

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

**Facultad de Ingeniería en Mecánica y Ciencias de la
Producción**

" Diseño de un método de pronóstico de demanda para una planta
ensambladora de televisores"

TRABAJO FINAL DE GRADUACIÓN

Materia Integradora

Previo la obtención del Título de:

INGENIERO INDUSTRIAL

Presentado por:

Roddy Oswaldo Pérez Parra

GUAYAQUIL - ECUADOR

Año: 2017

AGRADECIMIENTOS

A Dios, a mi familia y compañeros que han confiado en mí por tener la convicción de poder cosechar éxitos y así ser el orgullo de ellos como en especial un ejemplo a seguir para mi hija Aylin que ha sido mi inspiración durante el desarrollo del presente proyecto.

Extiendo los agradecimientos a la empresa por la confianza en realizar este trabajo y a mi tutor Msc. Luis Reyes quien me orientó con sus conocimientos y fundamentos sólidos que aportaron a mi formación profesional y motivan como investigador.

DECLARACIÓN EXPRESA

"La responsabilidad y la autoría del contenido de este Trabajo de Titulación, me corresponde exclusivamente; y doy mi consentimiento para que la ESPOL realice la comunicación pública de la obra por cualquier medio con el fin de promover la consulta, difusión y uso público de la producción intelectual"



Roddy Oswaldo Pérez Parra
AUTOR



Msc. Luis Ignacio Reyes Castro
TUTOR DE MATERIA
INTEGRADORA

RESUMEN

El presente proyecto se realizó para una empresa ensambladora de televisores ubicado en Durán-Ecuador, el mismo que tiene como objetivo reducir el nivel de incertidumbre de la demanda de televisores, por lo cual, se diseña un método que contribuye positivamente a la planificación de las operaciones y ventas, además que sirve de preparación en la disponibilidad de capacidad para almacenamiento e inventario controlado.

Durante el estudio se consideró el esquema DMAIC para que metodológicamente se desarrolle el proyecto, este inicia con definir la variable de interés siendo el error medio de porcentaje absoluto (MAPE), para la cual se debe encontrar una función basado en los datos históricos de ventas más los factores macroeconómicos investigados, las mismas que son medidos en una segunda etapa y luego son analizados por medio de regresión lineal para saber cuáles son significativos y para garantizar una mejora sostenible se usa programación matemática por medio de los criterios de redes neuronales recurrentes que se aplican en el método de Descenso por Gradiente para minimizar una función.

Como resultado, se obtiene un algoritmo de optimización iterativo de primer orden que es implementado en un software llamado Python el cual busca a través de iteraciones un MAPE reducido, y brinda información sobre la demanda pronosticada de dos meses con error reducido con respecto a los valores reales de esos mismos periodos.

En conclusión, se obtuvo un modelo de pronóstico de demanda del segmento de producto global que tiene 21 factores estratificados para lograr reducir el nivel de incertidumbre de la demanda de televisores para llegar a un MAPE de 24%, por otra parte desde un archivo de configuración en excel se puede facilitar el ingreso de información de manera que se tiene una herramienta que hace el Control del Sistema "Demand Forecasting RP". La recomendación es mantener actualizado cada 3 meses el archivo Data_base_X donde están todos los factores estratificados significativos.

Palabras Clave: MAPE

ABSTRACT

This project was carried out for an Assembly factory located in Durán-Ecuador, the objective of which is to reduce the level of uncertainty in the demand for televisions, by which a method is designed that contributes positively to the planning of operations and sales. Availability of storage capacity and controlled inventory.

During the study the DMAIC scheme was considered for methodological development of the project, it begins with defining the variable of interest being the mean absolute percentage error (MAPE), for which a function based on historical sales data must be found Plus the macroeconomic factors investigated, which are measured in a second stage and then analyzed by means of linear regression to know which are significant and to ensure a sustainable improvement is used mathematical programming through the criteria of recurrent neural networks that are Applied in the Gradient Drop method to minimize a function.

As a result, we obtain a first-order iterative optimization algorithm that is implemented in a software called Python which searches through iterations for a reduced MAPE and provides information about the predicted demand of two months with reduced error with respect to values Real of those same periods.

In conclusion, a model of demand forecast of the global product segment was obtained, which has 21 stratified factors to reduce the level of uncertainty of the demand of televisions to arrive at a MAPE of 24%, on the other hand from a configuration file In excel you can facilitate the input of information so that you have a tool that does the Control of the System "Demand Forecasting RP". The recommendation is to keep the Data_base_X file updated every 3 months where all the significant stratified factors are.

Keywords: MAPE

ÍNDICE GENERAL

RESUMEN.....	I
<i>ABSTRACT</i>	II
ÍNDICE GENERAL.....	III
ABREVIATURAS	V
SIMBOLOGÍA	VI
ÍNDICE DE FIGURAS.....	VII
ÍNDICE DE TABLAS	IX
CAPÍTULO 1	1
1. Introducción	1
1.1 Descripción del problema	2
1.1.1 Antecedentes	2
1.1.2 Declaración del Problema	3
1.1.3 Alcance	4
1.1.4 Restricciones.....	4
1.1.5 Justificación del proyecto	5
1.1.6 Variable de interés	6
1.1.7 Matriz de priorización de proyectos.....	6
1.2 Objetivos.....	7
1.2.1 Objetivo General	7
1.2.2 Objetivos Específicos	7
1.3 Marco teórico	7
CAPÍTULO 2.....	12
2. Metodología	12
2.1 Fase de Medición	12

2.1.1	Elaboración de Matriz de pesos	12
2.1.2	Fuentes del plan de recolección de datos	13
2.1.3	Equipo del Proyecto	14
2.1.4	Plan de recolección de datos y factores estratificados.....	15
2.1.5	Confiabilidad de los datos	16
2.1.6	Formato para uso de recolección de datos	18
2.2	Fase de Análisis	18
2.2.1	Diagrama de Ishikawa.....	19
2.2.2	Análisis de Pareto de Televisores más vendidos	19
2.2.3	Análisis estadístico de los factores estratificados	21
2.3	Fase de Mejora y Control.....	30
2.3.1	Plan de Implementación de soluciones	30
2.3.2	Instrucciones básicas de instalación del software Python.....	31
2.3.3	Diseño de un Sistema para reducir MAPE	35
2.3.4	Manual de Usuario del Sistema “Demand Forecasting RP”	43
CAPÍTULO 3.....		44
3.	Resultados	44
CAPÍTULO 4.....		46
4.	Discusión y Conclusiones	46
4.1	Conclusiones	46
4.2	Recomendaciones	47
APÉNDICES		48
BIBLIOGRAFÍA.....		70

ABREVIATURAS

ESPOL	Escuela Superior Politécnica del Litoral
DMAIC	Define, Measure, Analyze, Improve, Control
CIEC	Centro de Investigaciones Económicas
MAPE	Mean Absolute Percentage Error
VOC	Voice of Customers
V.D.	Variable Dependiente
V.I.	Variable Independiente
RNNs	Recurrent Neural Networks

SIMBOLOGÍA

H_0 :	Hipótesis nula
H_1 :	Hipótesis alterna
α :	nivel de significancia

ÍNDICE DE FIGURAS

Figura 1.1. Gráfica de descomposición de series de tiempo de Demanda Mensual usando el Método Multiplicativo	2
Figura 1.2. Exceso de inventario en piso de ensamblaje y bodega	3
Figura 1.3. Una red neuronal recurrente y el despliegue en el tiempo del cálculo implicado en su cálculo futuro.....	10
Figura 2.1. Entrevista con Ec. Pedro Zanzzi	14
Figura 2.2. Focus Group con Equipo del proyecto.....	14
Figura 2.3. Miembros del Equipo del Proyecto	15
Figura 2.4. Trazabilidad del código de barras por producto	18
Figura 2.5. Formato para recolectar datos.....	18
Figura 2.6. Análisis de causas por espina de pescado	19
Figura 2.7. Pareto de televisores más vendidos de Ene/2016 a Sep/2016.....	20
Figura 2.8. Correlación y valor-p de X_2 vs X_{1_global}	23
Figura 2.9. Aplicación del software “Minitab 17” para uso de métodos estadísticos de regresión.....	24
Figura 2.10. Valor F teórico del método “Stepwise regression” para el factor estratificado X_{1_50}	27
Figura 2.11. Valor F teórico del método “Forward regression” para el factor estratificado X_{1_50}	27
Figura 2.12. Valor F teórico del método “Backward regression” para el factor estratificado X_{1_50}	28
Figura 2.13. Búsqueda del software Python en Google - Parte 1.....	31
Figura 2.14. Búsqueda del software Python en Google - Parte 2.....	32
Figura 2.15. Verificación del Sistema Operativo en el computador.....	32
Figura 2.16. Librerías populares de aprendizaje profundo.....	33
Figura 2.17. Búsqueda del Procesador de comandos “cmd”.....	33
Figura 2.18. Activación de Tensorflow y Keras en cmd.....	34
Figura 2.19. Control del Sistema “Demand Forecasting RP”.....	36

Figura 2.20. Importación de librerías del software “Python” para programación de red neuronal recurrente.....	37
Figura 2.21. Extracción de metadatos del “archivo de configuración” de la carpeta de proyecto_ensambladora.	38
Figura 2.22. Extracción y Arreglo de datos de “Data_base_X” de la carpeta de proyecto_ensambladora.	39
Figura 2.23. Cálculo del número de muestras, construcción de matriz de entradas y salidas, tamaño de datos históricos.	40
Figura 2.24. Normalización de matrices de vectores de entrada “X”, conversión de salidas “Y”.....	40
Figura 2.25. Modelo Secuencial.....	41
Figura 2.26. Cálculo de MAPE, arreglo de índice de tiempos y gráficos de ventas. ...	42
Figura 2.27. Aplicación del software “Python” para programación de red neuronal recurrente.	43
Figura 3.1. Descomposición Gráfica de una Serie de tiempo para demanda mensual.	44
Figura 3.2. Descomposición Gráfica de una Serie de tiempo para demanda mensual.	45
Figura 3.3. Reducción del nivel de incertidumbre de la demanda.....	45

ÍNDICE DE TABLAS

Tabla 1.1. SIPOC de pronóstico de demanda	4
Tabla 1.2. Ranking 1000 mejores empresa del Ecuador 2013 – 2014 [1]	5
Tabla 1.3. Ranking 1000 mejores empresa del Ecuador 2014 – 2015 [2]	5
Tabla 1.4. Matriz de priorización de soluciones	6
Tabla 2.1. Matriz de pesos de situaciones que afectan a la asertividad del pronóstico de demanda.....	13
Tabla 2.2. Factores Estratificados para modelo de pronóstico de demanda	15
Tabla 2.3. Confiabilidad de los factores estratificados	17
Tabla 2.4. Identificación de ventas históricas globales y por tamaño de televisores más vendidos	20
Tabla 2.5. Correlación de factores estratificados con periodos originales versus ventas	22
Tabla 2.6. Correlación de factores estratificados con 3 periodos anteriores versus ventas	22
Tabla 2.7. Ecuaciones de regresión de las ventas históricas para el factor estratificado X_{1_50}	25
Tabla 2.8. Valor F del Análisis de Varianza del método “Stepwise regression” para el factor estratificado X_{1_50}	25
Tabla 2.9. Valor F del Análisis de Varianza del método “Forward regression” para el factor estratificado X_{1_50}	25
Tabla 2.10. Valor F del Análisis de Varianza del método “Backward regression” para el factor estratificado X_{1_50}	26
Tabla 2.11. Comparación del Valor F teórico contra Valor F_{α} de cada método de regresión para el factor estratificado X_{1_50}	29
Tabla 2.12. Datos de los R^2 ajustados de cada método de regresión para el factor estratificado X_{1_50}	29
Tabla 2.13. Verificación del R^2 ajustado de cada método de regresión para el factor estratificado X_{1_50}	30
Tabla 2.14. Plan de implementación de soluciones.....	31
Tabla 2.15. Factores significativos para el factor X_{1_global}	35

Tabla 2.16. Cuadro de hoja de cálculo para el factor X_{1_global} 39

CAPÍTULO 1

1. INTRODUCCIÓN

En Ecuador, por ser un país en vías de desarrollo no se cuenta claramente con una información asertiva sobre el futuro en el que los negocios prosperan en el campo empresarial a diferencia de otros países del mundo, por ello, hoy en día se ha convertido un tema de importancia crucial ser competitivos, es decir, saber administrar los recursos de forma óptima, y a su vez contar con una correcta planeación de las actividades, en el caso de las industrias se traduce en manejar de una forma correcta la gerencia de las operaciones cuando se logra un buen manejo de inventario de materia prima y/o producto terminado para cubrir una demanda en un periodo de tiempo determinado, sea corto, mediano o largo plazo.

En el negocio de empresas ensambladoras de televisores según los datos del Ministerio de Industrias y Productividad (MIPRO), son alentadores con miras a cambiar la matriz productiva porque según las estadísticas en el año 2015 el 70% de los televisores que se venden en el país son ensamblados localmente, por lo que es un mercado atractivo dado que la tecnología avanza muy rápido de modo que existen muy pocas fábricas en el mundo para producir en gran volumen o dinámica, sin embargo, para lograr una excelente nivel de ventas, implica basarse en alguna referencia que denote conocer el mercado de artículos del futuro y para ello lo elemental es partir de un pronóstico de demanda.

El presente estudio tiene como principal objetivo minimizar el error porcentual del pronóstico de demanda a través de un método cuantitativo adecuado que estará ajustada por el comportamiento real de ventas históricas de televisores más factores exógenos, de modo que se incluyen las variables que tienen fuerte impacto en un pronóstico con mayor asertividad.

Finalmente, con el proyecto a través de una prueba piloto se espera obtener los niveles eficientes para cubrir necesidades del mercado de modo que evite faltantes de productos para la venta o en su defecto no llegar a tener una gran cantidad de productos terminados dentro de bodegas, ya que al quedarse con exceso de

inventario ocasiona; despilfarro de tiempo y dinero que dicho de otro modo son pérdidas económicas, dificultad de liquidar productos por obsolescencia, se merma participación en el mercado local, y se cede oportunidades a la competencia.

1.1 Descripción del problema

En la definición del problema se analiza en detalle la incertidumbre que tiene la organización del caso de estudio al pronosticar la demanda de productos, comparando sus ventas históricas y las que ajustadamente debería considerar para producciones mensuales, tomando como fuente de información todos los datos provenientes del sistema SAP Business One desde Enero 2013 hasta Septiembre 2016, fecha correspondiente al inicio del presente estudio.

1.1.1 Antecedentes

La empresa ensambladora es una industria tecnológica constituida en el año 2008 y ubicada dentro de la Provincia del Guayas, dedicada al ensamblaje y comercialización de productos de audio-video especializada en la producción de televisores para el mercado ecuatoriano. Acorde a un diagnóstico inicial las complicaciones en las operaciones tanto para producción y las actividades de cada área de la cadena de abastecimiento se dan porque hay un elevado nivel de incertidumbre expresado en error porcentual del 47% (Figura 1.1) en pronosticar demandas efectivas, lo cual está generando exceso de inventarios (Figura1.2).

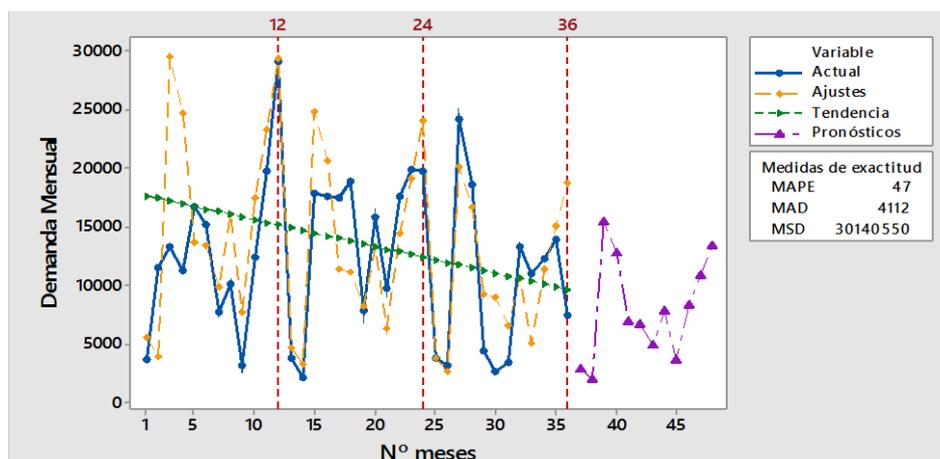


Figura 1.1. Gráfica de descomposición de series de tiempo de Demanda Mensual usando el Método Multiplicativo

Fuente: Elaboración propia.



Figura 1.2. Exceso de inventario en piso de ensamblaje y bodega

Fuente: Elaboración propia.

1.1.2 Declaración del Problema

Para profundizar el problema de una forma creativa se aplica la técnica de preguntas con palabras interrogativas 5W1H.

1.1.2.1 What? (¿Qué?)

La empresa ensambladora de televisores incrementa sus productos terminados e inventarios dado que hay incertidumbre en la demanda por parte de los clientes.

1.1.2.2 When? (¿Cuándo?)

Desde Marzo 2016.

1.1.2.3 Where? (¿Dónde?)

En el piso de ensamblaje y bodega.

1.1.2.4 How much? (¿Qué tanto?)

En promedio, el error del pronóstico de demanda está por 47%.

1.1.2.5 Why? (¿Por qué?)

Porque hay un crecimiento en la importación de CKD y decrecimiento en las ventas de televisores.

1.1.2.6 Who? (¿Quién?)

El CEO es quien toma las decisiones.

1.1.3 Alcance

En esta parte se usa como valor agregado a la consultoría del proyecto la herramienta SIPOC que facilita el diagnóstico del proceso de estimación de demandas futuras a través de la identificación de todos los elementos relevantes, por la cual, se crea un mapa de proceso de alto nivel que define el alcance del proyecto y sus principales ingresos, salidas, proveedores y clientes, que durante el desarrollo de este proyecto se busca mejorar para cumplir los objetivos a trabajar.

Tabla 1.1. SIPOC de pronóstico de demanda

Proveedores	Ingresos	Proceso	Salidas	Clientes
(Proveedores de los recursos requeridos)	(Recursos requeridos por el proceso)	(Descripción de alto nivel de la actividad)	(Entregables del proceso)	(Personas que reciben las salidas)
Sistema SAP Business One	Datos históricos	Elaborar base de datos de ventas	Nivel de demanda por año	Dpto Comercial
Dpto Comercial	Nivel de demanda por año	Clasificar productos	Productos ensamblados por tamaño	Gerente de Planta
Aduana	Datos de Importación	Comparar y analizar datos	Productos de mayor consumo	CEO
Gerente de Planta	productos top por tamaño			Gerente de Planta
Gerente de Planta	Productos de mayor consumo	Estimar demanda futura	Información para importar CKD	Bodega
			Actualización del plan de producción	Planeador de Producción
			Información de venta a mayorista	Distribuidores

Fuente: Elaboración propia.

1.1.4 Restricciones

- Todo lo referente al proyecto tiene una duración máxima de sólo 4 meses.
- La información de cantidad del sistema SAP se describe en meses.
- Falta de registro y visión de la empresa.
- El método de pronóstico de la demanda toma como entrada de todos los datos históricos de ventas disponibles (productos principales por tamaño), junto con datos macroeconómicos adicionales (por ejemplo, niveles de empleo, tasa de inflación, precios del petróleo, etc.).
- Tener al menos 5 factores macroeconómicos para encontrar un modelo matemático.

1.1.5 Justificación del proyecto

La empresa en estudio tiene como matriz productiva la concentración en productos tecnológicos donde la innovación es muy frecuente, siendo así, que al tener incertidumbre o no tener asertividad sobre la cantidad de televisores a producir ocasiona mucha variabilidad en los procesos de manera que se vuelve un punto crítico, ya que al tener exceso de inventario se despilfarra recursos como tiempo y dinero que dicho de otro modo se transforma en pérdidas económicas, dificultad de liquidar productos por obsolescencia, merma en la participación del mercado local, y se permite oportunidades a la competencia.

Tabla 1.2. Ranking 1000 mejores empresa del Ecuador 2013 – 2014 [1]

Rk. 2014	Rk. 2013	Cambio de posición	Razón Social	Total Ingresos (USD millones)		
				2013	2014	crecimiento 2014
174	388	Subió +214	AUDIOVISION ELECTRONICA AUDIOELEC S.A.	49,1	110,1	124,2%

Fuente: Ekosnegocios, 2015.

A nivel de competitividad en nuestro país, por medio de la revista empresarial Ekosnegocios se puede observar lo que hace público el “Ranking 1000 mejores empresas del Ecuador”, el cual es otro punto de análisis del status de la evolución de la empresa ensambladora de televisores entre los periodos del 2013 hasta 2015.

Tabla 1.3. Ranking 1000 mejores empresa del Ecuador 2014 – 2015 [2]

Rk. 2015	Rk. 2014	Cambio de posición	Razón Social	Ingresos (USD millones)		
				2014	2015	Variación Anual
210	174	↓-36	AUDIOVISIÓN ELECTRÓNICA AUDIOELEC S.A.	110,13	78,42	-28,8%

Fuente: Ekosnegocios, 2015.

En síntesis, se evidencia que la empresa del año 2014 al 2015 ha bajado 36 posiciones que se deben a la disminución de ingresos a diferencia de lo que había logrado en un periodo anterior y por esto la organización espera

mejorar aplicando un buen método de pronóstico de demanda para retomar altos estándares de competencia en el que estuvo anteriormente.

1.1.6 Variable de interés

Se utiliza el estadístico MAPE (Mean Absolutly Percent Error) como principal enfoque, ya que es una forma de determinar cuantitativamente la incertidumbre que tiene la empresa, considerando la ecuación 1.1 donde se toma los datos de; la demanda real vs la demanda pronosticada.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - Y_t|}{Y_i} \quad (1.1)$$

Y_i : demanda real

Y_t : demanda pronosticada

1.1.7 Matriz de priorización de proyectos

Al establecer soluciones que sean viables para la empresa se toma a consideración realizar un cuadro de relaciones entre criterios operacionales e impactos de alternativas de proyectos para priorizar cuál de ellas tienen mayor efecto para resolver el problema enfocado de la empresa.

Tabla 1.4. Matriz de priorización de soluciones

Matriz de priorización de proyectos		CRITERIOS OPERACIONALES											
		Relación con estrategia y objetivos	Relación con procesos claves del negocio	Impacto a la satisfacción del cliente	Disponibilidad de datos	Medible	ROI	Complejidad / Relación interdepartamental	Tiempo para resolver el problema	Fácil de analizar el impacto financiero	Impacto a la satisfacción del empleado	Disponibilidad de recursos	TOTAL
Impacto de criterios de selección		8	10	10	8	10	5	5	10	5	10	8	
A	Hacer un buen benchmarking	3	5	8	3	5	3	5	8	3	8	5	483
B	Elaborar un plan integrado entre ventas y operaciones	10	10	8	8	8	3	5	3	5	3	3	553
C	Establecer alianzas estratégicas con los clientes	10	10	5	5	5	5	3	3	5	8	5	535
D	Diseñar un método de pronóstico de demanda	10	10	10	8	10	5	5	8	5	10	8	763

Fuente: Elaboración propia.

1.2 Objetivos

1.2.1 Objetivo General

- Diseñar un método de pronóstico de demanda para una fábrica ensambladora de televisores, para que facilite la toma de decisiones con menores niveles de incertidumbre.

1.2.2 Objetivos Específicos

- Desarrollar un programa informático de acuerdo a las restricciones de compatibilidad y devuelve como resultado un pronóstico de la demanda del producto terminado.
- Simular un método de pronóstico de la demanda en Python Software.
- Desarrollar un manual de usuario para el programa informático mencionado.
- Reducir el error real del pronóstico de demanda en (47%) a la mitad.

1.3 Marco teórico

Herramienta 5W1H

5W1H significa las seis palabras con que comienzan las preguntas que deben responderse para describir correctamente un hecho: qué, cuándo, dónde, quién, por qué y cómo (what, when, where, who, why y how). Se recomienda que la gente de los CCC siga y formule estas preguntas para comprender los hechos sin omisión alguna. [3]

EI VOC

Para lograr la determinación de la demanda y los requerimientos del cliente, se decide emplear la metodología voz del cliente cuyo fin es recolectar información proveniente del beneficiario principal del producto o servicio en investigación. Se lo realiza empleando diferentes herramientas tales como entrevistas, encuestas, foros, grupos focales y otros. [4]

Método Seis Sigma-DMAIC

El método Seis Sigma, conocido como DMAIC, consiste en la aplicación, proyecto a proyecto, de un proceso estructurado en cinco fases: definir, medir, analizar, mejorar, controlar.

En la fase de definición se identifican los posibles proyectos Seis Sigma, que deben ser evaluados por la dirección para evitar la infrautilización de recursos. Una vez seleccionado el proyecto, se prepara su misión y se selecciona el equipo más adecuado, asignándole la prioridad necesaria.

