



UNIVERSIDAD DE CHILE  
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS  
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

**ESTIMACIÓN DEL NÚMERO DE TÉCNICOS PARA EL  
SERVICIO DE REPARACIONES DE TELEFÓNICA  
CHILE.**

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN GESTIÓN DE OPERACIONES

ANA ANDREA SOTO VÁSQUEZ

PROFESOR GUÍA

SEBASTIÁN RÍOS PÉREZ

MIEMBROS DE LA COMISIÓN:

CARLOS REVECO DÍAZ

RICARDO MUÑOZ CANCINO

DENIS SAURÉ VALENZUELA

SANTIAGO DE CHILE

AÑO 2016

## RESUMEN EJECUTIVO

Telefónica Chile actualmente tiene como problemática el no cumplimiento del SLA de atención de solicitudes de reparación acordada con el cliente, el cual consiste en: atender al 80% de clientes dentro de 24 horas, con el siguiente orden de prioridad de segmento de clientes: empresas, negocios y residencial, y al 20% restante atenderlo en las siguientes 48 horas, esto con el objetivo de mejorar la percepción del cliente del servicio post venta que realiza la compañía, disminuyendo reclamos, costos y la cantidad de clientes insatisfechos por este concepto.

Actualmente la compañía no cuenta con un modelo que le permita planificar los técnicos requeridos para atender las solicitudes de reparaciones dentro de los plazos definidos, todo se realiza en base a la experiencia, es por ello que requiere un modelo que permita optimizar y planificar la cantidad de técnicos que satisfagan la demanda por reparaciones dentro de los SLA definidos por la compañía.

En base a lo anterior el siguiente trabajo tiene como objetivo diseñar un modelo que permita optimizar y planificar la cantidad de técnicos requeridos para satisfacer la demanda del servicio de reparaciones, cumpliendo con los SLA y disminuyendo costos.

Para estimar la cantidad de técnicos se realiza la predicción de la demanda para cada día del año, utilizando información histórica, evaluando diferentes modelos de pronóstico de series de tiempo, de tal forma de contar con anticipación con la cantidad estimada de solicitudes de reparación, ya que este valor es un input para el modelo de optimización con el cual se obtendrá la cantidad de técnicos que satisfagan el requerimiento establecido por la compañía.

El modelo de programación lineal para estimar el número óptimo de técnicos, se probó inicialmente con los datos de la Agencia Apoquindo, es decir, con la cantidad de solicitudes de reparaciones realizadas por cada segmento de cliente para esta agencia el resultado fue aplazar al 26,6% de los clientes con un porcentaje de ocupación de 94,5%. Para alcanzar el 20% de clientes aplazados se aumentó la dotación de técnicos en 1 para aquellos días en que no se cumple la atención de clientes, obteniendo un promedio de clientes aplazados de un 18% pero disminuyendo la ocupación media a 62%, si se aumenta a dos técnicos el promedio de clientes aplazados llega a un 15% con un 61% de ocupación de técnicos.

Desde el punto de vista económico para este caso particular de la Agencia Apoquindo, aumentar en un técnico para cumplir con la calidad de servicio es mucho más conveniente que no cumplir y aplazar al 26,6% de los clientes, ya que el costo por pagar el sueldo de un técnico es menor al costo de un cliente perdido por no cumplir con el servicio.

Se requiere poner en práctica el modelo y evaluar el cumplimiento de los SLA y de clientes insatisfechos con el servicio de manera de medir la contribución del modelo a la mejora en el servicio de reparaciones, además, esto servirá para evaluar los modelos

predictivos y determinar en la práctica aquel que realiza los pronósticos con un menor error, permitiendo realizar las mejoras necesarias.

## TABLA DE CONTENIDO

1. Antecedentes de la Empresa [1].....	3
1.1. Participaciones de mercado en segmento internet fija. ....	3
1.2. Participación de Mercado Telefonía Local .....	4
1.3. Televisión pagada.....	5
1.4. Motivación del estudio .....	6
2. Objetivos.....	7
2.1. Objetivo General .....	7
2.2. Objetivos Específicos.....	7
2.3. Justificación del estudio .....	7
2.4. Alcances del Estudio .....	8
2.5. Resultados Esperados.....	8
3. Metodología .....	10
3.1. Proceso de Extracción del Conocimiento (KDD) .....	10
3.1.1. Definir el objetivo del proceso .....	11
3.1.2. Seleccionar los datos a estudiar.....	11
3.1.3. Preprocesar los datos.....	11
3.1.4. Preparar los datos para modelar .....	11
3.1.5. Determinar método de Data Mining a utilizar.....	11
3.1.6. Seleccionar modelo a utilizar .....	12
3.1.7. Evaluación e Interpretación.....	12
3.1.8. Consolidar el conocimiento descubierto .....	12
3.2. Modelos de Datamining .....	12
3.2.1. Red Neuronal .....	12
3.2.2. Regresión Lineal .....	13
3.2.3. Support Vector Machine .....	14
3.2.4. Suavizamiento Exponencial [9].....	16
3.2.5. Promedio Móvil [9].....	16
3.2.6. Evaluación de la predicción [9].....	17
3.3. Programación Lineal [10][12].....	18
4. Análisis de la situación actual.....	20
4.1. La Demanda .....	22
4.2. La Capacidad.....	24

5. Resultados .....	26
5.1. Predicción de demanda.....	26
5.1.1. Modelos y resultados predictivos .....	27
5.1.1.1. Resultados modelo mensual: .....	28
5.1.1.2. Resultados modelo semanal: .....	29
5.1.1.3. Resultados Modelo Diario:.....	31
6. Modelo de Programación Lineal propuesto .....	34
6.1. Resultados obtenidos del modelo .....	36
6.2. Conclusiones obtenidas del modelo de programación lineal .....	45
7. Conclusiones .....	47
8. Bibliografía .....	50

## ÍNDICE DE TABLAS

Tabla 1: Participación de mercado Internet Fija. ....	4
Tabla 2: Participación de mercado Telefonía Fija. ....	5
Tabla 3 Participación de mercado Televisión paga. ....	6
<b>Tabla 4: Porcentaje de error para cada modelo de Predicción mensual, por segmento de cliente, Agencia Apoquindo</b> .....	<b>28</b>
<b>Tabla 5: Porcentaje de error para cada modelo de Predicción mensual, por segmento de cliente, Agencia Centro</b> .....	<b>28</b>
<b>Tabla 6: Porcentaje de error para cada modelo de Predicción mensual, por segmento de cliente, Agencia Independencia</b> .....	<b>28</b>
<b>Tabla 7: Porcentaje de error para cada modelo de Predicción mensual, por segmento de cliente, Agencia San Bernardo.</b> ....	<b>29</b>
<b>Tabla 8: Porcentaje de error para cada modelo de Predicción semanal, por segmento de cliente, Agencia Apoquindo</b> .....	<b>29</b>
Tabla 9: Porcentaje de error para cada modelo de Predicción semanal, por segmento de cliente, Agencia Centro .....	29
Tabla 10: Porcentaje de error para cada modelo de Predicción semanal, por segmento de cliente, Agencia Independencia. ....	30
Tabla 11: Porcentaje de error para cada modelo de Predicción semanal, por segmento de cliente, Agencia San Bernardo .....	30
Tabla 12: Porcentaje de error para cada modelo de Predicción diaria, por segmento de cliente, Agencia Apoquindo .....	31
Tabla 13: Porcentaje de error para cada modelo de Predicción diaria, por segmento de cliente, Agencia Centro. ....	31
Tabla 14: Porcentaje de error para cada modelo de Predicción diaria, por segmento de cliente, Agencia Independencia. ....	32
Tabla 15: Porcentaje de error para cada modelo de Predicción diaria, por segmento de cliente, Agencia San Bernardo. ....	32
Tabla 16 Resultados de ejecutar el modelo para $x = 0.415$ .....	37
Tabla 17: Resultado de aumentar un técnico .....	39
Tabla 18: Resultado de aumentar en dos técnicos .....	41
Tabla 19: Modelos con error menor al 5%.....	47

## ÍNDICE DE ILUSTRACIONES

Ilustración 1: Participación de mercado internet fija.....	3
Ilustración 2: Evolución de líneas fijas y penetración por cada 100 habitantes. ....	4
Ilustración 3: Cantidad de líneas de Telefonía fija por empresa.....	5
Ilustración 4: Suscriptores de Televisión pagada por empresa.....	6
Ilustración 5: Etapas Proceso KDD. ....	10
Ilustración 6: Pesos en una red neuronal. [3] .....	13
Ilustración 7: Hiperplano para dos clases linealmente separables [6] .....	14
Ilustración 8: Regresión para una función no lineal.....	15
Ilustración 9: Diagrama de reparaciones .....	21
Ilustración 10: Proceso de reparaciones.....	22
Ilustración 11: Demanda de reparaciones Agencia Apoquindo.....	22
Ilustración 12: Demanda de reparaciones Agencia Centro.....	23
Ilustración 13: Demanda de reparaciones Agencia Independencia.....	23
Ilustración 14: Demanda de reparaciones Agencia San Bernardo.....	24
Ilustración 15: Predicción de demanda de Rapid Miner .....	27
Ilustración 16: Predicción de demanda de Rapid Miner, detalle de Validation.....	27
Ilustración 17: Cantidad de técnicos diaria para $x=0,415$ .....	38
Ilustración 18: Cantidad de técnicos diaria para $x=0,45$ .....	38
Ilustración 19: Cantidad de técnicos diaria al aumentar en un técnico.....	40
Ilustración 20: Porcentaje de ocupación al aumentar en un técnico .....	40
Ilustración 21: Cantidad de técnicos diaria al aumentar en dos técnicos.....	42
Ilustración 22: Porcentaje de ocupación diaria al aumentar en dos técnicos .....	42
Ilustración 23: Porcentaje de ocupación de técnicos para cada análisis .....	43
Ilustración 24: Porcentaje de clientes atrasados para cada análisis .....	44

## INTRODUCCIÓN

Telefónica Chile requiere mejorar la atención del área de reparaciones debido a que éstas no se realizan en el tiempo acordado con el cliente, lo cual afecta directamente en la satisfacción del mismo y se ha demostrado que influye en la decisión de dar de baja sus servicios y cambiarse de compañía.

