



**PROPUESTA PARA SELECCIÓN DE PARAMETROS DE MODELOS DE
PRONÓSTICOS MEDIANTE PODERACIÓN DE INDICADORES CLAVES DE
DESEMPEÑO: CASO SUAVIAZACIÓN EXPONENCIAL**

YENNY CATALINA SANCHEZ HENAO

ASESOR

CARLOS ALBERTO CASTRO ZULUAGA

**UNIVERSIDAD EAFIT
FACULTAD DE INGENIERÍAS**

2021

Nota de aceptación

Presidente del jurado

Jurado

Jurado

Medellín, 19 de noviembre de 2021

TABLA DE CONTENIDO

1. INTRODUCCIÓN.....	9
2. PROBLEMA DE INVESTIGACIÓN	11
3. OBJETIVOS.....	13
3.1 Objetivo general.....	13
3.2 Objetivos específicos	13
4. MODELOS DE PREDICCIÓN E INDICADORES DE EXACTITUD DE LOS MODELOS DE PRONOSTICO	14
4.1 Modelos de predicción	14
4.2 Indicadores de exactitud de los modelos de pronósticos	16
4.2.1 Indicadores académicos para la medición de exactitud de los errores de pronósticos.....	16
4.2.2 Otros indicadores académicos encontrados en la literatura	17
4.2.3 Modelos prácticos para la medición de exactitud de los errores de pronósticos.....	19
4.2.3.1 Definición para indicadores prácticos para la medición de exactitud de los errores de pronósticos.....	20
5. VERIFICACIÓN Y VALIDACIÓN DEL PARAMETRO DEFINIDO MEDIANTE PONDERACIÓN DE INDICADORES PROPUESTO	24
5.1 Series de datos y características	25
5.2 Selección de parámetros en modelos de suavización exponencial simple y suavización de Holt a partir de la optimización del MAD, MAPE y MSE.....	27
5.2.1 Selección del parámetro α del modelo de suavización exponencial simple (SE)	28
5.2.2 Selección de los parámetros α y β del modelo de suavización exponencial de Holt	30
5.2.3 Comparación de Resultados en la Optimización de MAD, MAPE y MSE.....	32
5.3 Propuesta para la definición de parámetros mediante ponderación de indicadores: Caso Suavización Exponencial Simple.....	34
5.3.1 Ponderación de indicadores	35
5.3.2 Propuesta para la determinación del parámetro α del modelo SE	36
5.4 Cálculo de α propuesto a partir de los indicadores seleccionados	37
6. CONCLUSIONES.....	43

7. RECOMENDACIONES.....	45
8. BIBLIOGRAFIA.....	46
9. ANEXOS	48

LISTA DE FIGURAS

- Figura 1.** Modelos de pronóstico cualitativos
- Figura 2.** Modelos de pronóstico cuantitativos
- Figura 3.** Clasificación de errores de pronósticos
- Figura 4.** Influencia de los pronósticos en los inventarios y en el nivel de servicio
- Figura 5.** Pasos para definición de parámetro mediante la ponderación de indicadores
- Figura 5a.** Gráfico de demanda de la serie N2480
- Figura 5b.** Gráfico de demanda de la serie N1695
- Figura 5c.** Gráfico de demanda de la serie N1405
- Figura 6.** Gráficos comparativo FA nuevos periodos con α mínimo MAPE y α ponderado

LISTA DE TABLAS

Tabla 1. Clasificación de errores de pronósticos según tipo de medida

Tabla 2. Series de M3-Competition y sus características utilizadas en la investigación

Tabla 3: Valores óptimos de α del modelo de suavización exponencial simple

Tabla 4: Valores óptimos de α y β del modelo de suavización exponencial de Holt.

Tabla 5: Valores obtenidos en la optimización de MAPE, ME y V* Cero

Tabla 6. Ponderaciones asignadas por expertos en planeación de demanda a los indicadores MAPE, ME y V*Cero

Tabla 7. Datos α mínimo para MAPE, ME, V * Cero y α ponderado

Tabla 8. Datos FA promedio MAPE nuevos periodos con α mínimo MAPE y α ponderado.

LISTA DE ANEXOS

Anexo 1: Varianza

Anexo 2: Desviación estándar

Anexo 3: Coeficiente de variación

Anexo 4: Estructura FOR TSM

Anexo 6: Hoja de Cálculo con Datos iniciales

Anexo 7: Hoja de Cálculo Datos propuesta

Anexo 8: Ruta para encuesta a Expertos

GLOSARIO

COEFICIENTE DE CORRELACIÓN: es una medida relativa del grado de relación de dos variables. Puede tomar valores entre -1 y 1. Los valores cercanos a ± 1 indican un alto grado de relación entre las variables. Fortaleza en la relación que tienen dos o más variables.

COEFICIENTE DE VARIACIÓN: es la relación entre la desviación estándar y el promedio de los datos de la demanda histórica. Sirve para determinar la estabilidad o no de los datos en el tiempo.

DEMANDA: cantidad de productos o servicios que el cliente requiere en un tiempo determinado. Según Chase et al (2004) la demanda está compuesta principalmente por seis componentes: la demanda promedio, la tendencia, el elemento estacional, los elementos cíclicos, la variación aleatoria y la correlación propia.

ERROR DEL PRONÓSTICO: diferencia entre el valor real de la demanda y el valor pronosticado para cada periodo.

DEMANDA INTERMITENTE: Demandas infrecuentes, irregulares y a menudo impredecibles. También llamada demanda esporádica.

FOR-TSM (Forecasting Time Series Models): Herramienta desarrollada en Excel® que se utiliza para correr diferentes Modelos de Pronósticos de Series de Tiempo

INDICADOR: Instrumento que provee información de una determinada condición o el logro de una cierta situación, actividad o resultado. Un indicador necesariamente debe representar una relación entre variables

PARAMETRO: Elemento o dato importante desde el que se examina un tema, cuestión o asunto

PRONÓSTICO: un pronóstico es una estimación de un evento futuro que se hace con base en un método específico y se usa para la planificación

RANGO DE LA SEÑAL DE RASTREO: indica el intervalo en el cual se encuentran las desviaciones medias absolutas de las señales de rastreo obtenidas en el análisis del error con relación al pronóstico.

SEÑAL DE RASTREO: indica la medida en que el promedio del pronóstico está siguiendo la tendencia de la demanda. Se construye con el número de desviaciones medias absolutas en que el valor del pronóstico se aleja de la realidad. Es la relación que existe en cada periodo entre RSFE y MAD.

1. INTRODUCCIÓN

La mayoría de las empresas dentro de sus procesos de planeación parten de la información histórica disponible de demanda o ventas, con el fin de realizar los procesos de planeación de operaciones a largo, mediano y corto plazo, y plantear así sus planes de trabajo. El principal interés de las personas encargadas de generar los pronósticos de la demanda será la de contar con la suficiente información que pueda soportar de manera confiable los análisis matemáticos realizados con los modelos de pronósticos utilizados, obteniendo los menores errores posibles.

Hoy en día la información histórica con la que normalmente cuentan la mayoría de las compañías es la información de sus ventas, pero el interés real es la proyección de la demanda. Cabe resaltar la diferencia existente entre las ventas y la demanda, la cual consiste en que no siempre las ventas coinciden con la demanda, ya que en algunas ocasiones las ventas reportadas pueden ser inferiores a la demanda o en algunas otras sobrepasarla.

Las variaciones existentes entre demanda y ventas se pueden dar principalmente por:

- Condiciones puntuales del mercado, como el gusto, la cultura, o las condiciones humanas no atribuibles a las leyes del mercado sino a los hábitos de las personas.
- Estacionalidad. La demanda se modifica frente a condiciones ambientales cíclicas o eventuales como las estaciones del año, las épocas de sequía o lluvia, entre otras.
- La tendencia. Los patrones de consumo siguen tendencias, es decir, patrones de consumo derivados del interés en el mercado o de hábitos de consumo que se reproducen a sí mismos y que pueden ser estudiados e incluso predichos.

Cuando no se logra tener un proceso de estimación alineado con la demanda real pueden darse dos fenómenos que implican sobrecosto y/o pérdida de imagen de la empresa. En el caso en que la demanda sobrepase los pronósticos, podemos decir que se presenta un desabastecimiento lo cual lleva a un nivel de servicio inadecuado. Para el caso en que la demanda está por debajo de las ventas, se presenta un sobre stock lo cual implica sobrecostos de manipulación, almacenamiento y en algunos casos pérdida de producto.

Dentro de las compañías, la mayoría de las áreas funcionales necesitan como información de entrada para sus procesos de toma de decisiones, pronósticos de demanda que les permita planear los múltiples recursos, los cuales necesitan ser asignados en los periodos futuros con el fin de lograr suplir estas necesidades. Algunas de estas áreas son compras, mercadeo, ventas, producción, operaciones, logística, finanzas y recursos humanos, entre otras. De allí que la importancia de los pronósticos radica en que estos tienen un efecto sobre toda la organización

El reto es entonces tratar de obtener pronósticos lo más exactos y consistentes posibles por parte de los encargados de las proyecciones de demanda, ya que esto permitiría a los directores de producción disminuir los tiempos de producción y costos, utilizando eficaz y

eficientemente los recursos existentes, planificar nuevos recursos y mantener los inventarios en niveles óptimos; a los directores de planeación les permitirá reducir tiempos y costos en la cadena de suministro a través de la adecuada programación de entradas y salidas; a los directores de finanzas, programar de la mejor manera los recursos financieros para la realización de los planes de las demás áreas y a los directores de recursos humanos programar eficientemente la llegada o salida de nuevos colaboradores, en caso de ser necesarios.

Este trabajo propone una forma de seleccionar parámetros de modelos por medio del cálculo a partir de varios indicadores utilizados a nivel práctico, buscando obtener los resultados más adecuados del comportamiento de un modelo de proyección, como es tener una magnitud de los errores los más bajos posibles y que los errores acumulativos del modelo tiendan a cero, buscando tener un balance entre los errores positivos y negativos. Inicialmente se determinará qué indicador de magnitud entre los múltiples existentes es el más adecuado a medir a partir de la optimización de los parámetros de los modelos de suavización exponencial simple y con tendencia. Posteriormente se hace un comparativo de los resultados al utilizar el parámetro alfa (α) en un modelo de suavización exponencial simple por medio de optimización del *MAPE* versus el parámetro propuesto. Para esto se utilizaron aleatoriamente 20 series del M3 competition disponibles en la página del International Institute of Forecasters.

Los resultados muestran que, aunque el modelo propuesto no obtiene los menores resultados de los indicadores de magnitud, éste si logra tener mayor consistencia entre los errores positivos y negativos, sin alejarse considerablemente del valor óptimo de la magnitud del error, lo cual muestra un mejor comportamiento combinado de los indicadores incluidos en la propuesta.

2. PROBLEMA DE INVESTIGACIÓN

Los pronósticos de demanda al ser un proceso que se realiza bajo situaciones de incertidumbre se convierten en uno de los principales retos para los encargados de planeación en las empresas.

Existen múltiples modelos para realizar los pronósticos de demanda los cuales serán usados teniendo la cuenta el comportamiento y el patrón histórico de los datos, así como la experiencia del pronosticador. Para cada uno de los escenarios o métodos de pronósticos que se usen es necesario determinar la forma o método para medir su desempeño o precisión.

Así como existen un gran número de modelos y estrategias para pronosticar, existen también diferentes formas para medir los errores de los pronósticos. Conocer cada modelo o estrategia tanto de pronóstico como de evaluación de asertividad, permitirá poder seleccionar los parámetros y el modelo más adecuado para lograr los mejores resultados.

