Revista científica Sociedad & Tecnología

ISSN: 2773-7349

Fecha de presentación: 24/09/2026 Fecha de aceptación: 22/10/2026 Fecha de publicación: 10/11/2026

Juan Carlos Medina-Jiménez
E-mail: jcmedina1981@gmail.com
Orcid: https://orcid.org/0009-0007-4830-3560

Franklin Alberto Noblecilla-Rivadeneira
E-mail: noblecillaalberto@gmail.com
Orcid: https://orcid.org/0009-0003-1179-2744

Harry Alexander Vite-Cevallos
E-mail: harryvite@yahoo.es
Orcid: https://orcid.org/0000-0003-2056-7111

Javier Alejandro Bermeo-Pacheco
E-mail: jbermeo@utmachala.edu.ec
Orcid: https://orcid.org/0000-0003-4606-3464

Universidad Técnica de Machala, Maestría en Administración de Empresas mención en dirección y gerencia, Machala, Ecuador.

Cita sugerida (APA, séptima edición)

Medina-Jiménez, J. C., Noblecilla-Rivadeneira, F. A., & Vite-Cevallos, V. C. (2026). Eficiencia operativa de la movilidad urbana y su impacto en la predicción: caso Santa Rosa. *Revista Sociedad & Tecnología*, 9(S3), 1916-1927, DOI: https://doi.org/10.51247/nxj9p014

==== o ====

Eficiencia operativa de la movilidad urbana y su impacto en la predicción: caso Santa Rosa

RESUMEN

Este estudio analiza cómo la eficiencia operativa de la movilidad urbana incide en la capacidad predictiva de los sistemas de gestión vial del cantón Santa Rosa, El Oro, Ecuador, con el fin de proponer un modelo de movilidad inteligente ajustado a su contexto institucional. Se adopta un diseño cuantitativo correlacional, no experimental y transversal, que combina una encuesta ciudadana (n = 374), observación sistemática en 20 intersecciones, entrevistas a 20 expertos, modelos de ecuaciones estructurales y una comparación de modelos predictivos con validación cruzada. La línea base muestra un índice de congestión vehicular de 1,65 y un tiempo de espera semafórica de 87,3 segundos. Los resultados proyectados indican que la eficiencia operativa incide en la capacidad predictiva ($\beta = 0,62$) y que el modelo GCN-LSTM alcanzaría el mayor ajuste ($R^2 = 0,912$) frente a ARIMA ($R^2 = 0,621$). Con ello se sustenta un modelo gradual en tres fases, que parte de XGBoost por su bajo costo y orienta las decisiones del Gobierno Autónomo Descentralizado Municipal y de la Comisión de Tránsito del Ecuador. El aporte es un protocolo replicable de medición y predicción para una ciudad intermedia de baja madurez digital, contexto poco documentado en la literatura sobre ciudades inteligentes.

Palabras clave: Eficiencia operativa; movilidad urbana; analítica predictiva; ciudades inteligentes; sistemas inteligentes de transporte (ITS).

Operational efficiency of urban mobility and its impact on prediction: the Santa Rosa case

ABSTRACT

This study analyzes how the operational efficiency of urban mobility affects the predictive capacity of road management systems in the canton of Santa Rosa, El Oro, Ecuador, in order to propose a smart mobility model adapted to its institutional context. A quantitative, correlational, non-experimental, cross-sectional design is adopted, combining a citizen survey (n = 374), systematic observation at 20 intersections, interviews with 20 experts, structural equation modeling, and a comparison of predictive models with cross-validation. The baseline shows a vehicular congestion index of 1.65 and an average signal wait time of 87.3 seconds. Projected results indicate that operational efficiency affects predictive capacity (β = 0.62) and that the GCN-LSTM model would achieve the best fit (R^2 = 0.912) compared with ARIMA (R^2 = 0.621). This supports a gradual three-phase model that starts with XGBoost because of its low cost and guides decisions by the municipal government and the Ecuadorian Traffic Commission. The contribution is a replicable measurement and prediction protocol for an intermediate city with low digital maturity, a context scarcely documented in the smart city literature.

Keywords: Operational efficiency; urban mobility; predictive analytics; smart cities; intelligent transportation systems (ITS).

==== o ====

Eficiência operacional da mobilidade urbana e o seu impacto na previsão: o caso de Santa Rosa

RESUMO

Este estudo analisa como a eficiência operacional da mobilidade urbana afeta a capacidade preditiva dos sistemas de gestão rodoviária no cantão de Santa Rosa, província de El Oro, Equador, com o objetivo de propor um modelo de mobilidade inteligente adaptado ao seu contexto institucional. Adotou-se uma abordagem quantitativa, correlacional, não experimental e transversal, combinando um inquérito aos cidadãos (n = 374), observação sistemática em 20 cruzamentos, entrevistas a 20 especialistas, modelação de equações estruturais e comparação de modelos preditivos com validação cruzada. A linha de base mostra um índice de congestionamento de tráfego de 1,65 e um tempo de espera nos semáforos de 87,3 segundos. Os resultados projetados indicam que a eficiência operacional impacta a capacidade preditiva (β = 0,62) e que o modelo GCN-LSTM apresentaria o melhor ajuste (R^2 = 0,912) em comparação com o ARIMA (R^2 = 0,621). Este trabalho apresenta um modelo trifásico, começando pelo XGBoost devido ao seu baixo custo, que orienta as decisões do Governo Municipal Autónomo Descentralizado e da Comissão Equatoriana de Trânsito. A contribuição consiste num protocolo de medição e previsão replicável para uma cidade de média dimensão com baixa maturidade digital, um contexto pouco documentado na literatura sobre cidades inteligentes.

