

Modelo de tendencias para series complejas: caso de estudio tarifas hoteleras

Abraham Briones Juárez¹, Judith Alejandra Velázquez Castro²

abrahambriones2003@gmail.com; judithalejandra666@gmail.com

¹ Universidad Autónoma del Estado de Hidalgo, ICEA, Turismo, 42160, Hidalgo México.

² Universidad Autónoma del Estado de Hidalgo, ICEA, Turismo, 42160, Hidalgo México.

DOI: [10.17013/risti.50.73-90](https://doi.org/10.17013/risti.50.73-90)

Resumen: El análisis riguroso de datos en turismo es cada vez más común a raíz de las afectaciones sufridas por el covid-19, lo que ha contribuido a identificar trayectorias a partir de datos históricos. En este artículo, se propone una combinación de la teoría de la complejidad y la suavización exponencial para conocer los patrones que ayuden a estimar la estacionalidad y tendencia en las tarifas hoteleras. Para ello, se fragmenta la serie en particiones para explorar la similitud y se aplican cinco métodos de trazado. Los resultados muestran que el gráfico de longitud R, es el único que despliega anti-persistencia, con una saturación en el tiempo $n=8$, este dato se usa como ciclo de longitud del modelo aditivo de Holt-Winters cuyos parámetros ($a=0.36$, $b=0.78$, $y=0.67$), minimizan el error presentado. Se concluye que la combinación de métodos de análisis numérico permite el ajuste estacional en los datos tarifarios.

Palabras-clave: Tarifas hoteleras, anti persistencia, minimización.

Trend Model for complex series: case study hotel rates

Abstract: In The rigorous analysis of data in tourism is increasingly common as a result of the effects suffered by covid-19, which has contributed to identifying trajectories based on historical data. In this article, a combination of complexity theory and exponential smoothing is proposed to understand the patterns that help to estimate the seasonality and trend in hotel rates. To do this, the series is fragmented into partitions to explore the similarity and five plotting methods are applied. The results show that the graph of the length R, is the only one that displays anti-persistence, with a saturation in time $n=8$, this data is used as the length cycle of the additive Holt-Winters model whose parameters ($a=0.36$, $b=0.78$, $y=0.67$), minimize the error presented. It is concluded that the combination of numerical analysis methods allows the seasonal adjustment in the tariff data.

Keywords: Hotel rates, anti-persistence, minimization.

1. Introducción

El turismo constituye una fuente de riqueza y desarrollo, pese a su vulnerabilidad por situaciones de conflictos sociales o emergencias sanitarias como el covid-19. La recuperación que muestra este sector, denota su resiliencia (Mendoza et al., 2021) y capacidad de adaptación, lo que en el mercado global se evidencia con el margen de estimación de ingresos que alcanzó 1.9 billones de dólares en el año 2021 a nivel global (NWTO, 2021). Sin embargo, la industria de la hospitalidad a nivel local puede presentar adversidades para incrementar la ocupación de cuartos. La ciudad de México por ejemplo reportó un margen de ocupación del 62% en periodo pre-pandémico (DATATUR, 2019), mientras que en tiempos de pandemia este dato oscilaba alrededor del 30% en el año 2021 (Camila, 2022). Por tanto, el éxito de la administración de estas empresas depende en gran medida de los medios analíticos para mejorar la previsión de datos, es decir trabajar sobre la precisión de las predicciones (Liu et al., 2014), lo que demanda un esfuerzo para desarrollar nuevos procedimientos matemáticos con la intención de identificar parámetros que se adapten a las necesidades del presente y con ello propicia el crecimiento y buen funcionamiento de las empresas al tiempo que se utilizan tecnología y sistemas de información que mejoren la toma de decisiones en la industria (Patiño et al., 2020).

La venta de servicios de hospedaje se realiza a través de la configuración tarifaria, lo que significa que los clientes reciben ciertos productos y servicios de acuerdo a los tipos de segmento a los que pertenecen (Liu et al., 2022), ejemplo de ello lo constituyen las condiciones particulares que integran el servicio (Somphong et al., 2022) como la ubicación del cuarto, el acondicionamiento, las amenidades y otros bienes de consumo. No obstante, el comportamiento de las tarifas hoteleras ha sido poco estudiado.

El análisis de datos en hotelería supone incluir aquellos aspectos que hacen variar las cifras de manera dinámica para determinar patrones a partir de la complejidad de los fenómenos. Los fractales denotan el comportamiento por puntos de cambio, que a su vez se pueden explicar por leyes de potencia. La teoría de la complejidad ha sido de gran utilidad para explicar situaciones en distintas ramas del conocimiento como la economía (Kachhia, 2023), la física (Hou et al., 2021), la mecánica (Peng, & Li, 2023), las ciencias sociales (Blanco, 2019) y en el turismo (Briones et al., 2011) por su gran capacidad para detectar patrones en series temporales.