Los errores de un modelo de pronósticos de demanda siempre van a existir, aunque para las empresas, tener pronósticos más precisos incrementa la posibilidad de poder responder más fácilmente a la demanda y a la disminución de costos ya sea por la generación de excesos o de faltantes. Es por esta razón que la medición de la asertividad se vuelve de vital importancia debido a que las decisiones futuras que se tomen deben estar basadas en la información más certera posible que proporcione el modelo de proyección.

La medición de la asertividad de los pronósticos se utiliza para:

- Determinar los parámetros de un modelo de pronóstico.
- Seleccionar un modelo de pronósticos.
- Mejorar el proceso de pronóstico.
- Obtener más y mejor información del desempeño esperado del pronóstico.
- Disponer de información comparativa para hacer “Benchmark”.
- Identificar problemas de manera anticipada.

Como se observa, tener una adecuada medición de los errores de los pronósticos se convierte hoy en una necesidad importante para las empresas, pero al existir un número tan variado de posibilidades para dicha medición, encontrar el más adecuado desde el punto de vista práctico no es una tarea fácil. Por lo anterior, este trabajo propone una forma alternativa al problema de seleccionar parámetros relacionando varios indicadores significativos de desempeño, pero con un enfoque práctico, buscando proporcionar a los tomadores de decisiones en el área de estimados de una empresa, una metodología que busca el desempeño más adecuado de un modelo de proyección.

En este trabajo se aplicarán herramientas estadísticas para pronósticos de demanda y medición de errores, con el fin de proponer un parámetro definido mediante ponderación de indicadores que permita tomar mejores decisiones en el proceso de pronósticos de demanda, tomando como base específicamente el modelo de suavización exponencial.

3. OBJETIVOS

3.1 Objetivo general

Proponer una metodología para la selección de parámetros de modelos de proyección de demanda utilizando la ponderación de indicadores utilizados a nivel práctico, buscando que el comportamiento del modelo de proyección trate de obtener los errores porcentuales absolutos medios lo más bajos posibles; los errores acumulativos lo más cercano posible a cero y tener un balance entre errores positivos y negativos en el tiempo, permitiendo de esta manera tomar mejores decisiones con respecto a los parámetros a usar en un modelo de proyección

3.2 Objetivos específicos

- Definir cuáles son los indicadores más aplicables, entendibles, que se relacionen que puedan ser usados en la industria.
- Encontrar los parámetros de los modelos suavización exponencial simple y del modelo de suavización exponencial de Holt que optimicen los indicadores MAPE, MAD y MSE, que permitan determinar similitudes entre ellos.
- Aplicar herramientas estadísticas para pronósticos de demanda y medición de errores, con el fin de proponer un parámetro definido mediante ponderación de indicadores que permita tomar mejores decisiones en el proceso de pronósticos de demanda, tomando como base específicamente el modelo de suavización exponencial.
- Determinar a través de una encuesta a expertos en el tema de pronósticos de demanda la ponderación para cada uno de los indicadores que serán la base para la definición del nuevo parámetro.
- Comparar por medio de medición de errores, el comportamiento del modelo de suavización exponencial utilizando el parámetro propuesto versus el parámetro obtenido al minimizar el MAPE con el fin de demostrar su aplicabilidad y efectividad en diferentes series de datos con características y patrones de comportamiento diferentes.

4. MODELOS DE PREDICCIÓN E INDICADORES DE EXACTITUD DE LOS MODELOS DE PRONOSTICO

La principal variable que afecta el proceso de planeación de producción en una compañía es la demanda, ya que esta a su vez puede depender de una gran cantidad de variables que hacen que los modelos utilizados para su predicción no generen datos con total exactitud. Adicional a esto, las variables que afectan la demanda generalmente presentan un comportamiento aleatorio, lo que hace que regularmente exista una desviación entre la demanda real vs la demanda proyectada.

La predicción de la demanda es un problema que las organizaciones enfrentan desde hace muchísimos años, para lo cual tanto académicos como los encargados de realizar las estimaciones de demanda en las empresas han buscado dar solución a través del uso de múltiples modelos y técnicas. A continuación, se hace una breve descripción de los modelos más comúnmente utilizados

4.1 Modelos de predicción

La predicción de la demanda consiste en estimar las ventas de un producto o servicio durante un determinado periodo de tiempo que puede ser corto, mediano y largo plazo. Los datos obtenidos en la estimación son útiles para planificar la producción, inventarios y los recursos necesarios para que el producto o servicio sea entregado al cliente final.

A pesar de que la tecnología ha permitido que la predicción de la demanda sea más eficaz, sigue siendo un concepto ambiguo. Así, para comprender la evolución y metodología de la predicción de la demanda, los modelos de predicción de demanda se pueden clasificar de acuerdo con su utilidad en dos grandes grupos: modelos cualitativos y cuantitativos.

Los modelos de *proyección cualitativos* son los más utilizados para el caso de proyecciones a largo plazo, pero en algunas ocasiones estos modelos se convierten en la única opción de pronóstico debido a la falta de información histórica, caso de productos completamente nuevos o con poca información histórica. En la Figura 1 se presentan algunos de los métodos utilizados para proyecciones de demandas mediante este enfoque.

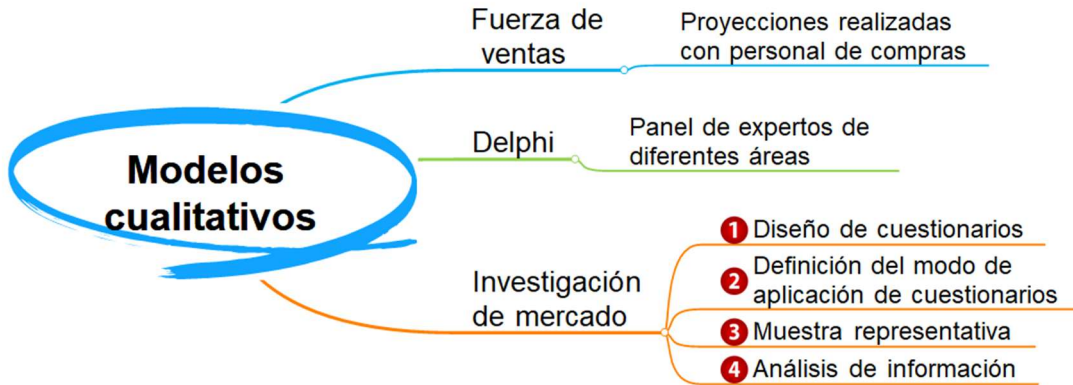


Figura 1. Modelos de pronóstico cualitativos

Los modelos de *proyección cuantitativos* son los usados comúnmente en las empresas, debido a que la mayoría tienen registros históricos de sus demandas o de sus ventas. Este registro histórico, normalmente puede ser ordenado cronológicamente, pudiendo presentar algún tipo de patrón de comportamiento de los datos. En caso de evidenciarse algún patrón de comportamiento regular, ya sea estable, de tendencia o de estacionalidad, es posible realizar ajustes por medio de algún modelo, de los denominados modelos de series de tiempo debido al comportamiento cronológico de los datos. Por otra parte, si no se evidencia un patrón de comportamiento regular, en la serie de datos histórica, es posible buscar correlaciones y causalidades entre la demanda y una o varias variables diferentes de tiempo, mediante el uso de modelos de tipo causal. La Figura 2 muestra una síntesis de este tipo de modelos de proyección.

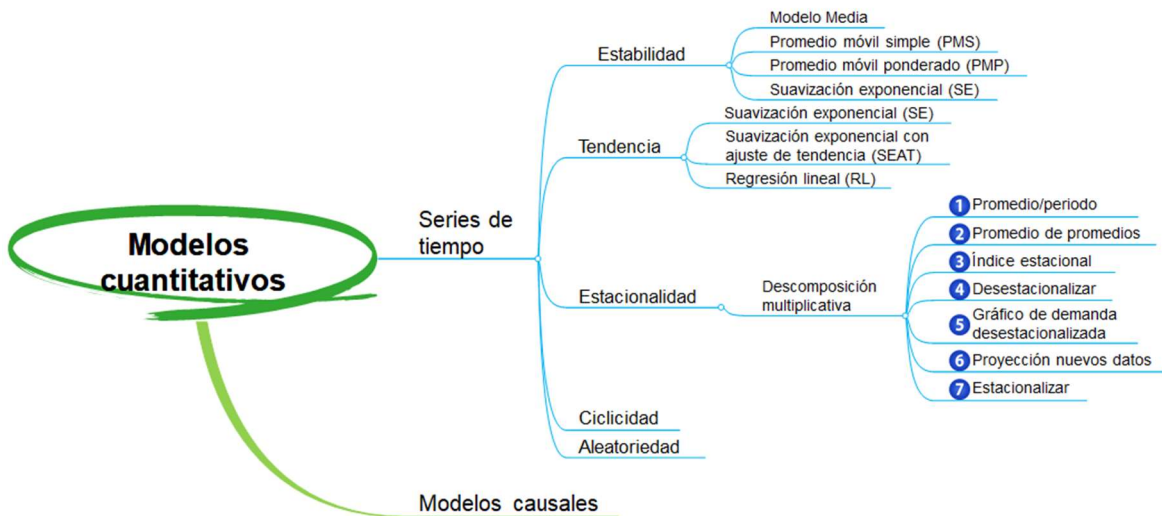


Figura 2. Modelos de pronóstico cuantitativos

La selección del modelo de predicción dependerá en mayor parte de las características de los datos, de la experiencia del pronosticador y en mayor parte de los errores o exactitud del modelo de pronóstico. A continuación, se hace una breve introducción a los indicadores de

exactitud de los pronósticos usados en la industria, los cuales se discutirán nuevamente en mayor detalle en el apartado 4.2.2

4.2 Indicadores de exactitud de los modelos de pronósticos

Tanto a nivel académico, como práctico, existen una gran cantidad de indicadores que tratan de medir el desempeño de los modelos de pronósticos, siempre buscando obtener un modelo y sus parámetros que logren estimar de manera más próxima la demanda, tanto histórica como futura, es decir que tengan menores errores. Aunque los indicadores que se utilizan en la academia como en la práctica tienen los mismos propósitos, no todos los propuestos desde el punto de vista académico tienen una interpretación fácil y uso desde el punto de vista práctico. A continuación, se hace una breve descripción de algunos indicadores utilizados por ambos tipos de usuarios.

4.2.1 Indicadores académicos para la medición de exactitud de los errores de pronósticos

El objetivo principal al momento de seleccionar y aplicar un modelo de proyección es obtener los mínimos valores de desviación o errores de la proyección. La desviación o error de un pronóstico, puede ser calculada con múltiples medidas de desempeño, algunas de las cuales se muestran en la Figura 3.

