el proceso de comunicaciones del equipo estará funcionando a su máxima potencia para lograr enlazarse a la red móvil. Considerando que se programa un equipo para enviar tres paquetes de datos al día, al existir problemas de intensidad de señal estos envíos representarán nueve intentos de conexión fallidos, lo que incidirá directamente en la vida útil de la batería.

Los problemas de intensidad de señal se generan, principalmente, por las desfavorables condiciones físicas de instalación del *datalogger*, así como la baja cobertura de la empresa proveedora del servicio de comunicación. Estos equipos generalmente se emplazan en cámaras que están construidas de hormigón armado y no tienen exposición al medio ambiente. Este confinamiento provoca un fenómeno de absorción y rebote de la señal que se traduce en una pérdida de intensidad considerable. El material de las cámaras provoca el fenómeno conocido como “Jaula de Faraday”, generando, en algunos casos, un aislamiento que no permite el ingreso de ningún tipo de señal. En algunos casos se ha logrado establecer que el porcentaje de pérdida es superior al 50%, respecto a la intensidad de señal justamente fuera de la cámara. Por otro lado, existen casos en que la cobertura que proporciona el proveedor de la red celular es insuficiente, inclusive fuera de la cámara.

Por esta razón es común que exista un índice de reflexión de la señal percibida de $CSQ < 10$, lo que produce problemas en la transmisión. En estos casos, es necesario instalar una antena en el exterior de la cámara o, por defecto, ubicarla lo más cercana posible a la superficie.

De todos modos, en el escenario de una baja cobertura, traducido en baja intensidad de señal (CSQ), las opciones de corrección corresponden a, en primer lugar, revisar la empresa proveedora del servicio de comunicación y, luego, modificar las condiciones de instalación.

En cuanto a la comunicación, el nivel de servicio de las compañías de telecomunicaciones depende de la disposición de su infraestructura, por ello cada una de las locaciones instrumentadas tendrá disponible distintos niveles de transmisión, según su cercanía a las antenas repetidoras. Ante ello, al momento del montaje, el equipo realiza una verificación del mejor proveedor disponible, y luego se parametriza la configuración con las propiedades de éste.



*Figura 6: Perforación en locación Av. Alemania con calle Alemania, datalogger N°29.
Fuente: Elaboración propia*

Por otro lado, desde la experiencia, se han realizado modificaciones en las instalaciones que permitan mejorar la conectividad. La figura 6, por ejemplo, muestra la perforación realizada con una testiguera en losa de cámara ubicada en Avenida Alemania con calle Alemania, de 80 [mm] de diámetro.

1.4 Gestión de alertas.

Anteriormente se destacó el sentido preventivo del sistema de monitoreo, objetivo originado en la magnitud de una rotura en grandes conducciones de distribución de agua potable. Pues bien, para alcanzar este nivel de desarrollo es necesario, y fundamental, complementar esta herramienta con el soporte del equipo de mantenimiento de redes, en el caso particular de Esval, a cargo del Departamento de Redes de Valparaíso.

El sistema de monitoreo permite identificar todas aquellas locaciones que experimenten un nivel de ruido sobre 15 [dB], alertando esta condición con un color rojo sobre el panel de control y emitiendo un correo (ver figura 7) hacia los usuarios registrados en la plataforma. Cuando el personal de mantenimiento se encuentra sobre aviso, se dirige al punto de conflicto para realizar una inspección visual, en primera instancia, para luego realizar la maniobra denominada “correlación acústica”, que consiste en inspeccionar detalladamente el sector, por medio de un equipo más preciso, que permite identificar filtraciones en un radio de aproximadamente 100 [m].




Figura 7: Notificación de alerta de fuga
 Fuente: Esval S.A.

El correlador acústico³ permite medir la velocidad de propagación del sonido entre dos transductores que se montan en contacto con el cuerpo de la tubería. Si la fuga se encuentra en medio de ambos, se puede calcular la distancia desde la filtración a cada uno de los equipos. La figura 8 muestra un esquema para la ubicación de los transmisores.

En otras palabras, el correlador acústico precisa la ubicación de una filtración calculando indirectamente la distancia desde el emisor hasta ella, a través de la velocidad de propagación del sonido. A su vez, la velocidad en que se propaga el sonido, está directamente relacionado al material de la tubería.

³ Correlador acústico: equipo electro-acústico que permite localizar la ubicación de una fuga mediante la propagación de la velocidad del sonido sobre el cuerpo de la tubería. Dicha velocidad de propagación dependerá de la materialidad de la tubería principalmente.




Figura 8: Principio de correlación acústica.

Fuente: “Encontrar y detener fugas”, <http://www.wikiwater.fr/e14-finding-and-stopping-leaks.html>

1.5 Implementación en matriz Gran Alimentadora de Valparaíso.

La matriz denominada “Gran Alimentadora” es un elemento de la infraestructura de redes de la empresa sanitaria Esval, diseñada por los ingenieros Isaac Faiguenbaum y Rubén León⁴, y construida en el año 1965. Su emplazamiento inicia en el estanque

⁴ Isaac Faiguenbaum y Rubén León: Ingenieros y socios fundadores de empresa IFARLE Ingenieros Civiles Consultores Ltda., cuyo inicio de actividades en el campo de la Ingeniería Sanitaria se remonta a junio del año 1956. Dentro de sus principales aportes destaca la conducción gravitacional Acueducto Las Vegas, proyectada entre los años 1957 a 1958.

Lyon, ubicado en Cerro Rodelillo, y finaliza en Playa Ancha, a la altura de la intersección de la Av. Pacífico con Aguayo, completando una extensión de 10.375 [m]. Gran parte de su trazado atraviesa avenidas de alta importancia, en cuanto al flujo vehicular y la conectividad de la ciudad, como las avenidas Santos Ossa, Washington, Alemania y Pacífico.

Su cota de inicio es de 171 [msnm] y 135 [msnm] en su punto cúlmine. El diámetro característico de la matriz es del orden de los 700 [mm], aunque se han encontrado tramos de mayor diámetro a lo largo de su extensión. En este sentido, según los antecedentes recabados, la configuración definitiva de la tubería es la siguiente: la cañería inicia su recorrido en el Estanque Lyon en el cerro Rodelillo, en material de acero, con espesor de 6 [mm] y un diámetro de 750 [mm]. Esta condición se mantiene hasta el kilómetro 4,7 para luego cambiar su dimensión a 700 [mm] de diámetro, con espesores entre los 7 [mm] y 8 [mm]. A continuación, la tabla 2 muestra el detalle:

Tabla 2: Composición por diámetro y material

D Nominal [mm]	D. Exterior [mm]	D. Interior [mm]	Espesor [mm]	Longitud [m]	% del total
750	762.2.	749.3	6.35	3100	29.88%
700	711.2.	698.5	6.35	7274.6	70.12%

Fuente: Conducción Gran Alimentadora de Valparaíso, Análisis de Vulnerabilidad. Empresa IFARLE.

Para el proceso de distribución de agua potable, es abastecida por medio del estanque Lyon, que a su vez es llenado desde el Acueducto Las Vegas,⁵ principal línea

⁵Acueducto Las Vegas: este acueducto nace en el sector de Rabuco, transportando el agua producida por la Planta de Pachacama, cuyas fuentes son superficiales y subterráneas. El acueducto

de conducción de Agua Potable de la región. En la actualidad el sistema abastece a 15.413 clientes ubicados en los cerros Rodelillo, Las Delicias, Ramaditas, La Virgen, Las Cañas, La Cruz, Florida, San Juan de Dios, Jiménez, Cárcel, Alegre, Cordillera, Locera, Las Perdices y Playa Ancha. En la figura 9 se muestra un esquema general de la matriz, permitiendo visualizar su trayectoria desde Cerro Rodelillo hasta Playa Ancha. A lo largo de toda su extensión cuenta con diversas obras complementarias, que permiten su correcta operación, como ramales de distribución, desagües, ventosas, válvulas de corte y grifos. Por otro lado, el estanque Lyon se encuentra instrumentado para cuantificar el flujo de entrada desde el Acueducto las Vegas, el nivel y el flujo de salida, cuyo máximo horario es de unos 350 [l/s].




Figura 9: Esquema de emplazamiento de Matriz Gran Alimentadora.
Fuente: Conducción Gran Alimentadora de Valparaíso, Análisis de Vulnerabilidad. Empresa IFARLE.

posee un diámetro de 1.315 [mm], con un caudal medio del orden de los 2.500 [l/s]. A lo largo de su extensión distribuye a las localidades de Limache, La Calera, Quilpué, Villa Alemana, Viña del Mar y Valparaíso. Su emplazamiento finaliza con la aducción al estanque Lyon de Valparaíso.

Dentro de los antecedentes recabados en este trabajo, el Departamento de Redes de Valparaíso de Esval señala que, desde 2001 a fines de 2012, se han registrado 61 incidentes, de los cuales 21 provocaron interrupción en la distribución de agua potable. Debido a la complejidad de un corte parcial o total del suministro a su clientela, se han generado diversos estudios que permitan evaluar su estado operacional, en pos de minimizar los efectos sobre terceros.

Al respecto, se ha podido catastrar el estado físico del material, con la respectiva propuesta de recuperación para los tramos mayormente afectados por la corrosión. Los primeros estudios de la calidad del material se realizaron en el año 1986 por la empresa ICI Ingenieros. En el año 2005 la consultora INVAR complementó las investigaciones, permitiendo detallar las demandas a lo largo de su extensión, medir espesores, analizar el estado de soldaduras y correlacionar los incidentes de roturas con las condiciones operativas de la conducción, logrando identificar zonas riesgosas.

En conocimiento de la fragilidad de ciertos tramos, durante los años 2009 y 2010, la empresa IFARLE realizó el análisis, e ingeniería de detalle para reemplazar el tramo comprendido entre los P.k. 2,85 y P.k. 5,528, totalizando 2.678 [m] (actualmente esta obra se encuentra operativa).

Los estudios citados indican que las principales causales de fallas son atribuibles al estado de los espesores y la calidad de soldaduras en puntos de conexión, esto último por las técnicas constructivas de la época. Para la primera condición se constata que el espesor se redujo desde 8 [mm] a 7 [mm], con una velocidad de corrección entre 0,014 a 0,028 [mm/año], y un promedio de 0,020 [mm/año]. Para el estado de los cordones

de soldadura, tanto transversal como longitudinal, su calidad es aceptable según los criterios de AWS D1.1 (Structural Welding Code-Steel); sin embargo, los métodos constructivos del año 1965 contemplaban realizar la unión de tramos “tope a tope” con ayuda de una “ventana”, que permitía al soldador aplicar el cordón de soldadura por el interior de la cañería, para luego cerrar la cavidad con el mismo trozo de tubería retirado en primera instancia. Por tanto esta “ventana” solamente quedaba soldada por una cara, comprometiendo la calidad de los trabajos según la pericia del ejecutor. En la figura 10 se muestra la filtración en un traslape transversal (tope a tope), ubicado a la altura de subida Anticlea y registrada el 01 de diciembre de 2005.

Este tipo de conexiones constituyen los puntos más débiles de la matriz y, efectivamente, es donde se han catastrado la gran mayoría de las fallas. El registro de incidentes indica que las roturas catastradas en el segundo tramo (65,1% del total de roturas), fueron producto de una mala ejecución e inspección de las soldaduras de ventanas. Por ejemplo, en agosto del año 2009 se registró una filtración por este motivo, donde se concluyó que la penetración de la soldadura no fue profunda, sin provocarse contacto íntimo con el borde interno de bisel de la placa. Además, se observaron diferentes aportes de material para un mismo cordón de soldadura.



Figura 10: Cordón de soldadura en locación Anticlea

Fuente: Conducción Gran Alimentadora de Valparaíso, Análisis de Vulnerabilidad. Empresa IFARLE.

Lo expuesto detalla la importancia de intervenir esta matriz con el sistema descrito en las páginas anteriores, cuyo montaje se realiza en cámaras de elementos hidráulicos como ventosas, válvulas de corte, desagües y derivaciones de distribución. Para ello, cada una de estas cámaras es perforada para posicionar una antena omnidireccional, luego sobre la pared de la cámara se monta el datalogger GPRS, para finalmente dejar en contacto de la tubería el sensor imantado.

En la figura 11 se muestra el proceso de instrumentación para locación ubicada en Avenida Pacífico, entre las calles Quebrada Verde y Piscis, del sector de Playa Ancha.



Figura 11: Instalación del sistema de monitoreo.
Fuente: Elaboración propia

2 Propuesta de solución definitiva.

Anteriormente se ha explicado detalladamente los componentes del sistema de monitoreo, así como su capacidad de mantener continuamente informado al equipo de mantenimiento de redes de agua potable, para mitigar filtraciones que pudiesen volverse críticas. Precisamente este aspecto otorga la virtud de prevención que propuso desarrollar Esval, generando la oportunidad de mejorar la calidad de servicio, minimizando daños sobre la infraestructura y sus propios clientes.

Sin embargo, el sistema de monitoreo con su configuración de fábrica no entrega un registro fidedigno por sí solo, que permita prevenir filtraciones y roturas con precisión. Por ello, en este capítulo se explicará claramente la diferencia entre el uso de una herramienta configurada por el proveedor, comparada con una adaptación adecuada a las particularidades de una tubería en operación, que continuamente distribuye el agua tratada a cerca de 15.000 clientes.

Si bien esta metodología de detección de fugas se usa habitualmente para discriminar sectores de la red de distribución con altos niveles de pérdida, en este apartado se detalla cómo ha sido posible migrar a una solución permanente de monitoreo, basándose en modelos estadísticos de predicción que inteligentemente permiten reproducir los patrones subyacentes en la estructura de los registros, estimando una situación futura contrastable con el comportamiento presente de los datos.

2.1 Configuración estándar.

Al momento de implementar el sistema de monitoreo, la sanitaria Esval debió realizar un detallado plan de inspección y comprobación acerca de la existencia de fugas, que en ese momento fueron detectadas por el *datalogger*. Ocho alertas fueron emitidas, informando que las locaciones de desagües Santos Ossa, Federico Costa, Av. Alemania con Santa Teresa, Av. Alemania con El Litre, Av. Alemania con Av. Francia, Av. Alemania con Yervas Buenas, Av. Alemania con Caupolicán, Av. Alemania con Plaza San Luis se encontraban en “estado de fuga”. Para determinar la existencia de filtraciones, un equipo especializado debió generar correlaciones acústicas en los sectores informados por los sensores, siendo todas las alertas descartadas una vez finalizada las maniobras. Este hecho, ocurrido a fines del año 2013 y principios del 2014, grafica claramente que el sistema debería adaptarse a las condiciones reales de operación de la tubería Gran Alimentadora.

La configuración por defecto que proporciona el sistema de monitoreo permanente para la detección de fugas, PermaNet (Halma Water Management, 2016), establece un criterio que relaciona la repetitividad de una frecuencia en comparación a la dispersión del registro, que se compone de 20.000 datos catastrados entre las 02:00 y 04:00 a.m., precisamente donde la tubería de acero experimenta la mayor carga hidráulica, correspondiendo, pues, a una condición ideal para aparición de fugas.

Los 20.000 registros (capturados en franjas de 2.000 datos por cada diez minutos) son traducidos por el algoritmo diseñado en el Reino Unido en dos variables. La primera, denominada intensidad de ruido, equivale a la moda estadística y, la segunda,

como una representación de la dispersión del registro. Luego, para determinar la existencia de una fuga, los datos son procesados a través del servidor www.hwmonline.com, donde ambos indicadores se restan con la finalidad de establecer la esbeltez del registro. Entonces, la variable que es objeto de análisis en este sistema de monitoreo, se obtiene al descontar la dispersión de la intensidad ($EF = \text{Intensidad} - \text{dispersión [dB]}$).

La figura 12 es una captura del registro diario de ruido, donde cada una de las diez curvas posee una densidad de 2.000 datos, dispuestos en la forma de un histograma de frecuencia absoluta. A su vez, el procesador interno del equipo PermaNet resume esta información diariamente en los ya nombrados indicadores de intensidad y dispersión de ruido, ambos medidos en decibelios. De este modo, la herramienta permite generar y visualizar una curva con información histórica, como se muestra en figura 13.




Figura 12: Registro de un sensor PermaNet. Muestreo de 2.000 datos por cada 10 minutos
Fuente: Captura de software Halma Water Management.




Figura 13: Registro de locación Desagüe Santos Ossa, muestra entre 01/09/2014 y 30/09/2014 para las variables de presión, intensidad y dispersión de ruido

Fuente: Servidor Empresa Halma Water Management

Finalmente, una de las flexibilidades que proporciona el servidor es redefinir el umbral de 15 [dB] que gatilla una alerta, que determinará un trabajo de inspección en los alrededores del sensor. Esta característica fue una variable relevante a la hora de definir la tecnología apropiada, ya que cada umbral puede ser redefinido en directa relación con su comportamiento histórico, permitiendo una relevante mejora evolutiva, que se detalla a continuación.

2.2 Uso de modelos predictivos para la reconfiguración.

Un modelo predictivo es un proceso de análisis estadístico que permite estimar el comportamiento futuro. Tiene como principal finalidad representar simplificada y representativamente procesos, sistemas, situaciones o todo aquel fenómeno que evolucione con el tiempo. Los modelos son una importante herramienta para apoyar la toma de decisiones, a partir de la explicación de la historia, un posterior contraste con situaciones reales, y cómo

este comportamiento se reproduce en períodos posteriores con un determinado grado de confiabilidad.

En el ámbito de prevenir el colapso de la tubería donde se ha implementado el sistema de monitoreo permanente, es relevante incorporar una metodología de análisis de la información, que proporcione la posibilidad de anticiparse certeramente a una filtración que detone en una situación crítica. Si bien la herramienta permite comparar el registro diario de un sensor, con un umbral calibrado en fábrica de 15 [dB], este criterio no representa necesariamente la existencia de una filtración en la infraestructura, ya que los registros pueden estar influenciados por otra fuente de ruido, como las corrientes vagabundas que emite un transformador de corriente eléctrica, un motor en funcionamiento, o una singularidad que genere vibraciones. Entonces, es necesario generar una estrategia de análisis de los datos históricos que permita calibrar los umbrales probables de cada sensor, eliminando la existencia de falsos positivos que dañen la credibilidad de la herramienta de monitoreo.

En los apartados siguientes, se utilizará como texto guía *Sarriko – On, Análisis de Series Temporales: Modelos ARIMA*, desarrollado por la académica de la Universidad del País Vasco, señora María Pilar González Casimiro, para explicar en detalle cómo la implementación de técnicas de análisis estadístico, basado en modelamiento autorregresivo y de medias móviles, permite mejorar la eficacia de detección para una óptima toma de decisiones, en el ámbito preventivo de esta propuesta.

3 Metodología de análisis Box – Jenkins para estructuras tipo ARIMA.

En 1970 Box y Jenkins desarrollaron un cuerpo metodológico destinado a identificar, estimar y diagnosticar modelos dinámicos de series temporales, que son una secuencia ordenada de observaciones, cada una de las cuales está asociada a un momento. La estructura de su información puede caracterizarse en una parte sistémica y otra aleatoria, también denominada “innovación”. En este tipo de estructuras la porción sistémica se determina única y exclusivamente a partir de la historia de su registro.

Los métodos de modelación basados en modelos paramétricos autorregresivos y de medias móviles, ARIMA, propuestos por Box-Jenkins, tienen como principal ventaja la de proporcionar predicciones óptimas en el plazo inmediato y en corto plazo. Permiten, a diferencia de los métodos tradicionales, reproducir la estructura intrínseca de la serie de datos a partir de su propia historia. Esta característica es de gran valor a la hora de modelar la evolución de los registros, porque no es necesario preestablecer la existencia de una estructura estandarizada, como tendencias, ciclos y estacionalidad, como solía hacerse tradicionalmente. De hecho, los registros de ruido no tienen componentes intuitivos que sean identificados a simple vista. Además, los modelos tipo ARIMA no son un único modelo, sino una familia de modelos probables de utilización con una estructura determinada que son capaces de generar predicciones óptimas.

Ningún otro modelo univariante⁶ consigue predicciones con un menor error cuadrático medio (González, Análisis de Series Temporales: Modelos Arima, 2009).

El instrumento fundamental a la hora de analizar las propiedades de una serie temporal es el coeficiente de autocorrelación, que mide el **grado de asociación lineal existente entre observaciones separadas en “k” periodos**.

El coeficiente de correlación lineal se define:

$$\rho_{xy} = \frac{cov(x, y)}{\sqrt{V(x)V(y)}} \quad (1)$$

Por definición es adimensional, tomando valores entre $-1 \leq \rho_{xy} \leq 1$. Cuando el coeficiente toma valor 0, no existe relación lineal entre las variables, mientras que cuando es 1 la relación es perfecta y positiva; por el contrario, cuando es -1, la relación es perfectamente negativa. En la figura 14 se muestra, a la izquierda una asociación positiva, mientras que a la derecha no existe asociación de las variables,

⁶ Modelo univariante: Modelo que permiten pronosticar eventos futuros. Sus principales características son su sencillez, menor cantidad de información y no requiere pronosticar variables explicativas que en la mayoría de los casos son difíciles de medir.