La fase de medición consiste en la caracterización del proceso identificando los requisitos clave de los clientes, las características clave del producto (o variables del resultado) y los parámetros (variables de entrada) que afectan el funcionamiento del proceso y las características o variables clave. A partir de esta caracterización, se define el sistema de medida y se mide la capacidad del proceso.

En la tercera fase, análisis, el equipo analiza los datos de resultados actuales e históricos. Se desarrollan y comprueban hipótesis sobre posibles relaciones causa-efecto utilizando las herramientas estadísticas pertinentes. De esta forma, el equipo confirma los determinantes del proceso, es decir, las variables clave de entrada o “pocos vitales” que afectan a las variables de respuesta del proceso.

En la fase de mejora, el equipo trata de determinar la relación causa-efecto (relación matemática entre las variables de entrada y la variable de respuesta que interese), para predecir, mejorar y optimizar el funcionamiento del proceso. Por último, se determina el rango operacional de los parámetros o variables de entrada del proceso.

La última fase, control, consiste en diseñar y documentar los controles necesarios para asegurar lo conseguido mediante el proyecto Seis Sigma se mantenga una vez que se hayan implantado los cambios. Cuando se han logrado los objetivos y la misión se dé por finalizada, el equipo informa a la dirección y se disuelve. [5]

El resultado deseado dentro de esta metodología es conocido como variable de respuesta o característica de calidad “Y” y las variables independientes que influyen a este resultado como “X’s”.

Dentro de un proceso pueden existir varias variables independientes X’s que podrían tener relación con la variable de respuesta Y, de todas estas X’s la metodología busca determinar aquellas X’s vitales que afecten el desempeño

de la variable de respuesta (Y) y establecer su relación como una ecuación matemática. [6]

Regresión Lineal Múltiple

La base de una regresión lineal múltiple es evaluar si una variable dependiente continua puede predecirse a partir de un conjunto de variables independientes o predictoras, es decir, cuánta varianza en una variable dependiente continua se explica por un conjunto de predictores.

Métodos Estadísticos de Regresión

La “Selección Hacia adelante” (Forward Selection) comienza con una ecuación vacía. Los predictores se añaden uno a uno comenzando con el predictor con la correlación más alta con la variable dependiente. Primero se introducen variables de mayor importancia teórica. Una vez en la ecuación, la variable permanece allí.

La “Eliminación hacia atrás” (Backward Elimination) es el proceso inverso. Todas las variables independientes se introducen primero en la ecuación y cada una se borra una a una si no contribuyen a la ecuación de regresión.

La “selección paso a paso” (Stepwise Selection) se considera una variación de los dos métodos anteriores. La selección paso a paso implica el análisis en cada paso para determinar la contribución de la variable predictora introducida previamente en la ecuación. De esta forma es posible entender la contribución de las variables anteriores ahora que se ha agregado otra variable. Las variables pueden ser retenidas o eliminadas en base a su contribución estadística. [7]

Redes Neuronales

Haciendo una analogía con el cerebro humano, no son más que un modelo artificial y simplificado que disponemos para un sistema que es capaz de adquirir conocimiento a través de la experiencia, en otras palabras es “un nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona”. [8]

Redes Neuronales Recurrentes

Con respecto a la inteligencia artificial, la idea detrás de RNNs es hacer uso de la información secuencial. En una red neuronal tradicional suponemos que todas las entradas (y salidas) son independientes entre sí. Pero para muchas tareas es una mala idea. Si quieres predecir la siguiente palabra en una oración, mejor sabes qué palabras le precedieron. Los RNN se llaman recurrentes porque realizan la misma tarea para cada elemento de una secuencia, dependiendo la salida de los cálculos anteriores. Otra forma de pensar en las RNN es que tienen una "memoria" que captura información sobre lo que se ha calculado hasta ahora. En teoría, las RNN pueden hacer uso de la información en secuencias arbitrariamente largas, pero en la práctica se limitan a mirar hacia atrás sólo unos pocos pasos (más sobre esto más adelante). Esto es lo que parece un RNN típico:

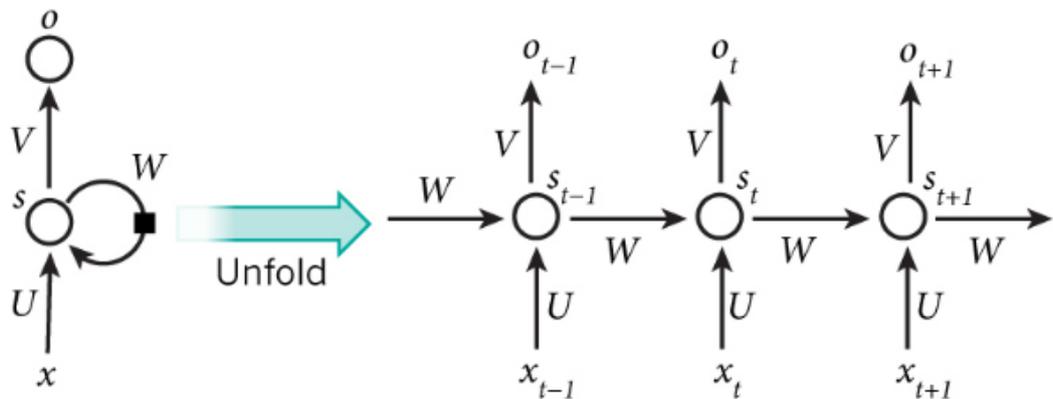


Figura 1.3. Una red neuronal recurrente y el despliegue en el tiempo del cálculo implicado en su cálculo futuro.

Fuente: RECURRENT NEURAL NETWORKS TUTORIAL, 2015.

El diagrama anterior muestra un RNN que está siendo desenrollado (o desplegado) en una red completa. Al desenrollar simplemente queremos decir que escribimos la red para la secuencia completa. Por ejemplo, si la secuencia que nos interesa es una oración de 5 palabras, la red sería desenrollada en una red neuronal de 5 capas, una capa para cada palabra. Las fórmulas que rigen el cálculo que ocurre en una RNN son las siguientes:

- x_t es la entrada en el paso de tiempo t .
- s_t es el estado oculto en el paso del tiempo t . Esto es la "memoria" de la red. s_t que se calcula en función del estado oculto anterior y de la entrada del paso actual: $s_t = f(Ux_t + Ws_{t-1})$. La función suele ser una no linealidad como tanh o ReLU. s_{-1} , que se requiere para calcular el primer estado oculto, se inicializa típicamente a todos los ceros.
- o_t is es la salida en el tiempo t . [9]

CAPÍTULO 2

2. METODOLOGÍA

En esta sección se presenta los pasos posteriores a la fase de Definición tratado en el capítulo 1, es decir, se continua con el esquema DMAIC con el fin de desarrollar las actividades y los elementos que forman parte de la fase de Medición, Análisis, Mejora y Control.

Las primeras fases de Medición y Análisis se llevan a cabo según el plan de recolección y análisis de datos donde se desea conocer los factores exógenos que influyen en el modelo de pronóstico de demanda de televisores.

Las últimas fases de Mejora y Control finalmente se encuentra en detalle la solución propuesta al problema desarrollada en una prueba piloto para reducir la incertidumbre que genera un gran error porcentual, así como medidas para que la mejora sea implementada con éxito y se mantenga en el tiempo.

2.1 Fase de Medición

En esta parte lo que se desea es recolectar la mayor cantidad de datos posibles que generen valor agregado al modelo a desarrollar.

2.1.1 Elaboración de Matriz de pesos

Para iniciar, se contempla cuáles son las posibles situaciones que generan mayor relación en la variable de interés denominada MAPE, es decir, aquellas que con mayor peso influyen en el incremento de incertidumbre al pronosticar demanda.

A continuación, en un recuadro se puede apreciar de forma cuantitativa sobre las tres opciones de mayor peso que se van enfocar.

Los criterios para evaluar cada una son; severidad, ocurrencia y costo. También tenemos que los valores a usar para el cálculo del peso de cada opción son de; 1, 3, 6 y 9, considerando como bajo nivel igual a 1 y alto nivel igual a 9.

Tabla 2.1. Matriz de pesos de situaciones que afectan a la asertividad del pronóstico de demanda

Nº	Situaciones o causas	Severidad	Ocurrencia	Costos	Pesos
1	Poco conocimiento del comportamiento de demanda	9	6	3	162
2	Base de datos general de importaciones	3	6	6	108
3	Desconocimiento de datos macro-económicos	9	9	6	486
4	Predicción solamente con ventas históricas	9	6	1	54
5	Poca inversión de programa para pronóstico	6	9	6	324

Fuente: Elaboración propia.

Finalmente como resultado del cálculo sobre las situaciones de mayor impacto son:

- 1.- Desconocimiento de datos macro-económicos, con 486 puntos.
- 2.- Poca inversión de programa para pronóstico, con 324 puntos.
- 3.- Poco conocimiento del comportamiento de demanda, con 162 puntos.

Con esto, se estructura una recolección de información cuantitativa que vaya acorde a lo encontrado y permita llegar a conocer los factores exógenos adecuados para el presente proyecto.

2.1.2 Fuentes del plan de recolección de datos

A priori, los factores endógenos son los datos disponibles internamente en la compañía, los mismos que corresponden a todas las ventas históricas registradas en el sistema SAP Business One, sin embargo, con respecto a los factores exógenos se aterriza una lluvia de ideas sobre cuáles podrían ser los factores adecuados a medir y a su vez considerar para la situación socioeconómica, por ello, se acude al CIEC (Centro de Investigaciones Económicas) por medio del Ec. Pedro Zanzzi Diaz quien recomienda en forma general tomar en cuenta los factores macroeconómicos muy a parte de las ventas históricas, las cuales son:

- Tasa de empleo, desempleo y subempleo.
- Tasa de pobreza.
- Tasa de PIB per cápita real.
- Tasa de población territorial.
- Nivel de competencia de CKD y televisores.
- Importaciones de televisores por medio de la Aduana.



Figura 2.1. Entrevista con Ec. Pedro Zanzzì

Fuente: CIEC, 2016.

La información recomendada de los factores macroeconómicos (exógenos) la mayoría se obtiene del CIEC, pero con respecto a los datos de importaciones de CKD y televisores es por medio del departamento de Importaciones que tiene usuario del sistema Cobus Group el cual brinda información de Aduana.

En general, como se observa se ha segregado lo que se debe estimar en el modelo y de lo que no se debe considerar, ya que es necesario aplicar datos que tienen un impacto en una fábrica ensambladora de televisores.

2.1.3 Equipo del Proyecto

Integra a los colaboradores de áreas claves que están inmersas en la operación diaria y que para la recolección de datos son canales de acceso y apoyo para hallar información relevante al proyecto, además que por medio de “focus group” participan con el propósito de aportar al éxito de cada etapa.



Figura 2.2. Focus Group con Equipo del proyecto

Fuente: Sala de sesiones de la empresa, 2016.



Figura 2.3. Miembros del Equipo del Proyecto

Fuente: Recursos Humanos de la empresa, 2016.

2.1.4 Plan de recolección de datos y factores estratificados

Con respecto a las variables que se incluyen en el modelo, se establece la identificación de cada una de ellas, más el detalle del plan de recolección de datos se aprecia en la siguiente tabla 2.2.

Los factores estratificados son:

Tabla 2.2. Factores Estratificados para modelo de pronóstico de demanda

<i>Factores Estratificados</i>		<i>¿Dónde está registrado?</i>
X₁	Ventas históricas	System SAP Business One
X₂	Tasa Urbana de Empleo Adecuado/pleno	Instituto Nacional de Estadística y Censos (INEC)
X₃	Tasa urbana de subempleo	Instituto Nacional de Estadística y Censos (INEC)
X₄	Tasa urbana de empleo no remunerado	Instituto Nacional de Estadística y Censos (INEC)
X₅	Tasa urbana de otros empleos no pleno	Instituto Nacional de Estadística y Censos (INEC)
X₆	Tasa urbana de Empleo no Clasificado	Instituto Nacional de Estadística y Censos (INEC)
X₇	Tasa urbana de Desempleo	Instituto Nacional de Estadística y Censos (INEC)
X₈	Tasa urbana de población	Instituto Nacional de Estadística y Censos (INEC)

X₉	Incidencia de pobreza nacional	Instituto Nacional de Estadística y Censos (INEC)
X₁₀	Incidencia de pobreza urbana	Instituto Nacional de Estadística y Censos (INEC)
X₁₁	Índice de Inflación_Nacional	Instituto Nacional de Estadística y Censos (INEC)
X₁₂	Variación porcentual Anual de Inflación_Nacional	Instituto Nacional de Estadística y Censos (INEC)
X₁₃	PIB_Bienes y Servicios	Banco Central del Ecuador
X₁₄	PIB_Valor Agregado Bruto por industria	Banco Central del Ecuador
X₁₅	Índice del precio del Crudo del Petróleo	Federal Reserve Economic Data
X₁₆	Índice del precio del Vidrio	Federal Reserve Economic Data
X₁₇	Datos Globales de Aduana_CKD	CobusGroup
X₁₈	Datos Globales de Aduana_TV	CobusGroup
X₁₉	Importador 1 (CKD)	CobusGroup
X₂₀	Importador 2 (CKD)	CobusGroup
X₂₁	Importador 3 (CKD)	CobusGroup
X₂₂	Importador 1 (Tv)	CobusGroup
X₂₃	Importador 2 (Tv)	CobusGroup
X₂₄	Importador 3 (Tv)	CobusGroup

Fuente: Elaboración propia.

2.1.5 Confiabilidad de los datos

Se procede a verificar la confiabilidad de información obtenida por factor estratificado, esto es, con la finalidad de conocer si poseen distribución normal por su tamaño de muestra, no obstante, si hay algún factor que tiene como disponible una cantidad menor a treinta datos es debido a que las frecuencias son trimestrales pero posteriormente se debe aplicar interpolación para encontrar datos mensuales, por otra parte, para los datos estudiados por el INEC referentes a tasas urbanas se aplica un cálculo de error para determinar si la información pertenece a una distribución normal, siendo eficiente y correcto cuando el error sea menor a 5%, por lo tanto, a continuación se muestra con sus detalles en la tabla 2.3:

Tabla 2.3. Confiabilidad de los factores estratificados

Descripción (Factores Estratificados)	Frecuencia	# años	# puntos	Evidencia: ¿Donde está registrado?	# personas encuestadas			
					¿Se aplica esto?	Tamaño de la muestra	Tamaño de Población Económicamente Activa	% Rango Error (≤5%)
X ₁ Ventas históricas	mensual	3	36	System SAP Business One	No	N/A	N/A	N/A
X ₂ Tasa urbana de Empleo Adecuado/pleno	trimestral	3	12	Instituto Nacional de Estadística y Censos (INEC)	Si	2586	6093173	1,93%
X ₃ Tasa urbana de subempleo	trimestral	3	12	Instituto Nacional de Estadística y Censos (INEC)	Si	2586	6093173	1,93%
X ₄ Tasa urbana de empleo no remunerado	trimestral	3	12	Instituto Nacional de Estadística y Censos (INEC)	Si	2586	6093173	1,93%
X ₅ Tasa urbana de otros empleos no pleno	trimestral	3	12	Instituto Nacional de Estadística y Censos (INEC)	Si	2586	6093173	1,93%
X ₆ Tasa urbana de Empleo no Clasificado	trimestral	3	12	Instituto Nacional de Estadística y Censos (INEC)	Si	2586	6093173	1,93%
X ₇ Tasa urbana de Desempleo	trimestral	3	12	Instituto Nacional de Estadística y Censos (INEC)	Si	2586	6093173	1,93%
X ₈ Tasa urbana de población	trimestral	3	12	Instituto Nacional de Estadística y Censos (INEC)	Si	2586	6093173	1,93%
X ₉ Incidencia de pobreza nacional	trimestral	3	12	Instituto Nacional de Estadística y Censos (INEC)	Si	6873	6093173	1,18%
X ₁₀ Incidencia de pobreza urbana	trimestral	3	12	Instituto Nacional de Estadística y Censos (INEC)	Si	6873	6093173	1,18%
X ₁₁ Índice de Inflación_Nacional	mensual	3	36	Instituto Nacional de Estadística y Censos (INEC)	No	N/A	N/A	N/A
X ₁₂ Variación porcentual Anual de Inflación_Nacional	mensual	3	36	Instituto Nacional de Estadística y Censos (INEC)	No	N/A	N/A	N/A
X ₁₃ PIB_Bienes y Servicios	trimestral	3	12	Banco Central del Ecuador	No	N/A	N/A	N/A
X ₁₄ PIB_valor Agregado Bruto por industria	trimestral	3	12	Banco Central del Ecuador	No	N/A	N/A	N/A
X ₁₅ Índice del precio del Crudo del Petróleo	mensual	3	36	Federal Reserve Economic Data	No	N/A	N/A	N/A
X ₁₆ Índice del precio del Vidrio	mensual	3	36	Federal Reserve Economic Data	No	N/A	N/A	N/A
X ₁₇ Datos Globales de Aduana_CKD	mensual	3	36	CobusGroup	No	N/A	N/A	N/A
X ₁₈ Datos Globales de Aduana_TV	mensual	3	36	CobusGroup	No	N/A	N/A	N/A
X ₁₉ Importador 1 (CKD)	mensual	3	36	CobusGroup	No	N/A	N/A	N/A
X ₂₀ Importador 2 (CKD)	mensual	3	36	CobusGroup	No	N/A	N/A	N/A
X ₂₁ Importador 3 (CKD)	mensual	3	36	CobusGroup	No	N/A	N/A	N/A
X ₂₂ Importador 1 (Tv)	mensual	3	36	CobusGroup	No	N/A	N/A	N/A
X ₂₃ Importador 2 (Tv)	mensual	3	36	CobusGroup	No	N/A	N/A	N/A
X ₂₄ Importador 3 (Tv)	mensual	3	36	CobusGroup	No	N/A	N/A	N/A

Fuente: Elaboración propia.

Respecto a las ventas históricas registradas en el sistema SAP Business One tienen alta confiabilidad porque durante el proceso de producción se pistolea (registra) cada producto con su respectivo código de barras grabándose en una etiqueta única que lleva cada televisor y sirve como identificación para ingresar la existencia del ítem al sistema SAP, este último a su vez no permite repetibilidad ni reproducibilidad de modo que facilita la trazabilidad que se hace desde que existe un producto ensamblado en producción hasta se despache dicho producto terminado de la bodega, lo que significa para este estudio no hay equivocaciones en la información obtenida.



Figura 2.4. Trazabilidad del código de barras por producto

Fuente: Elaboración propia.

En la figura 2.4 que muestra un ejemplo de trazabilidad se evidencia cuando un operador está registrando la información al sistema de un conjunto de productos de 50”.

2.1.6 Formato para uso de recolección de datos

lt	Year	Month	X _{1,general}	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈	X ₉	X ₁₀	X ₁₁	X ₁₂
16	2014	abr	17.658	55.90	10.79	3.85	23.49	0.36	5.63	61.61	24.58	16.60	98.86	2.56
17	2014	may	17.466	56.92	10.71	3.78	22.56	0.35	5.67	61.76	24.55	16.45	98.82	2.06
18	2014	jun	18.852	57.94	10.64	3.72	21.64	0.35	5.72	61.92	24.53	16.30	98.93	4.20
19	2014	jul	7.887	57.84	10.44	3.93	22.04	0.37	5.37	62.04	24.60	16.14	99.33	3.71
20	2014	ago	15.819	57.73	10.25	4.15	22.45	0.40	5.02	62.16	24.68	15.98	99.53	2.86
21	2014	sep	9.770	57.63	10.06	4.36	22.86	0.43	4.67	62.28	24.75	15.82	100.14	3.86
22	2014	oct	17.623	57.22	10.61	4.29	22.88	0.38	4.62	62.53	24.00	16.02	100.35	4.48
23	2014	nov	19.930	56.80	11.16	4.22	22.90	0.33	4.58	62.78	23.24	16.23	100.53	4.64
24	2014	dic	19.829	56.39	11.71	4.15	22.93	0.28	4.54	63.03	22.49	16.43	100.64	4.85
25	2015	ene	3.832	55.44	11.77	4.35	23.42	0.38	4.64	62.95	22.16	15.98	101.24	8.65
26	2015	feb	3.181	54.49	11.83	4.56	23.91	0.48	4.74	62.86	21.83	15.52	101.86	9.70
27	2015	mar	24.170	53.54	11.89	4.76	24.40	0.57	4.84	62.78	21.50	15.07	102.28	10.74
28	2015	abr	18.570	53.81	11.94	4.87	23.98	0.64	5.08	63.09	21.97	14.86	103.14	11.54
29	2015	may	4.454	54.07	12.00	4.58	23.31	0.71	5.33	63.40	21.84	14.65	103.32	12.27
30	2015	jun	2.657	54.34	12.05	4.48	22.77	0.78	5.58	63.71	22.01	14.44	103.74	13.98
31	2015	jul	3.381	54.36	12.50	4.57	22.27	0.75	5.54	64.25	22.12	14.62	103.66	15.74
32	2015	ago	13.254	54.38	12.95	4.66	21.77	0.73	5.51	64.79	22.24	14.80	103.66	18.54
33	2015	sep	11.046	54.39	13.40	4.75	21.27	0.70	5.48	65.34	22.35	14.98	103.93	16.63
34	2015	oct	12.217	54.28	13.18	4.59	21.67	0.75	5.54	65.10	22.66	15.21	103.84	14.73
35	2015	nov	13.948	54.16	12.96	4.43	22.07	0.79	5.59	64.87	22.97	15.45	103.95	13.41
36	2015	dic	7.433	54.04	12.75	4.26	22.47	0.84	5.65	64.63	23.28	15.68	104.05	10.42

Figura 2.5. Formato para recolectar datos

Fuente: Elaboración propia.

Para recolectar los datos se hace un cuadro que contiene un encabezado de cada variable o factor estratificado descrito por columnas, y las fechas mensuales están descritas por fila.

2.2 Fase de Análisis

Una vez realizadas las mediciones en la fase pasada, en la presente se analiza la relación entre las causas y la declaración del problema, además de conocer cuál de todos los factores tomados son significativos al momento de establecer el modelamiento de pronóstico de demanda, por ello, antes se

indica que para lograr un enfoque objetivo se consideran los productos de mayor rotación durante el año 2016 para en base a esto se pueda contemplar una proyección futura.

2.2.1 Diagrama de Ishikawa

Esta herramienta también conocida como espina de pescado, permite encontrar las causas raíces que generan impacto en el problema, por ello, se visualiza de la siguiente forma en la figura 2.6:

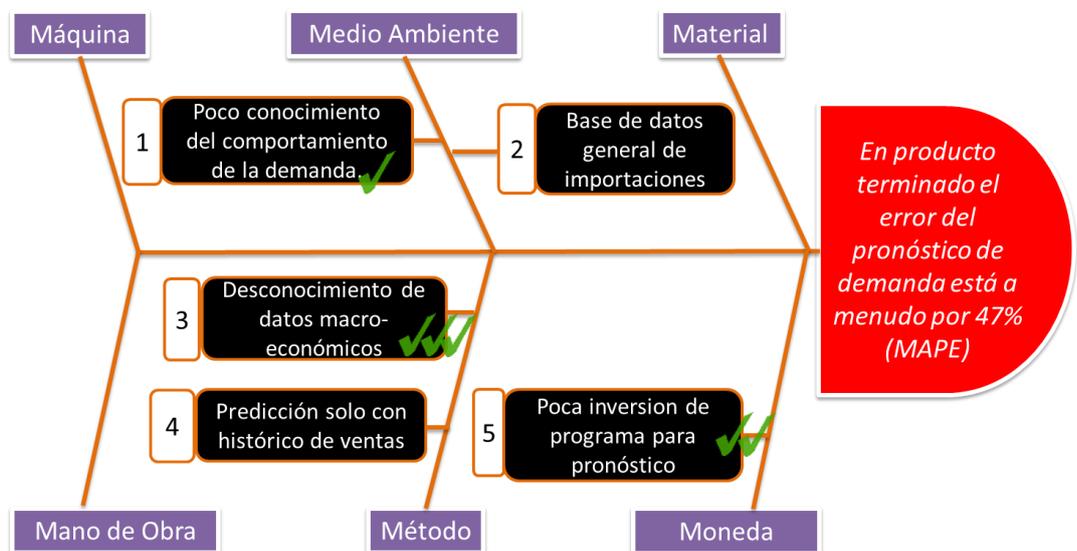


Figura 2.6. Análisis de causas por espina de pescado

Fuente: Elaboración propia.

Corroborando que las situaciones medidas en el capítulo anterior han sido las apropiadas, luego se procede a revisar con más detalle los factores endógenos como los factores exógenos.

2.2.2 Análisis de Pareto de Televisores más vendidos

El compromiso de la empresa ensambladora es servir al cliente con lo mejor de la gama de televisores disponibles y si se busca satisfacer la demanda del futuro mercado se debe analizar cuáles son los productos más vendidos o requeridos para enfocar el esfuerzo del presente proyecto.