Debido a que se examinará una serie que aparentemente es aleatoria se busca la repetición por escalas y a distintos niveles. Así, la compatibilidad estadística en fractales auto-afines, se presenta por un conjunto que muestra ser invariante por escalamiento. En este trabajo se propone desarrollar un análisis de tendencias futuras de series complejas en tarifas para determinar la estimación optimizada de parámetros. Para ello, se desarrollan las siguientes fases: 1) se recaban los datos con el sistema de ingresos de un hotel de la Ciudad de México. 2) Se realizan particiones de los valores por desviaciones estándar y se da a conocer el comportamiento de la serie a distintas ventanas de orden "n". 3) Se estiman los exponentes de Hurst y se presentan las ilustraciones log-log por método, para indicar el más apropiado que genera punto de estacionalidad y antipersistencia. 4) Se prueba la longitud del ciclo obtenida en el modelo Holt-Winters y se obtienen los parámetros optimizados. 5) Se presentan la gráfica de ajuste con los valores utilizados,

y la predicción de los primeros 8 datos de la serie. 6) Se vierten las conclusiones y recomendaciones finales.

2. Revisión de la bibliografía

El análisis de datos se encuentra ligado al uso tecnológico en empresas de hotelería no solamente para apoyar en las decisiones, sino para optimizar y maximizar los beneficios (Pimentel et al., 2019) ya que la información generada desde la gestión constituye una serie de datos que se gesta desde una estructura compleja (Hernández et al., 2021).

Algunos de los temas centrales en el manejo de cifras en la industria de la hospitalidad son los aspectos financieros (Ozdemir et al., 2021), la calidad de servicios (Nilashi et al., 2021) y el uso de los recursos (Iranmanesh et al., 2022). Sin embargo el análisis de datos toma relevancia significativa para revelar tendencias de comportamiento y con ello mejor la generación de fuentes de información confiables que direccionan la planeación de acciones en el servicio (Pan et al., 2012). Derivado de la gran necesidad de la industria turística se han empleado distintas herramientas para comprender, explicar y predecir la tendencia de datos en estas empresas, como se muestra en la tabla 1, que sintetiza algunos de los esfuerzos para adecuar modelos de previsión con base en datos recolectados.

Técnica	Explicación	Autores
<i>Modelos de de explicación automático</i>	<i>Combinación de modelos dinámicos de pronostico</i>	<i>(Pereira & Cerqueira, 2022)</i>
<i>Modelo de memoria de atención a corto y largo plazo</i>	<i>Usa datos de la demanda con características adicionales proporcionadas por una empresa de turismo.</i>	<i>(Kaya et al., 2022)</i>
<i>Modelo de aprendizaje profundo.</i>	<i>Usa correlaciones espaciales y temporales por medio de algoritmo bayesiano</i>	<i>(Huang & Zheng, 2021)</i>
<i>Modelo de previsión de cancelaciones en hotelería</i>	<i>Usa técnicas de redes neuronales optimizadas con algoritmos genéticos</i>	<i>(Sánchez-Medina & C-Sánchez, 2020)</i>
<i>Modelo de precios de las habitaciones</i>	<i>Usa modelo de promedio móvil, la máquina de Boltzman, el modelo de máquina de vector y el sistema de interferencia difusa de red adaptativa.</i>	<i>(Al Shehhi & Karathanasopoulos, 2020)</i>
<i>Modelo de pronóstico de series temporales</i>	<i>Usa el espacio de estado estacional</i>	<i>(Pereira, 2016)</i>
<i>Modelo de serie temporal con fuente de datos big data</i>	<i>Usa múltiples fuentes de big data</i>	<i>(Pan & Yang, 2017)</i>
<i>Modelo de redes neuronales</i>	<i>Redes con revisión de puntaje</i>	<i>(Chang et al., 2021)</i>

Tabla 1 – Métodos de previsión de datos en empresas turísticas

Pese, a que se ha incrementado el número y tipo de técnicas numéricas en la hospitalidad, existe muy poca evidencia sobre el análisis de tarifas hoteleras. En este sentido Kim

et al., (2020) desarrollaron un estudio de tarifas y la discrepancia entre los canales de distribución con la intención de conocer los criterios sobre los cuales se calculan los precios. Por su parte Lee (2011), aborda el cambio en las tarifas y subraya que el número de turistas y el desempeño económico se relacionan de forma positiva con su incremento. De igual manera Lim & Ok (2022), determinaron como las tarifas promocionales inflúan en las percepciones de los clientes. En contraste, la previsión de tarifas muestra poco interés por parte de los académicos y los analistas del turismo y la hotelería. Con el propósito de abonar a las herramientas de analíticas y dado que la pandemia de covid-19 ha incentivado el uso de la teoría compleja para realizar mediciones en la dinámica temporal de series de datos (Castillo & Melin, 2020) y debido a que su uso ha sido recurrente dado a que también describe la trayectoria de la enfermedad (Easwaramoorthy et al., 2021). En este trabajo se abordan los datos bajo la teoría de la complejidad, la cual ha sido utilizada en turismo para dar explicar la dinámica de datos a partir del dinamismo del sector (Baggio & Sainaghi, 2011;Baggio & Sainaghi, 2016;Baggio, 2014).

