



Revista Ciencia, Tecnología e Innovación en Ingeniería y Arquitectura

CTI-FIA

**Volumen 2
Número 1
Año 2026**



Facultad de Ingeniería y Arquitectura
Universidad de El Salvador
<https://revistas.ues.edu.sv/index.php/cti-fia>

Esta Revista es *Open Access* bajo la licencia *Creative Commons*
Atribución 4.0 Internacional (CC BY 4.0)

CTI-FIA

REVISTA CIENCIA, TECNOLOGÍA E INNOVACIÓN EN INGENIERÍA Y ARQUITECTURA (CTI-FIA)

Volumen 2, Número 1

Número ordinario

Enero-Junio 2026

<https://revistas.ues.edu.sv/index.php/cti-fia/index>

Revista CTI-FIA es gestionada por la Facultad de Ingeniería y Arquitectura de la Universidad de El Salvador se presenta como una plataforma de difusión de conocimiento científico y técnico en las áreas de ingeniería y arquitectura. Actúa como un vehículo para la promoción y difusión de investigaciones originales y novedosas, con un enfoque destacado en la sostenibilidad, lo que refleja su compromiso con el avance hacia un futuro más equitativo, resiliente y sostenible. Además, la revista desempeña un papel importante en la generación de impacto y la promoción del intercambio de conocimientos en el campo de la ingeniería y arquitectura, tanto a nivel local como global.

FACULTAD DE INGENIERÍA Y ARQUITECTURA, UNIVERSIDAD DE EL SALVADOR

Ciudad Universitaria "Dr. Fabio Castillo Figueroa", Final Avenida "Mártires Estudiantes del 30 de julio", San Salvador, El Salvador, América Central.

CORREO ELECTRÓNICO

cti.fia@ues.edu.sv

PERIODICIDAD

La revista emite dos ediciones anuales, correspondientes a los períodos de enero a junio y julio a diciembre. Los artículos se publican en la modalidad continua (Online First Publication), lo que facilita una difusión rápida y oportuna de la información.

OBJETIVO

Difundir investigaciones y conocimiento original en español en las áreas de ingeniería y arquitectura, con un enfoque central en la sostenibilidad, promoviendo el desarrollo de soluciones técnicas y tecnológicas que impulsen un futuro más equitativo, resiliente y sostenible para la sociedad.

DESCARGO DE RESPONSABILIDAD

La Revista CTI-FIA se compromete a proporcionar información precisa y actualizada en el ámbito de la Ciencia, Tecnología e Innovación. Sin embargo, los puntos de vista expresados en los artículos y trabajos publicados son responsabilidad exclusiva de los autores y no reflejan necesariamente la opinión de la revista, su equipo editorial, o la institución a la que pertenecen.

La Revista CTI-FIA no asume responsabilidad por cualquier daño, pérdida o perjuicio derivado del uso de la información proporcionada en sus publicaciones. Los lectores son alentados a verificar la exactitud y relevancia de los contenidos por medio de fuentes adicionales y a consultar a expertos en el campo correspondiente.

La reproducción, distribución o modificación de los contenidos de la Revista CTI-FIA sin autorización previa por escrito está estrictamente prohibida.

Los lectores son responsables de interpretar la información proporcionada en la Revista CTI-FIA y de tomar decisiones basadas en su propio criterio y conocimiento.

EQUIPO EDITORIAL

Ana Beatriz Lima de Zaldaña

Editora

 <https://orcid.org/0009-0008-4859-2638>

Mariela Vanessa Meléndez Ascencio

Correctora de Estilo

 <https://orcid.org/0009-0005-3902-6966>

Napoleón Ernesto López Espinoza

Editor Adjunto

 <https://orcid.org/0009-0005-2368-7639>

Daniel Neftalí Ramírez Salazar

Editor Adjunto

 <https://orcid.org/0009-0000-5013-9965>

Ligia Marcela Lazo Majano

Correctora de Estilo

 <https://orcid.org/0009-0006-6260-2869>

Jonathan Mauricio Argueta Martínez

Diseño y Maquetación

 <https://orcid.org/0009-0000-6130-0603>

AUTORIDADES UNIVERSITARIAS

M.Sc. Juan Rosa Quintanilla Quintanilla
Rector

Dra. Evelyn Beatriz Farfan Mata
Vicerrectora Académica

M.Sc. Roger Armando Arias Alvarado
Vicerrector Administrativo

Lic. Pedro Rosalío Escobar Castaneda
Secretario General

Lic. Carlos Amilcar Serrano Rivera
Fiscal General

M.Sc. Carlos Armando Villalta
Presidente Asamblea General Universitaria (AGU)

MSc. Luís Salvador Barrera Mancía
Decano, Facultad de Ingeniería y Arquitectura

MSc. Ana Beatriz Lima de Zaldaña
Vicedecana, Facultad de Ingeniería y Arquitectura

COMITÉ CIENTÍFICO

MSc. Luis Kelman Belloso Huevo
<https://orcid.org/0000-0002-2501-0411>
Profesor e Investigador Universitario
Universidad Don Bosco, El Salvador

Ph.D. Efren Locarno Florez
<https://orcid.org/0000-0002-8655-8456>
Profesor e Investigador Universitario
Universidad de Cartagena, Colombia

Política de acceso abierto

La Revista CTI-FIA opera sin finalidad de lucro. Provee libre y gratuito acceso a las publicaciones realizadas por la revista, inmediatamente a la publicación de sus respectivos números, de acuerdo con la periodicidad establecida. La finalidad es fomentar el intercambio global del conocimiento. En cuanto al proceso editorial, no cobra ni retribuye monetariamente a los autores que envían publicaciones, y ellos ceden el derecho de publicar sus trabajos en la revista. Tampoco realiza pagos o promueve dádivas para los revisores que participan en el proceso de arbitraje.

Política de acceso y reuso

La Revista CTI-FIA se compromete a promover el acceso libre y gratuito al conocimiento científico y técnico en las áreas de ingeniería y arquitectura. Todos los artículos publicados en la revista están disponibles en formato abierto bajo una licencia Creative Commons (CC BY-NC), lo que permite a los usuarios leer, descargar, copiar, distribuir, imprimir, buscar o enlazar los textos completos de los artículos, o utilizarlos para cualquier otro propósito legal, sin barreras financieras, legales o técnicas.

Los usuarios pueden reutilizar el contenido de la revista para fines no comerciales, siempre y cuando se dé la atribución adecuada al autor y a la Revista CTI-FIA. Esto incluye la cita correcta del trabajo y el reconocimiento de la fuente original de publicación. Para usos comerciales o cualquier modificación del contenido, los usuarios deben obtener permiso explícito de los autores y de la revista.



Contenido

Artículos / Articles

- 05 Predicción Probabilística del Mundial de Fútbol FIFA 2026 mediante Gradient Boosting y Simulación Monte Carlo**
Probabilistic Prediction of the 2026 FIFA World Cup Using Gradient Boosting and Monte Carlo Simulation
Bladimir Díaz Campos, David Deras
- 13 Aplicación de Inteligencia Artificial para la identificación de minerales usando imágenes de láminas delgadas**
Application of Artificial Intelligence for Mineral Identification Using Thin-Section Images
Bladimir Díaz; Sara Sofia Martinez Hernandez; José Antonio Osorio Guandique, Balmore Quintanilla Barrera, Nelly Lissette Henriquez Sanchez
- 19 Optimización de la predicción de retención estudiantil en la educación superior: un análisis comparativo de modelos de aprendizaje automático supervisados y no supervisado**
Optimizing student retention prediction in higher education: A comparative analysis of supervised and unsupervised machine learning models
Franklin Ivan Argueta Bermudez, Wilber Alexander Ortiz Cortez, Miguel García Torres
- 30 Desempeño energético del Edificio para el Centro Urbano de Bienestar y Oportunidades CUBO mediante simulación y escenarios de eficiencia en El Tamarindo, La Unión**
Energy performance of the CUBO Urban Center for Wellbeing and Opportunities building through simulation and efficiency scenarios in El Tamarindo, La Unión
Carlos Osmín Pocasangre Jiménez, Ronald Isaac Cabrera Viera, José René Urquilla Mojica
- 37 Adaptación de la IEEE Std 602 para la implementación de sistemas de alimentación normal y de emergencia en hospitales públicos de El Salvador**
Adaptation of IEEE Std 602 for the implementation of general electrical power supply and emergency systems in hospitals in El Salvador
Manuel Elias Granados Cruz, Marcelo Antonio Martinez Mejia, José Miguel Hernández

Predicción Probabilística del Mundial de Fútbol FIFA 2026 mediante Gradient Boosting y Simulación Monte Carlo

Probabilistic Prediction of the 2026 FIFA World Cup Using Gradient Boosting and Monte Carlo Simulation

David Deras¹, Bladimir Diaz^{1,2}

1 Facultad de Ingeniería y Arquitectura, Universidad de El Salvador

2  <https://orcid.org/0009-0007-3328-5179>

Correspondencia: ✉ bladimir.diaz@ues.edu.sv

Enviado: 4 de junio de 2026 Aceptado: 1 de julio de 2026

DOI: <https://doi.org/10.66778/CTI.v02n01.01>

PALABRAS CLAVE

Fútbol, predicción probabilística, XGBoost, Monte Carlo, ranking ELO, Mundial 2026, calibración de probabilidades

RESUMEN

Se presenta un sistema end-to-end para estimar la probabilidad de campeonato de cada una de las 48 selecciones que disputarán la Copa Mundial de la FIFA 2026 bajo el nuevo formato de 12 grupos. El pipeline integra fuentes heterogéneas (resultados internacionales 1872–2026, datos de eventos, goleadores y tandas de penales, Expected Goals (xG) de StatsBomb, valor de mercado de Transfermarkt y ranking FIFA histórico extendido con un snapshot de 2026) para construir nueve características incluyendo features derivadas calculadas estrictamente as of date que alimentan cuatro modelos multiclase (Regresión Logística, XGBoost, LightGBM y XGBoost calibrado con Platt) entrenados con ponderación por decaimiento temporal exponencial y rebalanceo de clases. El mejor modelo (XGBoost calibrado con método Platt) obtiene un Log-Loss de ,855 y un Brier de ,166 sobre un conjunto de prueba temporal y se acopla a un motor Monte Carlo de 10,000 iteraciones que respeta el reglamento 2026 (2 primeros de grupo + 8 mejores terceros, desempates puntos - DG - GF, definición por penales). Los intervalos de confianza de Clopper–Pearson sitúan a un grupo reducido de selecciones históricamente fuertes entre los favoritos. Una sección dedicada discute las limitaciones del modelo: equipos debutantes sin historial, cobertura parcial de xG y ausencia de modelado estructural de lesiones.

KEYWORDS

Soccer, probabilistic prediction, XGBoost, Monte Carlo simulation, ELO ranking, 2026 FIFA World Cup, probability calibration

ABSTRACT

A comprehensive end-to-end system is presented to estimate the championship probability of each of the 48 national teams participating in the 2026 FIFA World Cup under the new 12-group format. The pipeline integrates heterogeneous data sources, including international match results from 1872–2026, event data (goalscorers and penalty shootouts), Expected Goals (xG) from StatsBomb, Transfermarkt market values, and historical FIFA rankings extended with a 2026 snapshot, to construct nine features—including derived features calculated strictly as-of-date—which are used to train four multiclass models: Logistic Regression, XGBoost, LightGBM, and Platt-calibrated XGBoost. The models are trained using exponential temporal decay weighting and class rebalancing. The best-performing model, Platt-calibrated XGBoost, achieves a Log-Loss of 0.855 and a Brier score of 0.166 on a temporal test set and is coupled with a 10,000-iteration Monte Carlo engine that complies with the 2026 competition regulations (top two teams from each group + eight best third-placed teams, tiebreakers based on points–goal difference–goals scored, and penalty shootouts). Clopper–Pearson confidence intervals place a small group of historically strong national teams among the favorites. A dedicated section discusses the model's limitations, including debutant teams with no historical record, partial xG coverage, and the absence of structural injury modeling.



INTRODUCCIÓN

La Copa Mundial de la FIFA 2026 estrena el mayor cambio estructural de su historia: 48 selecciones repartidas en 12 grupos de 4, de los cuales avanzan los dos primeros lugares más los ocho mejores terceros, totalizando 32 equipos en la fase eliminatoria. El torneo agrega una ronda adicional (Round of 32) y eleva el total de partidos a 104 (FIFA, 2023). Este cambio reglamentario invalida directamente los modelos calibrados sobre formatos de 32 equipos y motiva un rediseño del motor de simulación. Este trabajo introduce un sistema reproducible para estimar la probabilidad de título de cada selección. Las contribuciones son: (i) un pipeline de datos automatizado que combina cuatro fuentes históricas y modernas; (ii) un benchmark de tres clasificadores multi-clase entrenados con time decay exponencial y calibración de Platt (sigmoid) sobre un hold-out temporal; (iii) un motor Monte Carlo que implementa fielmente el reglamento 2026, incluyendo el desempate de los ocho mejores terceros y la simetría local/visitante con excepción para los anfitriones; (iv) una validación histórica sobre el Mundial 2022 sin data leakage y un análisis de sensibilidad a lesiones (−30 % del valor de plantilla).

METODOLOGÍA
Trabajo relacionado

El árbol genético de la predicción futbolística parte del modelo Poisson de Maher (M. J. Maher, 1982) y de su refinamiento Dixon–Coles (M. J. Dixon and S. G. Coles, 1997), que captura la correlación de marcadores bajos. El sistema de puntuación Elo (A. E. Elo, 1978) proporciona una métrica de fuerza relativa actualizable partido a partido, hoy estandarizada para selecciones nacionales. Trabajos más recientes combinan *Random Forest* con ratings de equipo para Mundiales y Eurocopas (A. Groll, C. Ley, G. Schauburger, and H. Van Eetvelde, 2019). La popularización de *XGBoost* (T. Chen and C. Guestrin, 2016) y *LightGBM* (G. Ke et al., 2017) ha desplazado la frontera hacia modelos de *gradient boosting*, mientras que SHAP (S. M. Lundberg and S.-I. Lee, 2017) permite interpretar sus predicciones. Para evaluar la calibración de probabilidades el estándar son el *Log-Loss* y el *Brier score* (G. W. Brier, 1950), complementados con calibración isotónica o de Platt (J. C. Platt, 1999), (A. Niculescu-Mizil and R. Caruana, 2005).

Pipeline de datos

Los datos crudos se descargan o cargan en `src/data/` y se materializan en `data/raw/`; la limpieza y la unión producen `data/processed/features.csv`. El pipeline integra cinco fuentes, re-

sumidas en la Tabla 1.

Fuente principal de resultados

El dataset de Mart Jüri-soo (M. Jürisoo, 2026) disponible tanto en GitHub como en Kaggle (M. Jürisoo, 2026) constituye el núcleo del entrenamiento con ≈49,000 partidos internacionales (1872–2026); según su documentación, los datos se recopilan de Wikipedia, RSSSF y los sitios web de las federaciones nacionales. De la misma colección provienen los archivos de eventos goalscorers (goleadores con minuto y penal), shootouts (tandas) y former_names (continuidad de federaciones), usados para las features derivadas y la unificación de nombres. El ranking FIFA histórico (Cashncarry, 2023) serie 1993–2024 extendida con un snapshot manual del 2026-05-30–alimenta el feature ranking_diff.

Tabla 1

Fuente	Contenido	Cobertura
martj42 [12], [13] martj42 (eventos) [12]	Resultados internacionales Goleadores (min, penal), tandas y nombres históricos	1872–2026, ≈49 000 partidos 47.6k goles; 677 tandas
FIFA Ranking [14]	Posición y puntos (+ snapshot 2026)	1993–2026, ≈210 selecc.
StatsBomb [15]	xG por equipo	109 selecc.
Transfermarkt [16]	Valor de mercado plantilla	62 selecc., snapshot

Estadísticas avanzadas y valor de plantilla

Los xG históricos provienen del open data de StatsBomb (StatsBomb, 2024), consumido vía statsbombpy; las selecciones sin cobertura StatsBomb reciben la media global (≈1,2) como imputación. El *ELO* se calcula in-house con la fórmula de Elo (A. E. Elo, 1978) sobre el historial completo de resultados, sin depender de un proveedor externo. El valor de mercado de las plantillas se obtiene con un snapshot manual de Transfermarkt (Transfermarkt, 2026).

Limpieza y unión

El proceso incluye: estandarización de nombres de países a un canonical name (USA - United States) y unificación de federaciones sucesoras reconocidas por FIFA (Yugoslavia - Serbia, Checoslovaquia - Chequia) para dar continuidad al ELO; deduplicación por (date, home, away); geocodificación de sedes con *geopy* (distancia 0 cuando

falla); *merge-asof backward del ranking FIFA* extendido con el snapshot del 2026-05-30, libre de leakage pues todo partido solo ve ranks anteriores a su fecha- e imputación del xG con la media global ($\approx 1,2$) para selecc. sin cobertura StatsBomb. El ELO se acumula sobre el universo completo de partidos (todos los torneos, incl. amistosos, desde 1872), no sobre el subconjunto filtrado de filas a emitir.

Licencias de datos

Los xG provienen del open data de StatsBomb (StatsBomb,2024), empleado bajo su licencia de uso no comercial con atribución. El valor de mercado de Transfermarkt (Transfermarkt, 2026) es un snapshot manual utilizado exclusivamente con fines académicos, sin redistribución del dato original. Las demás fuentes (martj42 y el ranking FIFA) son datasets públicos de uso para investigación.

RESULTADOS

Ingeniería de características

Se construyen nueve características justificadas tanto teóricamente como mediante EDA (Tabla 2). Tres de ellas se derivan de datos de eventos (goleadores y tandas) y se calculan estrictamente as-of-date mediante *merge_asof(backward, allow_exact_matches=False)*, de modo que

Tabla 2

Características del modelo y su justificación

Feature	Justificación
elo_diff	ELO local – ELO visitante (ELO sobre historia completa); métrica dinámica superior al ranking FIFA estático [4].
squad_value_diff	$\log(\text{val}_i) - \log(\text{val}_i)$; proxy de calidad de plantilla.
xg_avg_for	xG prom. a favor: local – visitante; eficiencia ofensiva.
xg_avg_against	xG prom. en contra: local – visitante; solidez defensiva.
travel_distance_diff	dist. visitante–local a la sede (km); fatiga de viaje (no se anula en sede neutral).
ranking_diff	$\text{rank}_v - \text{rank}_i$; ranking FIFA (refrescado al 2026)
penalty_share_diff	% goles de penal, local – visitante (as-of)
striker_concentration_diff	Herfindahl de goleadores, local – visitante (as-of); dependencia de una figura.

cada partido solo observa eventos anteriores a su fecha (sin leakage). La Figura 2 ilustra la dinámica del ELO en cinco selecciones representativas; la Figura 4 muestra colinealidad alta entre *elo_diff* y *ranking_diff* ($r \approx 0,88$), mientras que el resto de pares se mantiene en niveles moderados.