Es por ello que se requiere estimar la cantidad de técnicos diarios que se requieren para responder a la demanda diaria de reparaciones dentro de los tiempos definidos, para esto se realizará un modelo de programación lineal que estime la cantidad de técnicos que requiere la compañía utilizando como input la demanda diaria de reparaciones, para ello se utilizará la metodología KDD (Knowledge Discovery in Databases) con la cual se tomarán los datos de cuatro agencias de la Región Metropolitana: Apoquindo, Independencia, San Bernardo y Centro, se estructurarán y analizarán de manera de ser utilizados por diferentes modelos predictivos: redes neuronales, Support Vector Machine, Regresión Lineal, Promedio Móvil y Suavizamiento Exponencial, el objetivo de realizar la predicción con los diferentes modelos es evaluar cuál de ellos da un porcentaje de error de predicción menor al 5% y de acuerdo a esto determinar cuál será aquel que utilizará Telefónica para realizar predicción de demanda.

Los datos utilizados para las 4 agencias comprendieron las solicitudes de reparaciones entre los años 2009 – 2012, los cuales fueron procesados para obtener el archivo con los datos necesarios a utilizar en el software para realizar la predicción, pero sin realizar ajustes en la demanda, es decir, se utilizaron los datos tal como se obtuvieron de la base de datos para obtener los pronósticos con cada uno de los modelos. Durante este proceso se analizaron los datos y se pudo observar estacionalidades y puntos que se escapaban de la tendencia de la serie, por lo cual, se realizaron correcciones en la data y se volvieron a ejecutar los modelos, entregando una predicción con un MAPE menor al obtenido con la data original.

Los resultados de la ejecución de la predicción además permitió observar que el error (MAPE) es menor para los datos agrupados de forma mensual, en comparación con los diarios, por lo cual, cuando Telefónica realice la predicción se aconseja utilizar el modelo que arrojó el menor porcentaje de error y los datos agrupados de forma mensual, para posteriormente obtener la demanda diaria y ejecutar el modelo de programación lineal.

Una vez realizada esta evaluación se elabora el modelo de programación lineal para estimar la cantidad de técnicos que lograrán atender al 80% de los clientes dentro de 24 horas y al 20% restante dentro de las siguientes 48 horas, priorizando a los clientes en el siguiente orden: empresas, negocios y residencial.



# Capítulo 1: Descripción del Problema

---

## 1. Antecedentes de la Empresa [1]

Telefónica Chile es una empresa que provee de servicios del área de Telecomunicaciones tales como: Telefonía Fija y Móvil, Banda Ancha y Televisión, los cuales son comercializados bajo la marca Movistar, con presencia en el 100% de comunas del país.

En Chile provee de servicios móviles y fijos de telefonía, banda ancha y televisión digital, con presencia en el 100% de comunas del país.

Sus operaciones las realiza a través de sus sociedades Telefónica Chile S.A y Telefónica Móviles S.A las cuales a partir de 2009 unificaron la comercialización de sus productos bajo la marca Movistar.

Movistar es hoy la mayor comunidad de clientes de Chile, con 13 millones de accesos a clientes, posición avalada por la gestión innovadora del grupo en Chile, con inversiones anuales de US\$ 700 millones y 6000 empleados directos. 158.434 empresas son clientes de Telefónica (156.049 son pequeñas y medianas empresas), a los que se suman 57.974 clientes de Movistar (55.500 pequeñas y medianas empresas).

### 1.1. Participaciones de mercado en segmento internet fija.

La participación de mercado en el segmento internet fija está en un 74,7% (a Diciembre de 2015) en manos de dos operadores: Movistar y VTR, con 1.034 mil y 1.003 mil conexiones respectivamente, tal como se muestra en la figura y tabla siguiente:




Ilustración 1: Participación de mercado internet fija.  
Fuente: Ppt\_Series\_Diciembre\_2015\_V5 www.subtel.com.

Participación de mercado	Dic 14	Dic 15
<b>Movistar</b>	39,0%	37,9%
<b>VTR</b>	37,3%	36,8%
<b>Claro</b>	11,2%	12,0%
<b>Grupo GTD</b>	8,4%	8,8%
<b>ENTEL</b>	1,2%	1,3%
<b>Otros</b>	2,9%	3,2%

Tabla 1: Participación de mercado Internet Fija.  
Fuente: Ppt\_Series\_Diciembre\_2015\_V5 www.subtel.com

## 1.2. Participación de Mercado Telefonía Local

La Telefonía local se ha mantenido estable en los últimos meses con una penetración promedio de 19 líneas por cada 100 habitantes desde el año 2013 a Diciembre de 2015, la ilustración siguiente muestra lo anteriormente descrito:




Ilustración 2: Evolución de líneas fijas y penetración por cada 100 habitantes.  
Fuente: Ppt\_Series\_Diciembre\_2015\_V5 www.subtel.com

En cuanto a la participación de mercado, ésta sigue liderada por Movistar con un 43,1%, sin embargo, sigue su tendencia a la baja registrando una disminución de 2,9% entre Diciembre de 2014 y el mismo mes en 2015.

La evolución de la telefonía fija para cada una de las empresas se puede ver a continuación:




Ilustración 3: Cantidad de líneas de Telefonía fija por empresa  
Fuente: Ppt\_Series\_Diciembre\_2015\_V5 www.subtel.com

La participación de mercado de cada una de las empresas se puede ver en la siguiente tabla:

%Líneas por empresa	Dic 2014 (*)	Dic 2015 (*)
<b>Movistar</b>	46,2%	43,1%
<b>VTR</b>	20,6%	20,4%
<b>Grupo GTD</b>	10,2%	10,3%
<b>Claro</b>	7,7%	7,8%
<b>Entel</b>	13,1%	16,3%
<b>Otros</b>	2,2%	2,1%

Tabla 2: Participación de mercado Telefonía Fija.  
Fuente: Ppt\_Series\_Diciembre\_2015\_V5 www.subtel.com

### 1.3. Televisión pagada

La televisión pagada sigue en aumento en el último año, con un crecimiento de 4,7%, el cual ha beneficiado a la mayoría de las compañías, siendo VTR la empresa que mantiene la mayor cuota de mercado en este servicio, la figura siguiente muestra la evolución de la cantidad de suscriptores por empresa en los últimos 5 años:

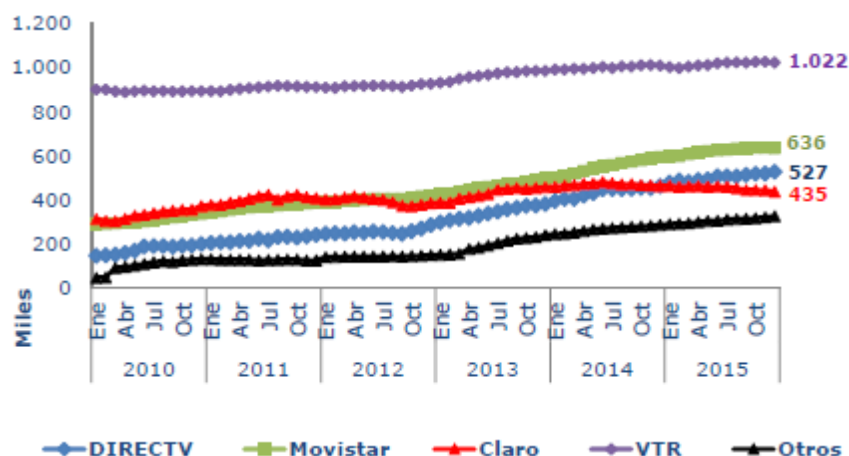


Ilustración 4: Suscriptores de Televisión pagada por empresa  
Fuente: Ppt\_Series\_Diciembre\_2015\_V5 www.subtel.com

La participación de mercado por empresa es la siguiente:

%Suscriptores TV por empresa	Dic 14	Dic 15
VTR	35,9%	34,7%
Movistar	21,1%	21,6%
Claro	16,4%	14,8%
DIRECTV	16,4%	17,9%
Otros	10,2%	11,0%

Tabla 3 Participación de mercado Televisión paga.  
Ppt\_Series\_Junio\_2014\_V1 www.subtel.com

Donde VTR mantiene la mayor cuota de mercado con un 34,7% del total de suscriptores, seguido por Movistar con un 21,6%.

