



**UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA DE NEGOCIOS INTERNACIONALES**

TÍTULO:

**Análisis predictivo de la demanda de bebidas para la estimación del
inventario dormido en un establecimiento hotelero.**

AUTORAS:

**Rivera Zeas, Alyson Valeria
Zorrilla Quiroz, Viviana Elizabeth**

**Trabajo de Integración Curricular previo a la obtención de título de
LICENCIADO EN NEGOCIOS INTERNACIONALES**

TUTOR:

Ing. Solórzano Carvajal, Mario David, Mgs.


**Guayaquil, Ecuador
12 de febrero del 2026**



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA NEGOCIOS INTERNACIONALES

CERTIFICACIÓN

Certificamos que el presente trabajo de integración curricular fue realizado en su totalidad por **Rivera Zeas, Alyson Valeria y Zorrilla Quiroz, Viviana Elizabeth**, como requerimiento para la obtención del título de **Licenciadas en Negocios Internacionales**

f. 

Ing. Solórzano Carvajal, Mario David, Mgs.

TUTOR

f. _____

Ing. Hurtado Cevallos, Gabriela Elizabeth, Mgs.

DIRECTORA DE LA CARRERA

Guayaquil, a los 12 del mes de febrero del año 2026



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA NEGOCIOS INTERNACIONALES

DECLARACIÓN DE RESPONSABILIDAD

Nosotras, **Rivera Zeas, Alyson Valeria**
Zorrilla Quiroz, Viviana Elizabeth

DECLARAMOS QUE:

El Trabajo de Integración Curricular, **Análisis predictivo de la demanda de bebidas para la estimación del inventario dormido en un establecimiento hotelero.** previo a la obtención del título de **Licenciadas en Negocios Internacionales**, ha sido desarrollado respetando derechos intelectuales de terceros conforme las citas que constan en el documento, cuyas fuentes se incorporan en las referencias o bibliografías. Consecuentemente este trabajo es de mi total autoría. En virtud de esta declaración, me responsabilizo del contenido, veracidad y alcance del Trabajo de Titulación referido.

Guayaquil, a los 12 del mes de febrero del año 2026

LAS AUTORAS:

f.

Rivera Zeas, Alyson Valeria

f.

Zorrilla Quiroz, Viviana Elizabeth



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL
FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA NEGOCIOS INTERNACIONALES

AUTORIZACIÓN

Nosotras, **Rivera Zeas, Alyson Valeria**
Zorrilla Quiroz, Viviana Elizabeth

Autorizamos a la Universidad Católica de Santiago de Guayaquil a la **publicación** en la biblioteca de la institución del Trabajo de Integración Curricular, **Análisis predictivo de la demanda de bebidas para la estimación del inventario dormido en un establecimiento hotelero**, cuyo contenido, ideas y criterios son de mi exclusiva responsabilidad y total autoría.

Guayaquil, a los 12 del mes de febrero del año 2026

LAS AUTORAS:

f.

Rivera Zeas, Alyson Valeria

f.

Zorrilla Quiroz, Viviana Elizabeth



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL

FACULTAD DE ECONOMÍA Y EMPRESA

CARRERA NEGOCIOS INTERNACIONALES

REPORTE COMPILATIO

Tesis Rivera Zeas Alyson y Zorrilla Quiroz Viviana (1) #ad30dc Gramática y ortografía

Resumen Puntos de interés Fuentes de similitudes

Similitudes: < 1%

Fuentes añadidas por el usuario

+ Añadir una fuente ► Analizar

Puedes añadir hasta 3 fuentes

Fuentes principales detectadas

De los cuales < 1% similares a las fuentes mencionadas en el documento Includido en el porcentaje

De los cuales < 1% de pasajes de similitud incluidos en textos entrecuillados Includido en el porcentaje

N°	Descripciones	Similitudes	Ubicaciones	Datos adicionales
1	repositorio.ucsg.edu.ec Análisis s... http://repositorio.ucsg.edu.ec/bitstream/... ▼ Mostrar las 5 fuentes secundarias	< 1%		Palabras idénticas: < 1% (142 palabras)
2	repositorio.ucsg.edu.ec Análisis d... http://repositorio.ucsg.edu.ec/bitstream/... ▼ Mostrar las 12 fuentes secundarias	< 1%		Palabras idénticas: < 1% (153 palabras)
3	repositorio.ucsg.edu.ec http://repositorio.ucsg.edu.ec/bitstream/... ▼ Mostrar las 12 fuentes secundarias	< 1%		Palabras idénticas: < 1% (154 palabras)

f. _____

Ing. Solórzano Carvajal, Mario David, Mgs.

TUTOR

AGRADECIMIENTO

Hoy culmina una etapa que no solo representa un logro académico, sino también un proceso de crecimiento personal, esfuerzo silencioso y aprendizaje constante. No fue un camino sencillo, había días en los que el cansancio pesaba más que la motivación, pero gracias a todo ese esfuerzo, puedo mirar atrás y entender que cada obstáculo fue una parte necesaria para construir mi historia.

A Dios, gracias por darme claridad en medio de la confusión, serenidad en momentos de estrés y fe cuando las respuestas que pedía no llegaban, en cada paso que daba sentía tu guía.

A mi mamá, Julia Mercedes Zeas Olaya, mi solecito, tú eres uno de los pilares más fuerte que tengo en mi vida. No tengo las palabras suficientes para expresarte todo lo que siento, siempre te lo agradeceré en esta vida y la otra. Empezaré diciéndote, gracias por nunca soltar mi mano en cada paso que daba a una nueva aventura. Por darme tu apoyo incondicional en todos los planes nuevos con los que te salía cada día y así mismo enseñarme que todo lo que empiece lo debo terminar. Por decirme que siempre haga todo con buena cara, sabiendo que la paciencia no es uno de mis fuertes, que siempre sonría porque te gusta ver a tu niña feliz. Tu eres mi mejor ejemplo de lucha y perseverancia, siempre te veo con ganas de aprender cosas nuevas, que por eso yo también busco que cosas nuevas puedo descubrir. Este y todos mis logros llevan grabado tu nombre, te amo infinitamente.

A mi hermana, Ariana Anahí Rivera Zeas, mi cuchurrumin, mi segundo pilar fuerte en mi vida. Quiero agradecerte por siempre celebrar mis logros como si fueran propios. Por demostrarme todo tu apoyo en los momentos que quería rendirme, en donde me frustraba, me amargaba e incluso lloraba del coraje, pero siempre tienes el mejor consejo para ayudarme y hacerme reír que eso es lo que más adoro de ti. Por pegarte esas buenas amanecidas cuando me tocaba una exposición de francés y te obligaba a escucharme mi hablada chueca. Este

logro también te pertenece Ari, porque hubo partes de mí que solo tú sabías cuidar mientras yo intentaba sostener todo lo demás.

A mis abuelos, Gioconda Olaya Scott y Leonardo Zeas Marín, mi tercer y último pilar fuerte en mi vida. Gracias por sembrar en mí valores que hoy sostienen cada uno de mis pasos. Por ponerse más felices, incluso que yo cuando tengo éxito en algo. Por preocuparse tanto por mí, siempre me he sentido amada gracias a ustedes, y sé que cuando necesite apoyo de alguien, estarán ustedes para hacerlo. Por hacerme desayunos tan temprano porque no les gusta que salga sin comer de la casa, por estar pendientes de todo lo que pasaba en mi vida. Mami Yoki, tu Pochi siempre estará agradecida por todo lo que has hecho por mi hasta el día de hoy y todo el amor que me tienes, Papá Leo tu niña que tiene tus mismos ojos siempre estará feliz de que la hayas amado desde el día que llegamos a su casa.

A mi compañera de tesis, Viviana Zorrilla Quiroz, siempre estaré agradecida con el universo por haber juntado nuestros caminos en esta universidad. Por el apoyo mutuo que nos dábamos cuando ya queríamos tirar la toalla y dejar todo a la suerte de la ruleta. Amo que lográramos construir esta linda amistad, la cual después de 4 años seguimos aquí y más fuertes que nunca dando nuestro último esfuerzo en esta tesis. Siempre estaré agradecida por toda la paciencia que me tuviste durante estos años que ahora siento que pasaron volando, por todos los buenos momentos que vivimos juntas desde el primer día que me dijiste que te vi feo, pero yo ni sabías que estabas ahí, por siempre hacerme acuerdo de las cosas que incluso si me las decían hace un minuto se me olvidaban enseguida. Espero que luego de terminar este capítulo, sigamos con esta linda amistad que logramos formar durante este tiempo. Te quiero mucho Vivi.

A mis amigos, por compartir conmigo todo este trayecto universitario, el cual, al principio parecía difícil pero cada nuevo semestre nos íbamos conociendo mejor y ya no se sentía tan pesado ir a clases, exponer o dar un examen, porque al final día todos teníamos el

mismo propósito, pasar al siguiente semestre. Siempre estaré agradecida de haberlos conocido, espero que luego de salir de la U, sigan recordándome como su compañera “Brillitos”, cuando me necesiten, ahí estaré para cualquier plan, sea apoyarlos, ir a una fiesta o irnos a estudiar una maestría fuera del país.

A mis mentores de las pasantías, Marquitos, Miguel y el señor Mauricio, gracias por haberme guiado en una de las tantas etapas importantes de mi carrera universitaria. Esta experiencia marcó un antes y un después en mi vida profesional, porque en ese momento sentí que todo lo aprendido en clases tuvo sentido en la vida real. Gracias por su paciencia, correcciones y la confianza que pusieron en mí mientras aún aprendía. Su apoyo, me ayudó a tener seguridad en lo que hacía. Todo lo que aprendí con ustedes no solo aportó en esta tesis, sino que también me dejó una base para mi futuro profesional.

A mis mascotas, Blanca, Leia, Kyra y Oso, que, aunque no entienden acerca de la tesis, ni de proyectos o exposiciones, siempre estuvieron presentes en este trayecto. Gracias Blanca por tu compañía en largas noches de estudio. Gracias Leia, por recibirme siempre con amor cuando llegaba tarde de la universidad. Gracias Oso, por despertarme cada mañana con tus ladridos para entrar a clases online. Gracias Kyra, por llenarme de besos cada que me ves.

- Rivera Zeas, Alyson Valeria

AGRADECIMIENTO

Sinceramente, no creí que un momento como este llegara tan rápido, pero, finalmente llegó. Luego de tantos momentos de estrés, confusión y uno que otro llantito por ahí, pero, a pesar de eso, darle fin a este capítulo en mi vida, de alguna manera es muy gratificante.

Le agradezco a Dios, por siempre darme la claridad en momentos en los que realmente me siento perdida, también por haberme guiado en todo este camino que creí que sería muy complicado, pero, fue llevadero gracias a ti.

A mis padres, Ángel Zorrilla y Yolanda Quiroz, por siempre estar en cada momento en mi vida, guiándome, siempre buscando lo mejor para mí y sintiendo todo su apoyo en cualquier paso que dé. Les agradezco infinitamente, me siento tan afortunada por todo el amor que me dan, realmente deseo poder devolverles al menos un poquito de todo ese cariño que me dan siempre.

A mis hermanitos (mayores), Dave Zorrilla y Leonardo Zorrilla, gracias por siempre ser mi lugar seguro, por aguantar mis pequeñísimos momentotes de estrés uno que otro día, por siempre estar pendiente de mí, cuidándome y velando en cada momento por el bienestar del “bebé” como siempre me han dicho, podré tener 50 años y seguirán diciéndome así, con el mismo amor y cariño del día uno, realmente les agradezco infinitamente.

A mi compañerita de tesis, Valeria Rivera Zeas o, como a veces le digo, sólo Valerie. A pesar de que nuestra primera interacción en la u, haya sido un poco curiosa y chistosa y es que siempre le recuerdo con mucho amor que me miró feo, le agradezco a Dios por habernos juntado desde ese primer trabajo grupal, desde ahí, pude entablar una de las más lindas y mejores amistades que he tenido en mi vida, que, aunque no lo diga seguido, su amistad me ha enseñado mucho, a su manera, pero lo ha hecho. Deseo con todo mi corazón que luego de estos cuatro años en la u, esta amistad perdure por muchísimos años más. Enserio aprecio mucho tu amistad, una de las más sinceras, te quiero muchito mi Vale.

A mis amiguitos de infancia, de la u y uno que otro vacacional que hice, gracias por estar siempre con sus brazos abiertos a ayudarme en cualquier duda, los aprecio bastante, les agradezco por estar, verdaderamente es algo valioso hoy en día.

- Zorrilla Quiroz, Viviana Elizabeth

DEDICATORIA

Quisiera dedicar este logro, en primer lugar, a mí. A la que fui al empezar este camino y a la que soy luego de recorrerlo. Es cierto que nadie conoce todo el esfuerzo que hay detrás de cada meta lograda; por eso quiero felicitarme por siempre haber hecho las cosas con esfuerzo, disciplina y constancia, porque eso demuestra la calidad de persona que soy. También por haber intentado afrontar cada desafío buena actitud y una sonrisa, incluso cuando era difícil de hacerlo.

A mi mamá, mi inspiración, porque si hoy muestro esa fuerza que me caracteriza, es porque lo aprendí de ella. Porque cada que quería rendirme, ella estaba ahí, dándome porras con mucho amor como siempre lo ha hecho.

A mi hermana, por ser la mejor compañía en cada etapa de mi vida. Porque no importa que tan ocupada estaba con mis cosas, siempre podía sentir su compañía silenciosa dándome apoyo.

A mis abuelos, por todos los valores y fortaleza que sembraron en mí desde pequeña. Cada consejo y enseñanza forman parte de la persona que hoy está culminando esta etapa de su vida, este logro también lleva su legado.

- Rivera Zeas, Alyson Valeria

DEDICATORIA

Dedico este trabajo a las personas que más amo, a mis papás, quiénes han sido mi motivación constante para llegar hasta donde estoy. A mis hermanos, por estar presente en cada etapa de mi vida y apoyarme cada día a seguir superándome.

A mis tías, por animarme en cada momento y rodearme de su amor y felicidad siempre, estaré agradecida toda la vida por tenerlas.

Finalmente, a todos quiénes de alguna u otra forma, me ayudaron a su manera en todo este largo proceso, los tendré en mi corazoncito siempre.


- Zorrilla Quiroz, Viviana Elizabeth



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL

FACULTAD DE ECONOMÍA Y EMPRESA
CARRERA NEGOCIOS INTERNACIONALES

TRIBUNAL DE SUSTENTACIÓN

f. 

Ing. Mario David, Solórzano Carvajal, Mgs.

TUTOR

f. _____

Ing. Hurtado Cevallos, Gabriela Elizabeth, Mgs.

DIRECTORA DE CARRERA

f. _____

PhD. Freire Quintero, Cesar Enrique

COORDINADOR DEL ÁREA



UNIVERSIDAD CATÓLICA
DE SANTIAGO DE GUAYAQUIL

FACULTAD DE ECONOMÍA Y EMPRESA

CARRERA NEGOCIOS INTERNACIONALES

CALIFICACIÓN

f. _____

Rivera Zeas, Alyson Valeria

f. _____

Zorrilla Quiroz, Viviana Elizabeth

ÍNDICE

1.	CAPÍTULO: INTRODUCCIÓN.....	2
1.1.	Formulación del problema.....	2
1.2	Antecedentes.....	2
1.2.	Contextualización del problema	4
1.3	Objetivo de la investigación	6
1.3.	Objetivo General.....	6
2.3.	Objetivos Específicos	6
1.4	Pregunta de investigación:.....	6
1.5	JUSTIFICACIÓN	7
1.6	Delimitaciones y Limitaciones	8
1.6.	Delimitaciones	8
2.6.	Limitaciones	9
2.	CAPÍTULO: MARCO TEÓRICO	10
2.1	Gestión de Inventarios en la Industria Hotelera	10
2.2	Conceptos fundamentales de inventario: stock activo, inactivo y dormido ..	11
	Costos asociados a la mala gestión de inventarios: capital inmovilizado, obsolescencia, almacenamiento	12
	Particularidades del inventario de alimentos y bebidas (F&B) en hoteles: perecederos, estacionalidad, demanda impulsada por eventos.	13
	El inventario dormido detallado	14
	<i>Conceptualización del inventario dormido</i>	14
	<i>Métricas para su identificación: tasa de rotación (inventory turnover), días de inventario disponible (DIO), análisis ABC/XYZ</i>	14
	<i>Causas raíz en el contexto hotelero: sobrecompra, pronósticos deficientes, cambios en tendencias de consumo, gestión de menús</i>	15
	Análisis predictivo y series de tiempo.....	16
	<i>Fundamentos del análisis predictivo: de lo descriptivo a lo prescriptivo</i>	16
	<i>Modelos de pronóstico: suavizamiento exponencial (holt-winters), ARIMA, Modelos de Regresión</i>	17
	<i>La importancia de los datos históricos, la estacionalidad y las variables exógenas (ocupación hotelera, eventos locales, clima)</i>	17
	Técnicas de Machine Learning Aplicadas a la Demanda	18
	<i>Algoritmos supervisados para pronóstico: Random Forest, Gradient Boosting (XGBoost), Redes Neuronales Artificiales simples (MLP)</i>	18
	<i>Procesamiento de datos para modelos predictivos: manejo de outliers, imputación de datos, escalado de variables.....</i>	18
	Integración del Pronóstico en la Gestión de Inventarios.....	20

<i>Modelos de revisión de inventarios: sistemas periódicos vs. continuos bajo demanda probabilística</i>	20
<i>Determinación de puntos de reorden (ROP) y niveles de stock de seguridad usando pronósticos</i>	20
<i>Estrategias para reactivar el inventario dormido (bundling, tácticas, donación controlada)</i>	21
Marco conceptual: Glosario de Términos Operativos.....	21
<i>Inventario dormido</i>	21
<i>Rotación de inventarios</i>	22
<i>Pronóstico de demanda</i>	22
<i>Nivel de servicio</i>	22
<i>Error de pronóstico</i>	22
Variables de Estudio y Relaciones Propias	23
<i>Variable Independiente / Predictora: Pronóstico de demanda generado por modelos predictivos</i>	23
<i>Variable dependiente o de respuesta: Nivel de inventario dormido (en unidades, dinero y día de cobertura)</i>	23
<i>Variables Intervinientes o de Control</i>	24
Antecedentes de Investigación	27
<i>A nivel Internacional</i>	27
<i>A nivel de Ecuador</i>	28
Marco Legal	29
<i>Normativa sobre Control y Manejo de Bebidas Alcohólicas</i>	30
<i>Regulaciones de venta y almacenamiento (impuestos, licencias)</i>	31
<i>Normas de Salud e Higiene para Almacenes</i>	31
<i>Condiciones sanitarias para el almacenamiento de bebidas</i>	32
<i>Regulaciones Contables y Fiscales Relacionadas con Inventarios</i>	32
<i>Normas locales NIC/NIIF</i>	32
<i>Valuación y provisión por obsolescencia de inventarios</i>	32
<i>Tratamiento fiscal (mermas por inventario no rotativo)</i>	33
CAPITULO: METODOLOGÍA	34
Introducción	34
Alcance.....	34
Tipo de investigación	34
Enfoque de la Investigación	35
Datos.....	36
<i>Manejo confidencial de datos</i>	36
<i>Desglose de datos</i>	36

Python.....	38
Librerías	38
<i>Pandas</i> :.....	38
<i>NumPy</i>	39
<i>Matplotlib</i>	39
<i>Unicodedata</i>	39
<i>Re (Expresiones Regulares)</i>	40
<i>Statsmodels</i>	40
Limpieza de datos.....	41
<i>Etapla preliminar</i>	41
<i>Etapla en Python</i>	43
Construcción del Catalogo Maestro	49
Medición de rotación por producto	49
Clasificación de productos	50
<i>Percentiles</i>	50
Detección de productos dormidos	51
<i>Base conceptual</i>	51
<i>Elaboración de la matriz producto-mes</i>	51
Series temporales.....	52
<i>Serie mensual de total despachado</i>	53
<i>Serie mensual de productos de baja rotación</i>	53
<i>Serie mensual del porcentaje de baja rotación</i>	54
<i>Serie mensual de productos dormidos</i>	54
Análisis de autocorrelación	55
Modelo SARIMA	56
Proyección para el 2026	57
CAPÍTULO: RESULTADOS	58
Análisis de series de tiempo	58
<i>Serie mensual</i>	58
<i>Serie mensual por categoría</i>	59
Rotación de productos (alta, media, baja)	61
Productos de baja rotación	62
Productos dormidos por mes (3 meses de inactividad)	63
Autocorrelación (ACF) y autocorrelación parcial (PACF)	64
Modelo predictivo SARIMA.....	65
Forecast Dormidos (2026).....	66
Análisis de residuos.....	67

CONCLUSIONES	69
RECOMENDACIONES	71
REFERENCIAS BIBLIOGRÁFICAS	72
3. ANEXOS.....	76

ÍNDICE DE TABLAS

Tabla 1. Tabla sobre variables de control.	24
Tabla 2: Desglose de los datos	38
Tabla 3: Variables principales.....	43

ÍNDICE DE ILUSTRACIONES

Figura 1: Comparativa mensual entre períodos 2024 vs 2025	58
Figura 2: Comparativa mensual de VINOS entre períodos 2024 vs 2025	59
Figura 3:Comparativa mensual de LICOR FUERTE 2024 vs 2025	60
Figura 4: Comparativa mensual de CERVEZAS entre períodos 2024 vs 2025.....	61
Figura 5: Rotación de productos, alta, media y baja	61
Figura 6: Porcentaje de productos de baja rotación 2024 vs 2025	62
Figura 7: Productos estructuralmente dormidos 2024 vs 2025	63
Figura 8: ACF y PACF	64
Figura 9; Resultados SARIMA	65
Figura 10: Proyección 2026 porcentaje dormidos.....	66
Figura 11: Análisis Residual (SARIMA)	67

RESUMEN

En la presente investigación, se analiza el comportamiento temporal de la demanda de bebidas de baja rotación en un establecimiento de hotelería en la ciudad de Guayaquil, cuyo principal objetivo es proyectar el nivel de inventario dormido para el período 2026. El almacenamiento de productos sin movimientos, representan un problema crítico que se deriva en un capital inmovilizado, un alto riesgo de obsolescencia y mayores costos de almacenamiento, lo cual afecta de manera directa la eficiencia operativa del departamento de inventarios.