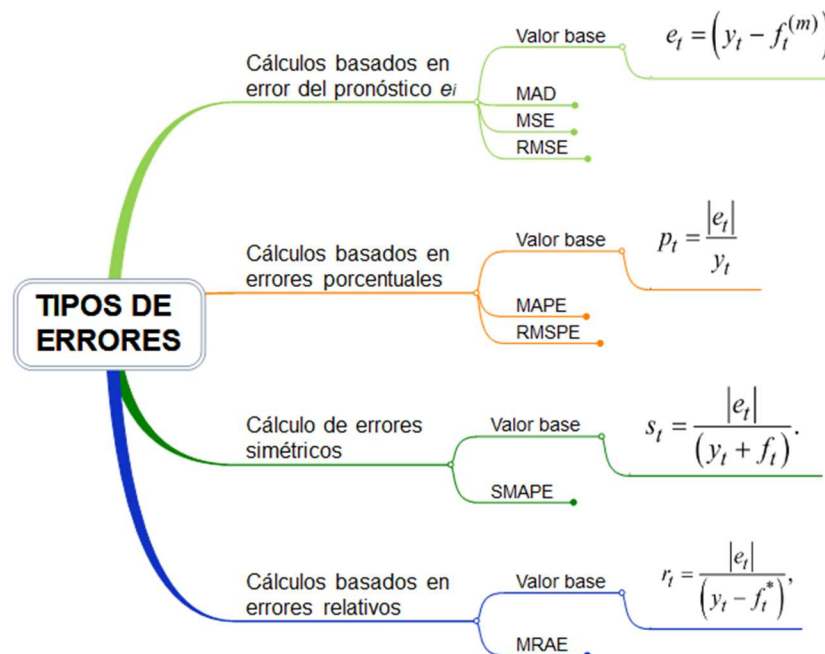


Figura 3. Clasificación de errores de pronósticos

Las proyecciones de demanda, realizadas a través de cualquier modelo de pronósticos, deben ser evaluadas con el fin de seleccionar inicialmente los parámetros y posteriormente aquel modelo que mejor estime la información histórica disponible, es decir, seleccionar el mejor pronóstico. Para lo anterior será necesario medir el desempeño de cada uno de los modelos evaluados mediante indicadores de exactitud. Esta evaluación y selección no resulta tan simple como podría parecer ya que, a pesar de que existen diferentes herramientas para medir o evaluar la exactitud de los pronósticos, no son siempre tan simples de interpretar lo que dificulta en primer lugar la selección de los parámetros más adecuados de un modelo, seguido de la determinación del mejor modelo a utilizar según los resultados obtenidos.

4.2.2 Otros indicadores académicos encontrados en la literatura

A pesar de los ya mencionados modelos de pronósticos propuestos para diferentes tipos de patrones en la demanda, diferentes autores han propuestos modelos o metodologías adicionales para realizar proyecciones [1]–[2] y para mejorar la forma de cálculo de errores en proyecciones [3]–[4]. Estos nuevos modelos comprenden variables que no se habían llegado a considerar, mejorando notablemente los errores encontrados. Uno de estos errores es el modificado SMAPE propuesto por Mathai et al. [4] y el modificado MAPE propuesto por los mismos autores.

El Error porcentual absoluto simétrico (SMAPE, por sus siglas en inglés Symmetric Mean Absolute Porcentaje Error), es calculado a partir de la expresión inicial mostrada en la ecuación (1), y puede ser calculado finalmente a partir de la expresión mostrada en la ecuación (2).

$$s_t = \frac{|e_t|}{y_t + f_t} \quad (1)$$

$$sMAPE = \frac{\sum_{i=1}^n |s_i|}{n} \quad (2)$$

Sin embargo, algunos autores aseguran que los errores MAD y MAPE pueden llevar a selecciones inadecuadas de parámetros y modelos de pronósticos debido a que se podrían generar proyecciones inapropiadas para un caso específico de demandas como son las intermitentes [5], [6].

En el indicador RMAPE propuesto por los autores Montaña et al. [7] proponen un nuevo planteamiento para el cálculo del error MAPE. El R-MAPE o MAPE Resistente, propone un índice alternativo, utilizando los resultados derivados de la aplicación de modelos de

Red Neuronal Artificial (ANN) y modelos Autorregresivos Integrados de Media Móvil (ARIMA) en la previsión de una serie temporal, lo cual permite superar la limitación que presenta el MAPE en cuanto a la distribución de errores porcentuales absolutos proporcionando una sobre estimación del correspondiente parámetro poblacional. Los autores concluyen que los resultados ponen de manifiesto que el R-MAPE representa una adecuada alternativa en la medición del ajuste en la previsión, debido a que proporciona una evaluación válida de dicho ajuste en comparación al MAPE.

Por otro lado, partiendo de la demostración que ciertas métricas para la medición de errores comunes como el MAE y MAPE pueden conducir fácilmente a la selección de métodos de pronósticos inadecuados cuando las demandas son intermitentes (las demandas intermitentes son un caso especial de distribuciones asimétricas (sesgadas), se propone el BMAE como otro indicador para el cálculo de los errores para modelos de proyecciones de demanda. [8]. El estudio concluye que el BMAE puede servir como la métrica para la medición de errores mas valida y apropiada para cualquier distribución de demandas, simétricas o asimétricas.

Finalmente, de acuerdo con Vladimirovich et al. [9], es recomendable a la hora de seleccionar un modelo de pronóstico o un modelo para el cálculo de los errores, tener en cuenta algunas consideraciones como las siguientes [9];

- ✓ Si los modelos de pronósticos son con series de tiempo, las escalas temporales son las mismas, entonces es razonable utilizar los errores MAD o RMSE.
- ✓ A pesar de que los errores porcentuales son ampliamente utilizados en la industria, no son recomendables debido a su carácter no simétrico. Es así como los indicadores MAD y MAPE pueden llevar a selecciones inadecuadas de modelos de pronósticos debido a que se podrían generar proyecciones inapropiadas para un caso específico de demandas como son las intermitentes.
- ✓ Si los datos contienen valores atípicos, es recomendable aplicar las medidas de error escalados. En este caso el horizonte debe ser lo suficientemente grande, no deben ser valores idénticos, el factor normalizado no debe ser igual a cero.
- ✓ Si los datos tienen patrones estacionales o cíclicos, es recomendable utilizar las medidas de error normalizadas, en donde los factores de normalización podrían calcularse dentro del intervalo igual al ciclo o la estación.
- ✓ Si no hay resultados de análisis previos e información previa sobre la calidad de los datos, es razonable utilizar el conjunto definido de medidas de error, acompañado de un cuidadoso análisis de los resultados.

Un planteamiento interesante que presentan los autores Gilliland y Sglavo [10], es acerca de los errores que normalmente se cometen a la hora de realizar pronósticos. Aquellas razones que los autores mencionan son básicamente tratar de realizar procesos de pronóstico demasiado complejos y politizados, incorporando al proceso algunas etapas ineficientes o que no aportan ningún tipo de valor y que no generan una mejora en el resultado final. Otra razón es la selección del modelo de pronóstico solamente tratando de ajustarlo a los datos históricos y, aunque puede funcionar, lo que se quiere es pronosticar el

comportamiento del futuro. A su vez, la suposición de que el error del modelo se ajuste a los datos históricos será el mismo error en los pronósticos, puede generar complicaciones cuando las desviaciones sean mucho mayores. Por su parte, tratar de perseguir niveles inalcanzables de precisión en los pronósticos y consumir recursos enfocados en este objetivo no es recomendable a la hora de generar proyecciones. Finalmente, definir objetivos inalcanzables por parte de la compañía y considerar datos de pronósticos para productos nuevos a partir de juicios de expertos en la empresa normalmente no funcionan adecuadamente.

En conclusión, los pronósticos de demanda son y serán una actividad con una alta carga de incertidumbre, debido a la inherente suposición de continuidad de la información histórica. Actualmente se puede tener una medida de la precisión para cada uno de los modelos utilizados, lo cual, como se mencionó anteriormente, no garantiza la misma precisión hacia el futuro. Lo que se intenta hacer en el presente trabajo de investigación es profundizar en el conocimiento de cada una de las medidas de error de las que se dispone y comprender las diferencias fundamentales entre cada una de ellas para tener una base sólida de decisión de modelos. Por ahora no queda otra opción diferente a trabajar sobre el supuesto de que lo que ha sucedido en el pasado sucederá en el futuro, y realizar un plan de seguimiento periódico riguroso a los resultados proyectados periodo a periodo.

4.2.3 Modelos prácticos para la medición de exactitud de los errores de pronósticos

Desde el punto de vista práctico, los indicadores deben servir como información vital que ayuda al tomador de decisiones a medir, evaluar y seleccionar qué modelo y parámetros utilizar para una serie de datos determinada.

Es por esto último que se realiza una clasificación de las medidas de desempeño de un pronóstico, de acuerdo con su aplicabilidad, las cuales podrían segmentarse en tres grandes grupos:

1. Medidas de selección:

Este tipo de medidas son adecuadas para la selección de los parámetros de un modelo y del modelo de pronóstico que se ajuste de buena manera a los datos históricos con el menor error. En las medidas de selección es importante considerar características de la información como el horizonte de tiempo de los datos históricos y variables logísticas entre otras.

2. Medidas de interpretación:

Son las medidas utilizadas para conocer los sesgos positivos o negativos del pronóstico. Son las medidas que permiten identificar si el pronóstico está subestimado o sobreestimado. Cuando tenemos un pronóstico sobreestimado se puede genera un exceso de inventario, sobre costo por manejo de materiales, rechazo por obsolescencia. Cuando se tiene un pronóstico subestimado se incurre en reducción de niveles de servicio, pérdida de ventas e imagen.

3. Medidas de precisión y validación:

Son las medidas usadas para probar qué tan efectivo fue el modelo o los modelos seleccionados para realizar los pronósticos. Consiste en medir y comparar los valores pronosticados versus el valor obtenido con la demanda real.

A continuación, se muestra una breve descripción de algunos de los indicadores utilizados en las empresas.

4.2.3.1 Definición para indicadores prácticos para la medición de exactitud de los errores de pronósticos

- MSE: El error cuadrado medido (MSE, por sus siglas en inglés Mean Squared Error), se calcula mediante la ecuación (3) presentada a continuación.
-

$$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (3)$$

En este error, los errores de los periodos son potenciados a través del cálculo de los cuadrados, castigando de mayor manera las dispersiones altas de los datos. Al igual que en el error MAD, entre más pequeño sea este valor del MSE mayor será la precisión de los modelos de pronósticos.

- **MAD:** La desviación absoluta media (MAD, por sus siglas en inglés Mean Absolute Deviation), y puede calcularse a través de la ecuación (4), presentada a continuación:

$$MAD = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (4)$$

En donde $|e_i|$ representa el error absoluto calculado para el periodo i , y n representa el número total de errores. Este error indica la dispersión de los datos observados con los calculados, por tal motivo, a menor error mejor será la precisión del modelo de pronóstico.

- **RMSE:** La raíz cuadrada del error cuadrado medio o la desviación estándar poblacional (RMSE, por sus siglas en inglés Root Mean Square Error), es una de las medidas más usadas en la estadística descriptiva. Esta medida es una variación del error, en el cual se calcula una raíz cuadrada adicional la cual reduce la severidad de las dispersiones entre datos observados y calculados. Puede ser calculado mediante la ecuación (5).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (5)$$

Este error al igual que todos los anteriormente descritos, entre más pequeño su valor denota una mayor precisión del modelo de pronóstico empleado.

- **MAPE:** el error porcentual absoluto medio (MAPE, por sus siglas en inglés Mean Absolute Percentage Error) es calculado a partir del porcentaje de desviación entre dato obtenido y el calculado de cada periodo según se muestra en la ecuación (6). Teniendo el error porcentual, el MAPE se calcula con la ecuación (7).

$$p_t = \frac{|e_t|}{y_t} \quad (6)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n 100 * |p_i| \quad (7)$$

En donde e_t , y_t y p_t representan el error en el tiempo t , el dato histórico del pronóstico en el tiempo t y el porcentaje del error en el tiempo t . De la misma forma de los errores anteriores, entre menor sea este error mejor desempeño podría tener el modelo de pronóstico utilizado.

- **ME:** El error medio representa la relación que existe entre la sumatoria de los errores del pronóstico obtenidos en cada periodo y el número total de errores. Representa en promedio el error obtenido en cada periodo y se espera que tienda a “cero”. se calcula con la ecuación (8).