Figura 14: Ejemplos de correlación

Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"

A su vez el **correlograma** es el gráfico de los coeficientes de autocorrelación de orden "k" contra el retardo "k". Esta herramienta es muy útil a la hora de interpretar el conjunto de los coeficientes de autocorrelación, que dan cuenta del dinamismo de la serie. Según la sucesión de las observaciones se pueden diferenciar los siguientes tipos de comportamientos:

Correlación a corto plazo: para una serie sin tendencia donde las observaciones están correlacionadas positivamente, es decir, una serie donde una observación por encima de la media es seguida de una, o varias, que también están por encima del valor medio. El correlograma muestra un alto valor para el primer retardo (r_1), mientras que los sucesivos retardos posteriores decaen rápidamente.




Figura 15: Ejemplificación de serie temporal y correlograma (a)
Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"

Cuando la serie no experimenta una tendencia, pero sus valores oscilan en torno a un valor medio, el correlograma también experimenta este comportamiento.




Figura 16: Ejemplificación serie temporal y correlograma (b)
Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"

Serie tiene tendencia: cambia continuamente de nivel, los valores del correlograma (r_k) no decrecerán rápidamente hacia cero, porque varias observaciones presentan sucesivamente valores sobre (o bajo) un valor medio.




Figura 17: Ejemplificación serie temporal y correlograma (c)

Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"

Serie que presenta algún tipo de ciclo: el correlograma también experimentará una evolución oscilante con la misma frecuencia. La frecuencia presente en la estructura de la serie responderá a la naturaleza de la misma, como es el caso de producción de agua, ventas de *retail*, etc., donde hay una clara influencia de los meses (periodos de 12 meses).




Figura 18: Ejemplificación serie temporal y correlograma (d)

Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"

3.1 Expresión general de un modelo ARMA.

El acrónimo ARMA significa modelo autorregresivo de medias móviles, que se construye a partir del pasado de la serie de registros, y de sus errores de ajuste tanto en el presente, como en el pasado. De esta manera, y como se verá más adelante, esta

herramienta estadística permitirá desarrollar modelos que representen el eventos ocurridos en tiempo presente a través de registros capturados en un tiempo pasado. Para desarrollar el concepto, en la ecuación (2) se presenta la estructura algebraica característica para una serie de registros Y_t modelados a través de un proceso autorregresivo de medias móviles:

$$Y_t = C + \phi_1 * Y_{t-1} + \dots + \phi_p * Y_{t-p} + \theta_1 * a_{t-1} + \theta_q * a_{t-q} + a_t \quad (2)$$

Donde:

t : Corresponde al tiempo presente

Y_t : Representa cualquier serie de registros, cuyas observaciones estén consecutivamente ordenadas en el tiempo.

C : Valor constante a considerar, o no, en el modelo.

ϕ_1 : Coeficiente que pondera la primera observación registrada en el pasado.

Y_{t-1} : Primera observación que se registra en tiempo pasado, $t - 1$.

p : Orden o grado de la estructura autorregresiva, es decir el último retardo necesario para describir el comportamiento histórico de la serie de datos.

ϕ_p : Coeficiente que pondera la última observación que permite describir la serie de registros.

Y_{t-p} : Última observación necesaria que permite describir la serie de registros.

θ_1 : Coeficiente que pondera el primer error de ajuste registrado en el pasado.

a_{t-1} : Primer error de ajuste que se registra en tiempo pasado, $t - 1$

q : Orden o grado de la estructura de medias móviles, es decir el último retardo necesario para describir el comportamiento de la serie de errores de ajuste del modelo.

ϕ_q : Coeficiente que pondera el último error de ajuste que permite describir la serie de registros.

a_{t-q} : Último error de ajuste necesario para el modelo

a_t : Error de ajuste en tiempo presente

El modelo presentado en la ecuación (2) se denota ARMA de órdenes p y q . Es lineal, lo que significa que la serie temporal Y_t depende de un valor constante “C”, linealmente de valores pasados de la misma variable, $(\phi_1 * Y_{t-1} + \dots + \phi_p * Y_{t-p})$, y linealmente de una ponderación de errores de ajustes realizados en el pasado y presente, $(\theta_1 * a_{t-1} + \dots + \theta_q * a_{t-q} + a_t)$.

La estructura, que define la dependencia con los valores pasados de la misma, se denomina **componente autorregresiva** (AR). El número de retrasos de la serie Y_t que se introducen en el modelo es el **orden autorregresivo** “ p ”. El comportamiento se modela como una regresión lineal múltiple con valores propios de la misma serie temporal retrasado un periodo de muestreo ($t=1,2,\dots, p$).

La componente media móvil (MA) representa la dependencia de la serie temporal Y_t con valores pasados de los errores. El número de errores pasados que se consideran en el modelo es el **orden de media móvil** (q). Su comportamiento se modela como una regresión lineal múltiple con valores propios de la misma serie de errores de ajuste retrasado un periodo de muestreo ($t=1,2,\dots, q$).

La ecuación (2) se puede escribir en términos del operador de retardos⁷:

$$(1 - \phi_1 L - \dots - \phi_p L^p) * Y_t = (1 - \theta_1 L - \dots - \theta_q L^q) * a_t$$

Donde:

$\Phi_p(L) = (1 - \phi_1 L - \dots - \phi_p L^p)$, es el polinomio autorregresivo y,

$\Theta_q(L) = (1 - \theta_1 L - \dots - \theta_q L^q)$, es el polinomio de media móvil.

Luego, las condiciones excluyentes que deben cumplir todo tipo de modelo ARIMA son las siguientes:

Condición de estacionariedad: un modelo autorregresivo de medias móviles se considerará estacionario cuando el módulo de las raíces del polinomio autorregresivo, $\phi_p(L)$, sea menor que uno.

Condición de invertibilidad: un modelo autorregresivo de medias móviles se considerará invertible cuando el módulo de las raíces del polinomio de media móvil, $\theta_q(L)$, sea menor que uno.

Para ejemplificar lo anterior se propone revisar el módulo de la raíz del polinomio autorregresivo de primer orden. Primero se corrobora la estacionariedad:

$$1 - \phi_1 L = 0 \rightarrow L = \frac{1}{\phi} \rightarrow |L| = \left| \frac{1}{\phi} \right| \rightarrow |\phi| < 1$$

⁷ Operador de retardos: se denota por “L”, y corresponde a una función matemática que aplicada a un valor de una serie de registros ordenados consecutivamente en el tiempo, sencillamente, desfasa dicho valor en un período. Cuando se aplica en forma sucesiva, por ejemplo “m” veces, desfasa el valor de la serie en “m” períodos.

Luego, para corroborar la invertibilidad se tiene que:

$$1 - \theta_1 L = 0 \rightarrow L = \frac{1}{\theta} \rightarrow |L| = \left| \frac{1}{\theta} \right| \rightarrow |\theta| < 1$$

De este modo se ha presentado la composición general de un modelo autorregresivo de medias móviles, luego se explicará cómo aplicar esta lógica de análisis en series temporales de datos que carecen de la condición de estacionariedad, es decir, que sus registros históricos oscilen en torno a un valor constante, y su variabilidad tienda a cero.

3.2 Expresión general de un modelo ARIMA.

Los modelos ARIMA se construyen a partir de los modelos autorregresivos de medias móviles, pero en este caso, como se verá más adelante, los registros de la serie temporal no oscilan en torno a un valor constante, por lo que no se cumple la condición de estacionariedad. Para superar esta restricción, a la serie original se le aplica una transformación que consiste en restar los registros del primer retardo a los registros originales. Por tanto, se denominará como orden de integración “d” al número de diferencias sucesivas que se deben aplicar a la serie original para conseguir que los registros de la serie transformada oscilen en torno a un valor constante, es decir, que sea estacionaria respecto a su promedio. Entonces, se define que un proceso Y_t es integrado de orden “d”, si la serie de datos no es estacionaria, pero que una vez diferenciada “d” veces tiene un comportamiento ARMA (p-d, q) estacionario. La expresión algebraica para este tipo de modelos es la siguiente:

$$Y_t^{(d)} = C + \phi_1 * Y_{t-1}^{(d)} + \dots + \phi_p * Y_{t-p}^{(d)} + \theta_1 * a_{t-1}^{(d)} + \theta_q * a_{t-q}^{(d)} + a_t^{(d)} \quad (3)$$

Donde:

t : Momento o período de la serie de registros.

d : Orden de integración, o diferenciación, necesario para dar estacionariedad a la serie temporal.

$Y_t^{(d)}$: Serie diferenciada en “d” ocasiones sucesivas,

$a_t^{(d)}$: Serie de errores de ajustes de la serie diferenciada “d” veces.

p : Orden o grado de la estructura autorregresiva. Representa la cantidad de términos autorregresivos utilizados en el modelo

q : Orden o grado de la estructura media móvil. Representa la cantidad de términos de error de ajuste considerados en el modelo.

En general, la ecuación (3) se puede representar por el siguiente modelo, que permite identificar claramente su estructura:

$$\Phi_p(L) * \Delta^d * Y_t = C + \dots + \Theta_q(L) * a_t$$

Donde Δ^d es el polinomio de integración de orden “d”, $(1 - L)^d$, que contiene un número de “d” raíces que son mayores a la unidad.

El comportamiento de un modelo ARIMA permite que pueda definirse como un **modelo lineal múltiple**, donde la variable dependiente es la propia serie (con o sin una diferencia de orden “d”) y las variables independientes corresponden a los valores de la serie y sus errores retrasados, hasta los órdenes p y q, respectivamente.

3.3 Propiedades de un modelo ARIMA óptimo.

La descripción de las principales propiedades de un modelo ARIMA optimizado, permitirá entender cuán cercano es el modelo propuesto respecto al comportamiento ideal.

Parsimonia: la clave de un buen modelo es su sencillez. Se dice que un modelo es parsimonioso si para lograr un ajuste adecuado no requiere de términos innecesarios. Si existen dos modelos, por ejemplo MA (1) y MA (2), que describen idénticamente el comportamiento de una serie de datos, se optará por MA (1) en desmedro de MA (2), ya que contiene un menor grado de información para representar un mismo comportamiento. En este caso el modelo MA (1) permitirá describir el comportamiento de la serie de registros a través de la reproducción de una única variable, mientras que en el caso de un modelo MA (2) se requerirá de dos variables para describir el mismo proceso.

Estacionariedad: se cumple cuando la media es constante y la varianza es cero. Cuando la serie no es estacionaria, es decir, sus observaciones no evolucionan en torno a un valor constante, es posible aplicar alguna transformación (función) para generar que la media sea constante y la varianza tienda a cero. La técnica más utilizada para determinar si una serie de registros es estacionaria es el **contraste de existencia de raíz unitaria**.

Correcta estimación de coeficientes: se traduce en que los coeficientes de los polinomios autorregresivo (ϕ) y de medias móviles (θ), descritos en el apartado 3.1, sean significativamente distintos de cero.

Comportamiento de ruido blanco para los residuos: el residuo del proceso de modelación no puede contener información relevante para el modelo. Esto se puede corroborar al notar la insignificancia de los coeficientes del correlograma de los residuos.

Grado de ajuste: es esperable que el resultado de la modelación entregue un modelo que se ajuste correctamente al comportamiento histórico de sus registros. La bondad del ajuste es cuantificable mediante la medición del error cuadrático medio, u otra expresión medible en términos de error.

Predicciones óptimas: el objetivo de todo proceso de modelación predictiva es generar innovaciones correctas. La evaluación se debe realizar comparando las proyecciones contra los sucesivos valores reales.

3.4 Proceso de Modelación.

En el capítulo anterior se ha descrito la metodología de análisis, que debe utilizarse para modelar una serie de registros, que evolucionan conforme avanza el tiempo. Con el objetivo de obtener una estructura que respete las hipótesis formuladas, se han mencionado las principales características y herramientas para abordar el análisis. El procedimiento práctico propuesto consta de cuatro etapas: i. análisis de estacionariedad de la serie, ii. Identificación del modelo, iii. Validación del modelo y iv. Pronóstico para períodos futuros. A continuación, se detalla cada una de las etapas que permitirán generar el modelo óptimo de las locaciones monitoreadas.

3.4.1 Análisis de estacionariedad.

La metodología Box-Jenkins exige que la serie en análisis sea estacionaria tanto en media como en varianza, de otro modo no se podrá parametrizar el modelo. Se entenderá por una serie estacionaria, a aquellos procesos donde la media y la varianza presentan una evolución constante y finita.

Para la **estacionariedad en varianza**, cuando no es posible sostener el supuesto de que la serie es estacionaria se deben aplicar las transformaciones para su estabilización. El objetivo es conseguir aquella función que transforme la serie para obtener una varianza constante. En general se utilizan las transformaciones de Box-Cox:

$$Y_t^{(\lambda)} = \begin{cases} \frac{Y_t^\lambda - 1}{\lambda} & \lambda \neq 0 \\ \ln(Y_t) & \lambda = 0 \end{cases} \quad (4)$$

En la expresión λ representa el parámetro de transformación. De aquí se desprenden dos transformaciones regularmente utilizadas para estabilizar la varianza: logaritmos y raíces. Por otro lado, estas transformaciones también mejoran la aproximación a la **distribución normal** de la serie Y_t .

Como se mencionó con anterioridad, para que la serie sea **estacionaria en media**, debe evolucionar en torno a un valor constante. Para todo caso contrario, donde los niveles de la serie tengan un comportamiento tendencioso, tanto creciente como decreciente, se trata de una serie no estacionaria. Son muchas las actividades que

pueden arrojar series con una variación en sus niveles, tales como la tecnología, la demografía, el consumo, etc.

Como se explicó en la sección 3.2, aunque una serie de datos no sea estacionaria, igualmente se puede modelar mediante un modelo paramétrico del tipo ARIMA (p , d , q), donde la estructura autorregresiva que explica su dependencia histórica de los registros contiene “ p ” términos, el número de raíces no estacionarias da origen al orden de integración “ d ”, y contiene “ q ” términos de la serie de errores de ajuste. Sin embargo, para aplicar este proceso de modelación, primeramente se deberán identificar las raíces del polinomio autorregresivo AR (p), que no satisfagan la condición de estacionariedad, es decir, el orden de integración “ d ”.

Para el análisis de las raíces del polinomio autorregresivo debe tenerse en cuenta lo siguiente:

- El módulo de alguna raíz es mayor que uno: Estos procesos son de tipo explosivos. Crecen o decrecen a gran velocidad hacia infinito. Esta evolución temporal no se evidencia en análisis de la variable “estado de fuga”; por tanto, no será tomada en cuenta en el presente estudio.
- El módulo de alguna raíz es exactamente igual a uno: A diferencia del caso anterior, estos procesos no son explosivos y su comportamiento es estable en el tiempo, salvo por los cambios de nivel. Precisamente, la variable estado de fuga presenta este tipo de secuencias.
- El módulo de la raíz es menor que uno: En este caso estamos en presencia de una serie estacionaria.

Para encontrar el orden de integración de aquella serie, que no cumple el principio de estacionariedad, se utilizan las siguientes herramientas de análisis:

- Gráfica de la serie original y sus transformaciones para observar si se cumple la condición de oscilar en torno a un nivel constante.
- Correlograma de la serie original y sus transformaciones para comprobar si existe un rápido decaimiento hacia cero.
- Prueba formal basada en el contraste de raíz unitaria propuesto por Dickey- Fuller.

La prueba de Dickey-Fuller (Dickey & Fuller, 1979) se utiliza para **confirmar** la existencia de una raíz unitaria en un modelo autorregresivo. Para su explicación se utilizará un modelo autorregresivo de primer orden, AR (1):

$$Y_t = \phi * Y_{t-1} + a_t, \quad \text{con } a_t \sim RB(0, \sigma^2) \quad (5)$$

Donde ϕ es un parámetro por estimar y a_t es un término de error que debe cumplir el comportamiento de un ruido blanco. ϕ es un coeficiente de autocorrelación, que pondera la primera observación desfasada en un período, y toma valores entre $-1 < \phi < 1$. Si $\phi = 1$, la serie Y_t , deja de ser estacionaria. Por tanto, la hipótesis de estacionariedad puede evaluarse analizando si el valor absoluto de ϕ es estrictamente menor que uno.

El test Dickey-Fuller, en adelante “DF” sencillamente plantea contrastar estadísticamente si $\phi = 1$. Ahora bien, si la ecuación (5) se diferencia en un período, se obtiene:

$$Y_t - Y_{t-1} = \phi_1 * Y_{t-1} - Y_{t-1} + a_t \quad (6)$$

$$\Delta Y_t = \beta Y_{t-1} + a_t \quad (7)$$

Donde

$\beta = \phi - 1$, corresponde a un término auxiliar que se construye para simplificar la prueba de hipótesis estadística.

Por tanto, definido el término auxiliar " β " es posible replantear la prueba de contraste estadístico sobre la existencia de una raíz unitaria en base a la siguiente hipótesis:

Hipótesis nula:

$H_0: \beta = 0$, es decir, no existe raíz unitaria en el modelo, o alternativamente,

Hipótesis alternativa:

$H_a: \beta < 0$, existe alguna raíz unitaria en el modelo.

El término β se plantea de forma negativa, porque de lo contrario implicaría un proceso de comportamiento explosivo. El estadígrafo utilizado para generar el contraste de la hipótesis de existencia de raíz unitaria corresponde a:

$$t_c = \frac{\hat{\beta} - 0}{\sqrt{\hat{V}\hat{\beta}}} \quad (8)$$

Donde:

t_c : Estadístico de contraste Dickey – Fuller

$\hat{\beta} = \frac{\sum_{t=2}^T y_{t-1} \Delta y_t}{\sum_{t=2}^T (y_{t-1})^2}$, es el estimador de mínimos cuadrados ordinarios⁸ de la variable

auxiliar β de primer orden, y

$\hat{V}(\hat{\beta}) = \frac{\sigma^2}{\sum_{t=2}^T (y_{t-1})^2}$, es el estimador de mininos cuadrados ordinarios de la

varianza de la variable auxiliar β de primer orden.

Aunque existen similitudes entre el estadígrafo “t” planteado por Dickey – Fuller y la distribución de probabilidad “t-Student”, no son equivalentes; por ello, se han debido simular los valores críticos para una selección de distintos tamaños muestrales. Las tablas construidas por Dickey – Fuller están en función del tamaño de la muestra y el nivel de significancia (α). Todo lo anterior permite enunciar la hipótesis nula como: se rechaza la hipótesis nula H_0 , es decir, la no existencia de raíz unitaria a un

⁸ Estimador de mínimos cuadrados ordinario: también conocido como mínimos cuadrados lineales. Método para encontrar los parámetros poblacionales en un modelo de regresión lineal. Este método minimiza la suma de las distancias (diferencias) verticales entre las respuestas observadas en la muestra y las respuestas del modelo.

nivel de significancia α , si el valor muestral de “t” es menor que el valor crítico de las tablas Dickey-Fuller, $t < DF(\alpha)$.

Lo planteado anteriormente resuelve el problema para un proceso autorregresivo de primer orden, AR (1), sin embargo naturalmente nace la duda de cómo proceder cuando el modelo es más complejo, e incluye una estructura de medias móviles (MA). Para estos casos el contraste de existencia de raíz unitaria se realiza mediante el test de Dickey-Fuller aumentado, en adelante ADF, cuya notación algebraica es la siguiente:

$$\Delta Y_t = \beta Y_{t-1} + \alpha_1 * \Delta Y_{t-1} + \dots + \alpha_{p-1} * Y_{t-p+1} + a_t \quad (9)$$

Esta especificación aumentada del test DF se basa en la hipótesis nula y alternativa sobre la existencia de raíz unitaria en el término β .

Donde:

Hipótesis nula:

$H_0: \beta = 0$, es decir, no existe raíz unitaria en el modelo, o alternativamente,

Hipótesis alternativa:

$H_a: \beta < 0$, existe alguna raíz unitaria en el modelo.

Además, la estructura de la ecuación (9) puede incluir una constante, tendencia o ambas; sin embargo, en todos los casos el proceso de comparación (contraste) es el presentado en la ecuación (8).

3.4.2 *Identificación del modelo.*

Anteriormente se explicó la importancia del parámetro “d” para dar estacionariedad a la serie. La correcta identificación de este parámetro permite obtener una serie estable tanto en media como varianza, donde la primera debe evolucionar en torno a un valor constante, y la segunda acercarse al valor cero. Cuando se ha encontrado el orden de integración “d” se obtiene la transformación que estacionariza la serie original Y_t . Es decir:

$Z_t = (1 - L)^d Y_t$, que corresponde a “d” diferencias aplicadas en forma sucesiva para obtener que los registros de la serie trasformada, en primer lugar oscilen en torno a un valor constante, y en segunda instancia, su variabilidad tienda a cero.