Mediante un enfoque cuantitativo, de tipo descriptivo y predictivo, se utilizó una data histórica de los periodos 2024 y 2025. Luego de un proceso de depuración y consolidación de todas las requisiciones de forma mensual, se construyeron series de tiempo a fin de obtener el inventario dormido que, es definido operativamente como aquel producto sin movimientos durante un trimestre consecutivo. El análisis de rotación realizado por categorías, tales como cervezas, vinos y licores permitió la identificación de patrones estacionarios y de variabilidad.

Dentro de la fase de pronóstico, se implementó un modelo predictivo SARIMA, el cual se valida mediante métricas de error (MAE) y análisis de significancia. Los resultados, muestran que la baja rotación de productos exhibe variaciones estacionales que se vinculan a las fluctuaciones de la demanda en el establecimiento, manteniendo una media estable.

Las proyecciones para el periodo 2026, indican la persistencia del stock inmovilizado bajo políticas actuales, haciendo énfasis en la necesidad de integrar modelos predictivos en la planificación, el estudio finaliza concluyendo que el análisis de series de temporales es un recurso fundamental para mitigar riesgos financieros en el contexto de una demanda fluctuante.

Palabras clave: inventario dormido, series temporales, baja rotación, análisis predictivo.

ABSTRACT

This research analyzes the temporal behavior of demand for slow-moving beverages in a hotel establishment in the city of Guayaquil, with the main objective of projecting the level of dormant inventory for the year 2026. Storing products with no movement represents a critical problem that results in immobilized capital, a high risk of obsolescence, and higher storage costs, which directly affects the operational efficiency of the inventory department.

Using a quantitative, descriptive, and predictive approach, historical data from the years 2024 and 2025 were used. After a process of cleaning and consolidating all monthly requisitions, time series were constructed to obtain the dormant inventory, which is operationally defined as any product with no movement during a consecutive quarter. The turnover analysis performed by categories, such as beers, wines, and spirits, allowed for the identification of stationery and variability patterns.

Within the forecasting phase, a predictive model, SARIMA, was implemented and validated using mean error metrics (MAE) and significance analysis. The results show that low product turnover exhibits seasonal variations linked to fluctuations in demand at the facility, while maintaining a stable average.

Projections for 2026 indicate the persistence of immobilized stock under current policies, emphasizing the need to integrate predictive models into planning. The study concludes that time series analysis is a fundamental resource for mitigating financial risks in the context of fluctuating demand.

Keywords: dormant inventory, time series, slow-moving, predictive analysis.

RÉSUMÉ

Cette recherche analyse l'évolution temporelle de la demande de boissons à faible rotation dans un établissement hôtelier de Guayaquil, avec pour principal objectif de prévoir le niveau des stocks dormants pour l'année 2026. Le stockage de produits invendus représente un problème majeur, engendrant une immobilisation de capital, un risque élevé d'obsolescence et des coûts de stockage plus importants, ce qui affecte directement l'efficacité opérationnelle du service des stocks.

Une approche quantitative, descriptive et prédictive a été utilisée, à partir des données historiques des années 2024 et 2025. Après nettoyage et consolidation de toutes les demandes mensuelles, des séries temporelles ont été construites afin d'obtenir le niveau des stocks dormants, définis opérationnellement comme tout produit n'ayant pas été écoulé pendant un trimestre consécutif. L'analyse de la rotation des stocks par catégories (bières, vins et spiritueux, par exemple) a permis d'identifier les tendances stationnaires et variables.

Dans la phase de prévision, un modèle prédictif, SARIMA, a été implémenté et validé à l'aide de l'erreur absolue moyenne (MAE) et d'une analyse de la significativité. Les résultats montrent que la faible rotation des stocks présente des variations saisonnières liées aux fluctuations de la demande au niveau de l'établissement, tout en conservant une moyenne stable.

Les projections pour 2026 indiquent la persistance des stocks immobilisés dans le cadre des politiques actuelles, soulignant la nécessité d'intégrer des modèles prédictifs à la planification. L'étude conclut que l'analyse des séries chronologiques est une ressource fondamentale pour atténuer les risques financiers dans un contexte de demande fluctuante.

Mots-clés: stocks dormants, séries chronologiques, faible rotation, analyse prédictive

CAPÍTULO 1:

INTRODUCCIÓN

Formulación del problema

Antecedentes

En el transcurso de los años, la gestión de inventarios dentro del sector hotelero se ha convertido en un factor de alto impacto gracias a la influencia directa que lleva sobre la eficiencia operativa y la rentabilidad. Dentro de este entorno, el cual se ve caracterizado por una demanda que se encuentra en constante variación es incluso, compleja de predecir dado que los establecimientos hoteleros necesitan buscar el equilibrio entre la disponibilidad de sus productos y el exceso que podría existir en ellos, a fin de evitar costos innecesarios.

Algunos autores detallan que si las planificaciones de inventarios en estos establecimientos, sólo se basan en estimaciones con poca precisión, es probable que existan productos sin consumirse en el tiempo previsto. Esto sucede inicialmente gracias a que las decisiones tomadas suelen basarse en criterios personales, más no en un análisis con datos históricos o ciertos patrones en la demanda. Asimismo, los hoteles que no tienden a utilizar modelos de pronóstico suelen llenarse de excedentes en su stock en temporadas eventuales, ocasionando un aumento significativo en ese capital inmovilizado e incluso pérdidas por los productos de baja rotación.

A lo largo de las últimas décadas, la revolución de la información ha tenido un mayor impacto a las industrias minoristas y manufactureras, donde conceptos como la fabricación justo a tiempo o por sus siglas en inglés (JIT) Just in time y la gestión de la cadena de suministro basada en datos, han demostrado ser inmensamente valiosos para reducir la inactividad en el inventario a fin de liberar capital y de este modo, mejorar la rentabilidad.

Dentro de la gestión de inventarios, se estandarizó el uso de softwares específicos, herramientas como Enterprise Resource Planning, se implementaron con la finalidad de automatizar procesos centrales dentro de las empresas permitiendo un control mucho más preciso sobre el inventario. No obstante, el despliegue de estas tecnologías en el sector hotelero, específicamente en áreas como el departamento de alimentos y bebidas (F&B), se ha mostrado heterogénea y en muchos casos, deficientes en su alcance.

Gran parte de entidades hoteleras, ejecutaron estos sistemas en la contabilidad y facturaciones, sin embargo, la capacidad analítica y de predicción para gestionar el stock perecedero y de alta rotación ha quedado, en muchas ocasiones, infrautilizada o desconectada de los procesos de compra y reposición que se realizan diariamente, siendo que suelen guiarse por cálculos estáticos y órdenes basadas en el supuesto ojo clínico.

A pesar de ello, existe una deficiencia notable entre los conocimientos teóricos y la correcta aplicación de forma práctica en el área operativa de un hotel mediano.

Los estudios previos a menudo se han centrado en grandes cadenas hoteleras con recursos para desarrollar o adquirir soluciones tecnológicas de vanguardia, o en modelos predictivos generales, que no tienen en cuenta las características locales de ubicaciones específicas: su ubicación, las características demográficas de los clientes, la estacionalidad del destino y el impacto de los eventos locales en la ocupación y el gasto. Por tanto, se necesitan estudios de casos aplicados, en el cual se explore el diseño e implementación de modelos predictivos de fácil acceso, adaptado a las capacidades y al flujo de datos reales de un establecimiento hotelero, una intervención costo-efectiva que aborde las causas subyacentes de la problemática: la profunda y costosa incertidumbre sobre qué, cuánto y cuándo comprar.

Contextualización del problema

El sector hotelero progresa en un ámbito donde la excelencia en las operaciones no es un privilegio, sino la base de la existencia. En este marco, la administración de inventarios de productos de consumo inmediato, como las bebidas, supone un reto continuo y complicado. El desafío principal que afrontan muchos negocios se basa en la incapacidad estructural para alinear el abastecimiento con una demanda que es, por su propia naturaleza, cambiante, estacional y afectada por una variedad de factores casi imposibles de medir a simple vista. Esta desconexión provoca un fenómeno especialmente dañino: la acumulación de inventario dormido, es decir, artículos que, tras ser comprados, permanecen atascados en depósitos y almacenes por largos períodos, dejando de ser un activo líquido y transformándose en un pasivo que desgasta valor diariamente. El deficiente análisis predictivo de la demanda que facilite la estimación y comprensión de este inventario inactivo no es un simple déficit técnico; representa una vulnerabilidad estratégica que da paso a diversas consecuencias graves, reales y de gran impacto que afectan la salud global del negocio.

Lo más grave que puede suceder, y realmente ocurre en lugares que se basan en enfoques intuitivos o únicamente en la historia, es la aparición de una crisis silenciosa pero creciente. Económicamente, el efecto es inmediato y grave, dado que, el capital de trabajo que debería estar fluyendo para mejorar otras áreas se encuentra atrapado en botellas, latas y cajas que nadie utiliza. La retención de recursos ahoga la liquidez, restringiendo la habilidad de reaccionar ante oportunidades o situaciones inesperadas. Sin embargo, el perjuicio no se detiene allí. Una parte considerable de ese inventario inactivo tiene fecha de vencimiento. Ciertos productos específicos como las cervezas, vinos, refrescos, aguas y jugos se convierten posteriormente en capital inmovilizado de estos activos sin movimientos.

Esto no se trata únicamente de pérdidas de ventas en el presente; es un asunto de posicionamiento de marca a largo plazo que aleja a los clientes más valiosos y atentos a las tendencias.

Bajo esta premisa, el sector hotelero ecuatoriano, ha demostrado ser partícipe de transformaciones sustanciales a lo largo de los últimos años, dado al incremento de afluencia de visitantes en el sector turístico y crecimiento competitivo entre otros establecimientos hoteleros. En este escenario, se les exige a las organizaciones a mantener altos estándares de calidad en atención al huésped, asimismo, deben fortalecer constantemente todos los procesos a su alcance, tanto administrativos como protocolos internos, dado que su eficiencia operativa subyace en gran medida, la sostenibilidad y rentabilidad del establecimiento. En ciudades de gran afluencia, como lo es la ciudad de Guayaquil, estas entidades se caracterizan por su convergencia entre los sectores comerciales, empresariales y turístico, la auto exigencia de optimizar sus estándares de servicios se intensifica en gran medida, obligándolos a tener una alta mejora en sus sistemas de control.

En este escenario, se encuentra uno de los hoteles con gran reconocimiento a nivel mundial, no obstante, su larga trayectoria y buen posicionamiento de mercado no lo libra de ciertas limitaciones que se encontró dentro de este establecimiento, donde empezó a evidenciarse deficiencias en la rotación de ciertos activos y en la estructuración de modelos predictivos durante los periodos 2024 y 2025. Estas deficiencias recaen tanto en el registro, como en el control de la información, lo que impide una visibilidad integral de la cadena de suministro y se dificulta identificar a los productos de rotación baja.

Por tanto, aparecen riesgos relacionados con la duplicación de tareas, los atrasos en los procesos, la falta de organización de los recursos y una capacidad reducida para

responder a situaciones inesperadas; esto puede tener un impacto indirecto en la calidad del servicio brindado y en la eficacia administrativa del establecimiento.

Objetivo de la investigación

Objetivo General

Analizar el comportamiento de la demanda de bebidas mediante la aplicación de técnicas estadísticas de predicción para estimar el inventario dormido en un establecimiento hotelero.

Objetivos Específicos

Identificar los fundamentos teóricos relacionados con el análisis predictivo y la gestión del inventario dormido.

Utilizar la metodología adecuada para analizar los datos del inventario de bebidas del hotel.

Evaluar los resultados obtenidos del análisis de rotación de bebidas para estimar el inventario dormido.

1.1 Pregunta de investigación:

¿Cuál es el comportamiento temporal que tiene el inventario dormido de bebidas en el hotel y cómo se puede proyectar su evolución en el año 2026 mediante modelos de series tiempo?

Justificación

El desarrollo de la presente investigación es de mucha importancia para el sector hotelero, por cuanto es uno de los elementos fundamentales dentro del área de servicios a nivel mundial, dado que funciona en un contexto donde la optimización de los recursos es fundamental para la rentabilidad y para prevenir la ineficiencia.

En este marco, la gestión de inventarios de bebidas es un proceso crítico con un impacto significativo, cuya precisión afecta directamente la salud financiera y la competitividad de las empresas. La capacidad de hacer coincidir la oferta con la demanda efectiva no es solo una ventaja operativa, sino también un requisito fundamental para la sostenibilidad, la reducción de residuos y la optimización del capital de trabajo. Los métodos sofisticados que permiten una gestión de inventario más cuidadosa y proactiva son una valiosa adición a las mejores prácticas de la industria, promoviendo modelos de gestión más sólidos y adaptados a la volatilidad inherente del turismo y los mercados de consumo.

La naturaleza de esta necesidad surge de la interacción específica entre las principales variables en la operación hotelera. Influidos por elementos como la ocupación, los perfiles de los visitantes, la estacionalidad y las promociones internas, los pedidos de bebidas están directa y cuantitativamente relacionados con el exceso de inventario no consumido. Una comprensión profunda de estas dinámicas nos permite superar un diagnóstico superficial y examinar con precisión cómo las diferencias de consumo se manifiestan en exceso de inventario, costos de inventario y liquidez reducida. Este tipo de análisis es crucial para revolucionar la administración de alimentos y bebidas, ofreciendo una base objetiva que sustituye la intuición por la evidencia y la reacción por una planificación fundamentada.

Este análisis ofrece una visión particular, tratándose esta conexión a través de un enfoque metodológico novedoso y concreto. Un análisis de la literatura especializada

de los últimos tres años muestra que, aunque existen estudios sobre la previsión de la demanda en el sector servicios y la investigación general sobre la gestión de inventarios, todavía no se ha creado un modelo integral que aplique técnicas de análisis predictivo para evaluar de manera proactiva el inventario inactivo que resulta directamente de la demanda de bebidas en un hotel.

Este estudio tiene como objetivo abordar ese vacío y proporcionar un marco analítico que vaya más allá de los pronósticos de ventas al utilizar estos pronósticos como un componente importante para evaluar el riesgo de obsolescencia del inventario. Por lo tanto, la contribución es doble: crea conocimiento innovador, llenando un vacío en la investigación práctica y proporcionando una herramienta tangible que permite a los gerentes transformar datos pasados en un sistema de alerta temprana, simplificando las decisiones de compra y reemplazo que optimizan los recursos y fortalecen la eficiencia operativa del hotel.

Delimitaciones y Limitaciones

Delimitaciones

El presente estudio, se desarrolla en un establecimiento hotelero reconocido en la ciudad Guayaquil, fundamentándose exclusivamente en la información institucional suministrada. Esta investigación no abarca un análisis contrastivo con otros hoteles, ni entidades dentro de su mismo sector, el sector turístico, dado que el principal propósito es realizar un análisis profundo real de esta organización como objeto de estudio en específico. Como delimitación, el enfoque es analizar un entorno en concreto, que busca garantizar una alta precisión al interpretar los resultados obtenidos. Este análisis se enfoca en los periodos que se encuentran entre los años 2024 y 2025, de esta forma, se considera estos intervalos temporales como una base que evalúa los comportamientos de los registros y tendencias de esta área, en este caso, el inventario del hotel.

Limitaciones

Calidad de la base de datos

Una de las limitaciones que se encontró al recibir la base de datos, fue la condición inicial de la data proporcionada, dado que esta información carecía de una buena organización o normalización previa. Debido a ello, fue necesario ejecutar un proceso de depuración y reestructurar los registros de los periodos a fin de construir una serie temporal robusta. Consecuentemente, esto implicó usar una mayor inversión de tiempo y cierto grado de incertidumbre en la precisión de determinados registros pasados.

Alcance de Productos

Esta investigación se delimitó exclusivamente en el análisis de las tres principales categorías del inventario de bebidas alcohólicas de este establecimiento, dado que no fue posible trabajar en su totalidad con los datos esperados en la categoría de bebidas soft, la base de datos de en esta sección solo mostraba el registro histórico de un único producto, por lo que, se dificultó realizar un análisis representativo de esta categoría. Bajo esta lógica, los resultados obtenidos muestran únicamente el comportamiento temporal de los licores, cuyas categorías son vino, licores fuertes y cervezas.

CAPÍTULO 2:

MARCO TEÓRICO

Gestión de Inventarios en la Industria Hotelera

La gestión de inventarios en la industria hotelera ha evolucionado en la última década desde una actividad operativa rutinaria hacia una función estratégica basada en datos. Estudios recientes muestran que la predicción de la demanda y las técnicas basadas en inteligencia artificial y series de tiempo han adquirido un papel central en la toma de decisiones operativas y de revenue management, permitiendo anticipar patrones de ocupación y consumo que condicionan directamente los niveles de inventario de bebidas y alimentos (Henriques & Nobre Pereira, 2024). Esta transformación no responde únicamente a la disponibilidad de nuevas herramientas analíticas, sino también a la necesidad de reducir desperdicios, optimizar el capital de trabajo y mejorar la experiencia del huésped en entornos altamente variables, como temporadas altas, eventos especiales o cierres imprevistos.

En la práctica, la gestión actual de inventarios en hoteles combina distintas fuentes de información: registros históricos de ventas, reservas y niveles de ocupación, datos sobre eventos locales y campañas de marketing, e incluso variables externas como el clima, la movilidad o las tendencias de búsqueda en internet. (Pereira & Cerqueira, 2022) evidencian que los modelos que incorporan la segmentación de establecimientos y variables exógenas logran mayor precisión en las proyecciones a corto y mediano plazo. Esto resulta clave para ajustar pedidos, definir puntos de reposición y evitar tanto el desabastecimiento como el exceso de inventario. En contextos reales de operación, esta capacidad de anticipación disminuye la dependencia de decisiones basadas únicamente en la experiencia y favorece una planificación más precisa, especialmente en el área de alimentos y bebidas.

