

ANÁLISIS DE LA FORMACIÓN BRUTA DE CAPITAL FIJO EN EL SECTOR TURÍSTICO MEDIANTE TENSORFLOW PARA DEFINIR POSICIONAMIENTO COMPETITIVO

ANALYSIS OF GROSS FIXED CAPITAL FORMATION IN THE TOURISM SECTOR USING TENSORFLOW TO DEFINE COMPETITIVE POSITIONING

**JENNIFER LÓPEZ CHACÓN,
MARTHA BEATRIZ FLORES ROMERO,
MARCELA FIGUEROA AGUILAR**

UNIVERSIDAD MICHOACANA DE SAN NICOLAS DE HIDALGO

México

Recibido el 11 de septiembre de 2024; Aceptado el 16 de enero 2025; Disponible en Internet el 01 de diciembre de 2025

E-mail de Contacto: jennifer.lopez@umich.mx

© Universidad Michoacana de San Nicolás de Hidalgo (México)

Vol. 9, N.º 18 Pág.24-33. ISSN: 2448-6051

Av. Gral. Francisco J. Múgica S/N
Edificio AII C.P. 58030
Ciudad Universitaria
Morelia, Michoacán, México.
Tel. y Fax (443) 3-16-74-11
Email: rfcca@umich.mx
Web: <http://rfcca.umich.mx>

Resumen- Este estudio analiza el impacto de la inversión en formación bruta de capital fijo (FBCF) sobre el posicionamiento competitivo del sector turístico en México, utilizando redes neuronales en TensorFlow para predecir y optimizar decisiones de inversión. La investigación se enfoca en dos componentes clave de la FBCF: la construcción y la inversión en maquinaria y equipo. Con datos de la Cuenta Satélite del Turismo de México, el modelo propuesto permite predecir el comportamiento de estas variables y su efecto en el rendimiento del sector turístico. La metodología empleada incluye un modelo de red neuronal que consta de múltiples capas, optimizado para identificar patrones en la inversión y su relación con la producción del sector turístico. El análisis estadístico de los resultados indica que la inversión en construcción y maquinaria tiene una influencia positiva y significativa en la producción del sector, con un modelo real mostrando un R^2 de 0.928 y un modelo predicho con un R^2 de 0.975. Los coeficientes obtenidos sugieren que, por cada millón de pesos invertido, la producción en el sector turístico podría aumentar en aproximadamente 13,213 pesos cuando la inversión se destina a construcción y en 8,643 pesos cuando se destina a maquinaria. Este enfoque cuantitativo proporciona a los tomadores de decisiones herramientas efectivas para planificar inversiones en infraestructura turística, lo que permite maximizar el retorno económico y fortalecer la competitividad del sector. Los hallazgos también destacan la aplicabilidad de redes neuronales en el análisis de datos económicos complejos y sugieren futuras investigaciones en áreas como la predicción de demanda hotelera y la creación de perfiles turísticos. La capacidad del modelo para predecir y optimizar la FBCF en turismo aporta valor a la planificación estratégica del sector en México, promoviendo su desarrollo sostenible.

Palabras Clave- Formación de capita; TensorFlow; Turismo Mexicano; Inteligencia Artificial; Redes neuronales.

Abstract- This study analyzes the impact of gross fixed capital formation (GFCF) investment on the competitive positioning of Mexico's tourism sector, using neural networks in TensorFlow to predict and optimize investment decisions. The research focuses on two key components of GFCF: construction and investment in machinery and equipment. Using data from Mexico's Tourism Satellite Account, the proposed model allows for the prediction of these variables' behavior and their effect on the sector's performance. The methodology employs a neural network model with multiple layers, optimized to identify patterns in investment and its relationship with tourism production. Statistical analysis of the results indicates that investment in construction and machinery has a positive and significant influence on the sector's production, with a real model showing an R^2 of 0.928 and a predicted model with an R^2 of 0.975. The obtained coefficients suggest that, for each million pesos invested, tourism sector production could increase by approximately 13,213 pesos when the investment is allocated to construction and by 8,643 pesos when allocated to machinery. This quantitative approach provides decision-

makers with effective tools for planning investments in tourism infrastructure, allowing them to maximize economic returns and strengthen the sector's competitiveness. The findings also highlight the applicability of neural networks in analyzing complex economic data and suggest future research in areas such as predicting hotel demand and creating tourism profiles. The model's ability to predict and optimize GFCF in tourism adds value to strategic planning in Mexico's tourism sector, promoting sustainable development.

Keywords- Capital formation; TensorFlow; Mexican Tourism; Artificial Intelligence; Neural Networks.

JEL CODE— L83, C45, C55, E22, O47

INTRODUCCIÓN

En México, el turismo es una de las actividades económicas más relevantes debido a la diversidad de paisajes y destinos que ofrece el país. Esta actividad impacta el desarrollo regional y contribuye significativamente al Producto Interno Bruto (PIB) nacional, de acuerdo con la Secretaría de Turismo y la Cuenta Satélite del Turismo de México. En este contexto, resulta crucial entender cómo la inversión en formación bruta de capital fijo puede contribuir al posicionamiento competitivo del sector turístico mexicano (Secretaría de Turismo, 2022).

El problema de la presente investigación consiste en predecir el comportamiento de la Formación Bruta de Capital Fijo, a partir de datos históricos de Inversión en Construcción e Inversión en Maquinaria y Equipo, lo cual permitirá a la Industria del Turismo hacer planeación de Inversiones y financiamientos, para fortalecer aquellas áreas que de acuerdo al modelo no resulten con resultados favorables a las políticas de inversión requeridas para mantener el Turismo en el Largo Plazo.