Esta transformación sobre la serie temporal original se puede representar mediante un proceso ARMA (p-d, q) estacionario. Luego, será necesario encontrar los órdenes de la estructura autorregresiva y de medias móviles, es decir “p” y “q”, respectivamente

Los parámetros de las estructuras autorregresiva y de medias móviles se identifican analizando las funciones de **autocorrelación**, en adelante se denotara **FAC**, y de **autocorrelación parcial**, en adelante se denotara **FACP**. La representación gráfica de ambas en función de los distintos periodos pasados, o retardos, se denomina **correlograma**. Pues bien, la identificación se realiza comparando las características observadas en el correlograma de la serie en análisis y las propiedades esperables para los distintos, y posibles, modelos teóricos.

Se puede comprobar que un modelo AR (1) podría presentar uno de los siguientes correlogramas, en los que se observan los primeros diez retardos que explican la estructura regular de este modelo:




Figura 19: Correlograma de autocorrelación y autocorrelación parcial para un modelo AR (1) de forma regular
Fuente: María Pilar González Casimiro 2009 “Análisis de Series Temporales: Modelos ARIMA”




Figura 20: Correlograma de autocorrelación y autocorrelación parcial para un modelo AR (1) alternando valores positivos y negativos
Fuente: María Pilar González Casimiro 2009 “Análisis de Series Temporales: Modelos ARIMA”

En un modelo AR (1) –o ARMA (1,0) – encontramos que la función de autocorrelación decrece rápidamente hacia cero, bien sea de forma regular (ver figura 19) o alternando valores positivos y negativos (ver figura 20). A su vez, la función de autocorrelación parcial presenta un único valor distinto de cero, es decir, tantos como el orden del proceso AR. Estas características son generalizables para los modelos

ARMA, con orden de medias móviles igual a cero. Un modelo ARMA (2,0) podría presentar los siguientes correlogramas teóricos:




Figura 21: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (2,0) con todos sus coeficientes positivos

Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"




Figura 22: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (2,0) con alternancia en el signo de sus coeficientes

Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"




Figura 23: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (2,0) con alternancia en sus dos primeros retornos y posterior decaimiento en forma sinusoidal

Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"




Figura 24: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (2,0) con sus dos primeros retardos negativos y posterior decaimiento en forma sinusoidal
Fuente: María Pilar González Casimiro 2009 “Análisis de Series Temporales: Modelos ARIMA”

En esta misma línea, para modelos del tipo medias móviles, donde los más comunes son MA (1) y MA (2), por ejemplo ARMA (0,2) podría presentar cualquiera de los siguientes correlogramas en sus primeros diez retardos:




Figura 25: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (0,2) con sus dos primeros retardos negativos y posterior decaimiento
Fuente: María Pilar González Casimiro 2009 “Análisis de Series Temporales: Modelos ARIMA”




Figura 26: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (0,2) con sus dos primeros retardos alternando y posterior decaimiento
Fuente: María Pilar González Casimiro 2009 “Análisis de Series Temporales: Modelos ARIMA”




Figura 27: Correlograma de autocorrelación y autocorrelación parcial para un modelo ARMA (0,2) con sus dos primeros retardos positivos y posterior decaimiento de forma sinusoidal
Fuente: María Pilar González Casimiro 2009 “Análisis de Series Temporales: Modelos ARIMA”

Las situaciones descritas anteriormente permiten generalizar la idea de que, si la función de autocorrelación de la serie Z_t presenta un corte a partir de un retardo finito “j”, la identificación del proceso adecuado corresponde a un modelo MA (j). Por otro lado, si la función de autocorrelación no presenta un corte, sino que parece decrecer rápidamente siguiendo una forma exponencial, o de onda seno-coseno, la identificación no es tan clara, ya que pudiese ser representado por un proceso AR (p) o ARMA (p, q).

Por lo tanto, las características dinámicas de la serie de registros están contenidas en la función de autocorrelación, FAC, por lo que su correcta interpretación permitirá identificar el orden autorregresivo “p”, y el de medias móvil “q” del modelo ARMA que representará la serie temporal. Si la serie de registros Y_t no es estacionaria, pero al aplicar “d” diferencias sucesivas se logra cambiar esta condición, logrando obtenerse la nueva serie Z_t , que cumple con la condición de estacionariedad, entonces sus coeficientes de autocorrelación se definirán como:

$$\hat{\rho}_k = \frac{\sum_{t=k+1}^{T^*} (Z_t - \bar{Z})(Z_{t-k} - \bar{Z})}{\sum_{t=1}^{T^*} (Z_t - \bar{Z})^2} \text{ con } k = 1, 2, \dots, T^*$$

Donde:

T : Número de observaciones de la serie de registros que definen la longitud de la serie original Y_t .

T^* : Longitud de la serie estacionaria, es decir $T - d$.

Cuando la interpretación del correlograma de la función de autocorrelación no permita identificar claramente la estructura del modelo, se debe recurrir al análisis de la función de autocorrelación parcial, cuyo coeficiente de orden “k” se denota por p_k , y mide el grado de asociación lineal existente entre las variables Y_t e Y_{t-k} . Las propiedades de la función de autocorrelación parcial, FACP, son equivalentes a las de la función de autocorrelación, FAC:

- $p_0 = 1$ y $p_1 = \rho_1$
- Los coeficientes son menores que la unidad en valor absoluto.
- Es una función simétrica
- Decrece rápidamente hacia cero cuando $k \rightarrow \infty$

Luego, la estructura de la función de autocorrelación parcial para un modelo estacionario, autorregresivo y de medias móviles, ARMA (p, q) se define como:

Para modelo AR (p):

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \phi_3 Y_{t-3} + \dots + \phi_q Y_{t-q} + a_t \quad (10)$$

La estructura de su función de autocorrelación parcial es:

$$p_k = \begin{cases} p_k \neq 0 & k = 1, 2, \dots, p \\ p_k = 0 & k = p + 1, p + 2, \dots \end{cases}$$

Entonces, si un proceso sigue un modelo AR (p), Y_t depende directamente de su pasado hasta el retardo “p” de forma que las variables aleatorias separadas un periodo, dos y hasta “p” periodos mantienen una relación lineal directa. No obstante, para variables separadas más de “p” periodos, el coeficiente de autocorrelación parcial es cero porque no existe tal relación lineal entre las variables. Dado lo anterior puede establecerse que:

Para modelos MA (q):

$$Y_t = \theta_1 a_{t-1} + \theta_2 a_{t-2} + \theta_3 a_{t-3} + \cdots + \theta_q a_{t-q} + a_t \quad (11)$$

La función de autocorrelación parcial de un modelo de medias móviles finito, es infinito y decrece rápidamente hacia cero de forma exponencial cuando las raíces del polinomio de medias móviles son reales. En caso contrario, cuando las raíces sean un número complejo, decaerá de manera amortiguada en forma de onda seno-coseno.

Para modelos ARMA (p, q):

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \cdots + \phi_p Y_{t-p} + \cdots + \theta_1 a_{t-1} + \cdots + \theta_q a_{t-q} + a_t \quad (12)$$

La función de autocorrelación parcial para este modelo es infinita. Los p primeros coeficientes dependen de los parámetros autorregresivos y de medias móviles. A partir del retardo $p+1$, depende únicamente de la parte de medias móviles.

La tabla 3 resume el comportamiento esperable de las estructuras descritas anteriormente:

Tabla 3: Comportamiento teórico de funciones de autocorrelación simple y parcial

Modelo	FAC	FACP
MA (q)	Se anula para $j > q$	Decrecimiento rápido, no se anula
AR (p)	Decrecimiento rápido, no se anula	Se anula para $j > p$
ARMA (p, q)	Decrecimiento rápido, no se anula	Decrecimiento rápido, no se anula

Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"

Gráficamente los factores de autocorrelación y autocorrelación parcial lucen como se muestra en las figuras 28 y 29.




Figura 28: Función de autocorrelación (Modelo tipo ARMA (2,1))

Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"




Figura 29: Función de autocorrelación parcial (Modelo tipo ARMA (2,1))

Fuente: María Pilar González Casimiro 2009 "Análisis de Series Temporales: Modelos ARIMA"

Para la identificación del modelo apropiado solamente se cuenta con las herramientas de FAC y FACP, que son construidas a partir de los datos de la serie Y_t . Para identificar el orden del proceso ARMA (p, q) adecuado es necesario determinar su estructura realizando contrastes estadísticos para corroborar la significancia individual de los coeficientes que han sido estimados a través de las funciones de

autocorrelación y autocorrelación parcial. Entonces, bajo el supuesto de que $k > 0$, el estimador de los coeficientes de autocorrelación $\hat{\rho}_k$ sigue una distribución normal que se define a continuación:

$$\hat{\rho}_k \sim N(\rho_k, V(\hat{\rho}_k)) \text{ con } V(\hat{\rho}_k) \cong \frac{1}{T^*} \quad (13)$$

Donde $T^* = T - d$, es la longitud de la serie estacionaria

Para corroborar la significancia de los coeficientes, se realiza el siguiente contraste de hipótesis nula, donde k toma valores $k = 1, 2, \dots, T^*$:

$H_0: \rho_k = 0$, es decir que el coeficiente de autocorrelación no es significativo, o alternativamente que:

$H_a: \rho_k \neq 0$, es decir que el coeficiente de autocorrelación es significativo.

Luego, si para el análisis se toma en consideración la hipótesis nula, H_0 , el estadístico de contraste sigue una distribución normal, que se define:

$$\frac{\hat{\rho}_k}{\sqrt{V(\hat{\rho}_k)}} \sim N(0,1) \quad (14)$$

En consecuencia, se rechazará la hipótesis nula, H_0 , a un nivel de significancia del 5% si se cumple que:

$$\left| \frac{\hat{\rho}_k}{\sqrt{V(\hat{\rho}_k)}} \right| \geq N_{0,025} = 1,96 \quad (15)$$

O análogamente:

$$|\hat{\rho}_k| \geq 1,96 * \sqrt{\hat{\rho}_k} \approx \frac{2}{\sqrt{T^*}} \quad (16)$$

Por lo tanto, $\pm \frac{2}{\sqrt{T^*}}$ es la banda de confianza que delimita la zona de significancia del coeficiente ρ_k .

En cuanto a la función de autocorrelación parcial, FACP, los coeficientes de autocorrelación parcial $\hat{p}_k$, con $k > p$, en un modelo autorregresivo de orden “p”, AR(p), siguen la siguiente distribución normal:

$$\hat{p}_k \sim N(0, V(\hat{p}_k)) \text{ con } V(\hat{p}_k) \cong \frac{1}{T^*} \quad (17)$$

Donde $T^* = T - d$, es la longitud de la serie estacionaria

Análogamente al proceso anterior, se requiere realizar el siguiente contraste basado en la hipótesis nula para $k = 1, 2, \dots, T^*$

$H_0: p_k = 0$, es decir que el coeficiente de autocorrelación parcial no es significativo, o alternativamente que:

$H_a: p \neq 0$, es decir que el coeficiente de autocorrelación parcial es significativo.

Por tanto, se rechaza la hipótesis nula de no significancia del coeficiente de autocorrelación parcial, a un nivel de significancia de 5% cuando:

$$|\hat{p}_k| \geq 1,96 * \sqrt{\hat{p}_k} \approx \frac{2}{\sqrt{T^*}} \quad (18)$$

Nuevamente las bandas de confianza están delimitadas por $\pm \frac{2}{\sqrt{T^{**}}}$, ello implica que todo coeficiente que escape a este valor será significativo estadísticamente.

Para la identificación del modelo correcto se interpretará la información que proporcionen las FAC y FACP, resultando difícil dar con una única modelación; más bien se acotarán un conjunto de modelos probables que den solución a la evolución de la serie original. En la siguiente sección, “etapa de validación”, podrá corroborarse cuál de los modelos propuestos es el que mejor se ajusta y reproduce la serie original.

3.4.3 Validación del modelo.

Anteriormente se ha descrito la forma de identificar la estructura que representa la evolución de una serie de registros en el tiempo, comparando la forma de los correlogramas de autocorrelación y autocorrelación parcial con la estructura esperable. De hecho, se ha planteado cómo diferenciar aquellos coeficientes del correlograma, que son estadísticamente significativos. Por tanto, en la presente sección se explicará cómo evaluar la adecuación de los modelos estimados a los registros de la serie temporal, teniéndose en cuenta que:

- Si las estimaciones de los coeficientes del modelo son significativas y cumplen las condiciones de estacionariedad e invertibilidad.
- Si los residuos del modelo tienen el comportamiento de un “ruido blanco”.

- Es necesario comparar los modelos propuestos en base la cantidad de información o términos que los componen. Esta comparación se realizará conforme a los criterios de información, que tienen como objetivo cuantificar la parsimonia de los mismos.

Primeramente, para determinar si los coeficientes que conforman el modelo son estadísticamente significativos se deben realizar los contrastes de significancia individual de los coeficientes asociados a la parte regular (AR) y de medias móviles (MA). En el caso más general, un modelo ARMA (p, q) requiere formular las siguientes hipótesis para su contraste:

$H_0: C = 0$, es decir la no significancia de incluir una constante en el modelo.

$H_0: \phi_i = 0$, es decir la no significancia de los coeficientes que ponderan la estructura autorregresiva del modelo.

$H_0: \theta_i = 0$, es decir la no significancia de los coeficientes que ponderan la estructura de media móvil del modelo.

Por tanto, para contrastar la hipótesis nula de no significancia individual de los parámetros, se utilizará el estadístico “t” que sigue una distribución normal para el estimador $\hat{X}_i$ de algún parámetro evaluado:

Se rechazará la hipótesis nula a un nivel de significación $\alpha = 5\%$, cuando:

$$\left| \frac{\hat{X}_i}{\sqrt{\hat{V}(\hat{X}_i)}} \right| \geq N_{\alpha/2}(0,1) \cong 1,96 \quad (19)$$

Para corroborar las condiciones de estacionariedad e invertibilidad se deben calcular las raíces del polinomio autorregresivo, $\Phi_p(L) = 0$, y las del polinomio de medias móviles, $\Theta_q(L) = 0$. Como se explicó en secciones anteriores, si alguna de las raíces calculadas está próxima a la unidad, podría indicar falta de estacionariedad o invertibilidad, lo que implicaría una **redefinición del modelo propuesto**.

Cuando se ha validado que los coeficientes son estadísticamente significativos, y cumplen la condición de estacionariedad e invertibilidad, se procede a analizar el comportamiento de los residuos.

Se dirá que la serie de errores de ajuste a_t es **ruido blanco** si su media es cero, su varianza es constante y los coeficientes de autocorrelación estimados están dentro del intervalo de no significancia, definido como:

$$|\hat{\rho}_k(a)| \leq \frac{1,96}{\sqrt{T^*}} \quad (20)$$

Donde $T^* = T - d$, es la longitud de la serie estacionaria

La expresión anterior aplica para todos los retardos “ k ”, y al menos para el 95% de los coeficientes estimados.

Como alternativa se puede realizar un contraste de significancia sobre un conjunto de coeficientes de autocorrelación. Por lo tanto, la hipótesis nula es:

$$H_0: \rho_1(a) = \rho_2(a) = \dots = \rho_m(a) = 0$$

El estadígrafo más utilizado para corroborar la significancia del conjunto de coeficientes es el propuesto por Ljung-Box (Box & Jenkins, 1976), y se presenta a continuación, en la ecuación (21):

$$Q^{**}(M) = T^{**}(T^{**} + 2) \sum_{k=1}^M \frac{\hat{\rho}_k(a)}{T^{**} - k} \sim \chi^2(M - p - q) \quad (21)$$

Donde:

T : Número total de observaciones de la serie

T^{**} : Número efectivo de observaciones, $T - d$.

Q^{**} : Estadístico de Ljung – Box.

M : Último período en análisis, que a su vez determina el último coeficiente a incluir en la hipótesis de correlación serial.

χ^2 : Distribución de probabilidad Chi – cuadrado

p : Orden o grado de la estructura autorregresiva del modelo.

q : Orden o grado de la estructura media móvil del modelo.

La prueba de contraste de hipótesis para el conjunto de coeficientes se enuncia como: “se rechazará la hipótesis nula de ausencia de correlación serial, con un nivel de significancia del 5%, para valores grandes del estadístico, si”:

$$Q^{**}(M) > \chi^2_{0,05}(M - p - q) \quad (22)$$

Si ocurre el caso de que exista correlación serial de los residuos del modelo, esto es que exista información relevante para la reproducción del moldeo contenida en la serie de errores, inmediatamente se concluye que la modelación no ha sido capaz de reproducir el patrón de comportamiento sistemático de la serie, y habría que reformularlo.

Por último, cuando se han identificado los modelos que pueden representar la evolución estructural de la serie analizada, se debe seleccionar el idóneo entre ellos. El enfoque que se utilizará se basa en la comparación del beneficio de tener más información en comparación de la reducción de la variabilidad de la serie de errores de ajuste, a_t , es decir, minimizar el error de ajuste del modelo. Las principales propuestas para las funciones de criterios de información corresponden a las enunciadas por Akaike (1973, 1974), Schwarz (1978) y Hannan-Quinn (1979). Dichos criterios serán definidos por medio de la tesis doctoral *Selección de modelos mediante criterios de información en análisis factorial. Aspectos teóricos y computacionales*, (Universidad de Granada, 2011). Aunque su desarrollo no será incluido en esta memoria de título, ya que sus algoritmos se considerarán aplicados por medio de los softwares de análisis estadístico que serán utilizados para calcular los modelos de las series temporales de datos.

Criterio de información de Akaike: fue desarrollado en el año 1974 para diferenciar modelos de representación de series temporales. La idea clave de este criterio es la de penalizar el exceso de parámetros a incorporar. El criterio de información de Akaike, AIC, es un estimador muestral y viene dado por la siguiente expresión:

$$AIC(m) = -2 * Ln (\hat{f}(m)) + 2m \quad (23)$$

Donde:

m : Número de parámetros independientes considerados en el modelo

$AIC(m)$: Estadístico de Akaike para comparar el grado de información presente en la serie de registros.

$\hat{f}(m)$: Estimación máximo verosímil ⁹ (Universidad de Valencia, 2018) del conjunto de parámetros

En el caso de un modelo de regresión lineal o no lineal, el AIC puede también ser escrito como:

$$AIC(\sigma) = \log(\hat{\sigma}^2) + \frac{2}{n} \quad (24)$$

Donde:

$\hat{\sigma}^2$: Es el estimador de máxima verosimilitud de la varianza de los errores de regresión.

⁹ Estimación máximo verosímil: la verosimilitud consiste en otorgar a un estimador, o estimación, la máxima “credibilidad” de representar el comportamiento objetivo, o real. En términos probabilísticos podríamos hablar de que la verosimilitud es la probabilidad de que ocurra o se dé una determinada muestra si es cierta la estimación que hemos efectuado o el estimador que hemos planteado.

Las dos ecuaciones presentadas generan resultados idénticos; no obstante, cuando se utilice la ecuación (23), el modelo escogido corresponderá a aquel que proporcione el mayor valor de AIC, mientras que, si se utiliza la ecuación (24), prevalecerá el modelo que entregue el menor valor.

Criterio de información de Schwarz: El criterio bayesiano de Schwarz, *CBS*, se formula para mostrar una alternativa a la penalización que realiza el criterio Akaike, *AIC*. En este criterio, el número de retardos se penaliza respecto a la cantidad “*n*” de la muestra, por medio del factor $\ln(n)$. Esto es significativo respecto al criterio anterior, que penaliza la cantidad de información, o número de retardos, duplicándolos por medio de un factor “2” que pondera los grados de libertad, o número de parámetros independientes. El criterio se define:

$$CBS(m) = -2 * \ln(\hat{f}(m)) + \ln(n) * m \quad (25)$$

Donde:

n: Tamaño de la muestra.

m: Número de parámetros independientes considerados en el modelo.

CBS: Criterio bayesiano de Shwarz.

$\hat{f}(m)$: Estimación máximo verosímil del conjunto de parámetros.

Al comparar CBS entre modelos, el que muestre el más alto valor será el seleccionado. Para modelos de regresión, una versión alternativa basada en el error estándar de estimación de la regresión, $\hat{\sigma}$, está dado por:

$$CBS(\sigma) = Ln(\hat{\sigma}^2) + \frac{Log(n)}{n} * m \quad (26)$$

De acuerdo con este criterio, el modelo que indique el menor valor de $CBS(\sigma)$ será el seleccionado.

Criterio de información Hannan – Quinn: Este criterio de información puede ser considerado como una variante del criterio bayesiano de Shwarz con una pequeña penalización del tamaño muestral. El criterio de información propuesto:

$$HQIC(m) = -2 * Ln(\hat{f}(m)) + 2 * Ln(Ln(n)) * m \quad (27)$$

Donde:

$HQIC(m)$: Corresponde al criterio de información de Hannan – Quin para “m” términos independientes.

O su equivalente para un modelo de regresión, σ :

$$HQIC(\sigma) = Ln(\hat{\sigma}^2) + \frac{2 * Log(Log(n))}{n} * m \quad (28)$$

Al igual que en criterios anteriores, el modelo con el menor valor para $HQIC$ será seleccionado.