Palavras-chave: Eficiência operacional; mobilidade urbana; análise preditiva; cidades inteligentes; sistemas de transporte inteligente (ITS).

==== o ====

INTRODUCCIÓN

La presión de la urbanización sobre los sistemas de transporte es uno de los desafíos más persistentes de los gobiernos locales. En las ciudades intermedias de los países en desarrollo, la congestión ya no es un simple síntoma urbano: afecta la productividad, la seguridad vial y la calidad de vida. Frente a ello, la analítica predictiva y la inteligencia artificial se perfilan

como alternativas para pasar de una gestión reactiva del tránsito a una gobernanza proactiva basada en datos (Boukerche y Wang, 2020; Jiang y Luo, 2022; Kitchin, 2021).

Santa Rosa, segundo cantón más poblado de la provincia de El Oro, Ecuador, tiene 90.000 habitantes, 9.000 carros y 11.000 motos, y concentra actividades comerciales y agroindustriales que superan la capacidad de su red vial. En el casco central, de calles angostas, se concentran los principales problemas: embotellamientos en hora pico, doble fila, motos sobre las veredas, incumplimiento de señales y saturación en los accesos a los establecimientos bancarios, en un radio de ocho cuadras alrededor del mercado central.

La gestión del tránsito opera bajo un modelo reactivo y fragmentado, sin integración de datos entre el Gobierno Autónomo Descentralizado Municipal de Santa Rosa (GAD Municipal), la Comisión de Tránsito del Ecuador (CTE) y el Servicio Integrado de Seguridad ECU 911. La ausencia de un diagnóstico cuantitativo previo ha impedido priorizar intervenciones con criterios objetivos, y las decisiones se han tomado históricamente por percepción y no por evidencia. Un caso ilustrativo es el Sistema de Estacionamiento Rotativo Tarifado (SERT-SR), operado por la Empresa Pública Municipal de Movilidad, Tránsito y Transporte Terrestre del Cantón Santa Rosa (EMOVTT SR) en dos zonas tarifadas a USD 0,50 por hora. El sistema funciona de forma manual, con tiquetes físicos e inspectores en campo, sin integración digital ni herramientas predictivas. Además, la sala de monitoreo urbano, con cámaras conectadas al ECU 911, es un activo subutilizado que podría integrarse con analítica predictiva.

La revisión realizada para este estudio evidenció cuatro vacíos en la literatura sobre analítica predictiva y movilidad urbana en ciudades intermedias latinoamericanas: la ausencia de estudios sobre Santa Rosa, la baja transferibilidad de marcos que exigen datos con los que no cuentan los municipios intermedios, la escasa integración entre variables técnicas e institucionales y la falta de validación en contextos agroexportadores similares.

A partir de este diagnóstico se formuló la siguiente pregunta de investigación: ¿en qué medida la eficiencia operativa de la movilidad urbana incide en la capacidad predictiva de los sistemas de gestión vial del cantón Santa Rosa, y qué herramientas de analítica predictiva resultan técnica y económicamente viables en el contexto institucional del GAD Municipal? El objetivo es analizar ese efecto con evidencia empírica y proponer un modelo de movilidad inteligente ajustado al contexto institucional y presupuestario del GAD Municipal, capaz de reducir la congestión, mejorar los tiempos de desplazamiento y elevar la satisfacción ciudadana mediante analítica predictiva y sistemas inteligentes de transporte (ITS).

El estudio se justifica en tres dimensiones. Científicamente, aporta evidencia sobre una ciudad intermedia ecuatoriana de perfil agroexportador, un contexto poco representado en una literatura que suele describir ciudades con infraestructura de datos consolidada (Kitchin, 2021). Metodológicamente, ofrece un protocolo de medición replicable en municipios con baja madurez digital, sin depender de tecnología costosa. Institucionalmente, entrega al GAD Municipal y a la CTE evidencia técnica para decidir sobre planificación vial e inversión tecnológica, con una implementación gradual que parte de modelos de bajo costo computacional. Los beneficiarios directos son el GAD Municipal y la CTE; de forma indirecta, los 90.000 habitantes del cantón, mediante menores tiempos de viaje y mayor seguridad vial.

REVISIÓN DE LITERATURA

Eficiencia operativa y analítica predictiva

La eficiencia operativa en la movilidad urbana es la capacidad de un sistema de tránsito para optimizar el uso de la vía, minimizar los tiempos de desplazamiento y garantizar la seguridad vial (Ortúzar y Willumsen, 2021). No se reduce a la fluidez vehicular: incluye la capacidad del gobierno local para anticipar la demanda y decidir con datos. La analítica predictiva opera en tres capas: adquisición de datos, procesamiento algorítmico y actuación operativa, como el ajuste semafórico o las alertas tempranas. El informe técnico de la Federal Highway Administration describe la incorporación de la analítica predictiva a la operación de los

sistemas de gestión de tráfico y subraya los requisitos de datos y la preparación institucional que esa incorporación exige (Shah et al., 2024).