El impacto de la presente investigación es por un lado actualizar el estado del arte en torno a la Formación Bruta de Capital Fijo y su análisis a través de Redes Neuronales y por otro mostrar otra vertiente metodológica, que no se había utilizado para medir las variables de esta investigación. Otra contribución de esta investigación es a través de un modelo, que plasme la realidad del Turismo, aplicándolo a datos históricos para poder predecir las tendencias de las variables, aportando a la investigación empírica.

Dentro de los trabajos de investigación encontrados donde se usan redes neuronales en el sector turístico se encuentran aquellos que usan las redes neuronales para la predicción de la demanda turística, para esto se emplean datos históricos relacionados con el turismo,

como la cantidad de visitantes, tendencias de reserva, factores económicos y eventos locales. El proceso implica la recopilación y preprocesamiento de datos, el diseño del modelo de red neuronal adecuado, el entrenamiento del modelo con datos históricos y la validación del modelo para evaluar su rendimiento. Una vez entrenado y validado, el modelo puede utilizarse para predecir la demanda futura de turismo en función de las variables seleccionadas. Este enfoque permite tomar decisiones informadas sobre la gestión de destinos y la planificación de actividades turísticas. En este trabajo se propone usar redes neuronales enfocadas para predecir la Formación Bruta de Capital Fijo (FBCF) utilizando un modelo multivariable.

Este estudio contribuye a la literatura sobre turismo en México al proporcionar un análisis detallado del impacto de la inversión en infraestructura sobre el posicionamiento competitivo del sector a nivel estatal. El estudio se enfoca en aspectos concretos y medibles, como la formación bruta de capital fijo en construcción y maquinaria, y su impacto en el posicionamiento de los destinos turísticos. Esto permite ofrecer recomendaciones específicas y prácticas para la planeación de inversiones que optimicen la competitividad del turismo en un contexto nacional.

Hipótesis General:

La inversión en formación bruta capital fijo es determinante para el posicionamiento competitivo de la Industria del Turismo.

Objetivo General

Analizar el impacto de la inversión en formación bruta de capital fijo en el posicionamiento competitivo del sector turístico en México, empleando redes neuronales para predecir y optimizar estrategias de inversión en infraestructura.

Objetivos específicos:

1. Medir el impacto de la inversión en construcción en la competitividad del sector turístico.
2. Cuantificar cómo influye la inversión en maquinaria y equipo en el sector turístico.
3. Evaluar la precisión de un modelo de redes neuronales en la predicción de FBCF en el turismo, utilizando TensorFlow.

Tanto las hipótesis como los objetivos planteados anteriormente, se sustentan teóricamente en el desarrollo de la presente investigación. De la misma forma, el diseño de la investigación nos permite

contrastar dicha hipótesis con los resultados encontrados, alcanzando los objetivos planteados en un origen. El diseño y desarrollo metodológico, de la presente investigación permitirá la predicción de otras variables del Sector Turismo.

MARCO TEÓRICO

Competitividad Turística

El posicionamiento competitivo de la Industria del Turismo se ha medido desde diferentes aristas y utilizando diversas herramientas o indicadores. El análisis de la información depende si es turismo receptivo o turismo de exportación (Flores Lujano, 2018).

Otra forma de medir la Competitividad Turística en sus diversos estudios a través de indicadores, para definir el posicionamiento a Nivel Micro y Meso, basado en elementos de infraestructura de la Industria, referentes a los elementos físicos aportados por inversionistas, tales como la infraestructura, el mobiliario y equipo de cómputo y de transporte, considerados en estudios, como Recursos y factores condicionantes y limitantes (Crouch, 2011), Este modelo fue uno de los primeros en la literatura académica y, al ser de naturaleza conceptual, ha establecido las bases para el desarrollo de otros modelos como los de Dwyer y Kim (2003), Cucculelli y Goffi (2016), Goffi (2013).

Otros estudios orientados a medir la Competitividad a través de indicadores, consideran los Factores y Recursos de Apoyo, así como los Recursos Creados (Berdo, 2015). Este modelo ha sido utilizado en destinos de Corea, Australia, Serbia, Croacia y Eslovenia. Incluye tanto la oferta como la demanda, y los atributos se evalúan de forma cuantitativa, multidimensional, abstracta y con cierto grado de imprecisión (Berdo, 2015; Gomezelj & Mihalic, 2008; Petkovic et al., 2017).

Un enfoque diferente en conceptos, pero con la misma orientación, la medición de la Competitividad Turística, es el de WEF que clasifica los elementos de infraestructura, los denomina facilitadores y habla específicamente del alojamiento, considerando la infraestructura y equipamiento.

Otra aportación es la de Jiménez y Aquino (2012) cuyo modelo se basa en otros enfoques sobre competitividad propuestos por Ritchie y Crouch (2000), Dwyer y Kim (2003), así como en los índices elaborados por el Foro Económico Mundial y el Instituto Tecnológico de Estudios Superiores de

Monterrey. No obstante, su enfoque principal se encuentra en la cadena de valor turística, analizando los resultados por etapas en relación con los cinco factores, con el fin de determinar cómo la competitividad puede impulsar o frenar el desarrollo de un destino y para diseñar estrategias de mejora (Jiménez y Aquino, 2012). Este modelo ha sido aplicado en el destino turístico Bahías de Huatulco, y un indicador analizado es la participación de la infraestructura turística.

Desde el 2007, el Foro Económico Mundial, ha desarrollado tres índices de medición de la competitividad, orientados a la medición de la política turística, otro enfocado a la infraestructura turística y un tercero sobre los recursos humanos, naturales y culturales (Sánchez, 2012).