3.4.4 Pronóstico para períodos futuros.

Hasta el momento, la metodología Box-Jenkins ha permitido identificar, estimar y validar una familia de modelos posibles y, por cierto, encontrar el que mejor se ajuste

a la secuencia de datos. Ahora bien, el procedimiento utilizado, además de encontrar la estructura que modela la información disponible, permitirá estimar las **predicciones óptimas**¹⁰ de algún momento “ t ” en el futuro. Por tanto, si se tiene la serie Y_t , para $t = 0$ hasta $t = T$, donde T es la última observación conocida de la serie temporal, predecir un valor futuro implicará estimar el valor que tomará la serie en un momento futuro, es decir $T + \ell$, donde ℓ representa el número de períodos en el futuro que se considerarán para la predicción. Luego, a la predicción de $Y_{T+\ell}$, que posee información conocida hasta el período T , se denotará por $Y_T(\ell)$. En consecuencia, si $\ell = 1$, entonces se realizará una predicción de un periodo en adelante. A su vez, si $\ell = 3$, entonces se calculará la predicción de tres períodos en adelante.

Como se considera que la serie temporal es la realización de un proceso estocástico estacionario¹¹, el valor a predecir $Y_{T+\ell}$ será también una variable aleatoria. Para predecir una variable de este tipo es necesario estimar su función de distribución de probabilidad. En general, es complejo determinar completamente la forma de la función de distribución, sin hacer supuestos muy fuertes y poco realistas sobre su forma. De hecho, por este último motivo es más conveniente diseñar intervalos de

¹⁰ Predicciones óptimas: término utilizado que guarda relación con minimizar el error cuadrático medio de predicción.

¹¹ Proceso estocástico estacionario: concepto matemático que sirve para caracterizar una sucesión de variables aleatorias que evolucionan en función de otra variable, generalmente asociada al tiempo.

confianza en torno al valor de $Y_{t+\ell}$ para un $(1 - \alpha)\%$ de confianza. En adelante, esta será la estrategia utilizada.

Se entenderá por predictor óptimo, o predicción óptima, a aquel que minimiza una determinada función de pérdida de información, como es el caso del error cuadrático medio de predicción, ECMP¹², por tanto $Y_T(\ell)$ será un predictor óptimo si minimiza el error cuadrático medio del proceso, es decir:

¹² Error Cuadrático Medio de Predicción, ECMP: el error cuadrático medio de un estimador estadístico mide el promedio de los errores de ajuste al cuadrado, es decir, el cuadrado de la diferencia entre el estimador y lo que se estima. A su vez, la diferencia que se produce entre el estimador y el valor esperado, se genera por la aleatoriedad de la serie de datos, o bien porque el estimador no toma en consideración la totalidad de información que permite reproducir la secuencia de información. Entonces, si se tiene en consideración que $\hat{Y}_t$ es un vector de “n” predicciones e Y es el vector de los verdaderos valores observados, entonces, el error cuadrático medio del predictor es:

$$ECMP = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_t - Y)^2$$

Este valor es conocido, y dependerá de los valores de la muestra. Luego si se define el error cuadrático medio de predicción en función de un vector de parámetros desconocidos W , se tendrá que:

$$ECMP(\hat{W}) = E \left[(\hat{W} - W)^2 \right]$$

Por último, el error cuadrático medio de predicción será igual a la suma de la varianza y el cuadrado del sesgo del estimador, o las predicciones. En este caso, se plantea el ECMP en función de un estimador estadístico $\hat{W}$:

$$ECMP(\hat{W}) = Var(\hat{W}) + \left(sesgo(\hat{W}, W) \right)^2$$

$$E[Y_{T+\ell} - Y_T(\ell)]^2 \leq E[Y_{T+\ell} - Y_T^*(\ell)]^2 \quad \forall Y_T^*(\ell) \quad (29)$$

Donde $E[Y_{T+\ell} - Y_T(\ell)]^2$ corresponde al cuadrado del valor esperado, o esperanza matemática, de la diferencia que se produce entre el predictor, $Y_{T+\ell}$, y el valor observado ℓ períodos en adelante, $Y_{T+\ell}$.

De igual manera, es importante mencionar que bajo ciertas condiciones de regularidad, la predicción de un evento futuro estará asociada a **un único valor**, si éste viene dado por la esperanza condicionada al conjunto de información. Si se denota por I_T , entonces el predictor óptimo de $Y_T(\ell)$ será:

$$Y_T(\ell) = E[Y_{T+\ell}|I_T] = E_T[Y_{T+\ell}] \quad (30)$$

En otras palabras, es el valor esperado de la distribución de $Y_T(\ell)$ sujeto a la información disponible I_T , donde $I_T = \{Y_T, Y_{T-1}, Y_{T-2}, Y_{T-3}, \dots\}$.

Por otro lado, la predicción óptima por **intervalos** se construye a partir del error de predicción que, perentoriamente, debe tener un comportamiento de ruido blanco, $a_t \sim RBN(0, \sigma^2)$. Luego, el error de predicción será:

Por tanto, el error cuadrático medio de predicción es una medida de la calidad del estimador, o el conjunto de las predicciones en cuanto a su variación y sesgo, que corresponde a la diferencia entre la esperanza matemática del estimador, y el valor numérico del parámetro que se requiere estimar.

$$e_T(\ell) = Y_{T+\ell} - Y_T(\ell) \sim N(0, V(e_T(\ell))) \quad (31)$$

Donde $e_T(\ell)$ es el error de predicción para ℓ períodos en adelante, y sigue una distribución normal de media cero y varianza $V(e_T(\ell))$.

Al normalizar la ecuación (31), para que tenga una distribución normal conocida, de media cero, varianza unitaria, se obtiene que:

$$\frac{Y_{T+\ell} - Y_T(\ell)}{\sqrt{V(e_T(\ell))}} \sim N(0,1) \quad (32)$$

Por tanto, el intervalo de predicción para un $(1 - \alpha)\%$ de confianza es:

$$\left[Y_T(\ell) - N_{\frac{\alpha}{2}} * \sqrt{V(e_T(\ell))}, Y_T(\ell) + N_{\frac{\alpha}{2}} * \sqrt{V(e_T(\ell))} \right] \quad (33)$$

Lo expuesto anteriormente permite establecer la predicción de un modelo estacionario.

Para ejemplificar el análisis, a continuación se utilizará la estructura de un proceso ARMA(1,2), donde:

$$Y_t = \delta + \phi Y_{t-1} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} \quad \text{con } a_t \sim RBN(0, \sigma^2) \quad y \quad t = 1, 2, 3 \dots \quad (34)$$

Por tanto, la media del proceso no es cero si se cumple que la constante del proceso es distinta de cero, $\delta \neq 0$, es decir:

$$E(Y_T) = \frac{\delta}{1 - \phi} \quad (35)$$

Entonces, las predicciones de un proceso autorregresivo y de media móvil, de primer y segundo orden, respectivamente serán:

Primera predicción, para un período adelante, $\ell = 1$:

$$Y_{T+1} = \delta + \phi Y_T + a_{T+1} - \theta_1 a_T - \theta_2 a_{T-1}$$

$$Y_T(1) = E_T[Y_{T+1}] = E_T[\delta + \phi Y_T + a_{T+1} - \theta_1 a_T - \theta_2 a_{T-1}]$$

$$Y_T(1) = \delta + \phi Y_T - \theta_1 a_T - \theta_2 a_{T-1}$$

Segunda predicción, para dos períodos adelante, $\ell = 2$:

$$Y_{T+2} = \delta + \phi Y_{T+1} + a_{T+2} - \theta_1 a_{T+1} - \theta_2 a_T$$

$$Y_T(2) = E_T[Y_{T+2}] = E_T[\delta + \phi Y_{T+1} + a_{T+2} - \theta_1 a_{T+1} - \theta_2 a_T]$$

$$Y_T(2) = \delta + \phi Y_T(1) - \theta_2 a_T$$

Tercera predicción, para tres períodos adelante, $\ell = 3$:

$$Y_{T+3} = \delta + \phi Y_{T+2} + a_{T+3} - \theta_1 a_{T+2} - \theta_2 a_{T+1}$$

$$Y_T(3) = E_T[Y_{T+3}] = E_T[\delta + \phi Y_{T+2} + a_{T+3} - \theta_1 a_{T+2} - \theta_2 a_{T+1}]$$

$$Y_T(3) = \delta + \phi Y_T(2)$$

Al generalizar el pronóstico para “ ℓ ” períodos adelante, se obtiene la siguiente relación:

$$Y_T(\ell) = E_T[Y_{T+\ell}] = \delta + \phi Y_T(\ell - 1) \quad \forall \ell > 2 \quad (36)$$

En la estructura de la función de predicción, las dos primeras predicciones dependen de la última observación Y_T (parte autorregresiva), y de los últimos errores de predicción un periodo hacia adelante a_T y a_{T-1} (parte medias móviles). Cuando $\ell > 2$, la estructura media móvil, asociada a los errores de ajuste del modelo, no aparece de forma explícita en la función de predicción, y cada nueva predicción, consecutivamente, se va obteniendo de las anteriores siguiendo una regla en cadena marcada por la parte autorregresiva. Esta función se va acercando a la media del proceso, conforme se distancia hacia el futuro. Por tanto, al revisar el comportamiento del pronóstico de un modelo ARMA (1,2) cuando la cantidad de períodos tiende a infinito, se obtiene:

$$\lim_{\ell \rightarrow \infty} Y_T(\ell) = \delta \sum_{i=0}^{\ell-3} \phi^i = \frac{\delta}{1-\phi} = E(Y_t) \quad (37)$$

La ecuación (37) corresponde al valor esperado de predicción considerando " ℓ " períodos adelante, y se denomina **función de predicción** para un modelo autorregresivo y de media móvil, de primer y segundo orden, respectivamente.

A continuación, para construir el intervalo de confianza, se procede a calcular la varianza del error de predicción. Si la ecuación (34) se reescribe en función del operador de retardos, L , se obtiene:

$$(1 - \phi L)Y_t = (1 - \theta_1 L - \theta_2 L^2)a_t \quad (38)$$

Si se reescribe la ecuación (38) en función de la serie temporal de registros Y_t , se obtiene:

$$Y_t = \frac{(1 - \theta_1 L - \theta_2 L^2)}{(1 - \phi L)} a_t = (1 + \psi_1 L + \psi_2 L^2 + \psi_3 L^3 + \dots) a_t \quad (39)$$

Donde:

L : Corresponde al operador de retardos

ϕ : Coeficiente que pondera la estructura autorregresiva, en este caso de primer orden.

θ_1 : Coeficiente que pondera al primer término de la estructura de media móvil

θ_2 : Coeficiente que pondera al segundo término de la estructura de media móvil

ψ_i : Coeficiente que pondera la secuencia infinita de la estructura media móvil.

Por tanto, los coeficientes, o pesos relativos, que ponderan la estructura media móvil infinita para un modelo ARMA (1,2), se definen como sigue:


$$\psi_i \begin{cases} k = 0, \psi_0 = 1 \\ k = 1, \psi_1 = \phi - \theta_1 \\ k = 2, \psi_2 = \phi\psi_1 - \theta_2 = \phi(\phi - \theta_1) - \theta_2 \\ k > 2, \psi_k = \phi\psi_{k-1} \end{cases} \quad (40)$$

Con la determinación de los pesos relativos, φ_i , es posible construir los intervalos de predicción. Como el proceso es estacionario, la amplitud de los intervalos

irá creciendo conforme aumentan los periodos adelante, con una cota máxima definida por $\pm N_{\alpha/2}\sqrt{V(Y_t)}$. La metodología descrita puede extenderse para pronosticar cualquier serie estacionaria que cumpla con las condiciones descritas en esta sección.

3.4.5 *Síntesis del proceso de modelación Box – Jenkins.*

En la sección 3.4 se ha descrito el proceso de modelación que permitirá componer la mejor estimación para representar, y pronosticar, una serie ordenada de datos, que evolucionan consecutivamente conforme avanza el tiempo, es decir, una serie temporal de registros. Dicha serie debe cumplir con las condiciones de estacionariedad, definida por las raíces del polinomio autorregresivo, e invertibilidad, definida por las raíces del polinomio de la estructura media móvil. En ambos casos, para que se cumplan las condiciones, el módulo de las raíces deberá ser menor a la unidad. De este modo, y para resumir el proceso de modelación Box – Jenkins, en la figura 30 se presenta el diagrama de procesos ARIMA.






Figura 30: Diagrama de proceso para la Modelación Autorregresiva y de Medias Móviles (ARIMA)
Fuente: Elaboración propia.

4 Análisis y generación de modelos ARIMA para matriz Gran Alimentadora.

La metodología para generar modelos tipo ARIMA, como se ha mencionado en el apartado anterior, consta de las fases de identificación, estimación, validación y predicción. Como el sensor “Permalog+”, instalado en matriz Gran Alimentadora, genera datos en forma diaria, tanto para la intensidad de ruido como para la variabilidad del mismo, la variable estado de fuga también se generará en forma diaria, resultando un proceso que, en principio, tendrá una periodicidad “s” de siete días. Luego, cuando se hayan recopilado los primeros 365 días de datos, será posible evaluar períodos de treinta días, que no estarán influenciados por el régimen estacional de información.

El objetivo será encontrar el modelo que mejor ajuste la serie original, diferenciando la influencia periódica de siete días, y el comportamiento de periodos contiguos que no guardan directa relación con la forma del muestro, pero que pudiesen influenciar la evolución de la serie. La propuesta es obtener un modelo de la forma ARIMA (p, d, q) x (P, D, Q), donde “p”, “d” y “q” son los órdenes del modelo que definirán la parte regular (no estacional) y “P”, “D” y “Q” representan los órdenes de la parte estacional, es decir, los períodos $s = 7, 14, 21, 28, \dots, 7n$, donde “n” representa la cantidad de períodos estacionales a incluir en el modelo.

En general, si se considera una serie estacional Y_t con periodo “s” conocido –por ejemplo una serie diaria–, es posible subdividirla en 7 subseries, una por cada día, denotándose:

$$y_T^{(1)}, y_T^{(2)}, \dots, y_T^{(7)} \text{ con } T = 1, 2, \dots, N \quad (41)$$

La relación entre las subseries y la serie de partida es:

$$y_T^{(j)} = Y_{j+7(T-1)} = Y_t \quad \text{con } T = 1, 2, \dots, N \text{ con } j = 1, 2, \dots, 7 \quad (42)$$

Donde:

t : En una secuencia ordenada de registros, representa la posición de la observación Y

j : Representa un día de la serie temporal

T : Representa el período donde se observa el día “ j ”

$y_T^{(j)}$: Corresponde a la sub – serie del día “ j ” para un período “ T ”

Y_t : Representa la serie original de registros para cada momento “ t ” observado.

La ecuación (42) muestra claramente que alguna observación de la sub – serie $y_T^{(j)}$ registrada en el día “ j ”, se corresponde con la observación de la serie original Y_t desplazada en un período de siete días.

Luego, cada una de las siete subseries presentadas en la ecuación (41) no tiene un comportamiento estacional, por lo que pueden ser representadas mediante un proceso ARIMA (p, d, q). Entonces, suponiendo que el modelo ARIMA adecuado para las siete subseries $y_T^{(j)}$ es el mismo:

$$(1 - \phi_1 L - \dots - \phi_p L^p)(1 - L)^D y_T^{(j)} = (1 - \theta_1 L - \dots - \theta_q L^q) v_T^{(j)} \quad \text{con } T = 1, 2, \dots, N \quad (43)$$

Donde:

Φ_1 : Término que pondera el primer retardo de la estructura autorregresiva.

Φ_p : Término que pondera el último retardo de la estructura autorregresiva.

L : Operador de retardo de primer orden, que retrasa la serie y_t en un momento.

L^p : Operador de retardo de orden “p”, que retrasa la serie $y_T^{(j)}$ en “p” momentos.

$y_T^{(j)}$: Corresponde a la sub – serie del día “j” para un período “T”.

D : Orden de integración estacional para la serie $y_T^{(j)}$ que representa el número de veces que debe ser diferenciada para volverla estacionaria.

Θ_1 : Término que pondera el primer retardo de la estructura media móvil.

Θ_q : Término que pondera el último retardo de la estructura media móvil.

L^q : Operador de retardo de orden “q”, que retrasa la serie de errores $v_T^{(j)}$ en “q” momentos.

$v_T^{(j)}$: Corresponde a la sub – serie de errores de ajuste del día “j” para un período “T”.

Las siete subseries, que representan cada uno de los días de la semana, se pueden reescribir en función de la serie de partida Y_t . Si se aplica el operador de retardos de

primer orden, L , sobre la sub – serie $y_T^{(j)}$, y se replica la relación propuesta en ecuación (42), se obtiene:

$$Ly_T^{(j)} = y_{T-1}^{(j)} = Y_{j+7(T-2)} = Y_{j-7+7(T-1)} = L^7 Y_{j+7(T-1)} \quad (44)$$

Es decir que, si se retrasa la sub – serie $y_T^{(j)}$ mediante un retardo de primer orden, L , es equivalente a retrasar siete momentos, L^7 , la serie original $Y_{j+7(T-1)}$ para volverla estacionaria.

Además del comportamiento estacional, se debe definir una serie de ruido, o de errores de ajuste, común para las siete subseries, α_t , asignando a cada día el ruido del modelo correspondiente a dicho día. En consecuencia, la serie para el ruido se obtendrá de las siete subseries, $v_T^{(j)}$, de la siguiente manera:

$$v_T^{(j)} = \alpha_{j+7(T-1)} \text{ con } T = 1, 2, \dots, N \quad (45)$$

Por tanto, el modelo final que incluye ambas consideraciones es:

$$(1 - \phi_1 L^7 - \dots - \phi_p L^{7p})(1 - L^7)^D y_T^{(j)} = (1 - \theta_1 L^7 - \dots - \theta_q L^{7q}) \alpha_t \text{ con } T = 1, 2, \dots, N \quad (46)$$

Cada uno de los modelos de las subseries $v_T^{(j)}$ son, por construcción, ruido blanco, no obstante la serie conjunta $\alpha_t, t = 1, 2, \dots, T$ no es necesariamente un ruido blanco, debido a que la mayoría de las veces existirá dependencia entre las observaciones contiguas, esta condición quedará contenida en esta serie de ruido. A esto se le

denomina estructura regular o estructura asociada a los intervalos naturales de medida de la serie (días para el caso en observación). Ahora, suponiendo que la serie α_t sigue el siguiente modelo ARIMA no estacional:

$$\phi_p(L)(1-L)^d \alpha_t = \theta_q(L) a_t \quad \text{con } a_t \sim RBN(0, \sigma^2) \quad (47)$$

Finalmente, tomando la información resultante de las subseries, y cómo estas permiten construir de manera independiente tanto la estructura regular como estacional de la serie conjunta, se presenta el modelo completo para la serie temporal Y_t :

$$\Phi_p(L^s) \phi_p(L) \Delta^d \Delta_s^D Y_t = \theta_q(L) \theta_q(L^s) a_t \quad (48)$$

Donde:

$\phi_p(L)$: Polinomio autorregresivo de la parte denominada regular, o no estacional

$\theta_q(L)$: Polinomio media móvil de la parte denominada regular, o no estacional

d : Orden de integración, o diferenciación consecutiva, que permite dar estacionariedad a la estructura regular, o no estacional, de la serie temporal Y_t . Esta diferenciación se aplica por momentos consecutivos, en este caso por cada día.

$\Phi_p(L)$: Polinomio autorregresivo de la parte denominada estacional

$\theta_p(L)$: Polinomio media móvil de la parte denominada estacional

D : Orden de integración, o diferenciación consecutiva, que permite dar estacionariedad a la estructura estacional de la serie temporal Y_t . Esta diferenciación se aplica por períodos consecutivos, en este caso cada siete días.

Este tipo de modelos, que contemplan el espectro completo de información, que posee una serie tanto en su morfología regular como estacionaria, son denominados ARIMA estacionales multiplicativos, $ARIMA(p, d, q) \times (P, D, Q)_s$, o SARIMA. Es este tipo de modelación, precisamente, el que se utilizará para el análisis de cada locación.

Pues bien, reconocida la implicancia de la procedencia del registro en cuanto a su periodicidad, se procederá a modelar la variable “estado de fuga” perteneciente a la locación Desagüe Santos Ossa, primer sensor del sistema de alertas propuesto.

4.1 Caso: Modelamiento de locación Desagüe Santos Ossa.

El sensor ubicado en Av. Santos Ossa tiene la particularidad de estar emplazado en infraestructura vial de alto tránsito, lo que pudiese implicar algún grado de influencia sobre los niveles de ruido. La serie observada tiene una longitud de 300 registros, comenzando a censarse desde el 18 de octubre del año 2013 hasta el día 26 de septiembre del año 2014. Se decide presentar el desarrollo de la metodología de análisis sobre el comportamiento de esta serie temporal, porque se cumple una continuidad del registro, existe una homogeneidad en la información analizada y se sobrepasa el valor umbral (detallado en sección configuración estándar), establecido por el fabricante hasta por un máximo de 15 [dB] para la emisión de una alerta. En esta sección se presentará el análisis detallado del proceso de modelamiento, comenzando con la etapa análisis de estacionariedad.