#### 1.4. Motivación del estudio

Con el inicio de la portabilidad numérica, la incorporación de nuevas empresas al mercado de la telefonía y el bajo incremento de clientes que contratan telefonía fija, es decir, voz, internet y televisión, se hace imprescindible contar con un mejor servicio postventa que mantenga a los actuales clientes satisfechos con el servicio prestado y con ello disminuir la probabilidad de fuga de clientes a otras compañías, es por ello que Telefónica requiere mejorar la atención del proceso de reparaciones ya que es uno de los servicios que afecta directamente a la satisfacción del cliente y a aumentar sus intenciones de fuga.

## **2. Objetivos**

### **2.1. Objetivo General**

Elaborar un modelo que permita a Telefónica Chile optimizar y planificar con anticipación, la cantidad de técnicos necesarios para satisfacer la demanda de reparaciones en el SLA comprometido con el cliente y disminuir los costos asociados a la insatisfacción del cliente con el servicio.

### **2.2. Objetivos Específicos**

1. Pronosticar la demanda diaria de reparaciones por tipo de cliente.
2. Determinar la cantidad de técnicos necesarios para cumplir con las restricciones de negocio asociadas al proceso de reparaciones.
3. Diseñar herramienta que permita pronosticar y optimizar la cantidad de técnicos requeridos para satisfacer la demanda de acuerdo a las restricciones del problema.

### **2.3. Justificación del estudio**

Telefónica tiene como uno de sus objetivos de negocio disminuir la tasa de churn, es decir, de clientes que dejen la compañía para irse a la competencia, y es por ello que uno de sus focos es otorgarle un mejor servicio al cliente, para que de esta forma se encuentre satisfecho con el servicio y la atención postventa brindada. Todo esto fundamentado en un estudio que indicó que el no cumplimiento de reparaciones en 2 días genera mensualmente 1.006 bajas de servicio y el reitero dentro del mismo mes 709 bajas, lo cual, en conjunto asciende a 1.715 bajas al mes, si consideramos además que un cliente perdido le cuesta a la compañía \$30.000 pesos en promedio, se tiene una pérdida mensual de \$51.450.000, sólo por este concepto.

Es por ello que se requiere estimar la cantidad de técnicos necesarios para atender al cliente dentro de los tiempos comprometidos mejorando la calidad del servicio post venta y como consecuencia disminuyendo la tasa de churn.

## **2.4. Alcances del Estudio**

El estudio consiste en proporcionar una herramienta que permita a Telefónica estimar diariamente la cantidad de técnicos necesarios para realizar la reparación de los servicios de telefonía fija, mediante el estudio de cuatro agencias de la Región Metropolitana, las cuales son las siguientes:

- Apoquindo: agencia piloto del proyecto de reparaciones que actualmente realiza la empresa.
- Santiago Centro: agencia más antigua y con mayor cantidad de reclamos.
- Independencia y San Bernardo: agencia con mayor diversidad de clientes.

Para realizar la estimación de técnicos se requiere predecir la demanda de reparaciones, para ello se utilizarán modelos predictivos con los datos de reparaciones de los años 2009 a 2011, el año 2012 se utilizará para evaluar la calidad de los modelos y así determinar cuál de ellos es el que aporta una mejor predicción.

Posteriormente, mediante un modelo de programación lineal, se determinarán los técnicos necesarios para realizar la reparación, considerando: tiempos de atención, agendamiento con el cliente y máxima duración de la jornada laboral.

## **2.5. Resultados Esperados**

1. Contar con una herramienta que permita determinar la cantidad diaria de técnicos necesaria para atender las solicitudes de reparaciones en el tiempo comprometido con el cliente.
2. Disminuir la pérdida de ingresos por clientes que se cambian de compañía debido a un deficiente servicio postventa.

## Capítulo 2: Marco Teórico

---



### 3. Metodología

La metodología a utilizar en este estudio será la del Proceso de Extracción del conocimiento o KDD para realizar la predicción de demanda y la de optimización para realizar el modelo de programación lineal que realizará la estimación diaria de técnicos necesarios para atender la demanda.

#### 3.1. Proceso de Extracción del Conocimiento (KDD)

En el mundo actual, donde se procesa un gran número de datos, se ha vuelto necesario contar con una metodología que permita extraer patrones de conocimiento que faciliten la toma de decisiones, es así como surge el proceso KDD o Knowledge Discovery in Databases, el cual cuenta con una serie de etapas que culminan con la obtención del conocimiento de los datos almacenados.

Las etapas de esta metodología se pueden observar en la Figura 1:

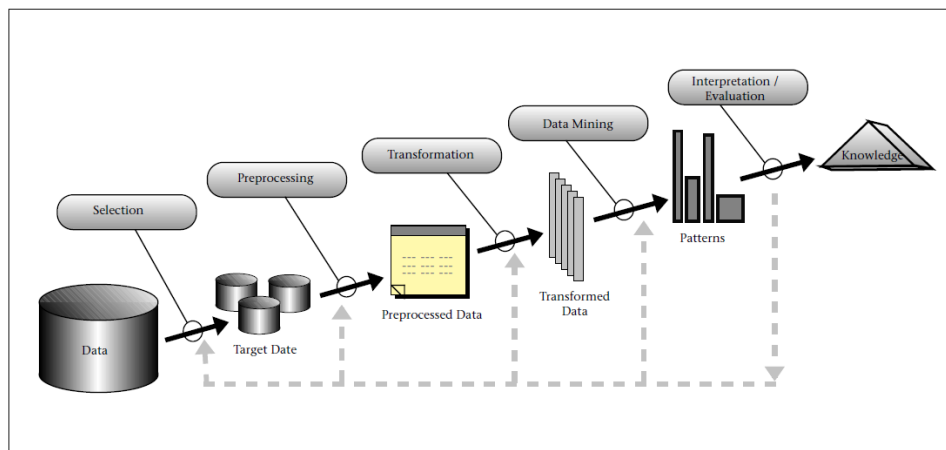


Ilustración 5: Etapas Proceso KDD.

Fuente: From Data Mining to Knowledge Discovery in Databases, Fayyad

Y son definidas a continuación:

### **3.1.1. Definir el objetivo del proceso**

Antes de iniciar la extracción de conocimiento de los datos, lo primero y también lo más importante es definir el objetivo del proceso KDD, de tal forma de tener la claridad de qué datos utilizar y que se busca con su análisis, sin este paso difícilmente se podrá conocer el problema a resolver y por ende interpretar correctamente los resultados.

### **3.1.2. Seleccionar los datos a estudiar**

De acuerdo al objetivo definido en el paso anterior se selecciona la data con la cual se trabajará a lo largo del proceso para extraer la información requerida. Este paso junto con el siguiente toman más del 50% del tiempo del proceso KDD.

### **3.1.3. Preprocesar los datos**

En esta etapa se debe revisar el conjunto de datos de tal forma de analizar si existen datos faltantes, fuera de rango, definir cuáles serán los datos a utilizar y si requieren agruparse para facilitar la obtención de la información.

### **3.1.4. Preparar los datos para modelar**

Encontrar una manera de representar los datos para que sean más acordes al objetivo definido para el proceso, se pueden seguir los siguientes pasos para llevar a cabo esta etapa:

- Seleccionar las variables
- Seleccionar filas.
- Construir nuevas variables.
- Transformar las variables.

### **3.1.5. Determinar método de Data Mining a utilizar**

Una vez terminado el paso anterior se debe analizar y determinar cuál es el método de Data Mining que más se ajusta al objetivo definido para el proceso, por ejemplo si se abordará como clasificación o regresión.

### **3.1.6. Seleccionar modelo a utilizar**

Se debe seleccionar el modelo de datamining el cual puede ser: árboles de decisión, red neuronal o regresión logística. La elección del modelo influirá en la preparación de la data, una vez se haya modificado se puede continuar con el entrenamiento del modelo. El proceso para construir un modelo predictivo requiere de un entrenamiento y validación, es por ello que para realizar el entrenamiento se utiliza parte de los datos del modelo y se realiza el test y validación de su exactitud en la predicción con los datos restantes. En ocasiones un tercer set de datos es necesario para realizar la validación del modelo ya que los datos de testeo pueden estar influenciados por las características del modelo.

### **3.1.7. Evaluación e Interpretación**

Revisar los resultados obtenidos y evaluar si se ajustan al objetivo del proceso, de no ser así se debe volver al paso 1 para modificar alguna de las etapas del proceso que puede estar influyendo en que el parámetro obtenido no sea el requerido.

### **3.1.8. Consolidar el conocimiento descubierto**

Consiste en incorporar el conocimiento descubierto a través de la interpretación de los patrones en algún sistema informático o reporte para consulta de las partes interesadas.

## **3.2. Modelos de Datamining**

### **3.2.1. Red Neuronal**

Las redes neuronales surgieron en 1930 de la investigación del aprendizaje humano, éstas aprenden de la experiencia y aplican este conocimiento a la resolución de problemas nuevos. [3]

Las redes neuronales cuentan con tres capas: capa de entrada, capa escondida y capa de salida. En la capa de entrada está conformada por nodos que representan a las variables predictoras, las cuales se conectan con cada uno de los nodos que integran la capa escondida, los cuales a su vez pueden conectarse con nodos que conformen otra capa escondida o

con nodos de la capa de salida, los cuales consisten en una o más variables de respuesta. [2]

Cada nodo de la capa de entrada se multiplica por un peso de conexión  $W_{ij}$ , y se calcula el valor de la siguiente capa a través de la función de activación, la cual multiplica el peso de  $W_{ij}$  por el valor del nodo  $i$  y lo suma con la multiplicación del peso  $W_{kj}$  por el valor del nodo  $k$ . Tal como se muestra en la Figura




Ilustración 6: Pesos en una red neuronal. [3]

Los pesos de conexión son parámetros desconocidos, los cuales se van estimando a medida que se va entrenando el modelo.