La clasificación de televisores en general radica un 70% por su tamaño y un 30% por preferencias tecnológicas, sin embargo, según la evolución tecnológica muestra que la tendencia es tener televisores con características SMART, más no con la tecnología DIGITAL.

Por otra parte, se recalca que el 90% del costo de un televisor es la pantalla o panel, de manera que al final del día lo que interesa de un producto es el tamaño.

Por lo antes mencionado, se establece el criterio de 80-20 de Pareto para tomar en cuenta los televisores que generan mayor ingreso según su tamaño, con ello, al menos el 80% son los pocos vitales y 20% los muchos triviales.

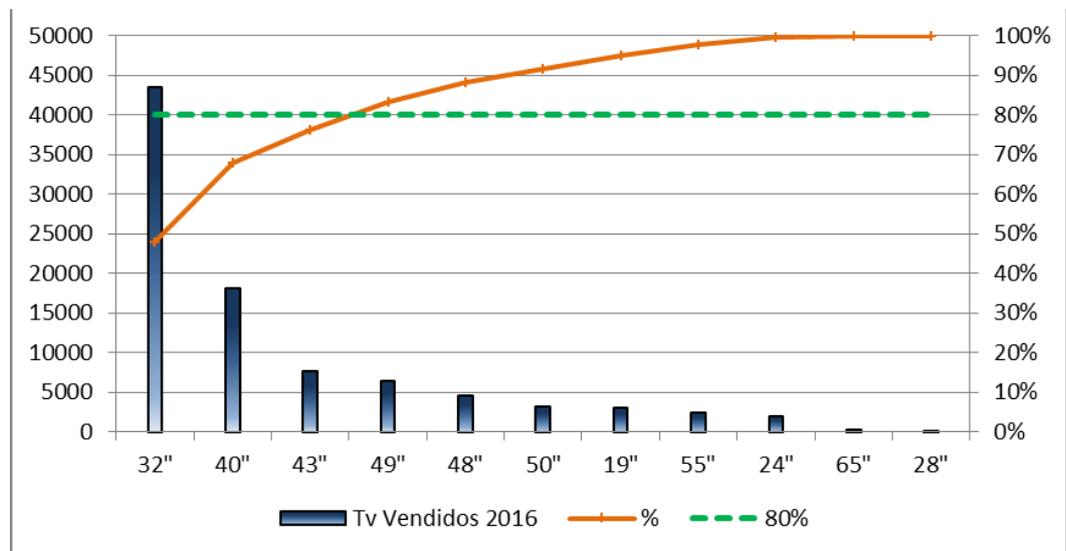


Figura 2.7. Pareto de televisores más vendidos de Ene/2016 a Sep/2016

Fuente: Elaboración propia.

Como se observa en la figura 2.7 los televisores importantes acorde a su tamaño son: 32", 40", 43", 49", además de esto, también se opta escoger los de 48" y 50" para incluirlos en el análisis porque tiene una tendencia creciente en su demanda.

Una vez seleccionado los televisores más vendidos al cual se hace el estudio, se procede a filtrar las ventas globales a ventas por tamaño, asignando una nomenclatura como factor a cada una de ellas, las cuales son identificadas en la tabla 2.4.

Tabla 2.4. Identificación de ventas históricas globales y por tamaño de televisores más vendidos

X_{1_global}	Historial de Ventas Globales TVs
$X_{1_32''}$	Historial de Ventas TVs 32"
$X_{1_40''}$	Historial de Ventas TVs 40"
$X_{1_43''}$	Historial de Ventas TVs 43"
$X_{1_49''}$	Historial de Ventas TVs 49"

$X_{1_48''}$	Historial de Ventas TVs 48"
$X_{1_50''}$	Historial de Ventas TVs 50"

Fuente: Elaboración propia.

Luego de haber definido nomenclatura para ventas, se plantea el análisis de estos factores de ventas versus los factores macroeconómicos para ver la relación entre ellas y por medio de regresión lineal obtener los factores significativos.

2.2.3 Análisis estadístico de los factores estratificados

Al estar priorizados los productos por tamaño, se estima agregar al conjunto de datos una duplica de los factores macroeconómicos fuera del grupo de ventas históricas ($X_{1_tamaños}$) con propósito de realizar el análisis estadístico de factores con magnitudes acordes al periodo original (X_n) y de 3 periodos anteriores (X_{n_MOVE}) contra las variables de respuesta (Ventas) para encontrar la relación entre ellas e interpretar resultados de sus impactos. En este subcapítulo se presenta un cuadro resumen de la correlación de todas las variables que tienen influencia sobre las ventas históricas y también el análisis de regresión del factor $X_{1_50''}$ como muestra de lo desarrollado.

Correlación de los factores estratificados

El coeficiente de correlación mide el grado de fortaleza que hay entre dos variables. El valor del coeficiente de correlación varía entre +1 y -1, si tienden dos variables a cambiar al mismo tiempo en paralelo significa que "r" es +1 o -1, es decir, que hay relación directa o inversa entre sí respectivamente. En caso de ser valores intermedios de ± 1 , la mejor correlación es aquella que se aproxime a la unidad o aleje de cero.

Tabla 2.5. Correlación de factores estratificados con periodos originales versus ventas

Análisis de datos	X _{1_global}		X _{1_32"}		X _{1_40"}		X _{1_43"}		X _{1_49"}		X _{1_48"}		X _{1_50"}	
	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p
X ₂	0,256	0,090	0,110	0,474	0,182	0,231	-0,647	0,000	-0,534	0,000	-0,253	0,094	0,252	0,095
X ₃	-0,131	0,390	-0,114	0,455	-0,004	0,981	0,731	0,000	0,572	0,000	0,431	0,003	0,019	0,904
X ₄	-0,239	0,114	-0,122	0,426	-0,024	0,877	0,448	0,002	0,367	0,013	0,178	0,241	-0,126	0,408
X ₅	-0,041	0,788	0,088	0,564	-0,137	0,368	-0,327	0,029	-0,260	0,085	-0,283	0,060	-0,244	0,107
X ₆	-0,163	0,285	-0,017	0,914	-0,182	0,233	-0,311	0,038	-0,213	0,160	-0,306	0,041	-0,310	0,038
X ₇	-0,147	0,336	-0,127	0,407	-0,178	0,241	0,699	0,000	0,614	0,000	0,296	0,048	-0,121	0,427
X ₈	-0,218	0,150	-0,233	0,123	0,087	0,572	0,602	0,000	0,481	0,001	0,387	0,009	0,088	0,564
X ₉	0,034	0,822	0,100	0,515	-0,170	0,263	0,554	0,000	0,400	0,007	0,273	0,069	-0,429	0,003
X ₁₀	0,110	0,473	0,136	0,375	-0,196	0,198	0,413	0,005	0,302	0,044	0,200	0,187	-0,361	0,015
X ₁₁	-0,142	0,351	-0,221	0,144	0,167	0,274	0,560	0,000	0,402	0,006	0,427	0,003	0,268	0,075
X ₁₂	-0,074	0,631	-0,187	0,220	0,198	0,193	-0,403	0,006	-0,348	0,019	-0,157	0,302	0,447	0,002
X ₁₃	0,141	0,354	-0,045	0,771	0,329	0,027	-0,035	0,819	-0,138	0,364	0,226	0,135	0,460	0,001
X ₁₄	0,157	0,302	-0,002	0,989	0,353	0,017	-0,438	0,003	-0,330	0,027	-0,149	0,327	0,578	0,000
X ₁₅	0,174	0,252	0,200	0,188	-0,171	0,261	-0,486	0,001	-0,334	0,025	-0,420	0,004	-0,272	0,071
X ₁₆	-0,109	0,476	-0,156	0,305	0,095	0,536	0,715	0,000	0,544	0,000	0,502	0,000	0,098	0,522
X ₁₇	0,009	0,953	-0,051	0,741	-0,012	0,939	0,015	0,920	-0,054	0,725	0,083	0,586	-0,091	0,552
X ₁₈	0,387	0,009	0,356	0,016	0,073	0,634	-0,424	0,004	-0,308	0,040	-0,261	0,084	-0,022	0,888
X ₁₉	0,004	0,979	-0,022	0,884	-0,103	0,501	-0,073	0,632	-0,057	0,711	-0,090	0,555	-0,120	0,431
X ₂₀	-0,119	0,438	-0,130	0,397	0,038	0,807	0,574	0,000	0,254	0,092	0,484	0,001	-0,038	0,804
X ₂₁	-0,055	0,719	-0,056	0,715	0,079	0,606	-0,107	0,486	-0,155	0,309	0,114	0,455	0,051	0,738
X ₂₂	0,461	0,001	0,444	0,002	0,072	0,637	-0,358	0,016	-0,251	0,096	-0,213	0,160	0,011	0,944
X ₂₃	0,362	0,015	0,311	0,038	0,104	0,496	-0,365	0,014	-0,252	0,095	-0,273	0,070	0,044	0,773
X ₂₄	0,318	0,033	0,276	0,066	0,112	0,463	-0,272	0,071	-0,190	0,211	-0,112	0,463	-0,008	0,958

Fuente: Elaboración propia.

Tabla 2.6. Correlación de factores estratificados con 3 periodos anteriores versus ventas

Análisis de datos	X _{1_global}		X _{1_32"}		X _{1_40"}		X _{1_43"}		X _{1_49"}		X _{1_48"}		X _{1_50"}	
	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p	Correlación	Valor p
X _{2_move}	0,198	0,192	0,013	0,931	0,253	0,093	-0,585	0,000	-0,460	0,001	-0,124	0,418	0,482	0,001
X _{3_move}	-0,137	0,371	-0,147	0,336	0,082	0,594	0,397	0,007	0,310	0,038	0,182	0,232	-0,103	0,502
X _{4_move}	0,011	0,945	0,062	0,685	-0,112	0,466	-0,023	0,883	-0,015	0,921	-0,057	0,710	-0,147	0,335
X _{5_move}	0,070	0,646	0,247	0,102	-0,324	0,030	-0,462	0,001	-0,357	0,016	-0,436	0,003	-0,347	0,020
X _{6_move}	-0,006	0,969	0,193	0,205	-0,255	0,091	-0,251	0,097	-0,160	0,293	-0,291	0,052	-0,470	0,001
X _{7_move}	-0,059	0,700	-0,134	0,382	0,064	0,677	0,736	0,000	0,581	0,000	0,393	0,008	-0,075	0,624
X _{8_move}	-0,146	0,339	-0,146	0,337	0,111	0,467	0,706	0,000	0,532	0,000	0,459	0,002	0,048	0,756
X _{9_move}	0,250	0,097	0,229	0,131	0,029	0,851	0,299	0,046	0,190	0,212	0,202	0,182	-0,133	0,384
X _{10_move}	0,152	0,319	0,186	0,222	-0,164	0,282	0,063	0,683	0,042	0,782	-0,056	0,716	-0,185	0,223
X _{11_move}	-0,170	0,264	-0,238	0,115	0,138	0,366	0,599	0,000	0,415	0,005	0,460	0,001	0,220	0,146
X _{12_move}	-0,183	0,229	-0,227	0,134	0,103	0,502	-0,073	0,636	-0,088	0,565	0,121	0,430	0,261	0,083
X _{13_move}	0,105	0,491	-0,079	0,605	0,379	0,010	-0,026	0,863	-0,055	0,720	0,200	0,188	0,564	0,000
X _{14_move}	0,036	0,814	-0,118	0,440	0,332	0,026	-0,208	0,170	-0,181	0,234	0,051	0,740	0,542	0,000
X _{15_move}	0,258	0,087	0,230	0,129	-0,023	0,879	-0,622	0,000	-0,506	0,000	-0,321	0,032	-0,116	0,447
X _{16_move}	-0,101	0,511	-0,151	0,324	0,165	0,280	0,763	0,000	0,557	0,000	0,529	0,000	0,104	0,499
X _{17_move}	-0,103	0,502	-0,035	0,818	0,054	0,724	-0,071	0,645	-0,113	0,460	0,043	0,780	0,013	0,932
X _{18_move}	-0,012	0,939	-0,061	0,690	0,068	0,656	-0,460	0,001	-0,339	0,023	-0,205	0,176	0,073	0,634
X _{19_move}	-0,124	0,417	-0,058	0,703	-0,029	0,848	-0,069	0,652	-0,066	0,667	-0,075	0,624	-0,120	0,433
X _{20_move}	-0,170	0,263	-0,133	0,383	-0,172	0,260	0,376	0,011	0,258	0,087	0,481	0,001	0,004	0,980
X _{21_move}	0,204	0,180	0,300	0,045	0,227	0,133	-0,075	0,627	-0,049	0,751	-0,030	0,844	0,150	0,324
X _{22_move}	-0,020	0,894	-0,136	0,372	0,048	0,755	-0,386	0,009	-0,270	0,073	-0,168	0,269	0,097	0,527
X _{23_move}	0,103	0,500	0,050	0,745	0,170	0,264	-0,379	0,010	-0,276	0,066	-0,168	0,270	0,141	0,357
X _{24_move}	-0,006	0,968	-0,041	0,789	-0,020	0,896	-0,288	0,055	-0,202	0,184	-0,147	0,337	0,055	0,719

Fuente: Elaboración propia.

Mientras se observa las tablas anteriores, es importante saber lo que el valor-p (valor de probabilidad) nos indica, y la misma contiene la siguiente hipótesis:

Ho: probable que dos V.I. den valor “r” mayor al mostrado (cuando valor-p > 0.05)
VS

H1: no es Ho (cuando valor-p < 0.05)

Dicho de otra forma, el valor-p es el resultado de realizar un test para comprobar la hipótesis de independencia entre las variables consideradas, y su interpretación es como se explica a continuación:

Análisis de datos	X _{1_global}	
	Correlación	Valor p
X ₂	0,256	0,090

Figura 2.8. Correlación y valor-p de X₂ vs X_{1_global}

Fuente: Elaboración propia.

Valores de “r” obtenidos al realizar 10.000 simulaciones con muestras INDEPENDIENTES entre las variables X₂ vs X_{1_global}, el 9,0 % de los casos da un valor de $|r| > 0,256$.

Proceso de selección para la regresión múltiple

Esencialmente, el proceso de selección de regresión múltiple permite al investigador obtener un conjunto reducido de variables de un conjunto más grande de predictores, eliminando predictores innecesarios, simplificando datos y aumentando la precisión predictiva. Se utilizan dos criterios para lograr el mejor conjunto de predictores; estos incluyen la validez a la situación y la significancia estadística.

Ciertos métodos de selección de regresión son útiles para probar predictores, aumentando así la eficiencia del análisis. La selección, por otra parte, permite la construcción de una ecuación de regresión óptima junto con la investigación de variables predictoras específicas. El objetivo de la selección es reducir el conjunto de variables predictoras a las que son necesarias y representan casi la mayor parte de la varianza que se explica por el conjunto total. En esencia, la selección ayuda a determinar el nivel de importancia de cada variable predictora. También ayuda a evaluar los efectos una vez que las otras variables predictoras se eliminan estadísticamente. Las circunstancias del estudio, junto con la naturaleza de las preguntas de investigación guían la selección de variables predictoras.

Métodos de Regresión Estadístico

Se utilizan tres procedimientos de selección para obtener la ecuación de regresión más adecuada: selección directa (Forward selection), eliminación hacia atrás (Backward elimination), y selección por etapas (Stepwise selection). Los tres primeros se consideran métodos de regresión estadística y sirven introducir ítems que sean apropiados para uno como investigador para tener una idea de qué predictores pueden impactar la variable dependiente. Para la ejecución de esta etapa se aplica el software Minitab 17 que contiene un orden dado basado en teoría, lógica o practicidad, el cual se muestra en la figura 2.9, de tal manera que nos permite determinar las ecuaciones con las variables significativas, y posteriormente poder analizarlas. En esta ocasión se toma de ejemplo la aplicación de la herramienta para el factor estratificado X_{1_50} .

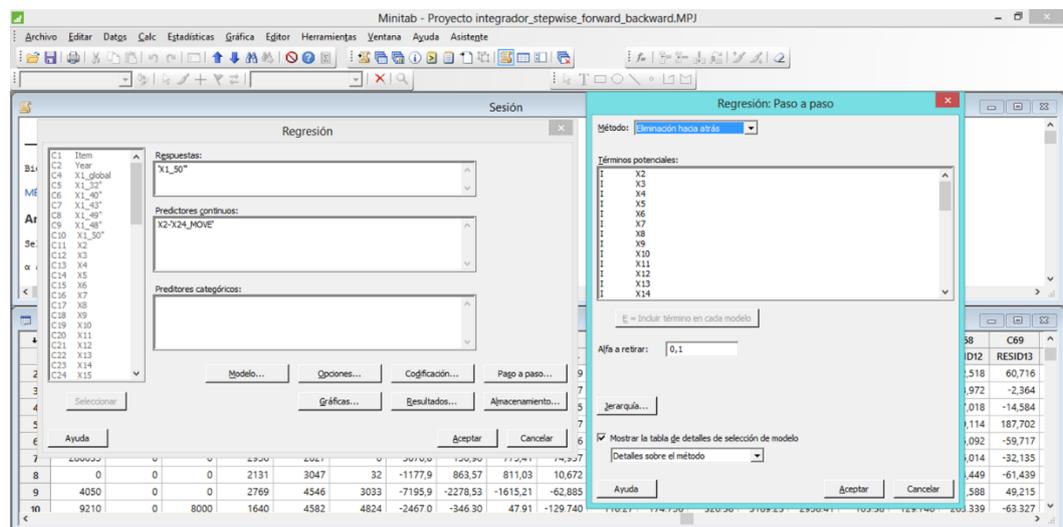


Figura 2.9. Aplicación del software “Minitab 17” para uso de métodos estadísticos de regresión.

Fuente: Elaboración propia.

A continuación, se obtiene las ecuaciones de regresión establecidas por cada método, este procedimiento se lo efectúa para todos los factores estratificados de ventas históricas por tamaño de televisores que han sido elegidas en el subcapítulo 2.2.1. Nótese que para efectos didácticos se sigue la explicación con la opción del ejemplo anterior, dado que son muchas ecuaciones que se las detallan en el Apéndice A donde se podrán

encontrar las pruebas estadísticas para el resto de factores, por lo tanto, se muestra en un cuadro lo conseguido por método estadístico de regresión para el factor mencionado:

Tabla 2.7. Ecuaciones de regresión de las ventas históricas para el factor estratificado X_{1_50}"

Análisis del método de regresión para	Descripción	Método de Regresión	Ecuación de la regresión
X _{1_50} "	Historial de Ventas TVs 50"	Stepwise Regression	$X_{1_50} = -15611 + 0,02359 X_{14} - 37,02 X_{15} - 0,01612 X_{14_MOVE}$
X _{1_50} "	Historial de Ventas TVs 50"	Forward Regression	$X_{1_50} = -16355 + 0,02119 X_{14} - 39,65 X_{15} + 140,0 X_{2_MOVE} - 0,01633 X_{14_MOVE}$
X _{1_50} "	Historial de Ventas TVs 50"	Backward Regression	$X_{1_50} = -355133 - 101695 X_2 - 138496 X_3 - 76199 X_5 - 32684 X_6 + 22145 X_8 - 67869 X_9 + 14579 X_{10} - 3121 X_{11} - 1566 X_{12} + 0,1068 X_{13} - 0,4358 X_{14} + 929 X_{16} + 0,0959 X_{18} - 0,04197 X_{19} - 0,3454 X_{20} - 0,4777 X_{22} - 0,587 X_{23} + 38256 X_{2_MOVE} - 486,0 X_{3_MOVE} - 991 X_{4_MOVE} + 64793 X_{5_MOVE} + 36882 X_{6_MOVE} + 124258 X_{7_MOVE} + 52133 X_{8_MOVE} + 36402 X_{9_MOVE} - 5451 X_{11_MOVE} + 655 X_{12_MOVE} - 170,2 X_{15_MOVE} + 1715 X_{16_MOVE} + 0,0505 X_{17_MOVE} - 0,2753 X_{18_MOVE} - 0,0303 X_{19_MOVE} + 0,1660 X_{20_MOVE} - 0,2937 X_{21_MOVE} + 1,047 X_{22_MOVE} + 0,5928 X_{24_MOVE}$

Fuente: Elaboración propia.

Mencionada las ecuaciones, se comprueba si efectivamente los factores estratificados elegidos por cada método son significativos. La manera de lograrlo es obtener el Valor F del Análisis de Varianza obtenido del Minitab 17 que se muestra en la tabla 2.8, tabla 2.9, y tabla 2.10.

Tabla 2.8. Valor F del Análisis de Varianza del método "Stepwise regression" para el factor estratificado X_{1_50}"

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	3	37703872	12567957	14,17	0,000
X14	1	15551358	15551358	17,54	0,000
X15	1	12715097	12715097	14,34	0,000
X14_MOVE	1	7556053	7556053	8,52	0,006
Error	41	36359714	886822		
Total	44	74063585			

Fuente: Elaboración propia.

Tabla 2.9. Valor F del Análisis de Varianza del método "Forward regression" para el factor estratificado X_{1_50}"

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	4	39478361	9869590	11,41	0,000
X14	1	11519055	11519055	13,32	0,001
X15	1	14076976	14076976	16,28	0,000
X2_MOVE	1	1774489	1774489	2,05	0,160
X14_MOVE	1	7743734	7743734	8,96	0,005
Error	40	34585224	864631		
Total	44	74063585			

Fuente: Elaboración propia.

Tabla 2.10. Valor F del Análisis de Varianza del método “Backward regression” para el factor estratificado X_{1_50}”

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	36	72929904	2025831	14,30	0,000
X2	1	7996594	7996594	56,43	0,000
X3	1	8270661	8270661	58,36	0,000
X5	1	7126682	7126682	50,29	0,000
X6	1	2313848	2313848	16,33	0,004
X8	1	7746858	7746858	54,67	0,000
X9	1	8836607	8836607	62,36	0,000
X10	1	10082331	10082331	71,15	0,000
X11	1	3130902	3130902	22,09	0,002
X12	1	6778926	6778926	47,84	0,000
X13	1	6818947	6818947	48,12	0,000
X14	1	5197733	5197733	36,68	0,000
X16	1	3599730	3599730	25,40	0,001
X18	1	1906410	1906410	13,45	0,006
X19	1	8312223	8312223	58,66	0,000
X20	1	7412884	7412884	52,31	0,000
X22	1	3550588	3550588	25,06	0,001
X23	1	923412	923412	6,52	0,034
X2_MOVE	1	11129298	11129298	78,54	0,000
X3_MOVE	1	9739265	9739265	68,73	0,000
X4_MOVE	1	13657469	13657469	96,38	0,000
X5_MOVE	1	11364201	11364201	80,19	0,000
X6_MOVE	1	5670845	5670845	40,02	0,000
X7_MOVE	1	11006716	11006716	77,67	0,000
X8_MOVE	1	9082713	9082713	64,09	0,000
X9_MOVE	1	10635453	10635453	75,05	0,000
X11_MOVE	1	1728036	1728036	12,19	0,008
X12_MOVE	1	1894291	1894291	13,37	0,006
X15_MOVE	1	3325149	3325149	23,46	0,001
X16_MOVE	1	7176073	7176073	50,64	0,000
X17_MOVE	1	1383982	1383982	9,77	0,014
X18_MOVE	1	7118826	7118826	50,24	0,000
X19_MOVE	1	690378	690378	4,87	0,058
X20_MOVE	1	2922594	2922594	20,62	0,002
X21_MOVE	1	3415671	3415671	24,10	0,001
X22_MOVE	1	5414899	5414899	38,21	0,000
X24_MOVE	1	5539649	5539649	39,09	0,000
Error	8	1133681	141710		
Total	44	74063585			

Fuente: Elaboración propia.

Luego el Valor F se compara con el Valor F teórico con probabilidad de 0.05, que se presenta en la figura 2.10, figura 2.11, y figura 2.12

respectivamente para el factor estratificado X1_50", ya que el resto de factores de ventas se aprecian en el Apéndice B.