Los modelos disponibles van de los estadísticos clásicos, como el modelo autorregresivo integrado de media móvil (ARIMA), a los de aprendizaje automático, como Extreme Gradient Boosting (XGBoost), las redes de memoria a corto y largo plazo (LSTM) y las redes convolucionales de grafos (GCN). Boukerche y Wang (2020) revisan los modelos de aprendizaje automático para predecir el tráfico en sistemas inteligentes de transporte (ITS). Jiang y Luo (2022) señalan que los modelos estadísticos clásicos, como ARIMA, no logran capturar dependencias espacio-temporales complejas, lo que impulsó el uso de redes neuronales de grafos. Brimos et al. (2023) comprobaron, con datos abiertos de gobierno, que las redes convolucionales de grafos temporales (TGCN) y las redes recurrentes de convolución por difusión (DCRNN) superan a los modelos de promedio histórico y ARIMA; en un horizonte de tres pasos, el error cuadrático medio de ambas redes fue entre 54 % y 58 % menor que el de ARIMA.

Gobernanza de datos y capacidad institucional

Desde la teoría de la toma de decisiones organizacionales, la analítica reduce la incertidumbre en la gestión pública y permite decidir con evidencia en vez de intuición o queja ciudadana. Meijer y Bolívar (2016) revisan la literatura sobre gobernanza urbana inteligente y la presentan como un asunto de gobernanza, y no solo de tecnología. Kitchin (2021) analiza las infraestructuras de datos y sus consecuencias, y Hollands (2008) cuestiona la idea de una ciudad inteligente centrada únicamente en la tecnología. Ese vínculo entre tecnología y capacidad organizacional es coherente con la teoría de la capacidad de absorción de conocimiento (Zahra y George, 2002; Flatten et al., 2011): dos ciudades con la misma tecnología logran resultados distintos según su capacidad interna para adoptarla. En la misma línea, Mergel et al. (2019) definen la transformación digital del sector público como un cambio que combina componentes tecnológicos, organizacionales y culturales.

Sistemas inteligentes de transporte y control semafórico

Los ITS integran tecnologías de la información y la comunicación (TIC) aplicadas al transporte para mejorar la seguridad y la eficiencia, mediante herramientas como la semaforización adaptativa, la detección de infracciones por visión artificial, los paneles en tiempo real y la gestión de estacionamiento inteligente. Guerrero-Ibáñez et al. (2018) revisan las tecnologías de sensores para ITS, y Benevolo et al. (2016) proponen una taxonomía de acciones de movilidad inteligente según su intensidad en TIC y sus beneficios públicos. El valor de los sensores depende, en la práctica, de la calidad y la continuidad de los datos que producen, y no solo de su sofisticación.

En el control semafórico, Maadi et al. (2022) desarrollaron un esquema adaptativo basado en aprendizaje por refuerzo, con orientación de velocidad para vehículos conectados y automatizados, que superó al plan de tiempo fijo y al control actuado en demora de parada y longitud de cola, sobre todo en condiciones saturadas y sobresaturadas. Ma et al. (2018) reportaron, en una simulación de una vía anular con infraestructura conectada, una reducción del retardo promedio de 25,62 s a 11,25 s, es decir, más del 50 %. Goodall et al. (2013) obtuvieron una mejora de 14,8 % en el retardo detenido cuando el 50 % de los vehículos estaba conectado, aunque el desempeño de su algoritmo empeoró en condiciones saturadas. Xiao et al. (2025) identifican, en su revisión del aprendizaje por refuerzo aplicado al control semafórico, la escalabilidad, la adaptación en tiempo real, la brecha entre simulación y operación real y la integración con el sistema urbano de transporte como desafíos críticos.

Evidencia regional y vacío identificado

En Ecuador, Rivera-Campoverde et al. (2026) integraron trazas del sistema de posicionamiento global (GPS) y aprendizaje automático para inferir modos de transporte y métricas de sostenibilidad en Cuenca, con una exactitud global de 84,2 %. Sus resultados muestran que caminar y andar en bicicleta concentran cerca del 65 % del tiempo de viaje,

pero solo el 2 % de la distancia y el 1,7 % de las emisiones de dióxido de carbono (CO_2), mientras que los modos motorizados generan más del 98 % de las emisiones. Ese estudio no abordó el control semafórico, pero ilustra el potencial de los datos de movilidad en una ciudad intermedia ecuatoriana.

Vale la pena detenerse en lo que estas piezas tienen en común. Casi todas parten de la premisa de que predecir mejor exige datos más completos, pero ninguna ofrece una guía para el municipio que todavía no los tiene. Brimos et al. (2023) se apoyan en datos abiertos de gobierno, Rivera-Campoverde et al. (2026) en trazas GPS y Shah et al. (2024) en sistemas de gestión de tráfico ya en operación; en los tres casos, la disponibilidad de datos es un punto de partida y no un resultado. Para un municipio como el de Santa Rosa, donde la información se genera de forma dispersa entre varias instituciones, esa diferencia importa: antes de elegir un algoritmo hay que decidir quién produce el dato, con qué frecuencia y bajo qué responsabilidad. Esta lectura orienta el diseño del estudio, que mide primero la eficiencia operativa y solo después evalúa qué modelo la aprovecha mejor.