### 3.2.2. Regresión Lineal

La regresión lineal incluye dos variables, una variable de respuesta  $y$ , que es función lineal de una variable predictora  $x$ . [3][4]

La ecuación que representa a la regresión lineal está dada por:

$$y = a + bx$$

Donde,  $a$  y  $b$  son llamados coeficientes de regresión e indican la intersección con el eje  $y$ , y la pendiente de la recta, respectivamente.

Lamentablemente, los problemas en su mayoría no son problemas lineales, es por ello que existe otro modelo denominado Regresión Lineal Múltiple.

La Regresión Lineal Múltiple contiene más de una variable predictora, esto permite que la variable  $y$  sea planteada como una función lineal de un

vector multidimensional, la ecuación que representa a la regresión lineal múltiple para  $n$  variables predictoras sería la siguiente:

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n$$

### Regresión No Lineal

En ocasiones la variable de respuesta depende de las variables independientes como una función polinómica, lo cual da origen a una regresión polinómica. La regresión polinómica se puede resolver de forma lineal a través de un reemplazo de variables y de esta forma se puede utilizar la técnica de mínimos cuadrados para su resolución.

### 3.2.3. Support Vector Machine

Las máquinas de soporte vectorial (SVM), creadas por Vladimir Vapnik, son métodos relacionados con problemas de clasificación y regresión, formados por un conjunto de algoritmos de aprendizaje supervisado.

Las SVM permiten clasificar los puntos en un plano, y mediante el entrenamiento predecir a qué clase pertenece un nuevo punto agregado a la muestra, esto lo realiza separando los puntos por un espacio lo más amplio posible, debido a que los datos no son separables linealmente, se introduce el concepto de espacio de funciones kernel, lo cual hace que los datos se encuentren separados en un espacio de mayor dimensión. [5]

En la figura que se muestra a continuación se puede observar el hiperplano que separa los puntos en el plano:





Ilustración 7: Hiperplano para dos clases linealmente separables [6]

Tal como se mencionò con anterioridad, este método puede ser utilizado en clasificación como en regresión, para el caso de la regresión, se

mantienen sus características principales de algoritmo de máximo margen; convertir una función no lineal a una lineal utilizando un espacio de funciones kernel de mayor dimensión

La capacidad del sistema es controlada por parámetros que no dependen de la dimensionalidad característica del espacio. Se basaron en la definición de la función de pérdida (epsilon intensiva) que ignora los errores que están situados dentro de una cierta distancia al valor real.

La figura siguiente muestra un ejemplo para una regresión de una función no lineal:



**Ilustración 8: Regresión para una función no lineal**

Una de las ideas más importantes en Support Vector Machine Regression (SVMR) es la de representar la solución por medio de pequeños subconjuntos de puntos de entrenamiento. Usando la función de pérdida se asegura la existencia de mínimos globales y al mismo tiempo se optimiza la confiabilidad de la cota. [7]

Las principales características de SVM son las siguientes:

- Es una herramienta matemática.
- No tiene mínimos locales.
- No tiene el problema de overfitting.
- La solución no depende de la estructura del planteamiento del problema.
- Aplicabilidad en distintos tipos de problemas, es decir, clasificación, regresión y descubrimiento de patrones en general. [8]

### 3.2.4. Suavizamiento Exponencial [9]

Es un promedio ponderado entre el valor actual de la serie original y el valor de la serie suavizada en el tiempo inmediatamente anterior, su fórmula está dada por:

$$Z(t) = \alpha Y(t) + (1 - \alpha)Z(t - 1)$$

Donde:

$Z(t)$ : serie de tiempo suavizada.

$Y(t)$ : serie de tiempo original

$t$ : tiempo

$\alpha$ : valor entre 0 y 1.

Si  $\alpha$  es cercano a 1, la serie suavizada considera en la ponderación el valor actual, por lo cual el suavizamiento es mínimo.

Si  $\alpha$  es cercano a 1/2, la serie original y la suavizada se ponderarán en partes iguales.

Si  $\alpha$  es cercano a cero se pondera fuertemente el valor suavizado inmediatamente anterior, por lo que el suavizado es importante.

En este método los valores históricos van influyendo cada vez menos en el término presente mientras más avanzamos hacia el pasado.

### 3.2.5. Promedio Móvil [9]

Este método, de fácil aplicación, consiste en fijar un número  $k$  de términos para los cuales se calculará el promedio de todos los grupos de  $k$  términos consecutivos, con  $k$  preferentemente impar. De esta manera se anulan las variaciones aleatorias de la serie. Su fórmula está dada por:

$$Z(t) = \frac{Y(t - k) + Y(t - k + 1) + \dots + Y(t) + Y(t + 1) + \dots + Y(t + k)}{2 * k + 1}$$

Donde:

$Z(t)$ : serie de tiempo suavizada.

$Y(t)$ : serie de tiempo original

$t$ : tiempo

$k$ : número de términos para los cuales se calculará el promedio móvil

### 3.2.6. Evaluación de la predicción [9]

Cuando se realiza la predicción para una serie de tiempo, es necesario medir que tan cerca se encuentran los valores obtenidos de la serie de datos pronosticada. Una medida para establecer este error es el Promedio de Error Porcentual Absoluto (MAPE), el cual está dado por la siguiente fórmula:

$$MAPE = \frac{1}{T} \left( \sum_{t=1}^T APE_t \right) = \frac{1}{T} \left( \sum_{t=1}^T \frac{|y_t^s - y_t^a|}{y_t^a} \right) \times 100$$

Donde:

APE= error porcentual absoluto

$y_t^a$ = valor pronosticado de  $y_t$

$y_t^s$ = valor real de  $y_t$

T= número de periodos

Para evaluar la dispersión de los errores se puede utilizar la Desviación Estándar del error porcentual absoluto (APE):

$$Desviación\ Estándar\ APE = \sqrt{\frac{1}{T} \sum_{t=1}^T (APE_t - MAPE)^2}$$

La raíz cuadrática media del error RMSE, también es utilizada para medir el error de los pronósticos, éste mide la dispersión de la variable simulada en el curso del tiempo, penalizando mayormente los errores grandes al elevarlos al cuadrado. El RMSE se recomienda cuando el costo de cometer un error es proporcional al cuadrado de ese error.

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t^s - y_t^a)^2}$$

Donde:

$y_t^a$ = valor pronosticado de  $y_t$

$y_t^s$ = valor real de  $y_t$

T= número de periodos



### 3.3. Programación Lineal [10][12]

La programación lineal se encarga de optimizar, maximizar o minimizar, una función lineal, la cual es denominada función objetivo. Las variables contenidas en la función objetivo se encuentran sujetas a una o varias restricciones representadas por inecuaciones lineales.

Un problema de programación lineal se escribe de manera explícita como:

$$\begin{aligned} \min z &= c_1x_1 + c_2x_2 + \dots + c_{n-1}x_{n-1} + c_nx_n \\ a_{1,1}x_1 + a_{1,2}x_2 + \dots + a_{1,n-1}x_{n-1} + a_{1,n}x_n &= b_1 \\ a_{2,1}x_1 + a_{2,2}x_2 + \dots + a_{2,n-1}x_{n-1} + a_{2,n}x_n &= b_2 \\ \vdots & \qquad \qquad \qquad \vdots & \qquad \qquad \qquad \vdots & \qquad \qquad \qquad \cdot \\ a_{m,1}x_1 + a_{m,2}x_2 + \dots + a_{m,n-1}x_{n-1} + a_{m,n}x_n &= b_m \\ x_i &\geq 0 \quad \forall i \end{aligned}$$

Y de forma compacta como:

$$\begin{aligned} \min z &= c^T x \\ Ax &= b \\ x &\geq 0 \end{aligned}$$

Con  $x, c \in \mathbb{R}^n$ ,  $b \in \mathbb{R}^m$ ,  $A \in \mathcal{M}_{m \times n}(\mathbb{R})$ , con  $m \leq n$ , donde  $x$  es la variable de decisión y  $c$  es el vector de costos.

El conjunto de restricciones es un poliedro cerrado denominado conjunto factible.

$A$  es la matriz de coeficientes tecnológicos y  $b$  el vector de recursos.

## Capítulo 3: Situación Actual

---

#### 4. Análisis de la situación actual

La actividad de reparaciones es gestionada por la Gerencia de Operaciones de Telefónica Movistar, por medio de un contrato marco de actividades de instalación y reparaciones que lleva adelante con empresas externas de reconocida experiencia. Dicha cuenta es organizada y distribuida por áreas de operación de apoyo y gestión de las actividades de terreno que desarrolla la fuerza de trabajo externa.

El área de reparaciones de Telefónica está orientada a resolver aquellos problemas que surjan durante el uso del servicio en cuestión o en el uso de algún artefacto facilitado por la compañía.

El área geográfica se encuentra dividida en zonas o AMA (Área Mínima de Atención), a la cual es asignado un técnico que atiende todos los reclamos de la zona.

