

Improvement of a restaurant's Service Level through Process Standardization and Machine Learning Techniques

Gianmarco Concha-Oblitas¹ ; Alex Gonzalez-Chiroque¹ ; Marcos Fernando Ruiz-Ruiz¹ ;
Juan Carlos Quiroz-Flores¹ 

¹Carrera de Ingeniería Industrial, Universidad de Lima, Perú, 20190510@aloe.ulima.edu.pe, 20192835@aloe.ulima.edu.pe, mruiz@ulima.edu.pe, jcquiroz@ulima.edu.pe

Abstract— This research aimed to demonstrate how combining engineering tools with Machine Learning models can help reduce the percentage of unserved customers in a restaurant. To achieve this, a methodology was designed that integrated process standardization through BPMN diagrams, the development of a digital reservation registration system, and the implementation of a predictive model based on linear regression. This approach made it possible to connect process improvement with data analytics, resulting in a practical solution adapted to the company's real operational conditions. Additionally, a custom code has been developed to make the most of the available information, despite the initial limitations related to the lack of digitalization. The results show significant improvements. The service level increased from 86.6% to 95.8% using the program Arena simulator, while demand planning accuracy improved from approximately 85% to 89%. Furthermore, a system guaranteeing 100% traceability of reservations was implemented, something the company did not have before. These findings demonstrate that integrating BPMN, process standardization and Machine Learning is a viable, efficient and replicable alternative for demand planning in environments with limited resources. Finally, the study concludes that digitalization plays a key role in enhancing operational efficiency within the food service sector. It is recommended to strengthen a data-driven organizational culture and progressively advance toward the adoption of digital predictive systems.

Keywords— Demand planning, Machine Learning, Linear regression, Process standardization, BPMN

Mejora en el Nivel de Servicio de un restaurante a partir de Estandarización de Procesos y Técnicas de Machine Learning

Gianmarco Concha-Oblitas¹ ; Alex Gonzalez-Chiroque¹ ; Marcos Fernando Ruiz-Ruiz¹ ;
Juan Carlos Quiroz-Flores¹

¹Carrera de Ingeniería Industrial, Universidad de Lima, Perú, 20190510@aloe.ulima.edu.pe, 20192835@aloe.ulima.edu.pe, mruiz@ulima.edu.pe, jcquiroz@ulima.edu.pe

Resumen— La presente investigación tuvo como objetivo demostrar cómo la combinación de herramientas de ingeniería y modelos de Machine Learning puede ayudar a reducir el porcentaje de clientes no atendidos en un restaurante. Para ello, se diseñó una metodología que integró la estandarización de procesos mediante diagramación BPMN, la creación de un sistema digital para el registro de reservas y la elaboración de un modelo predictivo basado en regresión lineal. Esta propuesta permitió unir la mejora de procesos con el análisis de datos, logrando una solución práctica y ajustada a las necesidades reales de la empresa. Además, se desarrolló un código propio capaz de aprovechar la información disponible, a pesar de las limitaciones iniciales en la digitalización. Los resultados obtenidos evidencian mejoras significativas. El nivel de servicio se elevó de 86.6% a 95.8% usando el simulador Arena, mientras que la precisión en la planificación de la demanda pasó de aproximadamente 85% a 89%. Asimismo, se logró implementar un sistema que garantiza el 100% de la trazabilidad en las reservas, un aspecto inexistente antes del estudio. Estos avances muestran que la integración de BPMN, estandarización de procesos y Machine Learning es una alternativa viable, eficiente y replicable en contextos con recursos limitados. Finalmente se concluye que la digitalización desempeña un papel clave en la mejora operativa del sector gastronómico. Se recomienda promover una cultura organizacional basada en datos y avanzar progresivamente hacia la adopción de sistemas predictivos digitales.

Palabras clave— planificación de demanda, Machine Learning, Regresión Lineal, Estandarización de procesos, BPMN

I. INTRODUCCIÓN

El sector gastronómico peruano ha experimentado un crecimiento sostenido en los últimos años, impulsado por el aumento del consumo fuera del hogar y la expansión de la oferta culinaria a nivel nacional. Un estudio reciente sobre gastronomía peruana identifica una evolución constante del segmento de restaurante y servicio asociados, destacando su posición de crecimiento exponencial en el ámbito [1]. De igual modo, el análisis de innovación en la industria gastronómica del Perú señala que la demanda interna, el turismo gastronómico y la diversificación culinaria han sido motores de expansión para establecimientos de lujo y de barrio [2]. En este entorno altamente competitivo, las micro y pequeñas

empresas que representan la mayoría del sector deben optimizar sus procesos para sostener niveles adecuados de servicio [3].