(8)

$$ME = \frac{\sum_{i=1}^n e_i}{n}$$

- **INTERSECCIONES CON CERO:** Indica el porcentaje de veces que la señal de rastreo pasa por cero con relación al número total de periodos utilizados. Es un indicador que se obtiene del gráfico de las SR (señales de rastreo) el cual busca identificar la cantidad de veces que el error acumulado pasa de valores positivos a negativos y viceversa. Se busca que este indicador sea lo más alto posible, lo cual muestra un mayor equilibrio entre los errores positivos y negativos, lo cual es un comportamiento deseado en un modelo de proyección. Este indicador se obtiene contando las veces que la señal de rastreo pase por cero.
- **FA:** La precisión del pronóstico (FA, por las siglas en ingles Forecast Accuracy) es un indicador de precisión que consiste en comparar los resultados del pronóstico contra los valores reales y obtener un resultado porcentual en función de la desviación de los datos. El objetivo de esta medición es encontrar valores cercanos al 100% para emitir juicios favorables sobre el modelo de pronóstico seleccionado. Este indicador se puede utilizar para medir la precisión por periodos, y su facilidad de aplicación permite que la precisión sea medida en horizontes de tiempo cortos, semanas e incluso días lo cual permitirá al pronosticador tomar decisiones rápidas con respecto a la demanda, si la operación de la empresa así lo permite.

La precisión de un pronóstico puede ser calculada mediante la ecuación (9):

$$FA = 100\% - EA(\%) \quad (9)$$

En donde *EA* representa el error absoluto expresado en unidades porcentuales, calculado según la ecuación (10).

$$EA = \frac{|ventas - pronósticos|}{ventas} * 100\% \quad (10)$$

Por lo tanto, la precisión de los pronósticos, pueden entonces arrojar valores entre 0 y 100%, tal y como se puede observar en la ecuación (11).

$$FA = \text{Máximo}(0\%, (100 - EA)) \quad (11)$$

De acuerdo con la anterior ecuación, la precisión del pronóstico podría presentar tres situaciones específicas:

1. La precisión del pronóstico puede ser cero (0%), en el caso en el que el error absoluto calculado con la ecuación **¡Error! No se encuentra el origen de la referencia.** de como resultado un porcentaje mayor al 100% o un valor menor que cero (0%).

2. La precisión del pronóstico puede ser del 100%, en el caso en el que el error absoluto de como resultado un valor igual al 100%.
3. La precisión del pronóstico puede estar entre 0% y 100%, para el caso en el que el error absoluto presente un valor entre este mismo rango.

Según Rodolfo Torres-Rabello [11] menciona que “Si hubiera que coronar un rey de los KPI sería la precisión de los pronósticos de demanda. Mientras más cerca el pronóstico esté de la realidad, más se podrán evitar sobrestocks, quiebres de stock, pérdidas de venta y costos logísticos en exceso, entre otros efectos”. Situación que podemos ver gráficamente en la **¡Error! No se encuentra el origen de la referencia..**

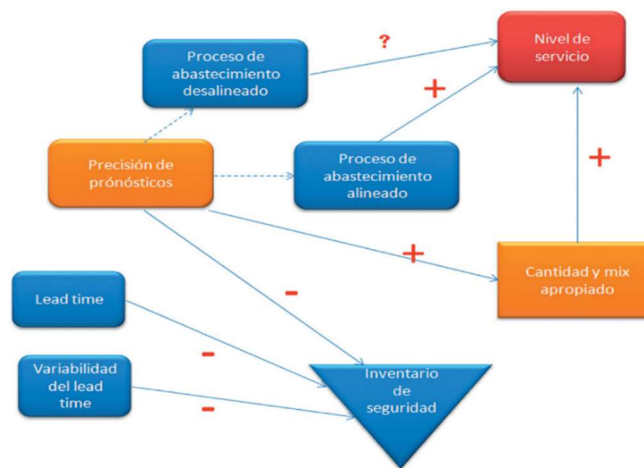


Figura 4. Influencia de los pronósticos en los inventarios y en el nivel de servicio [11]

Algunos autores [12] recomiendan hacer una separación de estas medidas de desempeño, debido a la aplicabilidad de estos errores mostrados.

Finalmente, las anteriores medidas de errores de pronósticos se pueden clasificar por su aplicabilidad de la siguiente manera:

Indicador	Medidas de selección	Medidas de interpretación	Medidas de precisión / validación
MSE	X		
MAD	X	X	
RMSE	X	X	

MAPE	X	X	X
ME	X	X	
V. x Cero	X	X	
FA			X

Tabla 1. Clasificación de errores de pronósticos según tipo de medida

En la anterior tabla no se incluyen todos los indicadores para medición de errores de pronósticos existentes, pero si algunos de los más significativos, debido en primer lugar a que a nivel práctico algunas de ellas son ampliamente usadas en las empresas y en segundo lugar son de más fácil interpretación.

Es claro que, a nivel empresarial, el principal objetivo de un modelo de pronósticos y de los parámetros asociados a dicho modelo, es lograr obtener los menores errores posibles, para lo cual se utilizan indicadores como el MSE, MAD, RMSE y el MAPE los cuales miden las magnitudes del error en términos de cantidad o porcentaje. Pero adicionalmente es importante medir que los pronósticos que arroja este modelo y sus parámetros logren en el tiempo balancear los errores positivos y negativos, para lo cual se mide el ME, entendiendo que los pronósticos de cualquier modelo de proyección siempre tendrán un error. Finalmente, es importante buscar que el modelo no haga sobreestimaciones o subestimaciones de manera consistente o repetida durante muchos periodos, para lo cual se debe medir el número de V* Cero.

Como se observa, el comportamiento ideal de un modelo de proyección debe ir más allá de solo buscar disminuir el error en un periodo. Un modelo de proyección y sus parámetros se deben seleccionar de tal forma que se logre un equilibrio entre las magnitudes de los errores, los valores y frecuencias de la sobre y subestimación de los errores de los pronósticos que el modelo de estimación arroja en el tiempo.

Es por lo anterior que este proyecto busca proporcionar una forma para determinar parámetros de los modelos a partir de una expresión que agrupe los tres valores anteriormente mencionados, de tal forma que se pueda obtener un comportamiento del modelo de proyección más cercano al ideal esperado.

5. VERIFICACIÓN Y VALIDACIÓN DEL PARAMETRO DEFINIDO MEDIANTE PONDERACIÓN DE INDICADORES PROPUESTO

Encontrar la forma acertada y práctica de determinar el modelo y parámetros de proyección de demanda se hace cada vez más importante para las empresas. El reto consiste en lograr la disponibilidad de los productos y/o servicios cuando lo requiere el mercado. Es por esto que elaborar un pronóstico de demanda más acertado garantizará una eficiencia de todas las áreas de la empresa. Pronosticar la demanda con buena exactitud normalmente no es fácil. No existen recetas de cómo hacerlo y cada empresa tiene que determinar cómo mejorar este proceso.

Con este trabajo como se mencionó anteriormente se busca encontrar una alternativa que permita de forma práctica seleccionar parámetros de modelos relacionando varios indicadores significativos de desempeño.

Para la realización de pruebas se seleccionaron series de datos de las observaciones realizadas por M3-competition-International Institute of Forecasters, los cuales fueron sometidos a los siguientes pasos, como se muestra en la Figura 5.

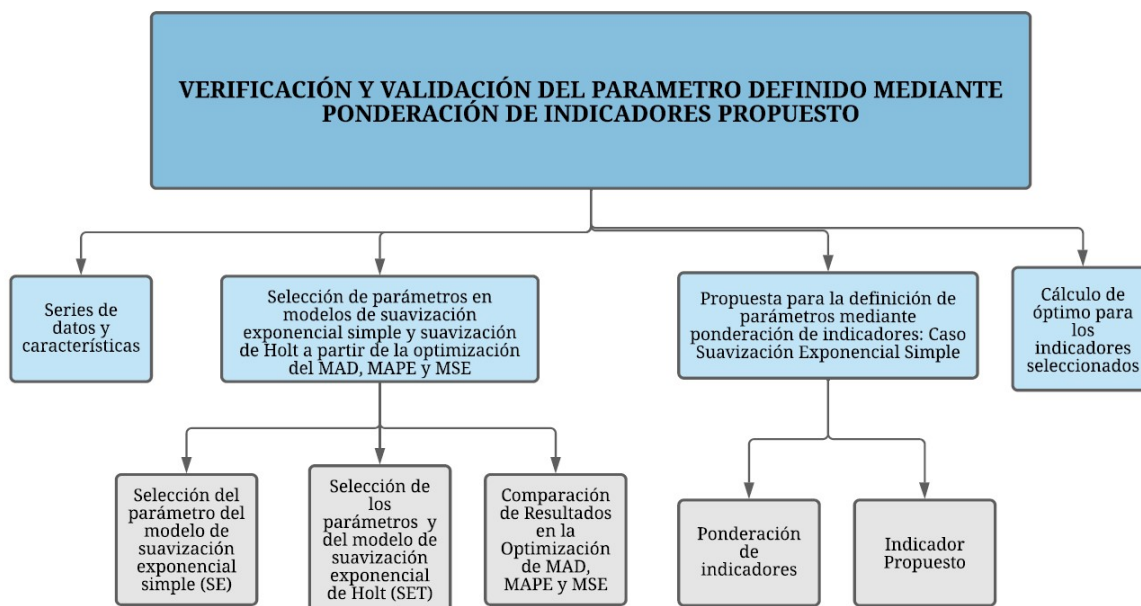


Figura 5. Pasos para definición de parámetro mediante la ponderación de indicadores

Los pasos propuestos en la Figura 5 se detallan en el capítulo 5 de este trabajo. Los cálculos, comparaciones y demás información no mostrada en este capítulo podrá ser revisada en los Anexos 6 y 7 (Anexo 6: Hoja de Cálculo con Datos iniciales; Anexo 7: Hoja de Cálculo Datos propuesta).

5.1 Series de datos y características

Para la parte experimental se seleccionaron de forma aleatoria 20 series de datos de la Plataforma <https://forecasters.org/resources/time-series-data/m3-competition/>. Como recomendación de M3-Competition - International Institute of Forecasters, las últimas 6 observaciones de cada serie no se deben utilizar para seleccionar parámetros y/o modelos con base en los pronósticos históricos obtenidos, sino que deben ser usadas para evaluar la precisión del pronóstico. Adicionalmente en este trabajo estas observaciones se usaron para evaluar el comportamiento del indicador propuesto. La Tabla 2 muestra un resumen de las series utilizadas y algunas de sus características.

Estos cálculos pueden ser vistos en el Anexo 6. Hoja de Cálculo con Datos iniciales.

Serie	Nº De Observaciones	Promedio	Desviación	Coefficiente de Variación	Coefficiente de Correlación
N1875	126	3296.0	876.9	0.27	-0.32
N1683	126	3790.7	502.4	0.13	0.30
N2480	66	6977.3	5448.7	0.78	-0.76
N2640	69	6085.5	2691.6	0.44	-0.71
N1413	68	5077.9	4857.7	0.96	-0.08
N1429	69	4137.7	1442.1	0.35	-0.69
N1691	126	3214.9	1579.3	0.49	-0.29
N1408	68	3229.4	1384.1	0.43	0.42
N1697	126	2157.8	1477.1	0.68	-0.69
N1695	126	3423.0	2526.3	0.74	-0.82
N1406	68	6217.0	3219.9	0.52	0.60
N1442	69	5671.0	1466.5	0.26	-0.07
N1707	126	3985.7	2080.9	0.52	-0.69
N1419	68	2191.8	877.3	0.40	0.34
N1422	69	6085.5	2691.6	0.44	-0.70
N1778	126	3671.3	502.7	0.14	-0.76
N1405	68	3666.5	2751.7	0.75	0.78
N1559	69	4176.8	1250.2	0.30	0.92
N1490	69	2796.5	886.9	0.32	-0.67
N1594	69	7671.1	824.4	0.11	0.01

Tabla 2. Series de M3-Competition y sus características utilizadas en la investigación

Así por ejemplo de acuerdo con la Tabla 2, la serie N1875 tiene en total 126 observaciones de las cuales 120 serán usadas para determinar los parámetros de los modelos de pronósticos y mediciones de errores y las otras 6 observaciones serán usadas para evaluar el comportamiento. Así mismo, la anterior tabla muestra los resultados de estadísticos importantes de cada serie como son: el promedio, la desviación estándar muestral, el coeficiente de variación (CV) y coeficiente de correlación (CC), esto con el fin de obtener algunas características propias de las series utilizadas

De las series seleccionadas se logra observar que el 65% (13 series) presentan un coeficiente de variación por debajo de 0,5 valor que de acuerdo a Silver, pueden considerarse series con baja variabilidad [13] es decir con un patrón de comportamiento aproximadamente estable. El restante 35% de series tiene coeficientes de variación superiores al 0,5, valores correspondientes a series que puedan tener un patrón de comportamiento de tendencia o estacional, o en su defecto a demandas erráticas.