El proceso de reparación consiste principalmente de 5 etapas:

1. Necesidad de reparación: etapa inicial del proceso, en la cual el cliente se comunica con la empresa debido a que alguno de los servicios fijos que posee (Televisión, Telefonía y/o Banda Ancha) se encuentran con problemas, los canales de atención a los que puede recurrir son: atención telefónica, página web o atención presencial en las sucursales de la compañía.
2. Recepción: ingreso de la solicitud de reparación por parte de los ejecutivos de atención e identificación del problema.
3. Diagnóstico: identificar si se puede dar una solución inmediata de forma remota o es necesario enviar un técnico a terreno a reparar la falla. Además, se determina el tipo de trabajo que hay que hacer en terreno, por ejemplo: si se debe mandar a un técnico a terreno, se debe enviar un equipo a cliente (lo que se hace mediante empresas de despacho, etc).
4. Reparación: una vez identificado el problema y tipo de trabajo a realizar se realiza la reparación del servicio por cada uno de los actores involucrados: técnicos en terreno y operadores logísticos que realizan despacho.
5. Cierre: realizada la reparación, el técnico se debe comunicar con la plataforma de cierre indicando que se efectuó la solución al problema. La

plataforma se comunica con el cliente de manera de comprobar que el problema haya sido solucionado.

Cada una de las etapas se pueden observar en la siguiente figura:

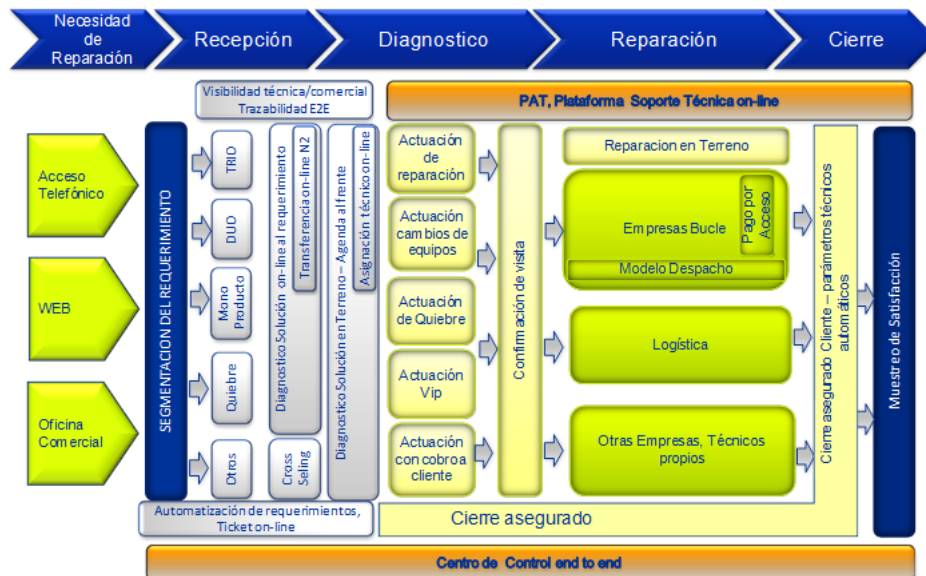


Ilustración 9: Diagrama de reparaciones  
Fuente: Telefónica Chile.

En la figura 10 se puede observar el proceso con mayor detalle, destacándose el flujo que sigue el reclamo antes de ser enviado a su solución en terreno, pasando por Recepción de Primer y Segundo Nivel, en las cuales los ejecutivos intentan solucionar el problema de manera online desde las plataformas, cuando ambos niveles no dan resultado se envían las solicitudes de reparaciones a cada una de las empresas contratistas de acuerdo a la zona a la que pertenece el reclamo las cuales son asignadas por un despachador que de acuerdo a la experiencia y al segmento al que pertenece el cliente prioriza las solicitudes de reparación que debe atender cada técnico.

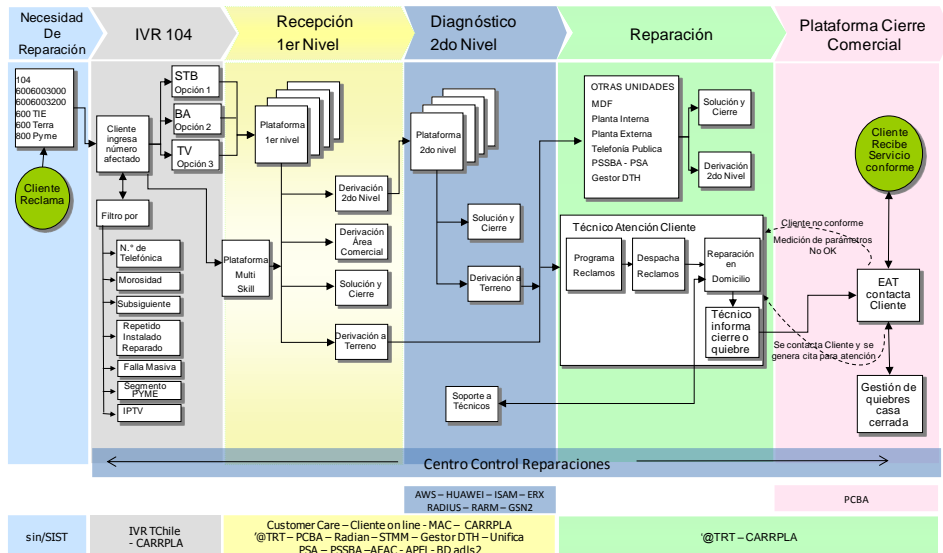


Ilustración 10: Proceso de reparaciones  
 Fuente: Telefónica Chile.

#### 4.1. La Demanda

La demanda de reparaciones en general tiene un comportamiento homogéneo, siendo los meses de Marzo, Julio y Agosto aquellos con mayor demanda.

A continuación se muestra la demanda de reparación para cada una de las Agencias desde el año 2009 a 2012 y por cada segmento de clientes:

#### Agencia Apoquindo:





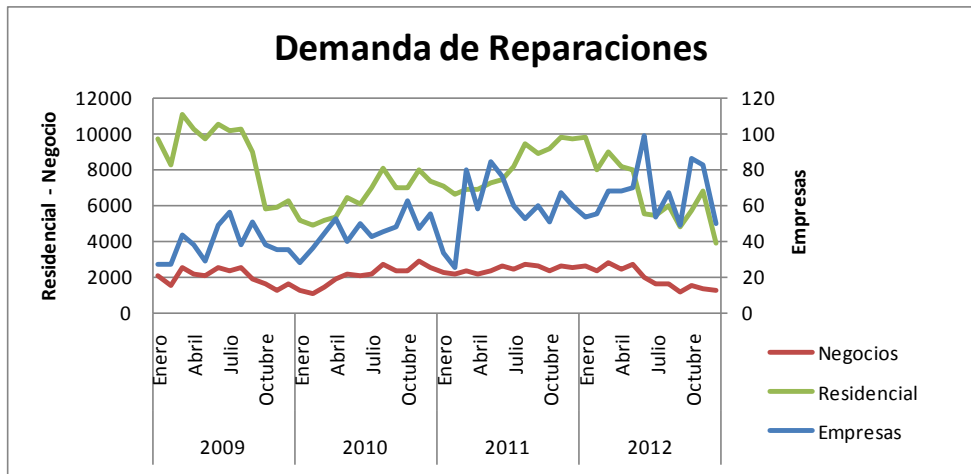
Ilustración 11: Demanda de reparaciones Agencia Apoquindo  
 Fuente: Elaboración Propia

**Agencia Centro:**



**Ilustración 12: Demanda de reparaciones Agencia Centro**  
Fuente: Elaboración Propia

**Agencia Independencia:**



**Ilustración 13: Demanda de reparaciones Agencia Independencia**  
Fuente: Elaboración Propia

## Agencia San Bernardo:




Ilustración 14: Demanda de reparaciones Agencia San Bernardo  
Fuente: Elaboración Propia

## 4.2. La Capacidad

Telefónica negocia cada 3 años el contrato (Bucle) con empresas externas que prestan servicios de reparación y esto se refleja en capacidad de técnicos fija mensual por sector.

Los técnicos propios son 30 personas que están orientadas al segmento de alto valor, además hay 5% de la capacidad son técnicos *on demand* que están para apoyar cuando un técnico de la empresa colaboradora falla. El contrato actual para reparaciones se encuentra definido por AMA, en la cual el técnico de la empresa colaboradora debe atender los reclamos pendientes de solución y además, realizar mantenimiento preventivo, lo que ocasionaría una disminución de las fallas asociadas a un mismo evento, por lo tanto, una disminución en los reclamos.

# Capítulo 4: Resultado de los modelos predictivos

---



## 5. Resultados

### 5.1. Predicción de demanda

Se realizó el cruce de los archivos reparaciones 2009-2012 y SMA\_detalle Febrero 2012, en el cual se filtraron los teléfonos de las agencias en estudio, de manera de obtener los reclamos históricos asociados a cada una.

Para realizar la predicción de demanda se utilizará el programa computacional Rapid Miner y se compararán 5 modelos predictivos: Redes Neuronales, Support Vector Machine, Regresión Lineal, Promedio Móvil y Suavizamiento exponencial.