A pesar de este dinamismo, muchos negocios tradicionales presentan debilidades estructurales en planificación, control y estandarización operativa. En este contexto, la gestión eficiente de la demanda se vuelve crítica, especialmente para establecimientos que trabajan con insumos perecibles, alta variabilidad en el flujo de clientes y recursos limitados. El restaurante analizado es un ejemplo representativo de esta problemática: opera en una zona de elevada presión competitiva.

Durante el diagnóstico inicial, se identificaron deficiencias en la planificación del insumo principal, variabilidad en los tiempos de producción y la ausencia de un sistema formal para gestionar reservas, las cuales se registran de manera manual en conversaciones de WhatsApp o anotaciones sin trazabilidad. Esta falta de estandarización genera inconsistencias en la estimación diaria de la demanda, ocasionando sobreproducción, desabastecimientos y pérdidas directas por clientes no atendidos. Según el análisis de la información de 2024, estas deficiencias han impactado de manera significativa en el desempeño operativo y en el nivel de servicio del establecimiento.

Frente a esta problemática, la literatura reciente respalda el uso de herramientas analíticas y predictivas para mejorar la toma de decisiones en operaciones de alimentos. Diversos estudios demuestran que los modelos de Machine Learning permiten anticipar la demanda con mayor precisión que los métodos tradicionales, reduciendo la incertidumbre en la producción [4][5][6]. Asimismo, enfoques de estandarización como BPMN, SIPOC y Lean han mostrado mejoras en la calidad operativa y la eficiencia del servicio en negocios de hospitalidad [7][8][9].

A partir de lo identificado, surge la siguiente pregunta de investigación: “¿Cómo puede la estandarización de procesos y

la implementación de un modelo predictivo de demanda mejorar la planificación operativa y el nivel de servicio de un restaurante tradicional?”. La motivación de este estudio radica en demostrar que la integración de técnicas de ingeniería de procesos con modelos de aprendizaje automático puede ofrecer una solución de bajo costo, escalable y replicable para pequeñas empresas gastronómicas. Estudios previos señalan que esta combinación permite reducir pérdidas, optimizar el uso de insumos y anticipar fluctuaciones en la demanda [10][11][12]. Esta investigación busca aportar evidencia aplicada de cómo estas herramientas pueden mejorar el desempeño operativo en un restaurante local con recursos limitados.

Diagnóstico

Para evaluar la magnitud del problema, se analizaron los indicadores operativos correspondientes al año 2024. El establecimiento registró 16 935 clientes totales, de los cuales 1 635 no pudieron ser atendidos, lo que supone una pérdida directa del 9.65% del flujo anual de clientes. Asimismo, se identificó una brecha significativa entre la demanda real y la capacidad de producción, lo que generó la preparación incompleta de insumos y la acumulación de pérdidas operativas. Estas deficiencias se reflejaron en un nivel del servicio 86.6%, por debajo del estándar aceptable para servicios gastronómicos, lo que evidencia inconsistencias en la planificación diaria y la ausencia de un flujo formal para gestionar reservas, aforos y disponibilidad de inventario.

Otro indicador crítico identificado fue la ausencia de un sistema formal para gestionar reservas. La información recopilada muestra que estas se registran sin un formato estandarizado, no se asigna un responsable definido y no existe una base única para la toma de decisiones. Este proceso manual dificulta la estimación de la demanda esperada y contribuye directamente a la variabilidad en el uso del insumo principal. Además, la falta de integración entre reservas, previsiones de consumo y disponibilidad real de insumos incrementa la probabilidad de desabastecimientos en horas pico.

La Fig. 1 presenta una síntesis del proceso actual de planificación operativa del restaurante. Este diagrama evidencia la falta de sistemas de registro, estandarización y retroalimentación, lo que explica la brecha entre la demanda real y la capacidad operativa.




Fig. 1 Diagrama del proceso actual de planificación operativa (Bizagi)

La causa raíz principal fue el stock del día insuficiente, la cual representa el 72.2% del total con 1 635 clientes no atendidos por falta de stock. Esta causa responde a una planificación empírica y la falta de estandarización del proceso de planificación. En segundo lugar, su falta de control y gestión de reservas y pedidos anticipados generó una pérdida de 630 clientes (27.8%), debido a que el restaurante no cuenta con un procedimiento formal que permita registrar y organizar las reservas. Esto genera sobrecargas en días de alta demanda sin capacidad de una respuesta adecuada.