4.1.1 Análisis de estacionariedad de la serie temporal correspondiente a locación Desagüe Santos Ossa.

El requisito básico para la implementación de métodos de predicción estadística tipo ARIMA (proceso autorregresivos y de medias móviles), es que la serie de registros analizados sea estacionario conforme evolucione en el tiempo o, en otras palabras, que su media sea constante y la varianza tienda a cero. En cuanto a la varianza, la herramienta primera y más sencilla, es la interpretación de la gráfica de secuencia, que permite observar si la variabilidad es homogénea a lo largo del tiempo. En este caso, los datos de la serie permiten identificar cambios de nivel asociados a tendencias; por tanto, es necesario ajustar los registros mediante una transformación, que permita aminorar este efecto. La serie “estado de fuga”, se construye a partir de la diferencia entre las variables “intensidad de ruido” y “dispersión de ruido”; en consecuencia, el comportamiento individual de alguna de ellas influirá directamente sobre el comportamiento de la variable, que gatilla las alertas del sistema de alerta temprana. A continuación, se presentan las gráficas para la misma data temporal, de las series intensidad de ruido (figura 31), dispersión de ruido (figura 32) y el resultante estado de fuga (figura 33). Precisamente esta última será utilizada para el desarrollo del análisis.




Figura 31: Serie de intensidad de ruido para locación Desagüe Santos Ossa
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0




Figura 32: Serie de dispersión de ruido para locación Desagüe Santos Ossa
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0




Figura 33: Serie de estado de fuga para locación Desagüe Santos Ossa
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

En la figura 33 se observa que la serie desarrolla un componente de tendencia arraigada en la evolución de la variable “intensidad de ruido” (figura 31). Sin embargo, este efecto se ve aminorado con la participación de la “dispersión de ruido” (figura 32). Aun cuando se reconoce el aspecto tendencioso de la serie “estado de fuga”, es aventurado proponer que no es estacionaria únicamente por la lectura de la secuencia del registro; por esta razón, es importante realizar el análisis formal, para determinar si se requiere de alguna transformación que la estabilice, obteniéndose una nueva serie que posea media y varianza constantes en el tiempo. En esta línea es importante analizar el correlograma de la función de autocorrelación simple, FAS.

La figura 34 muestra el lento decaimiento para los retardos periódicos $s = 7, 14, 21$ y 28 . Por otro lado, los retardos no estacionales solamente presentan un coeficiente significativo en el primer retardo, mientras que el resto decrece al punto de

caer dentro del rango de no significancia. Los coeficientes que acompañan al factor de autocorrelación periódico, tanto a derecha como izquierda, dan cuenta de la interacción entre la estructura regular y estacional. Si el proceso que define la parte regular fuese del tipo medias móviles de primer orden, aparecerán a ambos lados del coeficiente estacional un valor distinto de cero. Por el contrario, si fuese un proceso de segundo orden, dos coeficientes estarán a cada lado del factor periódico y el resto de los retardos presentarán un coeficiente nulo. Cuando la parte regular es de tipo autorregresiva, por ejemplo AR (1), los coeficientes, que acompañan al factor de autocorrelación en el retardo estacional, presentarán el decaimiento exponencial propio de un proceso autorregresivo.




Figura 34: Función de autocorrelación para los primeros 30 retardos de serie estado de fuga en locación Desagüe Santos Ossa
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

En la función de autocorrelación obtenida para Desagüe Santos Ossa, presentada en la figura 34, se aprecia que la estructura regular es estacionaria, por ello no requiere de alguna transformación para notar que corresponde a un proceso MA (1). No obstante, cuando se observa el comportamiento de la estructura estacional, se aprecia que no decrece lentamente hacia cero, pudiendo, entonces, plantear la necesidad de

transformar esta parte de la serie para darle estacionariedad. Para corroborar esta idea intuitiva, guiada por la interpretación del correlograma, se utilizará el test de Dickey-Fuller aumentado (ADF). Mediante el software Eviews 6.0¹³ se puede calcular el test de existencia de raíz unitaria (unit root test) para tres posibles modelaciones de la serie original: i. modelo general que incluye una constante, ii. Modelo que incluye constante más tendencia y iii. Ninguna de las dos opciones anteriores. Los resultados se presentan en las tablas 4, 5 y 6.

Tabla 4: Test ADF para estado de fuga en locación Desagüe Santos Ossa, sin incluir constante ni tendencia

		t-statistic	Prob
Augmented Dickey-Fuller test statistic		0,095997	0,7124
Test critical values:	1% level	-2,572878	
	5% level	-1,941910	
	10% level	-1,615976	

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Tabla 5: Test ADF para estado de fuga en locación Desagüe Santos Ossa, incluyendo constante

		t-statistic	Prob
Augmented Dickey-Fuller test statistic		-3,864614	0,0026
Test critical values:	1% level	-3,452519	
	5% level	-2,871195	
	10% level	-2,571986	

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

¹³ Software EVIEWS 6.0: es un paquete estadístico desarrollado para Microsoft Windows, utilizado para análisis estadístico general, y principalmente, para análisis econométrico, como estimación y predicción de modelos de series de tiempo.

Tabla 6: Test ADF para estado de fuga en locación Desagüe Santos Ossa, incluyendo constante y tendencia

		t-statistic	Prob
Augmented Dickey-Fuller test statistic		-12,79033	0,0000
Test critical values:	1% level	-3,989153	
	5% level	-2,424977	
	10% level	-2,135584	

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

El estadígrafo de contraste “t”, presentado en ecuación (7), se compara con los valores críticos tabulados por Dickey – Fuller, DF , debiendo cumplirse que $t \leq DF(\alpha)$. Los valores críticos investigados por Dickey – Fuller fueron tabulados de manera independiente para modelos con y sin constante. Para un modelo sin una constante en su estructura, el estadígrafo de contraste es $t = 0,096$, mientras que el valor tabulado al 5% de significancia para 300 observaciones es de $DF(\alpha) = -1,942$; en consecuencia, no es posible rechazar la hipótesis nula de no existencia de raíz unitaria, entonces la serie no es estacionaria. En caso de que el modelo contenga en su estructura una constante, o constante y tendencia, los valores de “t” son $-3,864$ y $-12,79$ respectivamente, ambos menores al valor crítico obtenido por DF ($-2,87$ y $-2,43$). De este modo, se rechaza la hipótesis nula y se comprueba formalmente que la serie es estacionaria, tanto en media como varianza. En resumen, el test Dickey – Fuller aumentado, ADF, indica que, si un modelo incluye una constante en su estructura, será candidato para representar la evolución de la serie original, lo que no implica que sea el modelo idóneo para el proceso. Por otro lado, desde el correlograma se visualiza que los retardos estacionales no decrecen rápidamente hacia cero, siendo necesario diferenciar la parte estacional en el primer retardo $s = 1$ ó $k = 7$, para darle estacionariedad, quedando la estructura del modelo: ARIMA (p, 0, q) x (P, 1, Q). Las

gráficas de secuencia y el correlograma de la función de autocorrelación simple, para la serie transformada Z_t , se presentan en las figuras 35 y 36, respectivamente.

La figura 35 indica que tanto la media como varianza son estables en el tiempo. La función de autocorrelación, figura 36, muestra claramente que los retardos que influirán en el modelo corresponden al primero y al séptimo. El primero indica que el modelo debe ser de medias móviles para la parte regular, mientras que el séptimo da cuenta de la influencia del retardo estacional para el primer ciclo; como el segundo retardo estacional $s = 2$ decae al rango de no significancia, podemos concluir que el proceso que define la parte estacional es de medias móviles de primer orden, puesto que, decae rápidamente a cero.




Figura 35: Secuencia (1-L7) (Estado de fuga)
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0




Figura 36: Función de autocorrelación (1-L7) (Estado de fuga)
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Por otro lado, la estacionariedad de la serie transformada $Z_t = (1 - L^7)(estado\ de\ fuga)$ queda de manifiesto en las tablas 7, 8 y 9 del test ADF, donde se cumple que el estadístico “*t - statistic*” es menor, en todos los casos, a los valores críticos obtenidos por Dickey – Fuller, por tanto se rechaza la hipótesis nula de existencia de raíz unitaria.

Tabla 7: Test ADF para $(1-L^7)$ (Estado de fuga) en locación Desagüe Santos Ossa, sin incluir constante ni tendencia

	t-statistic	Prob
Augmented Dickey-Fuller test statistic	-5,831681	0,0000
Test critical values:		
1% level	-2,573307	
5% level	-1,941969	
10% level	-1,615937	

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Tabla 8: Test ADF para $(1-L^7)$ (Estado de fuga) en locación Desagüe Santos Ossa, incluyendo constante

	t-statistic	Prob
Augmented Dickey-Fuller test statistic	-5,861461	0,0000
Test critical values:		
1% level	-3,453737	
5% level	-2,871731	
10% level	-2,572273	

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Tabla 9: Test ADF para $(1-L^7)$ (Estado de fuga) en locación Desagüe Santos Ossa, incluyendo constante y tendencia

		t-statistic	Prob
Augmented Dickey-Fuller test statistic		-5,852640	0,0000
Test critical values:	1% level	-3,991412	
	5% level	-3,426073	
	10% level	-3,136231	

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Se concluye que la serie “estado de fuga” puede representarse por un modelo que contenga una constante en su estructura, sin tener que utilizar una transformación, o bien aplicando una diferencia estacional en el primer ciclo, para darle estacionariedad. De este modo, la serie “estado de fuga” es integrada de orden uno ($D=1$) en la parte estacional.

4.1.2 Identificación del modelo que representa la evolución de la serie temporal Desagüe Santos Ossa.

En el proceso de análisis de la estructura de la serie, se pudo concluir que existen dos posibles familias de modelos que permitan reproducir la serie “estado de fuga”. Pues bien, para acotar los modelos que reproduzcan la información, se requiere determinar los órdenes de los procesos de medias móviles y autorregresivos. Para ello se procede a interpretar la función de autocorrelación simple (FAS) y autocorrelación parcial (FACP), analizando el comportamiento tanto para la serie original como transformada.

En la interpretación de los correlogramas, ha de tenerse en cuenta que el patrón que sigue FAS y FACP es distinto para los procesos AR y MA. En el caso concreto de los procesos autorregresivos AR (p), FAS decrece geométrica o exponencialmente y

FACP desaparece después de “p” retardos, presentando “p” coeficientes significativos. En el caso de procesos de medias móviles MA (q) ocurre lo contrario: la función de autocorrelación parcial decrece de forma geométrica o exponencial, y la función de autocorrelación simple se anula para retardos de orden superior a q.

Al analizar los correlogramas FAS (figura 37) y FACP (figura 38), de la serie original, se aprecia que la parte regular, después del primer retardo, decae rápidamente al intervalo de no significancia, por tanto, el proceso que define la parte regular es de medias móviles de primer orden. Esta apreciación se corrobora al hacer lectura de los factores de FACP, ya que en la parte regular se presenta un rápido decaimiento (no nulo) a partir del segundo retardo. En cuanto a la parte estacional de la serie, FAS muestra el lento decaimiento de los factores en los retardos estacionales, lo que es un indicio de la no estacionariedad de la serie; o bien, que el proceso para su modelación debe contemplar que MA (Q) sea de un mayor orden, ya que hasta el cuarto retardo estacional, los factores están fuera del rango de no significancia. Ello se corrobora con FACP, porque después del primer retardo estacional los siguientes factores estacionales caen dentro del rango de no significancia, mas no decrecen de forma acelerada.

Sabiendo que la modelación debe incluir una constante para ser estacionario, es complejo determinar los órdenes de los procesos de medias móviles y autorregresivos, porque la no inclusión de términos en la estructura del modelo, dejará de recoger información relevante en la reproducción del mismo. Por otro lado, basándose en los criterios de información, se establece que el modelo idóneo debe contener el mínimo de parámetros posibles, para describir el comportamiento de la serie. Entonces, el

modelo que ajuste la serie estado de fuga, sin transformación, está compuesto por una constante: su estructura regular es de medias móviles de orden uno, MA (1), y la parte estacional mientras más términos considere tendrá un mejor ajuste. Por tanto la estructura del modelo es ARIMA (0, 0,1) x (0, 0, Q). Más adelante, cuando se comparen los modelos con y sin transformaciones, se verá como mejora el ajuste según la consideración de un orden mayor para MA (Q).




Figura 37: Función de autocorrelación para los primeros 30 retardos de serie estado de fuga en locación Desagüe Santos Ossa
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0




Figura 38: Función de autocorrelación parcial para los primeros 30 retardos de serie estado de fuga en locación Desagüe Santos Ossa
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

La última etapa del proceso de identificación consiste en corroborar si es necesaria la inclusión de un término independiente en la estructura. Para ello se contrasta la hipótesis nula de que la media de la serie original $Y_t = (\text{estado de fuga})$ es cero, mediante el estadígrafo:

$$t = \frac{\bar{Z}}{\hat{\sigma}_z} \quad (49)$$

Donde:

$\bar{Z}$: Media de la serie estacionaria.

$\hat{\sigma}$: Desviación estándar muestral.

Para evaluar la ecuación (49) se utilizan las principales propiedades de la serie “estado de fuga”, presentados en figura 39.




Figura 39: Estadísticos principales de serie $Y_t = (\text{estado de fuga})$
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Primero se calcula el valor de la varianza muestral:

$$\hat{\sigma}_z = \hat{V}(\bar{Z})(1 + 2 * \rho_1 + 2 * \rho_2 + \dots + 2 * \rho_n)$$

$$\hat{V}(\bar{Z}) = \frac{(Std. Dev.)^2}{T^*}$$

$$\hat{\sigma}_z = \frac{(2,86)^2}{300} (1 + 2 * 0,372 + 2 * 0,347) = 0,066$$

Por efectos de cálculo, $\hat{\sigma}_z$ se ha estimado solamente con los rezagos de mayor participación, $\rho_1 = 0.372$ y $\rho_7 = 0.347$. Entonces, al realizar el contraste sobre la hipótesis nula para la media, el valor de “t” es 606,1 ($t = 40/0,066$). Como $606,1 > N_{0,025} \approx 2$ se rechaza la hipótesis nula de que la media del proceso es igual a cero, por tanto se incluye una constante. En consecuencia la estructura del modelo es:

$$ARIMA(0,0,1)X(0,0,1) = (estado de fuga) = \delta + (1 - \theta)(1 - \theta^7)a_t \quad (50)$$

Luego, cargando los registros y la estructura de este modelo al programa estadístico IBM SPSS statistics¹⁴, se obtienen los coeficientes presentados en tabla 10.

Tabla 10: Parámetros del modelo ARIMA para la serie $Y_t = (estado de fuga)$

Estructura ARIMA	Retardo	Estimación	ET	t	Sig.
Sin Transformación	Constante	40,017	0,277	176,126	0,000
MA	Retardo 1	-0,368	0,053	-8,897	0,000
MA	Retardo 7	-0,159	0,054	-2,970	0,000

Fuente: Elaboración propia. Obtenido con software IBM SPSS STATISTICS

¹⁴ IBM SPSS Statistics: es uno de los principales softwares estadísticos que ofrece técnicas de recolección de datos y analítica predictiva. Se destaca por la capacidad de trabajar con bases de datos de gran tamaño. Su arquitectura está compuesta por un módulo base y módulos anexos de características específicas.

Al reemplazar los parámetros calculados, y presentados en tabla 10 en la ecuación (50), se obtiene el **modelo para serie original** Y_t :

$$ARIMA(0,0,1)X(0,0,1) = (\text{estado de fuga})$$

$$(\text{estado de fuga}) = 40,017 + (1 + 0,368L)(1 + 0,159L^7)a_t \quad (51)$$

$$Y_t = 40.017 + a_t + 0.368 * a_{t-1} + 0.159 * a_{t-7} + 0.059 * a_{t-8}$$

Donde:

δ : 40.017, constante del modelo.

θ_1 : 0.368, término que pondera el primer retardo de la estructura regular media móvil.

Θ_1 : 0.159, término que pondera el primer retardo de la estructura estacional media móvil.

θ_8 : 0.059, término que pondera el octavo retardo de la estructura regular media móvil.

Y_t : Serie temporal de registros.

a_t : Serie de errores de ajuste, o ruido blanco, presente en el modelo.

Por otro lado, la segunda familia de modelos propuesto, incorpora el uso de una diferencia (D) sobre el séptimo retardo, para eliminar la dependencia estacional (**serie transformada**). En este caso, el correlograma para la función de autocorrelación simple (ver Figura 40) permite establecer que la serie es estacionaria, porque la estructura regular se trunca inmediatamente después del primer retardo, sin mostrar

influencia significativa de rezagos posteriores, mientras que la estructura estacional también desaparece después del primer retardo estacional. Esta lectura se corrobora con la interpretación de la función de autocorrelación parcial (ver Figura 41), donde la estructura regular decrece aceleradamente y la parte estacional también lo hace luego del primer rezago estacional, mostrando la forma característica de un proceso de medias móviles para ambos casos. En resumen, para la serie transformada $Z_t = (1 - L^7)(estado\ de\ fuga)$ el modelo debe tener la forma ARIMA (0, 0,1) x (0, 1,1)




Figura 40: Función de autocorrelación para los primeros 30 retardos de serie $(1-L^7)$ (estado de fuga) en locación Desagüe Santos Ossa

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0




Figura 41: Función de autocorrelación parcial para los primeros 30 retardos de serie $(1-L^7)$ (estado de fuga) en locación Desagüe Santos Ossa

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Tal como se procedió con el análisis de la serie original, hay que corroborar si es necesario incluir un término independiente en la estructura del proceso. Para ello se contrasta la hipótesis nula, de que la media de la serie transformada $Z_t = (1 - L^7)(estado\ de\ fuga)$ es cero. Para calcular el valor de “t”, primeramente se obtienen las características principales de la serie, que se muestran en la figura 42.

Al incorporar los valores tabulados en el cálculo de la varianza muestral, se obtiene:

$$\hat{\sigma}_z = \hat{V}(\bar{Z})(1 + 2 * \rho_1 + 2 * \rho_2 + \dots + 2 * \rho_n)$$

$$\hat{V}(\bar{Z}) = \frac{(Std.Dev.)^2}{T^*}$$

$$\hat{\sigma}_z = \frac{(3,27)^2}{293} (1 + 2 * 0,253 - 2 * 0,450) = 0,022$$




Figura 42: Estadísticos principales de serie $Z_t = (1-L^7)(estado\ de\ fuga)$
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Por efectos de cálculo, $\hat{\sigma}_z$ se ha estimado solamente con los rezagos de mayor participación, $\rho_1 = 0.253$ y $\rho_7 = -0.450$, resultando $t = 0,053/0,022 = 2,4$. Como

$2,4 > N_{0,025} \approx 2$, se rechaza la hipótesis nula de que la media del proceso es igual a cero, por tanto se incluirá una constante.

En esta etapa de identificación de los órdenes del modelo, se ha logrado llegar a plantear la siguiente estructura:

$$\begin{aligned} ARIMA(0,0,1)X(0,1,1) &= (1 - L^7)(estado\ de\ fuga) \\ (1 - L^7)(estado\ de\ fuga) &= \delta + (1 - \theta L)(1 - \theta L^7)a_t \end{aligned} \quad (52)$$

Al cargar los registros y estructura de este modelo al programa estadístico IBM SPSS Statistics se obtienen los coeficientes desplegados en tabla 11.

Tabla 11: Parámetros del modelo ARIMA para la serie $Z_t = (1-L^7)$ (estado de fuga)

Estructura ARIMA	Retardo	Estimación	ET	t	Sig.
Sin Transformación	Constante	0,073	0,023	3,142	0,002
MA	Retardo 1	-0,323	0,056	-5,792	0,000
MA, estacional	Retardo 1	0,905	0,035	25,691	0,000

Fuente: Elaboración propia. Obtenido con software IBM SPSS STATISTICS

Por tanto, el modelo que ajusta la serie transformada es:

$$\begin{aligned} ARIMA(0,0,1)X(0,1,1) &= (1 - L^7)(estado\ de\ fuga) = Z_t \\ Z_t &= 0,073 + (1 + 0,323L)(1 - 0,905L^7)a_t \end{aligned} \quad (53)$$

$$Z_t = 0,073 + a_t + 0.323 * a_{t-1} - 0.905 * a_{t-7} - 0.29 * a_{t-8}$$

Donde:

δ : 0,073, constante del modelo.

θ_1 : 0.323, término que pondera el primer retardo de la estructura regular media móvil.

Θ_1 : -0.905, término que pondera el primer retardo de la estructura estacional media móvil.

θ_8 : -0.29, término que pondera el octavo retardo de la estructura regular media móvil.

Y_t : Serie temporal de registros.

a_t : Serie de errores de ajuste, o ruido blanco, presente en el modelo.

En resumen, se han encontrado dos modelaciones que permiten representar la serie estado de fuga para la locación desagüe Santos Ossa. Ambos son similares; no obstante, aún se debe evaluar cuál es el idóneo para representar la evolución de la serie en el tiempo, lo que se explicará en la siguiente sección.