Figura 1

Distribución de *elo_diff* por clase de resultado (H/E/V). La separación monotónica entre las tres distribuciones respalda el poder predictivo del feature





Figura 2

Evolución del rating ELO para cinco selecciones representativas a lo largo de cuatro décadas



Decaimiento temporal y ponderación de clases.


Cada partido contribuye al entrenamiento con un peso

$$W(t) = e^{-\lambda \Delta t} \cdot c_{yi}, \quad \lambda = 1 \times 10^{-3} \text{ días}^{-1}, \quad (1).$$

donde Δt son los días entre la fecha del partido y la más reciente del dataset, y c_{yi} es el peso balanced de sklearn sobre la etiqueta $y_i \in \{H, E, V\}$. Esto corrige el desbalance natural $H \approx 49 \%$, $E \approx 21 \%$, $V \approx 30 \%$ Figura 3 y prioriza la señal reciente. Los pesos se renormalizan por su media para que el aprendizaje permanezca a escala unitaria.

Figura 3

Distribución de la variable objetivo. El desbalance hacia la clase Local motiva la ponderación `class_weight= balanced`



Modelado

El problema se formula como clasificación multiclase a nivel de partido $\{H, E, V\}$. Se entrenan tres modelos: Regresión Logística multinomial (*baseline*, con *StandardScaler*), *XGBoost* (*multi:softprob*) y *LightGBM*. La búsqueda de hiperparámetros emplea Optuna (Transfermarkt, 2026) con 100 trials y *TimeSeriesSplit*($n = 5$) interno sobre el conjunto de entrenamiento, optimizando *neg_log_loss*; admite paralelización opcional de trials (*-n-jobs*), con valor por defecto en serie para garantizar reproducibilidad bit a bit del TPE. La Figura 5 resume la importancia SHAP agregada (*mean |SHAP|*) y muestra que *elo_diff* domina ($\approx 1,48$), seguido de forma notable por *striker_concentration_diff* ($\approx 0,36$) y *ranking_diff* ($\approx 0,25$). La concentración de goleadores, derivada de los datos de eventos, captura un eje (estructura del ataque) ortogonal al nivel del equipo. Las *features* de *xG* y *penalty_share_diff* forman un tercer nivel ($\approx 0,10-0,12$), mientras que *shootout_winrate_diff*, *squad_value_diff* y *travel_distance_diff* aportan marginalmente ($\approx 0,09, 0,04$ y $0,03$, respectivamente).

División temporal del dataset

Se evita rigurosamente el data leakage mediante un split estrictamente temporal (Tabla 3). La calibración Platt (sigmoid) del *XGBoost* se ajusta sobre la franja 2021 (validación) para no contaminar el conjunto de prueba. El método sigmoid es más estable que el isotónico cuando el conjunto de validación es pequeño (un año de datos, tres clases), evitando sobreajuste en la curva de calibración.

Recorte mínimo

El entrenamiento usa partidos con $\text{date} \geq 2010$, aunque *features.csv* contiene datos desde 1993. Los *features* estáticos (*xG*, valor de plantilla, ranking moderno) no son representativos del fútbol pre-2010, y el *time_decay* con $\lambda = 0,001$ ya reduce el peso de esos partidos a menos del 2 %. El ELO sigue calculándose sobre el histórico completo para mayor precisión.

Tabla 3

Slipt temporal y uso de cada conjunto

Conjunto	Filtro	Uso
Train	<code>date < 2021-01-01</code>	LogReg, XGBoost, LightGBM
Validación	<code>2021-01-01 ≤ date < 2022-01-01</code>	Calibración Platt (sigmoid)
Test	<code>date ≥ 2022-01-01</code>	Evaluación final

Doble pipeline

Para validar el Mundial 2022 sin *leakage* se reejecuta el entrenamiento con *cutoff = 2022-01-01*, produciendo *xgboost_pre2022.joblib*. Cuando este *cutoff* vacía el conjunto de validación temporal, se activa un *fallback* 85/15 que reserva el último 15 % temporal del train para la calibración.

Motor de simulación del torneo

El motor (*src/simulation/*) ejecuta $N = 10,000$ realizaciones del torneo completo ($104 \text{ partidos} \times N = 1,04 \times 10^6$ partidos simulados). Cada partido i, j pasa por las siguientes etapas:

1. Probabilidades simétricas. Salvo cuando uno de los equipos es anfitrión jugando en su país, se promedia $P(i \text{ vs } j)$ con la inversión de $P(j \text{ vs } i)$ para eliminar el sesgo *home/away* heredado del *dataset*.
2. Marcador y *outcome*. El *outcome* $\{H, E, V\}$ se sortea con las probabilidades del modelo. En fase de grupos se generan goles $g_i \sim \text{Poisson}(\mu_i)$, $g_j \sim \text{Poisson}(\mu_j)$ con μ basado en *xG* a favor/en contra, y el marcador se ajusta para ser coherente con el *outcome* (desempates por DG/GF).
3. Fase de grupos. 12 grupos de 4; clasifican los dos primeros más los 8 mejores terceros, con desempates, puntos, diferencia de goles, goles a favor según el reglamento FIFA 2026 (FIFA, 2026).

4. Eliminatorias. Round of 32 Round of 16 Round, Cuartos, Semifinales, Final. Si hay empate tras los 90, la definición por penales se modela como Bernoulli(0,5).

Se contabilizan, porequipo, las veces que alcanza cada ronda y los intervalos de confianza al 95 % se calculan con el método binomial exacto de Clopper–Pearson (C. J. Clopper and E. S. Pearson, 1934) vía `scipy.stats.beta`. Las N iteraciones, independientes entre sí, se reparten en bloques fijos ejecutados en paralelo (`joblib`); cada bloque usa un `stream RNG` propio derivado de `SeedSequence(seed).spawn`, de modo que el resultado es idéntico con cualquier número de workers (reproducibili-dad independiente del paralelismo).

Figura 4

Evolución del rating ELO para cinco selecciones representativas a lo largo de cuatro décadas.





Figura 5

Resumen SHAP agregado (mean |SHAP|) del XGBoost. elo_diff domina la contribución, con striker_concentration_diff en segundo lugar y ranking_diff en tercero



DISCUSIÓN

Evaluación

Se reportan *Log-Loss* y *Brier score* sobre el conjunto de prueba (date $\geq$ 2022). Se evita accuracy por ser inadecuada para predicciones probabilísticas desbalanceadas (G. W. Brier, 1950). Nota metodológica sobre el Brier. El valor reportado es el promedio de los tres scores binarios one-vs-rest (cada clase $\{H, E, V\}$ contra el resto), de modo que se sitúa en el rango $[0, 1]$ y no en la formulación multiclase de suma de diferencias cuadráticas (rango $[0, 2]$). Ambas medidas son equivalentes salvo un factor: el Brier de suma multiclase es K veces el promediado, con $K = 3$ clases; así, el ,166 reportado corresponde a ,499 en la escala $[0, 2]$. La Tabla 4 muestra que *XGBoost* calibrado es el mejor modelo en ambas métricas el único que supera a todos los demás simultáneamente en *Log-Loss* y *Brier*. La calibración Platt sobre datos de validación 2021 corrige la sobreconfianza del *XGBoost* base sin degradar su discriminación (*Log-Loss* ,866 ,855). El *XGBoost* sin calibrar supera a *LightGBM*, y *LogReg* queda en último lugar pese al rebalanceo de clases y el *time decay*.

Tabla 4

Métricas de evaluación sobre test temporal ($\geq$ 2022)

Modelo	Log-Loss ↓	Brier ↓
XGBoost-Cal	,8547	,1662
XGBoost	,8657	,1701
LightGBM	,8713	,1717
LogReg	,8832	,1728

Estudio de ablandación

Para cuantificar la contribución marginal de cada grupo de features se reentrena el *XGBoost* calibrado manteniendo fijos el split temporal, los pesos (time decay + balanced) y los hiperparámetros óptimos; lo único que varía entre filas es el conjunto de features. La Tabla 5 muestra que el grupo de mayor aporte son las features estáticas (xG + valor de plantilla, $\Delta LL = +0,0041$ al retirarlas) seguido de las features derivadas de eventos (+0,0035, impulsado sobre todo por striker_concentration_diff). Las features de aporte marginal (travel_distance_diff, penalty_share_diff y shootout_winrate_diff) se documentan con filas propias: sus Δ caen dentro del ruido de una sola corrida ($|\Delta LL| \leq 0,0008$). En particular, penalty_share_diff muestra un Δ ligeramente negativo,

indistinguible de cero. Una cuarta feature derivada evaluada (late_goal_ratio, proporción de goles tardíos) se descartó por completo del modelo: su ablación leave-one-out mostró aporte negativo (ruido neto, el modelo mejora sin ella).

Tabla 5

Ablación de Features (XGBOOST CALIBRADO, TEST ≥2022)

Configuración	Log-Loss	Brier	ΔLL	ΔBrier
Completo (9 feat.)	,8547	,1662	—	—
Sin xG	,8587	,1670	+0,0040	+0,0008
Sin squad_value	,8553	,1664	+0,0006	+0,0002
Sin derivadas	,8582	,1668	+0,0035	+0,0006
Sin travel_distance	,8548	,1663	+0,0001	+0,0001
Sin penalty_share	,8542	,1661	-0,0005	-0,0001
Sin shootout	,8555	,1664	+0,0008	+0,0002
Sin estáticas (xG+squad)	,8588	,1670	+0,0041	+0,0008

Validación histórica

El modelo xgboost_pre2022 (entrenado exclusivamente con date<2022-01-01) se evaluó sobre los partidos del Mundial 2022, sirviendo como prueba out-of-time sin contaminación. Los resultados numéricos se imprimen en consola al ejecutar make evaluate.

RESULTADOS DE LA SIMULACIÓN

La Tabla 6 lista el Top-10 de candidatos al título y la Tabla 7 resume la progresión por fase de los tres anfitriones, ambos con intervalos Clopper–Pearson al 95 %.

Análisis de sensibilidad a lesiones

Aunque las lesiones no se modelan estructuralmente, el script src/analysis/sensitivity.py aplica una perturbación de -30 % sobre squad_value para cada equipo del top-5 y reejecuta la simulación. La Tabla 8 muestra que el efecto es modesto ($|\Delta| \leq ,40$ pp en todos los casos), siempre en la dirección esperada (reducción de la probabilidad de título).

Esto es coherente con la importancia SHAP: squad_value_diff ocupa una de las últimas posiciones (Figura 5), muy por debajo de elo_diff y de las features de estructura del ataque.

Limitaciones

El modelo presenta cinco limitaciones reconocidas:

1. Debutantes. Equipos como Uzbekistán, Curazao o Cabo Verde tienen historial internacional escaso; su ELO se

Tabla 6

Top-10 candidatos a campeón (10 000 iteraciones)

Equipo	P(Campeón)	IC 95 %
España	23,72 %	[22,89, 24,57]
Argentina	11,27 %	[10,66, 11,91]
Francia	10,88 %	[10,28, 11,51]
Brasil	6,35 %	[5,88, 6,85]
Inglaterra	5,55 %	[5,11, 6,02]
Marruecos	4,51 %	[4,11, 4,94]
Alemania	4,18 %	[3,80, 4,59]
México	4,06 %	[3,68, 4,47]
Colombia	3,61 %	[3,25, 3,99]
Países Bajos	3,48 %	[3,13, 3,86]

Tabla 7

Progresión por fase de los anfitriones (% , IC 95 %).

Fase	México	EE.UU.	Canadá
Round of 32	94,5	66,3	96,5
Round of 16	63,3	30,3	53,6
Cuartos	33,5	16,9	25,8
Semifinales	18,4	7,7	11,7
Final	9,4	2,9	5,0
Campeón	4,1	1,1	1,9

Tabla 8

Top 10 candidatos a campeon (10000 iteraciones).

Equipo	Base %	Lesión %	Δ pp
España	23,72	23,38	-0,34
Argentina	11,27	10,87	-0,40
Francia	10,88	10,57	-0,31
Brasil	6,35	6,17	-0,18
Inglaterra	5,55	5,34	-0,21

inicializa con el valor neutro 1500 y converge lentamente, lo que probablemente infla su probabilidad relativa frente a rivales subestimados de la misma confederación.

2. Cobertura xG. El open data de StatsBomb [15] privilegia torneos UEFA/CONMEBOL; las selecciones de AFC, CAF y CONCACAF reciben un xG por defecto de 1,2, que es la media global. Esto subestima la varianza inter-equipos en estas confederaciones.

3. Features estáticas anacrónicas. El xG y el valor de plantilla son snapshots (un valor por equipo, sin fecha) aplicados a todos los partidos históricos, lo que introduce un anacronismo/leakage. No existe serie temporal histórica de estos datos, así que versionarlos sería fabricar información; el efecto se acota con el time decay ($< 2\%$ pre-2010), el recorte a $\text{date} \geq 2010$ y el uso de diffs relativos, y se cuantifica en la fila “Sin estáticas” de la Tabla V. El valor de Transfermarkt es además una fotografía manual (no live scraping).
4. Cobertura de travel_distance_diff. Las coordenadas solo están precargadas para los 48 equipos del Mundial; los partidos históricos entre otros equipos quedan en 0 (82,5 % del dataset). La feature ya no se anula en sedes neutrales, corrige el caso de los Mundiales y en la simulación (host_distance) está 100 % poblada.
5. Lesiones de última hora. No hay modelado estructural de bajas individuales; el sensitivity.py es únicamente un stress test agregado sobre squad_value. Una baja clave en una posición específica (e.g., portero titular) tiene un impacto que el modelo no puede capturar.

Reproducibilidad

El repositorio mantiene una arquitectura modular bajo src/ (data/, features/, models/, simulation/, analysis/, visualization/). Los CSVs versionables se producen en data/processed/ y las figuras en reports/figures/. Toda la cadena se reproduce con:

```
pip install -e .
```

```
make all # features -> train -> evaluate # -> simulate -> sensitivity
```

```
streamlit run \src\visualization\dashboard.py
```

La cobertura de pruebas (pytest tests/ -v) valida la mecánica del ELO, la lógica de desempates de grupos y el muestreo Poisson de goles.

CONCLUSIONES

Se ha presentado un sistema reproducible para predecir la Copa Mundial 2026 que cumple con los requisitos planteados: múltiples fuentes limpias, nueve características justificadas por EDA y SHAP –tres de ellas derivadas de datos de eventos y calculadas as-of-date–, benchmark

de cuatro modelos con calibración Platt sobre validación temporal y un motor Monte Carlo de 10,000 iteraciones fiel al nuevo reglamento. El XGBoost calibrado logra Log-Loss de ,855 y Brier de ,166 — mejor en ambas métricas simultáneamente. Más allá del núcleo elo_diff/ranking_diff, el hallazgo más relevante es que striker_concentration_diff (estructura del ataque) es la segunda feature más informativa. Las simulaciones ubican a España (23,7 %), Argentina (11,3 %) y Francia (10,9 %) como principales favoritas; los tres anfitriones alcanzan probabilidades de título entre 1,1 % y 4,1 %, con ventaja de local coherente en rondas iniciales pero convergencia en etapas avanzadas.

Trabajo futuro

1. Incorporar un modelo Dixon–Coles (M.J. Dixon and S.G. Coles, 1997) para los marcadores en lugar de Poisson independiente.
2. Reemplazar el snapshot Transfermarkt por un scraper programado y versionar xG/valor de plantilla por temporada para eliminar el anacronismo.
3. Escalar a 105–106 iteraciones mediante vectorización completa del bucle Monte Carlo (ya paralelizado con joblib); y (iv) modelar lesiones a nivel de jugador integrando features de minutos disputados y posición.

Disponibilidad de código y recursos

El código fuente, los scripts de entrenamiento, los datos procesados y los experimentos necesarios para reproducir los resultados de este estudio se encuentran disponibles públicamente en (D. Deras, 2026). Asimismo, se proporciona un dashboard interactivo para la exploración de resultados y simulaciones mediante (D. Deras, 2026).

REFERENCIAS

- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A next-generation hyperparameter optimization framework. Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2623–2631. <https://doi.org/10.1145/3292500.3330701>
- Brier, G. W. (1950). Verification of forecasts expressed in terms of probability. Monthly Weather Review, 78(1), 1–3. [https://doi.org/10.1175/1520-0493\(1950\)078%3C0001:VOFEIT%3E2.0.CO;2](https://doi.org/10.1175/1520-0493(1950)078%3C0001:VOFEIT%3E2.0.CO;2)
- Cashncarry. (2023). FIFA world ranking 1993–2023 [Data set].

- Kaggle. <https://www.kaggle.com/datasets/cashncarry/fifaworlddrinking>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>
- Clopper, C. J., & Pearson, E. S. (1934). The use of confidence or fiducial limits illustrated in the case of the binomial. *Biometrika*, 26(4), 404–413. <https://doi.org/10.1093/biomet/26.4.404>
- Deras, D. (2026a). Predictions—World Cup 2026 [Computer software]. GitHub. <https://github.com/daiv05/fifa-world-cup-model>
- Deras, D. (2026b). Predictions—World Cup 2026 [Computer application]. Streamlit. <https://fifa-world-cup-model.streamlit.app/>
- Dixon, M. J., & Coles, S. G. (1997). Modelling association football scores and inefficiencies in the football betting market. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 46(2), 265–280. <https://doi.org/10.1111/1467-9876.00065>
- Elo, A. E. (1978). *The rating of chessplayers, past and present*. Arco Publishing.
- FIFA. (2023). FIFA World Cup 2026 competition format and regulations. <https://www.fifa.com/fifaplus/en/tournaments/mens/worldcup/canadamexicousa2026>
- Groll, A., Ley, C., Schauburger, G., & Van Eetvelde, H. (2019). A hybrid random forest to predict soccer matches in international tournaments. *Journal of Quantitative Analysis in Sports*, 15(4), 271–287. <https://doi.org/10.1515/jqas-2018-0060>
- Jürisoo, M. (2026a). International football results from 1872 to 2026 (results, goalscorers, shootouts, former_names) [Data set]. GitHub. https://github.com/martj42/international_results
- Jürisoo, M. (2026b). International football results from 1872 to 2017 [Data set]. Kaggle. <https://www.kaggle.com/datasets/martj42/international-football-results-from-1872-to-2017>
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems*, 30, 3146–3154.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774.
- Maher, M. J. (1982). Modelling association football scores. *Statistica Neerlandica*, 36(3), 109–118. <https://doi.org/10.1111/j.1467-9574.1982.tb00782.x>
- Niculescu-Mizil, A., & Caruana, R. (2005). Predicting good probabilities with supervised learning. *Proceedings of the 22nd International Conference on Machine Learning*, 625–632. <https://doi.org/10.1145/1102351.1102430>
- Platt, J. C. (1999). Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. In A. J. Smola, P. Bartlett, B. Schölkopf, & D. Schuurmans (Eds.), *Advances in large margin classifiers* (pp. 61–74). MIT Press.
- StatsBomb. (2024). StatsBomb open data [Data set]. GitHub. <https://github.com/statsbomb/open-data>
- Transfermarkt. (2026). National teams market values [Data set]. <https://www.transfermarkt.com>

Aplicación de Inteligencia Artificial para la identificación de minerales usando imágenes de láminas delgadas

Application of Artificial Intelligence for Mineral Identification Using Thin-Section Images

Sofia Martínez¹, Jose Osorio¹, Balmore Quintanilla¹,
Bladimir Diaz^{1,2}, Nelly Henriquez¹

1 Facultad de Ingeniería y Arquitectura, Universidad de El Salvador

2  <https://orcid.org/0009-0007-3328-5179>

Correspondencia: ✉ bladimir.diaz@ues.edu.sv

Enviado: 20 de mayo de 2026 Aceptado: 30 de junio de 2026

DOI: <https://doi.org/10.66778/CTI.v02n01.02>

PALABRAS CLAVE

Transferencia de Aprendizaje
ResNet50
Hiperparámetros.