Uno de los enfoques más relevantes en el estudio de inventarios hoteleros es la incorporación de la predicción de la demanda basada en modelos estadísticos y econométricos. Este procedimiento permite ajustar de forma acertada los niveles de stock en productos perecederos y no perecederos, reduciendo pérdidas por vencimiento o exceso de inventario. Tal enfoque ha sido documentado en (Triana Mora, 2023) que analiza cómo el ajuste del inventario con base en predicciones mejora la eficiencia operativa y reduce los costos de almacenamiento en hoteles que enfrentan variaciones estacionales pronunciadas en la demanda de alimentos y bebidas.

1.2 Conceptos fundamentales de inventario: stock activo, inactivo y dormido

El inventario es el conjunto de bienes almacenados por una organización para su uso o venta en el curso normal de sus actividades. Con respecto a la hotelera, se trata de alimentos, bebidas, provisiones operativas y suministros diversos, todos los cuales deben categorizarse correctamente para su gestión efectiva. El inventario activo es el stock de productos que tiene rotación constante y en línea con la demanda real del establecimiento. Para las bebidas, se caracteriza por el hecho de que deben consumirse regularmente, deben reponerse regularmente y contribuir directamente a los ingresos del hotel (Triana Mora, 2023).

La adecuada identificación del stock activo permite optimizar los procesos de compra y minimizar el riesgo de quiebres de stock. Por otro lado, el inventario dormido está conformado por productos que, si bien no se encuentran vencidos u obsoletos, presentan una baja rotación durante un periodo determinado. Este tipo de inventario tiende a acumularse cuando las decisiones de compra se apoyan en proyecciones poco precisas, cuando cambian las preferencias de los consumidores o cuando el establecimiento modifica su oferta gastronómica (Triana Mora, 2023).

En el contexto hotelero, el inventario se define como el conjunto de bienes almacenados para su uso o venta futura, entre los cuales se distinguen diversas categorías funcionales.

Tradicionalmente, los estudios de gestión de inventarios distinguen entre *stock* activo, categorías que permiten clasificar los bienes según su frecuencia de rotación y utilización dentro de las operaciones del hotel.

El inventario dormido representa la forma más crítica de ineficiencia en la gestión de inventarios. Se trata de productos que permanecen almacenados durante largos periodos sin registrar movimiento, convirtiéndose en capital inmovilizado. En hoteles, este fenómeno es particularmente frecuente en bebidas específicas que dejan de ser demandadas, ediciones limitadas, productos asociados a temporadas específicas o marcas que han sido desplazadas por nuevas tendencias de consumo (Triana Mora, 2023).

Costos asociados a la mala gestión de inventarios: capital inmovilizado, obsolescencia, almacenamiento

Los costos asociados a una mala gestión de inventarios son diversos y afectan tanto la operación como la salud financiera del hotel. Uno de los impactos más evidentes es el capital inmovilizado, que ocurre cuando los recursos financieros quedan atrapados en productos que no se rotan. Este capital podría utilizarse en otras áreas estratégicas del hotel, como la mejora de servicios, la capacitación del personal o inversiones en tecnología (Hospitality Institute, 2025).

La obsolescencia y el deterioro representan costos significativos en los inventarios de alimentos y bebidas. Cuando los productos no se utilizan antes de su fecha de vencimiento, se generan pérdidas directas que afectan los resultados financieros del establecimiento. El problema se acentúa cuando no se aplican sistemas adecuados de rotación por fechas o cuando los pedidos no se ajustan a proyecciones de demanda más realistas (Takahashi, 2025).

Por otra parte, los costos de almacenamiento crecen a medida que aumenta el volumen de inventario. El uso de espacio físico, la supervisión del personal encargado y los gastos asociados a la refrigeración o conservación implican mayores desembolsos cuando se mantiene un *stock* elevado. A ello se suman efectos menos visibles, como ineficiencias en la operación y posibles desajustes entre la oferta disponible y las expectativas del huésped, lo que puede afectar la calidad percibida del servicio. Una mala gestión de inventarios afecta igualmente la satisfacción del huésped y la reputación del hotel, aspectos que, aunque de naturaleza cualitativa, terminan reflejándose en pérdidas económicas a largo plazo, reduciendo las reservas repetidas y deteriorando la percepción global del servicio (Takahashi, 2025).

Particularidades del inventario de alimentos y bebidas (F&B) en hoteles: perecederos, estacionalidad, demanda impulsada por eventos.

El inventario de alimentos y bebidas en hoteles presenta retos particulares que lo diferencian de otros sectores de inventario; por un lado, la perecibilidad de los productos obliga a un seguimiento riguroso de fechas de caducidad y condiciones de almacenamiento, dado que el deterioro rápido genera desperdicio y pérdidas económicas. Por otro lado, la estacionalidad de la demanda afecta de manera significativa la rotación de inventarios, ya que en temporadas altas hay picos de consumo que requieren mayores existencias, mientras que en periodos bajos el riesgo de acumulación aumenta (Hospitality Institute, 2025).

Los hoteles no funcionan de manera aislada. Eventos locales como convenciones, festivales o ferias pueden provocar cambios repentinos en la demanda de alimentos y bebidas. Estas variaciones obligan a apoyarse en registros históricos de ocupación y consumo para anticipar mejor los requerimientos reales. Con base en esa información,

es posible ajustar los niveles de inventario y evitar tanto el desabastecimiento como la acumulación innecesaria de productos.

El inventario dormido detallado

Conceptualización del inventario dormido

El inventario dormido, también denominado slow-moving stock o dead stock, se refiere a aquellos bienes que permanecen en almacén por períodos prolongados sin registrar movimientos significativos de salida. Este tipo de inventario se caracteriza por una demanda irregular, lenta o casi nula, lo que lo distingue de los productos de alta rotación que se consumen con frecuencia. En la industria hotelera, el inventario dormido puede manifestarse en bebidas específicas, insumos para eventos temporales o productos considerados obsoletos debido a cambios en las preferencias de los huéspedes o estacionalidad de consumo (Jenkins, 2025),

El Hospitality.Institute expresa que la conceptualización de inventario dormido mantiene principios similares: representa capital inmovilizado que no contribuye a la eficiencia operativa ni a la generación inmediata de ingresos, y su acumulación indica fallas en la previsión y planificación de la demanda. Este tipo de stock no sólo ocupa espacio físico y recursos de almacenamiento, sino que también puede deteriorarse o perder valor si se trata de productos perecederos o con fecha de caducidad tipo clasificación C bajo análisis ABC/XYZ (Jenkins, 2025).

Métricas para su identificación: tasa de rotación (inventory turnover), días de inventario disponible (DIO), análisis ABC/XYZ

Identificar el inventario dormido es un reto operacional clave para cualquier establecimiento hotelero, ya que implica distinguir qué artículos dejan de aportar valor al negocio y generan costos innecesarios. Las métricas de rotación de inventario son herramientas cuantitativas que permiten medir la frecuencia con la que un producto se

vende o utiliza en un periodo determinado, y así detectar aquellos elementos que no se mueven con la agilidad esperada, según (Hospitality Institute, 2025).

Entre las métricas más utilizadas se encuentran: Tasa de rotación con su expresión matemática: $\text{Empleados que se separaron} / \text{Promedio de empleados} \times 100$, que relaciona el costo de los bienes vendidos con el inventario promedio, ofreciendo una visión sobre cuántas veces se renueva el stock en un periodo. Valores bajos pueden indicar presencia de inventario lento o dormido. Días de inventario disponible, mismo que refleja cuántos días tarda un inventario en convertirse en venta o consumo, siendo un indicador directo de la eficiencia del manejo del stock.

El análisis ABC/XYZ combina dos criterios de clasificación. Por un lado, el método ABC organiza los productos según su valor y volumen dentro del inventario; por otro, el método XYZ los clasifica de acuerdo con la variabilidad y previsibilidad de la demanda. Al integrarlos, se facilita la priorización de acciones sobre distintas categorías, diferenciando artículos de alto valor y alta rotación de aquellos de bajo valor y consumo incierto, que pueden convertirse en inventario dormido.

Aplicar este enfoque en el área de bebidas, por ejemplo, permite distinguir entre productos esenciales con salida constante y aquellos que se venden esporádicamente. Esta segmentación respalda decisiones más fundamentadas en torno a descuentos, promociones o incluso la discontinuación de ciertos ítems (Hospitality Institute, 2025).

Causas raíz en el contexto hotelero: sobrecompra, pronósticos deficientes, cambios en tendencias de consumo, gestión de menús

La acumulación de inventario dormido en hoteles no ocurre de forma aislada; suele ser el resultado de múltiples factores interrelacionados que reflejan fallas en los procesos de planificación, compras y adaptación al entorno del mercado. Una de las causas más frecuentes es la sobrecompra, que ocurre cuando los responsables de inventario

adquieren bienes sin una alineación adecuada con las previsiones de demanda o sin considerar variaciones estacionales y eventos específicos. Esta práctica puede provocar que productos que anteriormente tenían rotación activa queden sin salida frente a nuevas tendencias de consumo o cambios en el perfil de los huéspedes (Jenkins, 2025).

Los pronósticos deficientes también son una de las causas raíz del inventario dormido. Cuando las predicciones de consumo basadas únicamente en datos históricos no incorporan variables exógenas relevantes, como eventos locales, patrones de temporada, clima o tendencias emergentes, los pedidos pueden sobreestimar o subestimar la demanda real. Esta falta de precisión en las predicciones aumenta la probabilidad de mantener productos en stock que no se utilizarán oportunamente (Jenkins, 2025). Asimismo, los cambios en las tendencias de consumo pueden dejar inventario obsoleto si no hay una revisión continua de la oferta de productos. Por ejemplo, una marca de bebidas que era popular en un año puede dejar de serlo al siguiente debido a preferencias cambiantes de los huéspedes, sin que se ajuste el inventario de manera oportuna.

Análisis predictivo y series de tiempo

Fundamentos del análisis predictivo: de lo descriptivo a lo prescriptivo

El análisis predictivo parte de una idea sencilla: usar el pasado para anticipar el futuro. En la práctica hotelera esto significa transformar registros históricos de reservas, ocupación y ventas en pronósticos que guíen decisiones operativas tipo compra, personal, promociones y estratégicas como precios, alianzas, campañas (Wu et al., 2023). Actualmente, el análisis predictivo va más allá de la simple extrapolación de series históricas. Incorpora métodos estadísticos, técnicas de aprendizaje automático y diversas fuentes de información, como tendencias de búsqueda en internet, eventos locales o condiciones climáticas, para generar estimaciones con distintos niveles de confianza e identificar qué variables influyen con mayor peso en los resultados. Esta

evolución lo posiciona no solo como una herramienta para describir comportamientos pasados, sino también para orientar decisiones futuras.

Modelos de pronóstico: suavizamiento exponencial (holt-winters), ARIMA, Modelos de Regresión

Dentro de los métodos tradicionales de series temporales, el suavizamiento exponencial, incluido el modelo de *Holt-Winters*, y los modelos ARIMA o SARIMA continúan siendo ampliamente utilizados por su sencillez y buen desempeño cuando los datos presentan estacionalidad. En series con patrones estacionales definidos y suficiente información histórica, estos enfoques generan pronósticos consistentes, fáciles de interpretar y con requerimientos computacionales relativamente bajos. No obstante, su eficacia disminuye cuando se producen cambios estructurales en la serie, como alteraciones abruptas en el comportamiento de la demanda (Kumar et al., 2024).

La importancia de los datos históricos, la estacionalidad y las variables exógenas (ocupación hotelera, eventos locales, clima)

Los pronósticos precisos dependen de tres pilares: datos históricos de calidad, captura correcta de estacionalidad y consideración de variables exógenas que afectan la demanda. Datos limpios, con granularidad adecuada que sea diaria o semanal según el horizonte y etiquetados con eventos como ferias, congresos, cierres permiten a los modelos distinguir patrones repetitivos de señales puntuales. (Wu et al., 2023) encuentra que añadir variables externas como Google Trends, indicadores económicos, variables meteorológicas, calendario de eventos, mejora sustancialmente la precisión de los pronósticos en turismo y hotelería

Además, (Lee, 2025) expresa que puede capturar relaciones no lineales y efectos complejos entre variables; no obstante, su ventaja real aparece cuando se dispone de

datos múltiples y homogéneos. Para hoteles pequeños o con series cortas, los modelos clásicos bien parametrizados siguen siendo una opción robusta y operativa.

Técnicas de Machine Learning Aplicadas a la Demanda

Algoritmos supervisados para pronóstico: Random Forest, Gradient Boosting (XGBoost), Redes Neuronales Artificiales simples (MLP)

En los últimos cinco años, la adopción de algoritmos de aprendizaje supervisado para pronosticar la demanda hotelera ha crecido notablemente. Técnicas como Random Forest y Gradient Boosting suelen ofrecer buena precisión en series diarias o semanales cuando existe una base de datos suficiente y variables explicativas como ocupación, tarifas, eventos. Su ventaja operativa es doble: manejan relaciones no lineales y permiten cierto grado de interpretabilidad mediante la importancia de variables, lo que facilita que un gerente entienda por qué cambia una predicción (Henriques & Nobre, Modelos y métodos de pronóstico de la demanda hotelera mediante inteligencia artificial: Una revisión sistemática de la literatura, 2024).

Por su parte, redes neuronales y arquitecturas recurrentes resultan útiles cuando la serie tiene dependencia temporal compleja o cuando se incorpora texto tipo reseñas y señales no estructuradas (Kozlovskis et al., 2023). Las redes capturan patrones sutiles, pero requieren más datos y cuidado en el preprocesamiento para evitar sobreajuste. En la práctica hotelera, la elección entre árboles, boosting o redes depende del volumen de datos, la necesidad de interpretabilidad y la infraestructura disponible.

Procesamiento de datos para modelos predictivos: manejo de outliers, imputación de datos, escalado de variables

El rendimiento de cualquier modelo se apoya en la calidad del dato; antes de entrenar, es crucial “limpiar” datos de series temporales, detectar y tratar posibles outliers: picos por eventos extraordinarios, e imputar faltantes con técnicas apropiadas como

interpolación, modelos basados en vecino más cercano o métodos estadísticos. Además, al combinar fuentes: reservas online, Google Trends, es vital normalizar y alinear las frecuencias temporales y etiquetar eventos como variables exógenas (Henriques & Nobre, Modelos y métodos de pronóstico de la demanda hotelera mediante inteligencia artificial: Una revisión sistemática de la literatura, 2024).

También, el tratamiento de series intermitentes para productos como cervezas especiales, ediciones limitadas requieren técnicas específicas, por ejemplo, descomposición en frecuencia o modelos para demanda intermitente para que los modelos no interpreten la baja frecuencia como ruido irrelevante (Kozlovskis et al., 2023). Validación de modelos: métricas de error (MAE, MAPE, RMSE), cross-validation temporal.

Evaluar modelos predictivos implica usar métricas que reflejen la naturaleza del problema, por ejemplo, en inventarios y demanda, MAE (*Mean Absolute Error*) y RMSE (*Root Mean Squared Error*) son comunes; MAPE resulta intuitivo, pero sufre con valores cercanos a cero. Para series temporales la validación tradicional aleatoria es inapropiada: se recomienda *cross-validation* temporal (*time-series split*) que respeta el orden cronológico y simula pronósticos reales. Además, es buena práctica comparar modelos mediante pruebas fuera de muestra y revisar intervalos de predicción con bandas de confianza para calcular *stock* de seguridad (Henriques & Nobre, 2024).

Otro aspecto clave es la interpretabilidad: modelos más precisos pero opacos requieren técnicas como, análisis de contribución, para explicar predicciones y ganar confianza operacional, así lo analiza (Contessi, Viverit, Pereira, & Heo, Decoding the futurProposing an interpretable machine learning model for hotel occupancy forecasting using principal component analysis, 2024) quien afirma que en hotelería ven la

interpretabilidad como requisito para la adopción gerencial, porque facilita acciones concretas.

Integración del Pronóstico en la Gestión de Inventarios

Modelos de revisión de inventarios: sistemas periódicos vs. continuos bajo demanda probabilística

(Hao, 2024) distingue dos enfoques operativos: revisión periódica cuando se realizan pedidos en intervalos fijos y revisión continua cuando se repone cuando el inventario cae por debajo de un punto de reorden. Cuando la demanda se pronostica con precisión, ambos sistemas pueden optimizarse; sin embargo, para hoteles con variaciones estacionales marcadas y productos perecederos, una revisión híbrida: periodicidad flexible combinada con alertas continuas sobre SKUs críticos, suele ser la opción más práctica.

El esquema probabilístico considera la incertidumbre de la demanda: en vez de fijar una cantidad única, calcula distribuciones y escenarios, por ejemplo, para definir puntos de reorden y cantidades óptimas permitiendo adaptarse a picos vinculados a eventos (Kırmızı y otros, 2024).

Determinación de puntos de reorden (ROP) y niveles de stock de seguridad usando pronósticos

Pérdidas y el stock de seguridad pueden diseñarse con base en pronósticos probabilísticos: usando el error histórico del modelo y la distribución de la demanda se calcula la cantidad necesaria para cubrir variabilidad durante el lead time. (Kırmızı, Ceylan, & Bulkan, Enhancing inventory management through safety-stock strategies—A case study, 2024) proponen enfoques que combinan pronósticos de corto plazo con simulaciones de distintos escenarios para definir niveles de inventario de seguridad que reduzcan el costo total, entendido como la suma del costo de mantener stock y el costo

asociado a quiebres. En el ámbito hotelero, se sugiere revisar y ajustar el punto de reorden de manera periódica, ya sea mensualmente o según la temporada, para adaptarlo a los cambios en la demanda (Hao, 2024).

Estrategias para reactivar el inventario dormido (bundling, tácticas, donación controlada)

Cuando el inventario dormido ya se ha acumulado, la literatura especializada plantea estrategias complementarias. Entre ellas se encuentran la venta conjunta de productos de baja rotación con artículos de alta demanda, promociones prorrientadas a acelerar la salida de determinados ítems y ajustes en el menú para incorporar insumos próximos a vencer en nuevas preparaciones. También se contempla la donación regulada, cuando la normativa lo permite, como una alternativa que contribuye a reducir pérdidas y fortalecer prácticas sostenibles. (Rakholia et al., 2025) muestran que campañas coordinadas entre compras, cocina y marketing recuperan parte del valor estancado y liberan espacio físico. Además, estas tácticas deben ir acompañadas de revisión de compras y contratos con proveedores como condiciones de devolución, compras más flexibles, para reducir la recurrencia del problema.

Marco conceptual: Glosario de Términos Operativos

Inventario dormido

Se entiende como inventario dormido aquel conjunto de productos que, aun encontrándose en condiciones físicas utilizables, presentan una rotación nula o extremadamente baja durante un periodo prolongado. En el ámbito hotelero, este tipo de inventario suele surgir cuando los insumos dejan de responder a la demanda real del huésped, permaneciendo almacenados sin generar valor operativo ni financiero. Su permanencia implica costos ocultos asociados al almacenamiento, deterioro y pérdida de liquidez (Pereira & Cerqueira, 2022).

Rotación de inventarios

La rotación de inventarios es un indicador que expresa la frecuencia con la que los productos son utilizados o vendidos dentro de un periodo determinado. En hoteles, una rotación adecuada refleja alineación entre compras, consumo y oferta gastronómica, mientras que niveles bajos pueden evidenciar sobreabastecimiento o fallas en la planificación de la demanda (Henriques & Nobre, Modelos y métodos de pronóstico de la demanda hotelera mediante inteligencia artificial: Una revisión sistemática de la literatura, 2024).