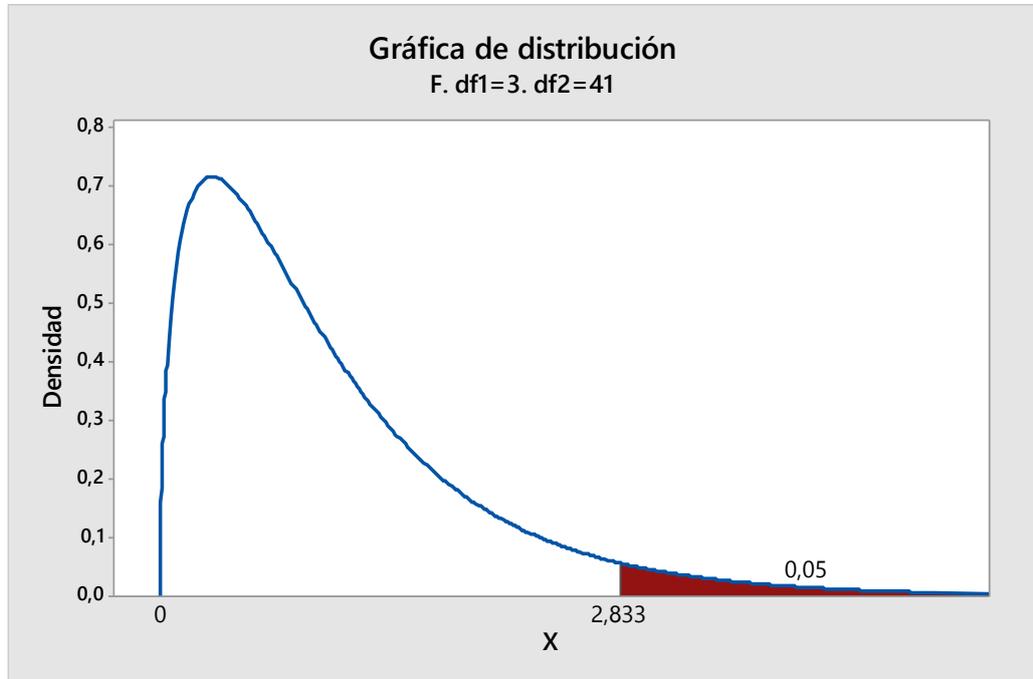


Figura 2.10. Valor F teórico del método “Stepwise regression” para el factor estratificado X1_50”.

Fuente: Elaboración propia.

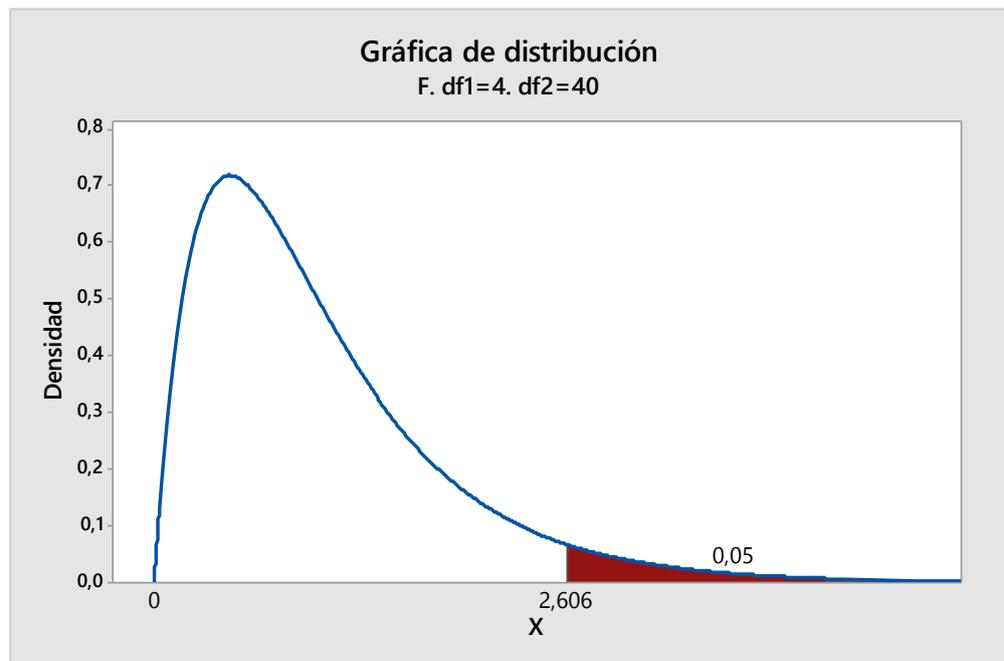


Figura 2.11. Valor F teórico del método “Forward regression” para el factor estratificado X1_50”.

Fuente: Elaboración propia.

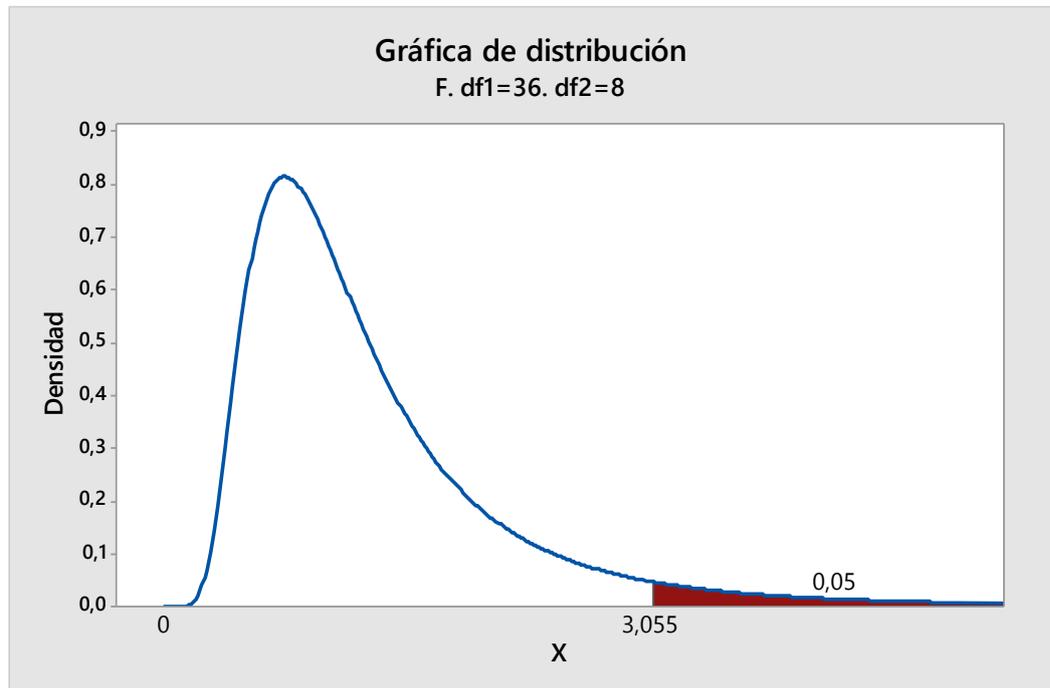


Figura 2.12. Valor F teórico del método “Backward regression” para el factor estratificado $X_{1_{50}}$.

Fuente: Elaboración propia.

Con la información anterior disponible, se estudia la respectiva significancia de las variables que existen en cada una de las ecuaciones encontradas, partiendo de la siguiente hipótesis.

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_{p-1} = 0$$

vs

$$H_1 : \text{al menos un betano es cero}$$

Con $(1-\alpha)*100\%$ de confianza rechace H_0 a favor de H_1 si:

$$\text{Valor } F > \text{Valor } F_{\alpha}(p-1, n-p)$$

Tabla 2.11. Comparación del Valor F teórico contra Valor F α de cada método de regresión para el factor estratificado X_{1_50}"

Método de Regresión	Ecuación de la regresión	Valor F (Estadístico de Prueba)	Valor F α (p-1, n-p)	Cumple F \geq F α (p-1, n-p)
Stepwise Regression	$X_{1_50} = -15611 + 0,02359 X_{14} - 37,02 X_{15} - 0,01612 X_{14_MOVE}$	14,17	2,83	Si
Forward Regression	$X_{1_50} = -16355 + 0,02119 X_{14} - 39,65 X_{15} + 140,0 X_{2_MOVE} - 0,01633 X_{14_MOVE}$	11,41	2,61	Si
Backward Regression	$X_{1_50} = -355133 - 101695 X_2 - 138496 X_3 - 76199 X_5 - 32684 X_6 + 22145 X_8 - 67869 X_9 + 14579 X_{10} - 3121 X_{11} - 1566 X_{12} + 0,1068 X_{13} - 0,4358 X_{14} + 929 X_{16} + 0,0959 X_{18} - 0,04197 X_{19} - 0,3454 X_{20} - 0,4777 X_{22} - 0,587 X_{23} + 38256 X_{2_MOVE} - 486,0 X_{3_MOVE} - 991 X_{4_MOVE} + 64793 X_{5_MOVE} + 36882 X_{6_MOVE} + 124258 X_{7_MOVE} + 52133 X_{8_MOVE} + 36402 X_{9_MOVE} - 5451 X_{11_MOVE} + 655 X_{12_MOVE} - 170,2 X_{15_MOVE} + 1715 X_{16_MOVE} + 0,0505 X_{17_MOVE} - 0,2753 X_{18_MOVE} - 0,0303 X_{19_MOVE} + 0,1660 X_{20_MOVE} - 0,2937 X_{21_MOVE} + 1,047 X_{22_MOVE} + 0,5928 X_{24_MOVE}$	14,30	3,06	Si

Fuente: Elaboración propia.

Una vez revisada la comparación se observa que sí cumple la condición, es decir, que todos los factores encontrados de cada ecuación de sus respectivos métodos de regresión son significativos.

Tabla 2.12. Datos de los R² ajustados de cada método de regresión para el factor estratificado X_{1_50}"

Resumen del modelo (STEPWISE REGRESSION)			
R-cuad.	R-cuad.		
S	R-cuad. (ajustado)	(pred)	
941,712	50,91%	47,32%	24,59%
Resumen del modelo (FORWARD REGRESSION)			
R-cuad.	R-cuad.		
S	R-cuad. (ajustado)	(pred)	
929,855	53,30%	48,63%	25,05%
Resumen del modelo (BACKWARD REGRESSION)			
R-cuad.	R-cuad.		
S	R-cuad. (ajustado)	(pred)	
376,444	98,47%	91,58%	0,00%

Fuente: Elaboración propia.

Con respecto a cuál ecuación es la más adecuada, se necesita saber cuál coeficiente de determinación múltiple (R²) es el porcentaje de variación de la variable de respuesta que mejor explica su relación con más variables predictoras.

Tabla 2.13. Verificación del R² ajustado de cada método de regresión para el factor estratificado X_{1_50}''

Método de Regresión	Ecuación de la regresión	Valor F (Estadístico de Prueba)	Valor F α (p-1, n-p)	Cumple F \geq F α (p-1, n-p)	R ² ajustado (%)
Stepwise Regression	$X_{1_50}'' = -15611 + 0,02359 X_{14} - 37,02 X_{15} - 0,01612 X_{14_MOVE}$	14,17	2,83	Si	47,32%
Forward Regression	$X_{1_50}'' = -16355 + 0,02119 X_{14} - 39,65 X_{15} + 140,0 X_{2_MOVE} - 0,01633 X_{14_MOVE}$	11,41	2,61	Si	48,63%
Backward Regression	$X_{1_50}'' = -355133 - 101695 X_2 - 138496 X_3 - 76199 X_5 - 32684 X_6 + 22145 X_8 - 67869 X_9 + 14579 X_{10} - 3121 X_{11} - 1566 X_{12} + 0,1068 X_{13} - 0,4358 X_{14} + 929 X_{16} + 0,0959 X_{18} - 0,04197 X_{19} - 0,3454 X_{20} - 0,4777 X_{22} - 0,587 X_{23} + 38256 X_{2_MOVE} - 486,0 X_{3_MOVE} - 991 X_{6_MOVE} + 64793 X_{5_MOVE} + 36882 X_{6_MOVE} + 124258 X_{7_MOVE} + 52133 X_{8_MOVE} + 36402 X_{9_MOVE} - 5451 X_{11_MOVE} + 655 X_{12_MOVE} - 170,2 X_{15_MOVE} + 1715 X_{16_MOVE} + 0,0505 X_{17_MOVE} - 0,2753 X_{18_MOVE} - 0,0303 X_{19_MOVE} + 0,1660 X_{20_MOVE} - 0,2937 X_{21_MOVE} + 1,047 X_{22_MOVE} + 0,5928 X_{24_MOVE}$	14,30	3,06	Si	91,58%

Fuente: Elaboración propia.

Por lo tanto, al hacer el análisis estadístico se obtiene que un buen modelo es el método de "Backward regression" porque mejor será el ajuste del modelo a sus datos con un valor particular para X_{1_50}'' de 91,58%.

2.3 Fase de Mejora y Control

Al encontrar las soluciones que serían los factores significativos de un buen modelo encontrado de cada X_{1_global} y tamaños de productos escogidos, en esta sección se busca desarrollar un software que facilite pronosticar la demanda midiendo el menor nivel de incertidumbre posible a través del MAPE, el cual fue seleccionado desde un inicio como variable de interés o respuesta.

2.3.1 Plan de Implementación de soluciones

En síntesis, se establece un esquema basado en la combinación de causa raíz y la aplicación de 5W1H para determinar la mejora enfocada a realizar.

Tabla 2.14. Plan de implementación de soluciones

Causa Raíz	Qué? (Soluciones)	Por qué?	Cómo?	Dónde?	Quién?	Que tanto?	Cuándo?
La empresa se enfrenta a problemas de pronóstico debido a la incertidumbre en las demandas de los clientes en Ecuador	Diseño de un método de predicción de demanda para una fábrica de ensamblaje de televisores	En el producto final, el error de pronóstico de la demanda se ha reducido en un 47%.	Factores de regresión lineal desarrollados en redes neuronales en Python.	Departamento de Ingeniería	Líder del Proyecto	Libre de costo	feb-17

Fuente: Elaboración propia.

2.3.2 Instrucciones básicas de instalación del software Python

Con respecto a la implementación de la mejora, para este estudio se contempla el uso del software “Python” para lograr sistematizar todas las variables encontradas en un solo programa que a través de algoritmos basados en redes neuronales permita encontrar la solución esperada. Cabe indicar que el uso del software mencionado, con respectivo instalador lo puede encontrar en la website de forma gratuita en la figura 2.13:

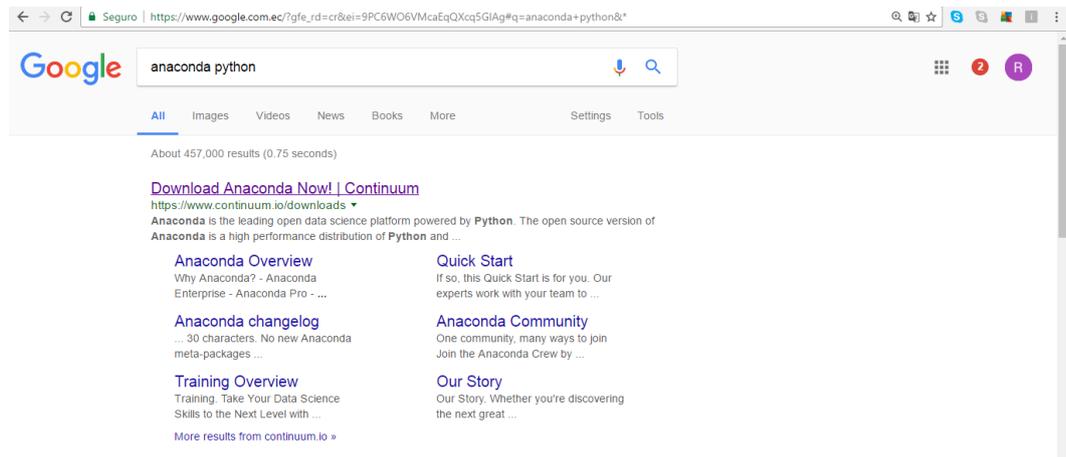


Figura 2.13. Búsqueda del software Python en Google - Parte 1.

Fuente: Internet.

En la propia website, como se observa en la figura 2.14 y figura 2.15, se puede descargar el instalador acorde a las opciones de capacidad o tipo que tiene el sistema operativo en el computador del usuario.

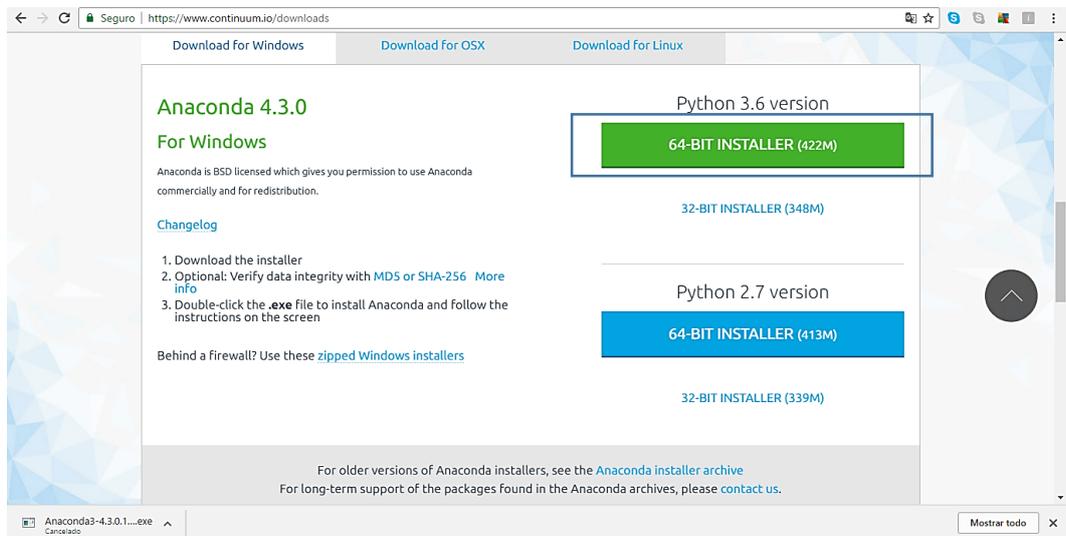


Figura 2.14. Búsqueda del software Python en Google - Parte 2.

Fuente: Internet.

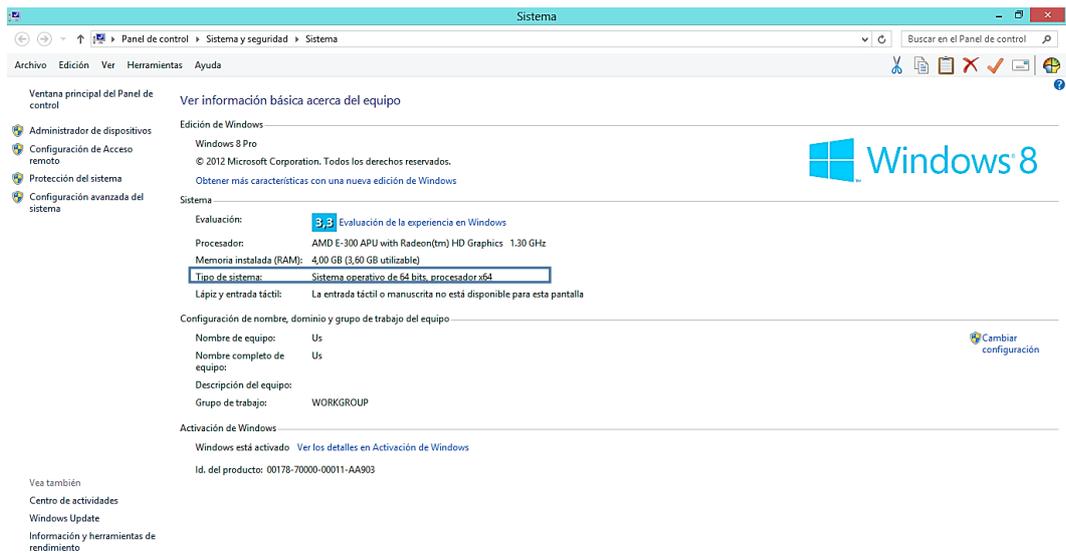


Figura 2.15. Verificación del Sistema Operativo en el computador.

Fuente: Elaboración propia.

Al tener descargado el ejecutador de Python, se procede a instalar de forma regular en el sistema. Una vez que haya sido instalado dicho software correctamente, se considera activar la importación de librerías que faciliten el uso de cálculos a través de algoritmos que se muestran en la figura 2.16:

#1:	12.42	tensorflow/tensorflow
#2:	4.01	fchollet/keras
#3:	3.35	BVLC/caffe
#4:	2.35	dmlc/mxnet
#5:	1.46	baidu/paddle
#6:	1.31	Microsoft/CNTK
#7:	1.04	tflearn/tflearn
#8:	0.94	deeplearning4j/deeplearning4j
#9:	0.92	Theano/Theano
#10:	0.77	NVIDIA/DIGITS
#11:	0.68	torch/torch7
#12:	0.48	pfnet/chainer
#13:	0.38	NervanaSystems/neon
#14:	0.27	Lasagne/Lasagne
#15:	0.25	karpathy/convnetjs
#16:	0.19	amznlabs/amazon-dsstne

Figura 2.16. Librerías populares de aprendizaje profundo.

Fuente: Pyimagesearch, 2016

Por lo tanto, en la siguiente figura 2.17, se evidencia el uso del procesador de comandos llamado “cmd” y aperturado como administrador con la finalidad de realizar la adecuada activación de librerías Tensorflow y Keras que van a servir al momento de la programación del modelo y corridas de cálculo de los algoritmos.

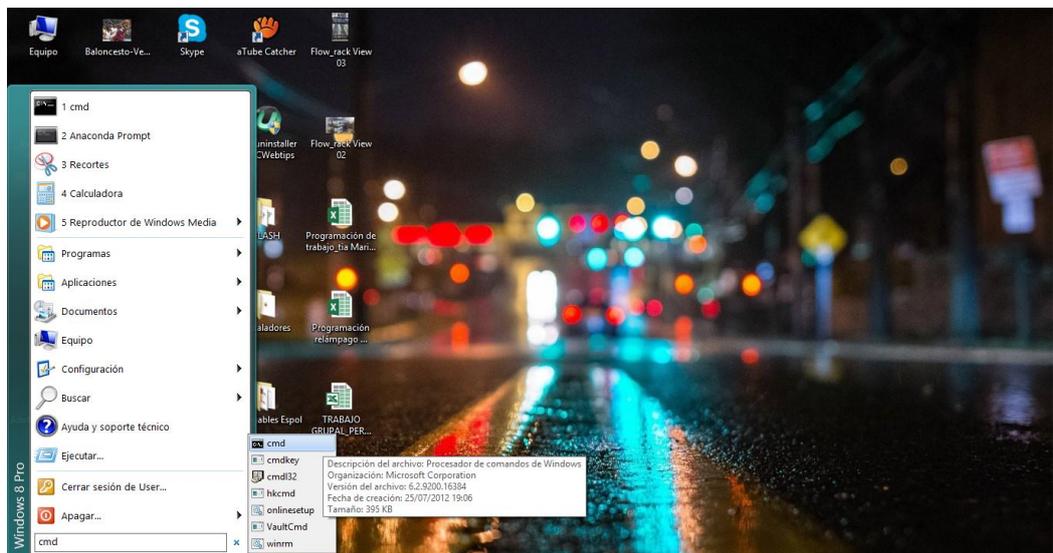
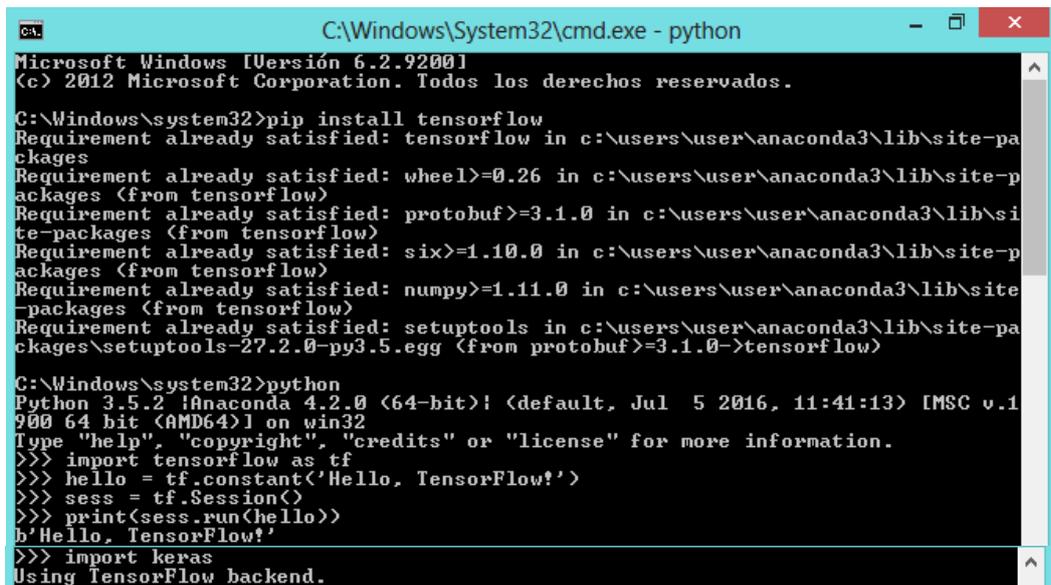


Figura 2.17. Búsqueda del Procesador de comandos “cmd”.

