



Asesorías y Tutorías para la Investigación Científica en la Educación Puig-Salabarría S.C.
José María Pino Suárez 400-2 esq a Lerdo de Tejada. Toluca, Estado de México. 7223898475
 RFC: ATI120618V12

Revista Dilemas Contemporáneos: Educación, Política y Valores.

<http://www.dilemascontemporaneoseducacionpoliticayvalores.com/>

Año: XIV Número: 1 Artículo no.:12 Período: 1 de septiembre al 31 de diciembre del 2026

TÍTULO: Impacto en la enseñanza en la educación superior. El machine learning y la dinámica de sistemas para evaluar el efecto dominó en la cadena de suministro.

AUTORES:

1. Máster. Víctor Hugo de la Cruz Madrigal.

2. Dra. Liliana Avelar Sosa.

RESUMEN: El objetivo del estudio es analizar el impacto en la enseñanza a nivel superior al evaluar el efecto dominó en la cadena de suministro. A partir de las entrevistas realizadas a las empresas automotrices, se recolectó la demanda histórica de componentes automotrices donde se integró machine learning para pronosticar la demanda en la cadena de suministro en la industria automotriz y dinámica de sistemas para diseñar un modelo dinámico que ayude a evaluar el efecto dominó. Los resultados revelan que el efecto dominó incrementa los retrasos en las órdenes enviadas al cliente y reduce el nivel de inventario de productos terminados y donde aparece el efecto látigo, afectando al efecto dominó y que tiene un impacto negativo en el cliente.

PALABRAS CLAVES: educación superior, machine learning, cadena de suministro, sistemas dinámicos, efecto dominó.

TITLE: Impact on teaching in higher education. Machine learning and systems dynamics to assess the domino effect in the supply chain.

AUTHORS:

1. Master. Víctor Hugo de la Cruz Madrigal.

2. PhD. Liliana Avelar Sosa.

ABSTRACT: The objective of this study is to analyze the impact on higher education by evaluating the domino effect in the supply chain. Historical demand data for automotive components was collected from interviews with automotive companies. Machine learning was then integrated to forecast supply chain demand in the automotive industry, and systems dynamics was used to design a dynamic model to help evaluate the domino effect. The results reveal that the domino effect increases delays in customer orders and reduces finished goods inventory levels. The study also identifies the bullwhip effect, which exacerbates the domino effect and negatively impacts the customer.

KEY WORDS: higher education, machine learning, supply chain, dynamic systems, domino effect.

INTRODUCCIÓN.

En el año 2020 cuando surgió la pandemia a causa del COVID-19, diversos sectores suspendieron sus operaciones, tal es el caso de la industria y la educación; por ejemplo, las empresas de autopartes dejaron de trabajar, lo mismo sucedió en la educación superior, debido a que las universidades tuvieron la necesidad de impartir las clases en línea y adaptarse a las nuevas formas de enseñanza.

Las empresas por su parte optaron por solicitar estudiantes practicantes o investigadores a las universidades para realizar actividades, clases o estancias de investigación semestral de forma virtual en el área de cadena de suministro (CS) para evaluar el efecto dominó y otros aspectos que afectaban el desempeño del negocio. El efecto dominó (ED) consiste en la disminución de la demanda por parte de los clientes, debido principalmente, a la escasez de material y a la poca capacidad de respuesta del proveedor. Debido a ello, y también a los cambios abruptos de productos solicitados por el cliente, se generan problemas de calidad impactando directamente en las ventas, el tiempo de entrega y la rentabilidad, además de menor participación en el mercado, y de retrasos en los pedidos del cliente, Garvey y Carnovale (2020) comentan que el efecto dominó es un evento no planeado y no previsto que interrumpe el flujo de materiales y productos en la cadena de suministro, lo que repercute negativamente en la satisfacción del cliente.

En ese sentido, se generó una cascada de cancelaciones de pedidos a los proveedores, lo que afectó también a las economías emergentes como el caso de México, donde la industria automotriz detuvo sus operaciones. Ivanov (2020) destaca que la pandemia favorece el efecto dominó, al retrasar los tiempos de entrega de materias primas, de 30 días a 90 días, de los proveedores de China y Estados Unidos.

Algunos estudios relacionan el efecto dominó en la cadena de suministro con la educación universitaria. Li (2020) propone analizar el efecto dominó en una cadena de suministro educativa que involucre la industria 4.0; por ejemplo, Ivanov et al. (2019) utilizan blockchain para predecir el efecto dominó en tiempo real; así mismo, Hald y Coslugeanu (2021) identifican las disrupciones en la cadena de suministro y Iftikhar et al. (2024) recomiendan capacitarse en análisis de datos para evaluar el efecto dominó.

Yu y Aviso (2020) evalúan la vulnerabilidad de la cadena de suministro y cómo el impacto del efecto dominó va en aumento. Xue y Li (2023) se enfocan en una cadena de suministro resiliente cuando existe presencia del efecto dominó para mejorar la capacidad de respuesta. Kosasih y Brintrup (2021) argumentan que el efecto dominó es un factor de riesgo en la cadena de suministro y Lei et al. (2024) lo mitigan utilizando redes neuronales. Truong et al. (2025) proponen mejorar la colaboración entre la educación superior y las empresas con tecnologías de la información para afrontar la variabilidad en la demanda; además, Kim et al. (2025) proponen capacitar a los estudiantes en semiconductores para reducir el desabasto de materias primas y así mitigar al efecto dominó en la cadena de suministro.

Estudios recientes han aplicado algoritmos de machine learning para predecir la demanda en la cadena de suministro como Liu et al. (2022), quienes predicen el impacto del efecto dominó con redes bayesianas, otros como Hosseini y Ivanov (2020) lo analizan, añadiendo a éstas los algoritmos de machine learning. Aslay y Ting (2022) utilizan el algoritmo Random Forest para anticipar el efecto dominó. Ntakolia et al. (2021) estiman las órdenes atrasadas para evaluar el riesgo disruptivo. Modgil et al. (2022) ajustan el nivel de inventario para mitigar el efecto dominó.

Mitra et al. (2022) proponen la combinación de machine learning con Random Forest y XGBoost para pronosticar la demanda en la cadena de suministro que ayude a mejorar el stock de seguridad. Hoque et al. (2021) proponen un modelo dinámico para pronosticar la demanda en la cadena de suministro disruptiva utilizando machine learning; esto para aumentar las órdenes entregadas.