La intención de refinar los modelos de pronóstico en la industria recae en el hecho de constituir herramientas que apoyen en la toma de decisiones gerenciales en la industria (Teixeira & Gunter, 2023). En tal sentido, han sido de gran utilidad las técnicas Box-Jenkins en su forma SARIMA y ARMA (Chuwang & Chen, 2022); los modelos de series de tendencias estructurales para identificar variables y dentar una mejora en la previsión de datos (Rashad, 2022); la combinación de técnicas de inteligencia artificial y enfoques convencionales que dan pie a modelos híbridos (Ouassou & Taya, 2022) y el uso de arquitecturas de redes neuronales con caracterización de periodos (Nguyen et al., 2022).

Estos esfuerzos tienen la intención de constituir métodos técnicas y herramientas que inducen modelos aplicables a la industria. (Gunter, 2021) especialmente en tiempos de pandemia en los que se vio afectado el flujo de turistas y de manera directa las comunidades residentes en los que se enclavan los atractivos turísticos (Godovykh et al., 2021).

3. Metodología

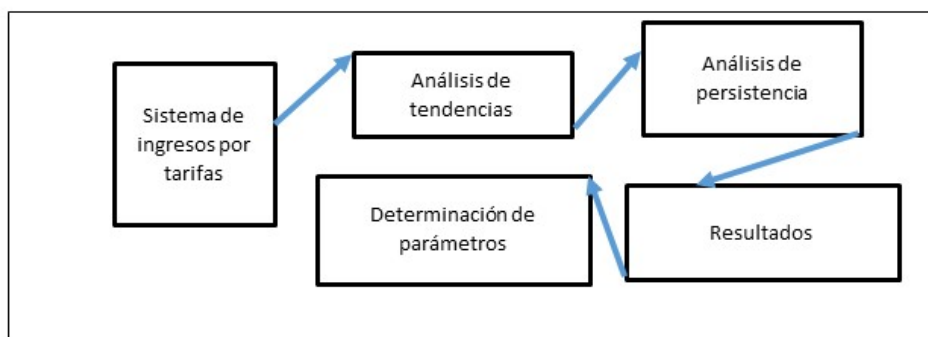


Figura 1 – Metodología

A continuación se presenta la metodología que sigue este trabajo en la figura 1, en la cual se puede percibir las fases que sigue la investigación. Cabe señalar que el cálculo de los parámetros ayudó en el desarrollo de datos futuros a partir del reconocimiento de las tendencias en los datos. Bajo esta consideración, enseguida se hace la descripción de los apartados para comprender el proceso que se siguió en este artículo.

3.1. Sistema de ingresos por tarifa

En esta fase primero se compilaron los datos a partir del sistema central de información del hotel (PMS) Property management system por sus siglas en idioma inglés, en un hotel categoría cinco estrellas. En esta empresa se asigna una clave a cada tipo de tarifa para poder otorgarla a los clientes. El gerente de recepción gestiona el otorgamiento de las tarifas según corresponda y tiene la facultad junto con la gerencia en turno de integrar servicios adicionales como llamadas telefónicas, alimentos, amenidades y promociones. Estos aspectos en general representan relaciones numéricas que cambian el total de ingresos por cada tarifa y la suma total de los datos que se observan.

El sistema central de información permite obtener datos por códigos y conceptos desglosados. El concentrado de la participación, su definición y el tipo de tarifa aparece en la tabla 2, que además muestra el porcentaje de participación de cada tipo de tarifa. Partiendo de la base anterior, se toma los datos de entrada del modelo, mismos que se constituyen con la sumatoria de las tarifas registradas en cada una de las observaciones que contabilizaron 974 de ellas.

Tipo de tarifa	Concepto	Porcentaje de representación
Corporaciones	Tarifa de descuento por ocupaciones	7%
Regular	Se brinda en recepción para clientes sin reservaciones	12%
Contratos	Se ofrece a partir de garantizar cierto número de estancias al año	19%
Gobierno	Tarifa preferencial a miembros diplomáticos y otros gobernantes	12%
Promocional	Se determina por la temporalidad	5%
Paquete	Incluye elementos de paquete	4%
Descuento	Se ofrece en temporada baja y fines de semana	6%

Tabla 2 – Tipología de tarifas del hotel.

3.2. Análisis de tendencias

Con el conjunto de datos se procedió a desarrollar el gráfico 2, para observar la dinámica a través del tiempo de los datos históricos de la serie y analizar su comportamiento. A primera vista, la serie parece aleatoria. Sin embargo bajo un análisis cualitativo se observan los siguientes aspectos:

Se observan oscilaciones periódicas, sin embargo es difícil precisar el número cíclico que describa la tendencia y la estacionalidad de la serie.

Se muestra que en el mes de abril del año 2022, no contabilizan ingresos por tarifas ya que el establecimiento permaneció cerrado en estas fechas debido a la contingencia sanitaria por covid-19.

Los datos mantienen una tendencia ascendente.