Fuente: Elaboración propia.



```
C:\Windows\System32\cmd.exe - python
Microsoft Windows [Versión 6.2.9200]
(c) 2012 Microsoft Corporation. Todos los derechos reservados.

C:\Windows\system32>pip install tensorflow
Requirement already satisfied: tensorflow in c:\users\user\anaconda3\lib\site-pa
ckages
Requirement already satisfied: wheel>=0.26 in c:\users\user\anaconda3\lib\site-p
ackages (from tensorflow)
Requirement already satisfied: protobuf>=3.1.0 in c:\users\user\anaconda3\lib\s
ite-packages (from tensorflow)
Requirement already satisfied: six>=1.10.0 in c:\users\user\anaconda3\lib\site-p
ackages (from tensorflow)
Requirement already satisfied: numpy>=1.11.0 in c:\users\user\anaconda3\lib\site
-packages (from tensorflow)
Requirement already satisfied: setuptools in c:\users\user\anaconda3\lib\site-pa
ckages\setuptools-27.2.0-py3.5.egg (from protobuf>=3.1.0->tensorflow)

C:\Windows\system32>python
Python 3.5.2 |Anaconda 4.2.0 (64-bit)| (default, Jul 5 2016, 11:41:13) [MSC v.1
900 64 bit (AMD64)] on win32
Type "help", "copyright", "credits" or "license" for more information.
>>> import tensorflow as tf
>>> hello = tf.constant('Hello, TensorFlow!')
>>> sess = tf.Session()
>>> print(sess.run(hello))
b'Hello, TensorFlow!'
>>> import keras
Using TensorFlow backend.
```

Figura 2.18. Activación de Tensorflow y Keras en cmd.

Fuente: Elaboración propia.

Los comandos que se deben escribir son:

```
>>> pip install tensorflow
```

Presiona botón enter y dejar cargar proceso.

```
>>> python
```

Presiona botón enter y dejar cargar proceso.

Si existe duda de la configuración hecha, se hace una comprobación de algún error de línea, por la cual, como ejemplo se puede verificar así:

```
>>> import tensorflow as tf
```

```
>>> hello = tf.constant('Hello, TensorFlow!')
```

```
>>> sess = tf.Session()
```

```
>>> print(sess.run(hello))
```

```
Hello, TensorFlow!
```

Si todo está bien hecho según el ejemplo anterior, se determina que no hay ningún tipo de error.

Por último, para el caso de Keras, se coloca:

```
>>> import keras
```

Y si está activado este módulo como resultado debe salir un escrito como:

```
Using Tensorflow backend.
```

De todo lo establecido hasta ahora, se trata de dejar claro que el proceso de instalación tanto del programa como las librerías son importantes considerarlas para lograr éxito desde un inicio del desarrollo del modelo de pronóstico, por lo tanto, hay que tomar en cuenta dichas pautas antes de pasar en sí a la parte de diseño del modelo.

2.3.3 Diseño de un Sistema para reducir MAPE

Para hacer el diseño del método de pronóstico de demanda, a priori se menciona que todos los archivos que tienen información relacionada entre sí, deben estar ubicados todos en una misma carpeta porque para ejercer la simulación del modelo, en Python se requiere que la base de datos y plataforma esté contenido en una misma ubicación.

De forma particular, enfocándonos en cada archivo, se tiene que todos los valores registrados de los factores significativos para un seleccionado segmento de producto X_{1_global} , X_{1_32} , X_{1_40} hasta X_{1_50} , deben estar llenados y revisados en todas las casillas o celdas del Excel como se muestra en la tabla 2.15 de manera que sirva para el modelo matemático a desarrollar.

Tabla 2.15. Factores significativos para el factor X_{1_global} .

Item	Mes	X_{1_global}	X_2	X_3	X_4	X_5	X_6	X_7	X_{10}	X_{11}	X_{12}	X_{13}	X_{14}	X_{15}	X_{16}	X_{17}	X_{18}	X_{19}	X_{20}	X_{21}	X_{22}	X_{23}	
1	1	3.643	52.51	9.44	4.82	26.85	60.87	22.04	17.63	95.01	1.18	22.687.030	2.378.833	94.76	90.30	11.658	4.060	0	0	0	0	0	0
2	2	11.461	52.45	9.85	4.85	26.38	61.16	22.49	17.30	95.18	2.29	22.874.060	2.397.156	95.31	90.80	10.472	9.305	0	0	0	0	1.066	0
3	3	13.347	52.40	10.25	4.87	25.92	61.45	23.37	17.74	95.60	2.89	23.019.786	2.416.809	92.94	90.90	16.546	22.079	0	0	6.300	2.297	0	0
4	4	11.250	52.34	10.66	4.89	25.46	61.74	23.48	16.80	95.77	2.31	23.160.299	2.436.462	92.02	89.90	297.569	36.289	280.635	0	0	0	2.627	0
5	5	16.668	52.29	11.06	4.91	25.00	62.03	23.58	15.87	95.56	1.16	23.300.811	2.456.114	94.51	90.70	1.512	19.577	0	0	0	0	3.047	32
6	6	15.142	52.23	11.47	4.93	24.54	62.32	23.69	14.93	95.42	1.49	23.441.324	2.475.767	95.77	91.60	21.886	27.427	4.050	0	0	4.546	3.033	0
7	7	7.758	52.81	10.52	4.78	25.08	62.38	24.48	15.20	95.41	1.20	23.707.075	2.494.090	104.67	92.60	20.794	26.061	9.210	0	8.000	4.582	4.824	0
8	8	10.070	53.38	9.57	4.63	25.63	62.45	25.26	15.47	95.57	0.10	23.972.825	2.512.414	106.57	91.50	4.792	24.328	0	0	0	2.231	1.824	0
9	9	3.111	53.95	8.62	4.47	26.18	62.52	26.05	15.74	96.11	0.29	24.238.576	2.530.737	106.29	91.60	15.970	22.415	4.270	0	3.000	2.539	3.590	0
10	10	12.347	54.94	9.13	4.31	25.38	62.02	25.88	16.37	96.51	-0.33	24.302.375	2.538.269	100.54	90.90	28.640	35.101	14.460	0	8.770	2.520	6.462	0
11	11	19.818	55.93	9.64	4.15	24.59	61.53	25.72	17.00	96.89	0.09	24.366.174	2.545.801	93.86	92.60	66.520	53.496	30.260	0	0	4.528	4.354	0
12	12	29.214	56.92	10.14	3.99	23.80	61.03	25.55	17.63	97.08	-0.75	24.429.973	2.553.333	97.63	92.40	12.092	29.244	460	0	0	2.205	5.020	0
13	1	3.790	56.24	10.38	3.97	24.00	61.17	25.23	17.34	97.78	-0.20	24.626.468	2.559.875	94.62	92.70	30.251	7.098	50	0	0	0	0	0
14	2	2.131	56.56	10.62	3.94	24.20	61.31	24.92	17.04	97.89	-0.06	24.822.962	2.566.417	100.82	93.00	45.846	2.454	0	0	15.392	0	0	0
15	3	17.840	54.87	10.86	3.92	24.41	61.45	24.60	16.75	98.57	1.34	25.019.457	2.572.959	100.80	92.40	20.578	11.775	0	0	6.000	4.198	5.520	0
16	4	17.658	55.90	10.79	3.85	23.49	61.61	24.58	16.60	98.86	2.56	25.236.827	2.596.923	102.07	93.50	14.654	53.281	0	0	4.000	5.255	11.190	0
17	5	17.466	56.92	10.71	3.78	22.56	61.76	24.55	16.45	98.82	2.06	25.454.196	2.620.888	102.18	93.40	76.976	53.707	0	0	14.368	7.031	1.165	0
18	6	18.852	57.94	10.64	3.72	21.64	61.92	24.53	16.30	98.93	4.20	25.671.566	2.644.852	105.79	94.70	25.342	38.875	0	0	0	4.642	125	0
19	7	7.887	57.84	10.44	3.93	22.04	62.04	24.60	16.14	99.33	3.71	25.779.596	2.654.682	103.59	94.30	19.768	40.837	0	0	0	2.920	1.756	0
20	8	15.819	57.73	10.25	4.15	22.45	62.16	24.68	15.98	99.53	2.86	25.887.625	2.664.512	96.54	96.00	68.943	36.933	8.170	0	13.499	6.707	7.434	0
21	9	9.770	57.63	10.06	4.36	22.86	62.28	24.75	15.82	100.14	3.86	25.995.655	2.674.342	93.21	94.60	59.440	58.181	2.880	0	6.749	9.159	11.382	0
22	10	17.623	57.22	10.61	4.29	22.88	62.53	24.00	16.02	100.35	4.48	25.865.631	2.670.469	84.40	94.40	63.157	45.527	0	0	7.400	4.424	8.996	0
23	11	19.930	56.80	11.16	4.22	22.90	62.78	23.24	16.23	100.53	4.64	25.735.606	2.666.595	75.79	93.90	27.369	10.069	0	0	420	606	0	0
24	12	19.829	56.39	11.71	4.15	22.93	63.03	22.49	16.43	100.64	4.85	25.605.582	2.662.722	59.29	95.50	30.479	13.782	0	0	3.725	462	0	0
25	1	3.832	56.44	11.77	4.35	23.42	62.95	22.16	15.98	101.24	8.65	25.486.343	2.682.549	47.22	94.00	39.312	5.047	0	0	8.703	0	0	0
26	2	3.181	54.49	11.83	4.56	23.91	62.86	21.83	15.52	101.86	9.70	25.367.104	2.702.375	50.58	95.00	11.486	12.284	0	0	0	0	0	0
27	3	24.170	53.54	11.89	4.76	24.40	62.78	21.50	15.07	102.28	10.74	25.247.865	2.722.202	47.82	96.00	12.483	14.236	0	0	4.250	2.264	160	0
28	4	18.570	53.81	11.94	4.67	23.86	63.09	21.67	14.86	103.14	11.54	25.262.273	2.700.689	54.45	94.60	30.132	24.883	0	0	2.000	2.078	6.772	0
29	5	4.454	54.07	12.00	4.58	23.31	63.40	21.84	14.65	103.32	12.27	25.276.681	2.679.175	59.27	94.40	17.495	15.082	2.500	0	0	877	0	0
30	6	2.657	54.34	12.05	4.48	22.77	63.71	22.01	14.44	103.74	13.98	25.291.089	2.657.662	59.82	95.10	32.807	14.917	0	0	500	1.970	1.325	0
31	7	3.381	54.36	12.50	4.57	22.27	64.25	22.12	14.62	103.66	15.74	25.153.328	2.638.631	50.90	96.20	34.492	8.885	3.400	10.500	4.250	1.088	0	0
32	8	13.254	54.38	12.95	4.66	21.77	64.79	22.24	14.80	103.66	18.54	25.015.566	2.619.599	42.87	97.80	31.658	2.813	18.500	0	0	0	0	0
33	9	11.046	54.39	13.40	4.75	21.27	65.34	22.35	14.98	103.93	16.63	24.877.805	2.600.568	45.48	97.10	75.394	3.620	1.140	27.530	0	0	0	0
34	10	12.217	54.28	13.18	4.59	21.67	65.10	22.66	15.21	103.84	14.73	24.838.553	2.574.047	46.22	97.00	45.731	1.113	0	13.260	6.500	0	0	0
35	11	13.948	54.16	12.96	4.43	22.07	64.87	22.97	15.45	103.95	13.41	24.799.301	2.547.526	42.44	97.60	52.808	2.566	11.000	15.380	7.250	0	0	0
36	12	7.433	54.04	12.75	4.26	22.47	64.63	23.28	15.68	104.05	10.42	24.760.049	2.521.005	37.19	98.80	40.439	371	0	11.150	9.250	0	0	0

Fuente: Elaboración propia.

Cabe mencionar que los factores significativos son los datos de entrada al modelo y para facilidad de registros al igual que actualizaciones se ha recopilado toda la información en un mismo archivo de Excel denominado Data_base_X.

Por otra parte, se crea independientemente un archivo de Excel como se muestra en la figura 2.19 donde se aprecia una plataforma de soporte que se denomina "Archivo_de_configuracion", su propósito es facilitar el ingreso de información deseado o necesario para posteriormente ejecutar la simulación en el software.

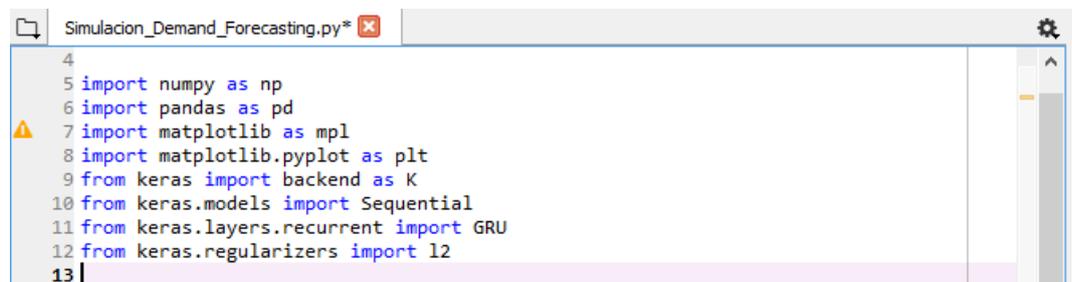


Campos	Valor
Numero de eras o iteraciones	550
Cantidad de periodos historicos (meses)	36
Regularización del modelo	0,002
Segmento de producto	X1_global
Cantidad de factores	21

Figura 2.19. Control del Sistema "Demand Forecasting RP".

Fuente: Elaboración propia.

Hasta este nivel desarrollado del proyecto, los archivos mencionados son netamente de Microsoft Office Excel, sin embargo, la parte robusta del sistema está en desarrollar un método de pronóstico de demanda basado en una sistematización o programación matemática que tenga soporte de librerías de redes neuronales recurrentes de alto nivel, por lo tanto, cabe mencionar cuáles son los pasos que se dan para lograr el modelo esperado.



```
4
5 import numpy as np
6 import pandas as pd
7 import matplotlib as mpl
8 import matplotlib.pyplot as plt
9 from keras import backend as K
10 from keras.models import Sequential
11 from keras.layers.recurrent import GRU
12 from keras.regularizers import l2
13 |
```

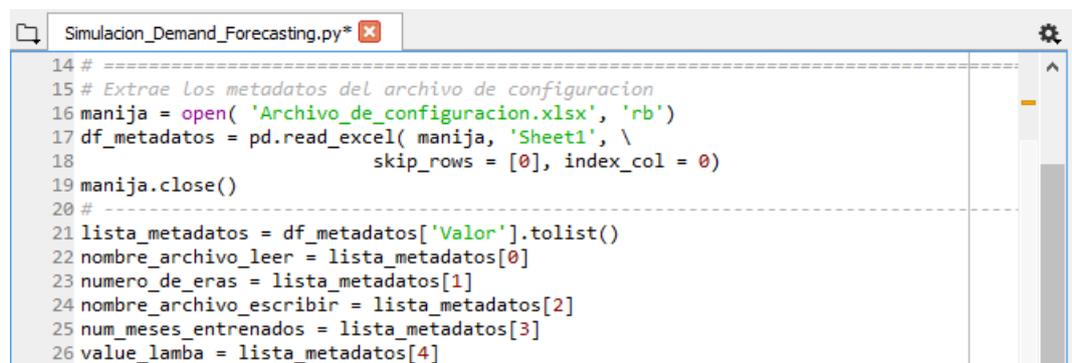
Figura 2.20. Importación de librerías del software “Python” para programación de red neuronal recurrente.

Fuente: Elaboración propia.

En la figura 2.20, se observa que hay algunas líneas de comandos, las mismas están descritas como “import” y significan importar información de bibliotecas o librerías con la finalidad de usarlas en el método a crear, dicho en otros términos, son algoritmos (funciones, cálculos) prediseñados que permiten simplificar la programación el desarrollo del método adecuado. Para efecto de conocimiento, a breves rasgos se menciona a que corresponde algunas terminologías:

1. NumPy tiene una biblioteca de funciones matemáticas de alto nivel y agrega mayor soporte para vectores y matrices.
2. Pandas, es destinada al análisis de datos, que proporciona unas estructuras de datos flexibles y que permiten trabajar con ellos de forma muy eficiente.

3. TensorFlow, porque es una excelente opción para el entrenamiento de redes distribuidas de aprendizaje profundo de una manera agnóstica de la arquitectura.
4. Keras, porque abstrae gran parte de la complejidad de construir una profunda red neuronal, dejando una interfaz muy simple, agradable y fácil de usar para construir, probar e implementar rápidamente arquitecturas de aprendizaje profundo.



```
14 # -----
15 # Extrae los metadatos del archivo de configuracion
16 manija = open( 'Archivo_de_configuracion.xlsx', 'rb')
17 df_metadatos = pd.read_excel( manija, 'Sheet1', \
18                               skip_rows = [0], index_col = 0)
19 manija.close()
20 # -----
21 lista_metadatos = df_metadatos['Valor'].tolist()
22 nombre_archivo_leer = lista_metadatos[0]
23 numero_de_eras = lista_metadatos[1]
24 nombre_archivo_escribir = lista_metadatos[2]
25 num_meses_entrenados = lista_metadatos[3]
26 value_lambda = lista_metadatos[4]
```

Figura 2.21. Extracción de metadatos del “archivo de configuración” de la carpeta de proyecto_ensambladora.

Fuente: Elaboración propia.

En la figura 2.21, se escriben dos zonas de comandos, la primera superior trata sobre la extracción de los metadatos y la segunda se enfoca en definir nomenclaturas como variables que van a utilizarse durante el desarrollo de la programación en Python. Ambas zonas toman los datos correspondientes a la segunda columna que están dentro de la plataforma Control del Sistema “Demand Forecasting RP” mostrada en la figura 2.19 y estos a su vez están relacionado con un cuadro de hoja de cálculo oculto como se aprecia en la tabla 2.16.

Para explicar mejor la segunda zona, cada fila se describe así:

- lista_metadatos (0) equivale al valor de “Data_base_X.xlsx”.
- lista_metadatos (1) equivale al valor de “550”.
- lista_metadatos (2) equivale al valor de “pronósticos.xlsx”.
- lista_metadatos (3) equivale al valor de “36”.
- lista_metadatos (4) equivale al valor de “0,002”.

Tabla 2.16. Cuadro de hoja de cálculo para el factor X_{1_global}

Campo	Valor
Nombre del archivo donde estan los datos	Data_base_X.xlsx
Numero de eras o iteraciones	550,00
Nombre del archivo de salida	pronosticos.xlsx
Numero de meses de entrenamiento	36,00
Valor de lambda	0,002
Nombre de la hoja de Data base	X1_global

Fuente: Elaboración propia.

Adicional, se vuelve a realizar una extracción de datos, más esta vez se obtiene específicamente de la Data_base_X.xlsx todos los valores de los factores estratificados de X_{1_global} visto en la figura 2.22.

```

29 # Extrae Los datos de La hoja de calculo como un DataFrame (df)
30 manija = open( nombre_archivo_leer, 'rb')
31 df_datos = pd.read_excel( manija, 'X1_global', \
32                          skip_rows = [0], header = 1, index_col = 0)
33 manija.close()
34
35 # =====
36 # Convierte el dataframe en un arreglo (matriz) numpy
37 datos = df_datos.as_matrix()
38 col_cos = np.cos( 2.0 * np.pi * (datos[:,0]-1) / 12.0 )
39 col_sin = np.sin( 2.0 * np.pi * (datos[:,0]-1) / 12.0 )
40 col_cos = col_cos.reshape( ( datos.shape[0], 1) )
41 col_sin = col_sin.reshape( ( datos.shape[0], 1) )
42 datos = np.concatenate( ( col_cos, col_sin, datos[ :, 1:] ), axis = 1)

```

Figura 2.22. Extracción y Arreglo de datos de “Data_base_X” de la carpeta de proyecto_ensambladora.

Fuente: Elaboración propia.

En esta misma sección, la figura 2.22 también muestra una parte interesante que trata sobre la modificación de los valores de la matriz, esto se debe a que la matriz original tiene unos valores decimales y otros de miles, haciendo difícil el cálculo por mucho peso en la desviación de la data y esos grandes diferencias que hay de magnitud entre uno a otros datos, sin embargo, aplicando el arreglo usando numpy permite transformar todos esos datos a valores que pequeños que van de -1 a +1 de forma que hace factible el cálculo correspondiente en la programación a realizar.

```

43 # Calcula el numero de muestras y el numero de variables
44 num_muestras = datos.shape[0] - 1
45 num_variiables = datos.shape[1]
46 # Construimos la matriz de vectores de entrada X y la matriz de salidas deseadas Y
47 X = datos[ :-1, :]
48 Y = datos[ 1:, 2].reshape( ( num_muestras, 1) )
49
50 # =====
51 # Ahora escogemos solo los primeros 36 meses para entrenamiento, y dejamos los
52 # ultimos meses para validacion y prueba
53 # =====
54 num_muestras_entren = num_meses_entrenados
55 num_muestras_vp      = num_muestras - num_muestras_entren
56 X_entren = X[ : num_muestras_entren, :]
57 Y_entren = Y[ : num_muestras_entren, :]

```

Figura 2.23. Cálculo del número de muestras, construcción de matriz de entradas y salidas, tamaño de datos históricos.

Fuente: Elaboración propia.

La figura 2.23, se concentra en datos asociados de ingreso y salida al proceso del método de pronóstico de demanda, definiendo el tamaño de la muestra y cantidad de variables. Por otra parte, se hace arreglo matricial de “X” (entrada de datos – factores macroeconómicos) como también de “Y” (salida de datos - demanda pronosticada) y se establece la cantidad de meses que se tiene como datos históricos.

```

59 # Normalizamos la matriz de vectores de entrada X. En particular, a cada variable
60 # le restamos su promedio y le dividimos su desviacion estandar
61 # =====
62 x_prom = X_entren.mean( axis = 0 )
63 x_std  = X_entren.std( axis = 0 )
64 X_todos = ( X - x_prom ) / x_std
65 X_entren = ( X_entren - x_prom ) / x_std
66 # =====
67 Y_entren = Y_entren / 10000.0
68 # =====
69 # Re-dimensionar las matrices para que sean tensores 3-dimensionales
70 X_todos3 = X_todos.reshape( ( 1, num_muestras, num_variiables) )
71 X_entren3 = X_entren.reshape( ( 1, num_muestras_entren, num_variiables) )
72 Y_entren3 = Y_entren.reshape( ( 1, num_muestras_entren, 1) )
73
74 # =====

```

Figura 2.24. Normalización de matrices de vectores de entrada “X”, conversión de salidas “Y”.

Fuente: Elaboración propia.

Importante destacar, que para ejercer los respectivos cálculos en el método a diseñar con distribución normal, se debe tener valores normales de entrada, de forma que en la figura 2.24 se muestra la fórmula que a todos los datos de “X_entren” se les aplica la estadística de normalización para que nos dé una matriz normalizada y de ese modo obtener como resultado

datos más estables, sobretodo porque se espera tener valores aproximados entre demandas reales y pronosticadas. No obstante, para efecto posterior tome en cuenta que el cálculo en términos de redes neuronales, en el modelo secuencial se deben tener matrices tridimensionales para poderlas aplicar, por ello, se ve que hay un redimensionamiento de las “X” y “Y”. El modelo secuencial se evidencia en la figura 2.25.

```

74 # =====
75 # Declaro un modelo secuencial
76 valor_lambda = value_lambda
77
78 while True :
79     print( 'ENTRENANDO RED NEURONAL...' )
80     modelo = Sequential()
81     modelo.add( GRU( input_dim = num_variiables,
82                     input_length = None,
83                     output_dim = 32,
84                     activation = 'linear',
85                     inner_activation = 'sigmoid',
86                     return_sequences = True,
87                     W_regularizer = l2(valor_lambda) ) )
88     modelo.add( GRU( output_dim = 1,
89                     activation = lambda x : K.exp(x),
90                     inner_activation = 'sigmoid',
91                     return_sequences = True) )
92     # Compilamos el modelo dandole una funcion de perdida y un optimizador
93     modelo.compile( loss = 'mse', optimizer = 'adam', metrics = ['mape'])
94     # Ajustamos el modelo a los datos
95     modelo.fit( X_entren3, Y_entren3, batch_size = 1, nb_epoch = numero_de_eras)
96     ( mse, mape) = modelo.evalueate( X_entren3, Y_entren3)
97     if mape < 20.0 :
98         print( 'Entrenamiento exitoso!' )
99         break
100    else :
101        print( 'Entrenamiento fracaso, intentando de nuevo...' )
102

```

Figura 2.25. Modelo Secuencial.

Fuente: Elaboración propia.

Dicho modelo tiene la parte más relevante y robusta de la programación, no por la complejidad de algoritmos sino por encontrarse la estructura adecuada que contribuya al efecto de mayor asertividad del método en desarrollo, ya que se conforma por una cantidad de capas, un número de neuronas que están dentro de capa, como también la función de activación adecuada y otra de regularización (lambda) que hace que los valores pronosticados sean parte de una curva más suavizada de la función del método.