A partir del análisis cuantitativo realizado en el árbol de problemas, se identificó que las causas más significativas que originan el bajo nivel de servicio son el stock del día insuficiente y la falta de control y gestión de reserva y pedidos anticipados, las cuales representan en conjunto el 94.8% de los clientes no atendidos durante el año 2024. Por este motivo la propuesta de mejora se centrará en abordar las dos causas raíz de mayor impacto mediante la implementación de herramientas de pronóstico de demanda que permitan planificar con una mayor precisión la cantidad de insumo a preparar, y la estandarización del proceso de gestión de reservas y pedidos anticipados. Este enfoque busca generar un efecto directo sobre la reducción de clientes no atendidos y el incremento del nivel de servicio, con el objetivo de alcanzar o incluso superar el estándar del sector.

Revisión de Literatura

La pandemia ha tenido un gran impacto para los restaurantes, llevándolos a tomar la decisión de analizar a profundidad el planeamiento de la demanda a través de la digitalización. Antes recurrían a las predicciones de demanda y en la metodología just-in-time, pero la cadena de suministro para alimentos sufrió cambios de complejidad para analizar la demanda y surgieron nuevas herramientas o métodos como Machine Learning, visualización de data y/o la planificación empresarial integrada (IBP en sus siglas en inglés) [13].

Como estrategia para mejorar la precisión de la planificación de la demanda, teniendo en cuenta que los resultados pueden ser variables, la mejor opción es el uso de modelos en redes neuronales. Si bien [14] reporta altos niveles de precisión de hasta 89% en escenarios con horizontes de demanda amplios (anual), otras investigaciones como la de [15] evidencia que, al aplicar redes neuronales en periodos cortos de tiempo, ya sea diario o semanal, no se obtiene cierta claridad y los modelos se tornan complejos. La efectividad de estos modelos depende de la escala temporal de la problemática y existe el riesgo de sobredimensionar entornos volátiles o planificación de corto plazo.

Un caso particular es el de [5], quien aplicó múltiples modelos predictivos en el sector gastronómico, obteniendo mejoras de entre 5-10% en la precisión de la demanda. Aunque usar diversas técnicas permitió visualizar patrones consistentes, tratar de complementarlas fue el obstáculo, los restaurantes son entornos de alta variabilidad, depender de datos históricos es un riesgo si no se acompaña con mecanismos de ajuste (retroalimentación continua) en tiempo real.

Finalmente, se evidencia la tendencia de uso de modelos de Machine Learning para la planificación de la demanda y estandarización de procesos en los diferentes casos de estudios presentados, pero es inevitable tener riesgos técnicos y operativos, como la sobrestimación de predicción o no contar con factores como la frecuencia de consumo. Además, se debe tener en cuenta la calidad de los datos o qué tan viable es aplicar cierto modelo en entornos como restaurantes.

II. METODOLOGÍA

La presente investigación se enmarca como un estudio de caso de mejora aplicada, con diseño simulado bajo un esquema pretest-postest. El alcance es descriptivo y predictivo, ya que se enfoca en la situación actual de la empresa y se proyectan los escenarios futuros mediante modelos de Machine Learning y el rediseño de proceso con BPMN y SIPOC. La metodología se organiza en tres fases: diagnóstico, diseño e implementación, y validación, estas fases servirán como una base para el desarrollo del modelo conceptual de la propuesta como se detalla en la siguiente Tabla I.

TABLA I
DISEÑO METODOLÓGICO

FASES	ALCANCE	HERRAMIENTAS	VALIDACIÓN
DIAGNÓSTICO DEL PROBLEMA	Identificar causas raíz y medir indicadores en base a la problemática	-El análisis de indicadores operativos (clientes atendidos/no atendidos, ventas totales del año). -Árbol de problemas	Triangulación con los datos históricos y validación con el personal del restaurante.
DISEÑO E IMPLEMENTACIÓN	Propuesta orientada a la estandarización del proceso de planificación de la demanda, pronóstico de ventas y gestión de reservas.	-Estandarización de procesos mediante el uso de BPMN -Machine Learning en Python: Regresión Lineal -Diagrama SIPOC	Simulación del modelo propuesto. Triangulación con expertos en Machine Learning y gestión de procesos.
VALIDACIÓN	Comparar indicadores AS-IS y TO-BE (nivel de servicio, precisión de planificación) Evaluar los impactos económicos y operativos.	Indicadores de precisión (MAE, RMSE, R ² y MAPE)	Datos reales de la empresa y contraste con estándares del sector.