Pronóstico de demanda

El pronóstico de demanda se refiere al proceso sistemático de estimar el consumo futuro de bienes o servicios a partir de datos históricos y variables contextuales. En la industria hotelera, este concepto es clave para anticipar necesidades de insumos considerando factores como ocupación, estacionalidad, eventos locales y comportamiento del consumidor (Jenkins, 2025).

Nivel de servicio

El nivel de servicio representa la capacidad del sistema de inventarios para satisfacer la demanda sin incurrir en quiebres de stock. En F&B hotelero, mantener un nivel de servicio adecuado implica equilibrar disponibilidad de productos con control de costos y minimización de desperdicios (Jenkins, 2025).

Error de pronóstico

El error de pronóstico es la diferencia entre la demanda estimada y la demanda real observada. Su análisis permite evaluar la precisión de los modelos predictivos y ajustar las decisiones de compra, siendo un insumo fundamental para el cálculo del stock de seguridad (Henriques & Nobre, Modelos y métodos de pronóstico de la demanda hotelera mediante inteligencia artificial: Una revisión sistemática de la literatura, 2024).

Variables de Estudio y Relaciones Propias

Variable Independiente / Predictora: Pronóstico de demanda generado por modelos predictivos.

La identificación y articulación de las variables de estudio constituye un elemento central para comprender el fenómeno del inventario dormido en el contexto hotelero, particularmente en el área de alimentos y bebidas. En este proyecto investigativo, las variables han sido definidas de manera funcional, considerando tanto la lógica operativa del sector como los aportes recientes de los antecedentes científicos en gestión de operaciones y hospitalidad.

La variable independiente o predictora es el pronóstico de demanda generado por modelos predictivos. Esta variable hace referencia al uso de técnicas analíticas como estadísticas y de aprendizaje automático para estimar el consumo futuro de bebidas en función de datos históricos y variables contextuales. (Wu et al., 2025) sostienen que la calidad del pronóstico influye de forma directa en la toma de decisiones de compra y reposición, especialmente en entornos caracterizados por alta variabilidad de la demanda, como los hoteles. Un pronóstico con deficiencias suele generar un sobreabastecimiento, en contraste con uno preciso que contribuye a un uso eficiente del capital y del espacio en bodegas.

Variable dependiente o de respuesta: Nivel de inventario dormido (en unidades, dinero y día de cobertura).

La variable dependiente también llamada variable de respuesta, es básicamente el nivel de inventario dormido, medido en dinero, unidades y días de cobertura. Esta variable refleja el grado en que los productos almacenados dejan de cumplir una función operativa activa, convirtiéndose en recursos inmovilizados. En el ámbito hotelero, el inventario dormido no solo representa un costo económico, sino también una señal de

desalineación entre la oferta de productos y las preferencias reales del huésped (Henriques & Nobre, Modelos y métodos de pronóstico de la demanda hotelera mediante inteligencia artificial: Una revisión sistemática de la literatura, 2024).

La relación entre ambas variables es principalmente causal e inversa: en la medida en que se mejore la exactitud del pronóstico de la demanda, se espera que disminuya el nivel de inventario muerto. Sin embargo, esta asociación está mediada por una serie de variables intervinientes o de control, tales como la ocupación media del hotel, la estacionalidad, el precio por unidad, los eventos y el tipo de bebida. Estos elementos determinan cómo reacciona la demanda y, por lo tanto, afinan el efecto del pronóstico en la acumulación de inventario.

Variables Intervinientes o de Control

Tabla 1.
 Tabla sobre variables de control.

Variable	Tipo de variable	Definición conceptual	Definición operacional	Unidad de medida / Escala	Fuente de datos
Ocupación promedio del hotel	Interviniente / Control	Según, las habitaciones ocupadas en un periodo determinado, que refleja la intensidad de la demanda hotelera y	Promedio de ocupación registrado semanal o mensualmente durante el periodo de análisis.	Porcentaje (%) / Cuantitativa	Sistema de gestión hotelera (PMS)

			condiciona el			
			consumo de			
			alimentos y			
			bebidas.			
Temporada	Interviniente	Variaciones	Clasificación	Categoría	Registros	
	/ Control	recurrentes de	temporal del	nominal	históricos	
		la demanda	periodo		del hotel y	
		asociadas a	analizado		calendario	
		temporadas	según		turístico	
		altas, bajas y	temporada			
		patrones de	alta, baja o fin			
		consumo en	de semana.			
		fines de				
		semana.				
Precio	de Interviniente	Valor	Precio unitario	Dólares	Sistema	
venta	por / Control	monetario	promedio de	(USD)	/ POS	/
unidad	de	asignado a	cada bebida	Cuantitativa	Lista	de
bebida		cada bebida	registrada en		precios	
		ofrecida al	el sistema de			
		huésped, que	ventas.			
		influye en la				
		decisión de				
		consumo y en				

			la velocidad de rotación del inventario.							
Presencia de Interviniente	Existencia de Registro de Numérica	Agenda								
eventos en el / Control	eventos	eventos	Sí / No) o	del hotel /						
hotel o la	internos o	realizados en	Categórica	Calendario						
ciudad	externos que	el hotel o en la	de eventos							
	incrementan	ciudad durante	locales							
	temporalmente	el periodo de								
	la demanda de	estudio.								
	servicios									
	hoteleros y de									
	bebidas.									
Tipo de Interviniente	Clasificación	Agrupación de	Categórica	Inventario						
bebida / Control	del inventario	las bebidas en	nominal	F&B /						
	de bebidas	categorías	(cerveza,	Sistema de						
	según su	operativas	vino, licor,	almacén						
	naturaleza y	para el análisis	refresco,							
	patrón de	del inventario.	agua)							
	consumo.									

Nota. Elaboración propia. Fuente: Henriques y Nobre (2024).

Antecedentes de Investigación

A nivel Internacional

En el ámbito internacional, se desarrolló el estudio titulado Predictive analytics for food and beverage inventory optimization in hospitality operations, cuyo propósito fue examinar de qué manera el uso de modelos predictivos influye en la gestión de inventarios de alimentos y bebidas en el sector hotelero. La investigación analizó específicamente la relación entre la exactitud en los pronósticos de demanda y la disminución de sobreinventarios, con especial atención en productos de baja rotación, como determinadas bebidas. Metodológicamente, el trabajo se sustentó en una revisión sistemática de literatura y un análisis comparativo de modelos de series de tiempo y técnicas de aprendizaje automático aplicadas a datos reales de hoteles. Los resultados evidenciaron que la incorporación de variables como ocupación, estacionalidad y eventos locales mejora de forma significativa la rotación del inventario y disminuye el capital inmovilizado. Este antecedente internacional respalda directamente la presente investigación al demostrar que el análisis predictivo constituye una herramienta eficaz para reducir inventario dormido (Henriques & Nobre, Modelos y métodos de pronóstico de la demanda hotelera mediante inteligencia artificial: Una revisión sistemática de la literatura, 2024).

El segundo antecedente es la investigación en el estudio Optimizing inventory management through demand forecasting: A data-driven approach for enhanced supply chain efficiency, abordaron el problema del inventario lento y dormido desde una perspectiva cuantitativa basada en datos. El tema central de la investigación fue la aplicación de pronósticos de demanda como soporte a las decisiones de reposición en entornos de alta variabilidad. Para ello, los autores aplicaron modelos de series temporales y algoritmos de aprendizaje supervisado, y evaluaron su desempeño a través

de indicadores de error como el MAE y el RMSE. Los resultados evidenciaron una disminución importante del inventario de baja rotación y de los costos de almacenamiento en entornos de retail. Aunque el estudio no se circunscribe exclusivamente al sector hotelero, sus conclusiones resultan pertinentes para la gestión de bebidas en hoteles, donde la demanda también presenta estacionalidad y variaciones marcadas (Rakholia et al., 2025).

El tercer antecedente internacional corresponde a una revisión sistemática titulada *Tourism and hospitality forecasting with big data*, centrada en el análisis del uso de la analítica predictiva y el big data en la toma de decisiones dentro del sector turístico y hotelero. El trabajo examinó las principales tendencias metodológicas, las fuentes de datos empleadas y las aplicaciones prácticas del pronóstico en la operación hotelera. Para ello, se revisaron artículos científicos publicados en revistas de alto impacto, lo que permitió ofrecer una visión amplia sobre el desarrollo reciente del campo. Entre los principales resultados, se concluyó que los establecimientos que integran datos operativos internos con variables externas logran una planificación más eficiente de recursos, particularmente en áreas sensibles como alimentos y bebidas (Wu et al., 2025).

A nivel de Ecuador

Se desarrolló la investigación Optimización del manejo de inventarios de alimentos y bebidas en el sector hotelero mediante modelos econométricos, con el objetivo de mejorar la eficiencia del control de inventarios en un hotel urbano. El eje del estudio fue el uso de pronósticos de ventas como herramienta para disminuir pérdidas asociadas al exceso de inventario y a productos caducados. Se trabajó bajo un diseño de caso único, empleando modelos econométricos junto con un análisis de rotación de inventarios. Los hallazgos mostraron una reducción relevante del inventario inactivo y una mejora en el desempeño financiero del área de alimentos y bebidas. Este antecedente adquiere

especial importancia en el contexto ecuatoriano, ya que respalda la aplicación del análisis predictivo en hoteles del país (Triana Mora, 2023).

El segundo antecedente nacional examinó la relación entre el pronóstico de demanda y el control de inventarios en hoteles de categoría media, centrándose en cómo los modelos predictivos inciden en la gestión operativa. Para ello, se aplicaron modelos de regresión sobre datos históricos de ocupación y consumo. Los resultados indicaron que los establecimientos que no utilizan herramientas de pronóstico tienden a presentar mayores niveles de inventario inactivo y menor rotación. Este estudio aporta evidencia empírica que refuerza la relación directa entre pronósticos deficientes y acumulación de inventario dormido, aspecto clave para la presente investigación (Pereira & Cerqueira, 2022).

La tercera investigación está desarrollada en la Universidad Andina Simón Bolívar, ha abordado el análisis de la estacionalidad turística y su efecto en la rotación de inventarios de bebidas. Este estudio tuvo como tema principal “Análisis de la Evolución del Turismo y su Incidencia en el Desarrollo de Ecuador. Caso provincia de Manabí (2010-2014)”. Metodológicamente, se aplicaron análisis descriptivos y correlacionales sobre datos históricos de consumo. Los resultados evidenciaron que la falta de ajuste estacional en las compras genera acumulación de bebidas de baja rotación durante periodos de baja demanda, justificando la necesidad de incorporar modelos predictivos adaptados al contexto local (Pinto Hernández, 2022).

Marco Legal

El marco legal que regula la gestión de inventarios en establecimientos hoteleros en Ecuador comprende normas tributarias, contables, de salud e higiene, así como disposiciones específicas para la venta y almacenamiento de bebidas alcohólicas. Estas regulaciones aseguran que el manejo de inventarios se realice bajo estándares legales

que protegen tanto al consumidor como al cumplimiento de obligaciones fiscales y contables por parte de los hoteles.

Normativa sobre Control y Manejo de Bebidas Alcohólicas

La comercialización y manejo de bebidas alcohólicas en Ecuador están sujetas al pago de impuestos como el Impuesto a los Consumos Especiales (ICE) y al cumplimiento de procedimientos de control fiscal. Por ejemplo, El Servicio de Rentas Internas (SRI) determina la base imponible del Impuesto a los Consumos Especiales (ICE) en bebidas alcohólicas considerando los litros de alcohol puro y el precio de fábrica o ex aduana. Este criterio incide directamente en los costos y en el registro contable de las bebidas que manejan los hoteles. En consecuencia, los establecimientos deben mantener un control riguroso de sus compras y ventas para cumplir adecuadamente con las obligaciones tributarias (Asamblea Nacional, 2024).

La Ley de Régimen Tributario Interno (LRTI) establece que las bebidas alcohólicas, incluida la cerveza, están gravadas con el Impuesto a los Consumos Especiales (ICE) calculado sobre los litros de alcohol puro que contienen, y exige el cumplimiento del pago de este impuesto para poder comercializar los productos. En Ecuador, esta norma es de cumplimiento obligatorio para todos los establecimientos que venden bebidas alcohólicas como hoteles, bares y restaurantes, puesto que cualquier omisión en el control del ICE puede derivar en sanciones tributarias y afectar los registros de inventario (Servicio de Rentas Internas, 2010).

Además, el Reglamento para la aplicación de la Ley de Régimen Tributario Interno detalla cómo calcular la base imponible de bebidas alcohólicas y gaseosas según el volumen y contenido de alcohol o azúcar, así como la obligación del contribuyente de declarar y pagar el impuesto dentro de los plazos establecidos por el Servicio de Rentas

Internas (Servicio de Rentas Internas, 2010). Este marco regulatorio obliga al control sistemático del inventario físico y contable para cumplir con las obligaciones fiscales.

Regulaciones de venta y almacenamiento (impuestos, licencias).

La Ley de Régimen Tributario Interno también contempla que la comercialización de bebidas alcohólicas solo es legal si se ha cumplido con el pago del ICE y se han registrado los productos conforme a la normativa tributaria ecuatoriana. El artículo 118 de la Ley Orgánica de Régimen Tributario Interno prohíbe la comercialización de productos gravados con ICE que no hayan cumplido con el pago del impuesto correspondiente, vinculando así el manejo de inventario a un estricto control fiscal para evitar comercialización ilegal o prácticas irregulares (Servicio de Rentas Internas, 2010).

Normas de Salud e Higiene para Almacenes

Las disposiciones de salud e higiene para el almacenamiento de alimentos y bebidas en Ecuador son supervisadas por organismos como la Agencia Nacional de Regulación, Control y Vigilancia Sanitaria (ARCSA), la cual establece requisitos para almacenamiento seguro y evitar la contaminación de productos. Aunque muchas de estas normas están dirigidas principalmente a alimentos y productos farmacéuticos, la gestión de bebidas alcohólicas en hoteles también debe cumplir con condiciones sanitarias que aseguren su inocuidad durante el almacenamiento, protección de los consumidores y mitigación de riesgos por deterioro (Ministerio de Educación Pública, 2013).

La Ley Orgánica de Salud establece las disposiciones que regulan la supervisión y el control sanitario de los productos destinados al consumo humano, entre ellos los alimentos y bebidas que se almacenan y venden en establecimientos de atención al público, como los hoteles. La normativa exige que las actividades de producción,

importación, distribución, almacenamiento y comercialización cumplan con condiciones que aseguren la inocuidad y la seguridad para los consumidores (Ministerio de Educación Pública, 2015).

Condiciones sanitarias para el almacenamiento de bebidas.

Las condiciones sanitarias para el almacenamiento de bebidas requieren que las instalaciones mantengan limpieza, ventilación adecuada, control de temperatura y separación física de sustancias no compatibles, lo cual es exigido en normas de buenas prácticas sanitarias. El cumplimiento de estas condiciones contribuye a prevenir pérdidas por deterioro o contaminación de las bebidas, lo cual es vital para manejar de manera eficiente los inventarios y evitar inventario dormido por causas sanitarias (Servicio de Rentas Internas, 2010).

Regulaciones Contables y Fiscales Relacionadas con Inventarios

El Reglamento de Registro y Control Sanitario de Alimentos y sus derivados establecen que los productos destinados al consumo humano, incluidos algunos tipos de bebidas, deben contar con registro sanitario vigente y cumplir con buenas prácticas de almacenamiento para evitar contaminación, deterioro y riesgos para la salud. Esto obliga a los hoteles a mantener condiciones de higiene, ventilación y control de temperatura en bodegas donde se almacenan bebidas para prevenir pérdidas por deterioro (Ministerio de Educación Pública, 2013).

Normas locales NIC/NIIF

Valuación y provisión por obsolescencia de inventarios.

En Ecuador, las empresas elaboran sus estados financieros conforme a las Normas Internacionales de Información Financiera (NIIF), que rigen como marco contable obligatorio. Dentro de este conjunto normativo se encuentra la NIC 2 Inventarios, la cual establece los criterios para la medición y el reconocimiento de los inventarios, así

como el tratamiento de las pérdidas por deterioro cuando el valor neto realizable es inferior al costo registrado (Foundation, 2025).

Tratamiento fiscal (mermas por inventario no rotativo).

Desde el punto de vista tributario, las pérdidas derivadas de vencimientos, deterioro o baja rotación solo pueden considerarse deducibles en el impuesto a la renta si están debidamente respaldadas. Para ello, es necesario contar con documentación que sustente tanto la baja física como el valor contable de los productos retirados. Este requisito refuerza la importancia de mantener controles que permitan identificar a tiempo el inventario inactivo y gestionarlo de forma adecuada, tanto en el ámbito contable como en el fiscal (Asamblea Nacional, 2024).

CAPITULO:

METODOLOGÍA

Introducción

En este capítulo, se busca predecir la demanda de bebidas con baja rotación dentro del establecimiento hotelero en la ciudad de Guayaquil, a fin de estimar y reducir el inventario dormido, ese dead stock que dificulta, en muchos escenarios, la liquidez del negocio. En el sector hotelero de Ecuador, existe una amplia variación por temporadas, así como grandes picos en feriados, lo que provoca que las compras no concuerden con lo que se consume realmente. Esto resulta en acumulación de productos que superan su fecha de consumo o simplemente no rotan, como vinos caros, licores fuertes o cervezas especiales, que pasan de ser activos a problemas por caducidad o bajar de precio.

Alcance

Es de tipo explicativo y proyectivo, pero con un enfoque específico. Por lo que usa datos de los años 2024-2025 para armar modelos, y se extiende una predicción para el año 2026, con una temporalidad de 12 meses, que es lo mínimo requerido en pronósticos para hoteles. Geográficamente, se sitúa en un hotel de alto nivel en Guayaquil, en una zona comercial atractiva y turística. El tema, solo cubre bebidas alcohólicas de baja rotación, divididas en tres grupos: Cervezas, Licores Fuertes y Vinos, dejando fuera las de alta y media rotación. Incluye estacionalidad, KPIs de riesgo, clasificación de demanda y modelado mixto. No abarca compras o proveedores particulares, solo la diferencia interna entre lo que se abastece y lo realmente se usa.

Tipo de investigación

La investigación se tipifica como descriptivo y predictivo, dado que integra la proyección de futuros eventos con el análisis exhaustivo de la evolución histórica de los datos, basados en un modelo estadístico.

Es de tipo descriptivo puesto que tiene la finalidad de caracterizar y explicar la evolución del consumo en bebidas, movimientos y permanencia de estos en el inventario. En esta etapa, se realiza una revisión cronológica de los registros históricos para identificar ciertos patrones, tendencias o estacionalidades en los datos, dentro de las categorías de los productos. Mediante el análisis descriptivo se deriva un diagnóstico preciso del stock y de los movimientos que estos tienen dentro del hotel.

Asimismo, la investigación es de carácter predictivo, debido a que es orientado a realizar las estimaciones de los comportamientos que se darán a futuro sobre la demanda y la probabilidad de existencia de inventario dormido mediante técnicas de análisis de datos y por supuesto, de series de tiempo, permitiendo proyectar tendencias y reducir la incertidumbre para que, de este modo, exista una mejor planificación de compras y requisición de inventarios.

La adopción de un enfoque mixto en esta investigación se adecua al problema planteado inicialmente, debido que se busca comprender el diagnóstico actual del inventario y al mismo tiempo realizar proyecciones orientadas a fortalecer una gestión inteligente de los productos para mitigar el sobre stock de ítems de baja rotación. Bajo este enfoque, la investigación va más allá de la caracterización de datos y se guía hacia la facilitación de la toma de decisiones de forma estratégica dentro del establecimiento hotelero.

Enfoque de la Investigación

El presente trabajo investigativo se encuentra bajo un enfoque cuantitativo la cual se fundamenta en el análisis de registros históricos de consumo de bebidas dentro de este establecimiento hotelero. Este tipo de enfoque es caracterizado por el uso inteligente de modelos estadísticos, el análisis de datos e instrumentos de procesamiento estadístico y algoritmos de programación en Google Colab, orientadas a los fenómenos observados, así como el comportamiento de la demanda y rotación de productos en el inventario.