Bhuvaraghavan y Matheen (2024) predicen la demanda en la cadena de suministro durante el Covid-19, utilizando el algoritmo Random Forest para visualizar el efecto dominó. Riad et al. (2024) incorporan machine learning para anticipar la disrupción de la cadena de suministro, reduciendo los riesgos de faltantes. Ivanov y Dolgui (2021) predicen las disrupciones e impacto del efecto dominó, utilizando Digital Twin. Sodiya et al. (2024) utilizan machine learning para pronosticar la demanda con una mayor precisión a fin de identificar las disrupciones y optimizar los niveles de inventario, minimizando los costos asociados al mejor riesgo de desabasto o al exceso de inventario.

También se reportan estudios que evalúan el efecto dominó en la cadena de suministro con dinámica de sistemas, como Wilson (2007) quien analizó la disrupción en el transporte para conocer el impacto en el nivel de servicio; por su parte, Bueno-Solano y Cedillo-Campos (2014) aumentaron el nivel de inventario en un 600% como medida de protección. Sánchez-Ramírez et al. (2020) analizaron la probabilidad de falla de una máquina por la escasez de refacciones y la forma en que afectó en el inventario de productos terminados y tiempos de entrega.

Badakhshan et al. (2020) analizan los costos de inventario y órdenes atrasadas combinando dinámica de sistemas y algoritmos genéticos. Llaguno et al. (2021) evalúan el nivel de inventario en la cadena de cadena de suministro y su influencia en el nivel de servicio. Olivares-Aguila y ElMaraghy (2021) cuantifican el efecto dominó que impacta en el nivel de servicio, el nivel de inventario, los costos y la rentabilidad.

Duan et al. (2021) evaluaron el nivel de inventario que influye en la disrupción del flujo de materiales y analizaron los riesgos en el transporte al reducir el nivel de inventario. Rathore et al. (2021) estudiaron la

disrupción en el transporte con un ajuste en el nivel de inventario y en el tiempo de entrega. Lai et al. (2023) evalúan el riesgo disruptivo al considerar el stock de seguridad, y un tiempo de entrega constante. Ghadge et al. (2022) visualizan el efecto dominó causado por los riesgos en la demanda y proveedores y su efecto en el nivel de servicio y en la satisfacción del cliente.

Cannella et al. (2021) evalúan la cantidad de órdenes enviadas al cliente mediante un ajuste en el nivel de inventario. Disney et al. (2021) analizan las ventas perdidas en la cadena de suministro y su efecto en el nivel de servicio. Oetomo et al. (2025) mitigan el efecto látigo para mejorar la resiliencia posterior a las disrupciones, integrando machine learning con dinámica de sistemas. Bussieweke et al. (2024) mitigaron el efecto dominó basados en datos secundarios de la industria aeroespacial, considerando el nivel de inventario y las órdenes enviadas al cliente.

Se concluye, que el análisis y evaluación del efecto dominó en la CS es un parteaguas, ya que por un lado se deben cumplir con los requerimientos de los clientes y el nivel de servicio, en entregas oportunas y en cantidades y calidad acordadas, y por otro, la disminución de los costos asociados, ya sea en el transporte o en los niveles de stock; por tanto, a partir de dichas premisas, en este trabajo se pretende evaluar el efecto dominó en la cadena de suministro del sector automotriz, integrando machine learning y dinámica de sistemas como un ejercicio para conocer el impacto de su uso en la educación superior.

DESARROLLO.

Metodología.

En la metodología de esta investigación se incluyen seis etapas que se organizan como una combinación al usar machine learning y dinámica de sistemas, y mostradas en la Figura 1, que indica el orden de cada etapa, y en los párrafos posteriores se explican a detalle cada una.

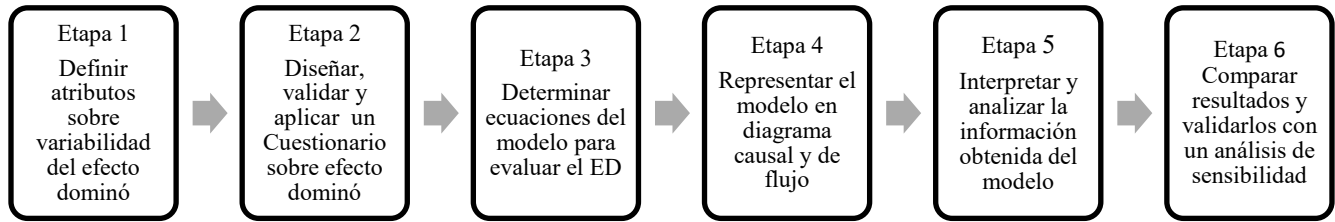


Figura 1 Metodología de investigación usada.

Etapa 1. Definir los atributos sobre la variabilidad del efecto dominó.

En esta primera etapa y como resultado de las entrevistas realizadas a los gerentes en empresas automotrices y de la revisión de la literatura realizada, se definen las variables demanda, inventario, tiempo de entrega variable y efecto látigo asociadas a la variabilidad del efecto látigo, que impactan directamente en el efecto dominó.

Etapa 2. Diseñar, validar y aplicar un cuestionario sobre el efecto dominó.

En la segunda etapa, se diseñó el cuestionario electrónico sobre el efecto dominó en la cadena de suministro del sector automotriz 2025, utilizando los atributos anteriores y algunos criterios de inclusión en la muestra, al considerar método estratificado por estar dirigido a directores, gerentes, e ingenieros que laboran en empresas de autopartes de nivel uno y nivel dos, considerando el nivel de educación mínimo de preparatoria con experiencia de tres años en adelante; esto con el fin de recolectar información verídica y confiable para evaluar los factores de riesgo a que están expuestas las empresas, y apoyados por la revisión de la literatura.

El cuestionario se evalúa por el Comité de Ética para proteger los derechos de los participantes mediante la política de privacidad y confidencialidad de la información. Antes de contestar el cuestionario, los responsables de los departamentos de compras, logística, planeación y cadena de suministro tienen la libertad de dar su consentimiento para participar y autorizar que la información se utilice con fines

académicos. El cuestionario está integrado por tres secciones; riesgo en los proveedores, evaluación de los factores de riesgo, y costos de desempeño de la cadena de suministro.