Los datos a utilizar son las solicitudes de reparaciones de Telefonía Fija registradas desde el año 2009 a 2012, las cuales incluyen la siguiente información:

- Número de teléfono que origina el reclamo
- Planta comercial asociada al número de teléfono
- Segmento de cliente (Residencial, Empresa, Pyme, etc)
- Fecha de ingreso de solicitud
- Fecha de atención de solicitud
- Agencia

Como input para los modelos predictivos todos los registros anteriores se agregaron para cada segmento y planta comercial de forma mensual, semanal y diaria por cada año, de manera de tener la evolución de la demanda.

Para la predicción de demanda, los atributos utilizados son:

- Número de mes/semana/día y año
- Cantidad de solicitudes para el año 2009
- Cantidad de solicitudes para el año 2010
- Cantidad de solicitudes para el año 2011
- Cantidad de solicitudes para el año 2012

Los modelos predictivos fueron aplicados a datos tomados directamente de la base de datos y sobre datos a los cuales se corrigió estacionalidad y posibles errores, los cuales fueron reemplazados por el promedio de la misma semana/mes o día de cada uno de los años considerados en el pronóstico (2009-2011)

### 5.1.1. Modelos y resultados predictivos

A continuación se muestra el modelo en Rapid Miner utilizado para los modelos: Regresión Lineal, SVM y Redes Neuronales, y los resultados obtenidos de cada uno de ellos:

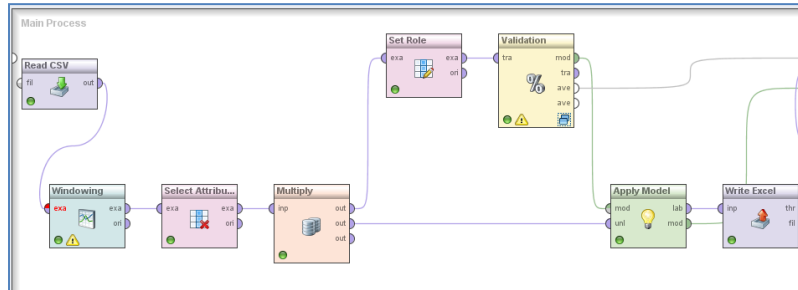


Ilustración 15: Predicción de demanda de Rapid Miner  
Fuente: Elaboración propia




Ilustración 16: Predicción de demanda de Rapid Miner, detalle de Validation  
Fuente: Elaboración propia

### 5.1.1.1. Resultados modelo mensual:

#### Apoquindo:

Segmento	Suavizamiento Exponencial (Alfa 0,1)		Promedio Móvil (Window width=2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	24,67	22,84%	22,10%	17,82%	4,08%	3,12%	28,07%	13,95%	6,73%	3,61%	0,00%	0,00%
Negocios	34,93%	33,64%	13,37%	11,84%	4,47%	0,10%	34,87%	28,53%	0,25%	0,19%	21%	12%
Residencial	26,97%	25,88%	9,86%	8,16%	4,05%	2,03%	25,36%	18,13%	0,08%	0,12%	19,23%	18,44%

Tabla 4: Porcentaje de error para cada modelo de Predicción mensual, por segmento de cliente, Agencia Apoquindo

Los resultados mostrados en la tabla 4, obtenidos al ejecutar los modelos en Rapidminer, muestran que se obtiene un menor error en la predicción mensual para el segmento empresa con SVM nu, para el segmento negocios el mejor predictor es Redes Neuronales y para el segmento Residencial el menor porcentaje de error se alcanza con SVM Epsilon.

#### Centro

Segmento	Suavizamiento Exponencial (Alfa 0,1)		Promedio Móvil (Window width=2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	45,73%	22,27%	11,39%	11,70%	5,95%	2,90%	24,78%	7,82%	1,61%	0,99%	0,00%	0,00%
Negocios	32,44%	27,93%	11,36%	9,21%	5,95%	1,78%	15,39%	13,43%	0,18%	0,16%	22%	19%
Residencial	46,68%	40,89%	10,30%	7,76%	5,94%	2,87%	11,99%	10,90%	1,14%	0,55%	27,83%	25,33%

Tabla 5: Porcentaje de error para cada modelo de Predicción mensual, por segmento de cliente, Agencia Centro

Para la agencia Centro, los mejores modelos predictivos fueron: SVM nu para el segmento empresas, SVM Epsilon para el segmento Negocios y Residencial.

#### Independencia

Segmento	Suavizamiento Exponencial (Alfa 0,1)		Promedio Móvil (Window width=2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	18,13%	15,40%	14,18%	5,15%	7,47%	4,74%	16,86%	6,90%	3,53%	3,52%	0,00%	0,00%
Negocios	33,82%	8,27%	8,90%	5,07%	3,59%	2,15%	13,76%	5,64%	0,16%	0,00%	24,30%	3%
Residencial	34,60%	11,02%	10,61%	5,17%	5,38%	2,56%	15,97%	7,19%	9,82%	1,06%	23,29%	5,95%

Tabla 6: Porcentaje de error para cada modelo de Predicción mensual, por segmento de cliente, Agencia Independencia

En el caso de la Agencia Independencia los modelos predictivos que presentaron un menor error en la predicción fueron: SVM nu para el segmento empresas y SVM Epsilon para los segmentos Negocios y Residencial, al igual que con la agencia Centro.

## San Bernardo

Segmento	Suavizamiento Exponencial (Alfa 0,1)		Promedio Móvil (Window width=2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	16,63%	12,17%	8,47%	5,63%	4,03%	2,12%	16,48%	8,76%	1,96%	1,04%	0,00%	0,00%
Negocios	13,93%	11,62%	5,08%	2,74%	2,47%	2,30%	9,31%	4,82%	0,14%	0,13%	0,51%	0,26%
Residencial	16,40%	6,91%	5,51%	3,66%	2,41%	2,10%	9,08%	6,50%	4,24%	0,42%	12,54%	5,27%

Tabla 7: Porcentaje de error para cada modelo de Predicción mensual, por segmento de cliente, Agencia San Bernardo.

Analizando los resultados de los modelos predictivos para la Agencia San Bernardo los modelos predictivos con menor error fueron: SVM Epsilon para segmento Negocios y Residencial y SVM Nu para segmento Empresas.

### 5.1.1.2. Resultados modelo semanal:

#### Apoquindo:

Segmento	Suavizamiento Exponencial (Alfa 0,1)		Promedio Móvil (Window width=2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	80,92%	53,42%	38,05%	28,81%	107,99%	78,38%	86,50%	59,36%	48,18%	38,33%	69,12%	55,98%
Negocios	74,10%	24,27%	15,60%	8,39%	38,53%	17,87%	48,36%	25,71%	5,59%	0,60%	0%	0%
Residencial	33,89%	20,46%	9,89%	7,50%	23,15%	14,96%	31,33%	19,01%	0,59%	0,49%	10,64%	2,83%

Tabla 8: Porcentaje de error para cada modelo de Predicción semanal, por segmento de cliente, Agencia Apoquindo

Al comparar los MAPE se puede observar que al corregir los datos disminuye el error de predicción de todos los modelos predictivos aplicados. En este caso, existen dos modelos que realizan una mejor predicción, estos son: SVM nu y SVM Epsilon, los cuales para los segmentos de clientes Negocio y Residencial tiene un error menor al 5% para los datos corregidos.

Una vez obtenidos los resultados para la Agencia Apoquindo, se realiza el mismo ejercicio para las demás agencias.

#### Centro:

Segmento	Suavizamiento Exponencial (Alfa 0,1)		Promedio Móvil (Window width= 2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	185,59%	53,32%	27,53%	20,32%	64,12%	40,64%	98,23%	52,35%	15,70%	11,60%	135,51%	14,25%
Negocios	257,65%	24,50%	71,69%	10,55%	199,51%	18,59%	236,71%	19,42%	0,93%	0,49%	12,02%	0%
Residencial	30,44%	29,00%	12,43%	11,74%	18,24%	15,83%	27,21%	23,87%	0,44%	0,30%	13,73%	11,97%

Tabla 9: Porcentaje de error para cada modelo de Predicción semanal, por segmento de cliente, Agencia Centro

Como se puede observar el modelo predictivo que realiza la predicción con un menor porcentaje de error de acuerdo a la información proporcionada por el software

Rapidminer es SVM Epsilon, ya que para los segmentos Negocio y Residencial logra un porcentaje de error menor al 5%, SVM nu, es otro modelo que alcanza un buen porcentaje de error para el segmento Negocio, por lo cual, podría ser utilizado para realizar una correcta predicción para este segmento. Para el segmento Empresas no existe un modelo que arroje un error en la predicción aceptable, por lo cual, se deberá trabajar la serie de tiempo de las solicitudes de reparación de tal forma que permita evidenciar las estacionalidades que ésta posee.

## Independencia:

Segmento	Suavizamiento Exponencial (Alfa=0,1)		(Window width = 2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	57,91%	30,22%	24,47%	19,45%	63,52%	27,91%	63,78%	30,59%	28,95%	14,24%	38,33%	19,98%
Negocios	209,30%	14,61%	50,98%	8,75%	56,57%	15,55%	53,27%	16,50%	2,39%	0,51%	34,18%	1,23%
Residencial	19,88%	15,37%	9,03%	6,78%	16,89%	13,31%	22,20%	17,31%	0,60%	0,13%	20,17%	16,31%

Tabla 10: Porcentaje de error para cada modelo de Predicción semanal, por segmento de cliente, Agencia Independencia.