Para el caso del Turismo Receptivo, hay estudios que orientan el incremento económico con el incremento al Producto Interno Bruto (PIB) (Guzmán, 2000). En el proceso de medición, hay modelos considerados exógenos, y modelos que consideran variables endógenas, asociadas al progreso tecnológico (Hernández, 2006), para el Centro de Investigación y Estudios Turísticos del Instituto Tecnológico de Estudios Superiores de Monterrey, consideran la Rentabilidad del destino, como la relación entre el ingreso del Turismo y su aportación al PIB, (Amaya & Schmidt, 2015). Si consideramos el Turismo de Exportación, y los ingresos derivados de su actividad, podría considerarse como elemento para invertir en aspectos de formación bruta de capital fijo (Gibson, 1998)

Formación bruta de capital fijo

La Organización Mundial del Turismo (OMT) en acuerdo con la Organización de las Naciones Unidas (ONU), reconocen que la primera es la encargada de recoger, analizar, publicar, uniformar y mejorar las estadísticas de turismo (Organización Mundial del Turismo, 2018), obteniendo los datos de los diferentes países a través de un sistema de contabilidad nacional, debido a la necesidad de conocer a profundidad las variables macroeconómicas, la información a detalle la encontramos dentro de las Cuentas Satélite de Turismo (CST), contenida en un conjunto de 10 tablas de resumen, cada una con sus datos de base y cada una representando un aspecto diferente de los datos económicos relativos al turismo (Organización Mundial del Turismo, 2019).

Dentro de las Cuentas Satélite de Turismo (CST), una de las variables consideradas como clave para el análisis del turismo es la inversión. La medición, análisis, clasificación e impacto de la misma, marca la

evolución a corto plazo y su proyección en el mediano plazo (Lichtle Frago et al., 2014). Una clasificación de la Inversión turística, establece un análisis del sector fuente de financiamiento, misma que puede ser pública o privada, así como el origen de los bienes considerados, nacionales o importados

De acuerdo a SECTUR, la formación bruta de capital se compone de: construcción e instalaciones y maquinaria y equipo (transporte), equipo de cómputo y mobiliario y equipo. En el Sistema de Cuentas Nacionales, se considera el valor real de las inversiones realizadas por unidades económicas del Sector Turismo en el período de análisis.

Redes neuronales

El modelo de neuronas propuesto por McCulloch y Pitts en su trabajo de 1943 marcó el primer intento significativo de formalizar matemáticamente el comportamiento de una neurona y analizar cómo esto afecta su capacidad de computar y procesar información (Colombo & Piccinini, 2023). En su trabajo de investigación desarrollaron un modelo matemático de neuronas que describe la transmisión de señales eléctricas entre ellas y cómo podrían integrarse para llevar a cabo operaciones básicas. Su enfoque se inspiró en el funcionamiento de las neuronas biológicas, las cuales procesan información y generan respuestas según ciertas reglas preestablecidas. Este modelo inicial de neuronas artificiales y su organización en redes establecieron los fundamentos teóricos para el desarrollo posterior de redes neuronales más sofisticadas. A pesar de ser una simplificación de la complejidad del cerebro humano, este modelo sentó las bases para explorar cómo los sistemas artificiales podrían emular el comportamiento de las redes neuronales biológicas para realizar diversas tareas computacionales (Kondolf, 2022).

En 1958, Frank Rosenblatt introdujo el perceptrón, una de las primeras versiones de redes neuronales artificiales de una sola capa. Inspirado en el modelo de neuronas de McCulloch y Pitts, el perceptrón incluía pesos ajustables en las conexiones entre las neuronas y una función de activación que determinaba si la neurona se activaba según la entrada recibida. El perceptrón destacó por su capacidad para realizar clasificaciones binarias simples. Utilizando un método de aprendizaje supervisado, podía aprender a distinguir entre dos clases de datos ajustando los pesos de las conexiones según ejemplos etiquetados proporcionados durante el entrenamiento (Interactive Chaos, 2025.).

El término "invierno de la inteligencia artificial" se emplea para referirse a un período histórico en el

campo de la inteligencia artificial durante el cual se observó una disminución sustancial en la investigación y el interés público en esta área. Este lapso, que abarcó aproximadamente las décadas de 1970 y 1980, estuvo marcado por un desencanto generalizado debido al progreso limitado en el desarrollo de sistemas inteligentes. Como resultado, muchas empresas y financiadores redujeron o suspendieron sus inversiones en proyectos de inteligencia artificial debido a la falta de avances significativos. Este término se utiliza comúnmente para describir una fase de desilusión y estancamiento en la investigación de inteligencia artificial, caracterizada por un escepticismo generalizado sobre las capacidades y el potencial futuro de la IA. Sin embargo, hacia finales de la década de 1980 y principios de la década de 1990, se produjo un resurgimiento del interés y la inversión en inteligencia artificial gracias a los avances en algoritmos, técnicas de aprendizaje automático y hardware informático más potente (Pino et. al 2021).

El avance de las redes neuronales profundas, conocidas como deep learning, marca un punto de inflexión importante en los campos de la inteligencia artificial y el aprendizaje automático. Estas redes, que están compuestas por múltiples capas ocultas, han logrado superar algunas de las limitaciones inherentes de las redes neuronales convencionales al aprender representaciones jerárquicas de los datos de entrada. Gracias a la incorporación de múltiples capas de procesamiento, las redes neuronales profundas son capaces de capturar y comprender características cada vez más abstractas y complejas de los datos, lo que permite un nivel de abstracción y generalización que antes no era alcanzable con las redes neuronales más simples. Esta capacidad para aprender representaciones jerárquicas resulta fundamental para abordar desafíos complejos en diversas áreas, incluyendo el reconocimiento de patrones, el procesamiento del lenguaje natural, la visión por computadora y otras aplicaciones tecnológicas (Pino et. al 2021).