En la sección uno se identifica cómo las empresas perciben el riesgo de sus proveedores y que influyen en la disrupción de la cadena de suministro del sector automotriz ya sea por el proceso de abastecimiento de materias primas o por su relación con los proveedores. Laguir et al. (2023) evaluaron la disrupción de la cadena de suministro en los proveedores, utilizando 16 ítems, y a partir de ellos, se tomaron en consideración algunos de ellos; por ejemplo, el deterioro de material, los paros de línea de producción, los accidentes naturales, el error en los pronósticos, la inestabilidad de la demanda, los retrasos de los proveedores, el decremento de la demanda, la relación con los proveedores, el incremento de los costos de materiales, la escasez de materiales, los costos de penalización, el nivel de inventario, el ajuste del nivel de inventario, la capacidad de respuesta, y la seguridad del producto; para ello, se consideró una escala de valoración tipo Likert con puntuación de 1 (nunca) al 5 (siempre).

En la sección dos se busca identificar los factores de riesgo que perciben las empresas y que influyen en la disrupción de la cadena de suministro ocasionada por la demanda, el inventario y el tiempo de entrega. Tomando en cuenta el trabajo de Ivanov (2019), donde evaluaron la demanda del cliente, el inventario, y el tiempo de entrega, todos ellos que favorecen al efecto látigo e influyen en el efecto dominó, se lograron integrar 28 ítems usando la escala Likert, escala del 1 (nunca) al 5 (siempre), y especialmente para el factor tiempos de entrega, la escala con valoraciones de 1 (diaria), 2 (seminal), 3 (quincenal), 4 (mensual), 5 (bimestral).

En la sección tres se analizan los costos asociados a los inventarios, al nivel de servicio, a la satisfacción del cliente, obtenidos en la cadena de suministro en la empresa de acuerdo con sus operaciones realizadas. Bevilacqua et al. (2020) identificaron los costos de desempeño de suministro, utilizando 14 ítems con escala Likert de 1 (nunca) al 5 (siempre). Se realizó una prueba piloto del cuestionario electrónico al enviarles el enlace a tres gerentes expertos en cadena de suministro, a dos egresados de ingeniería en

logística y transporte con menos de tres años de experiencia, y a un académico especialista en logística y cadena de suministro para contestar y validar la semántica. El cuestionario mejorado se aplicó de manera electrónica usando *Google Forms* a 54 empresas de autopartes, de un total de 100, en el estado de Guanajuato y Querétaro, México, en el periodo del 3 de agosto al 21 de noviembre del 2025 y así para recolectar información para validarlo estadísticamente.

Etapas 3. Determinar las ecuaciones del modelo para evaluar el efecto dominó.

En esta siguiente etapa, se determinan las ecuaciones del modelo para evaluar el ED con dinámica de sistemas; así mismo, se entrevista a los encargados de los departamentos de logística, la planeación de la demanda, la cadena de suministro y compras para obtener información cuantitativa con respecto a los pronósticos de la demanda, al inventario inicial, a los tiempos de entrega de proveedores y clientes, al nivel de cumplimiento, al retraso de pedidos y los costos de mantener el inventario, así como la gestión del pedido para alimentar las ecuaciones. Es un modelo de una cadena de suministro que incluye a proveedores nivel 1 (Tier 1) y armadoras (ensambladoras) en el periodo (τ), donde el cliente revisa su nivel de inventario para solicitar un pedido al proveedor q_τ .

La demanda del cliente D_τ se comporta de manera normal y determina si existe una demanda insatisfecha; con ello, se genera un pedido atrasado. Se considera un tiempo de entrega (LT) variable. Sánchez-Ramírez et al. (2020) proponen la ecuación 1 para el inventario de materia prima (RMI); a continuación:

$$RMI_t = RMI_{t_0} + \int_0^t (RRM - URM) dt \quad (1)$$

donde RRM son las órdenes de materia prima enviadas por los proveedores, y URP se refiere a las órdenes de productos terminados en embarques. Olivares-Aguila y ElMaraghy (2021) definen la ecuación 2 como inventario de productos terminados, mostrada a continuación:

$$FGP = FGP_{t_0} + \int_0^t (OPC - PE) dt \quad (2)$$

donde OPC son las órdenes preparadas a enviarse y PE se refiere a las órdenes de productos terminados entregados al cliente. Olivares-Aguila y ElMaraghy (2021) definen la ecuación 3 como el inventario en procesos, como se muestra:

$$WIP = WIP_{t_0} + \int_0^t (PR - OS) dt \quad (3)$$

donde PR es la tasa de producción y OS son las órdenes en embarques. Olivares-Aguila y ElMaraghy (2021) definen la ecuación 4 como órdenes en embarques, como se muestra:

$$ODC = DELAY(WIP, LT) \quad (4)$$

donde WIP es el inventario en procesos y LT es el tiempo de entrega. Oetomo et al. (2025) proponen la ecuación 5 para las órdenes enviadas, como se muestra:

$$OE = h_f(X) + SF * (SS - IP) \quad (5)$$

donde $h_f(X)$ es el pronóstico de la demanda, SS es el stock de seguridad, IP es el inventario posición, y SF es el factor de seguridad. Ramakrishna et al. (2023) proponen la ecuación 6, para el pronóstico de la demanda, utilizando el algoritmo de machine learning AdaBoost regresor, mostrado enseguida:

$$h_f(X) = \arg \max \sum_{t=1}^T \left(\log \frac{1}{B_t} \right) h_t(x, y) \quad (6)$$

donde $h_f(X)$ minimizar el error, x es la demanda real que representa el 70% de los datos de entrenamiento, y es la demanda pronosticada que representa el 30% de los datos de aprendizaje del modelo, β_t representan la aproximación de parámetros entre 0 y 1. Bueno-Solano y Cedillo-Campos (2014) proponen la ecuación 7 para calcular la posición del inventario y que indica la cantidad económica a solicitar al proveedor, como se muestra:

$$IP = FGI - BO + WIP \quad (7)$$

donde FGI es el inventario de productos terminados, BO son las órdenes atrasadas, y *WIP* es el inventario en procesos. Disney et al. (2021) proponen la ecuación 8 para evaluar las ventas perdidas, como se muestra:

$$IS = OE < h_f(X) \quad (8)$$

donde OE son las órdenes enviadas, $h_f(X)$ es el pronóstico de la demanda. Badakhshan et al. (2020) proponen la ecuación 9, para el efecto látigo, como se muestra:

$$BWE = \frac{VAR(OE)}{VAR(CU)} \quad (9)$$

donde *OE* son las órdenes enviadas, CU es la demanda actual. De la Cruz Madrigal et al. (2025) proponen la ecuación 10 como la demanda actual, como se muestra:

$$CU_{kt} = h(X) * (Normal(1, DV)) \quad (10)$$

donde $h(X)$ es la demanda pronosticada, DV es la variación de la demanda de $0 < CU < 1$, $k = 3$ ensamble, $k = 2$ es el proveedor Tier 1, $k = 1$ es el proveedor Tier 2. t es el tiempo en meses de 1 a 61.