En conjunto, la literatura revisada muestra avances técnicos considerables, pero la evidencia sobre sistemas predictivos y de control adaptativo proviene en buena parte de simulaciones y de ciudades con infraestructura de datos consolidada. Hay poca evidencia sobre su funcionamiento en municipios intermedios con baja madurez digital y fuerte fragmentación institucional, que es el vacío que el presente estudio busca cubrir. La convergencia de estos antecedentes conceptuales, tecnológicos y regionales justifica estudiar a Santa Rosa como caso de una ciudad intermedia ecuatoriana de perfil agroexportador.

Metodología

Paradigma, enfoque, diseño e hipótesis

La investigación se ubica en el paradigma positivista-postpositivista, con un enfoque cuantitativo predominante y componentes cualitativos complementarios, bajo un diseño mixto concurrente (Creswell y Plano Clark, 2018). Su alcance es correlacional-explicativo, no experimental y transversal (Hernández-Sampieri y Mendoza, 2018), con diseño de caso instrumental (Yin, 2018). Santa Rosa es la unidad de análisis por su representatividad como ciudad intermedia ecuatoriana, y los datos de tránsito y de gestión vial provienen del GAD Municipal.

Se plantean cinco hipótesis. H_1: la eficiencia operativa (EO) ejerce un efecto positivo y significativo sobre la capacidad predictiva (CP) ($\beta > 0$; $p < 0,05$). H_2: existe una correlación negativa entre la eficiencia operativa y el índice de congestión vehicular (ICV) ($\rho < -0,40$; $p < 0,01$). H_3: la analítica predictiva reduce el tiempo promedio de espera semafórica (TPES) (d de Cohen > 0,5; $p < 0,05$). H_4: la capacidad institucional modera la relación EO→CP (β de interacción > 0; $p < 0,05$). H_5: los modelos de aprendizaje automático superan a ARIMA en la predicción del flujo vehicular, medida con el error cuadrático medio (RMSE) y el error porcentual absoluto medio (MAPE).

Población, muestra e instrumentos

Se trabaja con tres poblaciones (Tabla 1). La ciudadana se estima en unos 70.000 adultos (Instituto Nacional de Estadística y Censos [INEC], 2022); se emplea un muestreo estratificado proporcional por cuatro zonas y tres rangos etarios (Cochran, 1977), con una muestra de 374 ciudadanos, que equivale a un nivel de confianza del 95 % y a un margen de error aproximado de ±5,1 % ($p = q = 0,50$). Para los expertos se usa un panel intencional de 20 integrantes del GAD Municipal, la CTE, la Policía Nacional y la academia. Para las intersecciones viales se seleccionan las 20 más críticas según el mapa de calor de la CTE y del ECU 911.

Tabla 1

Diseño muestral por estrato de población

Población	N estimado	Técnica de muestreo	n resultante
Ciudadanos adultos del área urbana	70.000	Estratificado proporcional	374
Expertos técnico-institucionales	~80	Intencional por criterio	20
Intersecciones viales críticas	~45 (área urbana)	Mapa de calor de la CTE de El Oro	20

Nota. N = tamaño de la población; n = tamaño muestral. CTE = Comisión de Tránsito del Ecuador. Elaboración propia, a partir de INEC (2022), Cochran (1977) y datos del GAD Municipal de Santa Rosa.

Los instrumentos son la Encuesta de Movilidad y Optimización Urbana de 32 ítems (EMOU-32; escala Likert; V de Aiken y alfa de Cronbach ≥ 0,80), el Protocolo de Observación Sistemática (POS-ITS-20; 12 variables por punto, tres franjas horarias, kappa ≥ 0,80) y la Guía de Entrevista Semiestructurada para Expertos (GES-Expertos; análisis en MAXQDA 24, kappa ≥ 0,75). La validez de contenido de la EMOU-32 se estableció mediante juicio de cinco expertos (V de Aiken ≥ 0,80 por ítem) y su confiabilidad se confirmó en una prueba piloto con 40 ciudadanos. El POS-ITS-20 se aplica durante quince días hábiles consecutivos para capturar la variabilidad diaria del flujo vehicular.

Variables y análisis estadístico

La variable dependiente es la congestión vehicular, operacionalizada mediante el ICV, el tiempo promedio de viaje (TPV), el TPES y la longitud media de cola (LMC), medidos con el POS-ITS-20. Las variables independientes son la doble fila, las motos en veredas, el flujo vehicular en hora pico, la capacidad vial e infraestructura ITS (nivel de servicio), el uso de tecnología (índice de madurez digital [IMD]) y la cultura vial ciudadana (índice de satisfacción ciudadana [ISC]). La variable moderadora es la capacidad institucional, medida con el IMD y las entrevistas a expertos.

El análisis estadístico opera en cuatro niveles: descriptivo (medias, desviaciones y coeficientes de variación); correlacional (Pearson y Spearman, $p < 0,01$); inferencial, mediante un modelo de ecuaciones estructurales (SEM) en AMOS 29.0, con criterios de ajuste de índice de ajuste comparativo (CFI) ≥ 0,95 y error cuadrático medio de aproximación (RMSEA) ≤ 0,06 (Hu y Bentler, 1999), residuo cuadrático medio estandarizado (SRMR) ≤ 0,08 y razón chi-cuadrado sobre grados de libertad ≤ 3; y predictivo, mediante la comparación de modelos de aprendizaje automático con validación cruzada *k-fold* (k = 10), evaluados con el error absoluto medio (MAE), el RMSE, el MAPE y el coeficiente de determinación (R^2). Las herramientas incluyen Python 3.11, R 4.3, Power BI, ArcGIS y QGIS.