Con relación a los coeficientes de correlación se puede observar que 5 de las 20 series analizadas tienen valores iguales o superiores a 0,75 o inferiores a -0,75, lo cual indica que posiblemente exista un patrón de tendencia positiva o negativa en la serie de datos.

Se puede observar entonces que, de las 20 series seleccionadas, se encuentran series como la N2480, N1695 y N1405 donde los coeficientes de variación y coeficientes de correlación no están dentro de los límites normales es decir los datos no tienen un comportamiento estable, sino que hay apreciable grado de tendencia y variabilidad, como se observa en las Figuras 5a, 5b y 5c.




Figura 5a. Gráfico de demanda de la serie N2480




Figura 5b. Gráfico de demanda de la serie N1695




Figura 5c. Gráfico de demanda de la serie N1405

Se observa entonces que las series seleccionadas tienen diferentes características y patrones, mostrando la heterogeneidad de los datos en las series utilizadas. Una característica importante de resaltar es que ninguna de las series seleccionadas tiene datos intermitentes, es decir en cada periodo los valores de demanda son mayores a cero, buscando que los indicadores utilizados no presenten algún tipo de problema de análisis como lo expuesto en el apartado 4.2.2.

Si es necesaria la ampliación de la información, Estos cálculos pueden ser vistos en el Anexo 6: Hoja de Cálculo con Datos iniciales

5.2 Selección de parámetros en modelos de suavización exponencial simple y suavización de Holt a partir de la optimización del MAD, MAPE y MSE

Una de las propuestas más utilizadas para seleccionar modelos de proyección y sus parámetros es mediante la optimización de alguno de los indicadores de magnitud mostrados en la Tabla 1. [14]

Con el fin de mostrar si existe alguna relación al minimizar los indicadores MAPE, MAD y MSE, se obtuvieron los parámetros óptimos de los modelos de suavización exponencial simple (parámetro α) y del modelo de suavización del Holt (α y β). La optimización se realizó utilizando SOLVER de EXCEL® en la herramienta FOR TSM [16] para cada una de las series 20 series mostradas en el Tabla 2

5.2.1 Selección del parámetro α del modelo de suavización exponencial simple (SE)

El modelo de Suavización Exponencial simple tiene el parámetro alfa (α), conocido como coeficiente de suavización, el cual puede modificar la importancia que se le da a los datos históricos más actuales con el fin de que el pronóstico capture cambios en el comportamiento de la demanda. Los pronósticos de este modelo se calculan por medio de la ecuación (12).

$$F_t = \alpha D_{t-1} + (1 - \alpha)F_{t-1} \quad (12)$$

En donde el parámetro α es el parámetro de suavización, el cual puede tomar valores entre 0 y 1, y representa el peso asignado a los datos más recientes. Un aspecto importante en el modelo de suavización exponencial es que deben asignarse valores iniciales o valores semillas para poder iniciar a obtener los datos pronosticados. Como puede observarse en la ecuación **¡Error! No se encuentra el origen de la referencia.**, el término D_{t-1} representa la demanda del periodo anterior, y el término F_{t-1} representa el pronóstico del periodo anterior, el cual no se tiene en la información inicial. Es por esta razón que para el pronóstico del periodo dos, se asigna normalmente el valor de la demanda del periodo uno, y a partir del periodo tres el modelo matemático se aplica normalmente.

El modelo de suavización exponencial es uno de los modelos de pronósticos más utilizados debido a su simplicidad, lo que facilita su aplicación por parte de los empleados y porque ha mostrado grandes aciertos para datos con comportamiento estable.

Los valores del parámetro α que se obtuvieron al minimizar los indicadores MAD, MAPE y MSE para cada una de las 20 series, se muestran en la Tabla 3.

Serie	INDICADOR		
	MAD	MAPE	MSE
	α	α	α
N1875	0.137	0.138	0.121
N1683	0.116	0.112	0.575
N2480	0.279	0.407	0.203
N2640	0.377	0.487	0.226
N1413	0.019	0.001	0.096
N1429	0.328	0.34	0.227
N1691	0.803	0.852	0.814
N1408	0.204	0.043	0.154
N1697	0.378	0.49	0.371
N1695	0.391	0.375	0.375
N1406	0.117	0.056	0.174
N1442	0.162	0.205	0.275
N1707	0.356	0.473	0.266
N1419	0.107	0.067	0.156
N1422	0.377	0.487	0.226
N1778	0.378	0.378	0.368
N1405	0.216	0.056	0.252
N1559	0.314	0.257	0.318
N1490	0.287	0.322	0.287
N1594	0.227	0.245	0.246

Tabla 3: Valores óptimos de α del modelo de suavización exponencial simple

Como se observa en la anterior tabla, solo las series resaltadas, (6 series, las cuales representan el 30% de la muestra) presentan diferencias significativas en el parámetro de al menos una medida de desempeño. Las restantes series (70%) muestran parámetros muy similares entre ellas. Lo anterior permite concluir a priori, que sin importar el indicador que se desea minimizar, los valores del parámetro α se encuentran en la vecindad de valor óptimo de los indicadores MAD, MAPE y MSE, por lo que, para un alto porcentaje de las series de una muestra, bastaría con tener que utilizar solo uno de estos indicadores para seleccionar el parámetro del modelo, así como medir la exactitud del modelo de proyección. Para las demás series, aunque el valor del alpha en algunos casos sean muy diferentes, las variaciones porcentuales de los indicadores al usar por ejemplo el valor de alpha que optimizar MAPE versus los otros dos indicadores en la mayoría de los casos no en mayor a un 10%. Cabe resaltar que, en unas pocas series, las variaciones pueden ser superiores al 20%, aunque dichas variaciones específicamente se encontraron en las series con mayores coeficientes de variación con la N1413 (CV = 0.96) y N1405 (CV=0.75),

mostrando que puede llegar a existir algún tipo de correlación, entre las variaciones descritas y el coeficiente de variación que tengan los datos de una serie.

5.2.2 Selección de los parámetros α y β del modelo de suavización exponencial de Holt

El modelo de suavización de Holt es un modelo en el cual se le incorpora un parámetro adicional de corrección al modelo original de suavización exponencial simple, y lo convierte en un modelo adecuado para el análisis de demandas con tendencia. Este modelo, al igual que el original, conserva el parámetro α el cual representa la importancia que se le quieren dar a los datos más actuales. Este modelo incorpora el parámetro adicional β , el cual representa el coeficiente de suavización de la tendencia, y al igual que α , toma valores entre 0 y 1. Este modelo puede ser aplicado según la ecuación (13).

$$F_t = S_t + T_t \quad (13)$$

En donde, S_t representan el valor proyectado con el modelo original de suavización exponencial simple, y T_t el valor para el ajuste de la tendencia según los datos de la demanda, respectivamente, que pueden ser calculados mediante las ecuaciones (14) y (15).

$$S_t = \alpha D_{t-1} + (1 - \alpha)(S_{t-1} - T_{t-1}) \quad (14)$$

$$T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1} \quad (15)$$

Es importante resaltar que los parámetros α y β son similares en todas las características, por lo que presentan el mismo impacto en los resultados de los pronósticos. Tal y como se mencionó para el modelo de suavización exponencial simple, a cerca de la iniciación del parámetro α , en este nuevo modelo, es necesario también inicializar con un valor semilla el parámetro β , el cual normalmente puede ser iniciado con un valor de cero. Lo anterior es coherente con la lógica del modelo, ya que corrige a medida que se presenten variaciones entre el pronóstico y el dato histórico, pero para el primer dato pronosticado no se tiene aún información de desviación del pronóstico, y es por esta razón que no puede ser inicializado en cero, ya que no se tienen desviaciones acumuladas.

Los valores óptimos obtenidos de los parámetros de α y β para el modelo de suavización exponencial de Holt para las 20 series, que minimizan los indicadores MAD, MAPE y MSE, se muestran en la Tabla 4.

Serie	MAD		MAPE		MSE	
	α	β	α	β	α	β
N1875	0.137	0.000	0.138	0.000	0.121	0.000
N1683	0.116	0.000	0.112	0.000	0.575	0.000
N2480	0.031	0.694	0.019	1.000	0.027	1.000
N2640	0.052	0.118	0.419	0.036	0.068	0.109
N1413	0.010	0.022	0.001	0.000	0.096	0.000
N1429	0.040	0.389	0.035	0.390	0.047	0.390
N1691	0.803	0.000	0.851	0.003	0.814	0.000
N1408	0.204	0.000	0.043	0.000	0.109	0.022
N1697	0.369	0.011	0.281	0.039	0.371	0.000
N1695	0.401	0.010	0.374	0.000	0.374	0.000
N1406	0.037	0.080	0.024	0.063	0.111	0.037
N1442	0.162	0.000	0.200	0.002	0.275	0.000
N1707	0.187	0.045	0.020	0.212	0.226	0.012
N1419	0.085	0.059	0.067	0.000	0.123	0.019
N1422	0.052	0.118	0.419	0.036	0.068	0.109
N1778	0.336	0.014	0.334	0.014	0.368	0.000
N1405	0.017	0.274	0.010	0.273	0.104	0.083
N1559	0.173	0.080	0.175	0.076	0.094	0.362
N1490	0.112	0.147	0.079	0.190	0.252	0.016
N1594	0.184	0.013	0.180	0.016	0.246	0.000

Tabla 4: Valores óptimos de α y β del modelo de suavización exponencial de Holt.

Como se observa en la Tabla 4, el 35% de las series (correspondientes a las 7 resaltadas en la tabla) muestran diferencias significativas en los parámetros de al menos una medida de desempeño. Las restantes series (que corresponden al 65% del total) muestran parámetros muy similares entre ellas. Se puede concluir nuevamente al igual que para la selección del parámetro α en el modelo SE, que los valores óptimos de los parámetros α y β en el modelo de Holt al minimizar los indicadores MAD, MAPE y MSE son similares entre ellos. Lo anterior nuevamente muestra la posibilidad de utilizar cualquiera de los tres indicadores, para seleccionar o medir de los errores al obtener valores de los parámetros muy cercanos a los valores óptimos. Nuevamente se observa que las variaciones porcentuales superiores al 20% en aquellos casos en los que se usa el valor de alpha que minimiza el valor del indicador MAPE en lugar de los valores de alpha que minimizan MSE o el MAD, pero solo en algunas series cuando los CV son superiores al 0,7, mostrando que puede existir alguna correlación entre las variaciones porcentuales y la variabilidad que tengan los datos de una serie.

5.2.3 Comparación de Resultados en la Optimización de MAD, MAPE y MSE

Finalmente, con el objetivo de mostrar que existe alguna relación entre los indicadores MAPE, MAD, MSE, y poder concluir si es viable el uso de uno solo de estos tres indicadores, se realiza la optimización con la herramienta FOR TSM para las 20 series seleccionadas para los indicadores MAPE, ME y V* Cero (Veces o intercesiones con cero), los resultados para la cada una de las series se muestran en la Tabla 5.