Etapla 4. Representar el modelo en un diagrama de flujo.

En la etapa cuatro, primero se genera el matemático para incluir las variables que permiten modelar el efecto dominó en la cadena de suministro en el eslabón Tier 1 dedicado a suministrar componentes automotrices para el ensamble del vehículo; para tal caso, se realiza un diagrama de flujo que integra las variables de flujo, de nivel y los parámetros.

Las variables de flujo se caracterizan por las cantidades que ingresan y salen del sistema y se representan con flechas. Las variables de nivel se refieren al stock de materiales que se tiene en almacén, la cantidad de inventario en procesos, y la cantidad de productos terminados disponibles; así mismo, la cantidad de órdenes atrasadas que necesitan entregarse al cliente y son representadas por cuadrados. Finalmente, las

variables auxiliares son los parámetros que se utilizaron en este modelo como: el factor de seguridad, el tiempo de entrega, la tasa de capacidad disruptiva, % de variabilidad de la demanda, el retraso de pedidos, el tiempo de entrega mínimo, el tiempo de ajuste, y se representan con círculos.

Para realizar la simulación del modelo con diversos escenarios se utiliza el software Stella Architect Versión 3.4.1®, usando la información histórica de la demanda de 61 meses (del año 2019 al 2024). Ésta corresponde a la cantidad de materiales de tipo automotriz, obtenida a partir de los datos reales proporcionados por las empresas automotrices durante la entrevista a gerentes y directivos. En la Figura 2 se muestra el diagrama realizado donde se indica cuándo el proveedor Tier 1 le solicita materia prima a su proveedor acorde a la demanda solicitada por la armadora; con ello, se evalúan los diversos parámetros y variables de respuesta.

La política de inventario establece al proveedor Tier 1 verificar el nivel de inventario que cuenta en su almacén de materiales, de acuerdo con el número de pedidos recibidos; esto para lograr cumplir con lo solicitado. Se considera un retraso de dos semanas por parte del proveedor Tier 2 a causa de la escasez de materiales a nivel global. El proveedor Tier 1 le envía el pedido al proveedor Tier 2 cuando el inventario alcanza el punto de reorden con una política de revisión periódica y de reabastecimiento. El proveedor Tier 1 establece manufacturar, de acuerdo con la orden que recibió por parte de la armadora cuando el inventario de materia prima que tiene en su almacén es menor al punto de reorden; es decir, se programa la producción de acuerdo con los requerimientos del cliente.

En el modelo se incluye la disrupción de la cadena de suministro, misma que inicia cuando falta inventario de materiales en el almacén; por lo que después de esto, se libera la orden de producción. La forma de calcularlo se hace cuando la cantidad de materia prima es mayor o igual a la capacidad mínima dividida entre la capacidad actual y las órdenes enviadas al cliente por parte del proveedor Tier 1; además, también en el modelo se calcula la capacidad actual, misma que se determina con la capacidad total del proveedor Tier 1 multiplicada por la capacidad disruptiva de $0 < DCR < 1$.

Las órdenes Tier 1 son el máximo de la diferencia entre el inventario máximo menos tamaño de lote, que es determinado por el inventario de productos terminados y se suman las órdenes atrasadas menos el inventario en proceso con un ajuste en las órdenes. Las órdenes listas por embarcarse tienen un retraso de máximo cuatro semanas equivalentes a un mes de producción. Para iniciar con la evaluación del inventario se considera como 2300 piezas como inventario inicial, y lo cual equivale a una semana de inventario.

La política de entrega a la armadora es la cantidad mínima entre el inventario de productos terminado y las órdenes confirmadas, incluyendo retraso en las órdenes, debe ser mayor que cero, y como resultado se entregan las órdenes confirmadas.

Se calculó el nivel de servicio que es la cantidad de pedidos entregados al cliente entre las órdenes confirmadas que son la suma de la demanda más las órdenes atrasadas divididas entre el tiempo de ajuste de dos semanas.




Figura 2. Modelo para evaluar el efecto dominó en la cadena de suministro.

Para evaluar la disrupción, se incorpora la tasa de capacidad disruptiva con valores de $0 < X < 1$, donde el cero indica que no hay disrupción, 0.25 indica paros técnicos en la empresa por el retraso de materiales y fallas en el equipo, 0.50 indica escasez de material debido al proveedor, y 0.7 a 1.0 indica que existe disrupción severa equivalente a 15 días de suspensión de operaciones causadas por la pandemia y cuestiones geopolíticas de los países. El total de capacidad disruptiva es de 2600 unidades equivalente al 25% de la producción mensual y que incluye la capacidad actual de 10300 unidades por mes, con una eficiencia de línea de producción del 75 %.

Etapas 5. Analizar la información obtenida.

En la etapa de análisis, primero se incorpora la tasa de capacidad disruptiva con diversos valores para evaluar la disrupción (efecto dominó) y considerando los siguientes parámetros: tiempo de entrega, tasa de capacidad disruptiva, variabilidad de la demanda, tiempo de ajuste de dos semanas, tiempo entre órdenes, factor de seguridad, y tiempo mínimo de entrega.

Un modelo de dinámica de sistemas en la cadena de suministro permite analizar diversos resultados a partir del conjunto de variables incluidas, a fin de comprender la relación causal entre ellas y determinar mejoras en toma de decisiones o ajustes pertinentes dentro de las empresas para reducir costos, gestionar mejor los inventarios, o mejorar el nivel de servicio al cliente; en definitiva, conocer de manera previa una posible disrupción.

Etapas 6. Análisis de sensibilidad del modelo.

Finalmente, en esta etapa se comparan los resultados obtenidos y se validan de manera empírica usando un análisis de sensibilidad. En la Tabla 1 se muestran los indicadores usados tales como la demanda, la cantidad de pedidos enviados al cliente, así como el tiempo de interrupción de la CS. Se observan cuatro diferentes escenarios.

Tabla 1. Análisis de sensibilidad.