4.1.3 Validación del modelo: ¿Cuál es el modelo que representa de mejor manera la evolución de los registros?

Como se explicó anteriormente, en la etapa de validación se debe corroborar estadísticamente, que la estructura de modelación propuesta responda a la correcta forma de reproducir la evolución de la serie. La validación se realiza generando los contrastes individuales para cada coeficiente resultante del análisis. Para analizar los términos que componen la estructura del modelo original. Se comprueba estadísticamente si los coeficientes son significativos, aplicando el contraste de significancia individual bajo las hipótesis $H_0: \theta = 0; \Theta = 0$ y $H_a: \theta \neq 0; \Theta \neq 0$, resultando (ver valores de coeficientes en tabla 11):

Para θ :

$$t = \left| \frac{\hat{\theta}}{\hat{\sigma}_{\theta}} \right| = \left| \frac{-0.368}{0.053} \right| = 6.94 > N_{0,025} \approx 2$$

Se rechaza la hipótesis nula $H_0: \theta = 0$ para un nivel de significancia del 5%, por tanto el coeficiente es estadísticamente significativo.

Para el caso de Θ :

$$t = \left| \frac{\hat{\Theta}}{\hat{\sigma}_{\Theta}} \right| = \left| \frac{-0.159}{0.054} \right| = 2.94 > N_{0,025} \approx 2$$

Se rechaza la hipótesis nula $H_0: \Theta = 0$ para un nivel de significancia del 5%, por tanto el coeficiente es estadísticamente significativo.

Comprobado que ambos términos son estadísticamente significativos, es importante revisar el comportamiento de las raíces unitarias del modelo. Se recuerda que para cumplir con el principio de invertibilidad ninguna de las raíces puede ser mayor a la unidad. Para el análisis de este caso, se presenta la figura 43 y tabla 12, que claramente muestran un proceso no explosivo e invertible, donde el módulo de las raíces del polinomio de media móvil es menor a la unidad.

La representación gráfica que se presenta en la figura 43 muestra que las siete raíces del polinomio de media móvil están íntegramente dentro del círculo unitario, que a su vez representa el límite máximo admisible para considerar que el proceso es invertible. Tal como se definió anteriormente, esta es una condición excluyente para el modelo.




Figura 43: Raíces del polinomio de medias móviles para serie Y_t = (estado de fuga)
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Tabla 12: Raíces calculadas del polinomio de medias móviles para serie Y_t = (estado de fuga)

MA Root (s)	Modulus	Cycle
-0,839206	0,839206	
-0,539947 ± 0,593263 i	0,802187	2,720960
0,123575 ± 0,754525 i	0,754525	4,467960
-0,651969 ± 0,332110 i	0,731684	13,33626

Fuente: Elaboración propia. Obtenido con software IBM SPSS STATISTICS

La etapa de validación culmina evaluando el comportamiento de los residuos del modelo. Se presentan sus gráficas de secuencia y correlograma en las figuras 44 y 45, respectivamente.




Figura 44: Secuencia de los residuos para $Y_t = (\text{estado de fuga})$
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0




Figura 45: Correlograma de FAS de los residuos para $Y_t = (\text{estado de fuga})$, primeros 24 retardos
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

La función de autocorrelación simple (FAS) da cuenta de la influencia de retardos posteriores, que no se han incluido en la estructura del modelo. Esta situación indica la

existencia de información relevante, contenida en los residuos que no ha sido representada en la modelación.

Para evaluar estadísticamente que el comportamiento de los residuos corresponde a un ruido blanco, se utiliza el estadístico propuesto por Ljung-Box (ver ecuación (21)). Entonces, *Se rechazará la hipótesis nula de ausencia de correlación serial, con un nivel de significancia del 5%, para valores grandes del estadístico.* Incorporando los primeros 24 retardos en la evaluación se obtiene $Q^*(M) > X_{0,05}^2(M - p - q) | 41,73 > 33,92$, de este modo existirá correlación serial de los residuos del modelo, lo que significa que **la modelación no es capaz de reproducir el patrón de comportamiento sistemático de la serie.** En consecuencia, es necesario reformular este modelo, proceso que no será tratado en este trabajo.

De forma homóloga, la validación del modelo obtenido para la serie transformada, se comprueba estadísticamente si los coeficientes son significativos, utilizando el contraste de significancia individual, bajo las hipótesis $H_0: \theta = 0; \Theta = 0$ y $H_a: \theta \neq 0; \Theta \neq 0$. En tabla 11 se presentaron las estimaciones de los parámetros correspondientes. Luego, el contraste sobre el parámetro de la estructura regular, θ , es:

$$t = \left| \frac{\hat{\theta}}{\hat{\sigma}_{\theta}} \right| = \left| \frac{-0.323}{0.056} \right| = 5,77 > N_{0,025} \approx 2$$

Se rechaza la hipótesis nula $H_0: \theta = 0$ para un nivel de significancia del 5%, por tanto el coeficiente es estadísticamente significativo

A su vez, el contraste sobre el parámetro de la estructura estacional de medias móviles:

$$t = \left| \frac{\hat{\theta}}{\hat{\sigma}_{\theta}} \right| = \left| \frac{0,905}{0,035} \right| = 25,86 > N_{0,025} \approx 2$$

Se rechaza la hipótesis nula $H_0: \theta = 0$ para un nivel de significancia del 5%, por tanto el coeficiente es estadísticamente significativo.

La figura 46 y tabla 13, permiten establecer que el modelo es invertible, tal como el caso anterior.




Figura 46: Raíces del polinomio de medias móviles para serie $Z_t = (1-L^7)$ (estado de fuga)
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Tabla 13: Raíces calculadas del polinomio de medias móviles para serie $Z_t = (1-L^7)$ (estado de fuga)

MA Root (s)	Modulus	Cycle
0,986344	0,986344	
-0,899698 ± 0,430837 i	0,993261	2,331077
-0,226574 ± 0,967073 i	0,988418	3,488849
-0,612792 ± 0,775535 i	0,986344	6,965159

Fuente: Elaboración propia. Obtenido con software IBM SPSS STATISTICS

Ya se corroboró para el modelo de la serie original, que parte importante de la información, que permite reproducir la estructura intrínseca del modelo, quedó contenida en sus residuos, lo que implica que más adelante se descarte como una opción válida. Este importante análisis también se realiza para la serie diferenciada en el periodo estacional ($s=7$).




Figura 47: Secuencia de los residuos para $Z_t = (1-L^7)$ (estado de fuga)
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0




Figura 48: Correlograma de FAS de los residuos para $Z_t = (1-L^7)$ (estado de fuga), primeros 24 retardos
Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

El correlograma indica que no hay rezagos que contengan información relevante de la serie; en efecto, los 24 primeros están dentro del intervalo de no significancia. En este caso, no existirá correlación serial de los residuos del modelo, y se concluye que **la modelación ha sido capaz de reproducir el patrón de comportamiento sistemático de la serie**, por tanto la evolución de los residuos es del tipo ruido blanco.

Hasta el momento se han evaluado dos modelos, que reproducen la serie de tiempo **estado de fuga** del sensor ubicado en Desagüe Santos Ossa; no obstante, la estructura que representa la serie original sin transformaciones $40,017 + (1 + 0,368L)(1 + 0,159L^7)a_t$ se ajustará de mejor manera cuantos más órdenes contenga su estructura. Por ejemplo, si adicionalmente este modelo considera los rezagos 8, 21, 28, 29 y 35, el ajuste medido por el error cuadrático medio (R^2) mejora de 0,189 a 0,296.

Al comparar ambos modelos en base al error cuadrático medio, aunque se contemplen más términos en la estructura que representa la serie original (Y_t), de igual forma la modelación de la serie transformada (Z_t) tiene un mejor ajuste ($ECMP = 0,449$).

Otro enfoque para la elección del modelo idóneo es evaluar la cantidad de información presente en la estructura del proceso. Algunos criterios para cuantificar el nivel de información fueron propuestos por Akaike (1973,1974), Schwarz (1978) y Hannan-Quinn (1979). La propuesta es evaluar aquellos modelos identificados como válidos bajo un mismo criterio, priorizando aquellos que minimicen el valor de éste. Los resultados, obtenidos con Eviews 6.0, se presentan en las tablas 14 y 15.

Tabla 14: Criterios de información para el modelo $Y_t = (\text{Estado de fuga})$.

Criterion	Value
Akaike info criterion	4,637305
Schwarz criterion	4,736072
Hannan-Quinn criterion	4,676832

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Tabla 15: Criterios de información para el modelo $Z_t = (1-L^7)$ (estado de fuga)

Criterion	Value
Akaike info criterion	4,630418
Schwarz criterion	4,668099
Hannan-Quinn criterion	4,645510

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Este enfoque corrobora que el modelo idóneo para representar la evolución de la serie de registros asociados a la locación Desagüe Santos Ossa corresponde al presentado en la ecuación (53):

$$Z_t = 0,073 + a_t + 0.323 * a_{t-1} - 0.905 * a_{t-7} - 0.29 * a_{t-8}$$

Esta representación, basada en un proceso de medias móviles tanto en la parte regular como estacional, requiere de la menor cantidad de grados de libertad (información) para lograr el mejor ajuste, medido por el error cuadrático medio de predicción, ECMP.

4.1.4 Expansión del análisis y resultados.

El sistema de monitoreo permanente para la detección de fugas en matriz Gran Alimentadora, ha permitido monitorear las variables de intensidad y dispersión de ruido desde el mes de febrero de 2014 en adelante. Sin embargo, el largo de los registro de cada sensor es variable, ya que los equipos no fueron montados ni configurados en el mismo instante. Si bien durante el periodo ha sido posible recabar bastante

información, siempre ha estado presente el problema de discontinuidades de los registros por fallas en la comunicación, lo que implica seleccionar para el análisis muestras que permitan atribuir las propiedades del modelo a la situación real que experimente la locación en un régimen habitual. Entonces, es razonable generar un criterio que permita discriminar la información que pueda generar un modelo predictivo. La estrategia propuesta se basa en:

1. Para cada serie de registros se seleccionará el rango de datos homogéneos, sin tendencia y sin presencia de datos extremos (outliers).
2. Selección del rango de datos donde haya información tanto para la dispersión de ruido como intensidad de ruido.
3. Mínimo 200 registros a analizar, exceptuando la locación Av. Alemania con Ferrari que se analizará con 195 registros. Disponibles.
4. Metodología Box-Jenkins para el análisis de la serie estado de fuga.
5. Detección de umbral con un nivel de confianza del 95%

La metodología propuesta permitirá filtrar aquella información que no satisfaga los requisitos mínimos para su modelación. Para estos 31 casos, donde se ha acentuado el problema de envío y recepción de información o no se cumple con el tiempo suficiente de instalación, se adoptará un umbral de 15 [dB] como límite que detone una alerta de fuga, es decir, la configuración estándar en condiciones ideales. Evidentemente el hecho de no contar con información que permita generar un modelo coherente representa una debilidad del sistema, pudiendo presentarse leves filtraciones que no serían detectadas con la misma precisión, por ello Esval, desde el año 2017,

trabaja en la adquisición de antenas GPRS con mejor cobertura, y en la reasignación de proveedores de servicios de comunicación.

Por otro lado, para las otras nueve locaciones, cuyos registros cumplen las condiciones de la estrategia de modelación, ha sido posible determinar el modelo autorregresivo o de medias móviles, ARIMA, que mejor ajusta su comportamiento. En cada uno de estos casos es factible redefinir el umbral de existencia de una fuga, ya que se ha calculado el correcto valor probabilístico al 95% de confianza. Por ejemplo, para el caso del sensor ubicado en Desagüe Santos Ossa se ha determinado el modelo (ver Ecuación 53) y predicción para el primer período, es decir, los primeros siete días a contar del último registro. El umbral, será obtenido entre las siete predicciones del límite superior como el máximo entre ellos, aproximado a su entero menor, en este caso corresponde al registro 271 con límite superior de 45 [dB].

En la figura 49 y tabla 16 se presenta el pronóstico del primer periodo para esta locación. La gráfica presenta en color azul el límite superior de la predicción, mientras que en color rojo se muestra su límite inferior.




Figura 49: Pronóstico para la serie correspondiente a locación Desagüe Santos Ossa
Fuente: Elaboración propia. Obtenido con software IBM SPSS STATISTICS

Tabla 16: Primer período pronosticado para serie de Desagüe Santos Ossa

Data	Lim Inf	Predict	Lim Sup
267	36,40192	40,2635	44,12508
268	34,29196	38,23605	42,18015
269	33,61459	37,55868	41,50278
270	37,23274	41,17684	45,12094
271	38,02932	41,97342	45,91752
272	37,98327	41,92737	45,87147
273	37,26761	41,21165	45,1557

Fuente: Elaboración propia. Obtenido con software EVIEWS 6.0

Por tanto, para este tramo de la tubería no es recomendable utilizar el sensor en su formato estándar, ya que generará una alerta por encontrarse el valor medio de los registros sobre los 15 [dB], siendo que es su comportamiento habitual. De este modo al analizar la serie de registro del sensor ubicado en desagüe Santos Ossa, es necesario reasignar un nuevo valor de 45 [dB] que detone la condición de alerta por una fuga, para eliminar algún “falso positivo”. En la figura 50 se muestra la gráfica compuesta entre la serie de registros para la serie “estado de fuga” y su umbral.




Figura 50: Umbral al 95% de confianza para la serie Desagüe Santos Ossa
Fuente: Elaboración propia. Obtenido con software IBM SPSS STATISTICS

En tabla 17 se presenta la estructura del modelo ARIMA, el criterio de información Akaike, AIC, y el rango de confiabilidad, donde el límite superior corresponde al umbral, para cada una de las locaciones modeladas.

Tabla 17: Modelos, resultado del análisis

Locación	Modelo ARIMA	AIC	Umbral
01_Desagüe Santos Ossa	SARIMA(0,0,1)x(0,1,1) ₇	1111	[41, 45]
02_Ventosa Los Ingleses	SARIMA(1,0,2)x(0,1,1) ₇	2131	[03, 10]
06_Lamar con Ramaditas	SARIMA(1,0,1)x(1,1,1) ₇	1801	[-01,05]
10_Ventosa Troncoso	SARIMA(1,0,0)x(0,1,1) ₇	0333	[08, 17]
11_Ventosa Padre Febres	ARIMA(1,0,1)	1595	[03, 15]
26_Av. Alemania con Ferrari	SARIMA(1,0,0)x(0,1,1) ₇	0995	[08, 17]
28_Av. Alemania con G. Rivera	SARIMA(1,0,2)x(0,1,1) ₇	1150	[-05,00]
30_Av. Alemania con Israel	SARIMA(0,0,1)x(0,1,1) ₇	2054	[-03,07]
39_Subida Toro (altura camino cintura)	SARIMA(0,0,1)x(0,1,1) ₇	1121	[-03,03]

Fuente: Elaboración propia. Obtenido con software IBM SPSS STATISTICS

Los umbrales que han resultado del análisis muestran la clara necesidad de modificar sus valores, de hecho solamente el sensor ubicado en la posición 11, que corresponde a Ventosa Padre Febres, mantiene el valor de 15 [dB]. En los ocho casos restantes el umbral superior cambia, siendo mayor a 15 [dB] en tres oportunidades permitiendo eliminar falsos positivos, mientras que en los cinco sensores restantes se logra mejorar la precisión del sistema de monitoreo.

Desde el punto de vista de la estructura de los modelos, en seis de ellos hay una dependencia de la historia de los registros (parte autorregresiva), ya sea en la parte regular o estacional. Mientras que las restantes tres estructuras están construidas únicamente por una composición lineal del ruido blanco existente en esas series (parte de medias móviles). Por último, es importante notar que ocho de los nueve modelos presentados han sido diferenciados en el séptimo retardo, mostrando una dependencia estacional, como era presumible porque se trata de una muestra diaria. Es posible que esta condición se relacione con el consumo de agua potable, cuyos registros también son estacionales, aunque para afirmarlo se debe realizar un análisis que no está contemplado en esta memoria.

En definitiva, el hecho de precisar el valor de los umbrales, adecuándolos al comportamiento particular de cada uno, permite mejorar considerablemente el grado de precisión, ya que son definidos en base al menor valor probable de un período de predicción (siete valores pronosticados) con un nivel de confianza del 95%. Por el contrario, es necesario modelar las 31 locaciones restantes para mejorar su grado de precisión, y examinar aquellos casos que estén influenciados por una fuente constante de ruido, que se traducirá en un “falso positivo” con un indicador del estado de fuga mayor a 15 [dB].

5 Experiencia de uso del sistema de monitoreo reconfigurado.

El sistema para la detección de fugas se ha implementado de manera parcializada, desde comienzos del año 2014 hasta principios del año 2015; sin embargo, durante los años 2015 y 2016 se han resuelto incidentes habituales desde el punto de la comunicación, mantenimiento del equipamiento, y reinstalaciones bajo un formato estandarizado. La mejora continua de esta iniciativa va en directa relación con las transformaciones técnicas y culturales que ha implementado Esva para el control activo de pérdidas de agua potable, aumentando los niveles de inversión en este tipo de iniciativas. Por ejemplo, los dispositivos han tenido que adecuarse a los continuos cambios que vive el sector de telecomunicaciones, migrando desde sistema 2G a 3G. Se han importado también antenas especializadas para los sistemas de telemetría GPRS, y existe una continua supervisión y análisis del comportamiento de los sensores. Afortunadamente la transformación cultural en este ámbito, que hace un llamado a mejorar las prácticas de mantenimiento preventivo a costa del correctivo, ha sido apoyada por los **casos de éxito** identificados por esta herramienta. Como su implementación se realizó sobre una tubería en operación, durante el proceso de instalación y posterior monitoreo, pese a que no se encontraron filtraciones en el cuerpo de la tubería, igualmente fue posible detectar eventos puntuales que permitieron generar credibilidad al interior de los equipos de mantenimiento de redes de Esva. Las incidencias reportadas corresponden a filtración en una derivación para distribución de agua potable, arranques filtrando tras el gran incendio que azotó a la ciudad de Valparaíso el sábado 12 de abril de 2014, y una fuga no visible correspondiente a un

arranque mal sellado. A continuación se explicarán las situaciones descritas, presentando la situación previa y post reparación de las incidencias.

5.1 Caso: Rotura en arranque, Av. José Tomás Ramos con calle Estanque, Valparaíso.

Este evento se registró el día 5 de junio de 2014. Mediante el monitoreo periódico de los sensores se detecta una abrupta alza en los niveles de ruido de la locación N° 36 Tomás Ramos con Miranda.



Figura 51: Locación N° 36 Tomás Ramos con Miranda
Fuente: Elaboración propia.




Figura 52: Registros de presión, intensidad de ruido y dispersión de ruido para locación N°36, año 2014.
Fuente: Servidor Empresa Halma Water Management.

Como se indica en la figura 52 la alerta se registra a las 05:00 a.m., justamente en el primer intento de comunicación entre el equipo Multilog LX-GPRS y el servidor que aloja los registros actualizados hasta las últimas ocho horas, incluyendo el periodo de escucha nocturna entre las 02:00 a.m. y las 04:00 a.m. del 5 de junio de 2014.

Un primer incremento eleva los niveles de ruido y dispersión desde (19 [dB], 4 [dB]) hasta (27 [dB], 7 [dB]). El indicador de existencia de fuga aumentó desde 15 [dB] hasta 20 [dB], activándose la alerta ($20 \text{ [dB]} > 15 \text{ [dB]}$). Luego, para el día 9 de julio de 2014 se desarrollan los máximos niveles (33 [dB], 8 [dB]), e indicador de fuga de 25 [dB]. El efecto neto fue un aumento de 10 [dB].

La situación expuesta fue corroborada en terreno por personal de redes y por el equipo de detección de fugas de Esval, quienes detectan una filtración de un arranque ubicado a 100 [m] aguas abajo de este sensor.

Una vez reparada la tubería los registros vuelven a la normalidad, como lo evidencia el siguiente gráfico:




Figura 53: Registros de presión, intensidad de ruido y dispersión de ruido para locación N°36, después de reparación, año 2014.
Fuente: Servidor Empresa Halma Water Management.

Puede notarse que la intensidad de ruido (curva amarilla) se estabiliza en torno a los 9 [dB], y la condición de alerta ya no se cumple (estado de fuga ≤ 15 [dB]).

5.2 Caso: Fugas en arranque provocadas por incendio.

El segundo caso en análisis corresponde a fugas en arranques provocadas por el incendio declarado el 12 de abril de 2014 en ciudad de Valparaíso. Los eventos fueron detectados por el *Logger* N°11 ubicado en Padre Febres.



Figura 54: Locación N° 11 Padre Febres
Fuente: Elaboración propia.




Figura 55: Registros de intensidad de ruido y dispersión de ruido para locación N°11, año 2014.
Fuente: Servidor Empresa Halma Water Management.

Según la gráfica de la figura 55 la alerta se gatilló a las 05:00 a.m. del día 13 de abril, que representa el primer intento de comunicación entre el *logger* y el servidor, incluyendo el periodo de escucha nocturna entre las 02:00 a.m. y las 04:00 a.m.