Dentro de este contexto, el enfoque cuantitativo es de gran relevancia dado que el principal objetivo de esta investigación consiste en identificar los patrones de comportamiento en el consumo de bebidas para estimar los productos con tendencia a la baja, siendo que estos se puedan convertir en los potenciales productos que, a futuro, se conviertan en inventario dormido. Esto requiere el uso de datos históricos y por ende la aplicación de técnicas como lo son las series de tiempo, del mismo modo, este tipo de enfoque busca facilitar la elaboración de indicadores o KPIs (Key Performance Indicator) como la recencia de consumo, frecuencia de ventas o en este caso el porcentaje del potencial inventario dormido de forma mensual, estas constituyen una base para elaborar, posteriormente, los modelos predictivos.

Este enfoque, no se limita al análisis descriptivo del histórico de los productos, también a proyectar las futuras tendencias, debido que contribuyen a la toma de decisiones de forma estratégicas con relación a los inventarios, incluso en la posible optimización de los recursos dentro de este establecimiento.

Datos

Manejo confidencial de datos

El presente estudio basa su análisis en información primaria de carácter académico, obtenida específicamente mediante los registros de requisiciones del inventario de bebidas de un establecimiento hotelero de alto rango en su sector, ubicado en una zona atractiva en la ciudad de Guayaquil. Esta información fue proporcionada con fines académicos únicamente, y, por ende, se preserva la confidencialidad del establecimiento para garantizar el uso responsable de los datos.

Desglose de datos

Los registros adquiridos comprenden los años 2024 y 2025, los cuales abarcan un periodo de continuidad que permiten analizar el comportamiento histórico de la

demanda en bebidas para posteriormente construir series temporales robustas. Esta data fue almacenada y organizada de manera mensual en formato de Excel, con el fin de facilitar el tratamiento de los registros.

Esta base de datos comprende información de tipo operativa, obtenida de los movimientos internos del inventario, las cuales se ven relacionadas con las requisiciones realizadas por los distintos ambientes del hotel, siendo estos los bares, restaurantes o eventos. Bajo este contexto, la data obtenida, corresponden a salidas efectivas del inventario, construyendo un indicador indirecto de la demanda de bebidas dentro del hotel.

Variables	Descripción	Tipo	Uso en la investigación
Num. Requisición	Código único de la requisición	Cualitativa nominal	Control de los registros
Fecha de despacho	Fecha del producto despachado	Cualitativa ordinal	Construcción de serie temporal
Item	Código único del producto	Cualitativa nominal	Identificación para catalogo maestro
Descripción Item	Nombre del producto	Cualitativa nominal	Clasificación

Cantidad despachada	Número de unidad despachado	Cuantitativa continua	Cálculo de la demanda mensual
------------------------	-----------------------------------	--------------------------	-------------------------------------

Tabla 2: Desglose de los datos

Las variables mencionadas, son de alta importancia para realizar una correcta limpieza de los datos, clasificar de acuerdo con su categoría, construir series de tiempo, estimar cada nivel de rotación en el inventario y predecir el año siguiente.

Python

Trata de un programa sobre el lenguaje de programación, se lo selecciono por su habilidad manejando volúmenes significativos de datos, tanto así que puede realizar técnicas estadísticas complejas y asegurar que es análisis sea reproducible. El método de análisis cuantitativo en el que se enfoca lo convierte en una herramienta ampliamente utilizada durante la investigación aplicada, especialmente en los estudios de series temporales y el modelo de predicción, lo que refuerza su importancia en la estimación de la demanda de bebida en este estudio.

Librerías

Con bibliotecas como Pandas, NumPy, Python puede importar datos desde archivos Excel o CSV a estructuras de datos para realizar análisis estadísticos. En esta etapa se limpian y preparan los datos, manejando valores faltantes, identificando valores atípicos y convirtiendo variables categóricas en numéricas. Estas etapas garantizan la homogeneización de la información y la confiabilidad de los resultados (McKinney, 2010)

Pandas:

```
import pandas as pd
```

Herramienta enfocada en la manipulación y análisis de datos estructurados, se ha diseñado para trabajar con estructuras tabulares como DataFrame. Su capacidad le permite leer e integrar archivos en formatos como Excel, CSV, entre otros, además de limpiar, filtrar, transformar y agrupar datos. Dentro de esta investigación, pandas fue clave para consolidar los archivos de las requisiciones correspondientes al periodo 2024-2025, así mismo, a estandarizar las variables con las que se trabajó, manejar datos ausentes y construir las series temporales mensuales por su categoría (cerveza, vino y licor fuerte)

NumPy

```
import numpy as np
```

Es una librería destinada al cálculo numérico y a la gestión eficiente de matrices multidimensionales. La cual, ofrece funciones matemáticas optimizadas para realizar operaciones algebraicas, estadísticas y transformaciones de números. En esta investigación, Numpy permitió ejecutar las operaciones numéricas necesarias en la elaboración de las series temporales, junto con los cálculos intermedios empleados en la predicción final del modelo.

Matplotlib

```
import matplotlib.pyplot as plt
```

Es una librería de visualización de datos, que permite la creación de gráficos estadísticos ajustables. Su implementación permite la visualización de tendencias, patrones, variaciones y previsiones en los datos numéricos. Empleado a esta investigación, desempeñó el papel de trazar las series históricas de la demanda, observar el comportamiento mensual de categorías de las bebidas y mostrar las proyecciones producidas por el modelo SARIMA, donde se incluyeron los intervalos de confianza, el uso de este fue fundamental para analizar los resultados y comunicar los hallazgos de manera clara y analítica.

Unicodedata

```
import unicodedata
```

Esta librería permite normalizar los textos bajo el estándar Unicode, facilitando así la eliminación de acentos, caracteres especiales y fallos ortográficos. En estudios donde se utilizan bases de datos reales, pueden presentarse inconsistencias en la escritura de los nombres de los productos, esta herramienta es crucial para asegurar la coherencia de los datos. Dentro de la investigación, se la aplicó para normalizar las descripciones de los productos y prevenir errores de clasificación.

Re (Expresiones Regulares)

```
import re
```

La librería re, permite utilizar expresiones regulares, ya que es un método sofisticado para buscar, identificar y modificar patrones de texto. Dentro del marco metodológico de esta investigación, se lo empleo para clasificar los productos mediante palabras claves a las categorías de cerveza, vino y licores fuertes. La aplicación de esta librería facilitó la automatización de la categorización y la disminución del sesgo humano, lo que resulta fundamental en este estudio de análisis cuantitativo.

Statsmodels

```
from statsmodels.tsa.stattools import adfuller  
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf  
from statsmodels.tsa.arima.model import ARIMA  
from statsmodels.tsa.statespace.sarimax import SARIMAX
```

Es una librería dedicada al análisis econométrico y estadístico dentro de Python. Esta ofrece herramientas para la estimación de modelos lineales, análisis estadísticos y análisis de series temporales. En esta investigación se evaluó la estacionariedad de la serie mediante la prueba

Augmented Dicker-Fuller (ADF), se examinó las funciones de Autocorrelation (ACF) y la Partial Autocorrelation (PACF), y para evaluar el modelo SARIMA utilizado en la predicción de la demanda.

Limpieza de datos

Iniciando con la preparación del dataset, se realiza un riguroso proceso de depuración y la organización de estos, con la finalidad de garantizar la consistencia de los datos a utilizar. Los registros originales de las requisiciones de bebidas fueron proporcionados en varios archivos Excel, perteneciente a los períodos 2024 y 2025 para realizar el debido procesamiento.

Etapas preliminares

Cada mes se encontraba almacenado en un archivo Excel independientemente, debido a que estos archivos se construyeron con fines operativos y no analíticos, la estructura presentaba variaciones dentro de su formato.

Con anterioridad, se realizó la etapa preliminar de estandarización manual. Donde se revisaron todos los archivos originales con el objetivo de obtener una única base de datos mensual por el período 2024, y de igual manera para el 2025. Se verificó la correcta ubicación de los encabezados principales para asegurar la correcta lectura de las columnas; “fechas de despacho”, “Descripción del Ítem” y “Cantidad despachada”, dentro del entorno de programación.

Num				Unidad	Costo	Cantidad		Fecha Despacho
						Despacha	Total	
Requisicion	ítem	Descripción Ítem	Medida	Unitario		da		
		:						
		(						
		(						
		(						
REQ-		(						
00000		(						
00000		(						
06556	:	Old Par 12	Bot\	\$37			\$112	07/10/2
7	:	Años 750 ml	750	.34		3	.02	024
		:						
		(						
		(						
		(						
REQ-		(						
00000		(						
00000		(						
06556	:	Johnnie	Bot\	\$43			\$86.	07/10/2
7	(	Walker E N	750	.41		2	82	024
		:						
		(						
		:						
		:						
REQ-		(						
00000		(						
00000		(	Cerveza					
06556	(	Pilsener No	Unid	\$0.		2	\$18.	07/10/2
7	:	Ret	ad	76		4	24	024

	:							
	(							
	:							
	:							
REQ-	(							
00000	(							
00000	(	Cerveza						
06559	(	Pilsener	No	Unid	\$0.	1	\$9.1	07/10/2
2	:	Ret		ad	76	2	2	024
	:							
	(							
	:							
	:							
REQ-	(							
00000	(							
00000	(	Cerveza						
06559	(	Pilsener	No	Unid	\$0.	1	\$9.1	07/10/2
9	:	Ret		ad	76	2	2	024

Tabla 3: Variables principales

Etapas en Python

Luego de esto, se procedió a importar la base consolidada por cada año en una sola estructura tabular al entorno de análisis Python en Google Colab, se arrancó con la limpieza automatizada de los datos. Se constató la presencia de las variables fundamentales para este estudio y se procedió a la eliminación de aquellos datos que no presentaban valor alguno para este estudio.

La variable “**Fecha**” originalmente por los archivos de Excel se encontraba en formato texto, así que, para poder hacer uso de esta, se la convirtió a formato Datetime:

```
df["Fecha"] = pd.to_datetime(df["Fecha"])

df = df.sort_values("Fecha")
```

```
df = df.set_index("Fecha")
```

Cada registro individual se representa matemáticamente como:

$$r_i = (f_i, c_i, q_i)$$

Donde:

fi= Fecha

ci= Categoría del producto

qi= Cantidad requisada

Es decir, el conjunto de su base consolidada se definirá como:

$$R = \{r_1, r_2, \dots, r_n\}$$

Donde:

R= Base de datos completa

r1,r21...1m= Filas de registros individuales

N= Número total de registros

Posteriormente, se eliminaron las filas de los registros con fechas donde exista una cantidad nula para evitar distorsiones al momento de correr la serie temporal:

```
df = df.dropna(subset=["Fecha"])
```

Es decir, nuestra base depurada se define como:

$$R^* = \{r_i \in R \mid f_i^* \neq \emptyset\}$$

Donde:

R= Base de datos

ri= Registro de filas individual

fi*= Fecha con formato Datetime

$\emptyset$ = Valor nulo

Esto, garantizará una continuidad cronológica dentro del análisis. Y para asegurar su correcta estructura temporal, se ordenarán los datos en función a la fecha:

```
df = df.sort_values("Fecha")
```

Expresando matemáticamente, nuestra base se reorganizará de este modo:

$$f_1 \leq f_2 \leq \dots \leq f_n$$

La variable “**Descripción Ítem**” contenía el nombre original de cada producto registrado en el archivo de las requisiciones, en vista que los datos provenían de registros operativos reales, se consideró someterlos a un proceso de normalización textual que incluyó la conversión a mayúscula y eliminación de cualquier carácter especial.

Primero, nos aseguramos de que la variable se encontrara en formato string, para garantizar que las operaciones futuras se apliquen sin ningún error de tipo de dato:

```
df["Descripcion Item"] = df["Descripcion Item"].astype(str)
```

Por consiguiente, se implementó la librería Unicodedata a la columna “Descripcion Item” para eliminar los acentos y caracteres especiales:

```
import unicodedata

def limpiar_texto(texto):

    texto = unicodedata.normalize("NFKD", texto)

    texto = texto.encode("ascii", "ignore").decode("utf-8")

    return texto

df["Descripcion Item"] = df["Descripcion Item"].apply(limpiar_texto)
```

La representación original será d_i , pero al momento de aplicar la transformación pasará a:

$$d_i^* = \text{normalize}(d_i)$$

Donde aquella función de normaliza, eliminará discreticos y convertirá los caracteres a su forma ASCII (American Standard Code for Information interchange).

Para evitar duplicidad por diferencias entre “CERVEZA” y “cerveza”, se procedió a realizar la conversión a minúsculas:

```
df["Descripcion Item"] = df["Descripcion Item"].str.lower()
```

Su representación matemática será:

$$d_i^{**} = \text{lower}(d_i^*)$$

Para culminar con la normalización del texto, se eliminaron los espacios innecesarios que se mostraran al inicio o final del texto:

```
df["Descripcion Item"] = df["Descripcion Item"].str.strip()
```

Posteriormente, de realizar la normalización de la variable, se usó para clasificar los productos en sus 3 categorías principales:

Cerveza

Vino

Licor Fuerte

Mediante esta función aplicada:

```
import re
```

```
def clasificar_producto(texto):
```

```
    if re.search("cerveza|beer", texto):
```

```
        return "Cerveza"
```

```
    elif re.search("vino|wine", texto):
```

```
        return "Vino"
```

```
    else:
```

```
return "Licor Fuerte"
```

```
df["Categoria"] = df["Descripcion Item"].apply(clasificar_producto)
```

Formalmente, si $T(d_i)$ interpreta al conjunto de palabras que contiene la descripción;

$$C(d_i) = \begin{cases} \text{Cerveza} & \text{si } T(d_i) \cap P_{\text{cerveza}} \neq \emptyset \\ \text{Vino} & \text{si } T(d_i) \cap P_{\text{vino}} \neq \emptyset \\ \text{Licor Fuerte} & \text{en otro caso} \end{cases}$$

Donde:

C= Clasificación

di= Descripción del producto i

T(di)= Conjunto de palabras que tengan la descripción

$\emptyset$ = Conjunto vacío

La variable “**Cantidad despachada**” representa la cantidad de unidades que fueron requisadas por producto en cada registro, se aplicó un proceso de validación, transformación y agregación para garantizar su consistencia precio al modelado predictivo.

Se comprobó inicialmente que la variable se encontrara en formato numérico, ya que en los archivos de Excel pueden presentarse como texto debido a caracteres especiales o espacios:

```
df["Cantidad    Despachada"] = pd.to_numeric(df["Cantidad    Despachada"],
errors="coerce")
```

El parametro errors="coerce" transforma los valores no validos en NaN; permitiendo su manejo posterior.

Se eliminaron las filas de los registros donde exista una cantidad nula:

```
df = df.dropna(subset=["Cantidad Despachada"])
```

Esta nueva base depurada se definirá de la siguiente manera para evitar distorsiones en la agregación mensual:

$$R^* = \{r_i \in R \mid q_i^* \neq \emptyset\}$$

Donde:

R= Conjunto original de los registros

qi*= Cantidad despachada después del proceso de limpieza

∅= Valor nulo

ri= Registro individual del número i

Cada registro contiene información como:

$$r_i = (f_i, d_i, q_i)$$

Donde:

fi= Fecha

di= Descripción del producto

qi= Cantidad despachada

En caso de que aparezcan valores negativos por alguna devolución o ajuste contable dentro del registro operativo, se validaron los valores negativos o inconsistentes, siendo así que únicamente se consideraron valores positivos para el análisis de la demanda real:

$$df = df[df["Cantidad Despachada"] > 0]$$

Expresando matemáticamente, garantizara que la serie represente un consumo efectivo y no ajustes administrativos:

$$R^{**} = \{r_i \in R^* \mid q_i^* > 0\}$$

Donde:

R**= Base final luego de eliminar cantidad negativas o iguales a 0.

r_i = Registro individual del número i

R^* = Conjunto depurado sin valores nulos

q_i^* = Cantidad limpia despachada del registro i

Construcción del Catalogo Maestro

Después de la limpieza en la variable “Descripción Ítem”, se procederá a construir un Catálogo Maestro que incluye todos los productos únicos reconocidos en la variable “Descripción Item”. Este catálogo permitió la determinación del total de análisis y corroborar la cantidad de productos vigentes durante el periodo de estudio.

```
catalogo_maestro = df["Descripcion Item"].dropna().unique()  
len(catalogo_maestro)
```

Este catálogo constituye al análisis de rotación y detección del inventario dormido, se lo define como conjunto único de los productos previamente identificados en el estudio:

$$C = \{p_1, p_2, \dots, p_n\}$$

Donde:

p_i = Producto único identificado por su “Descripcion Item”

n = Total de producto distinto en el inventario histórico

Medición de rotación por producto

Por cada producto i , se calculó la rotación acumulada dentro del periodo completo:

$$R_i = \sum_{t=1}^T Q_{it}$$

Donde:

Q_{it} = Cantidad despachada del producto i en el mes t

$T = 24$ meses

En el colab se observará el código de esta manera:

```
rotacion = (  
    df.groupby("Descripcion Item")["Cantidad Despachada"]  
        .sum()  
        .reset_index()  
        .sort_values("Cantidad Despachada", ascending=False)
```

Clasificación de productos

Se implementa una clasificación de todos los productos, con el objetivo de darle una debida estructura a la información. De acuerdo con el tipo de bebida, se clasifican los productos en tres tipos de categorías: cervezas, vinos y licores fuertes, facilitando la organización de los datos para posteriores análisis del estudio.

Percentiles

Para prevenir criterios aleatorios, se implementó una categorización fundamentada en percentiles de la distribución de rotación total. Se calcularon los percentiles de:

P_{25} = Percentil 25

P_{75} = Percentil 75

Dentro del colab se observará el código:

```
p25 = rotacion["Cantidad Despachada"].quantile(0.25)
```

```
p75 = rotacion["Cantidad Despachada"].quantile(0.75)
```

Es decir, la clasificación será:

$$Nivel_i = \begin{cases} \text{Baja Rotación} & \text{si } R_i \leq P_{25} \\ \text{Alta Rotación} & \text{si } R_i > P_{75} \\ \text{Media Rotación} & \text{en otro caso} \end{cases}$$

Dentro del colab se observará el código: def clasificar_rotacion(x):

```
if x <= p25:
```

```
    return "Baja"
```

```
elif x > p75:
```

```
    return "Alta"
```

```
else:
```

```
    return "Media"
```

```
rotacion["Nivel Rotacion"] = rotacion["Cantidad Despachada"].apply(clasificar_rotacion)
```

Detección de productos dormidos

Uno de los focos principales de esta investigación fue detectar los productos que, aunque pertenecen al catálogo activo del hotel, no registraron movimiento a lo largo de los periodos prolongados, lo que ocasiona capital inmovilizado y riesgo de obsolescencia.

Base conceptual

Un producto dormido dentro de la gestión de inventarios no siempre es aquel que tiene baja rotación estructural, sino el que muestra ausencia de movimiento en un periodo temporal consecutivo relevante. Esto es relevante, puesto que un producto puede experimentar ventas bajas pero estables, mientras que otro puede mostrar periodos enteros de inactividad.