Figura 2 – Serie temporal de tarifas hoteleras

Para detectar la existencia de patrones repetidos se realiza una fragmentación de la serie en ventanas a partir de las desviaciones estándar de los datos; es decir, para la ventana 1, se calculó (sigma) del dato 1 al dato 2 (σ_1, σ_2), y así de manera sucesiva hasta completar 100 datos (σ_n, σ_{n+1}). Lo mismo se realizó con las ventanas sucesivas ampliando este cálculo a partir del dato 110 hasta 500, con conjuntos de 10 datos ($\sigma_{101}, \sigma_{111}$).y de 500 a 1000 con conjuntos de 50 datos. La tabla 3, muestra el procedimiento y las ventanas que se toman como muestra para analizar las tendencias.

Fecha	Datos	Ingresos por Tarifas			
01/01/2018	1	13,377.99	n=10		
02/01/2018	2	5,851.44	17.0315625	n=20	
03/01/2018	3	3,003.84	61.036875	0.375507812	n=30
04/01/2018	4	3,588.48	207.6428125	0.033203125	7.69043E-05
05/01/2018	5	3,669.12	197.1746875	0.255791016	0.000500488

Tabla 3 – Ventanas de muestra de la serie tarifas hoteleras.

Se tomó una muestra de 3 observaciones con la misma distancia de n , para visualizar si existe similitud, el origen de la muestra depende de las ventanas analizadas y de la comprobación de las tendencias del comportamiento gráfico en los datos. Para este caso se comprueba similitud en las fluctuaciones de las ventanas seleccionadas al observar las figuras 3, 4 y 5 respectivamente.

En la comparación de la las figuras 2 y 3, se preservan los picos de ascenso en los datos máximos.




Figura 3 – Ventanas de tamaño a) n=10, b) n=20 y c) n=30.

Con las figuras 3, se puede apreciar que a diferentes valores de ventana n, se guarda una similitud palpable en las tendencias de la serie. Esta partición de datos responde a la necesidad de visualizar el cambio relativo en cada iteración para valorar la pertinencia de desarrollar un análisis que induzca la identificación de parámetros a partir de patrones similares a distintas recursiones.

3.3. Análisis de persistencia

Con la certeza de que se puede encontrar una base de comportamiento que describa la serie, se realiza un análisis de persistencia de los datos a través del exponente de Hurts o exponente H. Lo anterior, para determinar si existe estacionalidad. Para ello, se utiliza el software Benoit 1.31, dado que la serie muestra aleatoriedad a primera vista, se desarrollan las gráficas log-log del exponente con distintos métodos de tratamiento auto-afín. Primero se empleó el método R/S o rango reescalado, el cual arroja un valor H, que mide la intensidad de dependencia a largo plazo de las series temporales.

$$\frac{R}{S} = \frac{R(n)}{S(n)} = \frac{\max\{0, r_t : t = 1, 2, 3, \dots, n\} - \min\{0, r_t : t = 1, 2, 3, \dots, n\}}{\sqrt{S^2(n)}} \quad (1), \text{ con}$$

$$r_k = \sum_{t=1}^k X_t - \frac{k}{n} \sum_{t=1}^n X_t \quad (2), \text{ y}$$

$$S(n) = \left[\frac{1}{n} \sum_{t=1}^n \left(X_t - \frac{1}{n} \sum_{t=1}^n X_t \right)^2 \right]^{\frac{1}{2}} \quad (3)$$

Donde: $X = \{X_t; t = 1, 2, 3, \dots, n\}$, y $R(n)$ es normalizada por la desviación estándar $S(n)$. Así, el rango rescalado se define por n^H , donde $n \rightarrow \infty$, en una serie con traza auto-afín.

En la figura 4, se observa una estacionalidad cercana al 0.5 por lo tanto, bajo este método la serie sigue siendo aleatoria y no se observan persistencias que favorezcan la previsión de datos, esto debido a que los exponentes H, vierte estacionalidad alrededor del punto medio =0.5.




Figura 4 – Estacionalidad aleatoria del método R/S.

En segundo lugar se utilizó la longitud de rugosidad o método R/L que se mide como el valor de la raíz cuadrada media del residuo en una tendencia lineal ajustada a los puntos de muestra en una ventana de longitud w , entonces la rugosidad de la raíz cuadrada media se calcula como sigue:

$$RL(w) = \frac{1}{n_w} \sum_{i=1}^{w_n} \sqrt{\frac{1}{m_{i-2}} \sum_{j \in W_i} (z_j - z)^2} \tag{4}$$

Donde n_w es el número total de ventanas de longitud w , m_i es el número de puntos en la ventana, w_i, z_j es el residual en la tendencia y z es la media residual en la ventana w_i .




Figura 5 – Comportamiento estacionario del exponente H con el método R/L

En la figura 5, se observa que con el método R/L se estacionaliza la serie en el dato 8, esto se presenta con valores de H alrededor de 0.70, lo que significa que existe persistencia traducida en la visualización del exponente H por encima del promedio, este gráfico ilustra un posible parámetro para precisar el comportamiento de la serie.

De la misma forma el análisis incluyo el Método de espectro de potencia P/S, el cual se relaciona con el exponente H a través de “b” como la pendiente negativa cuya forma matemática se constituye por:

$$D_s = \frac{5-b}{2} \tag{5}$$

Con este análisis se observa en la figura 6, que a partir del dato 22 la fórmula arroja datos cero para continuar con tendencia alcista. Por tanto, los valores del exponente H, no presentan estacionalidad alguna.