Se ha planteado un modelo conceptual que se compone de una estructura macro integrando diferentes módulos orientados a mejorar el nivel de servicio del establecimiento analizado. Este modelo reúne tanto información histórica de la demanda como los procesos vinculados a la gestión de clientes, con el fin de obtener una planificación de demanda más precisa y disminuir la brecha técnica identificada. Bajo esta lógica, se establecen entradas clave que permiten organizar los datos de acuerdo a las herramientas de ingeniería a utilizar.

A partir del modelo conceptual, este se divide en dos entradas principales: la información histórica del negocio y los registros de pedidos por reserva. La primera entrada reúne datos para entender el contexto de la empresa como ventas del periodo, la cual pasa por un análisis de estacionalidad semanal y manejo de eventos especiales, integrando factores como precios de los productos, y el bajo nivel de servicio identificado como problema inicial. La segunda entrada

complementa este enfoque mediante la recopilación de todas las reservas registradas, permitiendo integrar la demanda presencial y la demanda programada.

Ambas se integran en un modelo central dividido en tres módulos: la estandarización de procesos, el uso de Machine Learning y gestión de reservas. El primer módulo se orienta a simular y validar el proceso mediante el programa Arena, el segundo emplea un modelo de regresión lineal codificado en Python para proyectar la demanda. Para optimizar la predicción, el modelo incluye el manejo de eventos especiales (feriados), fines de semana y la tendencia de las ventas de días anteriores para identificar patrones de consumo. Se prioriza este algoritmo frente a modelos complejos como Redes Neuronales para evitar el sobreajuste al trabajar con un dataset limitado a un año de registros diarios [4][15].

Para garantizar el rigor técnico y evitar que el código memorice la información, se implementa una validación cruzada formal para series temporales (Time Series Split), asegurando que el código entrene con datos históricos para evaluar bloques futuros. Bajo este esquema, se incorpora un análisis de overfitting comparando el rendimiento entre entrenamiento y prueba para asegurar la capacidad de generalización del sistema. Por último, el flujo de reservas con un diagrama SIPOC actualizado. La combinación de estos módulos genera una única salida de información: el aumento del nivel de servicio, evidenciando que la mejora simultánea de la planificación de la demanda y del control de reservas contribuye directamente a reducir la brecha técnica.

III. RESULTADOS

El análisis del proceso actual evidencia que la ausencia de estandarización genera un nivel de servicio de 86.6%, con 1635 clientes no atendidos durante 2024; cabe precisar que, debido al horizonte de tiempo de un año, no se analizaron patrones de estacionalidad anual; sin embargo, el modelo captura la estacionalidad semanal mediante variables. El principal problema identificado fue la falta de un flujo formal para la planificación y la gestión de reservas, lo que ocasionó un stock insuficiente en el 72.2% de los casos y pérdidas adicionales del 27.8% debido a registro manuales sin trazabilidad. Estos hallazgos confirmaron que la raíz del problema era estructural y que la estandarización del proceso constituye el eje central de mejora.

Como soporte cuantitativo al proceso estandarizado, se desarrolló un modelo de Regresión Lineal el cual fue validado mediante Time Series Split, dando como resultado un R² de entrenamiento de 0.8943 y R² de prueba de 0.8901 explicando el 89% de la variabilidad. La diferencia entre ambos resultados demuestra empíricamente la ausencia de sobreajuste. Asimismo, los errores promedios de predicción se sitúan en 1.5077 clientes (RMSE) y 1.2047 clientes (MAE). El. Si bien el ML no constituye la herramienta principal de la

propuesta, si actúa como un componente crítico de apoyo, permitiendo alimentar el flujo de BPMN con datos confiables y reducto la incertidumbre operativa en la planificación.

El análisis del proceso de reservas mediante la herramienta SIPOC permitió identificar con precisión las entradas, responsables y salidas involucradas en el flujo To-Be. La digitalización del registro de reservas y la verificación automática de disponibilidad eliminaron las pérdidas de información presentes en el escenario As Is, donde predominaban registros manuales sin control. El SIPOC posibilitó clarificar los roles del cliente, la propietaria y sistema digital, estableciendo un circuito formal donde cada reserva queda registrada, confirmada y enviada al área de cocina. Como resultado, se logró trazabilidad completa de las solicitudes, lo que constituye la base del posterior desempeño mejora en los indicadores operativos. La Fig. 2 muestra la estructura del SIPOC para el proceso de reservas.