RESUMEN

Este trabajo presenta un enfoque de procesamiento de imágenes para la clasificación automatizada de minerales a partir de imágenes microscópicas, una tarea importante para aplicaciones geológicas y mineras. El método propuesto emplea la arquitectura *ResNet50* dentro de un esquema de transferencia de aprendizaje, optimizada mediante una búsqueda rigurosa de hiperparámetros. El modelo final, entrenado con un tamaño de lote de ocho y una regularización L2 de 1.0×10^{-5} , obtuvo una pérdida de validación de 0.0447 y una precisión de validación del 98.35% en diez clases de minerales. Estos resultados evidencian una capacidad de generalización superior respecto a los modelos base, posicionando al clasificador propuesto como una herramienta confiable para el análisis de muestras de minerales de rocas ígneas en laboratorio.

KEYWORDS

Transfer learning
ResNet50
Hyperparameters.

ABSTRACT

This article presents a computer vision approach for the automated classification of minerals from microscopic images, a task of significant relevance in geological and mining applications. The proposed method employs the *ResNet50* architecture within a Transfer Learning framework and is optimized through a rigorous hyperparameter search. The final model, trained using a batch size of 8 and an L2 regularization factor of 1.0×10^{-5} , achieved a validation loss of 0.0447 and a validation accuracy of 98.35% across ten mineral classes. The results indicate a superior generalization capability compared to baseline models, establishing the proposed classifier as a reliable tool for laboratory sample analysis.



INTRODUCCIÓN

La aplicación de inteligencia artificial (IA) en la clasificación automática de imágenes ha demostrado avances significativos en medicina, agricultura y teledetección geológica. En medicina, las redes neuronales convolucionales (CNN) han optimizado el análisis de imágenes radiográficas y tomográficas, incrementando la precisión diagnóstica (Esteve et al., 2017). En agricultura, estas técnicas han facilitado la detección temprana de plagas y deficiencias nutricionales, mejorando la eficiencia en el uso de recursos (Kamilaris & Prenafeta-Boldú, 2018).

En el ámbito de las geociencias, la IA se ha utilizado para tareas como el mapeo litológico y la clasificación de materiales a partir de imágenes y datos de teledetección, mostrando su capacidad para aprender patrones complejos y escalar a grandes volúmenes de información (Jahoda et al., 2020). En mineralogía óptica, el uso de CNN aún se encuentra en una etapa incipiente; sin embargo, estudios recientes demuestran su potencial para reconocer especies minerales a partir de microfotografías, logrando niveles de precisión competitivos frente a la clasificación manual (Khauleque et al., 2022; Hwang et al., 2021). Sin embargo, gran parte de la literatura reporta conjuntos de datos limitados o condiciones de captura poco representativas, por lo que resulta necesario avanzar hacia escenarios petrográficos más cercanos al trabajo rutinario de laboratorio.

En conjunto, la integración de CNN como apoyo a la metodología petrográfica tradicional ofrece ventajas como la automatización parcial del proceso, mayor consistencia en los resultados, detección de patrones sutiles y escalabilidad para el análisis de grandes volúmenes de muestras, particularmente en contextos donde la disponibilidad de personal especializado y el tiempo de análisis son limitantes.

El presente trabajo desarrolla un modelo de clasificación automática de minerales a partir de imágenes microscópicas de láminas delgadas, utilizando redes neuronales convolucionales (RNC) como herramienta principal de análisis. El enfoque se centra en la identificación de un conjunto definido de minerales representativos en rocas ígneas, empleando una arquitectura de aprendizaje profundo basada en transferencia de aprendizaje, entrenada y ajustada a partir de microfotografías petrográficas. Mediante este esquema se evalúa la capacidad de las RNC para reconocer patrones ópticos característicos de los minerales y apoyar el análisis petrográfico tradicional con un método reproducible, eficiente y alineado con las condiciones de laboratorio.

METODOLOGÍA

Conjunto de Datos

La base de datos está conformada por microfotografías petrográficas obtenidas a partir de láminas delgadas, preparadas con un grosor aproximado de 30 μm para permitir el paso de la luz y la observación bajo microscopía petrográfica. Considerando el contexto geológico de El Salvador —dominado por rocas ígneas asociadas al Arco Volcánico Centroamericano— el estudio se acotó a minerales frecuentes y representativos de rocas máficas e intermedias (p. ej., basaltos y andesitas), ampliamente distribuidas en todo el territorio de El Salvador (Lexa, Halouzka & Martí, 2011; Montalvo & Martí, 2013).

Se utilizaron diez tipos de minerales y litotipos de referencia: anfíbol, biotita, moscovita, cuarzo, biotita de grano grueso, piroxenos, olivino, augita-andesita y cuarzo porfirita. Para la evaluación del desempeño, se reservó un subconjunto de 484 imágenes para validación y prueba final. Con el fin de mitigar el sobreajuste y aumentar la variabilidad del conjunto de entrenamiento, se aplicaron técnicas de aumento de datos (data augmentation) sobre las imágenes.

Arquitectura y estrategia de entrenamiento

Modelo base: *ResNet50* pre-entrenado en ImageNet. La arquitectura *ResNet50* es robusta y con gran capacidad de generalización, especialmente si se combina con estrategias de control del entrenamiento como *EarlyStopping*, *ModelCheckpoint* y *ReduceLROnPlateau*, permitiendo obtener un modelo más estable y eficiente. Esta se atribuye principalmente a la incorporación de bloques residuales en *ResNet50*, los cuales facilitan la propagación del gradiente y mitigan el problema del desvanecimiento del gradiente, permitiendo entrenar redes más profundas de manera efectiva.

Fase 1 Transferencia de Aprendizaje: Las capas convolucionales de *ResNet50* fueron congeladas. Se adjuntó una nueva cabeza de clasificación (capas densas) y se entrenó con un Tasa de Aprendizaje estándar.

Búsqueda de hiperparámetros clave: Se evaluó el impacto de la regularización L2 y el tamaño de *Batch*. La configuración óptima identificada fue:

- Regularización L2: 1.0×10^{-5} (Crucial para reducir el sobreajuste)
- Tamaño del *batch*: 8 (Permitiendo ajustes de gradiente más finos).

Fase 2 Ajuste fino: Se descongelaron las capas convolucionales de *ResNet50*. El modelo se reentrenó con un LR extremadamente bajo (5.0×10^{-5}), asegurando que los pesos pre-entrenados fueran ajustados sutilmente hacia las características de los minerales.

Optimización: Se utilizaron funciones de retorno de *EarlyStopping* y *ModelCheckpoint* (monitoreando la *val_loss*) para detener el entrenamiento en el punto de máxima generalización.

RESULTADOS

Desempeño general

Los resultados obtenidos confirman que la inteligencia artificial constituye una herramienta viable para apoyar el análisis petrográfico, ya que el modelo basado en redes neuronales convolucionales alcanzó una precisión superior al 98% en validación. Este desempeño resalta la relevancia de la calidad del conjunto de datos y de las estrategias de preprocesamiento y normalización de imágenes, las cuales contribuyeron a reducir el impacto de variaciones en iluminación, enfoque y condiciones de captura. Asimismo, la comparación entre arquitecturas evidenció que *ResNet50* superó a *VGG16* en términos de robustez y capacidad de generalización, atribuible a la presencia de bloques residuales que mitigan el problema del desvanecimiento del gradiente.

En conjunto, estos resultados son consistentes con estudios previos en visión por computadora aplicada a geociencias y refuerzan el potencial de las arquitecturas profundas para identificar patrones ópticos complejos de manera confiable. El modelo desarrollado no pretende sustituir el análisis petrográfico convencional, sino complementarlo mediante un enfoque reproducible, eficiente y adecuado para el análisis de grandes volúmenes de muestras.

Impacto de hiperparámetros

Durante el proceso de entrenamiento se evaluó el impacto del tamaño de lote (*batch size*) sobre el desempeño y la capacidad de generalización del modelo. El *batch size* corresponde al número de muestras procesadas por la red neuronal antes de realizar una actualización de los pesos, y constituye un hiperparámetro clave que influye directamente en la estabilidad del gradiente, la velocidad de convergencia y la calidad de la solución alcanzada.

Los resultados obtenidos muestran que el tamaño de lote tuvo un efecto significativo en la pérdida de validación (*val_loss*) y en el comportamiento del ajuste fino del modelo

cuadro de resultados. En particular, los tamaños de lote pequeños favorecieron una mejor generalización, mientras que valores mayores condujeron a un deterioro progresivo del desempeño.

Tabla 1

Cuadro de resultados

Batch Size	Fase	Mejor val_loss (Mín.)	Mejor val_accuracy (Máx.)
8	Fase 2 (Ajuste Fino)	0.04467	0.9835
16	Fase 2 (Ajuste Fino)	0.09926	0.9897
16	Fase 1 (Transferencia)	0.10034	0.9876
32	Fase 1 (Transferencia)	0.13363	0.9876
64	Fase 2 (Ajuste Fino)	0.14203	0.9793
128	Fase 2 (Ajuste Fino)	0.14829	0.9793

Entre las configuraciones evaluadas, el *batch size* de 8 produjo el modelo más robusto, alcanzando la menor pérdida de validación registrada (*val_loss* = 0.0447) durante la fase de ajuste fino (*fine-tuning*). Este resultado indica una mayor confiabilidad en las predicciones y una menor incertidumbre en la clasificación de muestras no observadas. Si bien un *batch size* de 16 permitió alcanzar la mayor precisión de validación, su pérdida de validación fue superior, lo que sugiere relación entre exactitud y capacidad de generalización.

En contraste, tamaños de lote mayores (32, 64 y 128) mostraron un desempeño inferior, ya que el ajuste fino no mejoró los resultados obtenidos durante la fase de transferencia de aprendizaje, evidenciando una tendencia a converger hacia mínimos locales subóptimos y una menor robustez del modelo.

Figura 1

Gráficas que representan los resultados con tamaño de lote 8





Figura 2

Gráficas que representan los resultados con tamaño de lote 16




La imagen muestra que, en el gráfico de la izquierda, la pérdida disminuye rápidamente durante las primeras épocas de entrenamiento. La pérdida de validación (línea azul) se mantiene estable y alcanza su valor mínimo después del inicio del Ajuste Fino, señalado con la línea verde punteada.

En el gráfico de la derecha, la imagen muestra que la precisión de entrenamiento y validación aumenta rápidamente durante las primeras épocas, superando el 95 %. Posteriormente, la precisión de validación se mantiene cercana al 99 % durante la Fase 2.

Figura 3

Gráficas que representan los resultados con tamaño de lote 32




La imagen muestra un comportamiento similar al observado con el *Batch Size* 8, aunque con una fase de preentrenamiento más prolongada. La pérdida de validación se mantiene cercana a 0.1 y presenta un comportamiento estable durante el entrenamiento.

Por su parte, la precisión aumenta progresivamente hasta alcanzar valores cercanos al 99 % durante la Fase 2, evidenciando un buen desempeño del modelo con un *Batch Size* de 16.

Figura 4


Gráficas que representan los resultados con tamaño de lote 64



La imagen muestra que la pérdida de validación (*val_loss*, línea azul) alcanza su valor más bajo durante la Fase 1. Después del inicio del Ajuste Fino, indicado por la línea verde punteada, la pérdida de validación presenta un ligero aumento y se mantiene por encima de su mínimo anterior.

Figura 5


Gráficas que representan los resultados con tamaño de lote 108



La imagen muestra una mayor diferencia entre la pérdida de entrenamiento y la pérdida de validación. Además, la pérdida de validación se estabiliza en un valor más alto, lo que indica que, con esta configuración, el modelo presenta un menor desempeño de generalización sobre los datos de validación.

Figura 6

Matriz de confusión



El análisis de la matriz de confusión (Figura 6) reveló que la mayoría de las clasificaciones incorrectas (errores) se concentran en un número muy limitado de pares de clases con similitudes texturales o de coloración.

DISCUSIÓN

La métrica F1-Score ponderada (*Weighted Avg F1-Score*) de 0.9835 es la más significativa, ya que proporciona una media balanceada entre la Precision y el Recall, ajustada por el soporte de cada clase. Un valor tan cercano a 1.00 valida la alta calidad del modelo en todas las categorías, incluso aquellas con menor representación muestral.

Aciertos perfectos, F1-Score=1.0000: Cinco de las diez clases (GRANITO, GRANITO PORFIRITICO, CUARZO, OLIVINO y PIROXENO) alcanzaron un F1-Score perfecto. Esto indica que el modelo no cometió ningún falso positivo ni falso negativo en estas categorías, demostrando que sus características visuales son altamente distintivas.

Alto Recall (Evitando falsos negativos): La capacidad del modelo para identificar correctamente las instancias de cada mineral es sobresaliente. La mayoría de las clases tienen un *Recall* de 1.0000 o muy cercano, incluyendo MOSCOVITA 1.0000 y ANFIBOL 0.9826. Esto minimiza el riesgo de que el modelo pierda o no reconozca un mineral que está presente en la imagen.

Áreas de fricción (Mayor interés científico): Los errores

mínimos se concentran en las siguientes clases:

- BIOTITA (*Recall*=0.9583): Es la clase con el *Recall* más bajo. Esto sugiere que de los 24 casos reales de Biotita en la validación, el modelo no pudo identificar 1 o 2 de ellos. Estos errores son críticos, ya que representan la tendencia del modelo a confundir la Biotita con otra clase (Falso Negativo).
- CUARZO PORFIRITICO (*Precision*=0.9400): Es la clase con la *Precision* más baja. Esto indica que cuando el modelo predijo CUARZO PORFIRITICO, aproximadamente el 6% de esas predicciones fueron incorrectas (es decir, eran otro mineral que fue clasificado erróneamente como CUARZO PORFIRITICO).

Estos puntos de fricción sugieren una similitud textural o composicional entre estas clases y el mineral al que están siendo confundidas, lo que justifica la necesidad de la fase de *Fine-Tuning* a baja LR.

LIMITACIONES

- Dependencia de la calidad y cantidad de datos disponibles para el entrenamiento del modelo.
- Posibles sesgos en los datos que pueden afectar la precisión del modelo.
- Limitaciones en la generalización del modelo a diferentes tipos de rocas y minerales no incluidos en el conjunto de datos.
- Complejidad de las propiedades ópticas: algunos minerales pueden presentar características muy similares en color, birrefringencia y textura, lo que dificulta su clasificación precisa.

Dependencia del entrenamiento y de la representatividad de las muestras incluidas en el conjunto de datos, restringido únicamente a rocas ígneas.

CONCLUSIONES

Se ha desarrollado un clasificador de minerales robusto y de alto rendimiento utilizando transferencia de aprendizaje con *ResNet50*. La optimización de los hiperparámetros, en particular la regularización y el *Batch Size*, condujo a un modelo con una pérdida de validación sin precedentes (0.0447) y una precisión de 98.35%. Este desempeño confirma que el modelo es altamente fiable y generaliza de manera excepcional a nuevos datos de minerales, superando los desafíos de sobreajuste comúnmente asociados con

TRABAJOS FUTUROS

El éxito de este modelo abre varias vías para la investigación futura:

1. Expansión de clases: Integrar otros minerales, utilizando este modelo como base para una fase incremental de entrenamiento.
2. Pruebas de campo: Evaluar el rendimiento del modelo en imágenes capturadas bajo condiciones menos controladas (datos de campo) para probar su resiliencia ante variaciones de iluminación.
3. Segmentación: Explorar la integración de modelos de segmentación para no solo clasificar, sino también localizar y delimitar áreas específicas de un mineral dentro de la imagen para un análisis más limpio, mejorando aún más la precisión

BIBLIOGRAFIA

- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, 147, 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Jahoda, R., Moudrý, V., & Müllerová, J. (2020). Deep learning for lithological mapping using remote sensing data. *Remote Sensing*, 12(10), 1620. <https://doi.org/10.3390/rs12101620>
- Khaleque, A., Baran, R., & Islam, M. (2022). Deep learning-based mineral identification from petrographic images. *Applied Computing and Geosciences*, 14, 100084. <https://doi.org/10.1016/j.acags.2022.100084>
- Hwang, J., Kim, H., & Lee, S. (2021). Automatic mineral classification using convolutional neural networks on petrographic thin-section images. *Computers & Geosciences*, 157, 104921. <https://doi.org/10.1016/j.cageo.2021.104921>
- Lexa, J., Halouzka, R., & Martí, J. (2011). Volcanic evolution of the Central American Volcanic Arc. *Geological Society, London, Special Publications*, 361(1), 1–27. <https://doi.org/10.1144/SP361.1>

Montalvo, C., & Martí, J. (2013). Geological evolution of El Salvador volcanic regions. *Journal of Volcanology and Geothermal Research*, 258, 1–15. <https://doi.org/10.1016/j.jvolgeores.2013.03.012>

He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>

Optimización de la predicción de retención estudiantil en la educación superior: un análisis comparativo de modelos de aprendizaje automático supervisados y no supervisado

Optimizing student retention prediction in higher education: A comparative analysis of supervised and unsupervised machine learning models

Franklin Ivan Argueta Bermudez^{1,2}, Wilber Alexander Ortiz Cortez¹, Miguel García Torres¹

- 1 Facultad de Ingeniería y Arquitectura, Universidad de El Salvador
- 2 Escuela Politécnica Superior, España, Universidad Pablo de Olavide
- 3  <https://orcid.org/0000-0002-7463-9873>

Correspondencia:  fivan.bermudez@gmail.com
Enviado: 20 de mayo de 2026 Aceptado: 30 de mayo de 2026

DOI: <https://doi.org/10.66778/CTI.v02n01.03>

PALABRAS CLAVE

Retención estudiantil,
deserción,
Machine Learning,
educación superior,
modelos predictivos.