En los últimos años, ha habido un crecimiento exponencial en la investigación y progreso en el ámbito de las redes neuronales, impulsado en parte por el incremento en la disponibilidad de datos y el mejoramiento de la capacidad computacional. Esto ha generado importantes avances en campos como el procesamiento del lenguaje natural, la visión por computadora, la conducción autónoma y más (IBM, 2024).

En modelos macroeconómicos, las redes neuronales tienen una amplia gama de aplicaciones que incluyen

la predicción y el pronóstico económico, el modelado de series temporales, el análisis de sentimientos y la predicción de mercados financieros, así como el modelado de relaciones económicas complejas. Estas redes son capaces de mejorar la precisión de las predicciones al capturar relaciones no lineales y analizar grandes volúmenes de datos no estructurados. A pesar de sus beneficios, el uso de redes neuronales en este contexto también plantea desafíos, como la interpretabilidad de los resultados y la necesidad de datos de alta calidad para un entrenamiento efectivo de los modelos (Porras y Moreno, 2013).

Las redes neuronales han sido utilizadas en diversos sectores de la economía como en la predicción PIB de las principales economías (Jena et al., 2021), en el análisis técnico de la predicción del mercado de valores (Singh et al., 2022), así como en la aplicación de la predicción del precio del índice bursátil (Gao et al., 2020). Dentro de las aplicaciones destacadas de las redes neuronales en el sector turístico se encuentran su uso para estimar perfiles de turistas (Moral-Cuadra et al., 2021), además, se han utilizado para evaluar el desempeño turístico regional (Wang & Fu, 2023) y han sido una herramienta para analizar plataformas electrónicas de gestión turística con la finalidad de mejorar la competitividad (Wei et al. 2021), entre otras aplicaciones.

TensorFlow

TensorFlow es una plataforma de aprendizaje automático desarrollada por Google Brain en 2015, con una historia que se remonta al desarrollo interno de DistBelief en Google. DistBelief, aunque efectiva, presentaba limitaciones en flexibilidad y escalabilidad para satisfacer las necesidades crecientes de investigación y producción en aprendizaje profundo. Por lo tanto, TensorFlow surgió como una solución más flexible y poderosa para abordar estas limitaciones (TensorFlow, s.f.).

Lo que distingue a TensorFlow es su enfoque en la flexibilidad y la escalabilidad. Ofrece una API de alto nivel en Python que facilita el desarrollo rápido de modelos de aprendizaje automático, al tiempo que proporciona una interfaz de bajo nivel que permite a los desarrolladores definir y ejecutar operaciones matemáticas en tensores de manera eficiente. Esta capacidad para manejar operaciones en tensores, que son matrices multidimensionales que representan los datos, es fundamental para la computación en aprendizaje profundo (TensorFlow, s.f.). Además, TensorFlow se destaca por su capacidad para ejecutar computación distribuida en varios dispositivos, incluidas CPU, GPU y TPU. Esto permite entrenar modelos en grandes conjuntos de datos de manera

eficiente, lo que es crucial para aplicaciones del mundo real que requieren grandes cantidades de datos (Google Cloud, 2024).

Desde su lanzamiento inicial, TensorFlow ha experimentado múltiples actualizaciones y mejoras, lo que lo ha convertido en una herramienta popular tanto en la investigación como en la industria del aprendizaje automático. Ha sido ampliamente adoptado por empresas y organizaciones en una variedad de campos, desde la medicina hasta la robótica y la automoción. Actualmente el aprendizaje profundo es una nueva área de investigación del aprendizaje automático ampliamente utilizada en aplicaciones populares en diversos sectores (Long & Zeng, 2022).

En resumen, TensorFlow ha evolucionado para convertirse en una plataforma líder en el desarrollo y despliegue de modelos de aprendizaje automático y aprendizaje profundo. Su historia está marcada por una continua innovación y contribuciones significativas al campo de la inteligencia artificial.

METODOLOGÍA

Para predecir el comportamiento de la FBCF en el sector turístico, se utiliza un modelo de redes neuronales implementado en TensorFlow. Este modelo consta de múltiples capas: una capa de entrada, tres capas ocultas con función de activación ReLU y una capa de salida que predice la variable objetivo. Las conexiones entre las neuronas se representan matemáticamente mediante matrices de pesos, que se ajustan en cada iteración de entrenamiento para minimizar el error de predicción. Al aplicar este modelo a los datos de la CST, se procesan variables relacionadas con la inversión en construcción y maquinaria, facilitando la identificación de patrones complejos en el sector turístico. La estructura de TensorFlow permite entrenar el modelo con estos datos históricos, aprendiendo las relaciones entre la inversión en infraestructura y su impacto en el posicionamiento competitivo del turismo. Así, el modelo puede predecir el comportamiento futuro de estas variables, optimizando la toma de decisiones y permitiendo una planificación más efectiva en el sector.

Diseño de Investigación

En este trabajo se utilizó un modelo multineal para analizar la formación bruta de capital fijo en el sector turístico, esto debido a que este tipo de modelos son una herramienta estadística útil debido a su capacidad para capturar relaciones no lineales, incluir múltiples

variables explicativas, proporcionar un mejor ajuste del modelo y permitir la interpretación de coeficientes. Este modelo multineal fue construido en TensorFlow, pues, aunque es principalmente conocido por su capacidad para construir y entrenar modelos de aprendizaje profundo, como redes neuronales profundas es útil para implementar y trabajar con modelos multineales debido a su flexibilidad, escalabilidad, eficiencia computacional y facilidad de uso a través de su API de alto nivel.