El primer aumento en los registros muestra un incremento en los niveles de ruido y dispersión desde (15 [dB], 9 [dB]) hasta (40 [dB], 8 [dB]), por tanto el indicador de fuga pasa desde 6 [dB] a 32 [dB], activándose la alerta (32 [dB] > 15 [dB]). Luego, para el día 20 de abril de 2014 se desarrollan los máximos niveles (47 [dB], 9 [dB]), y el indicador en 38 [dB]. Por tanto, el efecto neto es un aumento de 32 [dB].

La situación expuesta no corresponde a un evento que acontece directamente sobre la matriz “Gran Alimentadora”, sino a la filtración en arranques colindantes a la locación denominada Padre Febres. Personal de redes trabajó *in situ* para reparar las filtraciones, hecho consumado el 22 de abril donde los niveles de ruido vuelven a la normalidad.




Figura 56: Trabajos de reparación de fugas producto del incendio
Fuente: Elaboración propia.

5.3 Caso: Fuga en arranque mal sellado.

El tercer y último incidente corresponde a un arranque sin uso, mal sellado. Se detectó gracias al *Logger* N°16 ubicado en Avenida Alemania con Santa Teresa.



Figura 57: Locación N° 61 Santa Teresa
Fuente: Elaboración propia.




Figura 58: Registros de intensidad de ruido y dispersión de ruido para locación N°16, año 2016
Fuente: Servidor Empresa Halma Water Management.

En la figura 58 se aprecia una importante reducción de la intensidad de ruido cuando se reparó la fuga del arranque. Tras la reparación se aprecia un cambio en los niveles de intensidad y dispersión de ruido desde (44 [dB], 7 [dB]) hasta (25 [dB], 15 [dB]), es decir, un cambio neto del indicador de fuga de 27 [dB]. En consecuencia el sistema no genera una alerta, ya que el estado actual del indicador de 10 [dB] no supera el valor umbral de 15 [dB].



Figura 59: Fuga de arranque mal sellado.
Fuente: Elaboración propia.

Conclusiones.

El trabajo desarrollado en esta memoria para optar al título de ingeniero civil, ha permitido conceptualizar e implementar un sistema de monitoreo permanente de detección de fugas para la matriz Gran Alimentadora, una de las principales tuberías de distribución de agua potable de la Región de Valparaíso. Para dar cumplimiento al objetivo de establecer una herramienta con estas características, se instrumentaron 40 puntos de control, dotados de un sensor que permite captar las variables de intensidad y dispersión de ruido, y un *datalogger* con la capacidad de conectarse a un servidor web a través del sistema de transferencia de datos GPRS. Tanto el montaje de los puntos de monitoreo, su configuración primaria y su re – parametrización, forman parte del aporte de esta memoria de título para la implementación del sistema de monitoreo permanente que actualmente posee Esval S.A.

La herramienta desarrollada permite que el Departamento de Mantenimiento de Redes sea notificado diariamente acerca de las posibles filtraciones que pudiesen provocarse sobre la tubería en operación, incorporando la oportunidad de anticiparse a un evento de rotura, posicionando a Esval S.A. como una empresa pionera en esta materia dentro del sector sanitario.

Si bien el sistema implementado tiene originalmente una finalidad preventiva, esta característica se ha potenciado a través de la inclusión de la estadística para el modelamiento de datos, siendo éste el principal aporte de esta investigación. La incorporación de modelos estadísticos autorregresivos integrados y de media móvil, ARIMA, ha dado un carácter de precisión y eficacia que optimiza la detección de fugas,

principalmente no visibles, proporcionando una herramienta para la toma de decisiones. Como vimos en el apartado *Generación de modelos, expansión del análisis*, nueve locaciones instrumentadas permitieron generar una modelación estadística capaz de pronosticar eventos futuros –con un 95% de confiabilidad–, una significativa evolución del sistema para dichos casos. Por ejemplo, ocho locaciones sufrieron una variación importante respecto al umbral estandarizado por el fabricante, mientras que solamente un sensor mantiene un umbral de 15 [dB] para la alerta de fuga. Concretamente, para cinco de los nueve sensores se tuvo que reasignar un umbral bajo los 15 [dB], mientras que en tres de ellos la reasignación fue mayor al definido por el proveedor. La primera reconfiguración proporciona una mayor sensibilidad, generando la posibilidad de encontrar fugas que anteriormente no hubiesen sido detectadas. Por otro lado, para los tres sensores donde el umbral de corte supera los 15 [dB], de no haberse redefinidos estarían constantemente notificando una situación de anormalidad, puesto que el ruido ambiente del punto de control es mayor al estándar, pudiendo generar esfuerzos innecesarios a nivel económico, y una pérdida de credibilidad por parte del Departamento de Mantenimiento de Redes, situación sumamente adversa para la internalización de este sistema dentro de las prácticas habituales de la empresa.

Pese a la complejidad de insertar este tipo de metodologías preventivas dentro de la cultura empresarial, orientada por años a la mejora continua del mantenimiento correctivo, las fugas no visibles que han sido detectadas por el sistema han permitido generar credibilidad dentro de la cadena de mando para la toma de decisiones,

adoptando su uso como una oportunidad de mejora y optimización para la reparación de eventos que pudieron haberse tornado críticos.

A su vez, el escenario propuesto por la SISS bajo la instrucción ORD. N° 2865/2016, insta a mejorar las prácticas de mantenimiento y vigilancia continua de las grandes conducciones. Esval, consiente de la relevancia de esta materia, y con el conocimiento adquirido en la implementación del sistema de monitoreo permanente para la detección de fugas en Matriz Gran Alimentadora, ya trabaja en su expansión y mejora. A propósito, para probar las nuevas tecnologías presentes en el mercado internacional, se ha instrumentado la tubería denominada Cañería de Alta, a la altura de la calle Simpson en Cerro Polanco, por medio de dos equipos hidrófonos que, a diferencia de los sensores actuales, tienen un alcance de unos 800 [m] lineales desde su punto de conexión, tanto aguas arriba como aguas abajo, ya que son instalados en contacto con la columna de agua. De este modo, permiten grabar un archivo de audio para la identificación de anormalidades, que a su vez proporciona la capacidad de realizar una correlación acústica desde un centro de control operacional, minimizando aún más los tiempos de detección de fugas. Además, registra las variables de intensidad y dispersión de ruido durante todo el día, permitiendo realizar un perfil horario, y no solamente diario como ocurre con el actual sistema de monitoreo, lo que se traduce en la posibilidad de generar notificaciones de alerta con una mayor frecuencia. Con esta nueva herramienta se visualiza una expansión del mantenimiento preventivo a gran nivel, ya que por primera vez se cuenta con una línea base del nivel de ruido que

experimenta la tubería en operación, lo que permitirá disminuir los tiempos de reacción y reparación, que va en directo beneficio de sus usuarios.

Referencias.

- Arce, P. R., & Mahia, P. R. (2001). *Modelos Arima*. Madrid: Universidad Autónoma de Madrid.
- biobiochile. (12 de 04 de 2014). *Zona de catástrofe por incendio en Valparaíso: más de 500 casas consumidas y 3 mil evacuados*. Obtenido de Zona de catástrofe por incendio en Valparaíso: más de 500 casas consumidas y 3 mil evacuados: <http://www.biobiochile.cl/noticias/2014/04/12/incendio-forestal-se-registra-en-camino-la-polvora-en-valparaiso.shtml>
- Box, G., & Jenkins, G. (18 de Marzo de 1976). *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day. Obtenido de Modelo Autorregresio Integrado de Media Móvil: https://es.wikipedia.org/wiki/Modelo_autorregresivo_integrado_de_media_m%C3%B3vil
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series With a Unit Root. En D. A. Dickey, & W. A. Fuller, *Distribution of the Estimators for Autoregressive Time Series With a Unit Root* (págs. 427-431). Taylor and & Francis Ltd. en nombre de American Statistical Association.
- González, M. P. (2009). Análisis de series temporales: Modelos ARIMA. En M. P. González, *Análisis de series temporales: Modelos ARIMA* (pág. 46). País Vasco: Sarriko-On.

González, M. P. (2009). *Análisis de Series Temporales: Modelos Arima*. País Vasco: Sarriko-On.

Gutermann. (24 de 07 de 2016). *Mejorando la eficiencia con monitoreo permanente de fugas*. Obtenido de Mejorando la eficiencia con monitoreo permanente de fugas: <http://es.gutermann-water.com/experiencia/estudio-de-casos/zonescan/global-incrementando-la-eficiencia-con-monitoreo-permanente-de-fugas/>

Halma Water Management. (24 de 04 de 2016). *Hwm online*. Obtenido de Hwm online, customer login: <https://www.hwmonline.com/>

Mejoras Energéticas. (2016). *Mejoras Energéticas*. Obtenido de Mejoras Energéticas: <http://www.mejoras-energeticas.com/>

Ministerio de planificación y cooperación. (1997). *Reducción de pérdidas en sistemas de agua potable*. Santiago: MIDEPLAN.

SISS. (2014). *Informe de Gestión del Sector Sanitario, página 88*. Santiago de Chile: LOM.

SISS. (2015). *Informe de Gestión del Sector Sanitario, página 105*. Santiago de Chile: LOM.

SISS. (27 de 03 de 2016). *Cobertura histórica del sector Sanitario*. Obtenido de Cobertura histórica del sector Sanitario: <http://www.siss.gob.cl/577/w3-article-3683.html>

Trabajos de estadística y de investigación operativa. (1981). Criterios de selección de modelos ARIMA. En D. P. Rivera, & G. A. Tovar, *Criterios de selección de modelos ARIMA* (págs. 70-93).

Universidad de Granada. (2011). En F. F. Díaz, *Selección de modelos mediante criterios de información en análisis factorial. Aspectos teóricos y computacionales* (págs. 49 - 64). Granada: Departamento de Estadística, Universidad de Granada.

Universidad de Valencia. (14 de 01 de 2018). *Método de máximo - verosimilitud*.
Obtenido de Estimadores de máximo - verosimilitud:
<https://www.uv.es/ceaces/tex1t/4%20estimacion/emv.htm>

Anexos.

Tabla: Válvulas de corte.

Designación	Características Válvulas de Corta					Observación
	Ubicación Km	Cota de terreno msnm	Cota de Radier msnm	Diámetro mm	Tipo	
Válvula de Corta VC1	0,0000	172,02	168,66	600	Compuerta	Filtración por el vástago, Válvula muy antigua.
Válvula de Corta VC2	2,4530	124,94	122,99	500	Compuerta	Con by-pass de 125 mm. Válvula muy antigua
Válvula de Corta VC3	5,5051	129,34	127,44	500	Compuerta	En esta cámara además existen 2 ventosas. Válvula muy antigua
Válvula de Corta VC4	6,9601	114,69	112,79	Sin información	Cámara inundada, válvula nueva, instalada en septiembre de 2009.	
Válvula de Corta VC5	8,4629	106,07	104,17	500	Compuerta	Con by-pass de 125 mm Válvula muy antigua

Fuente: Estudio de vulnerabilidad de matriz Gran Alimentadora, GSI, 2009-2010.

Tabla: Ventosas.

Designación	Ubicación Km	Cota de Terreno msnm	Cota de radier msnm	DN de la conexión [mm]	Ventosa Tipo	Marca	PN	Diámetros (mm y pulgadas)
Ventosa V1	0,9125	35,58	33,63	150	Triple Efecto	ARI	16	150 y 3/4 pulg
Ventosa V2	1,3962	91,56	89,61	75	Triple Efecto	ARI	16	50
Ventosa V3	1,5279	113,82	111,87	150	Triple Efecto	ARI	16	150y 3/4 pulg
Ventosa V4	1,5310	113,82	111,87	100	S/I	ACMO	16	80 y 3/4 pulg
Ventosa V5	2,4567	124,99	123,04	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V6	2,4592	124,99	123,04	80	Triple Efecto	ARI	16	80 y 3/4 pulg

Ventosa V7	2,5683	120,65	118,70	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V8	3,0603	90,17	88,22	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V9	3,2509	100,94	99,04	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V10	3,4394	100,47	98,57	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V11	3,5310	105,11	103,21	100	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V12	3,6373	104,92	103,02	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V13	3,7855	122,93	121,03	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V14	3,8909	122,12	120,22	100	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V15	5,1200	124,13	122,23	80	Triple Efecto	ARI	16	100 y 3/4 pulg
Ventosa V16	5,4977	129,60	127,70	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V17	5,4996	129,60	127,70	150	Triple Efecto	ARI	16	150 y 3/4 pulg
Ventosa V18	6,9600	114,69	112,79	S/I, cámara inundada				
Ventosa V19	7,2620	114,43	112,53	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V20	8,1680	75,92	74,02	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V21	8,1700	75,92	74,02	80	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V22	9,6249	143,47	141,57	50	Triple Efecto	ARI	16	80 y 3/4 pulg
Ventosa V23	10,0349	140,65	138,75	80	Triple Efecto	ARI	16	50

Fuente: Estudio de vulnerabilidad de matriz Gran Alimentadora, GSI, 2009-2010.

Tabla: Desagües.

Designación	Características de los Desagües				Observación
	Ubicación km	Cota de Terreno msnm	Cota de Radier msnm	Diámetro de la Tubería y válvula mm	
Desagüe D1	0,8873	36,57	34,62	100	Cámara Sucia. Válvula muy antigua.
Desagüe D2	2,1082	23,87	21,92	200	
Desagüe D3	3,0952	81,26	79,31	150	Cámara nueva.

Desagüe D4	4,1325	95,25	93,35	Sin información	Cámara con tierra, solo es visible el volante de la válvula. No se aprecia diámetro de la válvula
Desagüe D5	6,8250	115,47	113,57	200	
Desagüe D6	8,8200	33,09	31,19	200	Cámara Sucia

Fuente: Estudio de vulnerabilidad de matriz Gran Alimentadora, GSI, 2009-2010.

Tabla: Ramales de distribución.

Designación	Características de los Ramales de distribución				Observación
	Ubicación Km	Cota de Terreno msnm	Cota de Radier msnm	Diámetro de la Tubería mm	
Ramal R1	1,3961	91,56	89,61	250	Cámara sucia
Ramal R2	1,6738	105,30	103,35	100	
Ramal R3	2,4700	125,19	123,24		Sin información, cámara embancada
Ramal R4	2,6330	101,81	99,86	200	
Ramal R5	3,0570	96,54	94,59	100	
Ramal R6	3,2509	100,94	99,04	100	
Ramal R7	3,4356	100,30	98,40	200	Cámara sucia e inundada
Ramal R8	4,1300	95,38	93,48		Sin información, cámara embancada
Ramal R9	4,5648	110,86	108,96		Sin información, caja B-22
Ramal R10	4,9056	106,17	104,27	100	Cámara embancada
Ramal R11	5,4976	129,60	127,70		Sin catastrar
Ramal R12	5,8134	126,86	124,96		Sin información, cámara embancada
Ramal R13	5,9634	126,83	124,93	100	
Ramal R14	6,0620	126,67	124,77		Sin información, cámara embancada
Ramal R15	6,2260	125,53	123,63	150	Cámara embancada
Ramal R16	6,6500	120,65	118,76		Sin información, caja B-22
Ramal R17	6,8300	115,43	113,53		Sin información, caja B-22
Ramal R18	7,0800	111,68	109,78		Sin catastrar

Ramal R19	7,6650	110,87	108,97	250	Cámara embancada
Ramal R20	7,9129	97,70	95,80	100	
Ramal R21	8,2017	70,24	68,34		Sin información, cámara embancada
Ramal R22	8,4628	106,07	104,17		Sin catastrar
Ramal R23	9,2769	95,45	93,55	100	
Ramal R24	9,4613	118,71	116,81		Sin información, válvula embebida en hormigón
Ramal R25	10,0348	140,65	138,75	250	
Ramal R26	10,1475	137,83	135,88		Sin información, cámara embancada
Ramal R27	10,3746	129,64	127,74		Sin catastrar

Fuente: Estudio de vulnerabilidad de matriz Gran Alimentadora, GSI, 2009-2010.

Tabla: Grifos.

Designación	Ubicación km	Cota de Terreno msnm	Cota de Radier msnm
Grifo G1	1,6669	105,97	104,02
Grifo G2	3,0567	96,51	94,56
Grifo G3	3,5688	105,04	103,14
Grifo G4	3,6372	104,92	103,02
Grifo G5	3,8420	129,04	127,14
Grifo G6	4,7900	107,89	105,99
Grifo G7	4,7901	107,89	105,99
Grifo G8	4,8900	105,94	104,04
Grifo G9	5,4245	130,03	128,13
Grifo G10	5,6111	121,73	119,83
Grifo G11	5,6112	121,73	119,83
Grifo G12	5,9566	126,78	124,88
Grifo G13	5,9567	126,78	124,88
Grifo G14	6,23242	125,27	123,37
Grifo G15	7,1283	112,65	110,75
Grifo G16	7,6651	110,87	108,97
Grifo G17	7,93	96,80	95,80
Grifo G18	9,7415	140,69	138,79
Grifo G19	10,3224	132,83	130,93

Fuente: Estudio de vulnerabilidad de matriz Gran Alimentadora, GSI, 2009-2010.

Tabla: Medición de espesores realizados por empresa ICI (1986).

Punto de Medición	Ubicación	Km	Espesores (mm)			
			longitudinal		Transversales	
			Valores	Promedio	Valores	Promedio
A	Llegada tubería a Avda. Santos Ossa	0,290	6,0	5,92	6,0-6,0-5,9	5,96
			5,8		6,0-6,0-5,8	
			6,0		6,0-5,9-5,9	
			5,8		6,0-6,0-6,0	
B	Ramaditas 784 (con Lamar)	1,396	6,0	5,95	6,0-5,9	5,95
			5,9			
C	Subida Troncoso a 100m de Sta. Elena	2,225	8,0	7,93	7,8-7,8	7,80
			7,8			
			8,0			
D	Av. Alemania con subida Anticlea (370)	2,650	6,0	5,93	6,0-5,8	5,90
			5,8			
			6,0			
E	Blanquillo a 50m Camino Cintura	8,852	7,7	7,7	7,7-7,7	7,70
			7,7			
F	Blanquillo	8,882	7,7	7,77	7,7-7,8	7,75
			7,9			
			7,7			
G	Blanquillo	8,902	7,7	7,80	7,8-7,9	7,85
			7,9			
			7,8			

Fuente: Análisis de vulnerabilidad conducción Gran Alimentadora Valparaíso, IFARLE, 2011

Tabla: Medición de espesores realizados por empresa INVAR (2005).

Punto de Medicion	Ubicación	Km	Diametro Nominal (mm)	Espesores medidos (mm)			
				Registro 1	Registro 2	Registro 3	Promedio
1	Llegada tubería a Avda Santos Ossa	0,2900	750	6,00	5,90	5,90	5,93
2	Ramaditas 784 (con Lamar)	1,3960	750	5,70	6,05	5,85	5,87
3	Subida Troncoso a 100m de Sta. Elena	2,2250	750	5,30	6,05	5,85	5,73
4	Callejón Febres con calle La Virgen	2,4700	750	6,00	5,95	6,00	5,98
5	Av. Alemania con subida Anticlea	2,6500	750	-	-	-	-
6	Quebrada Lourdes	3,2000	700	5,95	6,00	5,95	5,97
7	Av. Alemania N° 8858	2,8500	700	6,80	6,70	6,60	6,70
8	Av Alemania con Baquedano	5,4000	700	6,00	6,00	6,00	6,00
9	Blanquillo	8,6250	700	7,00	6,95	7,05	7,00
10	Subida Toro	9,1000	700	5,85	5,95	5,85	5,88

Fuente: Análisis de vulnerabilidad conducción Gran Alimentadora Valparaíso, IFARLE, 2011

Tabla: Primera medición de espesores realizados por empresa IFARLE (2011).

Punto de Medicion	Ubicación	Km aproximado	Diametro Nominal (mm)	Espesores medidos (mm)		
				mínimo	máximo	Promedio

1	Washington, cámara entre N°1201 y 1203	1,3500	750	6,10	6,80	6,40
2	Lamar frente N° 141	1,4500	750	4,90	6,50	6,00
3	Lamar con Ramaditas	1,5850	750	5,60	6,30	6,10
4	Punto eliminado por condiciones terreno	-	-	-	-	-
5	Subida Troncoso frente al N°55	2,3000	750	5,30	6,40	5,70
6	Subida Troncoso frente al poste N°87552	2,3500	750	6,40	6,80	6,70
7	Padre Febres esq. La Virgen	2,4600	750	5,80	6,30	6,20
8	Pajonal esq. Talcuen	2,5200	750	5,60	6,20	5,80
9	Av. Alemania esq. Ferrari (junto Válvula VC4)	5,4900	700	6,00	6,30	6,10
10	Punto eliminado por condiciones terreno	-	-	-	-	-
11	Miranda esq. Balmes frente poste N° 108442	8,3700	700	6,20	7,40	7,00
12	Balmes frente hogar de niños	8,4400	700	7,10	7,40	7,30
13	Santos Tornero entre casa 245 y Palazuelos	9,5500	700	6,00	6,20	6,10
14	Pacífico frente N° 262	10,0500	700	6,20	6,50	6,30
15	Pacífico frente N° 316	10,1200	700	5,90	6,40	6,10

Fuente: Análisis de vulnerabilidad conducción Gran Alimentadora Valparaíso, IFARLE, 2011

Tabla: Segunda medición de espesores realizados por empresa IFARLE (2011).