RESUMEN

Esta investigación aborda el problema de la deserción estudiantil en la educación superior en El Salvador, utilizando modelos de aprendizaje automático. Para ello, se empleó un conjunto de datos históricos proveniente de una universidad privada, que incluye más de 83,000 registros de estudiantes entre los años 2019 y 2024. En la fase de análisis exploratorio, se aplicaron técnicas no supervisadas como Análisis de Componentes Principales (PCA), K-means y agrupamiento jerárquico, con el objetivo de segmentar a los estudiantes e identificar perfiles con características demográficas, académicas y económicas similares. Posteriormente, se implementaron modelos predictivos supervisados, entre ellos SVM, KNN, Random Forest, AdaBoost y XGBoost, evaluando su rendimiento mediante métricas como precisión y AUC-ROC. Los resultados indicaron que Random Forest ofrece una mayor capacidad predictiva, mientras que las técnicas de clusterización permitieron identificar grupos de riesgo sin necesidad de etiquetas previas. Se observó que los estudiantes en modalidad presencial, con bajo rendimiento académico y autofinanciamiento, presentan una mayor probabilidad de abandono. La investigación concluye que la combinación de análisis exploratorio y modelos predictivos facilita el diseño de estrategias efectivas para mejorar la retención estudiantil. Además, se destaca el valor del uso institucional de estas herramientas para desarrollar intervenciones proactivas, especialmente dirigidas a estudiantes de primer año o con condiciones académicas y económicas vulnerables.

KEYWORDS

Student retention,
dropout rate,
machine learning,
higher education,
predictive models.

ABSTRACT

This research addresses the problem of student dropout in higher education in El Salvador, using machine learning models. To do so, a historical dataset from a private university was used, which includes more than 83,000 student records between the years 2019 and 2024. In the exploratory analysis phase, unsupervised techniques such as Principal Component Analysis (PCA), K-means, and hierarchical clustering were applied to segment students and identify profiles with similar demographic, academic, and economic characteristics. Subsequently, supervised predictive models were implemented, including SVM, KNN, Random Forest, AdaBoost, and XGBoost, evaluating their performance using metrics such as accuracy and AUC-ROC.

The results indicated that Random Forest offers greater predictive capacity, while clustering techniques allowed identifying risk groups without the need for prior labels. It was observed that students enrolled in in-person classes, with low academic performance and self-funded programs, are more likely to drop out. The research concludes that the combination of exploratory analysis and predictive models facilitates the design of effective strategies to improve student retention. Furthermore, it highlights the value of institutional use of these tools to develop proactive interventions, especially those targeting first-year students or those with vulnerable academic and economic circumstances.



INTRODUCCIÓN

La educación superior desempeña un papel estratégico en el desarrollo económico, social y cultural de los países. Factores como el acceso, la permanencia y la finalización oportuna de los estudios universitarios son fundamentales para formar profesionales que contribuyan al progreso de sus comunidades. No obstante, la deserción estudiantil continúa siendo uno de los desafíos más persistentes en las instituciones de educación superior, generando impactos negativos a nivel individual, institucional y social. En el caso de El Salvador, este fenómeno se ha ido normalizando debido a las desigualdades socioeconómicas, la limitada disponibilidad de recursos educativos y en su momento las secuelas dejadas por la pandemia de COVID-19. Estas condiciones afectan especialmente a estudiantes de contextos vulnerables, reduciendo sus posibilidades de permanecer y culminar con éxito su formación universitaria.

Diversas investigaciones han documentado múltiples causas de la deserción, entre ellas el bajo rendimiento académico, las dificultades económicas, los problemas familiares y la falta de alineación entre las expectativas del estudiante y la experiencia universitaria. Aunque muchas instituciones han implementado programas de tutoría, orientación y apoyo financiero, estas iniciativas suelen carecer de mecanismos efectivos para identificar con anticipación a los estudiantes en mayor riesgo de abandono. La creciente digitalización de los procesos académicos y administrativos ha generado una abundante disponibilidad de datos estudiantiles. Este nuevo panorama ofrece una oportunidad valiosa para aplicar herramientas de análisis de datos y aprendizaje automático que permitan detectar patrones complejos y anticipar comportamientos como la deserción. A través de estos enfoques, es posible desarrollar sistemas de alerta temprana que faciliten intervenciones proactivas y personalizadas.

En este contexto, la presente investigación tiene como objetivo general optimizar la predicción de la retención estudiantil mediante un análisis comparativo de modelos de aprendizaje automático supervisados y no supervisados, aplicados a un conjunto de datos históricos proporcionado por una universidad privada en El Salvador, que comprende más de 83,000 registros entre 2019 y 2024. El estudio se aplica desde un enfoque cuantitativo y exploratorio, a través de técnicas de segmentación y modelado predictivo orientadas a identificar perfiles estudiantiles con características similares de riesgo y predecir la deserción. Esta perspectiva permite generar evidencia útil para la toma de decisiones estratégicas

en contextos institucionales con recursos limitados.

Además del aporte metodológico, esta investigación busca fomentar una cultura institucional basada en el uso sistemático de los datos para la mejora continua. En lugar de adoptar respuestas reactivas, se plantea un modelo de gestión proactiva que reconozca la diversidad del estudiantado y promueva intervenciones oportunas, especialmente dirigidas a estudiantes del primer ciclo o con condiciones académicas y económicas desfavorables. A nivel internacional, diversas universidades han demostrado que la integración de modelos predictivos en sus sistemas de gestión contribuye significativamente a mejorar los índices de retención y titulación. En sintonía con estas experiencias, el presente estudio se alinea con la tendencia global hacia una educación superior más analítica, digital y centrada en el estudiante, en la que los datos no solo documentan el pasado, sino que también proyectan el futuro educativo.

METODOLOGÍA

A. Estudios Similares

En el ámbito comercial, el concepto de valor del cliente se refiere a la cantidad de ingresos que un cliente genera para una empresa durante el período en que mantiene una relación activa con ella. Este valor no solo está vinculado a la rentabilidad inmediata, sino también al impacto que dicho cliente puede tener sobre la estabilidad y el crecimiento a largo plazo de la organización. Según Kotler y Keller (2016), comprender y gestionar el valor del cliente es esencial para que las empresas orienten sus estrategias hacia la retención de los segmentos más rentables, optimizando así el uso de recursos y maximizando beneficios.

En el contexto educativo, un concepto análogo es el valor del estudiante, entendido como la contribución que la permanencia de un estudiante en una institución tiene sobre sus ingresos, sostenibilidad financiera y reputación académica (Fahd et al., 2022). Este paralelismo entre ambos ámbitos pone de manifiesto que, aunque el producto o servicio sea distinto, la retención sigue siendo un factor crítico para la viabilidad organizacional. Sin embargo, existen diferentes factores que influyen en la permanencia. Mientras que en el sector comercial la retención depende principalmente de la calidad del producto o servicio, la experiencia del cliente y las políticas de fidelización (Kotler & Armstrong, 2018), en la educación superior la decisión de continuar o abandonar los estudios se ve influenciada por diferentes variables de tipo académicas, socioeconómicas, demográficas y psicosociales

(Tinto, 2012).

En este sentido, diversos autores han identificado y clasificado los factores que inciden en la retención estudiantil. Los factores demográficos incluyen la edad, el género, el nivel socioeconómico y la situación laboral del estudiante. Los factores académicos se relacionan con el rendimiento previo, la satisfacción con el programa de estudios y la percepción de la carga académica. Por último, los factores psicosociales abarcan aspectos como la motivación personal, la integración social dentro de la comunidad universitaria y el apoyo familiar (Astin, 1999; Tinto, 2012). Cabrera et al. (2006) señalan que la probabilidad de abandono aumenta significativamente cuando los estudiantes enfrentan una combinación de riesgos, como bajos ingresos familiares y dificultades académicas, lo que resalta la necesidad de una detección temprana de dichos factores.

Para abordar este reto, la literatura ha documentado el uso de modelos estadísticos y de aprendizaje automático que permiten identificar patrones y predecir la retención. Entre los enfoques más tradicionales, la regresión logística ha sido ampliamente utilizada para estimar la probabilidad de abandono en función de un conjunto de variables independientes, ofreciendo interpretaciones claras de la influencia de cada factor (Cortez & Silva, 2008). En paralelo, las técnicas de aprendizaje no supervisado, como el algoritmo K-means, han demostrado utilidad para agrupar estudiantes según similitudes en sus características, revelando patrones que no siempre son evidentes mediante análisis univariados o bivariados (Kurniawan & Taufiq, 2019).

Estudios comparativos han evaluado el rendimiento de diferentes modelos predictivos. Vandamme et al. (2017) confrontaron modelos supervisados como la regresión logística y los árboles de decisión, encontrando que estos últimos ofrecían una mayor precisión en la identificación de estudiantes en riesgo de deserción. Kurniawan y Taufiq (2019), por su parte, aplicaron técnicas de clustering para segmentar poblaciones estudiantiles y lograron identificar grupos con alto riesgo sin necesidad de etiquetas previas. Más recientemente, Arqawi et al. (2022) exploraron un enfoque híbrido que combina aprendizaje automático tradicional con modelos de aprendizaje profundo, alcanzando altos niveles de precisión y reduciendo la tasa de falsos positivos, lo que se traduce en intervenciones más focalizadas y efectivas.

Estos hallazgos reflejan que el uso de herramientas analíticas avanzadas no solo aporta valor académico, sino que también tiene implicaciones prácticas para la gestión institucional. La

detección temprana de estudiantes en riesgo, seguida de intervenciones personalizadas como tutorías académicas, orientación vocacional o apoyos económicos puede contribuir de manera significativa a mejorar las tasas de retención (Martínez et al., 2021). En este contexto, la presente investigación se alinea con estos esfuerzos, adoptando un enfoque cuantitativo y un diseño mixto que combina análisis descriptivo y exploratorio con modelado predictivo. El objetivo es doble: por un lado, caracterizar los patrones de deserción estudiantil, y por otro, estimar la retención a partir de variables sociodemográficas, académicas y económicas. Para ello, se emplean técnicas no supervisadas, que permiten segmentar la población en grupos con características similares, y supervisadas, que facilitan la predicción precisa del abandono estudiantil.

B. Datos y fuentes

El conjunto de datos utilizado en esta investigación fue extraído de los registros académicos de una universidad privada en El Salvador, abarcando el periodo 2019-2024. Este dataset, compuesto por 83,175 registros y 31 variables, constituye la base fundamental para el análisis y la predicción de la retención estudiantil.

Las variables se agrupan en cuatro categorías principales:

- Sociodemográficas: género, edad, departamento de residencia, estado familiar.
- Académicas: facultad, carrera, nivel académico, rendimiento (CUM), modalidad, asignaturas aprobadas y reprobadas.
- Económicas: tipo de financiamiento.
- Históricas: año y semestre de ingreso, tipo de ingreso, continuidad académica.

Todos los datos fueron anonimizados y tratados bajo estrictos criterios de confidencialidad institucional.

C. Preprocesamiento de datos

Antes de la implementación de los modelos, se desarrolló un preprocesamiento de datos, con el objetivo de garantizar la calidad, consistencia y adecuación de la información para el análisis de la retención estudiantil. Este procedimiento se estructuró en las siguientes etapas principales:

Limpieza de datos. Se identificaron y eliminaron registros duplicados. Los valores faltantes fueron tratados mediante estrategias específicas: imputación por la mediana en vari-

ables numéricas y por la moda en variables categóricas, o eliminación del registro cuando la ausencia de datos era insalvable. Adicionalmente, se realizó la detección de valores atípicos mediante análisis exploratorio. Los casos que correspondían a errores de captura fueron corregidos o eliminados, mientras que aquellos que representaban variabilidad natural del fenómeno fueron conservados.

Codificación de variables categóricas. Todas las variables categóricas fueron transformadas a formato numérico. Se empleó label encoding y one-hot encoding según las necesidades del algoritmo a aplicar. Por ejemplo, variables como Modalidad, Facultad y TipoIngreso se convirtieron en variables dummy para evitar introducir relaciones ordinales inexistentes y optimizar su manejo por parte de los modelos.

Normalización de variables numéricas. Las variables numéricas, como Edad, CUM, Aprobadas y Reprobadas, fueron estandarizadas mediante el método Z-score (media cero y desviación estándar uno).

División de datos. El conjunto de datos fue segmentado en dos subconjuntos: 75% para entrenamiento y 25% para prueba, manteniendo la proporción original de clases de la variable objetivo mediante stratified sampling. Esta estrategia aseguró una representación equitativa de las categorías en ambos subconjuntos, permitiendo una evaluación objetiva del rendimiento de los modelos.

Este preprocesamiento proporcionó una base sólida para la etapa de modelado, asegurando que los datos estuvieran libres de inconsistencias, en un formato adecuado y listos para maximizar el desempeño de las técnicas empleadas.

D. Análisis descriptivo

El análisis descriptivo constituyó la primera fase del tratamiento estadístico de la información y tuvo como finalidad caracterizar de manera integral el conjunto de datos utilizados en el estudio. Este procedimiento permitió comprender la estructura, distribución y comportamiento de las variables relevantes antes de aplicar los modelos predictivos, proporcionando un contexto sólido para la interpretación de los resultados posteriores.

Las técnicas de análisis descriptivo empleadas incluyeron medidas de tendencia central (media, mediana, moda), medidas de dispersión (desviación estándar, rango intercuartílico) y análisis de frecuencias para variables categóricas. Asimismo, se implementaron visualizaciones gráficas con el propósito de facilitar la interpretación de patrones y tenden-

cias.

Este análisis permitió identificar variables potencialmente influyentes en la retención estudiantil, así como establecer hipótesis iniciales sobre las relaciones entre factores académicos, socioeconómicos y demográficos. Los resultados obtenidos sirvieron como base para el análisis exploratorio y la posterior construcción de los modelos predictivos.

E. Análisis exploratorio: aplicación de metodos no supervisado

Se aplicaron técnicas estadísticas y visualizaciones para describir la distribución de estudiantes en variables clave. Con el objetivo de identificar patrones y reducir la dimensionalidad, se utilizó el Análisis de Componentes Principales (PCA) como técnica preliminar para transformar las variables numéricas y categóricas codificadas en un conjunto reducido de componentes no correlacionados entre sí, que explicaron la mayor parte de la varianza observada. Este procedimiento facilitó la visualización de los datos y optimizó el proceso de agrupamiento posterior al disminuir redundancias y ruido en las variables originales.

En la etapa de segmentación, se emplearon algoritmos de K-medias y agrupamiento jerárquico. El algoritmo de K-medias fue seleccionado como técnica principal debido a su eficiencia y simplicidad para trabajar con grandes volúmenes de datos numéricos estandarizados, permitiendo identificar grupos de estudiantes con patrones similares en variables académicas, demográficas y socioeconómicas, y minimizando la varianza intraclúster.

Como complemento, se utilizó la clusterización jerárquica con un enfoque aglomerativo, generando dendrogramas que facilitaron la exploración de la estructura de los datos y la validación de la coherencia de los grupos obtenidos mediante K-medias. Esta técnica aportó una visión jerárquica de las relaciones entre perfiles estudiantiles sin necesidad de fijar un número previo de clústeres.

La determinación del número óptimo de clústeres se realizó mediante el método del codo, identificando el punto de inflexión. Inicialmente, se estableció $k = 2$ para una segmentación básica que diferenciara perfiles de mayor y menor riesgo de deserción. Posteriormente, un segundo análisis determinó que $k = 5$ ofrecía una representación más precisa de la diversidad de perfiles estudiantiles, capturando patrones más específicos y significativos.

F. Análisis predictivo: aplicación de métodos supervisados

Con el propósito de estimar la retención estudiantil, se implementaron y compararon cinco modelos de aprendizaje automático supervisado: Máquinas de Vectores de Soporte (SVM), K-Vecinos Más Cercanos (KNN), Bosques Aleatorios (Random Forest), AdaBoost y XGBoost. La selección de estos algoritmos se basó en su eficacia reportada en la literatura para tareas de clasificación binaria, su capacidad para manejar datos con características mixtas y relaciones no lineales, así como su robustez frente a conjuntos de datos desbalanceados (Chen & Guestrin, 2016; Fernández-Delgado et al., 2014).

Todos los modelos fueron entrenados y optimizados sobre el conjunto de datos de entrenamiento, aplicando búsqueda en malla (Grid Search) y validación cruzada estratificada para ajustar sus hiperparámetros.

- **Máquinas de Vectores de Soporte (SVM):** Se implementó con función kernel para capturar relaciones no lineales, lo que resultó adecuado para entornos de alta dimensionalidad y problemas de clasificación binaria (Peng et al., 2020; Vandamme et al., 2017). Se ajustaron parámetros como el tipo de kernel, el parámetro de regularización (C) y el coeficiente de ajuste (gamma) para maximizar la capacidad de generalización.
- **K-Vecinos Más Cercanos (KNN):** Basado en la similitud entre instancias mediante distancia euclidiana, se evaluaron diferentes valores de k y métodos de búsqueda (ball_tree, kd_tree y brute), seleccionando la configuración óptima mediante validación cruzada (Qingtao et al., 2019).
- **Bosques Aleatorios (Random Forest):** Se entrenó un conjunto de árboles de decisión con muestreo bootstrap y selección aleatoria de características, lo que permitió manejar relaciones complejas, reducir el sobreajuste y estimar la importancia de las variables (Breiman, 2001).
- **AdaBoost (Adaptive Boosting):** Se implementó combinando clasificadores débiles (árboles poco profundos) de forma secuencial, aumentando el peso de las instancias mal clasificadas para mejorar la precisión global, particularmente en entornos con ruido moderado (Schapire & Freund, 2012).
- **XGBoost (Extreme Gradient Boosting):** Se aplicó con técnicas de regularización, poda temprana de árboles y paralelización, configurando un aprendizaje secuencial optimizado para datos estructurados (Chen & Guestrin,

2016).

G. Evaluación del rendimiento de los modelos predictivos

El rendimiento de los modelos se evaluó en el conjunto de prueba mediante métricas específicas para cada modelo predictivo. Estas métricas permitieron obtener una visión integral del desempeño más allá de la simple precisión y facilitaron la comparación entre algoritmos.