Escenarios	LT en meses	Tasa disruptiva	Variabilidad de la demanda	Periodo disruptivo en meses	Retraso	Ajuste del inventario en piezas
1	0.25	0	0	0	0.25	2500
2	0.50	0.5	-0.50	0.50	0.50	5000
3	0.75	0.7	0.50	0.75	1	7500
4	1	0.7	-0.50	1	1	10000

Elaboración propia.

Resultados del diseño, validación y aplicación del cuestionario.

A partir del cuestionario elaborado y siguiendo el proceso de evaluación y validación de este, primero se envió al comité de ética de la Universidad Autónoma de Ciudad Juárez antes de aplicarlo a las empresas. Una vez que se recibió el resultado favorable, se inició con la recolección de datos a partir del 03 de agosto del 2025, de manera electrónica, con el cuestionario realizado en *Google Forms*, logrando hasta el momento la respuesta de 54 empresas de autopartes de un total de 100 empresas que están consideradas. La información recabada servirá para evaluar cómo estas perciben el riesgo en sus proveedores, la demanda de sus clientes, el inventario, los tiempos de entrega, el efecto látigo que influyen en el efecto dominó que impactan en los costos de desempeño como son el nivel de servicio y la satisfacción del cliente.

En la Figura 3, se muestra una participación del 54% de 100 empresas automotrices, donde el 41% de las empresas contestadas son del departamento de cadena de suministro, 25% logística, 25 planeación, 8% compras. El 75% de los gerentes tiene licenciatura terminada con más de 5 años de experiencia en el puesto; así mismo, el 59% de las empresas corresponde a proveedores Tier 1 con alrededor de 500 empleados y el 41% son proveedores Tier 2 con 101 a 200 empleados.




Figura 3. Cuestionario sobre el efecto dominó de la cadena de suministro.

Se validó el cuestionario estadísticamente con 58 preguntas donde contestaron 54 empresas del sector automotriz tanto metal mecánico, inyección de plásticos y ensamble, entre otros, utilizando el software SPSS 21.0 ®; para ello, se usó el índice Alfa de Cronbach a fin de determinar la fiabilidad y la consistencia interna del cuestionario. Se obtuvo como resultado un valor de 0.853, siendo un valor aceptable para este índice, indicando con ello que el cuestionario es pertinente y fiable para continuar, aplicándose a las empresas de la industria automotriz y obtener información sobre cadena de suministro y efecto dominó.

Pronóstico de la demanda con machine learning.

Para realizar pronósticos y estimaciones se utilizan diversos algoritmos de machine learning; sin embargo, el algoritmo AdaBoost Regresor demostró tener una mayor precisión comparado con los modelos de series de tiempo tradicionales. En la Tabla 2, se muestra una comparativa de dos algoritmos de machine learning, el Random Forest y el AdaBoost Regresor con los modelos de pronóstico tradicionales de suavización exponencial y de modelo de Hold.

Se observa que el algoritmo AdaBoost Regresor mejoró un 45% con respecto al modelo de suavización exponencial, un 47.5% con respecto al modelo de Hold, y un 21.4% con respecto al algoritmo Random Forest. El algoritmo logró el aprendizaje para detectar el patrón de comportamiento de la demanda de los componentes automotrices (cantidad de tanques de gasolina para autos).

El código generado en Python para el pronóstico de la demanda con el algoritmo AdaBoost se exportó a Excel para mejorar su posterior análisis; después, el archivo Excel se importó desde Stella Architect para

evaluar los niveles de estimación de la misma, y continuar con el modelo dinámico. Los resultados obtenidos se muestran en la Figura 2.

Tabla 2. Comparación de modelos de pronóstico.

Modelos de pronóstico	MSE	MAE	MAPE
Suavización exponencial simple	455758	538	8
Modelo de Hold	506851	559	8.4
Random Forest	222081	374	5.6
AdaBoost Regresor	118122	288	4.4

Elaboración propia.

En la Figura 4, se indica la comparativa entre la demanda respecto la proyección que se realizó en el software Python con algoritmos de machine learning. En la fase uno, se utilizó el 70% de los datos de entrenamiento del modelo. En la fase dos, se aplicaron el 30% restante para el aprendizaje del modelo, donde la línea roja muestra el comportamiento de los datos reales de la demanda con una demanda intermitente a causa de paros técnicos que se llevaron a cabo en los meses marzo del 2020 hasta agosto del 2020 por la pandemia.




Figura 4. Pronóstico de la demanda de autopartes.

Análisis de la información obtenida.

En la Figura 5, se observa que durante los meses de enero a marzo del año 2020 se entregaron las órdenes completadas de acuerdo con los requerimientos solicitados por cliente; sin embargo, a partir del mes de abril del mismo año, cuando la cadena de suministro del sector automotriz suspendió operaciones a causa del COVID 19, se disminuyeron drásticamente las órdenes entregadas al cliente.

Posteriormente, la industria automotriz comenzó a recuperarse al incrementar la demanda de componentes en un 80%; en este caso, se observaron incrementos de 4500 a 8300 piezas (tanques de gasolina) en un periodo de tres años.




Figura 5. Órdenes enviadas al cliente.

En la Figura 6, se analizó el nivel de inventario de productos terminados que indican un impacto en la reducción del 66% del nivel de inventario de productos terminados; esto debido a la suspensión de labores en la industria automotriz en México a causa del COVID 19 durante el primer semestre del año 2020. Posteriormente, se incrementó un 30% el nivel de inventario que representa una semana de stock de seguridad que ayuda al proveedor Tier 1 a abastecer la demanda del cliente.




Figura 6. Inventario de productos terminados.

En la Figura 7, se muestran las ventas no concretadas, lo cual sucede cuando las órdenes enviadas al cliente son menores que la demanda solicitada. La línea indica que durante los meses de abril a septiembre del 2020 se incrementaron las ventas perdidas en un 80% debido al inicio de la Pandemia que causó cancelaciones de pedidos por la suspensión de operaciones en toda la cadena de suministro del sector automotriz y a nivel global. Esto demuestra la presencia de la disrupción causada por elementos adversos a la propia gestión de la CS.




Figura 7. Ventas perdidas.

Análisis de sensibilidad.