Punto de Medición	Ubicación	Km aproximado	Diámetro Nominal (mm)	Espesores medidos (mm)		
				mínimo	máximo	Promedio
1	Washington, cámara entre N°1201 y 1203	1,3500	750	5,40	6,10	5,94
2	Lamar frente N°141	1,4500	750	5,50	6,20	5,83
3	Lamar con Ramaditas	1,5850	750	5,60	6,20	5,90
4	Punto eliminado por condiciones terreno	-	-	-	-	-
5	Subida Troncoso frente al N°55	2,3000	750	5,40	5,90	5,73
6	Subida Troncoso frente al poste N°87552	2,3500	750	5,40	6,25	5,81
7	Padre Febres esq. La Virgen	2,4600	750	5,50	6,10	5,78
8	Pajonal esq. Talcuen	2,5200	750	5,55	5,90	5,80
9	Av. Alemania esq. Ferrari (junto Válvula VC4)	5,4900	700	5,95	6,30	6,19
10	Punto eliminado por condiciones terreno	-	-	-	-	-
11	Miranda esq. Balmes frente poste N° 108442	8,3700	700	6,95	7,35	7,11
12	Balmes frente hogar de niños	8,4400	700	7,10	7,50	7,35
13	Santos Tornero entre N° 245 y Palazuelos	9,5500	700	5,95	6,20	6,14
14	Pacífico frente N° 262	10,0500	700	6,15	6,50	6,38

15	Pacífico frente N° 316	10,1200	700	5,50	6,40	6,14
----	------------------------	---------	-----	------	------	------

Fuente: Análisis de vulnerabilidad conducción Gran Alimentadora Valparaíso, IFARLE, 2011

Tabla: Velocidad de corrosión.

Punto de Medición	Ubicación	Km aprox	DN (mm)	Espesores medidos (mm)			e original (mm)	e perdido (mm)	vel corrosión mm/año
				SINCO	CORROTE K	promedio			
1	Washington, cámara entre N° 1201 y 1203	1,3500	750	6,40	5,94	6,17	7,00	0,83	0,018
2	Lamar frente N° 141	1,4500	750	6,00	5,83	5,92	7,00	1,09	0,024
3	Lamar con Ramaditas	1,5850	750	6,10	5,90	6,00	7,00	1,00	0,022
4	Punto eliminado por condiciones terreno	-	-	-	-	-	-	-	-
5	Subida Troncoso frente al N°55	2,3000	750	5,70	5,73	5,72	7,00	1,29	0,028
6	Subida Troncoso frente al poste N°87552	2,3500	750	6,70	5,81	6,26	7,00	0,75	0,016
7	Padre Febres esq. La Virgen	2,4600	750	6,20	5,78	5,99	7,00	1,01	0,022
8	Pajonal esq. Talcuen	2,5200	750	5,80	5,80	5,80	7,00	1,20	0,026
9	Av. Alemania esq. Ferrari (junto Válvula VC4)	5,4900	700	6,10	6,19	6,15	7,00	0,86	0,019
10	Punto eliminado por condiciones terreno	-	-	-	-	-	-	-	-

11	Miranda esq. Balmes frente poste N° 108442	8,3700	700	7,00	7,11	7,06	8,00	0,95	0,021
12	Balmes frente hogar de niños	8,4400	700	7,30	7,35	7,33	8,00	0,68	0,015
13	Santos Torero entre casa 245 y Palazuelos	9,5500	700	6,10	6,14	6,12	7,00	0,88	0,019
14	Pacífico frente N° 262	10,050 0	700	6,30	6,38	6,34	7,00	0,66	0,014
15	Pacífico frente N°316	10,120 0	700	6,10	6,14	6,12	7,00	0,88	0,019

Fuente: Análisis de vulnerabilidad conducción Gran Alimentadora Valparaíso, IFARLE, 2011


Tabla: Emplazamiento de sensores.

Ubicación	Pto	Pk [m]	Tramo	Latitud	Longitud
Salida Estanque Lyon	0	0	Antiguo		
Entrada Santos Ossa	1	250	Antiguo	33° 03'04,58"	71°35'17,28"
Desagüe Santos Ossa	2	900	Antiguo	33°03'04,68"	71°35'37,68"
Ventosa Los Ingleses	3	975	Antiguo	33°03'07,61"	71°35'38,36"
Desagüe Ossandon	4	1100	Antiguo	33°03'11,40"	71°35'11,40"
Mac Iver con Washington	5	1300	Antiguo	33°03'19,12"	71°35'44,64"
Lamar con Ramaditas	6	1550	Antiguo	33°03'24,06"	71°35'49,52"
Federico Costa	7	1870	Antiguo	33°03'22,85"	71°35'58,21"
Escala Llanos, Santa Elena	8	1960	Antiguo	33°03'23,29"	71°36'0,89"
Desagüe Santa Elena	9	2100	Antiguo	33°03'21,79"	71°36'4,08"
Ventosa Troncoso	10	2350	Antiguo	33°03'27,02"	71°36'11,37"
Padre Febres	11	2450	Antiguo	33°03'27,47"	71°36'15,43"
Pajonal	12	2550	Antiguo	33°03'30,32"	71°36'18,60"
Desagüe Anticlea	13	2650	Antiguo	33°03'30,14"	71°36'20,51"
Av. Alemania 9742	14	2875	Nuevo	33°03'25,24"	71°36'24,97"
Av. Alemania 9660	15	3025	Nuevo	33° 3'21,48"	71°36'26,78"
Av. Alemania con Santa Teresa	16	3225	Nuevo	33°03'19,39"	71°36'34,03"
Av. Alemania con subida El Litre	17	3440	Nuevo	33°03'19,94"	71°36'40,41"
Av. Alemania	18	3600	Nuevo	33°03'16,09"	71°36'44,15"
Av. Alemania con calle Las Quintas	19	3800	Nuevo	33°03'18,39"	71°36'47,35"
Av. Alemania con Av. Francia	20	4140	Nuevo	33°03'22,84"	71°36'56,93"

Av. Alemania	21	4380	Nuevo	33°03'15,39"	71°36'54,80"
Av. Alemania con Zillemelo	22	4540	Nuevo	33°03'10,93"	71°36'55,40"
Av. Alemania con Calle 13	23	4790	Nuevo	33°03'12,89"	71°37'02,83"
Av. Alemania con Juan Torres	24	5225	Nuevo	33°03'16,37"	71°37'12,69"
Av. Alemania (llegando a Baquedano)	25	5370	Nuevo	33°03'18,74"	71°37'18,13"
Av. Alemania con Ferrari	26	5490	Antiguo	33°03'16,42"	71°37'21,79"
Av. Alemania con Yervas Buenas	27	5640	Antiguo	33° 3'16,06"	71°37'26,79"
Av. Alemania con Guillermo Rivera	28	5960	Antiguo	33°03'13,36"	71°37'31,89"
Av. Alemania con calle Alemania	29	6100	Antiguo	33°03'06,96"	71°37'35,50"
Av. Alemania con Israel	30	6630	Antiguo	33°03'04,72"	71°37'45,14"
Av. Alemania con Camila	31	6825	Antiguo	33°02'58,69"	71°37'47,10"
Carlos Lyon	32	7130	Antiguo	33°02'52,95"	71°37'51,80"
Av. Alemania con Caupolicán	33	7280	Antiguo	33°02'52,89"	71°37'56,13"
Av. Alemania (entre C. Armstrong y P. San Luis)	34	7700	Antiguo	33°02'44,71"	71°37'54,70"
Av. Alemania (Plaza San Luis)	35	7900	Antiguo	33°02'39,68"	71°37'53,13"
Tomas Ramos con Miranda	36	8200	Antiguo	33°02'37,95"	71°38'01,18"
Balmes (entre Castillo y Jiménez)	37	8450	Antiguo	33°02'32,25"	71°38'00,87"
San Francisco con Blanquillo	38	8825	Antiguo	33°02'23,58"	71°38'05,08"
Subida Toro (llegando a camino cintura)	39	9270	Antiguo	33°02'17,51"	71°38'12,40"
Santos Torneros con Obispo Villarreal	40	9410	Antiguo	33°02'14,56"	71°38'16,88"
Palazuelos con Uribe	41	9625	Antiguo	33°02'11,42"	71°38'21,23"
Av. Pacífico (entre Q. Verde y Piscis)	42	10000	Antiguo	33°02'00,54"	71°38'26,22"
Av. Pacífico con Aguayo	43	10150	Antiguo	33°01'56,76"	71°38'29,61"


Fuente: Elaboración propia

Tabla: Sensor N°1: Entrada Av. Santos Ossa.

Ubicación	Entrada Av. Santos Ossa
Elemento Hidráulico	Tubería a la Vista
Georreferencia	Latitud: 33° 03'04,58" Longitud: 71°35'17,28"  
Calidad de señal	Sin Señal
Modelación	ARIMA: SIN DATOS Umbral (dB): SIN DATOS


Fuente: Elaboración propia

Tabla: Sensor N°2: Desagüe Av. Santos Ossa.

Ubicación	Desagüe Av. Santos Ossa
Elemento Hidráulico	Cámara de Desagüe
Georreferencia	Latitud: 33°03'04,68" Longitud: 71°35'37,68" 
Calidad de señal	Operativo
Modelación	SARIMA: $(0,0,1)X(0,1,1)_7$ Umbral (dB): [41,45] → 45 Estado de Fuga – Umbral 95% 


Fuente: Elaboración propia

Tabla: Sensor N°3: Ventosa Parque Los Ingleses.

Ubicación	Ventosa Parque Los Ingleses
Elemento Hidráulico	Cámara de Ventosa
Georreferencia	Latitud: 33°03'07,61" Longitud: 71°35'38,36" 
Calidad de señal	Operativo
Modelación	SARIMA: $(1,0,2)X(0,1,1)_7$ Umbral (dB):[3,10]→15 Estado de Fuga – Umbral 95% 

Fuente: Elaboración propia

Tabla: Sensor N°4: Desagüe Ossandón.

Ubicación	Desagüe Ossandón
Elemento Hidráulico	Cámara de Desagüe
Georreferencia	Latitud: 33°03'11,40" Longitud: 71°35'11,40"  
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15


Fuente: Elaboración propia

Tabla: Sensor N°5: Mac-Iver con Washington.

Ubicación	Mac Iver con Washington
Elemento Hidráulico	Cámara de Inspección
Georreferencia	Latitud: 33°03'19,12" Longitud: 71°35'44,64"  
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°6: Lamar con Ramaditas.

Ubicación	Lamar con Ramaditas
Elemento Hidráulico	Cámara de Ventosa
Georreferencia	Latitud: 33°03'24,06 Longitud: 71°35'49,52" 
Calidad de señal	Operativo
Modelación	ARIMA: $(1,0,1)X(1,1,1)_7$ Umbral (dB): $[-1,5] \rightarrow 15$ Estado de Fuga - Umbral 95% 

Fuente: Elaboración propia

Tabla: Sensor N°7: Federico Costa.

Ubicación	Federico Costa
Elemento Hidráulico	Cámara de Interconexión
Georreferencia	Latitud: 33°03'22,85" Longitud: 71°35'58,21"  
Calidad de señal	Operativo
Modelación	ARIMA: SIN MODELO Umbral (dB): 15


Fuente: Elaboración propia

Tabla: Sensor N°8: Escala Llanos.

Ubicación	Escala Llanos, Santa Elena
Elemento Hidráulico	Tubería a la Vista
Georreferencia	Latitud: 33°03'23,29 Longitud: 71°36'0,89"  
Calidad de señal	Sin Señal
Modelación	ARIMA: SIN DATOS Umbral (dB): SIN DATOS


Fuente: Elaboración propia

Tabla: Sensor N°9: Desagüe Santa Elena.

Ubicación	Desagüe Santa Elena
Elemento Hidráulico	Cámara de Desagüe
Georreferencia	Latitud: 33°03'21,79" Longitud: 71°36'4,08"  
Calidad de señal	Operativo
Modelación	ARIMA: SIN MODELO Umbral (dB): 15


Fuente: Elaboración propia

Tabla: Sensor N°10: Ventosa Troncoso.

Ubicación	Ventosa Troncoso
Elemento Hidráulico	Cámara de Ventosa
Georreferencia	Latitud: -33°03'27,02" Longitud: -71°36'11,37" 
Calidad de señal	Operativo
Modelación	ARIMA: $(1,0,0)X(0,1,1)_7$ Umbral (dB): [8,17] → 17 Estado de Fuga - Umbral 95% 

Fuente: Elaboración propia

Tabla: Sensor N°11: Ventosa Padre Febres.

Ubicación	Calle Padre Febres, altura N°785
Elemento Hidráulico	Cámara de Ventosa
Georreferencia	Latitud: -33.057630° Longitud: -71.604285° 
Calidad de señal	Operativo
Modelación	ARMA: (1,0,1) Umbral (dB): [8,15] → 15 Estado de Fuga - Umbral 95% 

Fuente: Elaboración propia

Tabla: Sensor N°12: Ventosa Pajonal.

Ubicación	Calle El Pajonal, altura N°930
Elemento Hidráulico	Cámara de Ventosa
Georreferencia	Latitud: -33.058422° Longitud: -71.605168°° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°13: Desagüe Anticlea.

Ubicación	Calle Anticlea, altura N°9806
Elemento Hidráulico	Cámara de Desagüe
Georreferencia	Latitud: -33.058373° Longitud: -71.605697° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°14: Av. Alemania.

Ubicación	Av. Alemania, altura N°9742
Elemento Hidráulico	Cámara de Válvula
Georreferencia	Latitud: -33.057011° Longitud: -71.606936° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15


Fuente: Elaboración propia

Tabla: Sensor N°15: Av. Alemania.

Ubicación	Av. Alemania, altura N°9660
Elemento Hidráulico	Cámara de Ventosa
Georreferencia	Latitud: -33.055967° Longitud: -71.607439° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15


Fuente: Elaboración propia

Tabla: Sensor N°16: Av. Alemania.

Ubicación	Av. Alemania con calle Santa Teresa
Elemento Hidráulico	Cámara de
Georreferencia	Latitud: -33.055387° Longitud: -71.609453° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°17: Av. Alemania.

Ubicación	Av. Alemania con calle Subida El Lite
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.055540° Longitud: -71.611226° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°18: Av. Alemania.

Ubicación	Av. Alemania con calle Naylor
Elemento Hidráulico	Cámara de
Georreferencia	Latitud: -33.054468° Longitud: -71.612264° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°19: Av. Alemania.

Ubicación	Av. Alemania con calle Las Quintas
Elemento Hidráulico	Cámara de Ventosa
Georreferencia	Latitud: -33.055108° Longitud: -71.613153° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15


Fuente: Elaboración propia

Tabla: Sensor N°20: Av. Alemania.

Ubicación	Av. Alemania con Av. Francia
Elemento Hidráulico	Cámara de acceso a tubería
Georreferencia	Latitud: -33.056344° Longitud: -71.615814° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°21: Av. Alemania.

Ubicación	Av. Alemania, frente quebrada.
Elemento Hidráulico	Cámara de
Georreferencia	Latitud: -33.054276° Longitud: -71.615222° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°22: Av. Alemania.

Ubicación	Av. Alemania con calle Zillemelo
Elemento Hidráulico	Cámara de
Georreferencia	Latitud: -33.053035° Longitud: -71.615388° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°23: Av. Alemania.

Ubicación	Av. Alemania con calle 13
Elemento Hidráulico	Cámara de
Georreferencia	Latitud: -33.053581° Longitud: -71.617453° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°24: Av. Alemania.

Ubicación	Av. Alemania con Juan Torres
Elemento Hidráulico	Cámara de
Georreferencia	Latitud: -33.054548° Longitud: -71.620192° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15


Fuente: Elaboración propia

Tabla: Sensor N°25: Av. Alemania.

Ubicación	Av. Alemania con calle Baquedano
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.055206° Longitud: -71.621702° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°26: Av. Alemania.

Ubicación	Av. Alemania con calle Ferrari
Elemento Hidráulico	Cámara de ventosa
Georreferencia	Latitud: -33.054560° Longitud: -71.622719° 
Calidad de señal	Operativo
Modelación	SARIMA: $(1,0,0)X(0,1,1)_7$ Umbral (dB): [8,17] → 17 Estado de Fuga – Umbral 95% 


Fuente: Elaboración propia

Tabla: Sensor N°27: Av. Alemania.

Ubicación	Av. Alemania con calle Yervas Buenas
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.054460° Longitud: -71.624109° 
Calidad de señal	Operativo
Modelación	ARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°28: Av. Alemania.

Ubicación	Av. Alemania con calle Guillermo Rivera
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.053711° Longitud: -71.625526° 
Calidad de señal	Operativo
Modelación	SARIMA: $(1,0,2)X(0,1,1)_7$ Umbral (dB): $[-5,0] \rightarrow 15$ Estado de Fuga - Umbral 95% 


Fuente: Elaboración propia

Tabla: Sensor N°29: Av. Alemania.

Ubicación	Av. Alemania con calle Alemania
Elemento Hidráulico	Cámara de ventosa
Georreferencia	Latitud: -33.052978° Longitud: -71.626414° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral 15

Fuente: Elaboración propia

Tabla: Sensor N°30: Av. Alemania.

Ubicación	Av. Alemania con calle Israel
Elemento Hidráulico	Cámara de ventosa
Georreferencia	Latitud: -33.051175° Longitud: -71.629336° 
Calidad de señal	Operativo
Modelación	SARIMA: $(0,0,1)X(0,1,1)_7$ Umbral (dB): [-3,7] → 15 Estado de Fuga – Umbral 95% 

Fuente: Elaboración propia

Tabla: Sensor N°31: Av. Alemania.

Ubicación	Av. Alemania con calle Camila
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.049636° Longitud: -71.629750° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°32: Av. Alemania.

Ubicación	Av. Alemania con calle Carlos Lyon
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.048042° Longitud: -71.631056° 
Calidad de señal	EQUIPO NO INSTALADO
Modelación	SARIMA: NA Umbral (dB): NA

Fuente: Elaboración propia

Tabla: Sensor N°33: Av. Alemania.

Ubicación	Av. Alemania con calle Caupolicán
Elemento Hidráulico	Cámara de ventosa
Georreferencia	Latitud: -33.048025° Longitud: -71.632258° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°34: Av. Alemania.

Ubicación	Av. Alemania con calle Armstrong
Elemento Hidráulico	Cámara de ventosa
Georreferencia	Latitud: -33.045753° Longitud: -71.631861° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla Sensor N°35: Av. Alemania.

Ubicación	Av. Alemania con Plaza San Luis
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.044356° Longitud: -71.631425° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°36: Av. Tomás Ramos.

Ubicación	Av. Tomás Ramos con calle Miranda
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.043875° Longitud: -71.633661° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°37: Calle Balmes.

Ubicación	Calle Balmes, entre calles Castillo y Jiménez
Elemento Hidráulico	Cámara de ventosa
Georreferencia	Latitud: -33.042291° Longitud: -71.633576° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15


Fuente: Elaboración propia

Tabla: Sensor N°38: Calle Castillo.

Ubicación	Calle Castillo con Blanquillo
Elemento Hidráulico	Cámara de Válvula
Georreferencia	Latitud: -33.039883° Longitud: -71.634744° 
Calidad de señal	EQUIPO NO INSTALADO
Modelación	SARIMA: NA Umbral (dB): NA

Fuente: Elaboración propia

Tabla: Sensor N°39: Subida Toro.

Ubicación	Calle Subida Toro con Camino Cintura
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.038197° Longitud: -71.636778° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°40: Calle Santos Torneros.

Ubicación	Calle Santos Torneros con Obispo Villarreal
Elemento Hidráulico	Cámara de ventosa
Georreferencia	Latitud: -33.037378° Longitud: -71.638022° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°41: Calle Palazuelos.

Ubicación	Calle Palazuelos con Pelayo
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.036506° Longitud: -71.639231° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15


Fuente: Elaboración propia

Tabla: Sensor N°42 Av. Pacífico.

Ubicación	Av. Pacífico, entre calle Quebrada Verde y Piscis
Elemento Hidráulico	Cámara de válvula
Georreferencia	Latitud: -33.033483° Longitud: -71.640617° 
Calidad de señal	Operativo
Modelación	SARIMA: Sin Modelo Umbral (dB): 15

Fuente: Elaboración propia

Tabla: Sensor N°43 Av. Pacífico.

Ubicación	Av. Pacífico con calle Aguayo
Elemento Hidráulico	Cámara de Válvula
Georreferencia	Latitud: -33.032433° Longitud: -71.641558° 
Calidad de señal	EQUIPO NO INSTALADO
Modelación	SARIMA: NA Umbral (dB): NA

Fuente: Elaboración propia