Se emplearon las siguientes medidas:

- **Exactitud (Accuracy):** Porcentaje de predicciones correctas sobre el total de observaciones.
- **Precisión (Precision):** Proporción de verdaderos positivos entre todas las predicciones positivas.
- **Sensibilidad o Recall:** Proporción de verdaderos positivos entre todos los casos realmente positivos; en este estudio, representa la capacidad de identificar a estudiantes en riesgo de abandonar (Powers, 2011).
- **Error global:** Complemento de la exactitud, que indica la tasa de errores cometidos por el modelo.
- **Área bajo la curva ROC (AUC-ROC):** Mide la capacidad del modelo para discriminar entre clases en todos los umbrales de decisión, siendo un valor cercano a 1 indicativo de excelente discriminación (Fawcett, 2006).
- **Matriz de confusión:** Permite visualizar verdaderos positivos, verdaderos negativos, falsos positivos y falsos negativos, brindando un análisis detallado de los errores de clasificación (Chicco & Jurman, 2020).

Este esquema de evaluación garantizó la selección del modelo con mayor capacidad predictiva y menor riesgo de sobreajuste, asegurando la validez de los resultados de predicción de retención estudiantil.

H. Objetivos del estudio

La metodología implementada permitió avanzar de manera estructurada hacia el cumplimiento de los siguientes objetivos:

- Caracterizar la población estudiantil mediante análisis descriptivos, con el fin de identificar la distribución de estudiantes según las características de cada variable demográfica, socioeconómica y académica.
- Identificar patrones y perfiles de retención y deserción estudiantil a través de técnicas de análisis exploratorio, incluyendo métodos de reducción de dimensionalidad y agrupamiento.

- Evaluar y comparar el desempeño de modelos de aprendizaje automático supervisados para la predicción de la retención estudiantil, utilizando métricas de rendimiento que permitieron determinar los modelos más efectivos.


RESULTADOS

El análisis descriptivo constituye la primera etapa para comprender las características esenciales de la población estudiantil antes de la aplicación de técnicas de modelado predictivo. Su propósito es ofrecer una visión integral de las tendencias, patrones y distribuciones de variables clave que inciden en la continuidad académica, así como identificar relaciones preliminares que orienten la selección de atributos relevantes para los modelos.

El estudio de variables demográficas, como edad y género, permite evidenciar diferencias y tendencias asociadas a la retención. En la Fig 1.a, se observa que la mayoría de los estudiantes en cada semestre corresponde al género femenino, acompañado de una tendencia decreciente en el número total de matriculados por periodo. Asimismo, la Fig 1.b muestra que la mayor concentración de estudiantes se encuentra en el rango de 18 a 38 años, manteniéndose esta distribución de manera consistente a lo largo de los semestres.

Figura 1


a) Distribución porcentual de estudiantes por género y periodo. b) Distribución de estudiantes por edad y periodo Construcción



En cuanto a las variables socioeconómicas, el análisis revela su influencia directa sobre la permanencia estudiantil. La Fig 2.a indica que la principal fuente de financiamiento proviene del apoyo familiar, mientras que la Fig 2.b, tomando como referencia el total de estudiantes del semestre I-2019, evidencia una disminución progresiva en la matrícula, alcanzando en el semestre I-2024 una reducción significativa respecto al periodo base.

Figura 2


a) Distribución porcentual de estudiantes por tipo de financiamiento y periodo. b) Distribución porcentual de estudiantes por estado familiar y periodo



El análisis de las variables académicas profundiza en cómo factores institucionales, como la modalidad de estudio y la estructura de oferta académica, condicionan la trayectoria de los estudiantes. La Fig 3.a presenta la distribución de estudiantes según modalidad (presencial, semipresencial y no presencial) por periodo, y la Fig 3.b muestra la tendencia de matrícula por facultad a lo largo de los ciclos académicos, evidenciando variaciones diferenciales entre áreas de formación.

Figura 3


a) Distribución de estudiantes por modalidad y periodo. b) Tendencia de matrícula por periodo y facultad



El análisis exploratorio se complementó con la aplicación del Análisis de Componentes Principales (PCA), utilizado como etapa preliminar a la clusterización. Para ello, las variables cualitativas fueron transformadas en dicotómicas, lo que permitió representar de forma simultánea la variabilidad de todas las variables en un espacio de menor dimensionalidad. El biplot resultante (Fig 4) revela la estructura de los datos y facilita la identificación visual de patrones de agrupamiento iniciales.

Figura 4

a) Biplot de Análisis de Componentes Principales (PCA)



Como primer ejercicio, se ejecutó un análisis de clústeres con $k=2$, obteniéndose la distribución porcentual de estudiantes por facultad para cada grupo (Fig 5). No obstante, con el fin de determinar un valor óptimo de k clusters que mejore la representatividad y la complejidad del modelo, se aplicó el método del codo (Fig 6). Este procedimiento mostró una inflexión significativa en $k=5$, lo que sugiere que este número de grupos captura adecuadamente la heterogeneidad de la población sin incurrir en sobreajuste.

Figura 5

a) Porcentaje de individuos de cada clúster por Facultad para $k=2$





Figura 6


Aplicación del método del codo para determinar el número óptimo de clústers



La segmentación final con $k=5$ (Fig 7) permitió identificar perfiles diferenciados de estudiantes según la facultad, revelando patrones específicos asociados a factores académicos. Estos hallazgos exploratorios constituyeron la base para la siguiente etapa del análisis, orientada a la construcción y evaluación de modelos predictivos con el propósito de optimizar la estimación de la retención estudiantil.

Figura 7

Porcentaje de individuos de cada clúster por Facultad para $k=5$



Finalmente, se entrenaron y evaluaron diversos algoritmos supervisados, seleccionando aquellos con el mejor desempeño para su análisis comparativo. Entre los modelos con resultados más destacados se encuentran el Máquinas de Vectores de Soporte (SVM) optimizado, el método de K vecinos más cercanos (implementado con algoritmos de búsqueda ball_tree, kd_tree y brute), así como Bosques Aleatorios, XGBoost y AdaBoost. La Tabla I muestra el

rendimiento de estos modelos, permitiendo contrastar su capacidad predictiva y su aplicabilidad en entornos institucionales de educación superior.

Tabla 1

Desempeño de Modelos Predictivos de Retención Estudiantil por Clústers

Modelo	Parámetros optimizados	Precisión global
SVM	kernel=rbf_C=46	77.31%
KNN	algorithm=ball_tree_n_neighbors=9	75.74%
Random Forest	entropy_n_estimators=50_min_samples_split=32	78.99%
XGBoost	n_estimators=100_min_samples_split=31	78.91%
AdaBoost	entropy_n_estimators=50_min_samples_split=29	76.21%

DISCUSIÓN

El análisis demográfico evidencia que la población estudiantil está compuesta mayoritariamente por mujeres en todos los periodos analizados, pese a la tendencia decreciente en la matrícula total. Este grupo presenta una probabilidad de continuidad superior a la de los hombres, lo que sugiere una mayor permanencia académica. Asimismo, los rangos etarios de 18-24 y 25-34 años concentran la mayor proporción de estudiantes y constituyen segmentos clave para la implementación de estrategias de retención. Estos hallazgos refuerzan la relevancia de los factores demográficos como determinantes en la permanencia estudiantil y orientan la necesidad de intervenciones focalizadas.

Desde la perspectiva socioeconómica, se observa una disminución general en la matrícula, con predominio de estudiantes que financian sus estudios mediante apoyo familiar. Aquellos que dependen exclusivamente de recursos propios, aunque representan un grupo menor, exhiben mayores probabilidades de abandono entre ciclos, pero también una tasa de graduación más elevada. La reducción de matrícula afecta tanto a estudiantes solteros como casados, siendo los primeros los más impactados. La variabilidad en la continuidad según el estado familiar evidencia que las condiciones económicas y contextos personales influyen significativamente en la retención y finalización de los estudios, lo que destaca la necesidad de políticas institucionales que contemplen estos factores.

En el ámbito académico, la modalidad presencial sigue siendo la predominante, aunque ha registrado una disminución notable en la matrícula desde 2019, mientras que la modalidad no presencial ha crecido de forma sostenida. Este

cambio refleja una adaptación hacia esquemas educativos más flexibles, probablemente influenciada por el avance de la digitalización y factores externos recientes. Sin embargo, la modalidad presencial presenta mayores tasas de deserción, lo que demanda intervenciones específicas para este grupo. A nivel de facultades, la Facultad FCE enfrenta los mayores desafíos de retención, mientras que la Facultad FAD y la Facultad FCJ mantienen niveles estables de continuidad, lo que respalda la necesidad de estrategias diferenciadas por área académica.

El análisis por nivel académico confirma que los estudiantes de primeros niveles presentan mayores índices de abandono, mientras que en niveles avanzados la continuidad es más frecuente, lo que sugiere un incremento del compromiso académico conforme progresa la trayectoria formativa. Estos hallazgos proporcionan un panorama integral del progreso académico y ofrecen insumos clave para el diseño de estrategias de permanencia.

Los resultados en el análisis descriptivo justifican la aplicación de un análisis exploratorio focalizado en los estudiantes de primer nivel. Este procedimiento, basado en la segmentación no supervisada de la población en grupos homogéneos, permite identificar patrones latentes sin necesidad de etiquetas previas, lo que posibilita el desarrollo de estrategias de intervención personalizadas y orientadas a las necesidades específicas de cada segmento estudiantil.

La primera etapa de clusterización, con $k = 2$, proporcionó una división general de la población estudiantil en dos grupos bien diferenciados. Aunque esta configuración permitió detectar diferencias notables, su baja granularidad motivó la exploración de valores superiores de k . La aplicación del método del codo determinó que $k = 5$ ofrecía el mejor equilibrio entre variabilidad explicada e interpretabilidad, evitando el sobreajuste y capturando con mayor precisión la heterogeneidad de los datos.

La segmentación con $k = 5$ reveló combinaciones específicas de factores demográficos, socioeconómicos y académicos, generando información valiosa para el diseño de intervenciones focalizadas. El uso de Análisis de Componentes Principales (PCA) resultó clave para reducir la dimensionalidad de los datos, facilitar la visualización bidimensional de los clústeres y destacar las variables más influyentes en su formación, optimizando así el rendimiento del proceso de agrupamiento.

En la fase predictiva, se evaluaron diversos algoritmos de

aprendizaje automático incluyendo SVM con kernel RBF, KNN (con `ball_tree`, `kd_tree` y `brute`), Bosques Aleatorios, XGBoost y AdaBoost para determinar el mejor desempeño en términos de precisión global, positiva y negativa. El SVM con kernel RBF y $C = 46$ alcanzó un rendimiento notable (77.31 % de precisión global) con un adecuado balance en la clasificación de ambas clases, aspecto crítico en la predicción de retención.

No obstante, el mejor resultado fue obtenido por el modelo de Bosques Aleatorios (`entropy`, `n_estimators`

`= 50`, `min_samples_split = 32`), que alcanzó una precisión global del 78.99 %. Este algoritmo destacó por su alta precisión negativa, evidenciando una capacidad superior para identificar a los estudiantes con mayor probabilidad de continuar sus estudios. Si bien los modelos KNN y los métodos de ensamble como XGBoost y AdaBoost también mostraron un desempeño aceptable, se estima que podrían alcanzar mejores resultados mediante una calibración más exhaustiva de hiperparámetros (ver Tabla I).

En resumen, estos hallazgos demuestran que la combinación de análisis exploratorio no supervisado y modelado predictivo supervisado constituye una estrategia sólida para la identificación temprana de perfiles de riesgo y la optimización de intervenciones en el ámbito de la retención estudiantil.

CONCLUSIONES

La investigación confirma que la combinación de técnicas de análisis exploratorio no supervisado y modelos predictivos supervisados de aprendizaje automático ofrece una visión integral y operativa de los factores que inciden en la retención estudiantil. La aplicación de clusterización permitió segmentar a la población en perfiles homogéneos de alto y bajo riesgo de deserción, facilitando el diseño de estrategias de intervención personalizadas. También, los modelos supervisados alcanzaron un alto nivel de desempeño, demostrando su potencial para ser incorporados en sistemas de gestión académica con el fin de generar alertas tempranas y habilitar acciones preventivas oportunas.

El análisis reveló que variables como el rendimiento académico, la modalidad de estudio y el tipo de financiamiento tienen un peso significativo en la continuidad académica. En particular, los estudiantes con bajo CUM, modalidad presencial y financiamiento

propio conforman el grupo más vulnerable a la deserción, por lo que se recomienda priorizar intervenciones específicas para este segmento.

Finalmente, se propone ampliar el alcance de la investigación mediante la incorporación de variables de carácter psicopedagógico y el empleo de técnicas avanzadas como el aprendizaje profundo (Deep Learning), con el objetivo de incrementar la capacidad explicativa y mejorar la precisión en la predicción del abandono estudiantil.

REFERENCIAS

- Abdullah, N., Mohamad, A., & Bakar, A. (2019). Predicting student dropout using clustering techniques. *International Journal of Advanced Computer Science and Applications*, 10(9), 73-81.
- Arqawi, S., Zitawi, E., Rabaya, A., Abunasser, B., & Abu-Naser, S. (2022). Predicting University Student Retention using Artificial Intelligence. *International Journal of Advanced Computer Science and Applications*. <https://doi.org/10.14569/ijacsa.2022.0130937>.
- Asif, R., Merceron, A., Ali, S. A., & Haider, N. G. (2017). Analyzing undergraduate students' performance using educational data mining. *Computers & Education*, 113, 177-194.
- Astin, A. (1999). Student involvement: A developmental theory for higher education. *Journal of College Student Development*, 40(5), 518-529.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Cabrera, A., Nora, A., & Castaneda, M. (2006). College persistence: Structural equations modeling test of an integrated model of student retention. *The Journal of Higher Education*, 64(2), 123-139.
- Cabrera, A., Nora, A., & Castaneda, M. (2018). The role of finances in the persistence process: A structural model. *Research in Higher Education*, 33(5), 571-593.
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ACM, 785-794. <https://doi.org/10.1145/2939672.2939785>

- Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21(6), 1-13. <https://doi.org/10.1186/s12864-019-6413-7>
- Cortez, P., & Silva, A. (2008). Using data mining to predict secondary school student performance. In *Proceedings of the 5th Annual International Conference on Educational Data Mining*, 5-12.
- Fahd, K., Venkatraman, S., Miah, S. J., & Ahmed, K. (2022). Application of machine learning in higher education to assess student academic performance, at-risk, and attrition: A meta-analysis of literature. *Education and Information Technologies*, 1-33.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874.
- Fernández-Delgado, M., Cernadas, E., Barro, S., & Amorim, D. (2014). Do we need hundreds of classifiers to solve real world classification problems? *Journal of Machine Learning Research*, 15(1), 3133- 3181. Obtenido de <http://jmlr.org/papers/v15/delgado14a.html>
- Gupta, S., Lehmann, D., & Stuart, J. (2006). Valuing customers. *Journal of Marketing Research*, 43(1), 7-18.
- Hagedorn, L. S. (2021). How to define retention: A new look at an old problem. *Journal of College Student Retention: Research, Theory & Practice*, 23(1), 1-15.
- Herzog, S. (2006). Estimating student retention and degree-completion time: Decision trees and neural networks vis-à-vis regression. *New Directions for Institutional Research*(131), 17-33.
- Kotler, P., & Armstrong, G. (2018). *Principles of Marketing* (17th ed.). Education Pearson. Kotler, P., & Keller, K. (2016). *Marketing Management* (15th ed.). Pearson Education.
- Kurniawan, T., & Taufiq, M. (2019). Clustering students based on their academic data using K-Means algorithm. *Journal of Information Systems Engineering and Business Intelligence*, 5(2), 110-118. Obtenido de <https://www.ijstr.org/final-print/aug2019/Clustering-Student-Data-Based-On-K-means-Algorithms.pdf>
- Martínez, R., Caballero, A., & Figueroa, R. (2021). Early detection of student dropout in higher education using machine learning techniques. *Education and Information Technologies*, 26, 2133-2152. Obtenido de https://www.researchgate.net/publication/372493356_Predicting_Student_Dropout_
- Meneses, J., Rodríguez-Gómez, D., & Fernández, C. (2020). Determinants of higher education drop-out in Latin America: A systematic review. *Journal of Latin American Studies*, 52(3), 645-665.
- Peng, L., Chaoli, S., Guochen, Z., & Yaochu, J. (2020). Multi-surrogate multi-tasking optimization of expensive problems. *Knowledge-Based Systems*. <https://doi.org/10.1016/j.knosys.2020.106262>
- Powers, D. M. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- Qingtao, X., Xin, Z., & Chenghua, Z. (2019). Application Research of KNN Algorithm Based on Clustering in Big Data Talent Demand Information Classification. *International Journal of Pattern Recognition and Artificial Intelligence*, 34(19). <https://doi.org/10.1142/S0218001420500159>
- Romero, C., Ventura, S., & García, E. (2013). Data mining in course management systems: Moodle case study and tutorial. *Computers & Education*, 51(1), 368-384.
- Schapire, R., & Freund, Y. (2012). *Boosting: Foundations and Algorithms*. MIT Press (MA). <https://doi.org/10.7551/mitpress/8291.001.0001>
- Simões, A., & Soares, M. (2019). A model of student attrition and retention in higher. *Educational Research and Evaluation*, 25(2-3), 25(2-3), 133-152.
- Thomas, L. (2018). Understanding student retention and engagement: Contexts and strategies for improvement. *Higher Education Quarterly*, 72(3), 278-289.
- Tianqi, C., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Association for Computing Machinery*(10), 785-794. <https://doi.org/10.1145/2939672.2939785>
- Tinto, V. (2012). *Completing college: Rethinking institutional action*. University of Chicago Press. Tinto, V. (2017). *Through the eyes of students*. *Journal of College Student*

Retention: Research, Theory & Practice, 19(3), 254-269.

Vandamme, J.-P., Meskens, N., & Superby, J.-F. (2017). Predicting academic performance by data mining methods. *Education Economics*, 15(4), 405-419. Obtenido de <https://ideas.repec.org/a/taf/edecon/v15y2007i4p405-419.html>

Desempeño energético del Edificio para el Centro Urbano de Bienestar y Oportunidades CUBO mediante simulación y escenarios de eficiencia en El Tamarindo, La Unión

Energy performance of the CUBO Urban Center for Wellbeing and Opportunities building through simulation and efficiency scenarios in El Tamarindo, La Unión

Carlos Pocasangre^{1,2}, Ronald Cabrera^{1,3}, José Urquilla^{1,4}

1 Facultad de Ingeniería y Arquitectura, Universidad de El Salvador

2  <https://orcid.org/0000-0002-7463-9873>

3  <https://orcid.org/0009-0004-6955-9942>

4  <https://orcid.org/0009-0005-0012-9968>

Correspondencia: ✉ carlos.pocasangre@ues.edu.sv

Enviado: 17 de abril de 2026 Aceptado: 29 de mayo de 2026

DOI: <https://doi.org/10.66778/CTI.v02n01.01>

PALABRAS CLAVE

Eficiencia energética,
Simulación energética,
HVAC,
EnergyPlus,
Calibración de modelos,
Edificios públicos.