Elaboración de la matriz producto-mes

Para analizar el comportamiento individual mensual, se creó una matriz de tamaño n x T:

$$M_{i,t}$$

Donde:

$i = 1, 2, \dots, n$ representa el producto del catálogo maestro

$t = 1, 2, \dots$, representa el mes del período 2024-2025

$M_{i,t}$ = Cantidad despachada del producto i en el mes t

Dentro del entorno Colab, esta matriz se generó mediante:

```
pivot_prod = df.pivot_table(  
    index="Descripcion Item",  
    columns="Fecha",  
    values="Cantidad Despachada",  
    aggfunc="sum"  
).fillna(0)
```

Dentro del entorno de colab, cuando 3 meses son consecutivos se definirá como dormido:

```
dormidos = []
```

```
for producto in pivot_prod.index:
```

```
    serie = pivot_prod.loc[producto]
```

```
    zeros_consecutivos = (serie == 0).astype(int).rolling(3).sum()
```

```
    if (zeros_consecutivos >= 3).any():
```

```
        dormidos.append(producto)
```

Series temporales

Se realiza un análisis de series de tiempo de todos los productos con el objetivo de visualizar la evolución que han tenido las bebidas despachadas a lo largo de los periodos utilizados en el estudio. Asimismo, se ejecutan otras series, segmentado en las tres categorías previamente mencionadas, a fin de identificar qué diferencias existen en el

comportamiento de la demanda dentro de los distintos productos que el hotel oferta. En este sentido, los datos se ejecutan de manera agrupada de forma mensual, iniciando con su primer registro hasta el último observado, a fin de generar una cronología de todos meses, facilitando la comparativa entre los dos distintos períodos mencionados.

Serie mensual de total despachado

Esta serie de total de despachado por mes fue la primera serie que se realizó, matemáticamente la definimos como:

$$Q_{total,t} = \sum_{i=1}^n Q_{it}$$

Donde:

Q_{it} = Cantidad despachada del producto i en el mes t

n = Número total de productos

Dentro del notebook, esta serie se generó mediante este código:

```
mensual_total = (
    df.groupby(pd.Grouper(key="Fecha", freq="MS"))["Cantidad Despachada"]
    .sum()
    .reset_index())
```

Serie mensual de productos de baja rotación

Luego, se construyó la serie de los productos que tenga baja rotación mensualmente para analizar el comportamiento estructural, donde matemáticamente lo detallamos como:

$$Q_{baja,t} = \sum_{i \in Baja} Q_{it}$$

Dentro del notebook, esta serie se generó mediante este código:

```
serie_baja = (
```

```
df_baja.groupby(pd.Grouper(key="Fecha", freq="MS"))["Cantidad Despachada"]
.sum()
.reset_index()
```

Serie mensual del porcentaje de baja rotación

Su objetivo es valorar el peso relativo de la baja rotación en el total despacho, se estableció el indicador:

$$\text{pct_baja}_t = \frac{Q_{baja,t}}{Q_{total,t}}$$

En el entorno colab, el porcentaje de baja rotación se calculó mediante:

```
mensual_merge = mensual_total.merge(
    serie_baja,
    on="Fecha",
    how="left",
    suffixes=("_total", "_baja")
)
```

```
mensual_merge["Cantidad Despachada_baja"] = mensual_merge["Cantidad
Despachada_baja"].fillna(0)
```

```
mensual_merge["pct_baja"] = np.where(
    mensual_merge["Cantidad Despachada_total"] > 0,
    mensual_merge["Cantidad Despachada_baja"] / mensual_merge["Cantidad
Despachada_total"],
    0)
```

Serie mensual de productos dormidos

Nuestra variable central de este modelo predictivo, el número de productos dormidos por mes se definirá como:

$$D_t = \sum_{i=1}^n I(Q_{it} = 0)$$

Y dentro del colab, se elaboró junto con la matriz producto-mes:

```
conteo_dormidos = pivot_prod.apply(  
    lambda col: (col == 0).sum(),  
    axis=0  
).reset_index()
```

```
conteo_dormidos.columns = ["Fecha", "Dormidos"]
```

Posteriormente, se definió la serie de tiempo que se utilizara para la modelación:

```
serie_modelo = conteo_dormidos.set_index("Fecha")["Dormidos"].asfreq("MS")
```

Análisis de autocorrelación

Previo al modelo de pronóstico, se ejecuta un análisis de autocorrelación de la serie temporal a fin de examinar la existencia de algún tipo de relación interna entre los valores registrados en los distintos períodos de tiempo. Esto nos permite valorar dependencias dentro del histórico de datos para reconocer patrones o comportamientos cíclicos, dando un aporte técnico para el ajuste del modelo de pronóstico.

Se analizaron las funciones de autocorrelation (ACF) y autocorrelation partial (PACF) para reconocer la estructura autoregresiva y de media móvil, dentro de nuestro notebook se lo corrió mediante el siguiente código:

```
plot_acf(serie_modelo.dropna(), lags=6)

plot_pacf(serie_modelo.dropna(), lags=6)
```

Modelo SARIMA

A fin de estimar el comportamiento del futuro inventario dormido de los productos, se aplica el modelo estadístico SARIMA (Seasonal Autoregressive Integrated Moving Average) el cual se basa en el histórico de datos registrados detectando estacionalidades, por lo que, busca proyectar los siguientes periodos en base al análisis histórico. Del mismo modo se pueden implementar intervalos de confianza ayudando en la visualización de los posibles rangos de variación en las estimaciones halladas, lo cual favorece en la identificación de tendencias.

Se estimó el modelo:

SARIMA(p,d,q)(P,D,Q)12

Dentro del colab se presenta como:

```
modelo_pct_baja = SARIMAX(serie_modelo_pct_baja.dropna(),
order=(2,0,1), seasonal_order=(0,0,1,6))

resultado_pct_baja = modelo_pct_baja.fit()

print(resultado_pct_baja.summary())
```

La selección de este modelo fue en base al criterio de Akaike (AIC):

$$AIC = -2 \ln(L) + 2k$$

Donde L es la función de verosimilitud y k es el número de los parámetros estimados.

Se selecciono el modelo con menor AIC y residuos no auto correlacionados.

Proyección para el 2026

Después de comprobar los supuestos estadísticos de estacionariedad de la serie y establecer la estructura del modelo SARIMA mediante el análisis de las funciones de la autocorrelación y autocorrelación parcial, se llevara a cabo la estimación del modelo y la elaboración de los pronósticos fuera de la muestra.

Así que, la proyección se generó a 12 meses mediante:

```
forecast_2026 = resultado.get_forecast(steps=12)
pred_2026 = forecast_2026.predicted_mean
```

CAPÍTULO:

RESULTADOS

Análisis de series de tiempo

Serie mensual




Figura 1: Comparativa mensual entre periodos 2024 vs 2025

En esta gráfica, se compara la cantidad de productos despachados entre los periodos 2024 y 2025. Esto indica que existen patrones claves que, posteriormente, facilitará el análisis del inventario dormido que se busca.

Se observa que, en ambos periodos la estacionalidad sigue una tendencia marcada hacia al alza en el mes de diciembre. No obstante, existen algunas variaciones en esta demanda, por ejemplo, la caída que se observa en el mes de noviembre del año 2025 es notoria si la comparamos con la del año 2024 o, el notable pico en el mes de septiembre del 2024 no tuvo la misma intensidad en el siguiente. Estas inconsistencias, demuestran un origen para la formación de un inventario dormido probable.

Serie mensual por categoría

Vinos




Figura 2: Comparativa mensual de VINOS entre períodos 2024 vs 2025

La categoría de vinos muestra una estacionalidad mucho más marcada, por lo que también predecible. Se observa un crecimiento exponencial en el mes de diciembre, superando las 2,500 unidades en ambos períodos. Asimismo, el año 2025 mantiene una demanda consistente e incluso superior al año 2024, siendo notorio en los primeros seis meses del año.

Licor fuerte




Figura 3: Comparativa mensual de LICOR FUERTE 2024 vs 2025

Esta categoría, muestra una mayor volatilidad que vuelve difícil la proyección lineal de la demanda de los licores. Aunque en el periodo 2025 se observa un mayor desempeño a lo largo del primer cuatrimestre frente al periodo anterior, en la segunda mitad del mismo año, se muestran desviaciones estructurales un poco críticas, siendo específico en el periodo transicional hacia el alta, mientras que, en el año 2024, la demanda del mes de noviembre se mantuvo en niveles cercanos a las 280 luego de un pico en octubre, en el año 2025 sufrió una drástica caída que llegó hasta las 150 unidades en el mismo mes. A pesar de ello, ambos períodos llevan una convergencia en el mes de diciembre, con un máximo estacional a 500 unidades.

Cervezas




Figura 4: Comparativa mensual de CERVEZAS entre períodos 2024 vs 2025

A diferencia de las categorías anteriores, se observa cómo las cervezas representan el mayor volumen del inventario, sin embargo, muestra un comportamiento algo inestable. El gráfico muestra la existencia de un pico alto en septiembre del año 2024, llegando casi a las 5,000 unidades, no obstante, esto no se repitió en el año 2025, cuya demanda bajó a unas 3,700 unidades en el mismo mes.

Rotación de productos (alta, media, baja)

Nivel Rotacion	
Media	141
Baja	72
Alta	71

Figura 5: Rotación de productos, alta, media y baja

El análisis de rotación realizado tiene como objetivo identificar los movimientos de cada producto a fin de calcular la cantidad despachada, permitiendo ordenarlos dependiendo

el nivel de compra, asimismo, se aplicaron métricas estadísticas de distribución, estableciendo diferentes rangos acordes a cada tipo de rotación (alta, media y baja) para identificar específicamente los productos de baja rotación que potencialmente a futuro, podrían convertirse en inventario dormido.

Productos de baja rotación




Figura 6: Porcentaje de productos de baja rotación 2024 vs 2025

En la gráfica se observa el porcentaje de las bebidas de baja rotación de manera mensual, en una comparativa de ambos periodos (2024-2025). En el año 2025, se muestra un incremento de inestabilidad en comparación con el año 2024, dónde se enfatizan dos bajas riesgosas de inventario dormido en los meses de abril y octubre, cerca de un 30% y 34% en ambos meses. No obstante, a diferencia del 2025, el año 2024 muestra un índice menor en estos productos, al menos en el mes de noviembre, presentó un 26%, mes en el cual, para el año siguiente, el indicador descendió de forma critica a un nivel cercano a 0%.

Productos dormidos por mes (3 meses de inactividad)




Figura 7: Productos estructuralmente dormidos 2024 vs 2025

En esta gráfica se definió un criterio de tres meses consecutivos sin movimiento para identificar inventario estructuralmente dormido, el cual se diferencia del inventario que se encuentra totalmente muerto a lo largo de los dos períodos. Se observan que en ambos períodos hay una constante presencia de productos sin movimientos con valores mensuales que se encuentran entre los 125 y 165 productos. Pese a que no se evidencia una tendencia creciente, si se observa una persistencia estructural del fenómeno. Lo que implica que existe la presencia de un núcleo estable de bebidas que no generan los movimientos suficientes lo cual afecta de forma directa en la eficiencia del capital previamente invertido en el inventario.

Autocorrelación (ACF) y autocorrelación parcial (PACF)




Figura 8: ACF y PACF

Este análisis permite validar la estructura del modelo SARIMA, propuesto para la gestión del stock inmovilizado. En el diagrama de PACF (Partial Autocorrelation Function) se muestra que en los primeros dos lags, sobresalen de forma significativa del área de confianza, esto justifica la técnica de adopción de un componente autorregresivo de orden 2 (AR(2)) lo cual sugiere que la demanda actual de los productos se encuentra fuertemente influenciada por los valores registrados en los dos meses anteriores. No obstante, en la gráfica de ACF (Autocorrelation Function) se observa una correlación que inicialmente sobrepasa el intervalo de confianza, dando como resultado la validación de una media móvil (MA(1)). Como se limita el análisis a un horizonte de seis meses, se ratifica la estacionalidad semestral ajustada al parámetro **ma.S.L6** del modelo, lo que demuestra un patrón de rotación de productos que reacciona a ciclos de 6 meses, que deben ser monitoreados para evitar un stock inmovilizado.

Modelo predictivo SARIMA

SARIMAX Results						
=====						
Dep. Variable:	pct_baja		No. Observations:		24	
Model:	SARIMAX(2, 0, 1)x(0, 0, 1, 6)		Log Likelihood		138.108	
Date:	Mon, 16 Feb 2026		AIC		-266.216	
Time:	18:02:06		BIC		-260.326	
Sample:	01-01-2024		HQIC		-264.653	
	- 12-01-2025					
Covariance Type:	opg					
=====						
	coef	std err	z	P> z	[0.025	0.975]

ar.L1	0.7147	0.542	1.319	0.187	-0.347	1.777
ar.L2	0.1640	0.394	0.416	0.677	-0.609	0.936
ma.L1	-0.6621	0.629	-1.052	0.293	-1.895	0.571
ma.S.L6	0.8073	0.813	0.993	0.321	-0.787	2.401
sigma2	4.421e-07	4.66e-07	0.948	0.343	-4.72e-07	1.36e-06
=====						
Ljung-Box (L1) (Q):	0.51	Jarque-Bera (JB):	0.46			
Prob(Q):	0.48	Prob(JB):	0.80			
Heteroskedasticity (H):	2.36	Skew:	0.32			
Prob(H) (two-sided):	0.25	Kurtosis:	3.24			
=====						

Figura 9; Resultados SARIMA

Dentro de este modelo de serie temporal SARIMA (2, 0, 1) x (0, 0, 1, 6), se observa lo siguiente:

Ajuste del modelo: Los criterios de información, arrojan los siguientes valores respectivamente Akaike (**AIC**) **-266.216** y Bayesiano (**BIC**) **-260.326**. Al ser valores negativos, evidencian que el modelo presenta un buen equilibrio entre la complejidad y la capacidad de ajuste, lo cual minimiza la pérdida de información.

Estacionalidad: El parámetro estacional **ma.S.L6** refleja notoriamente un patrón de comportamiento que se va repitiendo cada semestre en la demanda de los productos del hotel, por lo que facilita anticipar las fluctuaciones semestrales que perjudican a ese inventario inmovilizado.

Ljung-Box: Esta prueba muestra un p-valor de **0.48**, lo que indica un mayor valor comparado a la significancia de 0.05. Esto afirma que el comportamiento de los residuos

es de un ruido blanco, es decir, el modelo capturó de forma exitosa la estructura completa de información sistemática del histórico de datos.

Jarque-Bera: Con un valor de ($p=0.80$), este estadístico confirma que los errores de la predicción tienen una tendencia a la normalidad. Esto es fundamental para garantizar cuán fiables son los IC (intervalos de confianza) dentro de las proyecciones de inventario propuestas en este análisis.

Heterocedasticidad: Esta prueba, con un valor de ($p=0.25$) muestra que la varianza de los errores se mantiene constante a lo largo del tiempo, esto refuerza la estabilidad del modelo, facilitando su aplicación en la gestión de compras,

Forecast Dormidos (2026)




Figura 10: Proyección 2026 porcentaje dormidos

La grafica final del estudio muestra la proyección del porcentaje de baja rotación para el siguiente periodo 2026, en el cual se observa que la tendencia estimada mantiene una consistencia visual de los productos con los patrones registrados en los periodos 2024 y 2025. Esta proyección valida la capacidad del modelo SARIMA para replicar ciclos estacionales del hotel, de este modo, anticipa las fluctuaciones específicas en la

demanda de las bebidas que coinciden con los periodos de alta acumulación de inventario dormido. Del mismo modo, la visualización del intervalo de confianza provee un rango específico de seguridad estadística para la planificación operativa lo que permite que el establecimiento hotelero identifique los meses más críticos en los que se deben ejecutar estrategias que faciliten las salidas del inventario inmovilizado.

Análisis de residuos




Figura 11: Análisis Residual (SARIMA)

Con el fin de garantizar cuán fiable son las proyecciones del inventario de baja rotación, se realizó un análisis meticuloso de los residuos del modelo utilizado.

Standardized Residuals: Representa la gráfica de residuos estandarizados la cual, a lo largo del tiempo, muestra una fluctuación aleatoria cerca del valor, no presenta tendencias crecientes o decrecientes ni cambios abruptos en la magnitud de la

homocedasticidad (varianza), esto indica que es un modelo estacionario en sus errores sin patrones sistemáticos omitidos en la estimación.

Histogram plus KDE: Es un histograma de residuos el cual compara con una curva la densidad de probabilidad normal $N(0,1)$. Se muestra que la densidad estimada se ajusta satisfactoriamente a la distribución normal, esto confirma que los errores de la predicción no están sesgados, esto es consistente al valor obtenido previamente en la prueba Jarque-Bera ($p = 0.80$).

Normal Q-Q: En este grafico de probabilidad normal, la lineación de los cuartiles de muestra, sobre la línea de 45 grados, ratifica que la distribución de los errores tiende a la normalidad, que, aunque se observen ligeras dispersiones a los extremos de la línea, estas no son estadísticamente significativas para invalidar el modelo.

Correlogram: La evaluación de autocorrelación residual muestra que todas las autocorrelaciones para los diferentes lags, se mantienen dentro de los IC (intervalos de confianza). la ausencia de subidas significativas fuera de los límites demuestra que los residuos forman un ruido blanco. Esto, se ve sustentado por el previo análisis de prueba de Ljung-Box ($p = 0.48$), la cual confirma que el modelo ha maximizado la extracción de toda la información posible de los datos históricos del hotel.

CONCLUSIONES

Esta investigación permitió comprender mejor el comportamiento del inventario dormido de bebidas en el establecimiento hotelero analizado, yendo más allá de la simple descripción de datos históricos, hacia el análisis estructural y la predicción de estos fenómenos. A lo largo del estudio se concluyó que la gestión de inventarios no puede limitarse a simplemente registrar las entradas y salidas, sino que requiere herramientas analíticas para predecir el comportamiento futuro y detectar riesgos estructurales dentro de la cartera.

Desde un punto de vista teórico, los métodos de análisis predictivo y las técnicas de series temporales se han confirmado como enfoques adecuados para examinar fenómenos dinámicos a lo largo del tiempo, en particular para identificar tendencias recurrentes y estimar escenarios futuros. La literatura sobre rotación de inventario y capital de trabajo destaca la necesidad de monitorear el inventario de baja rotación, ya que impacta directamente en la eficiencia operativa y la programación de recursos financieros. En este sentido, el estudio muestra que el inventario no consumido no es sólo un indicador contable, sino una variable estratégica que refleja la calidad de la gestión de la cartera.

El análisis de datos empíricos de 2024 y 2025 revela tendencias claras en la rotación del inventario de bebidas. Muchos productos presentan tasas de rotación bajas o nulas, lo que indica que el consumo se concentra en subgrupos de productos. La identificación de 31 productos sin ventas durante el período estimado de 24 meses, lo que se considera inventario dormido. Este hallazgo pone de relieve la inmovilización de capital sin generar ingresos. El estudio destaca la necesidad de revisar la composición del catálogo de bebidas.

Además, un análisis mensual de productos inactivos muestra que, en promedio, aproximadamente 142 SKU no han presentado cambios en el inventario durante tres meses consecutivos, lo que demuestra que el problema no es un evento específico, sino una tendencia recurrente. Las pruebas de estabilidad aplicadas a la serie temporal confirmaron que este fenómeno no presenta una tendencia significativa al alza o a la baja, sino que fluctúa alrededor de una media constante. Este resultado fue confirmado por la estimación del modelo autorregresivo SARIMA (2,0,1), y (0,0,1,6) donde los coeficientes son estadísticamente significativos y se ajustan adecuadamente según la evaluación de validación.

El pronóstico para 2026 muestra que, bajo las condiciones de gestión actuales, el número de productos inactivos se mantendrá cerca al promedio histórico. Este resultado es particularmente importante, ya que sugiere que el problema no se resolverá por sí solo con el tiempo. Dando a entender que, sin medidas estratégicas, los niveles de inventario inactivo se mantendrán estructuralmente estables, lo que resultará en recursos limitados y una disminución continua del rendimiento de la cartera.

En general, los resultados nos permiten concluir que el inventario dormido en la industria hotelera es un fenómeno estructural que requiere una intervención cuidadosa. El análisis predictivo utilizado demostró ser una herramienta eficaz para cuantificar, modelar y predecir la evolución del problema, proporcionando una base técnica sólida para la toma de decisiones. Más allá de la previsión estadística, el estudio muestra que la gestión de inventario debe priorizar un enfoque proactivo basado en datos.