Figura 6 – Tendencia alcista de H con el método P/S.

El siguiente método a valorar fue el variograma o V/R definido como el cuadrado medio del incremento de puntos, estimado de la siguiente manera:

$$\gamma(h) = \frac{1}{2n} \sum_{i=1}^n [V(x_i) - Vx_{i+h}]^2 \tag{6}$$

Donde h , es la distancia de seguimiento (distancia entre dos puntos sucesivos), $\gamma(h)$ es el variograma a distancia de seguimiento h (el número de pares a una distancia h de retraso) y $V(x_i)$ son los valores de la muestra en la ubicación x_i , entonces las distribuciones del fractal se caracterizan por un modelo de variograma de la siguiente forma:

$$\gamma(h) = \gamma_0 h^{2H} \tag{7}$$

Donde H , es el exponente de Hurst. Los métodos de rugosidad-longitud y variograma se basan en el comportamiento de la escala de la desviación estándar $S_n \propto (\tau)^{H_n}$ y la semi-varianza $Var \propto \tau^{2H}$.

Este método muestra en la figura 7, datos oscilando alrededor $H= 0.25$ y con datos ceros después de la observación 27, lo que denota incapacidad para identificar previsiones.




Figura 7 – Estacionalidad anti-persistente del método de variograma

Finalmente se valoró el método de veletas el cual se asocia con un coeficiente:

$$W \propto a^{H_n + 1/2} \tag{8}$$

Donde a es el un parámetro que mide la onda.

En este último análisis en la figura 8, solo aparecen los datos por debajo de 0.75, sin mostrar estabilidad ni punto de saturación.




Figura 8 – Dispersión de datos por el método de veletas.

3.4. Resultados

Con las fases desarrolladas hasta ahora se presentan a continuación los resultados observados.

La manera en la que están constituidas las tarifas hoteleras y la flexibilidad que tiene la gerencia para modificarlas además de la injerencia de fenómenos externos como el impacto del covid-19 generan comportamiento caótico en la serie difícil de caracterizar.

La serie muestra auto-afinidad de tendencias al ser observada mediante el análisis de desviaciones estándar.

La serie de datos de las tarifas hoteleras, solo se estaciona en el dato $H = 8$ en el método

de longitud de rugosidad o L/R, en que además se muestra persistencia entre los datos, por tanto se tiene posibilidad de estimar parámetros que expliquen el comportamiento de los datos.

Dado que el dato de saturación se puede interpretar como un ciclo de longitud de la serie se realiza una prueba para estimar parámetros en el del modelo aditivo de Holt-Winters. Lo anterior, debido a que la estacionalidad es constante, lo cual se realiza en el siguiente apartado.

3.5. Determinación de parámetros optimizados

Los parámetros principales del método de Holt-Winters están constituidos de la siguiente forma:

α = Constante que actúa como atenuante para el promedio de datos ($0 < \alpha < 1$)

β = Constante que actúa como atenuante de las tendencias estimadas ($0 < \alpha < 1$)

γ = Constante de atenuación que actúa en la estacionalidad ($0 < \gamma < 1$)

Para calcular el valor atenuado A_t , se usa la siguiente relación:

$$A_t = \alpha \frac{Y_t}{S_{t-L}} + (1 - \alpha)(A_{t-1} + T_{t-1}) \quad (9)$$

Donde

Y_t = *Son las observaciones*

S_t = *Estacionalidad*

L = *Longitud de estacionalidad*

T_t = *Tendencia*

Para calcular la tendencia T_t , se utiliza la siguiente relación:

$$T_t = \beta(A_t - A_{t-1}) + (1 - \beta)T_{t-1} \tag{10}$$

Para calcular el valor pronosticado Y_{t+p} se utiliza la siguiente fórmula:

$$Y_{t+p} = (A_t + pT_t)S_{t-L+p} \tag{11}$$

Donde p = Periodos a pronosticar

Con la primer parte del análisis se toma $L= 8$ asumiendo con ello que cada 8 datos se repite el ciclo de comportamiento de los datos, con tendencia creciente excepto en el periodo de cierre por covid-19 de acuerdo con la figura 2. Para medir la adaptabilidad de los datos se desarrollan los siguientes procesos:

Se utilizan parámetros iniciales para el modelo.

Se realiza una optimización con la herramienta de solver de EXCELL.

Se realiza una optimización con el software winQSB.

Se vierten las conclusiones.

En la tabla 4, se muestran los parámetros iniciales y los optimizados por técnica analítica.

Parámetros	Iniciales	Optimizados	
<i>L</i>	8	<i>Solver</i>	<i>WINQSB</i>
<i>Alfa (α)</i>	0.1	0.43433065	0.36
<i>Beta (β)</i>	0.2	0.83944777	0.78
<i>Gamma (γ)</i>	0.7	0.25185388	0.67

Tabla 4 – Parámetros del modelo

A partir de la información de la tabla 2, se prueban los parámetros iniciales obtenidos con la herramienta solver de Excell y los obtenidos con el software winQSB. Estos últimos remarcados en negritas en la tabla ya que minimizan el error del modelo de acuerdo con los siguientes coeficientes obtenidos.