Supplier (Proveedor)	Input (Entrada)	Process (Proceso To-Be)	Output (Salida)	Customer (Cliente)
Cliente externo	Solicitud de reserva ingresada mediante formulario digital (Google Forms o Excel Online)	- El cliente envía su solicitud. - El sistema verifica automáticamente e la disponibilidad según el aforo. - Se genera confirmación automática al cliente y notificación a la propietaria	Reserva confirmada y registrada en base de datos digital.	Área de atención / Propietaria
Propietaria del restaurante	Parámetros de capacidad y horarios establecidos en el formulario	- Supervisa reservas confirmadas. - Consolidar las solicitudes en el Plan Maestro Diario (PMD).	Reporte de reservas confirmadas integrado al PMD.	Cocina / Administración
Sistema digital	Base de datos de reservas actualizada en tiempo real	Genera reporte diario de reservas confirmadas y disponibilidad de mesas.	Información estructurada para la planificación de producción.	Propietaria / Cocina / Atención

Fig. 2 SIPOC del proceso de reservas

La estandarización del proceso mediante el BPMN permite reorganizar las actividades críticas, eliminar pasos redundantes y formalizar el flujo entre atención, cocina y administración. El rediseño incorporó puntos de control en la identificación y confirmación de reservas, integran un registro digital que alimenta automáticamente el Plan Maestro Diario (PMD). Este documento consolida las reservas confirmadas y la disponibilidad de producción, garantizando coherencia entre la demanda prevista y la planificación del día. El BPMN

To-Be, validado posteriormente en Arena, estructuró un proceso más estable y coordinado, disminuyendo la incertidumbre operativa observada en el escenario As-Is. La Fig. 3 muestra el flujo estandarizado del proceso To-Be.




Fig. 3 Proceso de planificación To-Be

La simulación del proceso To-Be en Arena permitió validar el desempeño del flujo estandarizado bajo condiciones operativas reales. En este escenario, el nivel de servicio se incrementó a 95.8%, mostrando una operación más estable frente a la variabilidad observada en el proceso actual. Asimismo, la tasa de pérdida se redujo a un 3.1%, reflejando una disminución significativa de clientes no atendidos. Estas mejoras responden a la reorganización del flujo operativo mediante BPMN y a la integración del PMD como consolidado diario, que fortalecen la coordinación entre reservas, cocina y atención. La comparación cuantitativa entre ambos escenarios se presenta en la Tabla II a continuación.

TABLA II
TABLA COMPARATIVA DE INDICADORES

KPI	As-Is	To-Be
NIVEL DE SERVICIO	86.6%	95.8%
TASA DE PÉRDIDA	13.4%	3.1%
PRECISIÓN DE LA PLANIFICACIÓN	85%	≥ 89%
TRAZABILIDAD DE RESERVAS	0%	100%

La comparación entre ambos escenarios evidencia mejoras significativas tras la estandarización del proceso. El nivel de servicio se incrementó de 86.6% a 95.8%, lo que representa un aumento de casi 10 puntos porcentuales en la capacidad de atención efectiva. La tasa de pérdida disminuye de 13.4% a 3.1%, consolidando una reducción superior al 75% en clientes no atendidos. La precisión de planificación pasó de 85% a un valor igual a 89%, reforzando la coherencia entre demanda estimada y producción. Finalmente, la trazabilidad, inexistente en el escenario del As-Is, alcanzó el 100% gracias a la digitalización del registro y la integración del Plan Maestro Diario (PMD). En conjunto, estos resultados

confirman que la propuesta To-Be genera una mejora estructural y medible en el desempeño operativo.

Todas las mejoras observadas en el escenario To-Be se mantuvieron estables en las distintas corridas de simulación, los resultados del escenario To-Be mantuvieron similares, lo que deja claro que no depende de variaciones aleatorias del sistema. El aumento en el nivel de servicio, la disminución de la tasa de pérdida y el mayor acierto en la planificación se mantuvieron dentro de un rango muy reducido, algo poco probable si todos estos cambios fueran de manera aleatoria. Esa constancia apunta a que las mejoras provienen del propio rediseño del proceso y de la manera en que se organizaron las actividades, más que de fluctuaciones pasajeras. En conjunto, la estabilidad de los resultados refuerza la solidez del modelo propuesto y muestra que su efecto puede replicarse sin problemas en condiciones reales de operación.