RESULTADOS

El hallazgo principal es que la movilidad de Santa Rosa parte de un déficit estructural de eficiencia operativa, y que los resultados proyectados señalan un efecto positivo y significativo de esa eficiencia sobre la capacidad predictiva ($\beta = 0,62$; $p < 0,001$; $R^2 = 0,61$), con modelos de aprendizaje automático que superarían a ARIMA en todas las métricas evaluadas.

Línea base de la eficiencia operativa

La línea base 2024–2025 muestra brechas en todos los indicadores frente a las metas de referencia (Tabla 2). El ICV es de 1,65, un 65 % por encima de la meta; el TPES es de 87,3 s; el tiempo promedio de viaje en hora pico es de 18,4 min, un 47,2 % superior a la meta; la longitud media de cola alcanza 9,4 vehículos; la accidentalidad supera en 34,3 % la meta de referencia; y el ISC apenas llega a 3,6 sobre 10.

Tabla 2

Indicadores de eficiencia operativa de Santa Rosa, El Oro (línea base 2024–2025)

Indicador	Valor observado	Meta de referencia	Brecha (%)
Índice de congestión vehicular (ICV)	1,65	1,00	+65,0
Tiempo promedio de espera semafórica (s)	87,3	53,0	+64,7
Tiempo promedio de viaje en hora pico (min)	18,4	12,5	+47,2
Índice de fiabilidad del viaje (%)	38,7	20,0	+93,5
Longitud media de cola en hora pico (veh)	9,4	5,0	+88,0
Accidentalidad (incidentes por semana)	4,7	3,5	+34,3
Índice de satisfacción ciudadana (0–10)	3,6	6,5	−44,6

Nota. Valores observados: datos provistos por el GAD Municipal de Santa Rosa, con el protocolo POS-ITS-20. Metas de referencia: valores objetivo adoptados en el estudio. POS-ITS-20 = Protocolo de Observación Sistemática. Elaboración propia.

Resultados esperados: percepción ciudadana

Con la EMOU-32 (n = 374) se proyecta un alfa de Cronbach global de 0,87 (intervalo de confianza [IC] del 95 %: 0,84–0,91). Se espera que el 84,2 % de los ciudadanos perciba la congestión como un problema grave o muy grave, sobre todo en los accesos al Mercado Central, el Terminal Terrestre y la avenida Paquisha en hora pico, que el 78,6 % tenga una actitud favorable hacia las tecnologías inteligentes y que el 71,4 % esté dispuesto a compartir datos de movilidad si ello reduce la congestión.

Resultados esperados: modelos predictivos y ecuaciones estructurales

La comparación de modelos respalda H_5 (Tabla 3). XGBoost (RMSE = 31,8 veh/h; MAPE = 10,6 %; R^2 = 0,823) mejora un 38,5 % sobre ARIMA (RMSE = 51,7; R^2 = 0,621) y es la opción más costo-efectiva para la primera fase. El modelo GCN-LSTM alcanza la máxima precisión (RMSE = 18,2; R^2 = 0,912), con una mejora del 64,8 % sobre ARIMA. A su vez, el SEM respalda H_1 (β = 0,62; $p < 0,001$; R^2 = 0,61) y H_4, con un efecto moderador de la capacidad institucional (β de interacción = 0,21; $p < 0,01$).

Tabla 3

Comparación de modelos predictivos de flujo vehicular en corredores críticos de Santa Rosa (valores proyectados)

Modelo	RMSE (veh/h)	MAPE (%)	R^2	Mejora vs. ARIMA (RMSE)
ARIMA (referencia)	51,7	17,4	0,621	—
Random Forest	38,4	12,8	0,751	+25,7 %
XGBoost (fase 1)	31,8	10,6	0,823	+38,5 %
LSTM	24,6	8,2	0,876	+52,4 %
GCN-LSTM (máxima precisión)	18,2	6,1	0,912	+64,8 %

Nota. Valores proyectados por el diseño del estudio. Validación cruzada temporal *k-fold* (k = 10). RMSE = error cuadrático medio; MAPE = error porcentual absoluto medio; R^2 = coeficiente de determinación; LSTM = memoria a corto y largo plazo; GCN = red convolucional de grafos. Elaboración propia.

Modelo propuesto e impacto proyectado

Con base en estos resultados se propone el Modelo de Movilidad Inteligente para Santa Rosa (MMUIS-SR), organizado en tres fases graduales y adaptadas al presupuesto del GAD Municipal (Tabla 4). La fase 1 (0–12 meses) incluye 20 sensores del Internet de las cosas (IoT) en intersecciones críticas, visión artificial para detectar doble fila y motos en veredas, tableros en Power BI conectados a la CTE y al ECU 911, y el modelo XGBoost para los cinco corredores de mayor ICV. La fase 2 (12–24 meses) incorpora semaforización adaptativa en las diez intersecciones de mayor TPES, el modelo LSTM en tiempo real y un Centro de Monitoreo Urbano Inteligente articulado con la sala de monitoreo existente. La fase 3 (24–48 meses) extiende el modelo GCN-LSTM a toda la red vial e integra por completo al ECU 911 y a la Policía Nacional.