Recopilación de Datos

Se utilizó la base de datos de la Cuenta Satélite del Turismo de México 2020 (año base 2018). Se analizó el periodo de tiempo comprendido entre 1993 y 2020. El indicador utilizado fue la Formación Bruta de Capital Fijo (Prod), teniendo como factores de análisis la Construcción (CTR), así como la inversión en Maquinaria y Equipo (MEQ). Para la producción del sector turístico se utilizó el Valor agregado bruto, precios básicos (año base 2018) (Data Tur, 2023). Con estos dos indicadores se elaboró una base de datos en formato .CSV debido a su simplicidad, además de ser compatible con una amplia gama de software, es eficiente en cuanto a tamaño de archivo, flexible para almacenar diferentes tipos de datos y permite el intercambio de datos entre diferentes sistemas y plataformas de manera efectiva.

Análisis de Datos

Es importante mencionar que como entorno de ejecución se utilizó Google Colab pues proporciona una manera cómoda y sin costo para utilizar recursos de computación en la nube, colaborar en proyectos en equipo y hacer uso de herramientas extra de Google para análisis de datos y trabajo colaborativo. La red neuronal definida en el código utiliza cuenta con una arquitectura de tres capas ocultas con activación ReLU y una capa de salida lineal.

Procedimiento

1. Cargar y preparar los datos: El código lee un archivo CSV que contiene los datos relevantes para el modelo de regresión multineal. Luego, separa las características (variables independientes) en X_train (CTR y MEQ) y la variable de destino (variable dependiente) en y_train (Producción).

2. Normalización de características: Utiliza StandardScaler de scikit-learn para normalizar las características (CTR y MEQ) y la variable de destino (Producción). Esto es importante para garantizar que todas las características están en la misma escala y facilitar el entrenamiento del modelo de red neuronal.

3. Definición de la arquitectura de la red neuronal:

Se creó un modelo de red neuronal secuencial utilizando TensorFlow Keras. El modelo consta de varias capas densas (totalmente conectadas) con activación ReLU y capas de abandono (dropout) para regularización.

4. Compilación del modelo: Se compiló el modelo especificando el optimizador (adam) y la función de pérdida (mean_squared_error) para minimizar durante el entrenamiento.

5. Entrenamiento del modelo: Se entrenó el modelo de red neuronal con los datos normalizados (X_{train_scaled} y y_{train_scaled}) durante 200 tiempos y un tamaño de lote de 64.

6. Predicciones: Se realizaron predicciones sobre los datos de entrenamiento normalizados para obtener las predicciones de la producción bruta del sector turismo. Luego, se invirtió la normalización para obtener las predicciones en la escala original.

7. Cálculo de las estadísticas del modelo: Se calcularon las estadísticas del modelo, incluido el error cuadrático medio (MSE) y el coeficiente de determinación (R-squared), para evaluar el rendimiento del modelo de red neuronal.

8. Entrenamiento del modelo de regresión lineal: Se entrenó el modelo de regresión lineal tanto para el modelo real como para el modelo predicho utilizando las características X_{train} y las predicciones de producción obtenidas.

9. Visualización de los modelos en 3D: Se creó una visualización 3D interactiva utilizando Plotly para mostrar los puntos de datos reales y predichos, así como los planos de ajuste para los modelos de regresión lineal real y predicho.

El diseño y desarrollo metodológico de la presente investigación, basado en redes neuronales implementadas en TensorFlow, permite la predicción de variables relacionadas en el sector turismo, debido a la capacidad de los modelos de aprendizaje automático para identificar patrones complejos en los datos. Al entrenar el modelo con datos históricos de la formación bruta de capital fijo, es posible extrapolar estos patrones a variables adicionales como el flujo turístico, la ocupación hotelera o el gasto promedio por visitante. Esta flexibilidad del modelo se debe a su arquitectura adaptable y al proceso de entrenamiento, que optimiza el ajuste de las relaciones entre las variables del turismo

Limitaciones

Las redes neuronales ofrecen flexibilidad, capacidad para aprender patrones complejos y generalización a

datos nuevos, lo que las convierte en una herramienta poderosa para la modelización y predicción en una variedad de aplicaciones. Sin embargo, es importante tener en cuenta las limitaciones y considerar el contexto específico del problema al elegir un modelo. Aunque el modelo presentado puede ser útil para hacer predicciones iniciales, tiene limitaciones en términos de rendimiento, interpretabilidad y requisitos computacionales, entre otros aspectos. Por ello es importante tener en cuenta estas limitaciones al interpretar los resultados y considerar enfoques alternativos si es necesario.

Validación y Fiabilidad

Se calculó el error cuadrático medio (MSE), la cual es una medida de la diferencia entre los valores predichos por el modelo y los valores reales en el conjunto de datos de entrenamiento, el cual se calcula sumando los cuadrados de las diferencias entre cada predicción y el valor verdadero, y luego dividiendo por el número total de muestras (Hastie et. al, 2009), se obtuvo un valor de 9091946607.79, también se calculó el coeficiente de determinación entre las etiquetas verdaderas (y_{train}) y las predicciones del modelo (predictions). El coeficiente de determinación es una medida de qué tan bien el modelo se ajusta a los datos y varía entre 0 y 1, un valor más cercano a 1 indica un mejor ajuste del modelo a los datos, mientras que un valor más cercano a 0 indica un ajuste deficiente (Hastie et. al, 2009), se obtuvo un valor de 0.97.

El modelo tiene un coeficiente de determinación (R^2) alto de 0.97, lo que indica que explica aproximadamente el 97% de la variabilidad en los datos de entrenamiento. Sin embargo, el error cuadrático medio (MSE) es considerablemente alto en comparación con el rango de los datos de y , que va hasta 1904228. Aunque el alto R^2 sugiere un buen ajuste del modelo a los datos de entrenamiento, el alto MSE podría indicar que el modelo está sobreajustando los datos y puede no generalizar bien a nuevos datos. Por lo tanto, es importante considerar técnicas adicionales para mejorar la capacidad de generalización del modelo y su rendimiento en datos no vistos.