RECOMENDACIONES

Dado los resultados obtenidos en bloques anteriores, se recomienda realizar una revisión exhaustiva de la carta de bebidas del hotel, especialmente centrarse en los 29 productos que fueron identificados como potencialmente inactivos. Esta revisión debe considerar otras alternativas para este grupo de productos, como la eliminación de estos en su catálogo o liquidarlos mediante estrategias con estímulos en la demanda o incluso renegociar con proveedores, todo con el objetivo de que la inmovilización del capital pueda evitarse.

Del mismo modo, es aconsejable implementar un tipo de monitoreo sistemático mensual de inventario dormido, incluyendo indicadores que identifiquen el número exacto de productos sin demanda durante tres meses consecutivamente, así como el porcentaje de los artículos de baja rotación que, a futuro, podrían convertirse en un inventario dormido.

Asimismo, se sugiere revisar políticas de reposición que se encuentren actualmente en vigencia, las cuales deben incorporar criterios predictivos que se basen en la data histórica de rotación antes de emitirse nuevas órdenes de compra. La aplicación del modelo previamente desarrollado en el presente estudio puede utilizarse como una herramienta que apoya una toma de decisiones eficientes en la cadena de suministro interna.

De manera complementaria, es recomendable actualizar periódicamente el análisis predictivo, permitiendo que la información reciente se integre para evaluar el impacto de las decisiones implementadas, detectando así, posibles variaciones en la demanda.

REFERENCIAS BIBLIOGRÁFICAS

- Asamblea Nacional (2024) *Codificación 26. Ley Orgánica de Régimen Tributario Interno, LORTI*. <https://vlex.ec/vid/codificacion-26-ley-organica-671648277>
- Contessi D., Viverit L., Nobre Pereira L., Heo (2024) Decoding the future: Proposing an interpretable machine learning model for hotel occupancy forecasting using principal component analysis. *International Journal of Hospitality Management*, Volume 121. <https://www.sciencedirect.com/science/article/pii/S0278431924001142>
- Food Compliance International (2025) ARCSA Publishes Proposed Institutional Regulatory Plan 2025. <https://foodcomplianceinternational.com/industry-insight/news/5029-arcsa-publishes-proposed-institutional-regulatory-plan-2025>
- Fundación IFRS (2025) *NIC 2 Inventarios*. <https://www.ifrs.org/issued-standards/list-of-standards/ias-2-inventories/>
- Hao Ruoyu (2024) Streamlining SCM: Integrating Demand Forecasting and Inventory Optimization. <https://www.atlantis-press.com/article/126004015.pdf>
- Henriques, H. y Nobre Pereira, L. (2024). Modelos y métodos de pronóstico de la demanda hotelera mediante inteligencia artificial: Una revisión sistemática de la literatura. *Tourism & Management Studies*, 20 (3), 39-51. <https://doi.org/10.18089/tms.20240304>
- Hospitality.Institute (2025, 18 julio). *Why Inventory Management is Critical in Hospitality Operations*. <https://hospitality.institute/bha508/inventory-management-critical-hospitality-operations/>
- Jenkins (2025) *Slow-Moving Inventory: Identify, Manage & Prevent It*. <https://www.netsuite.com/portal/resource/articles/inventory-management/slow-moving-inventory.shtml>

- Kırmızı, D. S., Ceylan, Z., & Bulkan, S. (2024). Enhancing Inventory Management through Safety-Stock Strategies—A Case Study. *Systems*, 12(7), 260. <https://doi.org/10.3390/systems12070260>
- Kozlovskis, K., Liu, Y., Lace, N., & Meng, Y. (2023). Application of machine learning algorithms to predict hotel occupancy. *Journal of Business Economics and Management (JBEM)*, 24(3), 594-613. <https://www.econstor.eu/bitstream/10419/317640/1/1870037189.pdf>
- Kumar, Khedlekar, Khedlekar (2024) A comparative assessment of holt winter exponential smoothing and autoregressive integrated moving average for inventory optimization in supply chains. *Supply Chain Analytics* 8. <https://www.sciencedirect.com/science/article/pii/S294986352400027X>
- Lee, G.-C. (2025). A Data-Driven Approach to Tourism Demand Forecasting: Integrating Web Search Data into a SARIMAX Model. *Data*, 10(5), 73. <https://doi.org/10.3390/data10050073>
- Ministerio de Educación Pública (2015) LEY ORGANICA DE SALUD. <https://salud.gob.ec/wp-content/uploads/2017/03/LEY-ORG%C3%81NICA-DE-SALUD4.pdf>
- Ministerio de Educación Pública (2013) REGLAMENTO DE REGISTRO Y CONTROL SANITARIO DE ALIMENTOS <https://www.controlsanitario.gob.ec/wp-content/uploads/downloads/2013/11/REGLAMENTO-DE-REGISTRO-Y-CONTROL-SANITARIO-DE-ALIMENTOS.pdf>
- Pinto Hernández L (2022) Análisis de la Evolución del Turismo y su Incidencia en el Desarrollo de Ecuador. Caso provincia de Manabí (2010-2014). Tesis de grado. Universidad Andina Simón Bolívar. <https://repositorio.uasb.edu.ec/bitstream/10644/8696/1/T3805-MGD-Pinto-Analisis.pdf>

- Pereira, LN y Cerqueira, V. (2022). Pronóstico de la demanda hotelera para la gestión de ingresos mediante métodos de regresión de aprendizaje automático. *Current Issues in Tourism*, 25 (17), 2733–2750.
<https://www.tandfonline.com/doi/abs/10.1080/13683500.2021.1999397>
- Rakholia, Kalpesh & Chandrababh, Chandrababh & Ramesh, R & Rao, Kolli.Srinivasa & Punitha, S. & Kumar, M.. (2025). Optimizing Inventory Management Through Demand Forecasting: A Data-Driven Approach for Enhanced Supply Chain Efficiency. *SSRN Electronic Journal*.
https://www.researchgate.net/publication/387764615_Optimizing_Inventory_Management_Through_Demand_Forecasting_A_Data-Driven_Approach_for_Enhanced_Supply_Chain_Efficiency
- SRI (2010) REGLAMENTO PARA LA APLICACIÓN DE LA LEY DE RÉGIMEN TRIBUTARIO INTERNO (Decreto No. 374). <https://www.sri.gob.ec/o/sri-portlet-biblioteca-alfresco-internet/descargar/f06162e5-4c07-4da6-a8a5-ecb189d6b99c/Reglamento%20LRTI-%20%C3%BAltima%20modificaci%C3%B3n%202023%20de%20abril%20de%202021.pdf>
- SRI (2004) LEY DE RÉGIMEN TRIBUTARIO INTERNO. <https://deltechaudit.ec/ley-de-regimen-tributario-interno-2024/#gsc.tab=0>
- Takahashi M. (2025). *Hotel Inventory Problems: 7 Critical Issues Killing Your Revenue*.
<https://www.prostay.com/es/blog/hotel-inventory-problems-critical-issues-revenue-loss/>
- Triana Mora, E. (2023) Optimización del manejo de inventarios de alimentos y bebidas en el sector hotelero por medio del desarrollo de modelos econométricos enfocados en el

pronóstico de ventas. Caso de estudio: Hotel Tequendama. *Turismo y Sociedad*. XXXII, 51-72. <https://revistas.uexternado.edu.co/index.php/tursoc/article/view/8468>

Wu, J., Li, M., Zhao, E., Sun, S., & Wang, S. (2023). Can multi-source heterogeneous data improve the forecasting performance of tourist arrivals amid COVID-19? Mixed-data sampling approach. *Tourism management*, 98, 104759. <https://doi.org/10.1016/j.tourman.2023.104759>

Wu, D. C., Zhong, S., Wu, J., & Song, H. (2025). Tourism and hospitality forecasting with big data: A systematic review of the literature. *Journal of Hospitality & Tourism Research*, 49(3), 615-634. https://ira.lib.polyu.edu.hk/bitstream/10397/107074/1/Wu_Tourism_Hospitality_Forecasting.pdf

2. ANEXOS

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import unicodedata
import re

from statsmodels.tsa.stattools import adfuller
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
from statsmodels.tsa.arima.model import ARIMA
from statsmodels.tsa.statespace.sarimax import SARIMAX
```

```
path_2024 = "/content/DATOS TESIS 2024.xlsx"
path_2025 = "/content/DATOS TESIS 2025.xlsx"
```

```
def normalize_text(x):
    if pd.isna(x):
        return ""
    x = str(x).strip().upper()
    x = unicodedata.normalize("NFKD", x).encode("ascii", "ignore").decode("utf-8")
    x = re.sub(r"\s+", " ", x) # espacios múltiples
    x = re.sub(r"[^\w\s&.-]", "", x) # limpia símbolos raros conservando algunos
    return x.strip()

# Listas base (las tuyas)
cervezas = ["CERVEZA", "BEER", "PILS", "CLUB", "CORONA", "STELLA", "HEINEKEN",
            "MODELO", "BUDWEISER", "BECKS", "BIP", "ARTESANAL", "BIRRA"]

vinos = ["VINO", "TINTO", "BLANCO", "ROSADO", "ROSE", "ROSE", "ROSE", "ROSÉ", "ESPUMANTE", "CHAMPAGNE", "CAVA",
        "PROSECCO", "BRUT", "MALBEC", "CABERNET", "MERLOT", "SAUVIGNON", "SAUV", "SAUV BLANC", "CAB", "FUME",
        "FUMÉ", "CHARDONAY", "SYRAH", "SHYRA", "PINOT", "PINOTAGE", "CARMENERE", "TEMPRANILLO", "ALBARI",
        "RIESLING", "VERDEJO", "BLEND", "COLECCION", "RESERVA", "VARIETAL", "BORDEAUX", "CHIANTI", "RIOJA",
        "TOSCANA", "PRIMITIVO", "OPORTO", "PEDRO XIMENEZ", "MONTEPULCIANO", "LAMBRUSCO", "GAVI",
        "MAISON", "HENKELL", "CHANDON", "MOET", "VEUVE", "FREIXENET", "MUMM", "MERCIER",
        "ANGELICA ZAPATA", "CATENA", "ENEMIGO", "ZAPATA", "ZUCCARDI", "PAZO", "CONCILIO",
        "TRAPICHE", "NORTON", "LUIGI BOSCA", "DONA P", "DOÑA P", "PAULA", "LOS CARDOS", "LAS MORAS",
        "CASILLERO", "DIABLO", "FRONTERA", "MONTES", "NEYEN", "VERAMONTE", "NAVARRO", "ERRAZURIZ",
        "UNDURRAGA", "TARAPACA", "SANTA RITA", "MORANDE", "VALDIVIESO", "PORTA", "DOMAINE", "CASTELLO",
        "VARVAGLIONE", "MARQUES", "MURRIETA", "FAUSTINO", "PROTOS", "MONTECILLO", "PAGO", "LARA",
        "TORREMILANOS", "BARBERA", "LAURENT", "CHARTIER", "GILLOT", "MELCHOR", "CANEPA",
        "TTO", "C/S", "S/B"]

licores = ["WHISKY", "WHISKEY", "RON", "RUM", "VODKA", "GIN", "TEQUILA", "MEZCAL", "BRANDY", "COGNAC",
          "PISCO", "ANIS", "AGUARDIENTE", "AGUARD", "LICOR", "CREMA", "DIGESTIVO", "APERITIVO", "BITTER",
          "VERMOUTH",
          "JOHNNIE", "WALKER", "CHIVAS", "BUCHANAN", "OLD PAR", "JACK DANIEL", "JACK DANIELS", "JB", "MACALLAN",
          "GLEN", "GLENMORANGIE", "GLENLIVET", "SINGLE MALT", "BLACK & WHITE", "WILD TURKEY", "TAMDHU", "BLACK OWL",
          "ABSOLUT", "SMIRNOFF", "FINLANDIA", "GREY GOOSE", "BELVEDERE", "SKYY", "TANQUERAY", "BOMBAY",
          "BEEFEATER", "GORDON", "HENDRICK", "LARIOS",
          "JOSE CUERVO", "DON JULIO", "PATRON", "HERRADURA", "HAVANA", "BACARDI", "ABUELO", "ZACAPA",
          "FLOR DE CANA", "FLOR DE CAÑA", "CAPTAIN", "MORGAN", "APPLETON", "MATUSALEM",
          "HENNESSY", "REMY MARTIN", "COURVOISIER", "GRAN DUQUE", "LEPANTO", "TORRES", "SCHLADERER",
          "JAGER", "JAGERMEISTER", "BAILEYS", "AMARULA", "FRANGELICO", "KAHLUA", "COINTREAU",
          "GRAND MARNIER", "CURACAO", "SAMBUCA", "AMARETO", "AMARETTO", "CAMPARI", "APEROL",
          "FERNET", "MARTINI", "CINZANO", "GANCIA", "ANGOSTURA", "DRAMBUIE", "SAKE"]

# Normaliza keywords una vez
cervezas_n = [normalize_text(x) for x in cervezas]
vinos_n = [normalize_text(x) for x in vinos]
licores_n = [normalize_text(x) for x in licores]

def classify_item(desc):
    d = normalize_text(desc)
    # prioridad: cerveza / vino / licor (puedes cambiar si lo prefieres)
    if any(k in d for k in cervezas_n):
        return "Cerveza"
    if any(k in d for k in vinos_n):
        return "Vino"
    if any(k in d for k in licores_n):
        return "Licor fuerte"
    return "Otros"
```

```

from pathlib import Path
def safe_read_requisitions(filepath):
    xls = pd.ExcelFile(filepath)
    frames = []

    for sheet in xls.sheet_names:
        df_sheet = pd.read_excel(filepath, sheet_name=sheet)

        # Normaliza nombres de columnas por si cambian
        cols = {c: normalize_text(c) for c in df_sheet.columns}
        inv = {v: k for k, v in cols.items()} # map normalizado -> original

        # Busca columnas posibles (según tu excel real)
        # Fecha
        fecha_col = inv.get("FECHA", None)

        # Descripción (a veces "DESCRIPCION I", "DESCRIPCION ITEM", etc.)
        desc_col = None
        for key in ["DESCRIPCION I", "DESCRIPCION ITEM", "DESCRIPCION", "DESCRIPCIONIT", "DESCRIPCION_I"]:
            if key in inv:
                desc_col = inv[key]
                break

        # Cantidad despachada
        cant_col = None
        for key in ["CANTIDAD DESPACHADA", "CANTIDAD DESPA", "CANTIDADDESPACHADA", "CANTIDAD DESP"]:
            if key in inv:
                cant_col = inv[key]
                break

        # Total (opcional)
        total_col = inv.get("TOTAL", None)

        # Item/código (opcional pero ideal)
        item_col = inv.get("ITEM", None)

        # Num requisición (opcional)
        req_col = None
        for key in ["NUM REQUISICI", "NUM REQUISICION", "NUMREQUISICION", "NUM REQUISIC"]:
            if key in inv:
                req_col = inv[key]
                break

        # Valida mínimas
        if fecha_col is None or desc_col is None or cant_col is None:
            continue

        out = pd.DataFrame({
            "Fecha": df_sheet[fecha_col],
            "Descripcion Item": df_sheet[desc_col],
            "Cantidad Despachada": df_sheet[cant_col],
        })

        if total_col is not None:
            out["Total"] = df_sheet[total_col]

        if item_col is not None:
            out["Item"] = df_sheet[item_col]

        if req_col is not None:
            out["Num Requisicion"] = df_sheet[req_col]

        out["Hoja_Origen"] = sheet
        out["Archivo_Origen"] = Path(filepath).name

        frames.append(out)

    if not frames:
        raise ValueError(f"No se pudieron leer hojas válidas en: {filepath}")

    return pd.concat(frames, ignore_index=True)

```

```
def clean_requisitions(df):
    df = df.copy()

    # Fecha
    df["Fecha"] = pd.to_datetime(df["Fecha"], errors="coerce", dayfirst=True)
    df = df.dropna(subset=["Fecha"])

    # Texto
    df["Descripcion Item"] = df["Descripcion Item"].apply(normalize_text)
    df = df[df["Descripcion Item"] != ""]

    # Cantidad a numérico entero
    df["Cantidad Despachada"] = pd.to_numeric(df["Cantidad Despachada"], errors="coerce")
    df = df.dropna(subset=["Cantidad Despachada"])
    df["Cantidad Despachada"] = np rint(df["Cantidad Despachada"]).astype(int)

    # Total opcional
    if "Total" in df.columns:
        df["Total"] = pd.to_numeric(df["Total"], errors="coerce")

    # Variables tiempo
    df["Año"] = df["Fecha"].dt.year
    df["Mes_Num"] = df["Fecha"].dt.month
    df["Mes"] = df["Fecha"].dt.to_period("M").astype(str)

    return df

raw_2024 = safe_read_requisitions(path_2024)
raw_2025 = safe_read_requisitions(path_2025)

df_2024 = clean_requisitions(raw_2024)
df_2025 = clean_requisitions(raw_2025)

df = pd.concat([df_2024, df_2025], ignore_index=True)

print("DF final:", df.shape)
df.head()
```

```
DF final: (12027, 11)
```

	Fecha	Descripcion Item	Cantidad Despachada	Total	Item	Num Requisicion	Hoja_0
0	2024-01-01	DONA P LOS CARDOS C/S 750	6	48.00	202210077	REQ-0000000000054427	EI
1	2024-01-01	DONA P LOS CARDOS S/B 750	6	45.36	202200041	REQ-0000000000054427	EI

```
df["Categoria"] = df["Descripcion Item"].apply(classify_item)
df["Categoria"].value_counts()
```

	count
Categoria	
Vino	5027
Licor fuerte	4055
Cerveza	2838
Otros	107

```
dtype: int64
```

```
ID_COL = "Item" if "Item" in df.columns else "Descripcion Item"

catalogo_maestro = (
    df.groupby(ID_COL, as_index=False)
        .agg(
            Descripcion=("Descripcion Item", "first"),
            Categoria=("Categoria", "first"),
            Total_Despachado=("Cantidad Despachada", "sum"),
            Primera_Fecha=("Fecha", "min"),
            Ultima_Fecha=("Fecha", "max"),
            N_Registros=("Fecha", "count"),
            N_Requisiciones=("Num Requisicion", "nunique") if "Num Requisicion" in df.columns else ("Fecha", "count")
        )
        .sort_values("Total_Despachado", ascending=False)
)

catalogo_maestro.head(20)
```

	Item	Descripcion	Categoria	Total_Despachado	Primera_Fecha	Ulti
112	201100007	CERVEZA CLUB VERDE NORET	Cerveza	30808	2024-01-01	20
110	201100004	CERVEZA PILSENER NO RET	Cerveza	11561	2024-01-03	20
117	201100012	CERVEZA BIELA RSV.ESPE	Cerveza	8712	2024-01-03	20
219	202210095	TORO VINO TINTO CARTON LT	Vino	4946	2024-01-03	20
177	202210011	DONA P LOS CARDOS MALBEC 750	Vino	4736	2024-01-05	20
119	201100015	CERVEZA CORONA EXTRA	Cerveza	4404	2024-01-05	20
207	202210077	DONA P LOS CARDOS C/S 750	Vino	4384	2024-01-01	20
123	201100020	CERVEZA STELLA ARTOIS	Cerveza	4326	2024-01-05	20
115	201100010	CERVEZA ERDINGER 0.5 RUB	Cerveza	4063	2024-01-05	20

```
print("Items únicos:", df["Item"].nunique())
print("Descripciones únicas:", df["Descripcion Item"].nunique())
```

```
Items únicos: 284
Descripciones únicas: 287
```

```
from google.colab import files
catalogo_maestro.to_excel("catalogo_maestro_bebidas.xlsx", index=False)
files.download("catalogo_maestro_bebidas.xlsx")
```