KEYWORDS

Energy efficiency,
Energy simulation, HVAC,
EnergyPlus,
Model calibration,
public buildings

RESUMEN

El presente estudio evaluó el desempeño energético del Centro Urbano de Bienestar y Oportunidades (CUBO), ubicado en El Tamarindo, La Unión, El Salvador, durante el año 2025, mediante la integración de mediciones experimentales y simulaciones energéticas calibradas. El objetivo fue analizar el comportamiento energético del edificio e identificar estrategias para optimizar su consumo eléctrico. Para ello, se realizó un levantamiento técnico del inmueble, se tomaron mediciones de consumo eléctrico mediante instrumentación y se desarrolló un modelo energético utilizando las herramientas SketchUp, OpenStudio y EnergyPlus. El modelo fue calibrado con datos reales, lo que permite representar de manera confiable el comportamiento energético del edificio. A partir de este modelo, se evaluaron distintos escenarios de eficiencia energética, incluyendo la optimización de los horarios de operación, ajustes en los sistemas de climatización, la gestión eficiente de cargas eléctricas, la implementación de estrategias de control solar y la reactivación del sistema fotovoltaico existente. Los resultados evidenciaron reducciones significativas en el consumo energético anual, destacando el impacto de los sistemas HVAC como el principal componente de la demanda energética. Asimismo, se determinó que la implementación conjunta de estrategias permitió alcanzar niveles de eficiencia superiores a los de su aplicación individual. Se concluyó que la simulación energética calibrada constituye una herramienta confiable para la evaluación y optimización del consumo energético en edificaciones públicas.

ABSTRACT

This study evaluated the energy performance of the Urban Center for Well-being and Opportunities (CUBO), located in El Tamarindo, La Unión, El Salvador, during 2025, through the integration of experimental measurements and calibrated energy simulation. The objective was to analyze the building's energy behavior and identify strategies to optimize its electricity consumption. A technical survey of the building was conducted, along with electrical consumption measurements using specialized instrumentation, and the development of an energy model using SketchUp, OpenStudio, and EnergyPlus. The model was calibrated using real data, allowing a reliable representation of the building's energy behavior. Based on this model, several energy efficiency scenarios were evaluated, including optimization of operating schedules, HVAC adjustments, electrical load management, implementation of solar control strategies, and reactivation of the existing photovoltaic system. The results showed significant reductions in annual energy consumption, with HVAC systems identified as the primary contributor to the building's energy demand. Furthermore, the combined implementation of strategies achieved higher efficiency levels compared to individual measures. It was concluded that calibrated energy simulation is a reliable tool for evaluating and optimizing energy consumption in public buildings.



INTRODUCCIÓN

El consumo de energía en edificaciones representa una parte significativa de la demanda energética a nivel mundial, lo que ha llevado a buscar soluciones que mejoren su eficiencia, especialmente en edificios públicos, debido a su impacto en el gasto estatal y a su potencial como modelo de sostenibilidad. En este contexto, la simulación energética se ha convertido en una herramienta clave para comprender cómo se comporta un edificio desde el punto de vista energético y evaluar posibles estrategias de mejora antes de implementarlas (U.S. Department of Energy, 2025; Ministerio de Energía, 2022).

Una de las formas más efectivas de estudiar este comportamiento es combinar mediciones reales con modelos de simulación. Este enfoque permite obtener resultados más cercanos a la realidad, especialmente cuando los modelos se calibran con datos experimentales. Además, el uso de indicadores de desempeño energético facilita la interpretación de estos resultados y la comparación entre distintas condiciones de operación del edificio (GIZ/MEN, 2019; HUB-HAUS, 2021).

En zonas de clima cálido, como El Salvador, es común que los sistemas de climatización (HVAC) sean los principales responsables del consumo energético en las edificaciones. Esto se debe a las altas temperaturas y a la radiación solar constante, que incrementan la carga térmica interna. Por ello, estrategias como el uso de materiales reflectantes o soluciones constructivas que reduzcan la ganancia de calor pueden contribuir a disminuir la demanda energética (Liu & Baskaran, 2005; Grau & Ayerra, 2018).

En América Latina, se han realizado avances importantes en materia de eficiencia energética, impulsados por políticas públicas y marcos regulatorios orientados al uso racional de la energía (CEPAL, 2017; Consejo Nacional de Energía [CNE], 2007). Sin embargo, todavía existen limitaciones en la evaluación del desempeño energético real de los edificios, especialmente en infraestructuras recientes, donde las condiciones de operación pueden diferir de las consideradas en el diseño.

En este contexto, el presente estudio se centra en el Centro Urbano de Bienestar y Oportunidades (CUBO) ubicado en El Tamarindo, La Unión, El Salvador. Para ello, se realizaron un levantamiento técnico del edificio, mediciones de consumo eléctrico y el desarrollo de un modelo energético mediante herramientas de simulación. Dicho modelo fue calibrado con datos reales, lo que permitió representar con mayor precisión el comportamiento energético del inmueble. A partir de

este modelo, se analizaron distintos escenarios de mejora, incluyendo ajustes en la operación de los sistemas de climatización, en la gestión de cargas eléctricas, en estrategias de control solar y en la reactivación del sistema fotovoltaico existente.


El objetivo de este estudio es evaluar el desempeño energético del CUBO El Tamarindo mediante la integración de mediciones experimentales y simulación energética calibrada, con el fin de identificar oportunidades que permitan optimizar su consumo energético.

METODOLOGÍA

El estudio se desarrolló durante el año 2025 en el Centro Urbano de Bienestar y Oportunidades (CUBO), ubicado en El Tamarindo, municipio de Conchagua, departamento de La Unión, El Salvador. La zona presenta un clima cálido tropical, caracterizado por altas temperaturas y elevada radiación solar durante gran parte del año, condiciones que influyen directamente en la demanda energética del edificio, especialmente en los sistemas de climatización. En la Figura 1 se presenta una vista general del edificio analizado.

Figura 1

Vista del edificio del Centro Urbano de Bienestar y Oportunidad (CUBO) El Tamarindo



Nota. Elaboración propia

La metodología se basó en la integración de mediciones experimentales y simulación energética, con el objetivo de evaluar el comportamiento energético del edificio y analizar diferentes escenarios de mejora.

Levantamiento técnico y caracterización del edificio

En una primera etapa, se realizó un levantamiento técnico del inmueble, que incluyó la caracterización arquitectónica, la envolvente térmica, así como los sistemas eléctricos, de iluminación y climatización (HVAC). Además, se elaboró un

inventario de las cargas eléctricas presentes y se analizaron las condiciones reales de operación, tales como horarios de uso, patrones de ocupación y configuración de los sistemas de aire acondicionado.

Adquisición de datos experimentales

Posteriormente, se llevaron a cabo mediciones eléctricas utilizando un analizador de potencia modelo PCE-PA 8000, instalado en el tablero principal del edificio. La Figura 2 muestra el equipo utilizado para la adquisición de datos eléctricos.

Figura 2

Analizador de potencia PCE-PA 8000 instalado en el tablero principal.



Nota. Registro de mediciones eléctricas del sistema.

Durante el periodo de medición se registraron variables como potencia activa (kW), energía consumida (kWh) y perfiles de demanda en función del tiempo. Estos datos permitieron establecer una línea base del consumo energético y comprender el comportamiento real del edificio bajo condiciones normales de operación.


Se observa una adecuada correspondencia entre los valores medidos y simulados, lo que indica que el modelo representa de manera confiable el comportamiento energético del

edificio bajo condiciones reales de operación.

Modelado y simulación energética

En una etapa posterior, se desarrolló un modelo energético del edificio mediante herramientas de simulación. La geometría del inmueble fue construida en SketchUp (SketchUp Help, 2025), mientras que la asignación de propiedades térmicas, cargas internas, horarios de operación y sistemas HVAC se realizó mediante OpenStudio (Open Studio manual, 2025). Finalmente, el motor de simulación EnergyPlus (EnergyPlus, 2025) se utilizó para ejecutar los cálculos energéticos, considerando condiciones climáticas representativas de la zona de estudio. En la Figura 3 se observa el modelo

Figura 3 *Modelo tridimensional del edificio desarrollado en SketchUp mediante OpenStudio.*



Nota. Representación de características constructivas, cargas térmicas y eléctricas, entre otros.

El modelo incluyó variables como cargas internas, condiciones de ocupación, propiedades térmicas de la envolvente, sistemas de climatización y condiciones climáticas externas.


Calibración del modelo

El modelo energético fue calibrado mediante la comparación entre los resultados simulados y los datos reales de consumo eléctrico obtenidos en campo, ajustando parámetros clave hasta lograr una correspondencia aceptable entre ambos conjuntos de datos.

La validación del modelo se realizó a partir del análisis comparativo de las curvas de consumo eléctrico medido y simulado, lo cual permitió verificar la capacidad del modelo para representar el comportamiento energético real del edificio bajo condiciones normales de operación. La calibración del modelo se validó mediante la comparación

Figura 4

Comparación de la demanda eléctrica medida y simulada del edificio.



Nota. Elaboración propia con base en datos experimentales y simulación en OpenStudio.

Se observa una adecuada correspondencia entre los valores medidos y simulados, lo que indica que el modelo representa de manera confiable el comportamiento energético del edificio bajo condiciones reales de operación.

Evaluación de escenarios de eficiencia energética

Una vez ajustado el modelo, se definieron y analizaron distintos escenarios de eficiencia energética, incluyendo: (i) optimización de horarios de operación y control de temperatura en sistemas HVAC, (ii) gestión eficiente de cargas eléctricas, (iii) desactivación de equipos de climatización en áreas específicas, (iv) implementación de estrategias de control solar mediante láminas polarizadas, (v) reactivación del sistema fotovoltaico existente y (vi) combinación de las estrategias anteriores. Se evaluó el impacto de cada escenario sobre el consumo energético anual del edificio y su comportamiento operativo.

Análisis técnico-económico

Finalmente, se realizó un análisis técnico-económico con el objetivo de estimar los ahorros potenciales derivados de la implementación de las estrategias propuestas. Para ello, se consideraron los costos asociados a cada medida y se determinó el periodo de recuperación de la inversión, permitiendo evaluar la viabilidad de su aplicación en el contexto del estudio.

DISCUSIONES Y RESULTADOS

El análisis del modelo energético permitió evaluar el comportamiento del edificio bajo distintos escenarios de

operación, mostrando con claridad el impacto de diversas estrategias de eficiencia energética sobre el consumo total. El modelo calibrado logró reproducir adecuadamente la tendencia del consumo real, lo que permitió utilizarlo como una base confiable para la simulación de escenarios.

El escenario base representó las condiciones actuales de operación del edificio, caracterizadas por un consumo elevado asociado principalmente al uso de sistemas de climatización, iluminación y equipos eléctricos. A partir de esta referencia, se analizaron seis escenarios de mejora energética, lo que permitió comparar tanto el efecto individual como el impacto conjunto de las estrategias evaluadas.

El escenario 1, enfocado en la optimización de horarios de operación y el ajuste de temperaturas en los sistemas de climatización, presentó una reducción del 13.87% en el consumo energético anual. Este resultado confirma que los sistemas HVAC son el principal factor en el consumo energético del edificio, lo cual coincide con estudios previos en edificaciones ubicadas en climas cálidos (Flensburg, 2020).

En los escenarios 2 y 3, relacionados con la gestión eficiente de cargas eléctricas y la desactivación de equipos de climatización en áreas específicas, se obtuvieron reducciones del 6.43% y 6.47%, respectivamente. Estos resultados muestran que las estrategias operativas ayudan a reducir el consumo, aunque su impacto es menor en comparación con los ajustes directos en los sistemas de climatización.

El escenario 4, correspondiente a la implementación de láminas polarizadas como estrategia de control solar, presentó una reducción del 2.29%. Esto indica que las estrategias pasivas, por sí solas, tienen un impacto moderado, pero siguen siendo útiles como complemento dentro de una estrategia más integral.

Por su parte, el escenario 5, basado en la reactivación del sistema fotovoltaico existente, permitió reducir en un 10.94% el consumo de energía proveniente de la red eléctrica. Este resultado resalta el papel de la generación distribuida como una alternativa efectiva para disminuir la dependencia energética del edificio.

El escenario 6, que integra todas las estrategias evaluadas, alcanzó la mayor reducción del consumo energético, con un valor del 28.58% respecto a la línea base. Esto demuestra que combinar medidas operativas, pasivas y tecnológicas es más efectivo que aplicarlas de forma aislada.


La Figura 4 muestra la comparación entre la demanda

eléctrica medida y simulada del edificio. Se observa una buena correspondencia entre ambos conjuntos de datos, lo que indica que el modelo representa de manera confiable el comportamiento energético del edificio bajo condiciones reales de operación.

La Figura 5 presenta el comportamiento del consumo energético mensual bajo los diferentes escenarios evaluados. En ella se aprecia una reducción constante en todos los casos, especialmente durante los periodos de mayor demanda térmica, lo que confirma la influencia del clima en el consumo energético y la efectividad de las estrategias aplicadas.

Figura 5

Consumo energético mensual del edificio bajo diferentes escenarios de simulación.




Nota. Resultados obtenidos a partir del modelo energético.

El análisis de los indicadores de desempeño energético, conforme a la norma ISO 50006, permitió evaluar con mayor precisión la eficiencia del edificio en cada escenario. En este sentido, se consideraron los siguientes indicadores:

- IGDE [kWh/m²·año]: Indicador global de desempeño energético
- ICO2 [kgCO₂/m²·año]: Indicador de kg CO₂/m² al año
- ICEE [\$/m²·año]: Intensidad de costo de la energía eléctrica
- IDEI [kWh/m²·año]: Indicador de desempeño energético en iluminación
- IDEE [kWh/m²·año]: Indicador de desempeño energético en equipos eléctricos

En la Figura 6 se observa una mejora general de estos indicadores en los escenarios optimizados, lo que refleja un uso más eficiente de la energía en el edificio.

Figura 6 Los datos medidos y simulados, como se muestra en la Figura 4. Comparación de indicadores de desempeño energético para los escenarios evaluados.



Nota. Elaboración propia con base en resultados de simulación.

Desde el punto de vista técnico-económico, la Tabla 1 muestra el periodo de recuperación de la inversión para cada una de las estrategias evaluadas. Los resultados indican que algunas medidas pueden implementarse rápidamente debido a sus bajos tiempos de retorno, mientras que otras requieren una mayor inversión inicial, pero ofrecen beneficios sostenidos en el tiempo.

	Escenario 1	Escenario 2	Escenario 3	Escenario 4	Escenario 5	Escenario 6
Gasto de energía eléctrica	\$18,121.26	\$18,812.58	\$18,808.27	\$19,583.13	\$17,917.78	\$15,417.70
Ahorro de energía	\$1,925.93	\$1,234.61	\$1,238.92	\$464.06	\$2,129.41	\$4,629.50
Costo de inversión	\$100.00	\$1,000.00	\$1,400.00	\$4,830.75	\$5,000.00	\$12,330.75
Periodo de recuperación (años)	0.05	0.81	1.13	10.41	2.35	2.66

En conjunto, los resultados obtenidos confirman que la aplicación de la simulación energética basada en datos reales permite identificar oportunidades significativas de mejora del desempeño energético de edificaciones públicas, proporcionando una base técnica para la toma de decisiones orientadas a la eficiencia energética.

CONCLUSIÓN

El presente estudio permitió evaluar el desempeño energético del Centro Urbano de Bienestar y Oportunidades (CUBO) El Tamarindo mediante la integración de mediciones reales y de una simulación energética calibrada, lo que demostró

que este enfoque permite representar de forma confiable el comportamiento energético del edificio bajo condiciones reales de operación.

Los resultados evidenciaron que los sistemas de climatización constituyen el principal componente del consumo energético, por lo que las estrategias orientadas a optimizar su operación generan los mayores niveles de ahorro. Asimismo, se comprobó que las medidas operativas y las estrategias pasivas contribuyen de manera complementaria a la mejora del desempeño energético.

La reactivación del sistema fotovoltaico existente permitió reducir la dependencia de la red eléctrica, lo que evidencia el potencial de la generación distribuida como parte de una estrategia integral de eficiencia energética. En conjunto, la aplicación simultánea de medidas operativas, pasivas y tecnológicas permitió alcanzar reducciones significativas en el consumo energético, superiores a las obtenidas con su implementación individual.

Finalmente, los resultados confirman que la simulación energética calibrada constituye una herramienta efectiva para evaluar el desempeño energético y tomar decisiones en edificaciones públicas, y aporta una base técnica para implementar estrategias de eficiencia energética en contextos similares. Este enfoque puede replicarse en otras edificaciones públicas con características similares.

AGRADECIMIENTOS

Los autores agradecen a la Universidad de El Salvador, en particular a la Escuela de Ingeniería Eléctrica, por el respaldo académico brindado. Asimismo, se reconoce el apoyo del personal del Centro Urbano de Bienestar y Oportunidades (CUBO) El Tamarindo por las facilidades brindadas para la obtención de datos experimentales.