IV. DISCUSIÓN

La sección de discusión analiza los resultados obtenidos a partir del rediseño del proceso, la digitalización del flujo de información y la integración de molesto predictivos de la demanda. Estos hallazgos se contrastan con evidencia científica reciente para identificar convergencias, divergencias y aportes del presente estudio en el ámbito de la gestión operativa de restaurantes. Asimismo, se discuten los beneficios del escenario To-Be respecto al As-Is, evaluando como la estandarización mediante BPMN, la simulación en Arena y el uso de Machine Learning contribuye a mejorar la eficiencia, la precisión de la planificación y la trazabilidad del servicio.

Los resultados del estudio evidencian que la digitalización y la estandarización de procesos son factores decisivos para mejorar el desempeño operativo en restaurantes. La reducción de pérdidas de información, la mejora en la trazabilidad y la consolidación del flujo de reservas coinciden con lo reportado por [16][17], quienes destacan que la adopción de tecnologías digitales reduce la variabilidad del servicio y fortalece la experiencia del cliente. A su vez, estos hallazgos se alinean con las conclusiones de [18][19], quienes subrayan que la digitalización no solo optimiza procesos internos, sino que también permite decisiones más acertadas basadas en datos confiables.

Los resultados del modelo de Machine Learning mostraron un desempeño superior al de los métodos tradicionales con un R^2 de 0.8901 y un MAE de 1.204 clientes. Este rendimiento se encuentra en línea con investigaciones previas, como las de [4][5][20], que demuestran que los algoritmos predictivos incrementan significativamente la exactitud en contextos alimentarios. De acuerdo con [13], refuerza este argumento al señalar que la calidad del dato

estructurado impulsa el rendimiento de modelos de predicción, lo cual coincide con la implementación del Plan Maestro Diario. De igual forma, [21] evidencia que la integración de Machine Learning puede optimizar la preparación en servicios de comida.

Desde la perspectiva de estandarización, el uso de BPMN permite simplificar el flujo operativo y clarificar responsabilidades, lo cual coincide con los resultados de [8], el cual muestra que la correcta estructuración de proceso en restaurante reduce cuello de botella y mejora el rendimiento general del servicio. La validación mediante simulación en Arena complementa este análisis, reproduciendo el comportamiento del sistema con base en el diseño To-Be y confirmando la mejora en nivel de servicio. Este enfoque de estandarización, digitalización y simulación coincide con tendencias actuales de análisis de escenarios destacados por [22][23].

En conjunto, los resultados del estudio convergen con evidencia internacional al demostrar que la transformación digital, el uso de análisis predictivo y la estandarización del proceso operativo pueden aplicarse con éxito incluso en pequeñas empresas gastronómicas con recursos limitados. Aunque investigaciones previas suelen centrarse en grandes cadenas [13][19], estos estudios aportan evidencia de que estas herramientas también pueden implementarse en restaurantes familiares. Las principales divergencias se encuentran en la limitada disponibilidad de datos históricos, aunque la evidencia indica que, con un flujo estructurado y disciplinado, es posible alcanzar resultados de alta precisión, tal como lo sugiere [14][23]. En conjunto, la evidencia confirma la relevancia de integrar digitalización, Machine Learning y BPMN en entornos gastronómicos de pequeña escala.

V. CONCLUSIONES

La investigación permitió comprobar que la combinación de herramientas de ingeniería y modelos predictivos basados en Machine Learning constituye una alternativa eficiente para mejorar la gestión de la demanda de restaurantes. La metodología aplicada permitió estandarizar los procesos y generar un flujo de información coherente, sobre el cual se construyó un modelo de regresión lineal que alcanzó una precisión del 89%, superando el 85%. También se incrementó el nivel de servicio de 86.6% a 95.8% y con la implementación del sistema digital de reservas se alcanzó el 100% de trazabilidad. Esto evidencia que los métodos de análisis de datos pueden reemplazar con éxito las proyecciones empíricas, contribuyendo a la reducción de clientes no atendidos y a una planificación más confiable. Se conoce el aporte de la investigación; no obstante, se conocen limitaciones al tamaño de muestra y al horizonte temporal de la información, como patrones estacionales o eventos especiales, que influyen directamente en el comportamiento de la demanda.

Durante el desarrollo del estudio se identificaron diversos obstáculos que enfrentan los restaurantes para predecir su demanda de forma efectiva. Entre los más relevantes destacan la escasez de registros históricos, la inexistencia de herramientas digitales y la poca familiaridad del personal con sistemas analíticos. Estos factores limitaron inicialmente la implementación del modelo y requirieron diseñar un código desde cero, ajustado a las condiciones reales de la empresa. A pesar de ellos, se logró desarrollar una solución funcional y válida, lo cual demuestra que la innovación no depende únicamente de recursos tecnológicos, sino también de la capacidad de adaptación y del uso eficiente de información disponible. Este proceso reafirma la importancia de fomentar una cultura orientada a los datos en las organizaciones de servicios y mejora continua.