En la Figura 8, se muestran las órdenes enviadas a la armadora, y en la línea azul se presenta el escenario uno donde no hay interrupción; no obstante, se observa que de abril a agosto del 2020 disminuyeron las órdenes enviadas al cliente causadas por el decremento de la demanda. El escenario dos está representado por la línea rosa discontinua que indica la presencia de una interrupción parcial a causa de los paros técnicos en la industria automotriz; esto debido a una cascada de cancelación de pedidos realizada por los clientes. En el escenario tres, mostrado con la línea azul discontinua, se muestran resultados de la presencia de una interrupción severa por la suspensión de operaciones durante 30 días y que indica la inestabilidad en el cumplimiento de los pedidos solicitados por la armadora; esto precisamente debido al incremento en los tiempos de entrega por parte del proveedor. Posteriormente, la industria automotriz comenzó a recuperarse al incrementar la demanda de componentes en un 80%; en este caso, se observan incrementos desde 4500 a 8300 unidades en un periodo de tres años.




Figura 8. Escenarios de órdenes enviadas al cliente.

En Figura 9, se muestra la evaluación del efecto dominó en la industria automotriz al comparar las órdenes enviadas de parte del proveedor Tier 1 (línea azul) con una interrupción severa con los parámetros y comparadas con la demanda. Se utilizó una tasa de capacidad disruptiva de 0.7, una variabilidad de la demanda -0.50, y un mes como tiempo de entrega. Estas son estimaciones basadas en Olivares-Aguila y

ElMaraghy (2021), que establecen que el cero es sin interrupción, el 0.5 es interrupción parcial y el 1.0 es una interrupción severa.

La variabilidad de la demanda supone valor de $-0.5 < D < 1$. El tiempo de entrega se obtuvo de las entrevistas realizadas a los gerentes en la industria automotriz. La demanda (línea roja discontinua) indica que el proveedor incrementó las órdenes atrasadas, debido a que la varianza de las órdenes entregadas con respecto a la demanda es de 1.08, indicando así que el proveedor corre el riesgo de generar efecto látigo, y asimismo, influir en la presencia del efecto dominó debido a que el Tier 1 utiliza una política de reabastecimiento que incluye a las órdenes atrasadas más la demanda solicitada por el cliente. Este comportamiento genera la aparición del efecto látigo; por ello, es clave evaluar primero a los proveedores de nivel 1.




Figura 9. Efecto látigo en la cadena de suministro.

En la Figura 10, se muestra el comportamiento del efecto dominó en la cadena de suministro; para ello, se utilizó el escenario 4 que indica que existe una interrupción severa debido a que el tiempo de interrupción es entre 20 y 30 días de paros de línea durante la Pandemia. En este escenario disminuyó la demanda mensual un 50%, con un inventario de 2300 equivalentes a una semana de inventario en la empresa, lo cual favorece también la presencia del efecto dominó; por otro lado, se identifica un tiempo de retraso de dos semanas por parte del proveedor Tier 2, y como resultado de esto la demanda (línea roja punteada) es

mayor que las órdenes enviadas al cliente (línea azul), indicando que existe efecto dominó en la cadena de suministro; además, con este escenario se incrementa la demanda insatisfecha. Esto significa que el cliente no recibe los productos solicitados al proveedor.




Figura 10. Efecto dominó en la cadena de suministro.

CONCLUSIONES.

Como conclusión, el efecto dominó en la cadena de la industria automotriz tuvo un impacto positivo debido a que las empresas solicitaron a las universidades alumnos para desarrollar su estancia profesional de forma virtual; así mismo, impulso a los alumnos a mejorar su autoaprendizaje en machine learning para pronosticar la demanda con mayor precisión ayudando a las empresas a cuantificar el nivel de inventario de dos semanas para producir los requerimientos del cliente.

Al integrar el modelo dinámico con machine learning fue posible evaluar el impacto del efecto dominó al reducir el número de órdenes recibidas por el proveedor de nivel 2 (Tier 2); además de disminuir los niveles de inventario de productos terminados que incrementó las órdenes atrasadas, generándose desabasto de material durante la pandemia. Estos escenarios permiten a los gerentes comprender la importancia de detectar y evaluar la disrupción en la cadena de suministro para prevenir desabasto de material.

En este caso se incorporó un modelo dinámico con machine learning para mejorar las predicciones, siendo una contribución de conocimiento al integrar nuevos métodos para evaluar el efecto dominó en la industria automotriz y en la cadena de suministro. Este modelo revela cómo el efecto látigo es el principal factor de riesgo en la presencia del efecto dominó y que causa un incremento en la demanda insatisfecha del 50%, generándose en consecuencia mayor incertidumbre en la demanda.

Importante, por otro lado, es considerar los costos asociados a ese desabasto de material, ya que en la cadena de suministro cuando sucede un efecto negativo a alguna de sus etapas se generan efectos posteriores a lo largo de ella, ocasionando no solamente falta de productos sino también pérdidas monetarias por los costos asociados a la falta de ellos o a la urgencia de hacerlos llegar a tiempo para el cliente.

En la industria automotriz, ese modelo tiene implicaciones industriales prácticas al conocer los principales elementos necesarios para evitar la presencia de interrupciones; es decir, contribuye porque al ser un modelo dinámico a partir de datos reales de empresas; en este sector, se pueden estimar posibles efectos adversos en lo futuro, permitiendo con ello tomar acciones correctivas ya sean de comunicación, coordinación, información compartida u ajustes en la demanda o niveles de inventarios permitidos.

Finalmente, al incorporar algoritmos de machine learning se pueden estimar futuros comportamientos de demanda y ser al mismo tiempo dinámicos para corregir y volver a evaluar los resultados. En las universidades, el que los estudiantes aprendan nuevos métodos de estimación les permitirá aplicar estos conocimientos en la industria a fin de mejorar los beneficios en las empresas y en sus cadenas de suministro; de aquí la relevancia de esta investigación. Se logran aplicar tendencias en tecnologías como inteligencia artificial a través de machine learning para evaluar la cadena de suministro en la práctica y en la teoría, siendo una forma versátil para solucionar problemas actuales en las empresas.

REFERENCIAS BIBLIOGRÁFICAS.