REFERENCIAS

- American Society of Heating, Refrigerating and Air-Conditioning Engineers. (2022). Standard 90.1-2022: Energy standard for sites and buildings except low-rise residential buildings.
- Baransu. (2020, diciembre 6). ¿La ventilación natural de mi habitación es adecuada? <https://baransu.net/ventilacion-natural-es-adecuada/>
- Comisión Económica para América Latina y el Caribe (CEPAL). (2017). Eficiencia energética en América Latina y el Caribe: avances y desafíos del último quinquenio. <https://>

www.cepal.org/es/publicaciones/4106-eficiencia-energetica-america-latina-caribe-avances-desafios-ultimo-quinquenio

- Climate.OneBuilding.Org. (2022). Development of Global Typical Meteorological Years (TMYx). <https://climate.onebuilding.org>
- Clod Ensemble. (2025, diciembre 10). Open House: Clod Ensemble Studios. <https://www.clodensemble.com/whatson/open-house-clod-ensemble-studios>
- Consejo Nacional de Energía (CNE). (2007). Ley de Creación del Consejo Nacional de Energía. Asamblea Legislativa. https://www.asamblea.gob.sv/sites/default/files/documents/decretos/171117_072913170_archivo_documento_legislativo.pdf
- Consejo de Alcaldes y Oficina de Planificación del Área Metropolitana de San Salvador (COAMSS). (2018). Guía de Hábitats Urbanos Sostenibles del AMSS (HAUS). https://opamss.org.sv/wp-content/uploads/2021/10/GUIA_HAUS.pdf
- Centro Urbano de Bienestar y Oportunidades (CUBO). (2025, febrero). El Tamarindo – CUBO. Dirección de Reconstrucción del Tejido Social. <https://cubo.gob.sv/cubo/el-tamarindo>
- Cueva Villafranco, R. A. (2024). Análisis energético con énfasis en la eficiencia energética en los Centros Urbanos de Bienestar u Oportunidades, CUBO: estudio de caso Mejicanos, San Salvador (Tesis). Universidad de El Salvador.
- Dirección General de Energía, Hidrocarburos y Minas (DGEHM). (2017). Por la sostenibilidad energética en el sector público. <https://estadisticas.dgehm.gob.sv/wp-content/uploads/2017/09/por-la-sostenibilidad-energetica-en-el-sector-pblico.pdf>
- Dirección General de Energía, Hidrocarburos y Minas (DGEHM). (2025, julio 28). Manuales de uso eficiente de la energía. <https://estadisticas.dgehm.gob.sv/biblioteca/documentos-eficiencia-energetica/manuales-de-uso-eficiente-de-la-energia>
- Dirección General de Energía, Hidrocarburos y Minas (DGEHM). (2026, enero 15). Manuales de uso eficiente de la energía. <https://estadisticas.dgehm.gob.sv/biblioteca/documentos-eficiencia-energetica/manuales-de-uso-eficiente-de-la-energia>
- DIALux Community. (2025, diciembre 4). How to install the

- light shelf in Dialux. <https://community.dialux.com/get-support-with-dialux/post/how-to-install-the-light-shelf-in-dialux-S9PabHRWC7bCvR9>
- Eco Home Essentials. (2026). Is spray foam insulation any good?
- EnergyPlus. (2025). Weather data for El Salvador (WMO Region 4). https://energyplus.net/weather-region/north_and_central_america_wmo_region_4/SLV
- FASHIONSAP. (2011, mayo). どこまでOK?クールビズ、はるやま1030人に意. <https://www.fashionsnap.com/article/2011-05-17/haruyama-save-biz>
- Fermosell, R. S. (2014). Se presenta en asamblea legislativa el anteproyecto de ley de eficiencia energética en El Salvador. Suelosolar. <https://suelosolar.com/noticias/eficiencia-energetica/el-salvador/16-4-2014/se-presenta-asamblea-legislativa-anteproyecto-ley-eficiencia-energetica-salvador>
- Flensburg, G. (2020). Hacia la construcción de la pirámide energética. Universidad Nacional del Centro de la Provincia de Buenos Aires.
- GIZ/MEN. (2019). Guía para realizar una auditoría energética.
- Grau, J. S., & Ayerra, J. L. (2018). Pavimentos reflectantes para la mitigación del cambio climático.
- Greenroofs.com. (2026). Nanyang Technological University (NTU) School of Art, Design and Media. <https://www.greenroofs.com/projects/nanyang-technological-university-ntu-school-of-art-design-and-media-adm/>
- Hihausbm.com. (2025). Ventanas del triforio: ilumina tu hogar. <https://es.hihausbm.com/clerestory-windows>
- Hábitats Urbanos Sostenibles (HUB-HAUS). (2021, marzo 3). Sistemas de gestión de energía: una estrategia para alcanzar la eficiencia energética. <https://opamssproyectos.com/haus/blog/sistema-de-gestion-de-energia>
- Lallana, M. (2022). Eso fue lo que empezó a hacer Japón... [Tweet]. X. <https://x.com/MartinLallanaS/status/1526824141315362816>
- Liu, K. K., & Baskaran, B. A. (2005). Thermal performance of extensive green roofs.
- Ministerio de Energía (Chile). (2022). Plan Nacional de Eficiencia Energética 2022–2026. https://energia.gob.cl/sites/default/files/eficiencia-energetica_16-nov.pdf
- OpenStudio Coalition. (2025). Installation and introductory tutorial. https://openstudiocoalition.org/getting_started/getting_%20%20
- OpenStudio Manual. (2025). OpenStudio Interface Quick Start Guide.
- PRASPAN. (2026). PRASPAN® Паркинг. <https://praspan.ru/product/polimernye-nalivnye-poly/gotovye-resheniya-dlya-polimernykh-polov/praspan-parking>
- reevEnergy. (2012). Iluminación solar. <https://reevenergy.wordpress.com/2012/02/08/iluminacion-solar>
- Superintendencia General de Electricidad y Telecomunicaciones (SIGET). (2025). Pliegos tarifarios del suministro de energía eléctrica. <https://www.siget.gob.sv/download/los-pliegos-tarifarios-del-suministro-de-energia-electrica-al-consumidor-final-vigentes-del-15-de-enero-al-14-de-abril-de-2025>
- SketchUp Help. (2025). Descargar SketchUp. Trimble Inc. <https://help.sketchup.com/es/downloading-sketchup>
- U.S. Department of Energy. (2025). EnergyPlus downloads. <https://energyplus.net/downloads>
- Valle, A. M. (2018). Oportunidades en el entorno de la eficiencia energética. Bravo Comunicación.

Propuesta de adaptación de la norma IEEE std 602-2007 para la implementación de sistemas de alimentación eléctrica general y de emergencia en hospitales de El Salvador

Proposal for the adaptation of the IEEE std 602-2007 standard for the implementation of general and emergency electrical power supply systems in hospitals of El Salvador

Marcelo Antonio Martínez Mejía¹, Manuel Elías Granados Cruz¹, José Miguel Hernández¹.

¹ Universidad de El Salvador

Correspondencia: ✉ jose.hernandez2@ues.edu.sv
Enviado: **30 marzo 2026** Aceptado: **07 agosto 2026**

DOI: <https://doi.org/10.66778/CTI.v02n01.05>

PALABRAS CLAVE

Sistemas eléctricos hospitalarios; IEEE Std 602-2007; Energía de emergencia; Confiabilidad eléctrica; Seguridad del paciente; Normativa eléctrica (NEC 517); Calidad de energía; Infraestructura hospitalaria.

RESUMEN

La operación segura y continua de los hospitales depende en gran medida de la confiabilidad de sus sistemas eléctricos, especialmente en áreas críticas como quirófanos, unidades de cuidados intensivos, salas de emergencia y áreas de soporte vital. La norma IEEE Std 602-2007, conocida como White Book, constituye una referencia técnica especializada para el diseño y evaluación de instalaciones eléctricas en hospitales; sin embargo, su aplicación directa en El Salvador presenta limitaciones debido a diferencias normativas, técnicas y contextuales. En el país, el diseño hospitalario se rige principalmente por el National Electrical Code (NEC), en particular por el artículo 517, así como por criterios regulatorios y condiciones reales de infraestructura, mantenimiento y disponibilidad de recursos. Por ello, la presente investigación propone una adaptación técnica de la IEEE Std 602-2007 a la realidad salvadoreña, mediante un análisis comparativo con el NEC Artículo 517 y los lineamientos aplicables del contexto nacional. El estudio aborda criterios de continuidad del servicio, sistemas esenciales, áreas de atención crítica, puesta a tierra, equipotencialidad, aislamiento eléctrico y seguridad del paciente, con el fin de generar una guía útil para el diseño, evaluación y mejora de instalaciones eléctricas hospitalarias en El Salvador.

KEYWORDS

Hospital electrical systems; IEEE 602-2007 standard; Emergency power; Electrical reliability; Patient safety; Electrical regulations (NEC 517); Power quality; Hospital infrastructure.

ABSTRACT

The safe and continuous operation of hospitals largely depends on the reliability of their electrical systems, especially in critical areas such as operating rooms, intensive care units, emergency rooms, and life-support areas. IEEE Std 602-2007, known as the White Book, is a specialized technical reference for the design and evaluation of hospital electrical installations; however, its direct application in El Salvador presents limitations due to regulatory, technical, and contextual differences. In the country, hospital electrical design is mainly governed by the National Electrical Code (NEC), particularly Article 517, as well as local regulatory criteria and real infrastructure, maintenance, and resource conditions. Therefore, this research proposes a technical adaptation of IEEE Std 602-2007 to the Salvadoran reality through a comparative analysis with NEC Article 517 and applicable national conditions. The study addresses service continuity criteria, essential electrical systems, patient care areas, grounding, equipotential bonding, isolated power systems, and patient safety, in order to develop a practical guide for the design, evaluation, and improvement of hospital electrical systems in El Salvador.



INTRODUCCIÓN

En El Salvador, la infraestructura hospitalaria enfrenta retos que van desde la coexistencia de instalaciones nuevas y antiguas, limitaciones presupuestarias, disponibilidad de repuestos y equipos, hasta variaciones en la calidad del suministro eléctrico y la necesidad de asegurar mantenimientos preventivos y correctivos oportunos. Además, los proyectos y mejoras hospitalarias deben alinearse con normativa y prácticas aplicables en el país, lo cual exige criterios claros y adaptados a la realidad local. En muchos casos se utilizan estándares internacionales como referencia técnica, pero su aplicación literal puede no ser viable o no cubrir completamente las condiciones específicas del entorno salvadoreño (técnicas, operativas, económicas y de gestión).

En este marco, la norma IEEE Std 602 se reconoce como una guía técnica de alto valor para instalaciones eléctricas en centros de salud, ya que integra recomendaciones de confiabilidad, continuidad del servicio, seguridad, coordinación de protecciones y buenas prácticas para sistemas críticos. Sin embargo, su adopción efectiva en El Salvador requiere un proceso de adaptación que traduzca sus principios a lineamientos aplicables a hospitales locales, considerando el marco normativo equivalente, los criterios de diseño usados en la región y las condiciones reales de operación. Adicionalmente, resulta esencial contrastar dichas recomendaciones con lo establecido en códigos comúnmente utilizados para instalaciones hospitalarias, como las disposiciones de áreas de atención a la salud del NEC (Artículo 517) y normativas técnicas de aplicación local, con el fin de identificar convergencias, brechas y oportunidades de mejora.

METODOLOGÍA

La metodología empleada en esta investigación es de carácter documental y analítico, en primer lugar, se realiza una revisión de los capítulos 2, 3, 4, 5, 6 y 9 de la norma IEEE Std 602-2007 para identificar los criterios técnicos aplicables a sistemas eléctricos hospitalarios. Posteriormente, se analiza la normativa vigente en El Salvador, particularmente el NEC adoptado por SIGET en específico el Artículo 517, con el fin de determinar su alcance y limitaciones. Con base en esta revisión, se identifican brechas técnicas entre ambos marcos normativos y la realidad operativa de los hospitales en El Salvador debido al auge que ha tomado en los últimos años la realización de hospitales o clínicas médicas. Finalmente, se elabora una propuesta de adaptación de la IEEE Std 602-2007 y una guía técnica que sintetiza los criterios mínimos aplicables al diseño y mejora de sistemas de alimentación eléctrica general y de emergencia en hospitales del país.

Marco normativo IEEE Std 602

Es una práctica recomendada desarrollada por el Institute of Electrical and Electronics Engineers (IEEE) para orientar el diseño, operación y evaluación de los sistemas eléctricos en establecimientos de atención de salud. Su propósito es proporcionar criterios técnicos que contribuyan a garantizar la seguridad del paciente, la continuidad del servicio, la confiabilidad del suministro eléctrico y el adecuado desempeño de los sistemas en áreas críticas hospitalarias. Esta norma aborda aspectos como sistemas esenciales, respaldo eléctrico, puesta a tierra, equipotencialidad, coordinación de protecciones y buenas prácticas de diseño.

La norma IEEE Std 602-2007, conocida comúnmente como White Book, constituye una de las referencias técnicas más importantes a nivel internacional para el diseño de sistemas eléctricos en instalaciones hospitalarias. A diferencia de los códigos eléctricos de cumplimiento obligatorio, esta norma se presenta como una guía de prácticas recomendadas, cuyo objetivo principal es apoyar a ingenieros y diseñadores en la planificación de sistemas eléctricos confiables, seguros y adecuados para el entorno clínico.

La IEEE Std 602 no establece requisitos mínimos legales, sino que desarrolla criterios técnicos orientados a reducir fallas, mejorar la continuidad del servicio y minimizar riesgos eléctricos que puedan afectar la seguridad del paciente y del personal médico. Su enfoque parte del reconocimiento de que los hospitales son instalaciones complejas, con altos niveles de dependencia energética y con procesos que no admiten interrupciones imprevistas.

Entre los aspectos fundamentales que aborda la norma se encuentra la estimación y clasificación de las cargas eléctricas hospitalarias, considerando no solo la potencia instalada, sino también los patrones reales de uso, la simultaneidad de operación y el crecimiento futuro de la demanda. Este enfoque permite diseñar sistemas más realistas y evita tanto el sobredimensionamiento innecesario como la insuficiencia de capacidad.

El Código Eléctrico Nacional (NEC) constituye la base normativa para el diseño y ejecución de instalaciones eléctricas en El Salvador, siendo adoptado oficialmente y supervisado por la Superintendencia General de Electricidad y Telecomunicaciones (SIGET). Dentro de este código, el Artículo 517 está dedicado específicamente a los hospitales y establecimientos de atención médica, estableciendo los requisitos mínimos que deben cumplirse para garantizar la seguridad eléctrica y la continuidad del servicio.

A diferencia de otras instalaciones eléctricas convencionales, los hospitales presentan condiciones particulares debido a la presencia permanente de pacientes, equipos médicos sensibles y procedimientos que no admiten interrupciones del suministro eléctrico. Por esta razón, el Artículo 517 introduce criterios adicionales orientados a reducir riesgos eléctricos y asegurar un nivel básico de confiabilidad en la alimentación eléctrica.

NEC artículo 517

El NEC Artículo 517 es la parte del National Electrical Code que trata sobre las instalaciones eléctricas en establecimientos de atención de salud. Su alcance indica que aplica a los criterios de construcción e instalación eléctrica en hospitales, clínicas y otros espacios donde se brindan servicios de salud a las personas.

Sistemas esenciales eléctricos

Uno de los ejes principales del análisis es el estudio de los sistemas esenciales eléctricos en hospitales, debido a su importancia para mantener operativas las cargas indispensables durante fallas del suministro normal. En la tesis, este punto se aborda como un elemento clave para garantizar continuidad del servicio en áreas donde una interrupción puede comprometer la atención médica, por lo que resulta necesario revisar cómo la IEEE Std 602 y el NEC Artículo 517 tratan su organización, funcionamiento y prioridad dentro de la infraestructura hospitalaria.

El artículo también debe considerar las áreas críticas hospitalarias, entendidas como aquellos espacios donde la energía eléctrica tiene una relación directa con la seguridad del paciente y la continuidad de procedimientos clínicos. Este aspecto es coherente con la tesis, ya que permite enfocar el análisis en sitios como quirófanos, unidades de cuidados intensivos, emergencia y otras áreas de atención prioritaria, donde los criterios eléctricos deben ser más estrictos y confiables.

Continuidad del servicio

La continuidad del servicio se refiere a la capacidad del sistema eléctrico para operar sin interrupciones. En instalaciones hospitalarias este parámetro es esencial, ya que la interrupción del suministro puede afectar procedimientos quirúrgicos, comprometer la operación de equipos de soporte vital o interrumpir sistemas de monitoreo clínico. Para mantener la continuidad se requiere que el sistema cuente con rutas alternativas de alimentación, sistemas de transferencia confiables, unidades UPS para cargas vitales y una estructura de mantenimiento preventivo que reduzca el riesgo de fallas inesperadas.

Puesta a tierra

La puesta a tierra en instalaciones hospitalarias es un elemento esencial para la seguridad eléctrica, especialmente en áreas donde los pacientes están expuestos a equipos médicos invasivos o monitores conectados directamente al cuerpo. A diferencia de edificaciones convencionales, en un hospital incluso pequeñas corrientes de fuga pueden representar riesgos fisiológicos graves, por lo que los requisitos de diseño y equipotencialidad son más estrictos.

La IEEE Std 602-2007 y el NEC 517 establecen lineamientos específicos para minimizar riesgos de microchoque, estabilizar los niveles de voltaje y garantizar un entorno seguro para pacientes y personal.

Los sistemas de puesta a tierra en hospitales cumplen las siguientes funciones fundamentales:

- Limitar corrientes de falla y permitir la operación adecuada de los dispositivos de protección.
- Estabilizar los niveles de tensión en condiciones normales y de falla.
- Reducir diferencias de potencial entre estructuras metálicas y equipos médicos.
- Evitar que pequeñas corrientes de fuga fluyan a través del cuerpo del paciente.
- Contribuir a la continuidad operativa de sistemas aislados tipo IT utilizados en quirófanos.

Equipotencialidad en áreas críticas

La equipotencialidad consiste en interconectar todos los elementos metálicos accesibles dentro de un área clínica tales como camillas, equipos médicos, bandejas, luminarias, soportes y tuberías mediante conductores que aseguren un potencial eléctrico común.

En áreas críticas como:

- Quirófanos.
- Unidades de cuidados intensivos.
- Salas de procedimientos invasivos.
- Laboratorios de cateterismo.
- Salas de partos.
-

La equipotencialidad es indispensable para evitar corrientes de paso que puedan fluir hacia el paciente por diferencias mínimas de voltaje entre partes metálicas en contacto.

El NEC 517 exige sistemas equipotenciales estrictos en estas zonas debido a la posibilidad de microchoques en pacientes con electrodos, catéteres o equipos conectados al sistema cardiovascular.

Respaldo y emergencia

El sistema de emergencia es la fuente alternativa que garantiza la continuidad del suministro eléctrico ante una falla de la fuente normal. Está conformado por:

- Generador de emergencia, encargado de suministrar energía cuando la red pública falla
- Interruptores de transferencia automática (ATS) que detectan la pérdida del suministro normal y conmutan la carga hacia el generador
- Sistemas UPS que proporcionan energía inmediata y sin interrupciones a equipos de soporte vital mientras el generador entra en operación
- Tableros de emergencia desde los cuales se distribuye la energía hacia las ramas del Sistema Esencial definidas en el NEC 517
- Sistemas de supervisión, control y combustible, necesarios para garantizar arranque confiable y operación continua.

El tiempo de transferencia varía de acuerdo con la criticidad de la carga:

- <1 segundo: cargas alimentadas por UPS (equipos vitales).
- 10 segundos: cargas esenciales transferidas mediante ATS.

Su funcionamiento adecuado es indispensable para garantizar la continuidad operativa en áreas críticas como quirófanos, UCI, laboratorios y salas de parto.