La digitalización generó un cambio estructural en la manera que los restaurantes administran sus operaciones. Su incorporación permitió mejorar la precisión de las proyecciones, optimizar la gestión de reservas, reducir tiempos de espera de clientes y disminuir los clientes no atendidos. Más allá de un avance tecnológico, representa una forma de gestionar conocimiento, basada en evidencia. Además de incrementar la eficiencia, impulsa la sostenibilidad al reducir desperdicios y mejorar el uso de recursos. En el contexto post pandemia, su relevancia se ha intensificado posicionándose como una necesidad estratégica para la supervivencia y crecimiento del sector gastronómico.

En función de los hallazgos, se recomienda que los restaurantes adopten gradualmente sistemas productivos integrados a sus procesos operativos. Este cambio debe ir acompañado de la capacitación del personal en el uso de herramienta analíticas, la consolidación de una base de datos confiable y la implementación de plataformas digitales para la gestión de reservas y demanda. Asimismo, sería conveniente establecer alianzas con instituciones académicas o tecnológicas que apoyen la transferencia de conocimiento y la validación de modelos predictivos. En definitiva, el fortalecimiento de la digitalización y la analítica permitirá a las empresas del sector gastronómico anticiparse a la variabilidad del mercado, mejorar la calidad del servicio y consolidar su competitividad a largo plazo.

REFERENCIAS

- [1] J. Aguirre-Sosa, M. L. Dextre, M. Lozada-Urbano, and J. A. Vargas-Merino, "Background of Peruvian gastronomy and its perspectives: an assessment of its current growth," *Journal of Ethnic Foods*, vol. 10, no. 1, Dec. 2023, doi: 10.1186/s42779-023-00212-4.
- [2] J. Elias and M. Lozada-Urbano, *Analysis of innovation in Peru's gastronomic industry*. Inter-American Development Bank, 2022. [Online]. Available: <https://publications.iadb.org/en/analysis-innovation-perus-gastronomic-industry>
- [3] D. Limaymanta-Rojas, C. Olguín-Rodríguez, A. Flores-Perez, and M. F. Ruiz-Ruiz, "Determinant factors for the restaurant sector since the COVID-19 pandemic. The Peruvian case," *Proc. 1st Australian Int. Conf. Industrial Engineering and Operations Management*, pp. 637–649, Apr. 2023, doi: 10.46254/au01.20220173.