		INDICADOR PARA OPTIMIZAR					
		MAD		MAPE		MSE	
Serie	INDICADOR	SE	Holt	SE	Holt	SE	Holt
N1875	MAPE	14.499%	14.499%	14.499%	14.499%	14.525%	14.525%
	ME	4.90	4.90	4.83	0.14	6.02	6.02
	V. * Cero	3.00	3.00	3.00	3.00	3.00	3.00
N1683	MAPE	9.629%	9.629%	9.628%	9.628%	9.375%	9.375%
	ME	75.407	75.407	77.469	77.469	15.357	15.357
	V. * Cero	0.00	1.00	1.00	1.00	1.00	1.00
N2480	MAPE	75.985%	46.952%	73.900%	44.637%	81.373%	53.886%
	ME	-747.73	55.91	-518.10	137.47	-1018.43	-12.04
	V. * Cero	6.00	7.00	6.00	5.00	4.00	10.00
N2640	MAPE	32.585%	31.926%	32.238%	31.731%	33.889%	31.555%
	ME	-249.37	-319.56	-194.22	-106.85	-397.20	-242.52
	V. * Cero	6.00	2.00	8.00	8.00	4.00	2.00
N1413	MAPE	112.616%	103.774%	66.429%	66.429%	194.115%	194.115%
	ME	3876.19	2711.35	4150.92	4150.92	632.88	632.88
	V. * Cero	0.00	0.00	4150.92	0.00	0.00	0.00
N1429	MAPE	24.054%	20.635%	24.038%	20.571%	24.614%	20.987%
	ME	-196.76	12.79	-189.82	24.91	-283.97	7.27
	V. * Cero	0.00	1.00	0.00	1.00	0.00	3.00
N1691	MAPE	34.692%	34.692%	34.684%	34.678%	34.689%	34.689%
	ME	-17.63	-17.63	-17.14	-13.02	-17.52	-17.52
	V. * Cero	14.00	14.00	18.00	20.00	14.00	14.00
N1408	MAPE	46.517%	46.517%	41.726%	41.726%	45.362%	46.557%
	ME	177.59	177.59	748.76	748.76	242.30	176.15
	V. * Cero	0.00	0.00	0.00	0.00	0.00	0.00
N1697	MAPE	48.473%	46.991%	48.315%	46.277%	48.507%	48.507%
	ME	-64.32	-21.82	-50.27	4.57	-65.47	-65.47
	V. * Cero	4.00	4.00	6.00	11.00	4.00	4.00
N1695	MAPE	34.666%	33.512%	34.673%	34.623%	34.673%	34.623%

		INDICADOR PARA OPTIMIZAR					
		MAD		MAPE		MSE	
Serie	INDICADOR	SE	Holt	SE	Holt	SE	Holt
	ME	-118.65	-43.98	-123.75	-121.35	-123.75	-121.35
	V. * Cero	4.00	4.00	4.00	4.00	4.00	4.00
N1406	MAPE	40.735%	38.692%	37.145%	36.003%	44.185%	44.096%
	ME	945.07	708.96	1678.41	1475.49	665.79	409.34
	V. * Cero	1.00	1.00	1.00	1.00	1.00	1.00
N1442	MAPE	25.208%	25.208%	25.126%	25.116%	25.165%	25.165%
	ME	-160.96	-160.96	-124.14	-113.97	-88.52	-88.52
	V. * Cero	2.00	2.00	2.00	2.00	2.00	2.00
N1707	MAPE	33.510%	31.225%	33.344%	28.967%	33.830%	32.103%
	ME	-168.02	-0.44	-130.54	60.79	-220.56	-96.02
	V. * Cero	0.00	4.00	0.00	1.00	0.00	0.00
N1419	MAPE	34.081%	36.628%	33.248%	33.247%	35.621%	36.011%
	ME	239.53	47.75	13.77	358.45	170.19	112.03
	V. * Cero	0.00	0.00	10.00	0.00	0.00	0.00
N1422	MAPE	32.585%	31.926%	32.238%	31.731%	33.889%	31.555%
	ME	-249.37	-319.56	-194.22	-106.85	-397.20	-242.52
	V. * Cero	6.00	2.00	8.00	8.00	4.00	2.00
N1778	MAPE	6.182%	6.112%	6.182%	6.111%	6.186%	6.186%
	ME	-22.76	-8.56	-22.76	233.88	-23.41	-23.41
	V. * Cero	4.00	4.00	4.00	4.00	4.00	4.00
N1405	MAPE	70.548%	58.030%	55.242%	51.921%	72.426%	75.251%
	ME	531.10	657.73	1421.12	1149.14	464.73	355.55
	V. * Cero	0.00	0.00	0.00	0.00	0.00	0.00
N1559	MAPE	10.834%	10.621%	10.802%	10.623%	10.842%	10.740%
	ME	181.46	54.38	220.33	57.37	179.28	21.22
	V. * Cero	1.00	1.00	1.00	1.00	1.00	1.00
N1490	MAPE	22.573%	20.898%	22.514%	20.740%	22.572%	22.001%
	ME	-151.03	-134.85	-134.85	4.58	-150.80	-83.32
	V. * Cero	0.00	3.00	0.00	3.00	0.00	0.00
N1594	MAPE	10.183%	10.048%	10.181%	10.042%	10.182%	10.182%
	ME	-124.28	-71.34	-115.56	-57.00	-115.25	-115.25
	V. * Cero	0.00	0.00	0.00	0.00	0.00	0.00

Tabla 5: Valores obtenidos en la optimización de MAPE, ME y V* Cero

Después de realizar la optimización de los indicadores propuestos, obtener los resultados para los modelos SE y Holt y comparar los indicadores del MAPE, MAD y MSE en cada una de las series, se puede concluir que solo dos series (las series resaltadas) presentan

variaciones considerables en los indicadores (esto es por encima de un 15%). De esta manera se puede decir, que al encontrar los parámetros de los modelos SE y Holt que optimicen los indicadores MAD y MSE, y compararlos contra los valores obtenidos con los parámetros de ambos modelos que minimiza el MAPE, en el 90% de las series analizadas las variaciones porcentuales fueron de menos del 15%. Lo anterior permite finalmente concluir que, al usar uno solo de los indicadores entre el MAD, MAPE o MSE para hallar los valores de los parámetros de los modelos SE y Holt, garantiza tener los valores óptimos o pseudo óptimos de cada uno de estos indicadores. En el Anexo 6: Hoja de Cálculo con Datos iniciales se encuentran los resultados completos de esta información.

Teniendo en cuenta que los datos de las 20 series seleccionadas no son intermitentes, y que al ser el MAPE una de las métricas más utilizadas para la medición e interpretación de los errores de pronóstico que se encontró en la literatura, debido a que al ser un porcentaje se hace más fácil de entender que otras métricas de medición de exactitud, se toma la decisión de utilizar sólo este indicador. De esta manera, se utilizarán los valores de alpha hallados en el numeral 5.2.1 que minimizan el MAPE de cada serie del modelo SE de acuerdo con la propuesta realizada por [15] y estos mismos valores serán usados para hallar el valor de alpha de acuerdo con la propuesta del presente trabajo de investigación, el cual se explica en el siguiente apartado. Los resultados de ambas propuestas serán posteriormente evaluados y comprados.

5.3 Propuesta para la definición de parámetros mediante ponderación de indicadores: Caso Suavización Exponencial Simple

Con el fin de seleccionar parámetros y/o modelos para la proyección de demanda, a los cuales posteriormente se les debe medir su asertividad, los pronosticadores de demanda tratan de encontrar parámetros y modelos que hagan que los errores sean lo más bajos posibles. Para estas mediciones se calculan indicadores como el MAPE, seleccionando los parámetros y modelos que obtengan los valores porcentuales más bajos. Pero en un modelo de proyección se debe buscar también que existan otras condiciones y comportamientos ideales las cuales deberían ser incluidas en la selección de dichos parámetros y modelos. Estas condiciones ideales son:

- Que los errores en términos de magnitudes sean lo más bajos posibles. Como se mencionó anteriormente, esto se logra al medir un indicador como el MAPE
- Los errores acumulativos tiendan a ser cero. Entendiendo que un pronóstico siempre estará equivocado, es ideal que en el tiempo la suma de los errores positivos y negativos se cancele. Para ello se debe buscar que ME sea lo más cercano a “cero”
- Exista una distribución adecuada de los errores positivos y negativos en el tiempo, esto es que no se presente una acumulación de valores positivos o negativos durante muchos periodos en el tiempo. Este indicador se podrá medir al contar las veces que la Señal de Rastreo pase por cero, por medio del indicador $V * \text{Cero}$.

Con el fin de lograr obtener los parámetros de un modelo de proyecciones que logren que se pueda tener una aproximación a estos comportamientos ideales, se propone calcular dichos parámetros usando los indicadores MAPE, ME y V * Cero, buscando cumplir de manera más equilibrada con las condiciones ideales descritas anteriormente. Para ello es necesario ponderar cada indicador, con el fin de proponer una forma de hallar los parámetros de los modelos a partir de la optimización de los indicadores que buscan dichos comportamientos.

5.3.1 Ponderación de indicadores

Luego de seleccionar estos tres indicadores a usar en esta propuesta, es necesario determinar la importancia o peso que cada uno de estos indicadores debe tener. Para ello se realizó una encuesta a 10 expertos en temas de proyección a nivel empresarial, por medio del siguiente formulario:

ENCUESTA MEDICION ERRORES DE PRONOSTICOS

En la literatura podemos encontrar muchos indicadores para la medición del desempeño de un pronóstico de demanda. Entre los más usados por los autores encontramos los siguientes. MAPE (Error Porcentual Absoluto Medio), el ME (Error Medio) e INTERSECCIONES CON CERO.

• **Error Porcentual Medio Absoluto (MAPE)**

El MAPE nos muestra la desviación en términos porcentuales (%) y no en unidades. El MAPE es el promedio del error absoluto o diferencia entre la demanda real y el pronóstico expresado como un porcentaje de los valores reales. Se busca que este indicador sea lo más bajo posible

• **ME (ERROR MEDIO)**

Es la relación que existe entre la sumatoria de los errores del pronóstico obtenidos en cada periodo y el número total de errores. Representa en promedio el error obtenido en cada periodo y se espera que tienda a “cero”.

• **INTERSECCIONES CON CERO:**

Indica el número de veces que la señal de rastreo pasa por cero $\text{Pronostico}=\text{demanda}$

Tomar decisiones con respecto a qué medida de desempeño usar para la medición de la desviación o el error de pronósticos es en muchas ocasiones complejo para el encargado de realizar los pronósticos, es por esto que intentamos diseñar una metodología que permita unir tres medidas de desempeño que sean relevantes en las empresas (sin importar sus características) con el fin de poder mantener los errores lo más bajos posible en el tiempo logrando que el error sea cada vez más cercano a cero.

¿Si usted como encargado de una empresa debe definir por la relevancia que tiene cada uno de estos tres indicadores un peso % para cada uno de ellos que peso les daría? La sumatoria de los 3 indicadores debe ser 100%.

(Responder y justificar en la parte inferior de la encuesta)

Esta encuesta fue aplicada a expertos que se encuentran laborando en cargos relacionados con planeación de demanda en diferentes empresas, y los resultados se muestran en la Tabla 6. Teniendo en cuenta los pesos porcentuales dados por cada experto a cada uno de los tres indicadores, se asignó a cada indicador un peso equivalente al promedio aritmético dado por los expertos encuestados. Este valor será utilizado para determinar el nuevo parámetro propuesto.