De la misma manera, se vierten los coeficientes de errores mínimos en la tabla 5, la cual muestra: la desviación absoluta media (MAD) “Meand absolute desviation”, el error medio cuadrático (MSE) “mean squared error” y la media absoluta por error (MAPE).

Coefficientes de error	Dato
<i>MAD</i>	7866.99
<i>MSE</i>	8.43
<i>MAPE</i>	42.52

Tabla 5 – Coeficientes de error mínimo del modelo

En el mismo sentido se procedió a calcular la predicción de los primeros 8 datos de la serie cuyos resultados se ilustran en la tabla 6 y en la gráfica 9.

Primera serie pronosticada	Dato		
$S(1)$	159642.575	$S(5)$	137442.295
$S(2)$	115612.975	$S(6)$	115525.905
$S(3)$	144109.575	$S(7)$	129278.515
$S(4)$	138241.935	$S(8)$	130956.785

Tabla 6 – Primera predicción de la serie

Finalmente se presenta el comparativo del ajuste de los parámetros encontrados en la figura 9, comparados con los datos históricos de la serie. En ella se observa que el uso de los parámetros mantiene un ajuste considerable con la serie original, lo cual muestra las bondades del modelo para predecir datos en el futuro. Cabe señalar que el pronóstico se puede calcular por bloques de 8 datos como aparece en la figura 9 para obtener datos futuros que contengan la relación interna de la serie original.




Figura 9 – Ajuste del comportamiento de la base de datos tarifas hoteleras, actual y modelo aditivo de Holt-Winters.



Figura 10 – Pronóstico de los primeros 8 datos de la serie.

4. Conclusiones

La previsión de datos en turismo y hotelería es una de los aspectos importantes dado que la emergencia de covid-19 ha generado impactos directos en la forma de estimar valores que apoyen los cursos de acción tomados por la dirección de las empresas. El turismo en este sentido se comporta de manera compleja dado que los datos analizados pueden contener información sin registro de ventas por tarifas hoteleras, tal es el caso del mes de abril del 2020 de la serie analizada.

Para poder realizar un modelo de previsión de datos en este trabajo se propuso la revisión de las tendencias de la serie para visualizar comportamientos afines a distintos valores de n , el uso de cinco métodos de análisis de persistencia a través del coeficiente H o de

Hurts para conocer la estacionalidad y el punto de cambio de sentido en las grafías en escalas logarítmicas. El resultado utilizado en el modelo aditivo de Holt-Winters parte del gráfico de longitud de rumorosidad L/R con una estacionalidad en el tiempo $n=8$,

este dato se usa como ciclo de longitud del modelo aditivo de Holt-Winters cuyos parámetros ($a=0.36$, $b=0.78$, $y=0.67$), minimizan el error presentado. Con este artículo se concluye que la combinación de herramientas matemáticas resulta pertinente para estimar el comportamiento de la serie de las tarifas hoteleras y describir la dinámica interna de los datos.

Estos resultados se pueden utilizar para mejorar la toma de decisiones en la gestión de servicios, a través de la ampliación del modelo para idéntica escenarios futuros del comportamiento de las tarifas que a su vez representen el comportamiento de la demanda para programar recursos físicos humanos y materiales en la gestión de servicios. Sin embargo este trabajo se limita solamente a encontrar la relación de parámetros que minimizan el error en la serie. Para futuras investigaciones se recomienda trabajar con los rendimientos logarítmicos de la serie y probar métodos que sean compatible con los resultados encontrados.

Referencias

- Al Shehhi, M., & Karathanasopoulos, A. (2020). Forecasting hotel room prices in selected GCC cities using deep learning. *Journal of Hospitality and Tourism Management*, 42, 40-50. <https://doi.org/10.1016/j.jhtm.2019.11.003>
- Blanco Rivero, J. J. (2019). The fractal geometry of Luhmann's sociological theory or debugging systems theory. *Technological Forecasting and Social Change*, 146, 31-40. <https://doi.org/10.1016/j.techfore.2019.05.020>
- Baggio, R. (2014). Complex tourism systems: a visibility graph approach. *Kybernetes*, 43(3-4), 445-461. <https://doi.org/10.1108/K-12-2013-0266>
- Baggio, R., & Sainaghi, R. (2011). Complex and chaotic tourism systems: towards a quantitative approach. *International Journal of Contemporary Hospitality Management*, 23(6), 840-861. <https://doi.org/10.1108/09596111111153501>