- [4] M. Aci and D. Yergök, "Demand forecasting for food production using Machine Learning Algorithms: A case study of University Refectory," *Tehnički Vjesnik - Technical Gazette*, vol. 30, no. 6, Oct. 2023, doi: 10.17559/tv-20230117000232.
- [5] T. Tanizaki, T. Hoshino, T. Shimmura, and T. Takenaka, "Demand forecasting in restaurants using machine learning and statistical analysis," *Procedia CIRP*, vol. 79, pp. 679–683, Jan. 2019, doi: 10.1016/j.procir.2019.02.042.
- [6] M. Rodrigues, V. Miguéis, S. Freitas, and T. Machado, "Machine learning models for short-term demand forecasting in food catering services: A solution to reduce food waste," *Journal of Cleaner Production*, vol. 435, p. 140265, Dec. 2023, doi: 10.1016/j.jclepro.2023.140265.
- [7] S. Chalupa and M. Petricek, "The application of business process management in the hospitality industry: a case study," *IBIMA Business Review*, pp. 1–11, Jul. 2020, doi: 10.5171/2020.301930.
- [8] A. A. Nurdin, A. N. Pristanti, and N. Samantha, "Business process modeling at steak restaurant using business process model and notation," *Journal of Soft Computing Exploration*, vol. 3, no. 2, Sep. 2022, doi: 10.52465/josce.v3i2.84.
- [9] H. Raharjo and E. Wahyurini, "Improving service quality using BPMN and Lean approaches: A case in reservation management," *International Journal of Quality & Reliability Management*, vol. 41, no. 2, pp. 221–239, 2024, doi: 10.1108/IJQRM-03-2023-0105.
- [10] N. K. Ahmed, A. F. Atiya, N. E. Gayar, and H. El-Shishiny, "An empirical comparison of machine learning models for time series forecasting," *Econometric Reviews*, vol. 29, no. 5–6, pp. 594–621, Aug. 2010, doi: 10.1080/07474938.2010.481556.
- [11] K. Bandara, P. Shi, C. Bergmeir, H. Hewamalage, Q. Tran, and B. Seaman, "Sales demand forecast in e-commerce using a Long Short-Term Memory Neural Network methodology," *Neural Information Processing (ICONIP 2019)*, T. Gedeon, K. Wong, and M. Lee, Eds., *Lecture Notes in Computer Science*, vol. 11955. Cham: Springer, 2019, pp. 462–474, doi: 10.1007/978-3-030-36718-3_39.
- [12] I. Vallés-Pérez, E. Soria-Olivas, M. Martínez-Sober, A. J. Serrano-López, J. Gómez-Sanchis, and F. Mateo, "Approaching sales forecasting using recurrent neural networks and transformers," *Expert Systems With Applications*, vol. 201, p. 116993, Apr. 2022, doi: 10.1016/j.eswa.2022.116993.
- [13] B. Chae, C. Sheu, and E. O. Park, "The value of data, machine learning, and deep learning in restaurant demand forecasting: Insights and lessons learned from a large restaurant chain," *Decision Support Systems*, vol. 184, p. 114291, Jul. 2024, doi: 10.1016/j.dss.2024.114291.
- [14] C. Saha, S. S. Lam, and W. Boldrin, "Demand Forecasting for Server Manufacturing Using Neural Networks," *Proceedings of the 2014 Industrial and Systems Engineering Research Conference*, Y. Guan and H. Liao, Eds., Montreal, Canada, 2014, [Online]. Available: https://www.researchgate.net/profile/Chanchal_Saha/publication/283732695_Demand_Forecasting_for_Server_Manufacturing_Using_Neural_Networks/links/564632b808ae451880aa3b5e.pdf
- [15] A. Schmidt, M. W. U. Kabir, and M. T. Hoque, "Machine learning based restaurant sales forecasting," *Machine Learning and Knowledge Extraction*, vol. 4, no. 1, pp. 105–130, Jan. 2022, doi: 10.3390/make4010006.
- [16] R. Alt, "Digital transformation in the restaurant industry: current developments and implications," *Journal of Smart Tourism*, vol. 1, no. 1, pp. 69–74, Mar. 2021, doi: 10.52255/smarttourism.2021.1.1.9.
- [17] B. Esposito, M. R. Sessa, D. Sica, and O. Malandrino, "Service innovation in the restaurant sector during COVID-19: digital technologies to reduce customers' risk perception," *The TQM Journal*, vol. 34, no. 7, pp. 134–164, May 2022, doi: 10.1108/tqm-01-2022-0016.
- [18] L. Bujalance-López, L. González-Serrano, M. P. L. Sancho, and P. Talon-Ballester, "Restaurant revenue management: a systematic literature review and future challenges," *British Food Journal*, vol. 127, no. 6, pp. 2169–2196, Apr. 2025, doi: 10.1108/bfj-08-2024-0816.
- [19] T. Gaertner, C. Lippert, and S. Konigorski, "Automated Demand Forecasting in small to medium-sized enterprises," *arXiv (Cornell University)*, Dec. 2024, doi: 10.48550/arxiv.2412.20420.
- [20] J. Garcia-Arismendiz, S. Huertas-Zúñiga, C. A. Lizárraga-Portugal, J. C. Quiroz-Flores, and Y. J. Garcia-Lopez, "Improving demand forecasting by implementing machine learning in poultry production company," *International Journal of Engineering Trends and Technology*, vol. 71, no. 2, pp. 39–45, Feb. 2023, doi: 10.14445/22315381/ijett-v71i2p205.
- [21] K. Posch, C. Truden, P. Hungerländer, and J. Pilz, "A Bayesian approach for predicting food and beverage sales in staff canteens and restaurants," *International Journal of Forecasting*, vol. 38, no. 1, pp. 321–338, Jul. 2021, doi: 10.1016/j.ijforecast.2021.06.001.
- [22] J.-G. Choi, Y.-W. Zhang, and N. I. B. M. Nadzri, "A Review of Forecasting Studies for the Restaurant Industry: Focusing on results, contributions and limitations," *GLOBAL BUSINESS & FINANCE REVIEW*, vol. 27, no. 2, pp. 61–77, Apr. 2022, doi: 10.17549/gbfr.2022.27.2.61.
- [23] S. Jayapal, *Food demand prediction using statistical and machine learning models*. Master's thesis, National College of Ireland, 2023. [Online]. Available: <https://norma.ncirl.ie/6594/>