1. Aslay, F., and Ting, N.S. (2022). Machine Learning-Based Estimation of Output Current Ripple in PFC-IBC Used in Battery Charger of Electrical Vehicles: A Comparison of LR, RF and ANN Techniques. IEEE Access, 10,50078–50086. <https://doi.org/10.1109/ACCESS.2022.3174100>
2. Badakhshan, E., Humphreys, P., Maguire, L., and Mcivor, R. (2020). Using simulation-based system dynamics and genetic algorithms to reduce the cash flow bullwhip in the supply chain, 58(17), 5253–5279 <https://doi.org/10.1080/00207543.2020.1715505>
3. Bevilacqua, M., Ciarapica, F. E., Marcucci, G., and Mazzuto, G. (2020). Fuzzy cognitive maps approach for analysing the domino effect of factors affecting supply chain resilience: a fashion industry case study. International Journal of Production Research,58(20), 6370–6398. <https://doi.org/10.1080/00207543.2019.1680893>
4. Bhuvaraghavan, S. T., and Matheen, U. (2024). Visualizing the ripple effect: COVID-19’S Impact and predictive insights. International Journal of Engineering Research and Sustainable Technologies (IJERST), 2(1), 1–8. <https://doi.org/10.63458/ijerst.v2i1.70>
5. Bueno-Solano, A., and Cedillo-Campos, M. G. (2014). Dynamic impact on global supply chains performance of disruptions propagation produced by terrorist acts. Transportation Research Part E, 61, 1–12. <https://doi.org/10.1016/j.tre.2013.09.005>
6. Bussieweke, F., Mula, J., and Campuzano-Bolarin, F. (2024). Optimisation of recovery policies in the era of supply chain disruptions: a system dynamics and reinforcement learning approach. International Journal of Production Research. 63(5), 1649–1673. <https://doi.org/10.1080/00207543.2024.2383293>
7. Cannella, S., Ponte, B., Dominguez, R., Framinan, J. M., Cannella, S., Ponte, B., Dominguez, R., Jose, M., y Cannella, S. (2021). Proportional order-up-to policies for closed-loop supply chains: the dynamic effects of inventory controllers effects of inventory controllers. International Journal of Production Research, 59(11), 3323–3337. <https://doi.org/10.1080/00207543.2020.1867924>

8. De la Cruz Madrigal, V. H., Avelar Sosa, L., Mejía-Muñoz, J. M., García Alcaraz, J. L., and Jiménez Macías, E. (2025). Dynamical System Modeling for Disruption in Supply Chain and Its Detection Using a Data-Driven Deep Learning-Based Architecture. *Logistics*, 9 (2), 51. <https://doi.org/10.3390/logistics9020051>
9. Disney, S. M., Ponte, B., and Wang, X. (2021). Exploring the nonlinear dynamics of the lost-sales order-up-to policy. *International Journal of Production Research*, 59(19), 5809–5830. <https://doi.org/10.1080/00207543.2020.1790687>
10. Duan, W., Ma, H., and Xu, D. S. (2021). Analysis of the impact of COVID-19 on the coupling of the material flow and capital flow in a closed-loop supply chain. *Advances in Production Engineering and Management*, 16(1), 5–22. <https://doi.org/10.14743/apem2021.1.381>
11. Garvey, M. D., and Carnovale, S. (2020). The rippled newsvendor: A new inventory framework for modeling supply chain risk severity in the presence of risk propagation. *International Journal of Production Economics*, 228, 107752. <https://doi.org/10.1016/j.ijpe.2020.107752>
12. Ghadge, A., Er, M., Ivanov, D., and Chaudhuri, A. (2022). Visualisation of ripple effect in supply chains under long-term, simultaneous disruptions: a system dynamics approach. *International Journal of Production Research*, 60(20), 6173–6186. <https://doi.org/10.1080/00207543.2021.1987547>
13. Hald, K. S., and Coslugeanu, P. (2021). The preliminary supply chain lessons of the COVID-19 disruption—What is the role of digital technologies? *Operations Management Research*. 282–297. <https://doi.org/10.1007/s12063-021-00207-x>
14. Hoque, M. E., Thavaneswaran, A., Appadoo, S. S., Thulasiram, R. K., and Banitalebi, B. (2021). A novel dynamic demand forecasting model for resilient supply chains using machine learning. 2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC), 218–227. <https://doi.org/10.1109/COMPSAC51774.2021.00040>

15. Hosseini, S., and Ivanov, D. (2020). Bayesian networks for supply chain risk, resilience and ripple effect analysis: A literature review. *Expert Systems with Applications*, 161, 113649. <https://doi.org/10.1016/j.eswa.2020.113649>
16. Iftikhar, A., Ali, I., Arslan, A., and Tarba, S. (2024). Digital innovation, data analytics, and supply chain resiliency: A bibliometric-based systematic literature review. *Annals of Operations Research*, 333(2), 825–848. <https://doi.org/10.1007/s10479-022-04765-6>
17. Ivanov, D. (2019). Disruption tails and revival policies: A simulation analysis of supply chain design and production-ordering systems in the recovery and post-disruption periods. *Computers and Industrial Engineering*, 127 (September 2018), 558–570. <https://doi.org/10.1016/j.cie.2018.10.043>
18. Ivanov, D. (2020). Predicting the impacts of epidemic outbreaks on global supply chains: A simulation-based analysis on the coronavirus outbreak (COVID-19/SARS-CoV-2) case. *Transportation Research Part E: Logistics and Transportation Review*, 136, 101922. <https://doi.org/10.1016/j.tre.2020.101922>
19. Ivanov, D., and Dolgui, A. (2021). A digital supply chain twin for managing the disruption risks and resilience in the era of Industry 4.0. *Production Planning and Control*, 32(9), 775–788. <https://doi.org/10.1080/09537287.2020.1768450>
20. Ivanov, D., Dolgui, A., and Sokolov, B. (2019). The impact of digital technology and Industry 4.0 on the ripple effect and supply chain risk analytics. 57(3), 829–846 <https://doi.org/10.1080/00207543.2018.1488086>
21. Kim, H., Kim, J., and Clipperton, A. (2025). WIP: Developing Hands-On Semiconductor Fabrication and Testing Courses Through Industry-University Partnerships in a Teaching-Focused Undergraduate School. 2025 ASEE-GSW Annual Conference. <https://peer.asee.org/55090>