Cargo	Empresa	INDICADORES		
		MAPE	ME	V*Cero
Analista forecast	Berhlan de Colombia	20%	50%	30%
Profesional de Planeación	Línea Directa	40%	30%	30%
Gerente de logística	Prebel	50%	25%	25%
Planeadora de demanda	Línea Directa	60%	20%	20%
Profesional de demanda	Línea Directa	55%	35%	10%
Planeador	Línea directa	60%	30%	10%
Profesional de demanda	Línea directa	60%	30%	10%
Planeación demanda	Línea Directa.	60%	30%	10%
Jefe Planeación Demanda	Línea Directa	70%	10%	20%
Especialista de planeación	Landers y cia	50%	30%	20%
VALOR PONDERADO INDICADOR		52.5%	29.0%	18.5%

Tabla 6. Ponderaciones asignadas por expertos en planeación de demanda a los indicadores MAPE, ME y V*Cero

Los pesos o ponderaciones dadas a cada indicador obtenido por medio de la encuesta a expertos se utilizan para calcular el valor del parámetro de α para cada una de las series.

5.3.2 Propuesta para la determinación del parámetro α del modelo SE

De acuerdo con lo mencionado anteriormente, se busca encontrar el parámetro α mediante una propuesta que relacione tres indicadores clave que buscan obtener un comportamiento ideal del modelo de suavización exponencial. De esta manera se propone ponderar los pesos calculados con los datos obtenidos por medio de la encuesta, con los valores de α obtenidos para cada indicador en la optimización, convirtiendo la sumatoria de estos datos en un único valor del parámetro para realizar las proyecciones con este modelo. El parámetro se calcula mediante la ecuación (16).

α Ponderado

(16)

$$= (\%MAPE * \alpha MAPE) + (\%ME * \alpha ME) + (\%V * Cero * \alpha V * Cero)$$

Donde $\alpha MAPE$ es el valor de α que minimiza el $MAPE$, αME es el valor de α que logra obtener el error medio más cercano a cero (0); y $\alpha V * Cero$ es el valor de α que obtiene la mayor cantidad de pasos por cero de la Señal de Rastreo. El cálculo este valor del parámetro para cada una de las series permite obtener un α Ponderado el cual será usado para el cálculo de proyecciones futuras con el modelo SE. Con esto se busca que dentro de un mismo parámetro se puedan incluir tres métricas que, como se mencionó anteriormente, pueden ser muy ajustadas al logro del propósito que tienen la medición de errores de proyecciones de demanda: errores lo más bajos posible; errores acumulativos que tiendan a cero y escalonamiento en el tiempo de los errores positivos y negativos.)

5.4 Cálculo de α propuesto a partir de los indicadores seleccionados

Para la selección de parámetros de modelos de proyección, algunos autores se enfocan en optimización de parámetros, otros simplemente lo hacen por tanteo y error o por análisis de datos, alternativas utilizadas especialmente a nivel práctico. Al proponer la definición de parámetro mediante ponderación de indicadores, lo que se busca desde el punto de vista práctico es dar a los encargados de realizar los pronósticos una forma adicional de hacer la selección de parámetros enfocados en múltiples indicadores, pero también teniendo en cuenta que son propuestas no definitivas y que estas no pueden garantizar que para todos los casos la metodología funcione siempre de manera óptima

Por medio de optimización de parámetros utilizando la herramienta de optimización Solver de Excel®, se determinan los valores óptimos de α para los indicadores propuestos para cada una de las series, tal como se explicó en el apartado 5.3.2. Una vez calculados los α óptimos y teniendo en cuenta los pesos o ponderaciones obtenidas por medio de la encuesta a expertos para estos indicadores, se calcula el α ponderado para con este valor obtener los pronósticos de los nuevos periodos usando el modelo de proyección SE. Los resultados obtenidos de α óptimos para $MAPE$, ME , $V * Cero$ y el α ponderado, se muestran en la Tabla 7.

PONDERACIÓN	52.5%	29.0%	18.5%	
SERIE	α MAPE	α ME	α V * Cero	α Ponderado
N1875	0.138	0.854	0.986	0.503
N1683	0.630	1.000	1.000	0.806
N2480	0.407	1.000	0.944	0.678
N2640	0.487	1.000	1.000	0.731
N1413	0.001	0.962	1.000	0.464
N1429	0.340	1.000	0.757	0.609
N1691	0.852	1.000	1.000	0.922
N1408	0.043	1.000	1.000	0.497
N1697	0.490	1.000	0.895	0.713
N1695	0.391	1.000	1.000	0.680
N1406	0.056	1.000	0.961	0.497
N1442	0.205	1.000	0.998	0.582
N1707	0.453	1.000	1.000	0.713
N1419	0.067	1.000	1.000	0.510
N1422	0.487	1.000	1.000	0.731
N1778	0.378	1.000	0.824	0.641
N1405	0.056	1.000	1.000	0.504
N1559	0.257	1.000	0.984	0.607
N1490	0.322	1.000	0.900	0.625
N1594	0.245	1.000	0.985	0.601

Tabla 7. Datos α mínimo para MAPE, ME, V * Cero y α ponderado

Con el fin de validar la efectividad del parámetro α Ponderado propuesto vs el α mínimo MAPE (α hallado al optimizar el MAPE), se proyectan los 6 periodos futuros propuestos por M3-Competition - International Institute of Forecasters. El cálculo de los 6 periodos propuestos se realiza con el modelo SE, utilizando en cada serie el valor de α MAPE y el valor de α Ponderado de la Tabla 7, esto para cada periodo proyectado. Posteriormente se comparan los resultados de los pronósticos obtenidos con cada parámetro, con relación a los valores reales de cada serie, obteniendo un resultado porcentual en función de la desviación de los datos para cada uno de los 6 periodos. Esta comparación se hace usando el indicador para la medición de precisión de pronósticos FA (Forecast Accuracy) explicado en el apartado 4.2.31. Finalmente se obtiene un promedio de los FA con los datos de los seis periodos de cada serie, los cuales se muestran en la Tabla 8. La información detallada de los resultados obtenidos se puede ver en el Anexo 7: Hoja de Cálculo Datos propuesta.

	PROMEDIO FA	
Serie	α Mínimo MAPE	α Ponderado
N1875	-1.228%	0.864%
N1683	-0.963%	0.475%
N2480	-5.969%	-10.740%
N2640	-5.892%	-9.250%
N1413	-693.230%	-1371.210%
N1429	7.577%	4.073%
N1691	-21.659%	-21.199%
N1408	6.342%	-9.078%
N1697	-21.743%	-11.448%
N1695	-3.924%	-0.445%
N1406	-7.082%	-3.481%
N1442	-1.456%	-9.304%
N1707	12.536%	13.477%
N1419	-28.964%	-9.565%
N1422	-5.892%	-9.250%
N1778	-0.672%	0.365%
N1405	-26.814%	-4.377%
N1559	4.699%	-0.289%
N1490	-21.782%	-9.174%
N1594	0.574%	0.814%

Tabla 8. Datos FA promedio MAPE nuevos periodos con α mínimo MAPE y α ponderado.

De los datos mostrados en la Tabla 8, se puede concluir que para el 60% (12 series resaltadas) el FA promedio resultante de la proyección de pronósticos usando el parámetro α Ponderado presentaron una mayor exactitud en las proyecciones. Adicionalmente, se observa que 5 de estas series tienen valores muy próximos a cero (series resaltada en color azul). Con esto se comprueba a priori que el 60% de los pronósticos hallados con el α ponderado con uno de los objetivos de un modelo de pronósticos (que los errores en términos de magnitudes sean lo más bajos posibles) y de estas 5 (cerca del 42%) buscan tener un error cercano a 0. Por su parte, de las 8 series que obtuvieron mejores exactitudes al usar el α que minimiza el MAPE, solo una tiende a que el error acumulado sea cercano a 0 (esto equivale al 12.5%)

Con el fin de poder comprobar de qué manera el parámetro definido mediante la ponderación de indicadores contribuye al cumplimiento de los objetivos propuestos: que exista una distribución adecuada de los errores positivos y negativos en el tiempo y que los

errores acumulativos tiendan a cero, se calculan los errores mínimos y máximos de los FA cálculos para cada uno de los 6 periodos, usando los parámetros de α Ponderado y α mínimo MAPE. Los valores de FA obtenidos en cada periodo para las 20 series se muestran en la figura 6.






Figura 6. Gráficos comparativo FA nuevos periodos con α mínimo MAPE y α ponderado

En el numeral 5.2 de este capítulo se analizan algunas de las características de las series tales como coeficientes de variación y coeficiente de correlación, encontrando series como por ejemplo la serie N2480 que presenta una alta desviación en los datos. Adicional a que en la serie fueron encontradas diferencias significativas en los coeficientes evaluados, se pueden observar que está no cumplen muy bien con los objetivos propuestos al utilizar el parámetro α ponderado, en relación al balance los de errores positivos y negativos.

Se evidencia que aunque existen excepciones como las mencionadas anteriormente, los valores obtenidos de errores con el modelo de suavización exponencial utilizando el α ponderado para el 50% de las series tales como las series N1683, N1429, N1691, N1442, N1408, entre otras cumplen de una mejor manera con el objetivo de tener errores en los pronósticos más balanceados, es decir errores positivos (subestimaciones) y errores negativos (sobrestimaciones) de manera alternante en el tiempo, indicando que en la mayoría de los casos el parámetro obtenido mediante la ponderación de indicadores propuesto cumple de mejor forma que al utilizar el parámetro α que minimiza el MAPE. También se pueden ver series como la N1405 y N1695 que al analizar inicialmente los datos presentan coeficientes de variación altos, pero sus errores al calcular los nuevos periodos con el α ponderado logran un balanceo de errores positivos y negativos según el objetivo propuesto

Finalmente, mediante las evidencias mostradas, se pueden concluir que al seleccionar el parámetro del modelo de forma ponderada, se logra que mayor cantidad de series, tengan un comportamiento en relación a los errores de los pronósticos de acuerdo con los objetivos propuestos en este trabajo que es encontrar un parámetro α que al ser usado en un modelo de proyección, trate de lograr que los errores acumulativos del modelo tiendan a cero, que exista un mejor balance entre los errores positivos y negativos y que los errores porcentuales sean los más bajos, posibles, entendiendo que dichos objetivos no siempre se podrán encontrar en todas las series, esto posiblemente por las características, patrones de comportamiento y comportamientos aleatorios que se presenten en una de las variables más difíciles de proyectar como es la demanda.

6. CONCLUSIONES

Una de las principales dificultades a las que se enfrentan los pronosticadores de demanda, es la de seleccionar los parámetros adecuados de un modelo para la proyección de demanda. Para la definición de los parámetros de un modelo, existen una gran variedad de técnicas y métodos, que van desde propuestas totalmente empíricas basadas en la asignación de valores de los parámetros por medio de ensayo y error, hasta enfoques completamente teóricos como la lógica difusa o las redes neurales, los cuales en muchos casos no son tan fáciles de entender e implementar a nivel práctico.

Uno de los enfoques más utilizados tanto a nivel académico como práctico para la determinación de los parámetros de un modelo de proyección, es por medio de la optimización, en donde el o los parámetros del modelo se obtiene al minimizar alguno de los indicadores claves de desempeño de los modelos de pronósticos como son el MAD, MAPE o MSE entre otros. En el presente trabajo se pudo concluir que al hallar los parámetros de los modelos de suavización exponencial simple y de suavización exponencial del Holt, para minimizar estos tres indicadores, bastaría con usar solo uno de estos para obtener el valor de los parámetros, ya que en un alto porcentaje (70% de las series) con estos se obtienen los valores óptimos o pseudo óptimos de cada uno de los indicadores. Lo anterior se hizo para 20 series seleccionadas aleatoriamente de la M3-Competition propuestas por la pagina del International Institute of Forecasters.