Estudios similares


Se han realizado estudios relacionados con la desagregación de la formación bruta de capital fijo, (Lichtle Fragoso et al., 2014), Se analizó el Turismo Receptivo a partir de 3 regiones emisoras, utilizando datos panel y analizando la inversión en capital fijo a partir de dicha derrama económica, (Flores Lujano, 2018).

Resultados

Una vez entrenada la red neuronal se obtuvieron dos modelos, el modelo considerando los datos reales y el modelo considerando los datos predichos, se realizó una gráfica comparativa 3D interactiva utilizando la librería de Plotly, la cual se muestra en la Figura 1. Podemos observar que los puntos generados con la red neuronal se acercan al comportamiento real de los datos.

Figura 1

Vista de la gráfica 3D del plano de ajuste del modelo real y el modelo predicho. Los puntos rojos representan los datos del modelo real, siendo su plano de ajuste el marcado por el color rojo, mientras que los puntos azules representan los valores predichos y el plano azul su ajuste.



Fuente: Elaboración propia con base en Información del Sistema de Monitoreo Data Tur 2023.

Los resultados del modelo real muestran una alta capacidad predictiva para explicar la variabilidad en la variable dependiente (Prod), con un R^2 de 0.928 y un R^2 ajustado de 0.923. Esto significa que el modelo puede explicar aproximadamente el 92.8% de la variabilidad en la producción (Prod) en función de las variables CTR (inversión en construcción) y MQE (inversión en maquinaria y equipo). El coeficiente de CTR (13.2129) indica que, por cada unidad adicional invertida en construcción, se espera un aumento de aproximadamente 13.21 unidades en la producción del sector turístico, manteniendo constante la inversión en MQE. Para el coeficiente de MQE (8.6425) sugiere que, al aumentar la inversión en maquinaria y equipo en una unidad, la producción aumenta en promedio en 8.64 unidades, manteniendo constante la inversión en CTR.

Ambos coeficientes son estadísticamente significativos, como se muestra en los valores p ($P>|t|$) de 0.000 y 0.034, respectivamente, lo cual indica que estas variables tienen un impacto relevante en la

producción del sector. El valor del estadístico F (168.6) y su probabilidad ($1.29e-15$) refuerzan la significancia general del modelo.

Tabla 1

Pruebas Estadísticas Completas para el Modelo Real.
OLS Regression Results

Dep. Variable:	Prod	R-squared:	0.928
Model:	OLS	Adj. R-squared:	0.923
Method:	Least Squares	F-statistic:	168.6
Date:	Fri, 01 Mar 2024	Prob (F-statistic):	1.29e-15
Time:	04:07:58	Log-Likelihood:	-386.55
No. Observations:	29	AIC:	779.1
Df Residuals:	26	BIC:	783.2
Df Model:	2		
Covariance Type:	nonrobust		

	coef	std err	t	P> t	[0.025	0.975]
const	1.852e+05	5.89e+04	3.142	0.004	6.4e+04	3.06e+05
CTR	13.2129	1.423	9.283	0.000	10.287	16.139
MQE	8.6425	3.870	2.234	0.034	0.689	16.596

Omnibus:	4.272	Durbin-Watson:	0.732
Prob(Omnibus):	0.118	Jarque-Bera (JB):	2.923
Skew:	-0.397	Prob(JB):	0.232
Kurtosis:	4.337	Cond. No.	1.33e+05

Fuente: Elaboración propia con base en información de DataTur 2023.

En la Tabla 2 se muestran los resultados obtenidos en el modelo predicho, el R^2 es aún mayor, alcanzando 0.975, lo que significa que el modelo logra explicar el 97.5% de la variabilidad en la variable dependiente y . Esto sugiere que el modelo predicho es muy eficaz para realizar estimaciones precisas en el contexto de la FBCF. Para el coeficiente de CTR (12.5960) sugiere que la inversión en construcción mantiene un impacto positivo en la producción del sector, aunque ligeramente menor en comparación con el modelo real. Cada unidad invertida en construcción se asocia con un aumento de 12.60 unidades en la producción. Para el coeficiente de MQE (8.3258) sigue teniendo un impacto positivo, con cada unidad adicional asociada a un aumento de 8.33 unidades en la producción.

El estadístico F en este modelo (510.8) y su probabilidad ($1.36e-21$) demuestran una alta significancia del modelo predicho. El Durbin-Watson cercano a 1 indica una posible autocorrelación en los errores, lo cual podría ser investigado en futuros estudios.

Tabla 2

Pruebas Estadísticas Completas para el Modelo Predicho.

OLS Regression Results						
Dep. Variable:	y	R-squared:	0.975			
Model:	OLS	Adj. R-squared:	0.973			
Method:	Least Squares	F-statistic:	510.8			
Date:	Fri, 01 Mar 2024	Prob (F-statistic):	1.36e-21			
Time:	04:07:59	Log-Likelihood:	-369.14			
No. Observations:	29	AIC:	744.3			
Df Residuals:	26	BIC:	748.4			
Df Model:	2					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025	0.975]
const	2.24e+05	3.23e+04	6.926	0.000	1.58e+05	2.91e+05
CTR	12.5960	0.781	16.125	0.000	10.990	14.202
MQE	8.3258	2.124	3.921	0.001	3.961	12.691
Omnibus:	14.090	Durbin-Watson:	0.987			
Prob(Omnibus):	0.001	Jarque-Bera (JB):	24.360			
Skew:	-0.898	Prob(JB):	5.13e-06			
Kurtosis:	7.115	Cond. No.	1.33e+05			

Fuente: Elaboración propia con base en información de DataTur 2023.