22. Kosasih, E., and Brintrup, A. (2021). A machine learning approach for predicting hidden links in supply chain with graph neural networks. *International Journal of Production Research* 60 (17), 5380-5393. <https://doi.org/10.1080/00207543.2021.1956697>
23. Laguir, I., Modgil, S., Bose, I., Gupta, S., and Stekelorum, R. (2023). Performance effects of analytics capability, disruption orientation, and resilience in the supply chain under environmental uncertainty. *Annals of Operations Research*, 324 (1), 1269–1293. <https://doi.org/10.1007/s10479-021-04484-4>
24. Lai, X., Chen, Z., Wang, X., and Chiu, C. H. (2023). Risk propagation and mitigation mechanisms of disruption and trade risks for a global production network. *Transportation Research Part E: Logistics and Transportation Review*, 170(December 2022), 103013. <https://doi.org/10.1016/j.tre.2022.103013>
25. Lei, Z., Cui, L., Tang, J., Chen, L., and Liu, B. (2024). Supply chain resilience in the context of I4.0 and I5.0 from a multilayer network ripple effect perspective. *Annals of Operations Research*, 342(2), 1149–1192. <https://doi.org/10.1007/s10479-023-05618-6>
26. Li, L. (2020). Education supply chain in the era of Industry 4.0. *Systems Research and Behavioral Science*, 37(4), 579–592. <https://doi.org/10.1002/sres.2702>
27. Liu, M., Tang, H., Chu, F., Zheng, F., and Chu, C. (2022). A reinforcement learning variable neighborhood search for the robust dynamic Bayesian network optimization problem under the supply chain ripple effect. *IFAC-PapersOnLine*, 55(10), 1459–1464. <https://doi.org/10.1016/j.ifacol.2022.09.596>
28. Llaguno, A., Mula, J., and Campuzano-Bolarin, F. (2021). State of the art, conceptual framework and simulation analysis of the ripple effect on supply chains. *International Journal of Production Research*, 60 (6). 2044–2066. <https://doi.org/10.1080/00207543.2021.1877842>
29. Mitra, A., Jain, A., Kishore, A., and Kumar, P. (2022). A Comparative Study of Demand Forecasting Models for a Multi-Channel Retail Company: A Novel Hybrid Machine Learning Approach. *Operations Research Forum*, 3 (58). <https://doi.org/10.1007/s43069-022-00166-4>

30. Modgil, S., Singh, R. K., and Hannibal, C. (2022). Artificial intelligence for supply chain resilience: learning from Covid-19. *The International Journal of Logistics Management*, 33(4), 1246–1268.
<https://doi.org/10.1108/IJLM-02-2021-0094>
31. Ntakolia, C., Kokkotis, C., Karlsson, P., and Moustakidis, S. (2021). An explainable machine learning model for material backorder prediction in inventory management. *Sensors*, 21(23), 7926.
<https://doi.org/10.3390/s21237926>
32. Oetomo, D. S., Fajar Ramdhani, R., and Hermawan, A. (2025). A Dynamic System Model for Multi-Echelon Inventory Policy Optimization Considering Bullwhip Effect and Supply chain Disruptions in the Sport Footwear Industry. *Jurnal Teknologika*, 15(1), 629–642.
<https://doi.org/10.51132/teknologika.v15i1.447>
33. Olivares-Aguila, J., and ElMaraghy, W. (2021). System dynamics modelling for supply chain disruptions. *International Journal of Production Research*, 59(6), 1757–1775.
<https://doi.org/10.1080/00207543.2020.1725171>
34. Ramakrishna, M. T., Venkatesan, V. K., Izonin, I., Havryliuk, M., and Bhat, C. R. (2023). Homogeneous Adaboost Ensemble Machine Learning Algorithms with Reduced Entropy on Balanced Data. *Entropy*, 25(2), 245. <https://doi.org/10.3390/e25020245>
35. Rathore, R., Thakkar, J. J., and Jha, J. K. (2021). Impact of risks in foodgrains transportation system: a system dynamics approach. *International Journal of Production Research*, 59(6), 1814–1833.
<https://doi.org/10.1080/00207543.2020.1725683>
36. Riad, M., Naimi, M., and Okar, C. (2024). Enhancing Supply Chain Resilience Through Artificial Intelligence: Developing a Comprehensive Conceptual Framework for AI Implementation and Supply Chain Optimization. *Logistics*, 8(4), 111. <https://doi.org/10.3390/logistics8040111>

37. Sánchez-Ramírez, C., Ramos-Hernández, R., Fong, J. R. M., Alor-Hernández, G., and García-Alcaraz, J. L. (2020). A system dynamics model to evaluate the impact of production process disruption on order shipping. *Applied Sciences (Switzerland)*, 10(1), 208. <https://doi.org/10.3390/app10010208>
38. Sodiya, E. O., Jacks, B. S., Ugwuanyi, E. D., Adeyinka, M. A., Umoga, U. J., Daraojimba, A. I., and Lottu, O. A. (2024). Reviewing the role of AI and machine learning in supply chain analytics. *GSC Advanced Research and Reviews*, 18(2), 312–320. <https://doi.org/10.30574/gscarr.2024.18.2.0069>
39. Truong, T. H., Lin, B.-W., and Tung, C.-P. (2025). Strategic legislation for the promotion of university–industry collaborations: a case study of Taiwan. *The Journal of Technology Transfer*, 50(1), 304–344. <https://doi.org/10.1007/s10961-024-10110-9>
40. Wilson, M. C. (2007). The impact of transportation disruptions on supply chain performance. *Transportation Research Part E: Logistics and Transportation Review*, 43(4), 295–320. <https://doi.org/10.1016/j.tre.2005.09.008>
41. Xue, J., y Li, G. (2023). Balancing resilience and efficiency in supply chains: Roles of disruptive technologies under Industry 4.0. *Frontiers of Engineering Management*. 10 ,171– 176. <https://doi.org/10.1007/s42524-022-0247-8>
42. Yu, K. D. S., and Aviso, K. B. (2020). Modelling the Economic Impact and Ripple Effects of Disease Outbreaks. *Process Integration and Optimization for Sustainability*. 4, 183– 186. <https://doi.org/10.1007/s41660-020-00113-y>

DATOS DE LOS AUTORES.

- 1. Víctor Hugo de la Cruz Madrigal.** Máster en Ingeniería Industrial, Candidato a doctor en el programa de Doctorado de la Ingeniería Avanzada, Universidad Autónoma de Ciudad Juárez, Correo electrónico: al220736@alumnos.uacj.mx
- 2. Liliana Avelar Sosa.** Doctora en Ciencias de la Ingeniería Avanzada. Profesora Investigadora en la Universidad Autónoma de Ciudad Juárez, México. Correo electrónico: liliana.avelar@uacj.mx

RECIBIDO: 20 de junio del 2026.

APROBADO: 23 de julio del 2026.