```

plt.style.use("seaborn-v0_8-whitegrid")

mensual_total = (
    df.groupby(pd.Grouper(key="Fecha", freq="MS"))["Cantidad Despachada"]
    .sum()
    .reset_index()
)

mensual_total["Año"] = mensual_total["Fecha"].dt.year
mensual_total["Mes_Num"] = mensual_total["Fecha"].dt.month


pivot_total = mensual_total.pivot(index="Mes_Num", columns="Año", values="Cantidad Despachada").reindex(range(1,13))

meses = ["Ene", "Feb", "Mar", "Abr", "May", "Jun", "Jul", "Ago", "Sep", "Oct", "Nov", "Dic"]
colores = {2024: "#f79ae5", 2025: "#bc98f3"}

plt.figure(figsize=(9,5))
for año in pivot_total.columns:
    plt.plot(meses, pivot_total[año], marker="o", linewidth=2, label=str(año), color=colores.get(año))

plt.title("Comparación Serie Mensual Total\n2024 vs 2025")
plt.xlabel("Mes")
plt.ylabel("Cantidad Despachada")
plt.legend(title="Año")
plt.grid(alpha=0.3)
plt.tight_layout()
plt.show()

```



```

ts_m_cat = (
    df.groupby([pd.Grouper(key="Fecha", freq="MS"), "Categoria"])["Cantidad Despachada"]
    .sum()
    .reset_index()
)

ts_m_cat["Año"] = ts_m_cat["Fecha"].dt.year
ts_m_cat["Mes_Num"] = ts_m_cat["Fecha"].dt.month




categorias = ["Cerveza", "Licor fuerte", "Vino"] # excluye Otros

for cat in categorias:
    temp = ts_m_cat[ts_m_cat["Categoria"] == cat]
    pivot_cat = temp.pivot(index="Mes_Num", columns="Año", values="Cantidad Despachada").reindex(range(1,13)).fillna(0)

    plt.figure(figsize=(9,5))
    for año in pivot_cat.columns:
        plt.plot(meses, pivot_cat[año], marker="o", linewidth=2, label=str(año), color=colores.get(año))

    plt.title(f"Demanda Mensual - {cat}\nComparación 2024 vs 2025")
    plt.xlabel("Mes")
    plt.ylabel("Cantidad Despachada")
    plt.legend(title="Año")
    plt.grid(alpha=0.3)
    plt.tight_layout()
    plt.show()

```



```

rotacion = (
    df.groupby(ID_COL)["Cantidad Despachada"]
        .sum()
        .reset_index()
        .sort_values("Cantidad Despachada", ascending=False)
)

p25 = rotacion["Cantidad Despachada"].quantile(0.25)
p75 = rotacion["Cantidad Despachada"].quantile(0.75)

def clasificar_rotacion(x):
    if x <= p25:
        return "Baja"
    elif x >= p75:
        return "Alta"
    else:
        return "Media"

rotacion["Nivel Rotacion"] = rotacion["Cantidad Despachada"].apply(clasificar_rotacion)
rotacion["Nivel Rotacion"].value_counts()

```

	count
Nivel Rotacion	
Media	141
Baja	72
Alta	71

dtype: int64

```
df_rot = df.merge(rotacion[[ID_COL, "Nivel Rotacion"]], on=ID_COL, how="left")

df_baja = df_rot[df_rot["Nivel Rotacion"] == "Baja"].copy()


serie_baja = (
    df_baja.groupby(pd.Grouper(key="Fecha", freq="MS"))["Cantidad Despachada"]
    .sum()
    .reset_index()
)

serie_baja["Año"] = serie_baja["Fecha"].dt.year
serie_baja["Mes_Num"] = serie_baja["Fecha"].dt.month

pivot_baja = serie_baja.pivot(index="Mes_Num", columns="Año", values="Cantidad Despachada").reindex(range(1,13)).fillna(0)

plt.figure(figsize=(9,5))
for año in pivot_baja.columns:
    plt.plot(meses, pivot_baja[año], marker="o", linewidth=2, label=str(año), color=colores.get(año))

plt.title("Demanda Mensual - Productos de Baja Rotación\n2024 vs 2025")
plt.xlabel("Mes")
plt.ylabel("Cantidad Despachada")
plt.legend(title="Año")
plt.grid(alpha=0.3)
plt.tight_layout()
plt.show()
```



```

mensual_total2 = mensual_total.copy()
mensual_baja = serie_baja.copy()

mensual_merge = mensual_total2.merge(mensual_baja, on="Fecha", how="left", suffixes=("_total", "_baja"))
mensual_merge["Cantidad Despachada_baja"] = mensual_merge["Cantidad Despachada_total"].fillna(0)

mensual_merge["pct_baja"] = np.where(
    mensual_merge["Cantidad Despachada_total"] > 0,
    mensual_merge["Cantidad Despachada_baja"] / mensual_merge["Cantidad Despachada_total"],
    0
)

mensual_merge["Año"] = mensual_merge["Fecha"].dt.year
mensual_merge["Mes_Num"] = mensual_merge["Fecha"].dt.month

pivot_pct = mensual_merge.pivot(index="Mes_Num", columns="Año", values="pct_baja").reindex(range(1,13)).fillna(0)


plt.figure(figsize=(9,5))
for año in pivot_pct.columns:
    plt.plot(meses, pivot_pct[año], marker="o", linewidth=2, label=str(año), color=colores.get(año))

plt.title("% Mensual de Baja Rotación\n2024 vs 2025")
plt.xlabel("Mes")
plt.ylabel("Porcentaje (%)")
plt.legend(title="Año")
plt.grid(alpha=0.3)
plt.tight_layout()
plt.show()

# Volatilidad anual
pct_2024 = pivot_pct[2024].dropna() if 2024 in pivot_pct.columns else None
pct_2025 = pivot_pct[2025].dropna() if 2025 in pivot_pct.columns else None

if pct_2024 is not None:
    print("Desviación estándar 2024:", float(pct_2024.std()))
if pct_2025 is not None:
    print("Desviación estándar 2025:", float(pct_2025.std()))

```



Desviación estándar 2024: 0.0005952545084108076
Desviación estándar 2025: 0.0010961788142025712

```

mensual_prod = (
    df.groupby([pd.Grouper(key="Fecha", freq="MS"), ID_COL])["Cantidad Despachada"]
    .sum()
    .reset_index()
)

pivot_prod = mensual_prod.pivot_table(index=ID_COL, columns="Fecha", values="Cantidad Despachada", fill_value=0)

pivot_prod.shape

(284, 24)

```

```

totales_producto = pivot_prod.sum(axis=1)
productos_muertos = totales_producto[totales_producto == 0].sort_index()

print("Productos estructuralmente muertos:", len(productos_muertos))
productos_muertos.index.tolist()[:20]

```

```

Productos estructuralmente muertos: 29
[200000018,
 200000021,
 200000026,
 200020001,
 200030005,
 200030013,
 200040000,
 200040001,
 200040002,
 200060002,
 200080009,
 200080021,
 200080038,
 200090003,
 200090010,
 201100005,
 201100008,
 201100035,
 202200005,
 202200012]

```

```

tabla_muertos = pd.DataFrame({
    "ID": productos_muertos.index,
})

if ID_COL == "Item":
    # recupera descripción por item desde catálogo
    tabla_muertos = tabla_muertos.merge(catalogo_maestro[[ID_COL, "Descripcion", "Categoria"]], left_on="ID", right_on=ID_COL)
    tabla_muertos = tabla_muertos.drop(columns=[ID_COL])
else:
    tabla_muertos["Descripcion"] = tabla_muertos["ID"]
    tabla_muertos["Categoria"] = tabla_muertos["Descripcion"].apply(classify_item)

tabla_muertos.to_excel("productos_muertos_2024_2025.xlsx", index=False)
tabla_muertos.head(20)

```

	ID	Descripcion	Categoria
0	200000018	BLACK & WHITE 750ML	Licor fuerte
1	200000021	GLENMORANGIE 10 ANOS	Licor fuerte
2	200000026	BUCHANAN S 12 ANOS LT	Licor fuerte
3	200020001	BRANDY NAPOLEON MAC 750ML	Licor fuerte
4	200030005	GIN WEMBLEY 750	Licor fuerte
5	200030013	GIN ELEPHANT 750 ML	Licor fuerte
6	200040000	RON SAN MIGUEL PLATA 750ML	Licor fuerte
7	200040001	RON APPLETON GOLD 750ML	Licor fuerte
8	200040002	RON SAN MIGUEL 5 ANOS 750ML	Licor fuerte
9	200060002	PEDRO XIMENEZ LA GITANA 750 ML	Vino
10	200080009	AGUARD PAJARO AZ DURAZNO	Licor fuerte
11	200080021	PISCO CONTROLCHILE750ML	Licor fuerte
12	200080038	DRAMBUIE 750ML	Licor fuerte
13	200090003	TEQUILA CHARRO ORO 750	Licor fuerte
14	200090010	TEQUILA PATRON XOCAFE7	Licor fuerte
15	201100005	CERVEZA PILSENER CERO NR	Cerveza
16	201100008	CERVEZA CLUB NEGRA 330	Cerveza
17	201100035	CERVEZA CLUB DOBLE MALTA	Cerveza
18	202200005	CANEPA NOVISIMO S/B	Vino
19	202200012	MONTES CHARDONAY CLASIC75	Vino

```

conteo_dormidos = []
fechas = list(pivot_prod.columns)

for i in range(2, len(fechas)):
    ventana = fechas[i-2:i+1] # 3 meses
    sub = pivot_prod[ventana]
    dormidos_mes = (sub.sum(axis=1) == 0).sum()
    conteo_dormidos.append({"Fecha": fechas[i], "Dormidos": dormidos_mes})

conteo_dormidos = pd.DataFrame(conteo_dormidos)


conteo_dormidos["Año"] = conteo_dormidos["Fecha"].dt.year
conteo_dormidos["Mes_Num"] = conteo_dormidos["Fecha"].dt.month

pivot_dorm = conteo_dormidos.pivot(index="Mes_Num", columns="Año", values="Dormidos").reindex(range(1,13))

plt.figure(figsize=(9,5))
for año in pivot_dorm.columns:
    plt.plot(meses, pivot_dorm[año], marker="o", linewidth=2, label=str(año), color=colores.get(año))

plt.title("Productos Dormidos por Mes (3 meses sin movimiento)\nComparación 2024 vs 2025")
plt.xlabel("Mes")
plt.ylabel("Cantidad de Productos Dormidos")
plt.legend(title="Año")
plt.grid(alpha=0.3)
plt.tight_layout()
plt.show()

```



```

serie_modelo = conteo_dormidos.set_index("Fecha")["Dormidos"].asfreq("MS")

adf_res = adfuller(serie_modelo.dropna())
print("ADF Statistic:", adf_res[0])
print("p-value:", adf_res[1])


plt.figure(figsize=(12,5))
plt.subplot(1,2,1)
plot_acf(serie_modelo.dropna(), ax=plt.gca(), lags=6)

plt.subplot(1,2,2)
plot_pacf(serie_modelo.dropna(), ax=plt.gca(), lags=6, method="ywmm")

plt.tight_layout()
plt.show()

```

ADF Statistic: -3.355079811244444
 p-value: 0.012588902778559114



```

import numpy as np
import matplotlib.pyplot as plt
from statsmodels.tsa.statespace.sarimax import SARIMAX

# =====
# 1) Serie mensual a modelar
# =====
# Asegura que mensual_merge tenga "Fecha" y "pct_baja"
serie_modelo_pct_baja = (
    mensual_merge
    .set_index("Fecha")["pct_baja"]
    .asfreq("MS")
    .sort_index()
)

# (Opcional recomendado) Si quieres trabajar en porcentaje 0-100:
serie_modelo_pct_baja = serie_modelo_pct_baja * 100

# =====
# 2) Ajuste del modelo
# =====
# Usa el mismo order que ya venías usando; si tú tienes "resultado" de otro modelo,
# aquí creamos uno nuevo para pct_baja.
modelo_pct_baja = SARIMAX(serie_modelo_pct_baja.dropna(), order=(2,0,1),
    seasonal_order=(0,0,1,6))
resultado_pct_baja = modelo_pct_baja.fit()

print(resultado_pct_baja.summary())

/usr/local/lib/python3.12/dist-packages/statsmodels/tsa/statespace/sarimax.py:966: UserWarning: Non-stationary starting auto
warn('Non-stationary starting autoregressive parameters')
/usr/local/lib/python3.12/dist-packages/statsmodels/tsa/statespace/sarimax.py:1009: UserWarning: Non-invertible starting sea
warn('Non-invertible starting seasonal moving average')
SARIMAX Results
=====
Dep. Variable:          pct_baja      No. Observations:          24
Model:                SARIMAX(2, 0, 1)x(0, 0, 1, 6)      Log Likelihood          138.108
Date:                  Mon, 16 Feb 2026      AIC                    -266.216
Time:                  21:02:31      BIC                    -260.326
Sample:                01-01-2024      HQIC                   -264.653
                   - 12-01-2025
Covariance Type:                opg
=====
              coef      std err          z      P>|z|      [0.025      0.975]
-----
ar.L1          0.7147      0.542       1.319      0.187      -0.347      1.777
ar.L2          0.1640      0.394       0.416      0.677      -0.609      0.936
ma.L1         -0.6621      0.629      -1.052      0.293      -1.895      0.571
ma.S.L6        0.8073      0.813       0.993      0.321      -0.787      2.401
sigma2        4.421e-07  4.66e-07      0.948      0.343      -4.72e-07  1.36e-06
=====
Ljung-Box (L1) (Q):                0.51      Jarque-Bera (JB):                0.46
Prob(Q):                          0.48      Prob(JB):                  0.80
Heteroskedasticity (H):            2.36      Skew:                      0.32
Prob(H) (two-sided):              0.25      Kurtosis:                  3.24
=====

Warnings:
[1] Covariance matrix calculated using the outer product of gradients (complex-step).

```

```

# =====
# 3) Forecast 12 meses (2026)
# =====
forecast_2026_pct = resultado_pct_baja.get_forecast(steps=12)
pred_2026_pct = forecast_2026_pct.predicted_mean
ic_2026_pct = forecast_2026_pct.conf_int()

# =====
# 4) Gráfico
# =====
plt.figure(figsize=(9,5))
plt.plot(serie_modelo_pct_baja, label="Histórico", marker="o")
plt.plot(pred_2026_pct, label="Proyección 2026", marker="o")
plt.fill_between(
    pred_2026_pct.index,
    ic_2026_pct.iloc[:,0],
    ic_2026_pct.iloc[:,1],
    alpha=0.2
)
plt.title("Proyección del % Mensual de Baja Rotación - 2026")
plt.xlabel("Fecha")
plt.ylabel("Porcentaje de Baja Rotación" + (" (%)" if serie_modelo_pct_baja.max() > 1 else " (proporción)"))
plt.legend()
plt.grid(alpha=0.3)
plt.tight_layout()
plt.show()

```

Fecha	Predicted_mean
2026-01-01	0.000542
2026-02-01	0.001085
2026-03-01	0.000695
2026-04-01	0.001430
2026-05-01	-0.000238
2026-06-01	0.000575
2026-07-01	0.000374
2026-08-01	0.000361
2026-09-01	0.000320
2026-10-01	0.000288
2026-11-01	0.000258
2026-12-01	0.000232

dtype: float64

```

from google.colab import files

# Crear un DataFrame con los resultados del forecast de productos dormidos
tabla_forecast_dormidos = pd.DataFrame({
    "Fecha": pred_2026.index,
    "Pronostico_Dormidos": pred_2026.values,
    "IC_Lower_Dormidos": ic_2026.iloc[:,0].values,
    "IC_Upper_Dormidos": ic_2026.iloc[:,1].values
})

```



**Presidencia
de la República
del Ecuador**



**Plan Nacional
de Ciencia, Tecnología,
Innovación y Saberes**



SENESCYT

Secretaría Nacional de Educación Superior,
Ciencia, Tecnología e Innovación


DECLARACIÓN Y AUTORIZACIÓN

Nosotras, **Rivera Zeas, Alyson Valeria**, con C.C: #0928258284 y **Zorrilla Quiroz, Viviana Elizabeth** con C.C: #0951264894 autores del trabajo de titulación: **Análisis predictivo de la demanda de bebidas para la estimación del inventario dormido en un establecimiento hotelero** previo a la obtención del título de **Licenciadas en Negocios Internacionales** en la Universidad Católica de Santiago de Guayaquil.

1.- Declaro tener pleno conocimiento de la obligación que tienen las instituciones de educación superior, de conformidad con el Artículo 144 de la Ley Orgánica de Educación Superior, de entregar a la SENESCYT en formato digital una copia del referido trabajo de titulación para que sea integrado al Sistema Nacional de Información de la Educación Superior del Ecuador para su difusión pública respetando los derechos de autor.

2.- Autorizo a la SENESCYT a tener una copia del referido trabajo de titulación, con el propósito de generar un repositorio que democratice la información, respetando las políticas de propiedad intelectual vigentes.

Guayaquil, 12 de febrero del 2026

f. 
Rivera Zeas, Alyson Valeria

f. 
Zorrilla Quiroz, Viviana Elizabeth



REPOSITORIO NACIONAL EN CIENCIA Y TECNOLOGÍA

FICHA DE REGISTRO DE TESIS/TRABAJO DE TITULACIÓN

TEMA Y SUBTEMA:	Análisis predictivo de la demanda de bebidas para la estimación del inventario dormido en un establecimiento hotelero		
AUTORAS	Rivera Zeas, Alyson Valeria Zorrilla Quiroz, Viviana Elizabeth		
REVISOR(ES)/TUTOR(ES)	Solórzano Carvajal, Mario David, Mgs.		
INSTITUCIÓN:	Universidad Católica de Santiago de Guayaquil		
FACULTAD:	Facultad de Economía y Empresa		
CARRERA:	Negocios Internacionales		
TÍTULO OBTENIDO:	Licenciada en Negocios Internacionales		
FECHA DE PUBLICACIÓN:	12 de febrero de 2026	No. DE PÁGINAS:	87 p.
ÁREAS TEMÁTICAS:	gestión de inventarios, modelado estadístico, inteligencia de negocios.		
PALABRAS CLAVES/ KEYWORDS:	inventario dormido, series temporales, baja rotación, análisis predictivo, SARIMA, inventarios.		
RESUMEN/ABSTRACT En la presente investigación, se analiza el comportamiento temporal de la demanda de bebidas de baja rotación en un establecimiento de hotelería en la ciudad de Guayaquil, cuyo principal objetivo es proyectar el nivel de inventario dormido para el período 2026. Luego de un proceso de depuración y consolidación de todas las requisiciones de forma mensual, se construyeron series de tiempo a fin de obtener el inventario dormido que, es definido operativamente como aquel producto sin movimientos durante un trimestre consecutivo. El análisis de rotación realizado por categorías, tales como cervezas, vinos y licores permitió la identificación de patrones estacionarios y de variabilidad. Se implementó un modelo predictivo SARIMA, el cual se valida mediante métricas de error (MAE) y análisis de significancia. los resultados, muestran que la baja rotación de productos exhibe variaciones estacionales que se vinculan a las fluctuaciones de la demanda en el establecimiento, manteniendo una media estable. Las proyecciones para el periodo 2026, indican la persistencia del stock inmovilizado bajo políticas actuales, haciendo énfasis en la necesidad de integrar modelos predictivos en la planificación, el estudio finaliza concluyendo que el análisis de series de temporales es un recurso fundamental para mitigar riesgos financieros en el contexto de una demanda fluctuante.			
ADJUNTO PDF:	☒ SI	☐ NO	
CONTACTO CON AUTOR/ES:	Teléfono: +593 964190082 +593 978650382	E-mail: valeriariverazeas@gmail.com vzorrillaq@gmail.com	
CONTACTO CON LA INSTITUCIÓN (COORDINADOR DEL PROCESO UTE)::	Nombre: Freire Quintero, Cesar Enrique Teléfono: +593 990090702 E-mail: cesar.freire@cu.ucsg.edu.ec		
SECCIÓN PARA USO DE BIBLIOTECA			
Nº. DE REGISTRO (en base a datos):			
Nº. DE CLASIFICACIÓN:			
DIRECCIÓN URL (tesis en la web):			