Estos resultados sugieren que las inversiones en construcción (CTR) y maquinaria y equipo (MQE) son factores cruciales para mejorar la formación bruta de capital fijo y, por ende, el posicionamiento competitivo del sector turístico. La alta significancia de ambas variables y sus coeficientes positivos indican que un aumento en estas inversiones podría tener efectos positivos en la producción y el crecimiento del sector. El modelo estadístico permite estimar de manera efectiva el impacto de la FBCF en la competitividad del turismo. Con base en los coeficientes obtenidos, se puede concluir que la inversión en infraestructura turística tiene un efecto multiplicador en el rendimiento del sector, destacándose la importancia de invertir en construcción y maquinaria como estrategias clave para potenciar el turismo en México.

CONCLUSIONES

A partir de los resultados encontrados, en torno a la Inversión en Construcción, podemos concluir la relevancia de esta variable en el posicionamiento competitivo de la Industria del Turismo, es un área de oportunidad para buscar la inversión de los socios o bien, una Inversión Extranjera Directa IED. El análisis propuesto a través de las redes neuronales, nos permite planear y proyectar niveles de Inversión y combinarlos con el Financiamiento, para encontrar así el punto

adecuado entre inversión propia y ajena, apoyando a la salud financiera de las empresas del sector turístico. Las redes neuronales aplicadas a la economía permiten resolver problemas econométricos desde otra perspectiva, debido a su capacidad para analizar grandes cantidades de datos y encontrar patrones complejos. En este trabajo se utilizaron para calcular la Formación Bruta de Capital Fijo, para ello se entrenó un modelo de red neuronal con una arquitectura de tres capas ocultas con activación ReLU y una capa de salida lineal, lo cual permite medir el impacto de la inversión en Construcción, Maquinaria y Equipo de la Industria del Turismo. La investigación ha demostrado que la inversión en formación bruta de capital fijo, específicamente en construcción y maquinaria, tiene un impacto significativo en el posicionamiento competitivo del sector turístico en México. Con base en los resultados del modelo, se estima que por cada millón de pesos (mdp) invertido en infraestructura turística:

La producción del sector (renta generada) podría aumentar en aproximadamente 13,213 pesos cuando esta inversión se destina a construcción (CTR), y en 8,643 pesos cuando se destina a maquinaria y equipo (MQE). Este análisis cuantitativo sugiere que las inversiones estratégicas en infraestructura turística no solo fortalecen la competitividad del sector, sino que también generan un retorno directo en términos de producción económica. Estos hallazgos son fundamentales para orientar futuras decisiones de inversión y planificación en el sector, destacando la importancia de focalizar las inversiones en áreas de alto impacto como infraestructura de transporte y equipo, que ofrecen un retorno económico medible y contribuyen al crecimiento sostenible del turismo en México.

Se plantean como futuras líneas de investigación el uso de redes neuronales en la Industria del Turismo para realizar pronósticos de demanda hotelera para fechas específicas dentro del estado de Michoacán, así como la predicción de demanda de productos turísticos y creación de perfiles turísticos.

REFERENCIAS

- Amaya, C. M., & Schmidt, N. C. (2015). La competitividad turística en la literatura académica a principios del siglo XXI. *Teoría Y Praxis*, 18(julio-diciembre), 35–77. <http://www.redalyc.org/pdf/4561/456144903003.pdf>

- Berdo, S. (2015). The Integrated Model of Dwyer and Kim as a Tool to Evaluate and Rank the Determinant Attributes of a Tourist Destination Competitiveness. *European Journal of Economics and Business Studies*, 1(1), 27–30.
http://journals.euser.org/files/articles/ejes_ja_n_apr_15/Sonila_Berdo.pdf
- Colombo, M., & Piccinini, G. (2023). *The computational theory of mind*. Cambridge University Press.
- Crouch, G. (2011). Destination Competitiveness: An Analysis of Determinant Attributes. *Journal of Travel Research*, 50(1), 27–45.
<https://doi.org/10.1177/0047287510362776>
- Cucculelli, M., & Goffi, G. (2016). Does sustainability enhance tourism destination competitiveness? Evidence from Italian Destinations of Excellence. *Journal of Cleaner Production*, 111, 370–382.
<https://doi.org/10.1016/j.jclepro.2014.12.069>
- Dwyer, L., & Kim, C. (2003). Destination competitiveness: Determinants and indicators. *Current Issues in Tourism*, 6(5), 369–414.
- Flores Lujano, F. (2018). Análisis de la demanda de turismo receptivo y su impacto en el crecimiento económico de la región de Puno: Periodo 1995-2016. *Revista de Investigaciones de la Escuela de Posgrado de la Universidad Nacional del Altiplano*, 7(4), 836–851.
- Gao, P., Zhang, R., & Yang, X. (2020). The application of stock index Price prediction with neural network. *Mathematical and Computational Applications*, 25(3), 53.
- Gibson, H.J. (1998): «Sport tourism: A critical analysis of research». *Sport Management Review*, (1), pp. 45-76.
- Google Cloud. (2024). Ejecuta un cálculo en una VM de Cloud TPU con TensorFlow. Recuperado el 4 de noviembre de 2024, de <https://cloud.google.com/tpu/docs/run-calculation-tensorflow?hl=es-419>
- Goffi, G. (2013). A model of tourism destination competitiveness: The case of the Italian destinations of excellence. *Turismo Y Sociedad*, 14(0), 121–147.
<http://revistas.uexternado.edu.co/index.php/tursoc/article/view/3718/4069>
- Gomezelj, D. O., & Mihalič, T. (2008). Destination competitiveness-Applying different models, the case of Slovenia. *Tourism Management*, 29(2), 294–307.
<https://doi.org/10.1016/j.tourman.2007.03.009>
- Guzmán, A. (2000). Las fuentes endógenas del crecimiento económico. *Economía Teoría y Práctica*, 13, 35-60.
- Hastie, T., Tibshirani, R., Friedman, J. H., & Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction* (Vol. 2, pp. 1-758). New York: springer.
- Hernández, J. (2006). *Visiones Exógena y Endógena de las Teorías del Crecimiento Económico. Contribuciones a la economía*, (2006-08).
- Hernández, M. G., & de la Calle Vaquero, M. (2006). Turismo en el medio rural: conformación y evolución de un sector productivo en plena transformación. *El caso del Valle del Tiétar (Ávila). Cuadernos de turismo*, (17), 75-102.
- IBM. (2024). Las principales tendencias en inteligencia artificial. IBM. Recuperado el 4 de octubre de 2024 de <https://www.ibm.com/es-es/think/insights/artificial-intelligence-trends>.
- Información del Sistema de Monitoreo DataTur. (22 de diciembre del 2023). Cuenta Satélite del Turismo de México. Consultado el 3 de enero de 2023. <https://www.datatur.sectur.gob.mx/SitePages/ProductoDestacado3.aspx>.
- Interactive Chaos. (2025). Breve historia de las redes neuronales. Interactive Chaos. Recuperado el 3 de octubre de 2024, de <https://interactivechaos.com/es/manual/tutorial-de-machine-learning/breve-historia-de-las-redes-neuronales>
- Jena, P. R., Majhi, R., Kalli, R., Managi, S., & Majhi, B. (2021). Impact of COVID-19 on GDP of major economies: Application of the artificial neural network forecaster. *Economic Analysis and Policy*, 69, 324-339.
- Jiménez, P., & Aquino, F. (2012). Propuesta de un modelo de competitividad de destinos turísticos. *Estudios Y Perspectivas En Turismo*, 21(4), 977–995.
<http://www.redalyc.org/pdf/1807/180724056010.pdf>
- Kondolf, R. S. (2022). La equivalencia formal en el lenguaje de las neuronas lógicas de McCulloch y Pitts. *Epistemología e Historia de la Ciencia*, 7(1), 22-40.
- Lichtle Frago, P. M., Guzmán Guerrero, M. A., & Sánchez Salinas, J. C. (2014). Método de desagregación temporal de cuentas nacionales: una propuesta para desagregar la formación bruta de capital fijo turístico (Documento de Investigación Estadística y Económica No. 2014-2). Secretaría de