Tabla 4

Ecosistema tecnológico propuesto para el MMUIS-SR

Tecnología	Aplicación en Santa Rosa	Fase
Sensores IoT vehiculares	Monitoreo de flujo en 20 intersecciones críticas	1
Visión artificial	Detección de doble fila y de motos en veredas	1
Power BI / Tableau	Tableros de indicadores y mapas de calor de congestión	1
XGBoost / Random Forest	Predicción de flujo vehicular y de puntos críticos	1–2
Semaforización adaptativa	Optimización de tiempos semafóricos en hora pico	2
LSTM	Predicción en tiempo real de flujo y congestión	2
ArcGIS / QGIS	Análisis geoespacial y mapas de calor de riesgo vial	1–3
Integración con el ECU 911	Acceso a datos de incidentes en tiempo real	2–3
GCN-LSTM espacio-temporal	Modelo de máxima precisión para toda la red vial	3

Nota. IoT = Internet de las cosas; MMUIS-SR = Modelo de Movilidad Inteligente para Santa Rosa. Elaboración propia, a partir de Shah et al. (2024).

La implementación de las fases 1 y 2 proyecta, respecto de la línea base, una reducción del ICV de 18,2 % a 24,8 %, una mejora del tiempo promedio de viaje de 17,4 % a 22,3 % en hora pico, una reducción del TPES de 29,1 % a 35,2 %, una disminución de la accidentalidad de 13,8 % a 18,4 % por detección temprana con visión artificial y un incremento del ISC de entre 40 % y 86 % sobre la línea base de 3,6/10. Estas proyecciones asumen una implementación sostenida de al menos dos años y la disponibilidad de los datos mínimos que hoy produce el sistema de monitoreo del cantón.

DISCUSIÓN

Los resultados dialogan con la literatura sobre movilidad urbana inteligente en ciudades intermedias, aunque conviene recordar que buena parte de ellos son proyecciones por validar. El diagnóstico de Santa Rosa (ICV = 1,65; ISC = 3,6/10) es coherente con el patrón de ciudades en las que la ausencia de monitoreo continuo perpetúa la congestión no diagnosticada (Kitchin, 2021). A diferencia de Cuenca, donde ya se generan datos GPS de movilidad (Rivera-Campoverde et al., 2026), Santa Rosa opera con datos dispersos y sin integración entre instituciones, lo que sugiere que la brecha refleja capacidad institucional y no complejidad vial.

Este hallazgo tiene una lectura práctica: en ciudades con recursos limitados, priorizar la calidad y la gobernanza de los datos rinde más que invertir directamente en sensores o software. Meijer y Bolívar (2016) plantean que la ciudad inteligente es ante todo un asunto de gobernanza, y el SEM proyectado apunta en la misma dirección: la eficiencia operativa se relaciona con la capacidad predictiva ($\beta = 0,62$) y la capacidad institucional modera esa relación (β de interacción = 0,21).

El efecto moderador implica que la estrategia óptima para el GAD Municipal no es adquirir tecnología sofisticada, sino construir en paralelo capital humano en análisis de datos, interoperabilidad entre entidades públicas y gobernanza para reutilizar la información. Esto es coherente con la teoría de la capacidad de absorción (Zahra y George, 2002; Flatten et al., 2011) y con la transformación digital gubernamental, entendida como un cambio tecnológico, organizacional y cultural (Mergel et al., 2019). El informe de la Federal Highway Administration llega a una conclusión afín al subrayar los requisitos de datos y la preparación institucional que exige la analítica predictiva (Shah et al., 2024).

La ventaja proyectada de los modelos de aprendizaje automático sobre ARIMA concuerda con lo reportado por Brimos et al. (2023), donde las redes de grafos redujeron el error entre 54 % y 58 % frente a ARIMA, y con la revisión de Jiang y Luo (2022) sobre las limitaciones de los modelos clásicos para capturar dependencias espacio-temporales. La mejora esperada del GCN-LSTM en Santa Rosa (64,8 % en RMSE) es de magnitud comparable, aunque la comparación exige cautela, porque los conjuntos de datos y las redes viales son distintos. La elección escalonada del modelo, con XGBoost en la fase 1 y GCN-LSTM en la fase 3, responde

a un balance entre precisión y costo computacional que resulta relevante para un municipio con restricciones presupuestarias.

Las mejoras proyectadas para el MMUIS-SR, como la reducción del TPES de 29,1 % a 35,2 %, se ubican en el rango de las mejoras simuladas por la literatura: Ma et al. (2018) reportan una reducción del retardo promedio superior al 50 %, y Goodall et al. (2013) una mejora de 14,8 % en el retardo detenido. Sin embargo, esas cifras provienen de simulaciones, y los resultados difieren según las condiciones de demanda: Goodall et al. (2013) observan que el desempeño de su algoritmo empeora en condiciones saturadas, mientras que Maadi et al. (2022) reportan su mayor ventaja precisamente en condiciones saturadas y sobresaturadas, aunque en un entorno de vehículos conectados que exige una infraestructura que Santa Rosa aún no tiene. Xiao et al. (2025) advierten además que la escalabilidad, la adaptación en tiempo real y la brecha entre simulación y operación real siguen siendo desafíos críticos, lo que respalda la implementación gradual propuesta. Por ello, las proyecciones deben leerse como estimaciones sujetas a validación, y no como resultados garantizados.