Este esquema presenta varios puntos que valen la pena destacar en la figura 2.26:

- línea 81, presenta modelo.add (GRU), el cual es un mecanismo de memoria a largo plazo de toda la información, donde se definen las capas; una de entrada que corresponde al input_dim, otra oculta y una de salida como output_dim, de esta forma también se debe definir la cantidad de neuronas por capa.
- La línea 93, presenta la función de pérdida y el optimizador.
- La línea 97 un condicional que hace posible que en cada iteración según el número de eras, llegue a encontrar un MAPE menor al 20%.

```

103 # Una vez que el modelo esta ajustado, podemos ver que predice para aquellas
104 # muestras que ya conocemos
105 Y_pred = modelo.predict( X_todos3 )
106 Y_pred = Y_pred.reshape( ( num_muestras, 1 ) )
107 Y_pred = Y_pred * 10000.0
108
109 # Calculamos el MAPE de validacion/prueba
110 mape_vp = ( Y[ -num_muestras_vp :, 0 ] - Y_pred[ -num_muestras_vp :, 0 ] ) \
111           / Y[ -num_muestras_vp :, 0 ]
112 mape_vp = np.mean( np.abs( mape_vp ) * 100.0 )
113 print( 'MAPE de validacion/prueba:', mape_vp )
114
115 # =====
116 # Declaramos un arreglo de indices de tiempo
117 tiempos_entren = np.arange(num_muestras_entren) + 2
118 tiempos_vp      = np.arange(num_muestras_vp) + tiempos_entren[-1] + 1
119 # Declaramos una figura con dos graficos
120 plt.plot( tiempos_entren, Y[ : -num_muestras_vp, 0 ], color = 'blue' )
121 plt.plot( tiempos_entren, Y_pred[ : -num_muestras_vp, 0 ], color = 'red' )
122 plt.plot( tiempos_vp, Y[ -num_muestras_vp :, 0 ], color = 'black' )
123 plt.plot( tiempos_vp, Y_pred[ -num_muestras_vp :, 0 ], color = 'red' )
124 plt.show()
125
126 # =====
127 Y_pred_como_df = pd.DataFrame(Y_pred)
128 writer = pd.ExcelWriter( nombre_archivo_escribir )
129 Y_pred_como_df.to_excel( writer, 'Sheet1', index = False, header = False )
130 writer.save()
131

```

Figura 2.26. Cálculo de MAPE, arreglo de índice de tiempos y gráficos de ventas.

Fuente: Elaboración propia.

En esta última sección, se configura la programación para obtener el valor MAPE de los valores futuros, además se establece de forma ordenada los tiempos o meses que son entrenados junto con los valores de prueba para luego lograr efectuar una gráfica de ventas históricas más los de prueba. Finalmente al tener la programación hecha, se busca iterar a través de las corridas y dichas iteraciones se aprecian del lado en una ventana donde se obtiene el resultado de medición de la variable de interés denominada MAPE.

```

36/36 [=====] - 0s - loss: 0.1837
MAPE de entrenamiento: 26.9869838329
MAPE de validacion/prueba: 23.3800238346
>>>

temp.py ejemplo_red_neuronal_02.py
66 modelo.add(Dense(input_dim = num_cols_X, \
67                      output_dim = 20, activation = 'tanh' ) )
68 modelo.add(Dense(output_dim = 10, activation = 'tanh' ) )
69 modelo.add(Dense(output_dim = 1) )
70 # Construimos el modelo dando una funcion de perdida y un optimizador
71 modelo.compile(loss = 'mse', optimizer = 'adam')
72 # Ajustamos el modelo a los datos
73 modelo.fit(X_entren, Y_entren, batch_size = num_muestras, nb_epoch = 50)
74 # Una vez que el modelo esta ajustado, podemos ver que predice para aquellas
75 # muestras que ya conocemos
76 Y_entren_pred = modelo.predict(X_entren )
77 Y_vp_pred = modelo.predict(X_vp )
78 # Des-normalizamos las salidas deseadas y predichas
79 Y_entren = ( Y_entren * y_std ) + y_prom
80 Y_entren_pred = ( Y_entren_pred * y_std ) + y_prom
81 Y_vp_pred = ( Y_vp_pred * y_std ) + y_prom
82 # Calculamos el MAPE de validacion/prueba
83 mape_entren = np.mean( np.abs( Y_entren - Y_entren_pred ) / Y_entren ) * 100.0
84 mape_vp = np.mean( np.abs( Y_vp - Y_vp_pred ) / Y_vp ) * 100.0
85 print('MAPE de entrenamiento:', mape_entren)
86 print('MAPE de validacion/prueba:', mape_vp)
87
88 #
89 # Declaramos un arreglo de indices de tiempo
90 tiempos_entren = np.arange( num_meses_entren ) + 1
91 tiempos_vp = np.arange( num_muestras - num_meses_entren ) + 1
92 # Creamos una figura con dos graficos
93 / fig, (ax1, ax2) = plt.subplots( 2, 1)

```

Figura 2.27. Aplicación del software “Python” para programación de red neuronal recurrente.

Fuente: Elaboración propia.

A pesar de que se te tiene una plataforma dinámica y de fácil uso, para utilizar el método se necesita ingresar al programa Python para presionar el comando “play” para dar arranque a la simulación.

2.3.4 Manual de Usuario del Sistema “Demand Forecasting RP”

Para comprender el sistema, a priori cabe indicar que los términos “Demand Forecasting RP” es la nomenclatura que se le asigna al simulador creado en Python como parte de la propuesta de mejora para este proyecto.

A pesar que el manejo del sistema no es complejo dado que se usa el “archivo_de_configuracion”, es vital tener una guía para administrar bien la información, por lo tanto, se establece un documento impreso para la empresa ya que sirve al usuario en el momento de utilizar el método de pronóstico de demanda en el simulador, donde se puede encontrar en forma general cómo usar el programa creado, las pautas para manejar los datos de manera correcta y además que sea un éxito usar la herramienta desde el inicio de la simulación. Los detalles son vistos con mayor facilidad en el Apéndice C.

CAPÍTULO 3

3. RESULTADOS

En la figura 3.1 y figura 3.2 se muestran los resultados de los MAPE´s obtenidos en la prueba piloto, como se puede apreciar en la primera imagen se encuentra el MAPE de entrenamiento es un 27% de los 36 meses usados de la Data_base_X y en la segunda imagen se encuentra el MAPE de prueba en un 24% que es comparando lo real de la demanda del 2016 versus la demanda pronosticada.

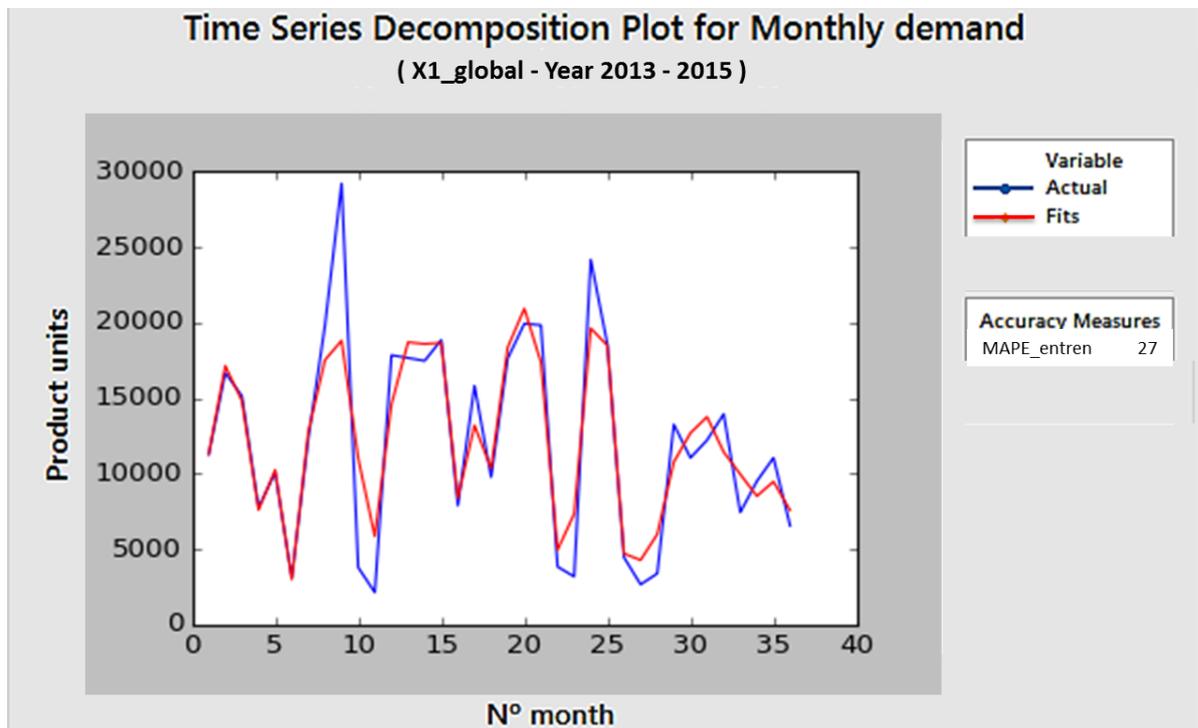


Figura 3.1. Descomposición Gráfica de una Serie de tiempo para demanda mensual.

Fuente: Elaboración propia.

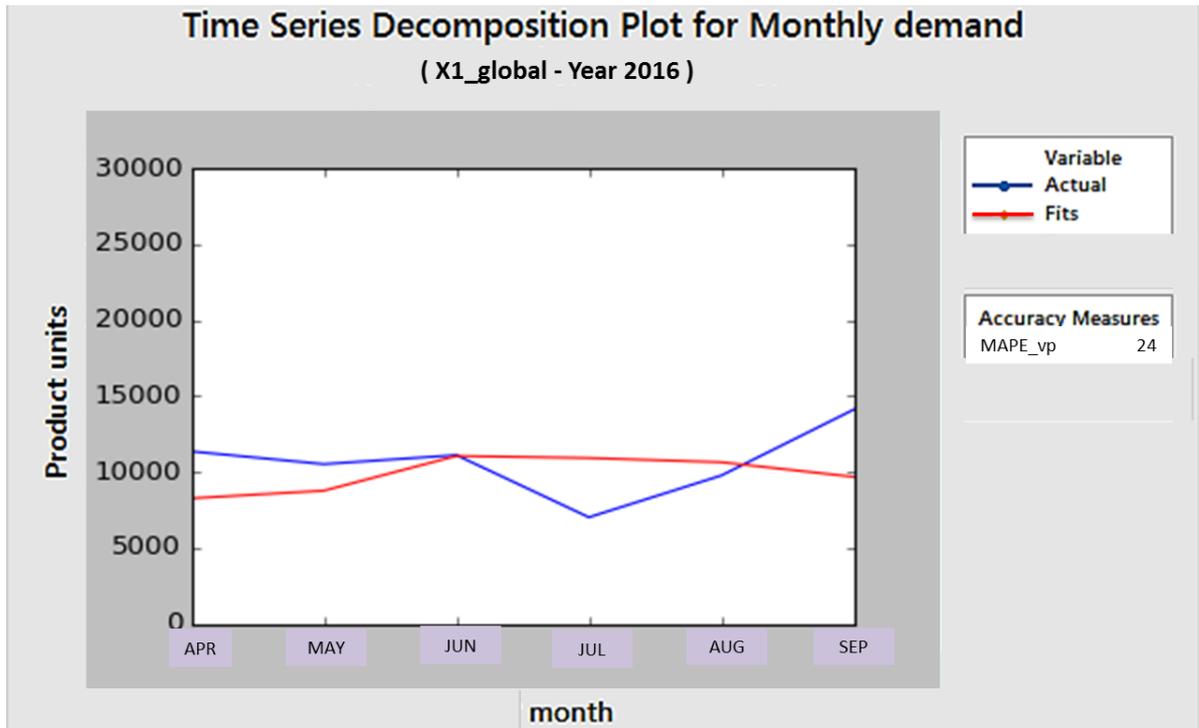


Figura 3.2. Descomposición Gráfica de una Serie de tiempo para demanda mensual.

Fuente: Elaboración propia.

En síntesis, al haber desarrollado un método de pronóstico de demanda se evidencia que la mejora está dada como se muestra en la figura 3.3:

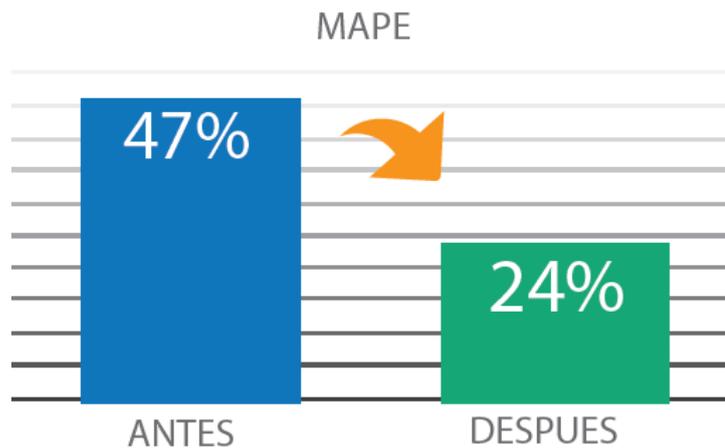


Figura 3.3. Reducción del nivel de incertidumbre de la demanda.

Fuente: Elaboración propia.

CAPÍTULO 4

4. DISCUSIÓN Y CONCLUSIONES

La importancia del trabajo desarrollado, es que contribuye con una fortaleza a los procesos claves de la fábrica y es punto de partida como referencia de la preparación que debe tener la operación de cara a un futuro cercano, por lo que de aquí en adelante la organización no debería tener problemas de alto impacto por el nivel de incertidumbre en la demanda de televisores ya que el presente proyecto disminuye el MAPE y optimiza el cálculo de la demanda pronosticada. Por otro lado, existe como debilidad que el sistema implementado logra hacer un buen pronóstico hasta dos meses posteriores al último periodo que se tiene como dato de entrada, es decir, si tuvimos 36 meses registrados, al menos el mes 37 y 38 serán correctamente pronosticados y tan cercanos a los valores reales de demanda, sin embargo, al intentar estimar un pronóstico de 3 meses en adelante esto hace complicado descubrir ya que este estudio tuvo la restricción inicial de contar con poca cantidad de datos (36 meses de análisis) además de tiempo límite para entrega de este trabajo que fueron 4 meses, por lo tanto, a medida que incremento la base de datos el modelo se hará más robusto que permitirá pronosticar una mayor cantidad de meses deseados ver en el futuro.

4.1 Conclusiones

- En el segmento global de productos hemos detectado que al menos 21 factores influyen en el método de pronóstico de la demanda, reduciendo la incertidumbre mediante el cálculo del MAPE en un 24%.
- Con base en el modelo de pronóstico de demanda, se creó un archivo de control del sistema "Demand Forecasting RP", que sirve como herramienta para que el usuario realice una simulación del próximo mes, lo cual ahora será con un error mucho menor en comparación al MAPE de 47% que estaba al principio, lo que permite una mayor satisfacción del cliente y el beneficio para la empresa.
- La flexibilidad del archivo de control del sistema "Demand Forecasting RP" permitirá reducir la alta variabilidad de la incertidumbre de la cual actualmente sufre la empresa ensambladora de televisores.

4.2 Recomendaciones

- A medida que transcurre el tiempo la actualización de los datos será vital dado que el modelo robustece al sistema “Demand Forecasting RP”.
- Tomar en consideración todo lo mencionado en el Manual de usuario para que tenga un buen desempeño al usar la herramienta que está a disposición del Departamento de Ingeniería.
- Para la actualización del sistema, se recomienda que se haga cada tres meses chequeos y registros actuales sobre todos los factores establecidos, de ese modo se podría ver ajustes o cambios en los pronósticos de forma que haya mayor asertividad.

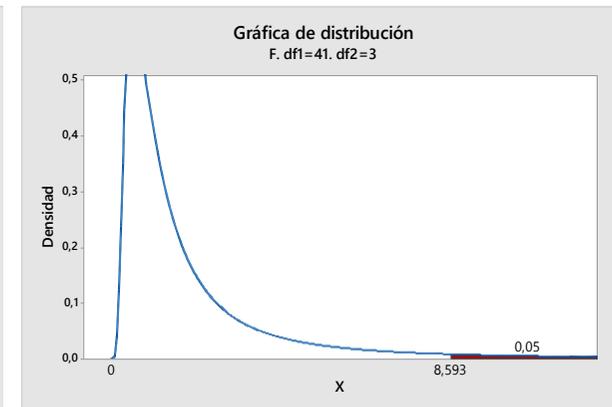
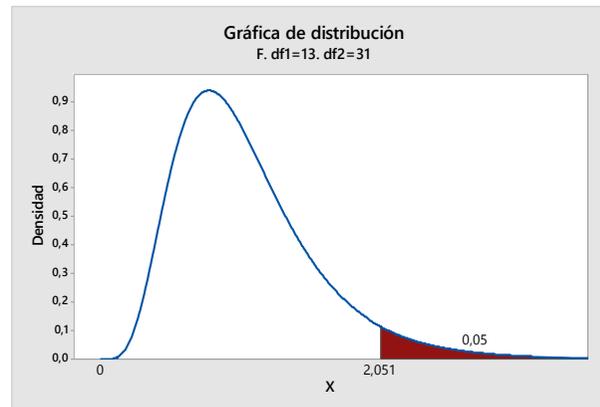
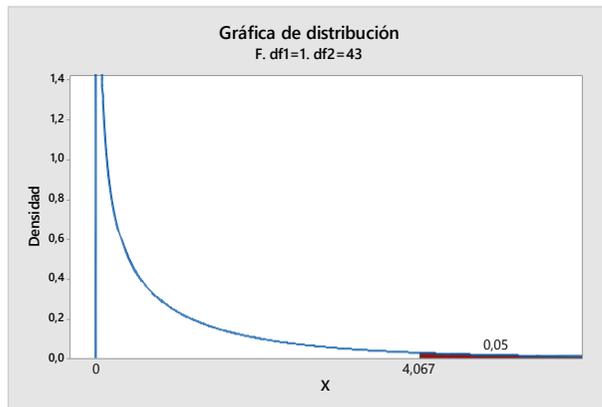
APÉNDICES

APÉNDICE A

Ecuaciones de regresión, Comparación valor F, y datos R² ajustado de las ventas históricas para el factor estratificado X_{1_global}

Análisis del método de regresión para	Descripción	Método de Regresión	Ecuación de la regresión	Valor F (Estadístico de Prueba)	Valor F _α (p-1, n-p)	Cumple F ≥ F _α (p-1, n-p)	R ² ajustado (%)
X _{1_global}	Historial de Ventas Globales TVs	Stepwise Regression	$X_{1_global} = 9566 + 1,139 X_{22}$	11,58	4,07	Si	19,39%
X _{1_global}	Historial de Ventas Globales TVs	Forward Regression	$X_{1_global} = 176783 + 1560 X_3 - 4451 X_9 + 1143 X_{12} - 0,00314 X_{13} + 3336 X_{16} + 0,290 X_{20} + 1,165 X_{22} + 0,557 X_{24} + 4759 X_{9_MOVE} - 6397 X_{11_MOVE} + 2137 X_{16_MOVE} - 0,300 X_{18_MOVE} + 1,742 X_{23_MOVE}$	4,59	2,05	Si	51,49%
X _{1_global}	Historial de Ventas Globales TVs	Backward Regression	$X_{1_global} = 45298795 - 559900 X_2 - 602057 X_3 + 321945 X_4 - 509541 X_5 - 324764 X_8 - 401470 X_9 - 19294 X_{10} - 79016 X_{11} - 13207 X_{12} + 0,4751 X_{13} - 3,717 X_{14} - 561 X_{15} + 8073 X_{16} + 0,3114 X_{17} - 0,3418 X_{18} + 0,3263 X_{19} - 1,446 X_{20} - 2,017 X_{21} - 4,093 X_{23} + 3,839 X_{24} + 178300 X_{2_MOVE} + 1179 X_{3_MOVE} + 7556 X_{4_MOVE} + 303901 X_{5_MOVE} - 301374 X_{6_MOVE} + 644376 X_{7_MOVE} + 300516 X_{8_MOVE} + 289974 X_{9_MOVE} - 367168 X_{10_MOVE} - 28725 X_{11_MOVE} + 6620 X_{12_MOVE} - 474 X_{15_MOVE} + 12971 X_{16_MOVE} + 0,4956 X_{17_MOVE} - 1,288 X_{18_MOVE} - 0,4156 X_{19_MOVE} + 0,693 X_{20_MOVE} - 1,043 X_{21_MOVE} + 4,256 X_{22_MOVE} - 6,596 X_{23_MOVE} + 4,238 X_{24_MOVE}$	67,15	8,59	Si	98,40%

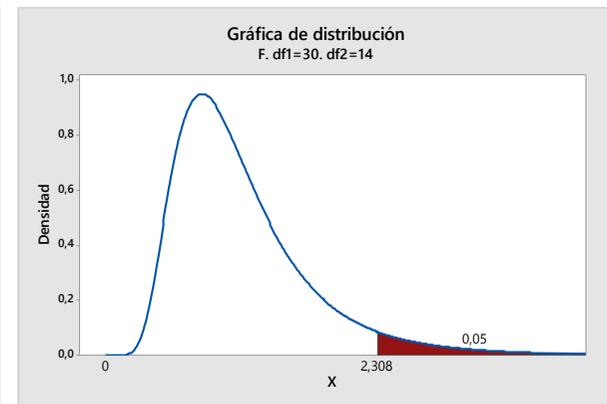
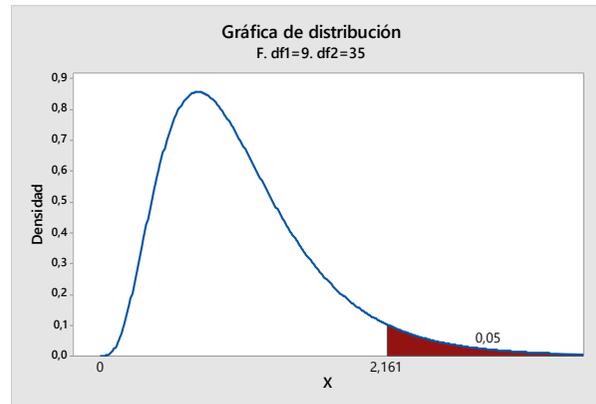
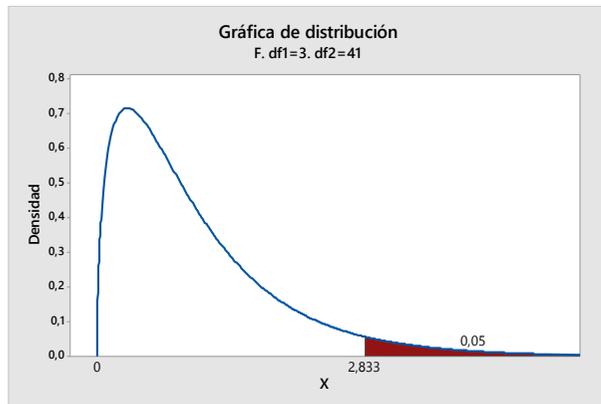
Gráficas de Distribución F α (p-1, n-p) para el factor estratificado X_{1_global}



Ecuaciones de regresión, Comparación valor F, y datos R² ajustado de las ventas históricas para el factor estratificado X_{1_32}"

Análisis del método de regresión para	Descripción	Método de Regresión	Ecuación de la regresión	Valor F (Estadístico de Prueba)	Valor F _α (p-1, n-p)	Cumple F ≥ F _α (p-1, n-p)	R ² ajustado (%)
X _{1_32} "	Historial de Ventas TVs 32"	Stepwise Regression	$X_{1_32} = 21619 - 345 X_2 + 0,788 X_{22} + 0,235 X_{21_MOVE}$	5,79	2,83	Si	24,60%
X _{1_32} "	Historial de Ventas TVs 32"	Forward Regression	$X_{1_32} = 54749 - 667 X_2 - 4105 X_6 - 2555 X_7 + 0,488 X_{22} + 0,288 X_{24} + 2767 X_{6_MOVE} - 0,1393 X_{18_MOVE} + 0,240 X_{21_MOVE} + 0,661 X_{23_MOVE}$	3,83	2,16	Si	36,67%
X _{1_32} "	Historial de Ventas TVs 32"	Backward Regression	$X_{1_32} = 7885117 + 185940 X_4 - 36391 X_5 + 53103 X_6 - 100845 X_8 - 15322 X_9 - 29075 X_{10} - 19299 X_{11} - 2329 X_{12} - 0,06421 X_{13} - 0,6381 X_{14} + 1498 X_{16} + 0,1894 X_{19} - 0,7534 X_{21} + 1,189 X_{22} + 0,781 X_{24} + 9738 X_{2_MOVE} + 889 X_{3_MOVE} + 2446 X_{4_MOVE} + 40859 X_{5_MOVE} - 256703 X_{6_MOVE} + 54573 X_{8_MOVE} + 47546 X_{9_MOVE} - 107186 X_{10_MOVE} + 1621 X_{12_MOVE} + 2234 X_{16_MOVE} + 0,1327 X_{17_MOVE} - 0,1332 X_{19_MOVE} + 0,4432 X_{21_MOVE} + 0,669 X_{22_MOVE} - 1,022 X_{23_MOVE}$	15,11	2,31	Si	90,58%