En el caso de los datos de la Agencia Independencia podemos observar que nuevamente el modelo que alcanza un porcentaje menor al 5% es SVM Epsilon, nuevamente para los segmentos Negocio y Residencial, para el segmento Negocio SVM nu también alcanza un porcentaje de error que indica que podría ser un buen modelo predictivo para este modelo, en el caso del segmento Empresa, al igual que con las Agencias anteriores, no existe un modelo que permita realizar una predicción aceptable.

## San Bernardo:

Segmento	Suavizamiento Exponencial (Alfa=0,1)		Promedio movil (Window width=2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	54,86%	30,56%	25,96%	21,02%	57,77%	32,47%	62,55%	32,57%	27,71%	20,83%	48,06%	30,09%
Negocios	22,52%	10,36%	14,45%	9,04%	24,20%	11,96%	24,24%	10,31%	5,23%	0,50%	1,92%	0,00%
Residencial	11,85%	8,64%	7,81%	6,27%	12,36%	9,40%	13,54%	9,94%	0,08%	0,07%	9,67%	8,11%

Tabla 11: Porcentaje de error para cada modelo de Predicción semanal, por segmento de cliente, Agencia San Bernardo

Para la Agencia San Bernardo se repite la situación anterior, el modelo con un menor error en la predicción es SVM Epsilon, para los segmentos Negocio y Residencial y SVM nu para el segmento Negocios.

De acuerdo a los resultados obtenidos se puede decir que el mejor modelo predictivo es SVM Epsilon y en Agencias como San Bernardo, Independencia y Centro SVM nu, es un buen predictor para el segmento Negocio. Para el segmento Empresas no hubo modelo que lograra predecir con un porcentaje de error menor al 5%, por lo cual, se deberá tomar una estrategia distinta, como por ejemplo, procesar los datos de este segmento evidenciando cambios relacionados con estacionalidad, días del año, etc.

### 5.1.1.3. Resultados Modelo Diario:

#### Apoquindo:

Segmento	Suavizamiento Exponencial (Alfa 0,1)		Promedio Móvil (Window width=2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	130,00%	119,23%	55,56%	40,32%	202,75%	194,92%	147,25%	121,04%	87,72%	73,03%	89,56%	79,71%
Negocios	119,37%	110,34%	111,07%	98,05%	52,18%	40,14%	68,86%	52,03%	62,06%	55,93%	134,52%	120,23%
Residencial	50,90%	30,09%	46,96%	33,46%	122,46%	114,34%	95,70%	87,10%	12,07%	8,43%	48,63%	42,52%

Tabla 12: Porcentaje de error para cada modelo de Predicción diaria, por segmento de cliente, Agencia Apoquindo

Se puede observar que los errores predictivos de los modelos para una demanda diaria de reparaciones son considerablemente mayores que los errores obtenidos con demandas mensual y semanal, de todas maneras, los modelos que presentan menor error son los siguientes: para el segmento empresa el modelo que presenta un menor error es Promedio Móvil, en Negocios es Red Neuronal y en el segmento Residencial es SVM Epsilon.

#### Centro:

Segmento	Suavizamiento Exponencial (Alfa 0,1)		Promedio Móvil (Window width= 2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	162,19%	101,20%	74,85%	60,71%	120,19%	118,73%	94,63%	74,83%	81,10%	74,44%	136,23%	103,61%
Negocios	271,04%	243,03%	249,34%	214,43%	356,21%	230,52%	367,34%	67,51%	96,75%	87,64%	223,80%	215,38%
Residencial	54,70%	41,13%	48,71%	31,93%	110,94%	85,90%	78,46%	75,83%	12,76%	0,84%	48,09%	33,28%

Tabla 13: Porcentaje de error para cada modelo de Predicción diaria, por segmento de cliente, Agencia Centro.

Para la agencia Centro en el segmento empresas el modelo con el menor error predictivo es Promedio Móvil y en el segmento Negocios y Residencial, Regresión Lineal y SVM Epsilon, respectivamente.

#### Independencia:

Segmento	Suavizamiento Exponencial (Alfa=0,1)		(Window width = 2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	69,19%	51,18%	65,88%	53,89%	70,14%	67,39%	70,53%	63,48%	100,78%	94,15%	78,87%	63,90%
Negocios	140,45%	129,59%	101,69%	89,35%	324,35%	289,94%	260,29%	258,24%	54,00%	35,15%	128,54%	115,36%
Residencial	52,69%	43,18%	43,55%	38,42%	106,75%	93,58%	88,46%	74,82%	1,22%	0,72%	14,18%	9,35%

Tabla 14: Porcentaje de error para cada modelo de Predicción diaria, por segmento de cliente, Agencia Independencia.

En la agencia Independencia los modelos con un porcentaje de error menor son: Suavizamiento Exponencial en segmento empresas y SVM Epsilon en segmento negocios y residencial.

## San Bernardo

Segmento	Suavizamiento Exponencial (Alfa 0,1)		Promedio Móvil (Window width=2)		Redes Neuronales		Regresión Lineal		SVM Epsilon		SVM nu	
	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido	Original	Corregido
Empresas	66,24%	53,46%	46,70%	42,29%	69,54%	53,89%	70,39%	64,62%	291,92%	246,36%	89,10%	74,14%
Negocios	81,03%	63,23%	31,60%	19,25%	134,43%	125,56%	119,89%	114,45%	49,04%	43,57%	79,03%	64,20%
Residencial	62,54%	54,09%	19,30%	14,59%	101,59%	98,34%	90,14%	84,26%	1,33%	0,66%	14,67%	7,63%

Tabla 15: Porcentaje de error para cada modelo de Predicción diaria, por segmento de cliente, Agencia San Bernardo.

Finalmente para la Agencia San Bernardo los modelos con menor error en la predicción son: Suavizamiento Exponencial para el segmento Empresas, Promedio móvil para el segmento Negocios y SVM Epsilon para el segmento Residencial.

# Capítulo 4: Resultado del modelo de programación lineal

---



## 6. Modelo de Programación Lineal propuesto

El modelo de programación lineal presentado a continuación tiene por objetivo responder a la problemática de Telefónica obteniendo el mínimo número de técnicos necesarios para atender la demanda diaria de reparaciones de telefonía fija en las agencias de la compañía.

Los clientes en Telefónica están divididos en tres tipos:

- Empresas
- Negocios
- Residencial

Y para ellos se debe cumplir con atender al 80% de los clientes dentro de las primeras 24 horas desde que se hizo la llamada solicitando la reparación, priorizando a los clientes empresa, luego negocios y por último residencial, y al 20% restante dentro de 48 horas.

Se debe tener en cuenta como restricciones las siguientes:

- Tiempo de jornada laboral
- Tiempo de servicio de cada tipo de cliente

Consideraciones:

- Tiempo de viaje despreciable, debido a que las distancias dentro de las áreas de atención son pequeñas.
- Tiempo de servicio estándar para cada cliente.

El modelo propuesto es el siguiente:

### **Conjuntos:**

tt: horizonte de tiempo completo (0,1, ... tt)

t: horizonte de tiempo (1, ..., t)

i: clientes a atender (1...i)

### **Parámetros:**

d1(t): Cantidad de cliente tipo 1 que llaman por atención el día t

d2(t): Cantidad de cliente tipo 2 que llaman por atención el día t

d3(t): Cantidad de cliente tipo 3 que llaman por atención el día t

JL= jornada laboral

EM: Plazo máximo de espera en la atención

TPO1: tiempo de atención a cliente 1

TPO2: tiempo de atención a cliente 2

TPO3: tiempo de atención a cliente 3

Tec(t): cantidad de técnicos utilizados el día t

Cli1(t): cantidad de cliente tipo 1 atendidos el día t

Cli2(t): cantidad de cliente tipo 2 atendidos el día t

Cli3(t): cantidad de cliente tipo 3 atendidos el día t

Cli\_Tot(t): cantidad total de clientes atendidos en el día t

Inv\_1(tt): clientes tipo 1 no atendidos el día t

Inv\_2(tt): clientes tipo 2 no atendidos el día t

Inv\_3(tt): clientes tipo 3 no atendidos el día t

### **Función objetivo**

$\min z = \sum(t, \text{Tec}(t));$

### **Restricciones:**

- Satisfacer demanda de clientes tipo 1 en el día t

$$\text{Cli1}(t) + \text{Inv1}(t) = d1(t);$$

- Satisfacer demanda de clientes tipo 2 en el día t

$$\text{Cli2}(t) + \text{Inv2}(t) = d2(t);$$

- Satisfacer demanda de clientes tipo 3 en el día t

$$\text{Cli3}(t) + \text{Inv3}(t) = d3(t);$$

- Conversión de tiempo a cantidad de técnicos

$$\text{Tec}(t) * JL = g = \text{TPO1} * (\text{Cli1}(t) + \text{Inv1}(t-1)) + \text{TPO2} * (\text{Cli2}(t) + \text{Inv2}(t-1)) + \text{TPO3} * (\text{Cli3}(t) + \text{Inv3}(t-1));$$

- Cantidad total de clientes que se atienden en un día

$$\text{Cli\_Tot}(t) = e = \text{Cli1}(t) + \text{Inv1}(t-1) + \text{Cli2}(t) + \text{Inv2}(t-1) + \text{Cli3}(t) + \text{Inv3}(t-1);$$

- Atender a todos los clientes tipo 1 en el día t  
 $Inv1(t)=e=0;$
- Atender a todos los clientes tipo 2 en el día t  
 $Inv2(t)=e=0;$
- Aplazar la atención del x% de los clientes tipo 3  
 $x*d3(t)=g=Inv3(t);$
- Inventario del final del período para cliente 1  
 $Inv1('365')=e=0;$
- Inventario inicial del periodo para cliente 1  
 $Inv1('0')=e=0;$
- Inventario del final del período para cliente 2  
 $Inv2('365')=e=0;$
- Inventario inicial del periodo para cliente 2  
 $Inv2('0')=e=0;$
- Inventario del final del período para cliente 3  
 $Inv3('365')=e=0;$
- Inventario inicial del periodo para cliente 3  
 $Inv3('0')=e=0;$

## 6.1. Resultados obtenidos del modelo

Se utilizan los datos de demanda de la Agencia Apoquindo y se va variando el valor de x en la ecuación:

- Aplazar la atención del x% de los clientes tipo 3  
 $x*d3(t)=g=Inv3(t);$

de tal forma de llegar a aplazar al 20% de los clientes privilegiando la atención de los clientes tipo 1 y 2.