- Baggio, R., & Sainaghi, R. (2016). Mapping time series into networks as a tool to assess the complex dynamics of tourism systems. *Tourism Management*, 54, 23-33. <https://doi.org/10.1016/j.tourman.2015.10.008>
- Briones-Juarez, A., Padilla, R. T., Morales-Matamoros, O., Badillo-Pintilde, I. (2011). Fractal behavior of the sales restaurant in a great tourism hotel. *International Journal of Physical Sciences*, 6(10), 2422-2431. <https://doi.org/10.5897/IJPS11.193>
- Camila, A. (2022, enero 6). *Hoteles capitalinos no alcanzaron los niveles de ocupación de prepandemia en 2021*. El Economista. <https://www.economista.com.mx/estados/Hoteles-capitalinos-no-alcanzaron-los-niveles-de-ocupacion-de-prepandemia-en-2021-20220106-0047.html>
- Castillo, O., & Melin, P. (2020). Forecasting of COVID-19 time series for countries in the world based on a hybrid approach combining the fractal dimension and fuzzy logic. *Chaos, Solitons, and Fractals*, 140, 110242. <https://doi.org/10.1016/j.chaos.2020.110242>
- Chang, Y.-M., Chen, C.-H., Lai, J.-P., Lin, Y.-L., & Pai, P.-F. (2021). Forecasting Hotel Room Occupancy Using Long Short-Term Memory Networks with Sentiment Analysis and Scores of Customer Online Reviews. *Applied Sciences*, 11(21), 10291. <https://doi.org/10.3390/app112110291>
- Chuwang, D. D., & Chen, W. (2022). Forecasting Daily and Weekly Passenger Demand for Urban Rail Transit Stations Based on a Time Series Model Approach. *Forecasting*, 4(4), 904-924. <https://doi.org/10.3390/forecast4040049>
- DATATUR. (2019). *Porcentaje de ocupación hotelera*. <https://datatur.sectur.gob.mx/SitePages/Inicio.aspx>
- Easwaramoorthy, D., Gowrisankar, A., Manimaran, A., Nandhini, S., Rondoni, L., & Banerjee, S. (2021). An exploration of fractal-based prognostic model and comparative analysis for second wave of COVID-19 diffusion. *Nonlinear Dynamics*, 106(2), 1375-1395. <https://doi.org/10.1007/s11071-021-06865-7>
- Godovykh, M., Ridderstaat, J., Baker, C., & Fyall, A. (2021). COVID-19 and Tourism: Analyzing the Effects of COVID-19 Statistics and Media Coverage on Attitudes toward Tourism. *Forecasting*, 3(4), 870-883. <https://doi.org/10.3390/forecast3040053>
- Gunter, U. (2021). Improving Hotel Room Demand Forecasts for Vienna across Hotel Classes and Forecast Horizons: Single Models and Combination Techniques Based on Encompassing Tests. *Forecasting*, 3(4), 884-919. <https://doi.org/10.3390/forecast3040054>
- Hernández Rangel, M., Nieto-Malpica, J., & Quiñónez Guagua, O. (2021). Sistema de gestión de calidad y comunicación en el sector del turismo: Una aproximación al estado del conocimiento. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (E39), 368-378.
- Huang, L., & Zheng, W. (2021). Novel deep learning approach for forecasting daily hotel demand with agglomeration effect. *International Journal of Hospitality Management*, 98, 103038. <https://doi.org/10.1016/j.ijhm.2021.103038>

- Hou, K., Qian, H., Zhang, Y., Qu, W., Ren, W., & Wang, H. (2021). Relationship between fractal characteristics of grain-size and physical properties: Insights from a typical loess profile of the loess Plateau. *CATENA*, 207, 105653. <https://doi.org/10.1016/j.catena.2021.105653>
- Iranmanesh, M., Ghobakhloo, M., Nilashi, M., Tseng, M.-L., Yadegaridehkordi, E., & Leung, N. (2022). Applications of disruptive digital technologies in hotel industry: A systematic review. *International Journal of Hospitality Management*, 107, 103304. <https://doi.org/10.1016/j.ijhm.2022.103304>
- Kachhia, K. B. (2023). Chaos in fractional order financial model with fractal–fractional derivatives. *Partial Differential Equations in Applied Mathematics*, 7, 100502. <https://doi.org/10.1016/j.padiff.2023.100502>
- Kaya, K., Yılmaz, Y., Yaslan, Y., Ögüdücü, S. G., & Çıngı, F. (2022). Demand forecasting model using hotel clustering findings for hospitality industry. *Information Processing & Management*, 59(1), 102816. <https://doi.org/10.1016/j.ipm.2021.102816>
- Kim, W. G., McGinley, S., Choi, H.-M., Luberto, E., & Li, J. (2020). How does room rate and rate dispersion in U.S. hotels fluctuate? *Journal of Hospitality and Tourism Management*, 44, 227-237. <https://doi.org/10.1016/j.jhtm.2020.06.014>
- Lee, C. G. (2011). The determinants of hotel room rates: Another visit with Singapore's data. *International Journal of Hospitality Management*, 30(3), 756-758. <https://doi.org/10.1016/j.ijhm.2010.09.010>
- Lim, S., & Ok, C. (2022). A percentage-off discount versus free surcharge: The impact of promotion type on hotel consumers' responses. *Tourism Management*, 91, 104504. <https://doi.org/10.1016/j.tourman.2022.104504>
- Liu, P., Wu, L., & Li, X. (2022). What can hotels learn from the last recovery? Examining hotel occupancy rate and the guest experience. *International Journal of Hospitality Management*, 103, 103200. <https://doi.org/10.1016/j.ijhm.2022.103200>
- Liu, X., Peng, H., Bai, Y., Zhu, Y., & Liao, L. (2014). Tourism Flows Prediction based on an Improved Grey GM(1,1) Model. *Procedia - Social and Behavioral Sciences*, 138, 767-775. <https://doi.org/10.1016/j.sbspro.2014.07.256>
- Mendoza, Á. G. F., Arce, A. Z., & Holguín, J. S. V. (2021). Turismo En Tiempo De Pandemias. Covid-19 En Latinoamérica1. *Turismo y Sociedad*, 29, 129-155.
- Nguyen, L. Q., Fernandes, P. O., & Teixeira, J. P. (2022). Analyzing and Forecasting Tourism Demand in Vietnam with Artificial Neural Networks. *Forecasting*, 4(1), 36-50. <https://doi.org/10.3390/forecast4010003>
- Nilashi, M., Abumalloh, R. A., Almulihi, A., Alrizq, M., Alghamdi, A., Ismail, M. Y., Bashar, A., Zogaan, W. A., & Asadi, S. (2021). Big social data analysis for impact of food quality on travelers' satisfaction in eco-friendly hotels. *ICT Express*, 9(2), 182-188. <https://doi.org/10.1016/j.ict.2021.11.006>