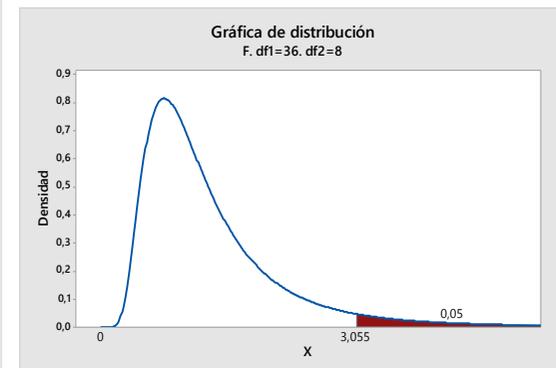
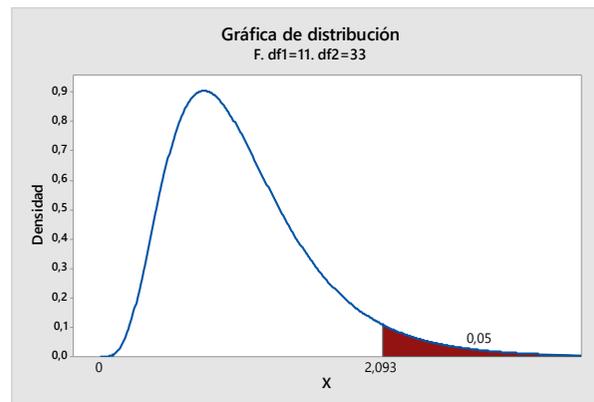
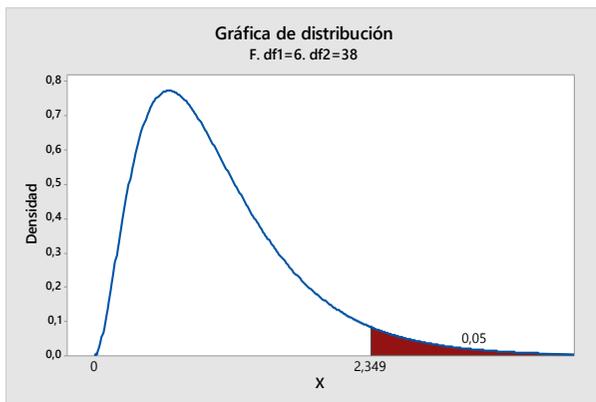
Gráficas de Distribución F α (p-1, n-p) para el factor estratificado X_{1_32}"



Ecuaciones de regresión, Comparación valor F, y datos R² ajustado de las ventas históricas para el factor estratificado X_{1_40}"

Análisis del método de regresión para	Descripción	Método de Regresión	Ecuación de la regresión	Valor F (Estadístico de Prueba)	Valor F _α (p-1, n-p)	Cumple F ≥ F _α (p-1, n-p)	R ² ajustado (%)
X _{1_40} "	Historial de Ventas TVs 40"	Stepwise Regression	$X_{1_40} = -9659 - 1895 X_7 - 432 X_{5_MOVE} + 344 X_{16_MOVE} - 0,1081 X_{20_MOVE} + 0,1301 X_{21_MOVE} - 0,1585 X_{24_MOVE}$	6,67	2,35	Si	43,62%
X _{1_40} "	Historial de Ventas TVs 40"	Forward Regression	$X_{1_40} = -25850 - 1656 X_7 + 87,3 X_{3_MOVE} - 1055 X_{5_MOVE} + 2413 X_{6_MOVE} + 701 X_{10_MOVE} + 0,001243 X_{13_MOVE} + 189 X_{16_MOVE} - 0,0468 X_{18_MOVE} - 0,1539 X_{20_MOVE} + 0,1122 X_{21_MOVE} - 0,022 X_{24_MOVE}$	4,43	2,09	Si	46,17%
X _{1_40} "	Historial de Ventas TVs 40"	Backward Regression	$X_{1_40} = 12992286 - 219889 X_2 - 230405 X_3 - 165654 X_5 - 54781 X_6 - 63777 X_8 - 149977 X_9 - 23411 X_{11} - 3624 X_{12} + 0,2377 X_{13} - 1,206 X_{14} - 357,6 X_{15} + 2372 X_{16} + 0,1366 X_{17} - 0,5392 X_{20} - 0,5570 X_{21} - 2,289 X_{23} + 0,7937 X_{24} + 68173 X_{2_MOVE} + 1802 X_{4_MOVE} + 98163 X_{5_MOVE} + 43998 X_{6_MOVE} + 274174 X_{7_MOVE} + 88296 X_{8_MOVE} + 79195 X_{9_MOVE} - 81850 X_{10_MOVE} - 13607 X_{11_MOVE} + 1302 X_{12_MOVE} - 241,9 X_{15_MOVE} + 3734 X_{16_MOVE} + 0,1681 X_{17_MOVE} - 0,5148 X_{18_MOVE} - 0,1223 X_{19_MOVE} - 0,4112 X_{21_MOVE} + 1,253 X_{22_MOVE} - 1,381 X_{23_MOVE} + 1,609 X_{24_MOVE}$	15,93	3,06	Si	92,43%

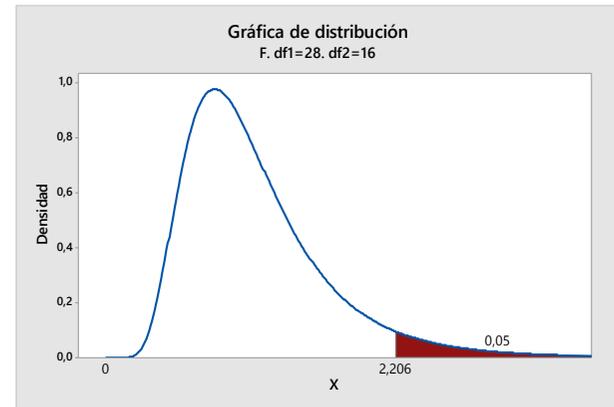
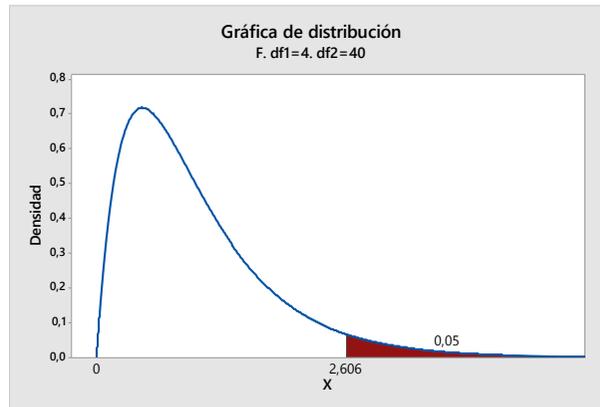
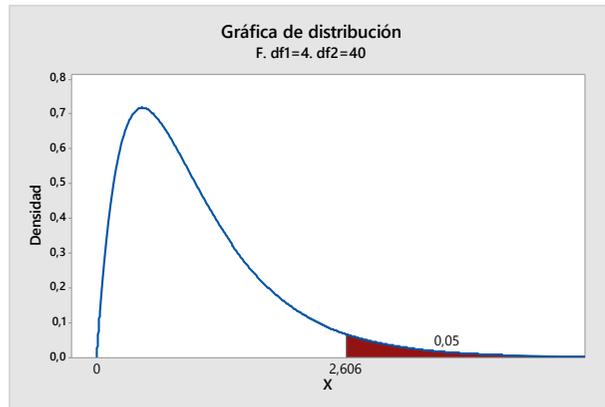
Gráficas de Distribución F α (p-1, n-p) para el factor estratificado X_{1_40}"



Ecuaciones de regresión, Comparación valor F, y datos R² ajustado de las ventas históricas para el factor estratificado X_{1_43}"

Análisis del método de regresión para	Descripción	Método de Regresión	Ecuación de la regresión	Valor F (Estadístico de Prueba)	Valor F _α (p-1, n-p)	Cumple F ≥ F _α (p-1, n-p)	R ² ajustado (%)
X _{1_43} "	Historial de Ventas TVs 43"	Stepwise Regression	$X_{1_43}'' = -9281 + 81,6 X_{8_MOVE} - 0,001718 X_{14_MOVE} + 92,9 X_{16_MOVE} - 0,02143 X_{20_MOVE}$	30,91	2,61	Si	73,11%
X _{1_43} "	Historial de Ventas TVs 43"	Forward Regression	$X_{1_43}'' = -9281 + 81,6 X_{8_MOVE} - 0,001718 X_{14_MOVE} + 92,9 X_{16_MOVE} - 0,02143 X_{20_MOVE}$	30,91	2,61	Si	73,11%
X _{1_43} "	Historial de Ventas TVs 43"	Backward Regression	$X_{1_43}'' = 146378 - 7015 X_2 - 10088 X_3 + 2069 X_4 - 7292 X_5 - 4248 X_9 + 871 X_{10} - 86,5 X_{12} + 0,00695 X_{13} - 0,04920 X_{14} - 25,0 X_{15} - 279,2 X_{16} - 0,002488 X_{17} - 0,01698 X_{20} + 2750 X_{2_MOVE} - 22,5 X_{3_MOVE} - 56,3 X_{4_MOVE} + 4072 X_{5_MOVE} + 6308 X_{7_MOVE} + 4687 X_{8_MOVE} + 2776 X_{9_MOVE} - 700 X_{10_MOVE} - 356 X_{11_MOVE} - 250,6 X_{12_MOVE} - 54,3 X_{15_MOVE} + 0,001238 X_{17_MOVE} - 0,0445 X_{20_MOVE} - 0,02624 X_{21_MOVE} + 0,0424 X_{22_MOVE}$	14,02	2,21	Si	89,23%

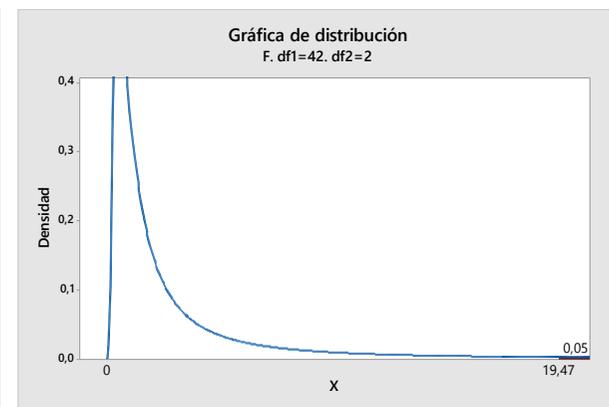
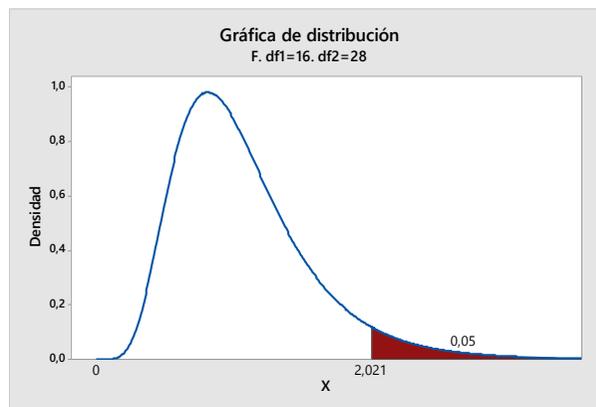
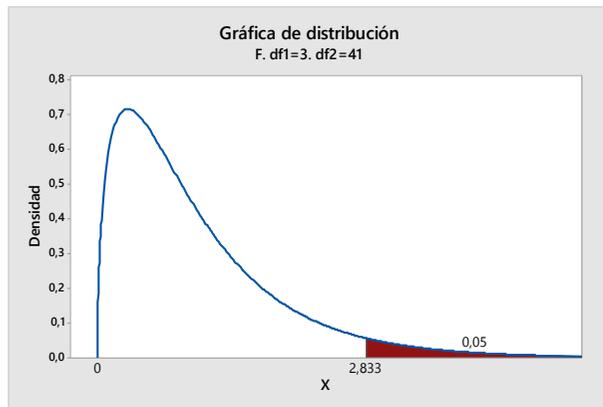
Gráficas de Distribución F α (p-1, n-p) para el factor estratificado X_{1_43}"



Ecuaciones de regresión, Comparación valor F, y datos R² ajustado de las ventas históricas para el factor estratificado X_{1_49}"

Análisis del método de regresión para	Descripción	Método de Regresión	Ecuación de la regresión	Valor F (Estadístico de Prueba)	Valor F _α (p-1, n-p)	Cumple F ≥ F _α (p-1, n-p)	R ² ajustado (%)
X _{1_49} "	Historial de Ventas TVs 49"	Stepwise Regression	$X_{1_49}'' = -70 + 181 X_7 - 31,9 X_{12_MOVE} - 8,15 X_{15_MOVE}$	12,12	2,83	Si	43,12%
X _{1_49} "	Historial de Ventas TVs 49"	Forward Regression	$X_{1_49}'' = 89647 - 559 X_2 - 935 X_3 - 798 X_4 - 1330 X_5 - 929 X_7 + 150 X_9 - 16 X_{11} - 0,001502 X_{13} + 234 X_{2_MOVE} - 124 X_{5_MOVE} - 16 X_{9_MOVE} - 216,7 X_{12_MOVE} + 0,00512 X_{14_MOVE} - 46,49 X_{15_MOVE} + 93,9 X_{16_MOVE} - 0,01539 X_{21_MOVE}$	13,85	2,02	Si	82,37%
X _{1_49} "	Historial de Ventas TVs 49"	Backward Regression	$X_{1_49}'' = -1474735 + 11370 X_2 + 10029 X_3 - 22792 X_4 + 12710 X_5 - 17086 X_6 + 23696 X_8 + 8640 X_9 + 4775 X_{10} + 4065,9 X_{11} + 791,6 X_{12} + 0,00509 X_{13} + 0,08837 X_{14} + 68,01 X_{15} - 170,16 X_{16} - 0,06047 X_{17} + 0,06156 X_{18} + 0,018582 X_{19} + 0,16348 X_{20} + 0,17241 X_{21} + 0,15144 X_{22} - 0,09606 X_{23} - 0,27351 X_{24} - 7230 X_{2_MOVE} - 149,14 X_{3_MOVE} - 460,7 X_{4_MOVE} - 14264 X_{5_MOVE} + 36249 X_{6_MOVE} - 20780 X_{7_MOVE} - 12052 X_{8_MOVE} - 12612 X_{9_MOVE} + 21089 X_{10_MOVE} - 3766,9 X_{11_MOVE} - 691,9 X_{12_MOVE} - 132,39 X_{15_MOVE} - 656,0 X_{16_MOVE} + 0,002071 X_{17_MOVE} + 0,02899 X_{18_MOVE} - 0,004008 X_{19_MOVE} - 0,02820 X_{20_MOVE} + 0,16142 X_{22_MOVE} + 0,16781 X_{23_MOVE} - 0,17011 X_{24_MOVE}$	1613,75	19,47	Si	99,94%

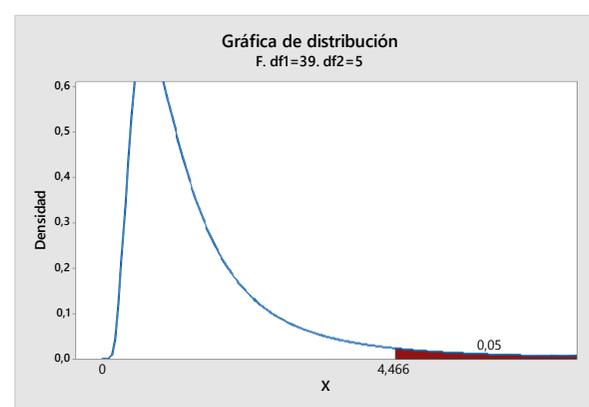
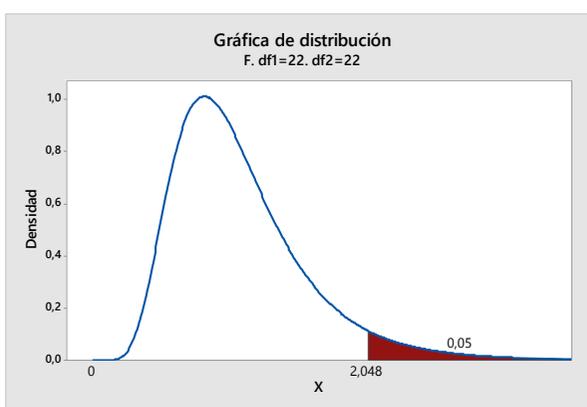
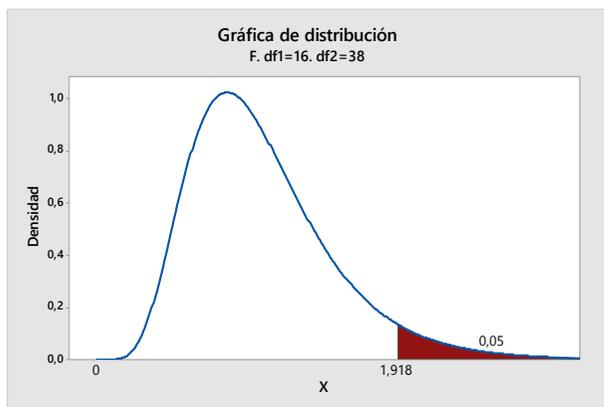
Gráficas de Distribución F α (p-1, n-p) para el factor estratificado X_{1_49}"



Ecuaciones de regresión, Comparación valor F, y datos R² ajustado de las ventas históricas para el factor estratificado X_{1_48"}

Análisis del método de regresión para	Descripción	Método de Regresión	Ecuación de la regresión	Valor F (Estadístico de Prueba)	Valor F _α (p-1, n-p)	Cumple F ≥ F _α (p-1, n-p)	R ² ajustado (%)
X _{1_48"}	Historial de Ventas TVs 48"	Stepwise Regression	$X_{1_48''} = -9371 - 249 X_7 + 0,01367 X_{20} + 8,66 X_{15_MOVE} + 107,7 X_{16_MOVE} + 0,02449 X_{20_MOVE} - 0,0388 X_{23_MOVE}$	6,74	1,92	Si	43,91%
X _{1_48"}	Historial de Ventas TVs 48"	Forward Regression	$X_{1_48''} = -18746 + 152,8 X_2 - 77 X_7 - 646 X_{10} - 89,8 X_{12} + 0,000784 X_{13} - 0,00839 X_{14} + 2,08 X_{15} + 197,6 X_{16} + 0,002984 X_{17} - 0,00880 X_{18} + 0,00577 X_{20} + 0,0387 X_{22} - 0,1248 X_{23} + 0,0363 X_{24} + 36,6 X_{4_MOVE} - 29,1 X_{5_MOVE} - 900 X_{7_MOVE} - 125,0 X_{9_MOVE} + 22,55 X_{15_MOVE} + 126,0 X_{16_MOVE} - 0,0162 X_{20_MOVE} - 0,1280 X_{23_MOVE}$	7,06	2,05	Si	75,19%
X _{1_48"}	Historial de Ventas TVs 48"	Backward Regression	$X_{1_48''} = -2659454 - 47424 X_2 - 61514 X_3 - 69294 X_4 - 17465 X_5 - 57651 X_6 + 53025 X_8 - 29905 X_9 + 12618 X_{10} + 2317 X_{11} + 0,0919 X_{13} - 0,1362 X_{14} + 33,81 X_{15} - 0,05209 X_{17} + 0,1083 X_{18} - 0,03311 X_{19} + 0,1389 X_{21} - 0,6658 X_{23} - 0,1836 X_{24} + 13807 X_{2_MOVE} - 528,4 X_{3_MOVE} - 1077 X_{4_MOVE} + 16431 X_{5_MOVE} + 107972 X_{6_MOVE} + 62098 X_{7_MOVE} + 10010 X_{8_MOVE} - 5355 X_{9_MOVE} + 35744 X_{10_MOVE} - 8566 X_{11_MOVE} - 597,2 X_{12_MOVE} - 139,6 X_{15_MOVE} - 282,9 X_{16_MOVE} + 0,05099 X_{17_MOVE} - 0,05600 X_{18_MOVE} - 0,04313 X_{19_MOVE} - 0,10513 X_{20_MOVE} - 0,1787 X_{21_MOVE} + 0,4941 X_{22_MOVE} - 0,0780 X_{23_MOVE} + 0,1211 X_{24_MOVE}$	26,97	4,47	Si	95,84%

Gráficas de Distribución F α (p-1, n-p) para el factor estratificado X_{1_48"}



APÉNDICE B

Valor F del Análisis de Varianza del método "Stepwise regression" para el factor estratificado X₁_global

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	1	364349703	364349703	11,58	0,001
X22	1	364349703	364349703	11,58	0,001
Error	43	1352566419	31455033		
Total	44	1716916123			

Valor F del Análisis de Varianza del método "Forward regression" para el factor estratificado X₁_global

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	13	1130176628	86936664	4,59	0,000
X3	1	29466912	29466912	1,56	0,221
X9	1	258708643	258708643	13,67	0,001
X12	1	129203226	129203226	6,83	0,014
X13	1	25929103	25929103	1,37	0,251
X16	1	177910998	177910998	9,40	0,004
X20	1	54802358	54802358	2,90	0,099
X22	1	172115443	172115443	9,09	0,005
X24	1	76675465	76675465	4,05	0,053
X9_MOVE	1	213018243	213018243	11,25	0,002
X11_MOVE	1	177025467	177025467	9,35	0,005
X16_MOVE	1	83786873	83786873	4,43	0,044
X18_MOVE	1	159943166	159943166	8,45	0,007
X23_MOVE	1	112723077	112723077	5,96	0,021
Error	31	586739495	18927080		
Total	44	1716916123			

Valor F del Análisis de Varianza del método "Backward regression" para el factor estratificado X₁_global

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	41	1715047329	41830423	67,15	0,003
X2	1	216700703	216700703	347,87	0,000
X3	1	210272803	210272803	337,55	0,000
X4	1	21118526	21118526	33,90	0,010
X5	1	184136513	184136513	295,60	0,000
X8	1	156988224	156988224	252,02	0,001
X9	1	235002644	235002644	377,25	0,000
X10	1	13454839	13454839	21,60	0,019
X11	1	170271462	170271462	273,34	0,000
X12	1	207353247	207353247	332,87	0,000
X13	1	123038326	123038326	197,52	0,001
X14	1	249104016	249104016	399,89	0,000
X15	1	10488470	10488470	16,84	0,026
X16	1	127536756	127536756	204,74	0,001
X17	1	23209213	23209213	37,26	0,009
X18	1	11111600	11111600	17,84	0,024

X19	1	23018588	23018588	36,95	0,009
X20	1	87689496	87689496	140,77	0,001
X21	1	104243277	104243277	167,34	0,001
X23	1	29207996	29207996	46,89	0,006
X24	1	125686085	125686085	201,77	0,001
X2_MOVE	1	153179065	153179065	245,90	0,001
X3_MOVE	1	35602170	35602170	57,15	0,005
X4_MOVE	1	115137966	115137966	184,83	0,001
X5_MOVE	1	244716887	244716887	392,85	0,000
X6_MOVE	1	20692472	20692472	33,22	0,010
X7_MOVE	1	87948452	87948452	141,18	0,001
X8_MOVE	1	297345568	297345568	477,33	0,000
X9_MOVE	1	203813755	203813755	327,18	0,000
X10_MOVE	1	211520364	211520364	339,56	0,000
X11_MOVE	1	51960054	51960054	83,41	0,003
X12_MOVE	1	84394365	84394365	135,48	0,001
X15_MOVE	1	12997698	12997698	20,87	0,020
X16_MOVE	1	187438132	187438132	300,90	0,000
X17_MOVE	1	92095390	92095390	147,84	0,001
X18_MOVE	1	99732999	99732999	160,10	0,001
X19_MOVE	1	85281249	85281249	136,90	0,001
X20_MOVE	1	28390038	28390038	45,57	0,007
X21_MOVE	1	47014609	47014609	75,47	0,003
X22_MOVE	1	51753595	51753595	83,08	0,003
X23_MOVE	1	123147800	123147800	197,69	0,001
X24_MOVE	1	198214447	198214447	318,20	0,000
Error	3	1868794	622931		
Total	44	1716916123			

Valor F del Análisis de Varianza del método "Stepwise regression" para el factor estratificado X_{1_32}"

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	3	174739065	58246355	5,79	0,002
X2	1	24811273	24811273	2,46	0,124
X22	1	120493783	120493783	11,97	0,001
X21_MOVE	1	42975697	42975697	4,27	0,045
Error	41	412768626	10067527		
Total	44	587507691			

Valor F del Análisis de Varianza del método "Forward regression" para el factor estratificado X_{1_32}"

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	9	291547838	32394204	3,83	0,002