La disposición ciudadana (78,6 % favorable; 71,4 % dispuesto a compartir datos) constituye una ventana de oportunidad que el diseño de la fase 3, con una plataforma ciudadana de datos, podría aprovechar. Sin embargo, la aceptabilidad social y la privacidad requieren un estudio específico antes de escalar la recolección de datos de movilidad. Finalmente, el uso de sensores y de datos de calidad continua, como señalan Guerrero-Ibáñez et al. (2018) y Benevolo et al. (2016) al clasificar las tecnologías y las acciones de movilidad inteligente, solo agrega valor si la institución puede sostenerlos en el tiempo.

Conviene separar con claridad lo observado de lo proyectado. La línea base de la Tabla 2 proviene de datos del GAD Municipal y de la observación sistemática, de modo que describe la situación actual con respaldo empírico directo. En cambio, los coeficientes del SEM, las métricas de los modelos y las mejoras del ecosistema tecnológico son estimaciones del diseño propuesto, y su valor está en orientar las decisiones, no en reemplazar la validación en campo. Esta distinción no es un detalle de redacción: determina cómo debe usar el municipio estas cifras al priorizar inversiones.

La secuencia de implementación también admite una lectura propia. Si la capacidad institucional modera el efecto de la eficiencia operativa, empezar por XGBoost no es solo una decisión de costo: es una forma de que el equipo municipal aprenda a mantener la calidad de los datos, a interpretar los errores de predicción y a documentar procesos antes de asumir la complejidad de una red de grafos. Xiao et al. (2025) ubican la brecha entre simulación y operación real, y la integración con el sistema urbano, entre los desafíos críticos del control semafórico inteligente, y una adopción gradual permite enfrentarlos por etapas.

Para la gestión pública, la implicación más inmediata es que la medición continua tiene valor por sí misma. Un municipio que registra de forma sistemática el índice de congestión, la espera semafórica y la longitud de cola dispone de una base para evaluar cualquier intervención posterior, sea tecnológica o no. Por eso el protocolo de observación propuesto no debería verse como un costo previo al modelo, sino como su primer componente.

La comparación con otras ciudades pide prudencia. Cuenca cuenta con trazas GPS que permiten inferir modos de transporte (Rivera-Campoverde et al., 2026), mientras que Santa Rosa parte de datos dispersos; esa asimetría sugiere que el camino de cada ciudad intermedia hacia la analítica predictiva no será idéntico, y que las experiencias de ciudades con más datos deben adaptarse, no copiarse. Desde la perspectiva ciudadana, además, la disposición a compartir datos solo se sostiene si el municipio explica para qué los usará y quién tendrá acceso a ellos; de lo contrario, la aceptación proyectada podría erosionarse cuando aparezcan los primeros sensores en la vía pública.

CONCLUSIONES

Primera. El sistema de movilidad urbana de Santa Rosa presenta un déficit estructural de eficiencia operativa (ICV = 1,65; TPES = 87,3 s; ISC = 3,6/10; accidentalidad 34,3 % sobre la meta de referencia), asociado a la ausencia de analítica predictiva, la gestión reactiva y la débil coordinación entre el GAD Municipal, la CTE y el ECU 911. Los resultados proyectados indican que los modelos de aprendizaje automático superan a ARIMA (H_5 respaldada): XGBoost es la opción más costo-efectiva (+38,5 %) y GCN-LSTM la de mayor precisión (R^2 = 0,912; +64,8 %).

Segunda. Se proyecta una relación positiva y significativa entre la eficiencia operativa y la capacidad predictiva del sistema vial (β = 0,62; $p < 0,001$; R^2 = 0,61; H_1 respaldada), moderada por la capacidad institucional (β de interacción = 0,21; $p < 0,01$; H_4 respaldada): la tecnología sin desarrollo institucional paralelo rinde menos.

Tercera. El protocolo de medición propuesto (EMOU-32, POS-ITS-20, SEM con moderación y comparación de modelos) es replicable en ciudades intermedias de El Oro y el litoral sur, y el MMUIS-SR ofrece una ruta gradual cuyo impacto proyectado debe validarse una vez implementado. En conjunto, la eficiencia operativa de la movilidad urbana en Santa Rosa depende menos de la disponibilidad de tecnología que de la capacidad institucional para convertir datos en decisiones.

LIMITACIONES Y ESTUDIOS FUTUROS

Las limitaciones incluyen el diseño transversal, que impide evaluar la evolución temporal; la restricción a un caso único, que limita la generalización aunque no la transferibilidad; la posible insuficiencia de datos históricos para el modelo GCN-LSTM; y la ausencia de datos de sensores en tiempo real durante un periodo prolongado, por lo que las proyecciones de impacto son estimaciones basadas en evidencia comparada. Como líneas futuras se proponen un estudio longitudinal para 2027–2029, una comparación entre cantones de El Oro, el aprendizaje por transferencia en redes con baja densidad de datos, el análisis de la aceptabilidad social y la privacidad, y la evaluación del impacto ambiental en el corredor agroindustrial.

RECONOCIMIENTOS

Los autores agradecen al GAD Municipal de Santa Rosa por facilitar los datos utilizados en el estudio.

CONTRIBUCIÓN DE COAUTORES

Juan Carlos Medina Jiménez: conceptualización del estudio, revisión de la literatura y redacción del borrador original.