- NWTO. (2021). *UNWTO World Tourism Barometer | Global Tourism Statistics*. <https://www.unwto.org/es/barometro-del-turismo-mundial-de-la-omt>
- Ouassou, E. H., & Taya, H. (2022). Forecasting Regional Tourism Demand in Morocco from Traditional and AI-Based Methods to Ensemble Modeling. *Forecasting*, 4(2), 420-437. <https://doi.org/10.3390/forecast4020024>
- Ozdemir, O., Dogru, T., Kizildag, M., Mody, M., & Suess, C. (2021). Quantifying the economic impact of COVID-19 on the U.S. hotel industry: Examination of hotel segments and operational structures. *Tourism Management Perspectives*, 39, 100864. <https://doi.org/10.1016/j.tmp.2021.100864>
- Pan, B., Chenguang Wu, D., & Song, H. (2012). Forecasting hotel room demand using search engine data. *Journal of Hospitality and Tourism Technology*, 3(3), 196-210. <https://doi.org/10.1108/17579881211264486>
- Pan, B., & Yang, Y. (2017). Forecasting Destination Weekly Hotel Occupancy with Big Data. *Journal of Travel Research*, 56(7), 957-970. <https://doi.org/10.1177/0047287516669050>
- Patiño, J., Mardones, R., Gonzalez, J., Romero-Riaño, E. , Palacios-Moya, L.(2020). Desarrollo de la investigación en sistemas de información para el turismo: una revisión centrada en visualización científica RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação, (E36), 387-398.
- Peng, D., & Li, X. (2023). Fractal contact analysis for transversely isotropic piezoelectric materials: Theoretical and numerical predictions. *Tribology International*, 181, 108323. <https://doi.org/10.1016/j.triboint.2023.108323>
- Pereira, L. N. (2016). An introduction to helpful forecasting methods for hotel revenue management. *International Journal of Hospitality Management*, 58, 13-23. <https://doi.org/10.1016/j.ijhm.2016.07.003>
- Pereira, L. N., & Cerqueira, V. (2022). Forecasting hotel demand for revenue management using machine learning regression methods. *Current Issues in Tourism*, 25(17), 2733-2750. <https://doi.org/10.1080/13683500.2021.1999397>
- Pimentel, V., Aizezikali, A., & Baker, T. (2019). Hotel revenue management: Benefits of simultaneous overbooking and allocation problem formulation in price optimization. *Computers & Industrial Engineering*, 137, 106073. <https://doi.org/10.1016/j.cie.2019.106073>
- Rashad, A. S. (2022). The Power of Travel Search Data in Forecasting the Tourism Demand in Dubai. *Forecasting*, 4(3), 674-684. <https://doi.org/10.3390/forecast4030036>
- Rocha, Á. (2012). Framework for a Global Quality Evaluation of a Website. *Online Information Review*, 36(3), 374-382. <https://www.abc.com>
- Sánchez-Medina, A. J., & C-Sánchez, E. (2020). Using machine learning and big data for efficient forecasting of hotel booking cancellations. *International Journal of Hospitality Management*, 89, 102546. <https://doi.org/10.1016/j.ijhm.2020.102546>

- Somphong, C., Udo, K., Ritphring, S., & Shirakawa, H. (2022). An estimate of the value of the beachfront with respect to the hotel room rates in Thailand. *Ocean & Coastal Management*, 226, 106272. <https://doi.org/10.1016/j.ocecoaman.2022.106272>
- Teixeira, J. P., & Gunter, U. (2023). Editorial for Special Issue: "Tourism Forecasting: Time-Series Analysis of World and Regional Data. *Forecasting*, 5(1), 210-212. <https://doi.org/10.3390/forecast5010011>