Los resultados son los siguientes para  $x=0,415$ :

Promedio de clientes aplazados	Ocupación Media de Técnicos	% de días donde se aplaza al 20% o menos de los clientes
26,6%	94,5%	6,6%

Tabla 16 Resultados de ejecutar el modelo para  $x = 0.415$

Cuyas gráficas de Cantidad de Técnicos utilizados diariamente y Ocupación diaria son mostradas a continuación:

Gráfica de cantidad de técnicos necesarios diariamente:




Ilustración 17: Cantidad de técnicos diaria para  $x=0,415$




Ilustración 18: Cantidad de técnicos diaria para  $x=0,45$

Este es el menor valor que pudo tomar x, ya que de otra forma el problema se hace infactible, posiblemente por la calidad de los datos de demanda, si Telefónica quiere aplazar un 20% de los clientes se deberá analizar si es conveniente, económicamente hablando, aumentar en uno o más técnicos para llegar al indicador requerido, si se realiza el ejercicio se tiene:

- **Aumentar en un técnico en aquellos días donde no se cumple el indicador**

Se considera que un técnico es capaz de realizar 6 reparaciones en una jornada de 8 horas.

No se incorporan técnicos en los días que pese a superar el porcentaje de atención tienen menos de 6 clientes para evitar tener capacidad ociosa.

Los resultados son los siguientes:

Promedio de clientes aplazados	Ocupación Media de Técnicos	% de días donde se aplaza al 20% o menos de los clientes
18%	62%	47%

**Tabla 17: Resultado de aumentar un técnico**

La cantidad de técnicos utilizados diariamente y el porcentaje de ocupación promedio se puede ver en las siguientes gráficas:




Ilustración 19: Cantidad de técnicos diaria al aumentar en un técnico




Ilustración 20: Porcentaje de ocupación al aumentar en un técnico

Como se puede observar se aplazan menos del 20% de los clientes tipo 3, menos del 50% de los días del año, por lo cual se analizará el caso de aumentar en dos técnicos:

- **Aumentar en dos técnicos en aquellos días donde no se cumple el indicador**

Los resultados son los siguientes:

Promedio de clientes aplazados	Ocupación Media de Técnicos	% de días donde se aplaza al 20% o menos de los clientes
15%	61%	92%

Tabla 18: Resultado de aumentar en dos técnicos

Del 7% de los días en que se aplaza a más del 20%, equivalente a 20 días, 18 de ellos corresponden a días que poseen menos de 6 clientes.

A continuación se pueden ver las gráficas de cantidad de técnicos y ocupación promedio:






Ilustración 21: Cantidad de técnicos diaria al aumentar en dos técnicos




Ilustración 22: Porcentaje de ocupación diaria al aumentar en dos técnicos

A continuación se puede observar un gráfico que compara el porcentaje de ocupación de técnicos dado por: el modelo, añadir un técnico a los días donde se supera el 20% de clientes aplazados y añadir dos técnicos:




Ilustración 23: Porcentaje de ocupación de técnicos para cada análisis

De la misma forma se tiene la siguiente gráfica pero mostrando el porcentaje de clientes atrasados para cada uno de los tres análisis:




Ilustración 24: Porcentaje de clientes atrasados para cada análisis

## 6.2. Conclusiones obtenidas del modelo de programación lineal

- El resultado que da el modelo si bien no da como resultado aplazar al 20% o menos de los clientes, da un mejor porcentaje de ocupación de la mano de obra.
- Al aumentar en un técnico disminuye la ocupación media de los técnicos a un 62% pero incrementa la cantidad de días en donde se aplaza a menos del 20% de los clientes a un 47% de los días del año.
- Al aumentar los técnicos en dos permite alcanzar un 92% de los días con aplazo de clientes menor al 20% disminuyendo el porcentaje de ocupación sólo en un 1% en comparación con el caso anterior.

# Capítulo 5: Conclusiones

---

## 7. Conclusiones

El presente trabajo fue realizado con el objetivo de entregar a Telefónica una solución que permita estimar la cantidad de técnicos óptimos para que el servicio de reparaciones de telefonía fija cumpla con los SLA comprometidos y disminuya los costos asociados.

Para estimar el número de técnicos se realizó primero la estimación de la demanda de reparaciones para contar con un pronóstico que sea el input del cálculo de técnicos, ya que de otra forma no se podrá adelantar a la demanda futura. Para realizar la predicción de demanda se estudiaron 5 diferentes modelos de manera de determinar cuál(es) de ellos otorga un error de pronóstico menor al 5% y en base a este dato determinar su utilización.

El estudio arrojó lo siguiente para cada Agencia, Período de estimación y Segmento de cliente:

Segmento	Apoquindo			Centro			Independencia			San Bernardo		
	Mensual	Semanal	Diario	Mensual	Semanal	Diario	Mensual	Semanal	Diario	Mensual	Semanal	Diario
<b>Empresas</b>	RN SVM			RN SVM			RN SVM			RN SVM		
<b>Negocio</b>	RN SVM Epsilon		SVM	RN SVM Epsilon		SVM	RN SVM		SVM	Promedio Móvil RL RN SVM		SVM
<b>Residencial</b>	RN SVM Epsilon		SVM	RN SVM Epsilon		SVM epsilon	RN SVM Epsilon		SVM epsilon	Promedio Móvil RN SVM Epsilon		SVM epsilon

Tabla 19: Modelos con error menor al 5%

Donde se puede observar que para estimar la demanda diaria sólo para las Agencias Independencia y San Bernardo en el segmento residencial se podría estimar con el modelo SVM con un error de pronóstico menor al 5%, una alternativa es realizar la estimación mensual que tiene un error menor y distribuir la carga de trabajo por día de acuerdo a la información histórica, evaluando el error que este método podría generar y comparándolo con el error obtenido desde los modelos predictivos.

En cuanto al modelo para estimar la cantidad de técnicos se puede observar que permite calcular la cantidad de técnicos requeridos para satisfacer la demanda de reparaciones, desde el punto de vista económico, aumentar en un técnico para cumplir con la calidad de servicio es mucho más conveniente que no cumplir con el SLA y aplazar al 26,6% de los clientes, ya que a un técnico se le paga aproximadamente \$300.000 pesos mensuales y la pérdida de los clientes que atiende un técnico asciende a \$180.000 pesos sólo por el concepto de pago de mensualidad, a esto hay que sumar los nuevos productos que puede contratar ese cliente y los clientes perdidos por los malos comentarios emitidos por un cliente insatisfecho.

Para mejorar este estudio se debe implementar el modelo de pronóstico y de estimación de técnicos para realizar el análisis económico de la situación actual y la situación una vez implementado el modelo predictivo y de estimación, debiendo además generar indicadores que evalúen el impacto de la mejora y evidenciar aquellos puntos que se deben mejorar.

## Capítulo 6: Bibliografía

---



## 8. Bibliografía

1. <http://www.telefonichile.cl/acerca-de-telefonica/telefonica-en-chile/>
2. From Data Mining to Knowledge Discovery in Databases, Fayyad.
3. Introduction to Data Mining and Knowledge Discovery, Third Edition, Two Crows Company.
4. Técnicas de análisis de datos. Aplicaciones prácticas usando Microsoft Excel y Weka, José Manuel Molina López y Jesús García Herrero, 2004
5. Data Mining Concepts and Techniques, Jiawei Han and Micheline Kamber, Second Edition.
6. Introduction to Support Vector Machines, Dustin Boswell, Agosto 6, 2002
7. Support Vector Machines Explained, Tristan Fletcher, Marzo 1, 2009.
8. <http://kernelsvm.tripod.com/>
9. Series de Tiempo, Gonzalo Ríos, Universidad de Chile. 2008.
10. Wikipedia, [https://es.wikipedia.org/wiki/Programaci%C3%B3n\\_lineal](https://es.wikipedia.org/wiki/Programaci%C3%B3n_lineal)
11. Apuntes clases Minería de datos. Clase 1 de Junio de 2012, Richard Weber.
12. Programación Lineal, Amaya Jorge, Abril 2007.