De los tres indicadores utilizados (MAD, MAPE, MSE), el Promedio del Error Porcentual Absoluto (MAPE) es probablemente una de las medidas de exactitud de las proyecciones más ampliamente utilizada y que es más fácil de interpretar por la mayoría de las personas a nivel práctico, es la que se utilizó en el desarrollo del trabajo. Lo anterior es ratificado en la encuesta en donde los expertos dieron una ponderación del 52.5% a dicho indicador.

Aunque existen muchos indicadores aplicables en la industria se lograron definir que los más utilizados, entendibles y relacionables son el MSE, MAD, RSME, MAPE, FA. Y aunque hoy no son muy aplicados en la industria se encuentran que indicadores como ME y V * Cero buscan medir que los resultados de un modelo de pronósticos se comporten de manera tal que, logren el objetivo de mantener los errores de pronósticos lo más bajo posible, se logren errores positivos y negativos de manera alternada, para que dichos errores tiendan a cancelarse en el tiempo.

Pese a los buenos resultados, encontrados con el método propuesto, es necesario que los pronosticadores de demanda evalúen las características de su información con el fin de determinar la aplicabilidad de dicha metodología para seleccionar los parámetros de un modelo y realicen las evaluaciones y modificaciones a que tenga lugar en caso de ser necesarias, como por ejemplo, para series de datos intermitentes.

Los resultados muestran que, aunque con el método propuesto para obtener alpha, todos los indicadores no obtiene siempre los mejores resultados, se evidencia que al usar este método para hallar los valores de los parámetros, se busca encontrar un balance entre los tres, esto es errores óptimos o pseudóptimos, mayor consistencia entre los errores positivos y negativos, sin alejarse considerablemente del valor óptimo de la magnitud del error, lo cual muestra un mejor comportamiento combinado de los indicadores incluidos en la propuesta.

Finalmente, el marco de referencia planteado en este trabajo, busca ser una guía para encargados de las proyecciones de demanda, que permita tener un proceso de estimación alineado con la demanda real, tomando decisiones adecuadas para la mejora de este proceso a nivel empresarial, obteniendo pronósticos los más exactos y consistentes posibles.

7. RECOMENDACIONES

Con el fin de corroborar la efectividad del método propuesto para seleccionar parámetros de forma ponderada, se considera importante realizar pruebas similares con los modelos, como son el modelo de suavización de Holt y el modelo de Winters, los cuales además de tener más cantidad de parámetros, son aplicables para otros patrones de comportamiento de la demanda. Igualmente sería conveniente incrementar el número de series para tener una mayor significancia estadística de los resultados.

Se recomienda probar el método de selección de parámetros propuesto en series con datos intermitentes modificando el parámetro MAPE por otro que se adapte mejor a este tipo de demandas, como es el S-MAPE propuesto en la revisión de la literatura.

Finalmente, una futura investigación se podría dirigir hacia obtener un indicador multicriterio para seleccionar modelos, de forma que se combinen algunos de los indicadores propuestos, buscando un comportamiento ideal del modelo de proyección como el mencionado a lo largo de este trabajo.

8. BIBLIOGRAFIA

- [1] J. David, V. Henao, C. Jaime, and F. Cardona, “a Comparison of Exponential Smoothing and Neural Networks in Time Series Prediction Redes Neuronales En La Predicción De Series De Tiempo,” pp. 66–73, 2013.
- [2] C. W. (Jeremy) Chiu, H. Mumtaz, and G. Pintér, “Forecasting with VAR models: Fat tails and stochastic volatility,” *Int. J. Forecast.*, vol. 33, no. 4, pp. 1124–1143, 2017.
- [3] T. M. Dantas and F. L. Cyrino Oliveira, “Improving time series forecasting: An approach combining bootstrap aggregation, clusters and exponential smoothing,” *Int. J. Forecast.*, vol. 34, no. 4, pp. 748–761, 2018.
- [4] A. V. Mathai, A. Ayush, A. Varnika, S. Narayanan, and E. Dhakshayani, “Development of new methods for measuring forecast error,” *Int. J. Logist. Syst. Manag.*, vol. 24, no. 2, pp. 213–225, 2016.
- [5] S. Morlidge, “Measuring the Quality of Intermittent-Demand Forecasts: It’s Worse than We’ve Thought!,” *Foresight Int. J. Appl. Forecast.*, vol. Spring2015, no. 37, pp. 37–42, 2015.
- [6] R. Hyndman, “Another Look At Forecast-Accuracy Metrics for Intermittent Demand,” *Foresight Int. J. Appl. Forecast.*, no. 4, pp. 43–46, 2006.
- [7] J. J. Montaña Moreno, A. Palmer Pol, A. Sesé Abad, and B. Cajal Blasco, “El índice R-MAPE como medida resistente del ajuste en la previsión,” *Psicothema*, vol. 25, no. 4, pp. 500–506, 2013.
- [8] S. Morlidge, “A Better Way to Assess the Quality of Demand Forecasts.,” *Foresight Int. J. Appl. Forecast.*, no. 38, pp. 15–21, 2015.
- [9] M. V. Shcherbakov, A. Brebels, N. L. Shcherbakova, A. P. Tyukov, T. A. Janovsky, and V. A. evich Kamaev, “A survey of forecast error measures,” *World Appl. Sci. J.*, vol. 24, no. 24, pp. 171–176, 2013.
- [10] M. Gilliland and U. Sglavo, “Worst practices in business forecasting,” *Focus Forecast.*, vol. July/Augus, 2010.
- [11] R. Torres-Rabello, “Precisión de Pronósticos,” *Negocios Globales*, pp. 30–31, 2015.
- [12] J. G. De Gooijer and R. J. Hyndman, “25 Years of Time Series Forecasting,” *Int. J. Forecast.*, vol. 22, no. 3, pp. 443–473, 2006.
- [13] Silver E.A., Pyke D.F., Peterson R. (1998). *Inventory Management and Production Planning and Scheduling*, pp 539-540. Tercera Edición. Estados Unidos.

- [14] Billah, B., King, M. L., Snyder, R. D., & Koehler, A. B. (2006). Exponential smoothing model selection for forecasting. *International journal of forecasting*, 22(2), 239-247.
- [15] Rasmussen, R. (2004). On time series data and optimal parameters. *Omega*, 32(2), 111-120.
- [16] MariaCristina_BravoGomez_Rosana_BuilesPalacio_2011. For-TSM: Desarrollo de una herramienta de pronosticos con los modelos de series de tiempo.

9. ANEXOS

Anexo 1: Varianza

Medida de dispersión de cada valor observado con respecto a la media.

$$\sigma^2 = \frac{\sum (X_i - \mu)^2}{N}$$

Donde:

N: tamaño de la población
Xi: Valor de la observación
 μ : media

Anexo 2: Desviación estándar

Raíz cuadrada positiva de la varianza.

$$\sigma = \sqrt{\sigma^2}$$

Donde:

σ^2 : Varianza

Anexo 3: Coeficiente de variación

Relación entre la desviación estándar y su media.

$$CV = \frac{\sigma}{\mu} \times 100$$

Donde:

σ : desviación estándar
 μ : media

Anexo 4: Estructura FOR TSM

Pantalla principal



Formulario para selección de modelos de pronósticos

The screenshot shows the 'FOR-TSM' window with the 'Modelos de Pronósticos' section. It contains several checkboxes for selecting forecasting models: Promedio Movil Simple, Promedio Movil Doble, Suavización Exponencial, Suavización Exponencial Doble, Suavización Exponencial con Ajuste de Tendencia, Regresión Lineal, Media, Descomposición Multiplicativa, and Winter. On the right, there is a 'Limpiar Formulario' button, a 'Número de datos a utilizar' dropdown, a 'Periodos a pronosticar' input field, and a 'Límites MAD para gráfica de Señal de' dropdown. A 'Calcular' button is located below these fields. A note at the bottom right states: 'Nota: Todo decimal debe estar separado por Puntos'.

Modelos de Pronósticos:

- Promedio Movil Simple
- Promedio Movil Doble
- Suavización Exponencial
- Suavización Exponencial Doble
- Suavización Exponencial con Ajuste de Tendencia
- Regresión Lineal
- Media
- Descomposición Multiplicativa
- Winter

Limpiar Formulario

Número de datos a utilizar:

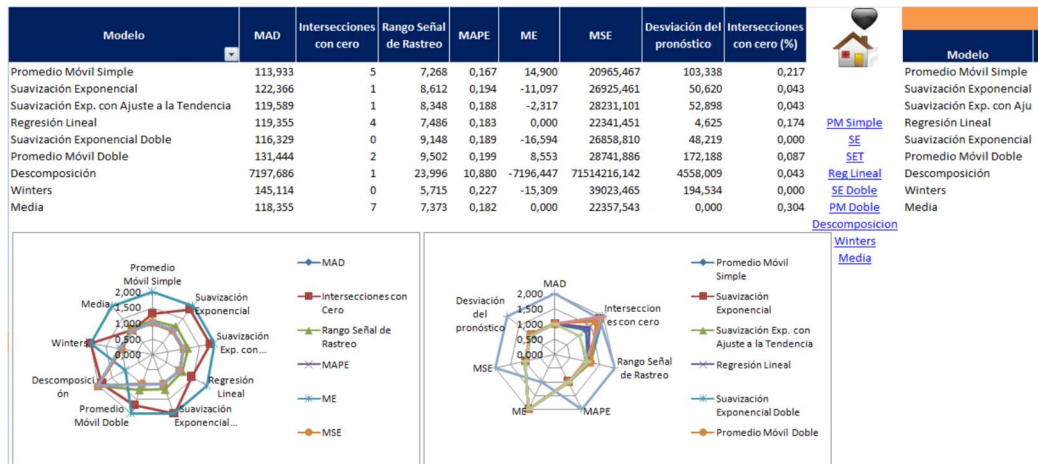
Periodos a pronosticar:

Límites MAD para gráfica de Señal de:

Calcular

Nota: Todo decimal debe estar separado por Puntos

Hoja de comparaciones de los modelos desarrollados en la herramienta FOR TSM.



Anexo 5: Estructura M3-Competition - International Institute of Forecasters

Pantalla principal

The 3003 time series of the M3-Competition are distributed as follows:

Interval	Types of Time Series Data						Total
	Micro	Industry	Macro	Finance	Demog	Other	
Yearly	146	102	83	58	245	11	645
Quarterly	204	83	336	76	57	0	756
Monthly	474	334	312	145	111	52	1428
Other	4	0	0	29	0	141	174
Total	828	519	731	308	413	204	3003

Link estructura de los datos:

<https://www.dropbox.com/s/sciycl4z2pptmck/Anexo%205.%20datM3C.xls?dl=1>

Anexo 6: Hoja de Cálculo con Datos iniciales

Link hoja de Calculo:

<https://www.dropbox.com/s/02xb7jro0mbip0q/Anexo%206.%20Hoja%20Calculo%20Datos%20Iniciales.xlsx?dl=1>

Anexo 7: Hoja de Cálculo Datos propuesta

Link hoja de Calculo:

<https://www.dropbox.com/s/hve2jf5e4nmhmcq/Anexo%207.%20Hoja%20Calculo%20Datos%20Propuesta.xlsx?dl=1>

Anexo 8: Ruta para encuesta a Expertos

Link encuesta:

https://forms.office.com/Pages/ResponsePage.aspx?id=Bo6PoIKmCkSaTmllak4L6io_GcdD1RRJFMhXabHSsJUOFM3VUFVUVPmzNKQzJWSkxaOTc5SkZBmi4u