X2	1	27018572	27018572	3,20	0,083
X6	1	68609098	68609098	8,11	0,007
X7	1	37887201	37887201	4,48	0,041
X22	1	31671348	31671348	3,75	0,061
X24	1	25080241	25080241	2,97	0,094
X6_MOVE	1	50156844	50156844	5,93	0,020
X18_MOVE	1	36658821	36658821	4,34	0,045
X21_MOVE	1	35896506	35896506	4,25	0,047
X23_MOVE	1	17035415	17035415	2,01	0,165
Error	35	295959853	8455996		
Total	44	587507691			

Valor F del Análisis de Varianza del método “Backward regression” para el factor estratificado X_{1_32} ”

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	30	569906440	18996881	15,11	0,000
X4	1	134987981	134987981	107,37	0,000
X5	1	95862364	95862364	76,25	0,000
X6	1	36646317	36646317	29,15	0,000
X8	1	117408658	117408658	93,39	0,000
X9	1	138563323	138563323	110,21	0,000
X10	1	97518003	97518003	77,57	0,000
X11	1	97867595	97867595	77,84	0,000
X12	1	54033959	54033959	42,98	0,000
X13	1	109608036	109608036	87,18	0,000
X14	1	112165591	112165591	89,22	0,000
X16	1	11865708	11865708	9,44	0,008
X19	1	123921072	123921072	98,57	0,000
X21	1	74135761	74135761	58,97	0,000
X22	1	43247308	43247308	34,40	0,000
X24	1	44463687	44463687	35,37	0,000
X2_MOVE	1	66430544	66430544	52,84	0,000
X3_MOVE	1	81541673	81541673	64,86	0,000
X4_MOVE	1	108542897	108542897	86,33	0,000
X5_MOVE	1	136333889	136333889	108,44	0,000
X6_MOVE	1	137380386	137380386	109,27	0,000
X8_MOVE	1	110724121	110724121	88,07	0,000
X9_MOVE	1	124252756	124252756	98,83	0,000
X10_MOVE	1	133062924	133062924	105,84	0,000
X12_MOVE	1	20586552	20586552	16,37	0,001
X16_MOVE	1	25459073	25459073	20,25	0,000
X17_MOVE	1	28361370	28361370	22,56	0,000
X19_MOVE	1	31259384	31259384	24,86	0,000
X21_MOVE	1	50895175	50895175	40,48	0,000
X22_MOVE	1	12663490	12663490	10,07	0,007
X23_MOVE	1	11653994	11653994	9,27	0,009
Error	14	17601251	1257232		
Total	44	587507691			

Valor F del Análisis de Varianza del método “Stepwise regression” para el factor estratificado X_{1_40}”

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	4	6467086	1616772	30,91	0,000
X8_MOVE	1	113186	113186	2,16	0,149
X14_MOVE	1	1360574	1360574	26,02	0,000
X16_MOVE	1	846930	846930	16,19	0,000
X20_MOVE	1	342025	342025	6,54	0,014
Error	40	2091911	52298		
Total	44	8558998			

Valor F del Análisis de Varianza del método “Forward regression” para el factor estratificado X_{1_40}”

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	11	89715749	8155977	4,43	0,000
X7	1	17256930	17256930	9,37	0,004
X3_MOVE	1	2540960	2540960	1,38	0,248
X5_MOVE	1	12071558	12071558	6,56	0,015
X6_MOVE	1	7906285	7906285	4,29	0,046
X10_MOVE	1	4634592	4634592	2,52	0,122
X13_MOVE	1	4930391	4930391	2,68	0,111
X16_MOVE	1	2570073	2570073	1,40	0,246
X18_MOVE	1	6593870	6593870	3,58	0,067
X20_MOVE	1	14895552	14895552	8,09	0,008
X21_MOVE	1	7859984	7859984	4,27	0,047
X24_MOVE	1	85268	85268	0,05	0,831
Error	33	60749044	1840880		
Total	44	150464793			

Valor F del Análisis de Varianza del método “Backward regression” para el factor estratificado X_{1_40}”

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	36	148394474	4122069	15,93	0,000
X2	1	32322876	32322876	124,90	0,000
X3	1	29825770	29825770	115,25	0,000
X5	1	30409018	30409018	117,50	0,000
X6	1	11928977	11928977	46,10	0,000
X8	1	24508301	24508301	94,70	0,000
X9	1	34829605	34829605	134,59	0,000
X11	1	29124366	29124366	112,54	0,000
X12	1	20377894	20377894	78,74	0,000

X13	1	34123568	34123568	131,86	0,000
X14	1	33312494	33312494	128,72	0,000
X15	1	5520122	5520122	21,33	0,002
X16	1	16545036	16545036	63,93	0,000
X17	1	32284660	32284660	124,75	0,000
X20	1	23399315	23399315	90,42	0,000
X21	1	18618791	18618791	71,95	0,000
X23	1	19632539	19632539	75,86	0,000
X24	1	18856407	18856407	72,86	0,000
X2_MOVE	1	31580619	31580619	122,03	0,000
X4_MOVE	1	27724064	27724064	107,13	0,000
X5_MOVE	1	28872368	28872368	111,57	0,000
X6_MOVE	1	22122483	22122483	85,48	0,000
X7_MOVE	1	33451180	33451180	129,26	0,000
X8_MOVE	1	31817008	31817008	122,95	0,000
X9_MOVE	1	32422096	32422096	125,28	0,000
X10_MOVE	1	33018842	33018842	127,59	0,000
X11_MOVE	1	19845965	19845965	76,69	0,000
X12_MOVE	1	7316104	7316104	28,27	0,001
X15_MOVE	1	5420113	5420113	20,94	0,002
X16_MOVE	1	22583891	22583891	87,27	0,000
X17_MOVE	1	16791069	16791069	64,88	0,000
X18_MOVE	1	26653941	26653941	102,99	0,000
X19_MOVE	1	12640859	12640859	48,85	0,000
X21_MOVE	1	9299555	9299555	35,93	0,000
X22_MOVE	1	14186230	14186230	54,82	0,000
X23_MOVE	1	11795616	11795616	45,58	0,000
X24_MOVE	1	32167171	32167171	124,30	0,000
Error	8	2070319	258790		
Total	44	150464793			

Valor F del Análisis de Varianza del método "Stepwise regression" para el factor estratificado X_{1_43}"

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	4	6467086	1616772	30,91	0,000
X8_MOVE	1	113186	113186	2,16	0,149
X14_MOVE	1	1360574	1360574	26,02	0,000
X16_MOVE	1	846930	846930	16,19	0,000
X20_MOVE	1	342025	342025	6,54	0,014
Error	40	2091911	52298		
Total	44	8558998			

**Valor F del Análisis de Varianza del método “Forward regression” para el factor
estratificado X_{1_43}”**

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	4	6467086	1616772	30,91	0,000
X8_MOVE	1	113186	113186	2,16	0,149
X14_MOVE	1	1360574	1360574	26,02	0,000
X16_MOVE	1	846930	846930	16,19	0,000
X20_MOVE	1	342025	342025	6,54	0,014
Error	40	2091911	52298		
Total	44	8558998			

**Valor F del Análisis de Varianza del método “Backward regression” para el factor
estratificado X_{1_43}”**

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	28	8223735	293705	14,02	0,000
X2	1	385870	385870	18,42	0,001
X3	1	423829	423829	20,23	0,000
X4	1	301845	301845	14,41	0,002
X5	1	536764	536764	25,62	0,000
X9	1	318788	318788	15,21	0,001
X10	1	155559	155559	7,42	0,015
X12	1	80327	80327	3,83	0,068
X13	1	450216	450216	21,49	0,000
X14	1	640193	640193	30,55	0,000
X15	1	73935	73935	3,53	0,079
X16	1	581889	581889	27,77	0,000
X17	1	171379	171379	8,18	0,011
X20	1	76847	76847	3,67	0,074
X2_MOVE	1	354497	354497	16,92	0,001
X3_MOVE	1	93796	93796	4,48	0,050
X4_MOVE	1	218365	218365	10,42	0,005
X5_MOVE	1	275972	275972	13,17	0,002
X7_MOVE	1	204730	204730	9,77	0,007
X8_MOVE	1	493970	493970	23,57	0,000
X9_MOVE	1	266586	266586	12,72	0,003
X10_MOVE	1	125398	125398	5,98	0,026
X11_MOVE	1	73857	73857	3,52	0,079
X12_MOVE	1	637924	637924	30,44	0,000
X15_MOVE	1	461211	461211	22,01	0,000
X17_MOVE	1	70953	70953	3,39	0,084
X20_MOVE	1	387283	387283	18,48	0,001
X21_MOVE	1	205384	205384	9,80	0,006
X22_MOVE	1	102821	102821	4,91	0,042
Error	16	335263	20954		
Total	44	8558998			

**Valor F del Análisis de Varianza del método “Stepwise regression” para el factor
estratificado X_{1_49}”**

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	3	4309629	1436543	12,12	0,000
X7	1	307436	307436	2,59	0,115
X12_MOVE	1	829261	829261	7,00	0,012
X15_MOVE	1	493017	493017	4,16	0,048
Error	41	4859368	118521		
Total	44	9168997			

**Valor F del Análisis de Varianza del método “Forward regression” para el factor
estratificado X_{1_49}”**

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	16	8140346	508772	13,85	0,000
X2	1	39648	39648	1,08	0,30857
X3	1	52535	52535	1,43	0,242
X4	1	74771	74771	2,04	0,165
X5	1	145339	145339	3,96	0,057
X7	1	131175	131175	3,57	0,069
X9	1	24475	24475	0,67	0,421
X11	1	214	214	0,01	0,940
X13	1	2111027	2111027	57,46	0,000
X2_MOVE	1	196821	196821	5,36	0,028
X5_MOVE	1	33665	33665	0,92	0,347
X9_MOVE	1	97	97	0,00	0,959
X12_MOVE	1	1889033	1889033	51,42	0,000
X14_MOVE	1	127728	127728	3,48	0,073
X15_MOVE	1	801092	801092	21,81	0,000
X16_MOVE	1	131295	131295	3,57	0,069
X21_MOVE	1	131015	131015	3,57	0,069
Error	28	1028651	36738		
Total	44	9168997			

**Valor F del Análisis de Varianza del método “Backward regression” para el factor
estratificado X_{1_49}”**

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	42	9168726	218303	1613,75	0,001
X2	1	63819	63819	471,76	0,002
X3	1	74751	74751	552,58	0,002
X4	1	32148	32148	237,65	0,004
X5	1	156076	156076	1153,75	0,001
X6	1	87791	87791	648,97	0,002
X8	1	103885	103885	767,95	0,001
X9	1	74422	74422	550,14	0,002
X10	1	104315	104315	771,12	0,001
X11	1	237035	237035	1752,21	0,001

X12	1	350144	350144	2588,35	0,000
X13	1	3085	3085	22,80	0,041
X14	1	203261	203261	1502,55	0,001
X15	1	128118	128118	947,08	0,001
X16	1	40817	40817	301,73	0,003
X17	1	313067	313067	2314,26	0,000
X18	1	142952	142952	1056,73	0,001
X19	1	53339	53339	394,30	0,003
X20	1	543580	543580	4018,27	0,000
X21	1	361358	361358	2671,24	0,000
X22	1	228902	228902	1692,10	0,001
X23	1	19934	19934	147,36	0,007
X24	1	238661	238661	1764,24	0,001
X2_MOVE	1	145235	145235	1073,61	0,001
X3_MOVE	1	55630	55630	411,23	0,002
X4_MOVE	1	84131	84131	621,91	0,002
X5_MOVE	1	391587	391587	2894,70	0,000
X6_MOVE	1	52769	52769	390,08	0,003
X7_MOVE	1	46636	46636	344,75	0,003
X8_MOVE	1	477735	477735	3531,53	0,000
X9_MOVE	1	186610	186610	1379,46	0,001
X10_MOVE	1	124480	124480	920,18	0,001
X11_MOVE	1	281245	281245	2079,03	0,000
X12_MOVE	1	340279	340279	2515,42	0,000
X15_MOVE	1	707864	707864	5232,69	0,000
X16_MOVE	1	197758	197758	1461,88	0,001
X17_MOVE	1	2782	2782	20,57	0,045
X18_MOVE	1	62775	62775	464,05	0,002
X19_MOVE	1	12092	12092	89,39	0,011
X20_MOVE	1	23874	23874	176,48	0,006
X22_MOVE	1	92298	92298	682,29	0,001
X23_MOVE	1	59326	59326	438,55	0,002
X24_MOVE	1	222855	222855	1647,39	0,001
Error	2	271	135		
Total	44	9168997			

**Valor F del Análisis de Varianza del método "Stepwise regression" para el factor
estratificado X_{1_48}"**

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	6	3216945	536158	6,74	0,000
X7	1	464843	464843	5,84	0,021
X20	1	193659	193659	2,44	0,127
X15_MOVE	1	469918	469918	5,91	0,020
X16_MOVE	1	1129044	1129044	14,20	0,001
X20_MOVE	1	504746	504746	6,35	0,016

X23_MOVE	1	172682	172682	2,17	0,149
Error	38	3022163	79531		
Total	44	6239108			

Valor F del Análisis de Varianza del método “Forward regression” para el factor estratificado X_{1_48}”

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	22	5465186	248418	7,06	0,000
X2	1	173231	173231	4,92	0,037
X7	1	15538	15538	0,44	0,513
X10	1	1031161	1031161	29,31	0,000
X12	1	290840	290840	8,27	0,009
X13	1	521521	521521	14,83	0,001
X14	1	588568	588568	16,73	0,000
X15	1	2755	2755	0,08	0,782
X16	1	410254	410254	11,66	0,002
X17	1	343243	343243	9,76	0,005
X18	1	61667	61667	1,75	0,199
X20	1	16376	16376	0,47	0,502
X22	1	66856	66856	1,90	0,182
X23	1	380609	380609	10,82	0,003
X24	1	129543	129543	3,68	0,068
X4_MOVE	1	292721	292721	8,32	0,009
X5_MOVE	1	5150	5150	0,15	0,706
X7_MOVE	1	735441	735441	20,91	0,000
X9_MOVE	1	107775	107775	3,06	0,094
X15_MOVE	1	315288	315288	8,96	0,007
X16_MOVE	1	170441	170441	4,85	0,039
X20_MOVE	1	85538	85538	2,43	0,133
X23_MOVE	1	629352	629352	17,89	0,000
Error	22	773922	35178		
Total	44	6239108			

Valor F del Análisis de Varianza del método “Backward regression” para el factor estratificado X_{1_48}”

Fuente	GL	SC Ajust.	MC Ajust.	Valor F	Valor p
Regresión	39	6209590	159220	26,97	0,001
X2	1	385975	385975	65,38	0,000
X3	1	464062	464062	78,61	0,000
X4	1	303216	303216	51,36	0,001
X5	1	282311	282311	47,82	0,001
X6	1	557890	557890	94,50	0,000
X8	1	592869	592869	100,43	0,000
X9	1	374574	374574	63,45	0,001
X10	1	438372	438372	74,26	0,000
X11	1	285721	285721	48,40	0,001

X13	1	434486	434486	73,60	0,000
X14	1	454043	454043	76,91	0,000
X15	1	84895	84895	14,38	0,013
X17	1	394510	394510	66,83	0,000
X18	1	368939	368939	62,49	0,001
X19	1	307433	307433	52,08	0,001
X21	1	433265	433265	73,39	0,000
X23	1	441587	441587	74,80	0,000
X24	1	202676	202676	34,33	0,002
X2_MOVE	1	348130	348130	58,97	0,001
X3_MOVE	1	508517	508517	86,14	0,000
X4_MOVE	1	521311	521311	88,30	0,000
X5_MOVE	1	414241	414241	70,17	0,000
X6_MOVE	1	384596	384596	65,15	0,000
X7_MOVE	1	278914	278914	47,25	0,001
X8_MOVE	1	515515	515515	87,32	0,000
X9_MOVE	1	247893	247893	41,99	0,001
X10_MOVE	1	569640	569640	96,49	0,000
X11_MOVE	1	608229	608229	103,03	0,000
X12_MOVE	1	859480	859480	145,59	0,000
X15_MOVE	1	339341	339341	57,48	0,001
X16_MOVE	1	264051	264051	44,73	0,001
X17_MOVE	1	380240	380240	64,41	0,000
X18_MOVE	1	196277	196277	33,25	0,002
X19_MOVE	1	367491	367491	62,25	0,001
X20_MOVE	1	788649	788649	133,59	0,000
X21_MOVE	1	494082	494082	83,69	0,000
X22_MOVE	1	361962	361962	61,31	0,001
X23_MOVE	1	35139	35139	5,95	0,059
X24_MOVE	1	264840	264840	44,86	0,001
Error	5	29518	5904		
Total	44	6239108			

APÉNDICE C

Manual de usuario “Demand Forecasting RP”

20 DE FEBRERO DE 2017

MANUAL DE USUARIO
SISTEMA “DEMAND FORECASTING RP”

ING. RODDY PÉREZ PARRA
AUDIOELEC S.A.

Contenido

Manual de Usuario de "Demand Forecasting RP".-	2
1. Security.-	2
2. Support Platform.-	3
3. Data Records.-	4

Manual de Usuario de "Demand Forecasting RP".-

En este documento encontrará toda la información necesaria del funcionamiento del método del sistema "Demand forecasting RP".

El sistema contiene 3 tipos de CyberServices:

- Security
- Support Platform
- Data Records

1. Security.-

Este servicio contiene los siguientes aspectos.

```
# Declara un modelo secuencial
valor_lambda = value_lambda

while True :
    print( "ENTRENANDO RED NEURONAL..." )
    modelo = Sequential()
    modelo.add( GRU( input_dim = num_variables,
                    input_length = None,
                    output_dim = 32,
                    activation = 'linear',
                    inner_activation = 'sigmoid',
                    return_sequences = True,
                    W_regularizer = l2(valor_lambda) ) )
    modelo.add( GRU( output_dim = 1,
                    activation = lambda x : K.exp(x),
                    inner_activation = 'sigmoid',
                    return_sequences = True ) )
    # Compilamos el modelo dándole una función de pérdida y un optimizador
    modelo.compile( loss = 'mse', optimizer = 'adam', metrics = {'mape'})
    # Ajustamos el modelo a los datos
    modelo.fit( X_entren3, Y_entren3, batch_size = 1, nb_epoch = numero_de_eras )
    ( mse, mape ) = modelo.evaluate( X_entren3, Y_entren3 )
    if mape < 20.0 :
        print( 'Entrenamiento exitoso!' )
        break
    else :
        print( 'Entrenamiento fracaso, intentando de nuevo...' )
```

El método contiene en servicio un nivel de seguridad en el sistema, la cual proporcionara un resultado de aprendizaje aceptable que no debe ser alterado por ningún motivo dado por:

- Ejecución del método de pronóstico es exclusivo desde el simulador

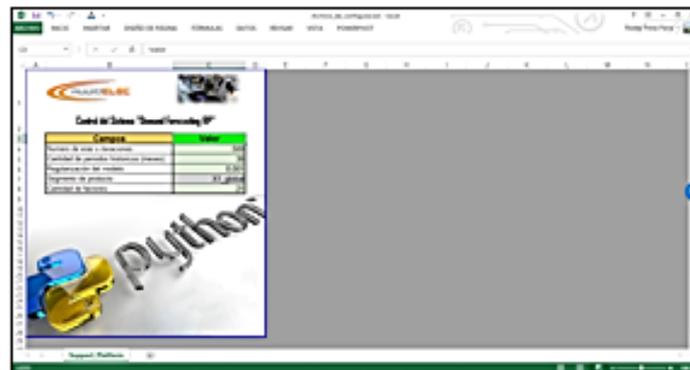
Cuando se quiere hacer la simulación del método es importante tomar en cuenta que el único sitio para proceder a ejecutar las iteraciones es al presionar el comando "PLAY" en el software Spyder-Python.



- **Condicionar el modelo secuencial dentro del método**
Compromete a tener un error deseado, en esta particularidad MAPE debe ser menor que 20%, de modo que detiene el cálculo de toda la programación cuando retorna true en el caso que sea exitoso, y en caso de salir false que no sea exitoso, tiene que recalcular hasta encontrar una solución acorde a la condición dada.
- **Extraer la información del Archivo_de_configuracion**
La cual permite introducir los respectivos valores validados a una lista que existen según el campo y hacen conexión al software.
- **Extraer los datos de la hoja de cálculo Data_Base_X**
La cual permite abrir el archivo que el software llama para hacer conexión con los valores registrados de cada factor o variable predictora, disponiendo al servicio de la base de datos.

2. Support Platform.-

Este servicio contiene las siguientes características.



Las características que contiene este servicio son a nivel del sistema, la cual proporcionara un tablero de control que permite realizar diferentes acciones tales como; seleccionar datos, actualizar y/o consultar información previa ingreso al sistema.

Los campos se encuentran:

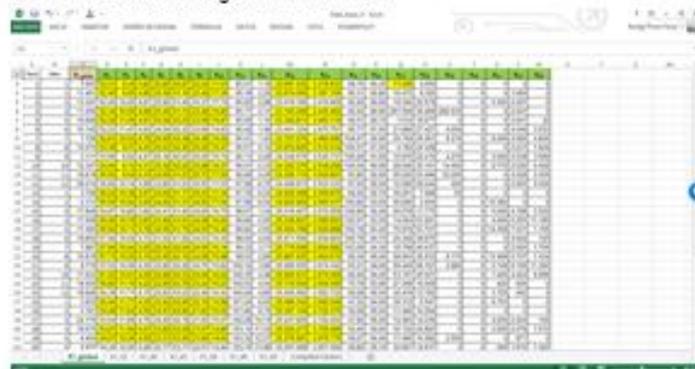
- **Número de era o iteraciones**
Permite calcular la cantidad de veces que consideramos necesario hasta asegurar un resultado estable.
- **Cantidad de periodos históricos**
Básicamente es la cantidad de meses de ventas históricas, que inicialmente son 36 pero enriquecen al modelo a medida que vaya aumentando la data con el paso del tiempo.
- **Regularización del modelo**

Contribuye que encontrar mejores resultado suavizando la curva generada por la base de datos al pronosticar demandas.

- **Segmento de producto**
Permite seleccionar el tipo producto que nos interesa analizar, la cual podría ser: $X_{1,2016}$, $X_{1,2017}$, $X_{2,2017}$, $X_{1,2018}$, $X_{1,2019}$, $X_{1,2020}$ Y $X_{1,2021}$.
- **Cantidad de factores**
Corresponde al número de variables predictoras que tiene cada ecuación.

3. Data Records.-

Este servicio contiene la siguiente información.



The image shows a screenshot of a data table with multiple columns and rows. The table is displayed in a web browser interface. The columns are labeled with various variables and factors, and the rows contain numerical data. Some cells in the table are highlighted in yellow, indicating specific data points or variables of interest.

Lo que se observa en el cuadro son variables o factores vitales que deben estar registrados completamente para enriquecer el proceso de aprendizaje del sistema a través de redes neuronales, por ello, se recomienda darles mantenimiento o actualización de datos cada 3 meses, considerando que siempre los datos a tomar sean provenientes de fuentes confiables, o por lo menos sean validados por calidad de información.

A pesar de tratarse de números, estos datos son factores macro-económicos que para ser incluidos en el sistema, se toman acciones tales como; investigación, encuestas, actualización y agregación de nuevos factores en caso de ser necesario con el transcurso del tiempo.

Note: Para todo lo mencionado, adicional al soporte escrito del presente manual, está la colaboración de quien(es) lidera(n) y administra esta herramienta de trabajo.

BIBLIOGRAFÍA

- [1] Ekosnegocios, (2015, agosto). Ranking 1000 empresarial 2015 [Online]. Disponible en: <http://www.ekosnegocios.com/revista/pdfTemas/1274.pdf>
- [2] Ekosnegocios, (2016, agosto). Ranking 1000 empresarial 2016 [Online]. Disponible en: <http://www.ekosnegocios.com/negocios/especiales/documentos/ranking2016.pdf>
- [3] Rebeca Gonzalez Avila, Manual de Administración de la Calidad Total y Círculos de Control de Calidad. México: Instituto Tecnológico y de Estudios Superiores de Monterrey, 2003.
- [4] C. CABRERA, «Liderazgo en 6sigma,» 26 febrero 2014. [Online]. Disponible: <http://www.liderazgolean6sigma.com/2014/02/la-voz-del-cliente.html>
- [5] Pérez-López, E; García-Cerdas, M. Implementación de la metodología DMAIC-Seis Sigma en el envasado de licores en Fanal. Tecnología en Marcha. Vol. 27, N° 3, Julio-Septiembre 2014.
- [6] Andi Ganti, Dr. Anita G. Ganti, «Six Sigma and Health care», IISE's Society for Health Systems, p. 9
- [7] Statistics Solutions, «Selection Process for Multiple Regression» Diciembre 2016. [Online]. Disponible en: <http://www.statisticssolutions.com/selection-process-for-multiple-regression/>
- [8] José T. Palma Méndez, Roque Marín Morales, Inteligencia artificial, Ed.McGraw Hill, pág.650-651
- [9] Wildml, « Recurrent Neural Networks Tutorial, Part 1 – INTRODUCTION TO RNNS » Septiembre 2015. [Online]. Disponible en: <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/>