- Turismo, Subsecretaría de Planeación y Política Turística.
https://datatur.sectur.gob.mx/Documentos%20Publicaciones/2014_2_DocInvs.pdf
- Long, L., & Zeng, X. (2022). Beginning deep learning with TensorFlow: Work with Keras. MNIST Data Sets, and Advanced Neural Networks, 1-978. <https://doi.org/10.1007/978-1-4842-7915-1>
- Moral-Cuadra, S., Solano-Sanchez, M. A., López-Guzmán, T., & Menor-Campos, A. (2021). Peer-to-Peer Tourism: Tourists' profile estimation through artificial neural networks. Journal of Theoretical and Applied Electronic Commerce Research, 16(4), 1120-1135.
- Organización Mundial del Turismo. (2018). Panorama OMT del turismo internacional Edición 2018 (OMT (ed.)). World Tourism Organization (UNWTO).
<https://doi.org/10.18111/9789284419890>
- Organización Mundial del Turismo. (2019). Entender el turismo: Glosario Básico.
<http://media.unwto.org/es/content/entender-el-turismo-glosario-basico>
- Petković, G., Knežević, B., & Pindžo, R. (2017). Social initiatives in trade and tourism: The cases of Serbia and Croatia. Ekonomika preduzeća, 65(1-2), 229-243.
- Pino, L. E., Rico-Carrillo, A. E., & Hernández-Arango, A. (2021). Del ábaco a las redes neuronales o la breve historia de la inteligencia artificial en salud. Medicina, 43(4), 514-526.
- Porras, S. T., & Moreno, E. M. (2013). Modelos Neuronales Aplicados en Economía: Casos Prácticos mediante Mathematica/Neural Networks. Addlink Software Científico.
- Ritchie, J. & Crouch, G. (2000). The competitive destination: A sustainability perspective. Tourism Management, 21, 1-7.
- Sánchez Rivero, M., (2012). ANÁLISIS CUANTITATIVO DEL IMPACTO ECONÓMICO DE LA COMPETITIVIDAD EN DESTINOS TURÍSTICOS INTERNACIONALES. Revista de Economía Mundial, (32), 103-125.
- Secretaría de Turismo. (2022). PIB turístico en México asciende a 2 billones 372 mil 556 millones de pesos en 2022. Gobierno de México. Recuperado el 5 de octubre de 2024, de <https://www.gob.mx/sectur/prensa/pib-turistico-en-mexico-asciende-a-2-billones-372-mil-556-millones-de-pesos-en-2022>
- Singh, A., Bhardwaj, G., Srivastava, A. P., Bindra, A., & Chaudhary, P. (2022). Application of neural network to technical analysis of stock market prediction. In 2022 3rd International Conference on Intelligent Engineering and Management (ICIEM) (pp. 302-306). IEEE.
- TensorFlow. (s.f.). Por qué TensorFlow. Recuperado el 5 de octubre de 2024, de <https://www.tensorflow.org/about?hl=es-419>.
- Wang, Y., & Fu, L. (2023). Study on regional tourism performance evaluation based on the fuzzy analytic hierarchy process and radial basis function neural network. Annals of Operations Research, 1-28.
- Wei, C., Wang, Q., & Liu, C. (2021). Application of an artificial neural network optimization model in e-commerce platform based on tourism management. EURASIP Journal on Wireless Communications and Networking, 2021(1), 21.