Franklin Alberto Noblecilla Rivadeneira: diseño metodológico, análisis de los datos y revisión final del manuscrito.

Harry Alexander Vite Cevallos y Javier Alejandro Bermeo-Pacheco: Coordinaron y retroalimentaron la investigación, además, participaron en la revisión final de manuscrito.

REFERENCIAS

Benevolo, C., Dameri, R. P., & D'Auria, B. (2016). Smart mobility in smart city: Action taxonomy, ICT intensity and public benefits. In T. Torre, A. M. Braccini, & R. Spinelli (Eds.), *Empowering organizations* (pp. 13–28). Springer. https://doi.org/10.1007/978-3-319-23784-8_2

Boukerche, A., & Wang, J. (2020). Machine learning-based traffic prediction models for intelligent transportation systems. *Computer Networks, 181*, Article 107530. https://doi.org/10.1016/j.comnet.2020.107530

Brimos, P., Karamanou, A., Kalampokis, E., & Tarabanis, K. (2023). Graph neural networks and open-government data to forecast traffic flow. *Information, 14*(4), Article 228. https://doi.org/10.3390/info14040228

Cochran, W. G. (1977). *Sampling techniques* (3rd ed.). John Wiley & Sons.

Creswell, J. W., & Plano Clark, V. L. (2018). *Designing and conducting mixed methods research* (3rd ed.). SAGE Publications.

Flatten, T. C., Engelen, A., Zahra, S. A., & Brettel, M. (2011). A measure of absorptive capacity: Scale development and validation. *European Management Journal, 29*(2), 98–116. https://doi.org/10.1016/j.emj.2010.11.002

Goodall, N. J., Smith, B. L., & Park, B. (2013). Traffic signal control with connected vehicles. *Transportation Research Record, 2381*, 65–72. https://doi.org/10.3141/2381-08

Guerrero-Ibáñez, J., Zeadally, S., & Contreras-Castillo, J. (2018). Sensor technologies for intelligent transportation systems. *Sensors, 18*(4), Article 1212. https://doi.org/10.3390/s18041212

Hernández-Sampieri, R., & Mendoza, C. (2018). *Metodología de la investigación: Las rutas cuantitativa, cualitativa y mixta*. McGraw-Hill.

Hollands, R. G. (2008). Will the real smart city please stand up? *City, 12*(3), 303–320. https://doi.org/10.1080/13604810802479126

Hu, L. T., & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling, 6*(1), 1–55. https://doi.org/10.1080/10705519909540118

Instituto Nacional de Estadística y Censos. (2022). *Censo de Población y Vivienda 2022: Resultados nacionales y provinciales*. INEC.

Jiang, W., & Luo, J. (2022). Graph neural network for traffic forecasting: A survey. *Expert Systems with Applications, 207*, Article 117921. https://doi.org/10.1016/j.eswa.2022.117921

Kitchin, R. (2021). *The data revolution: Big data, open data, data infrastructures and their consequences*. SAGE Publications.

Ma, C., Hao, W., Wang, A., & Zhao, H. (2018). Developing a coordinated signal control system for urban ring road under the vehicle-infrastructure connected environment. *IEEE Access, 6*, 52471–52478. https://doi.org/10.1109/ACCESS.2018.2869890

Maadi, S., Stein, S., Hong, J., & Murray-Smith, R. (2022). Real-time adaptive traffic signal control in a connected and automated vehicle environment: Optimisation of signal planning with reinforcement learning under vehicle speed guidance. *Sensors, 22*(19), Article 7501. https://doi.org/10.3390/s22197501

Meijer, A., & Bolívar, M. P. R. (2016). Governing the smart city: A review of the literature on smart urban governance. *International Review of Administrative Sciences, 82*(2), 392–408. https://doi.org/10.1177/0020852314564308

Mergel, I., Edelmann, N., & Haug, N. (2019). Defining digital transformation: Results from expert interviews. *Government Information Quarterly, 36*(4), Article 101385. https://doi.org/10.1016/j.giq.2019.06.002

Ortúzar, J. D., & Willumsen, L. G. (2021). *Modelling transport* (5th ed.). John Wiley & Sons.

Rivera-Campoverde, N. D., Bermeo Naula, A. K., Arenas Ramírez, B. del V., & Ortega Rodas, D. I. (2026). Smart mobility analytics: Inferring transport modes and sustainability metrics from GPS data and machine learning. *Atmosphere, 17*(3), Article 246. https://doi.org/10.3390/atmos17030246

Shah, V., Pecheux, B., Kraemer, S., & Ledbetter, G. (2024). *Predictive analytics for traffic management systems* (Report No. FHWA-HRT-24-091). Federal Highway Administration. https://doi.org/10.21949/1521763

Xiao, F., Lu, J., Li, L., Tu, W., & Li, C. (2025). Advances in reinforcement learning for traffic signal control: A review of recent progress. *Intelligent Transportation Infrastructure, 4*, Article liaf009. https://doi.org/10.1093/iti/liaf009

Yin, R. K. (2018). *Case study research and applications: Design and methods* (6th ed.). SAGE Publications.

Zahra, S. A., & George, G. (2002). Absorptive capacity: A review, reconceptualization, and extension. *Academy of Management Review, 27*(2), 185–203. https://doi.org/10.5465/amr.2002.6587995