Diagnóstico del sistema eléctrico hospitalario en El Salvador

Condiciones actuales típicas

Los tableros eléctricos saturados o sin capacidad adecuada de segregación dificultan la correcta separación de circuitos correspondientes a las ramas esenciales, especialmente en lo que respecta a las cargas críticas frente a las cargas del sistema normal. A esta problemática se suma la presencia de canalizaciones y empalmes intervenidos sin control técnico, lo que incrementa el riesgo de fallas, complica la trazabilidad de los circuitos y debilita la capacidad de auditar el cumplimiento normativo. Asimismo, la identificación deficiente de los sistemas eléctricos, evidenciada por la ausencia de rotulación, diagramas unifilares actualizados y una adecuada relación entre carga, circuito y tablero, provoca que la separación de sistemas exista únicamente a nivel teórico, mientras que

en la práctica resulta frágil e ineficiente.

En El Salvador, la regulación técnica de instalaciones eléctricas recae en SIGET, posteriormente sujeta a las OIA que son los organismos de inspección acreditados que adopta el Código eléctrico Nacional (NEC) como marco normativo obligatorio. Para instalaciones hospitalarias, el Artículo 517 del NEC es el único referente técnico disponible. No obstante, este artículo ofrece directrices generales y no abarca especificaciones detalladas para aspectos críticos como sistemas de distribución redundantes, perfiles de carga hospitalarios, sistemas aislados y diseño de sistemas de emergencia.

La realidad nacional refleja limitaciones en mantenimiento eléctrico, ausencia de sistemas especializados para áreas críticas, deficiencias en mecanismos de transferencia automática y falta de criterios técnicos actualizados para modernizar hospitales.

Actualmente no existe una adaptación en El Salvador que armonice la IEEE Std 602-2007 con la normativa vigente ni con las condiciones operativas reales de los hospitales, por lo que se vuelve necesario proponer una adaptación técnica que permita aplicar criterios internacionales de manera viable en el país.

Condiciones típicas de hospitales

La evaluación eléctrica no debe limitarse a verificar existencia de energía o cumplimiento de instalación en términos generales, porque un hospital opera como infraestructura crítica: la energía eléctrica es soporte directo de seguridad de vida, atención clínica y continuidad operativa. Por ello, el análisis normativo se fundamenta en:

- Los requerimientos hospitalarios del NEC 517, que estructuran el concepto de sistema eléctrico esencial y su separación funcional en ramas, así como el desempeño esperado ante pérdida de la fuente normal (transferencia automática para sostener funciones esenciales).
- El marco nacional se respalda en la adopción por referencia del NEC 2008 por SIGET y un esquema de revisión e inspección donde se verifican elementos técnicos típicos como puesta a tierra, tableros, canalizaciones, empalmes, separación de circuitos y polarización de tomacorrientes.

Bajo esta base, el diagnóstico del hospital público salvadoreño suele evidenciarse como una brecha entre lo normativo-funcional (continuidad por criticidad) y lo normativo instalativo (componentes y seguridad básica). Lo anterior no significa que no exista normativa, sino que el cumplimiento tiende a concentrarse en lo verificable por componentes (instalación)

y menos en lo verificable por desempeño (continuidad, segregación y sostenibilidad del sistema esencial).

Variaciones en calidad del suministro

La calidad del suministro eléctrico se refiere al nivel de estabilidad y pureza de la energía entregada a los equipos. Este parámetro incluye diversos aspectos que influyen directamente en la operación del hospital.

Las distorsiones armónicas son generadas por equipos electrónicos y pueden producir sobrecalentamiento en transformadores y fallas en protecciones. Las fluctuaciones rápidas de voltaje afectan la iluminación quirúrgica y las pantallas de monitoreo. Los transitorios de alta energía, ocasionados por descargas atmosféricas o maniobras en la red, pueden dañar equipos de diagnóstico y sistemas de soporte vital. Finalmente, la regulación deficiente del voltaje reduce la precisión y confiabilidad de equipos sensibles.

Una adecuada calidad del suministro contribuye a prolongar la vida útil de los equipos médicos, mejorar la confiabilidad de los diagnósticos y proteger los sistemas electrónicos utilizados en atención al paciente.

Falta de lineamientos específicos adaptados al país

La falta de lineamientos específicos adaptados al país dificulta que los hospitales cuenten con criterios técnicos unificados para diseñar, evaluar y mejorar sus sistemas eléctricos según la realidad salvadoreña. Esto provoca que, en muchos casos, se utilicen referencias internacionales de forma general, sin una adaptación clara a las condiciones locales. Como resultado, pueden surgir diferencias en la forma de diseñar, mantener o modernizar las instalaciones eléctricas hospitalarias.

Además, esta ausencia de criterios nacionales específicos limita la posibilidad de establecer prioridades técnicas comunes para áreas críticas, sistemas de respaldo y medidas de seguridad eléctrica. Por ello, se vuelve necesario contar con lineamientos que traduzcan las buenas prácticas internacionales a un marco más aplicable al contexto hospitalario de El Salvador.

Brechas entre norma ideal y realidad operativa

La IEEE Std 602 se plantea como una práctica recomendada para aplicar ingeniería sólida en el diseño y la operación de sistemas eléctricos en instalaciones de atención a la salud, es decir, orienta a que el sistema se conciba y se gestione “por desempeño” (continuidad, seguridad y confiabilidad), más que solo “por cumplimiento de instalación”. En El Salvador,

aunque existe una base técnica relevante para instalaciones de usuarios finales (adopción por referencia del NEC 2008 como estándar técnico), el entorno hospitalario público suele enfrentar limitaciones de infraestructura, expansión por etapas y recursos, lo que hace que ciertos elementos de desempeño queden incompletos o implementados de forma parcial. Bajo esta comparación, la brecha de “requisitos técnicos no implementados” no debe interpretarse únicamente como ausencia de equipos, sino como ausencia de una arquitectura integral y de prácticas de operación que permitan garantizar continuidad y seguridad de manera verificable.

Una primera brecha técnica aparece en la arquitectura de distribución y segregación funcional. Un enfoque hospitalario por desempeño requiere que la distribución refleje la criticidad: separación clara entre alimentación normal y esencial/emergencia, tableros diferenciados para cargas críticas y rutas de alimentación consistentes. Cuando la infraestructura ha crecido por etapas, se vuelve frecuente que la segregación sea incompleta: tableros “mixtos”, circuitos críticos compartiendo protecciones con cargas no críticas, o dependencia de ampliaciones “parche” que no respetan una jerarquía de prioridades. En términos de desempeño, esto vuelve frágil la continuidad, porque una falla localizada o una sobrecarga en una parte no crítica puede afectar áreas donde no debería.

Una segunda brecha está relacionada con la selectividad y coordinación de protecciones, que es un componente esencial del desempeño hospitalario: no solo importa que las protecciones disparen, sino que disparen las

correctas, en el orden correcto, para evitar apagones amplios ante fallas puntuales. En hospitales públicos, cuando no se realizan ajustes de coordinación en protecciones o cuando la distribución se modifica sin revalidar curvas y niveles de protección, se incrementa el riesgo de disparos no selectivos (es decir, que se desconecte una zona completa por una falla menor). Este problema es crítico porque convierte fallas comunes (sobrecargas locales, cortocircuitos en tomas, fallas en equipos) en interrupciones con impacto clínico.

Una tercera brecha se observa en la capacidad de expansión sin degradar el sistema. IEEE 602, al ser guía de diseño y operación, empuja a considerar el sistema como un ciclo de vida: crecimiento de carga, redistribución de servicios clínicos, incorporación de equipos biomédicos y cambios de uso de áreas. En la práctica, en hospitales con expansión incremental, la incorporación de nuevas cargas suele resolverse con derivaciones y ampliaciones parciales (más circuitos, más tableros pequeños, empalmes y canalizaciones adicionales) sin que se refuerce de forma proporcional la capacidad de alimentadores principales, la selectividad, la documentación técnica y la estructura de segregación. Esto produce un desequilibrio: el hospital aumenta su dependencia eléctrica (más

equipos y más criticidad), pero el sistema de distribución no madura al mismo ritmo.

Una cuarta brecha técnica relevante es la calidad de energía y protección de equipos sensibles. Un enfoque por desempeño no se limita a evitar apagones; también busca minimizar perturbaciones eléctricas (transitorios, variaciones de tensión, armónicos) que afectan directamente equipos biomédicos y sistemas de control. Cuando no se incorporan medidas sistemáticas de calidad de energía (por ejemplo, criterios de protección contra transitorios, revisión de cargas no lineales y su impacto, control de caídas de tensión en circuitos críticos), el hospital queda expuesto a fallas “silenciosas”: equipos que reinician, alarmas falsas, degradación de fuentes conmutadas, daños repetitivos o comportamiento errático, incluso sin pérdida total del suministro.

Finalmente, una quinta brecha transversal es la ausencia de una estructura integral demostrable: unifilar actualizado, trazabilidad carga-circuito-tablero-fuente, control de cambios, y criterios operativos (qué se respalda, qué se transfiere, qué se prioriza). IEEE 602 se usa como guía justamente para convertir el sistema eléctrico en un sistema “gestionable” y no solo “existente”. En entornos donde la documentación y el control de cambios no acompañan a la expansión, la continuidad puede depender de conocimiento informal (“el electricista sabe qué breaker es”), lo cuál es frágil ante rotación de personal, emergencias y fallas simultáneas.

Propuesta de adaptación de la IEEE Std 602-2007 al contexto salvadoreño

La propuesta de adaptación surge del contexto definido en los primeros artículos de la norma propuesta. Su origen se encuentra, en primer lugar, en el Artículo 1, donde se establece que la norma busca regular el diseño, instalación, operación, verificación, mantenimiento y mejora continua de los sistemas eléctricos en establecimientos hospitalarios y de atención a la salud en El Salvador. Luego, el Artículo 2 da el sentido de la propuesta al plantear como finalidad la continuidad del suministro para cargas críticas, la reducción de interrupciones por fallas localizadas, la mitigación de riesgos eléctricos en áreas de atención al paciente y la trazabilidad técnica y operativa del sistema. A esto se suma el Artículo 3, que delimita el ámbito de aplicación en hospitales, áreas con procedimientos invasivos y proyectos nuevos o de adecuación, mientras que el Artículo 4 define su carácter como una referencia técnica nacional complementaria a la normativa obligatoria vigente. Finalmente, el Artículo 5 aporta el enfoque bajo el cual se desarrolla toda la propuesta, al establecer principios rectores como la prioridad clínica por criticidad, la

continuidad operativa verificable, la gestión eficiente de cargas, la reducción de puntos únicos de falla y la mejora gradual por fases. De esta manera, la propuesta de adaptación no surge de forma aislada, sino de una base normativa interna que justifica su orientación técnica y su adecuación al contexto hospitalario salvadoreño.

Criterios prioritarios para áreas críticas

Uno de los elementos fundamentales de la propuesta es la adopción del principio de prioridad clínica por criticidad, el cual permite clasificar tanto las áreas hospitalarias como las cargas eléctricas según su impacto en la seguridad del paciente y la continuidad de la atención médica.

En este sentido, se propone una clasificación de áreas en tres niveles: áreas críticas, áreas clínicas generales y áreas de soporte. Las áreas críticas incluyen espacios como quirófanos, unidades de cuidados intensivos y salas de emergencia, donde la interrupción del suministro eléctrico puede comprometer directamente la vida del paciente. Por su parte, las áreas clínicas generales comprenden espacios de hospitalización y consulta, mientras que las áreas de soporte corresponden a servicios auxiliares.

De manera complementaria, se establece una clasificación de cargas eléctricas en diferentes niveles de prioridad, permitiendo definir cuáles deben mantenerse en operación durante fallas del suministro normal. Este enfoque facilita la toma de decisiones en el diseño del sistema eléctrico esencial y en la asignación de recursos de respaldo.

Organización del sistema eléctrico esencial y respaldo

La propuesta plantea la necesidad de estructurar el sistema eléctrico hospitalario de acuerdo con la criticidad de las cargas, garantizando una separación clara entre el sistema normal y el sistema esencial o de emergencia.

Para ello, se recomienda la implementación de una arquitectura de distribución que contemple tableros diferenciados para cada tipo de carga, tales como el Tablero General Normal (TGN) y el Tablero General Crítico o de Emergencia (TGC/TGE). Esta segregación permite evitar la interdependencia entre cargas críticas y no críticas, reduciendo el riesgo de interrupciones innecesarias.

En cuanto al sistema de respaldo, se establece la incorporación de una fuente alterna principal, generalmente mediante generadores eléctricos, complementada con sistemas de transferencia automática (ATS) que permitan la conmutación

oportuna ante fallas del suministro normal. Asimismo, se recomienda el uso de sistemas de alimentación ininterrumpida (UPS) para cargas de alta criticidad que requieren continuidad inmediata.

Adicionalmente, se deben considerar criterios de estabilidad posterior a la transferencia, secuenciamiento de cargas y estrategias de deslastre, con el fin de garantizar una operación segura y eficiente del sistema durante condiciones de emergencia.

Puesta a tierra y equipotencialidad

La seguridad eléctrica del paciente constituye un eje central de la propuesta, por lo que se enfatiza la necesidad de fortalecer los sistemas de puesta a tierra y equipotencialidad en instalaciones hospitalarias.

Se propone asegurar la continuidad del conductor de protección, así como la correcta implementación de sistemas de puesta a tierra que permitan limitar corrientes de falla y estabilizar los niveles de tensión. Asimismo, se recomienda la aplicación de equipotencialidad suplementaria en áreas críticas, mediante la interconexión de todos los elementos metálicos accesibles, con el objetivo de reducir diferencias de potencial que puedan generar corrientes de paso peligrosas para el paciente.

Estas medidas son especialmente relevantes en espacios donde se realizan procedimientos invasivos o donde los pacientes se encuentran conectados a equipos médicos.

Mantenimiento preventivo

La propuesta incluye la implementación de un programa institucional de mantenimiento preventivo, orientado a garantizar el correcto funcionamiento del sistema eléctrico hospitalario a lo largo del tiempo.

Este programa debe contemplar la definición de frecuencias mínimas de inspección y prueba, la elaboración de bitácoras técnicas obligatorias y la verificación periódica de equipos críticos como generadores, sistemas de transferencia automática y UPS. Asimismo, se recomienda la realización de auditorías internas que permitan identificar fallas, evaluar el desempeño del sistema y establecer acciones de mejora continua.

La documentación de estas actividades resulta fundamental para asegurar la trazabilidad del sistema y reducir la dependencia de conocimiento informal.

Lineamientos prácticos para hospitales existentes

Considerando las limitaciones técnicas y económicas del sistema hospitalario salvadoreño, la propuesta incorpora un enfoque de adecuación progresiva basado en fases.

En una primera fase, se prioriza el cumplimiento de condiciones mínimas de seguridad y continuidad para cargas críticas. Posteriormente, se plantea una segunda fase orientada a mejorar la confiabilidad del sistema mediante la reorganización de la distribución eléctrica y la corrección de deficiencias técnicas. Finalmente, una tercera fase contempla la modernización y la incorporación de redundancia en aquellos casos donde sea técnica y económicamente viable.

Este enfoque permite adaptar los sistemas eléctricos hospitalarios sin requerir intervenciones inmediatas de gran escala, facilitando su implementación en el contexto nacional.

Mayor Continuidad del servicio

Las tablas presentadas apoyan este resultado, ya que permiten registrar y verificar el desempeño del ATS durante una prueba, comprobar la respuesta del sistema de emergencia, confirmar la operación de las cargas críticas y documentar hallazgos, acciones correctivas y cierre. En conjunto, estos formatos contribuyen a evaluar si el sistema eléctrico mantiene la continuidad del servicio ante una pérdida de la fuente normal.(Figuras de la 1 a la 9 de elaboración propia)

Figura 1

Formato de bitácora de prueba ATS(transferencia automática).

Establecimiento	_____
Ubicación / Área	_____
Fecha	___/___/___
Hora inicio	_____
Hora fin	_____
Responsable de prueba (Nombre / Cargo)	_____
Personal de apoyo (si aplica)	_____
Área / Rama	☐ Seguridad de vida ☐ Crítica ☐ Equipos
ATS identificado como	_____
Fuente normal (SAN)	_____
Fuente de emergencia (SEEm)	☐ Generador ☐ UPS ☐ Mixto
Condición de prueba	☐ Simulación pérdida SAN ☐ Prueba programada ☐ Evento real (describir): _____
Tipo de transferencia	☐ Automática ☐ Manual controlada (si aplica)

Tiempo de arranque del generador (s)	_____ s
Tiempo de transferencia ATS (s)	_____ s
Tiempo de estabilización (si aplica) (s)	_____ s
Tiempo de retransferencia a SAN (s)	_____ s

Tensión (V)	Frecuencia (Hz)	Corriente (A) (si aplica)	Observaciones breves
_____	_____	_____	_____

Alarmas / disparos / ruidos / calentamiento (describir):

Cargas que NO operaron como se esperaba (equipo / ubicación):

1) _____

2) _____

3) _____

4) _____

5) _____

Cargas operaron correctamente: ☐ Sí ☐ No

Hallazgos identificados:

Acción correctiva requerida:

Responsable de ejecutar acción correctiva	_____
Fecha compromiso de cierre	____/____/____
Fecha de cierre	____/____/____
Evidencia adjunta (foto/lecturas)	☐ Sí ☐ No Descripción: _____
Firma responsable de prueba	_____
Firma responsable de mantenimiento	_____

Código del formato: NT-SEH/ES-SEEm-PRO-01

Establecimiento	_____
Fecha	____/____/____
Ventana de prueba (inicio-fin)	_____ a _____
Responsable (Nombre / Cargo)	_____
Áreas afectadas	_____

1. PREPARACIÓN

- Notificar a jefaturas clínicas y mantenimiento, confirmar autorización para prueba.
- Confirmar identificación de cargas críticas (Clase 1 y Clase 2) y presencia de personal clínico informado.
- Verificar combustible, alarmas activas, estado de baterías y cargador del generador.
- Asegurar disponibilidad de EPP, señalización y herramientas básicas, definir punto seguro para simular pérdida de SAN.

2. EJECUCIÓN DE LA PRUEBA

- Simular pérdida de SAN según el punto definido (sin comprometer la seguridad del paciente).
- Registrar tiempos: arranque del generador, transferencia ATS y estabilización.
- Verificar operación de cargas críticas por área (checklist por servicio).

Hallazgos y acciones correctivas (adjuntar bitácoras ATS, registro del generador y evidencia):

Evidencia adjunta	☐ Bitácora ATS ☐ Checklist generador ☐ Lecturas V/Hz ☐ Fotos ☐ Otros: _____
Firma responsable de prueba	_____
Firma responsable de mantenimiento	_____

Ruta de adecuación del sistema eléctrico hospitalario

Se requiere contar con un diagrama unifilar actualizado y una rotulación completa de los sistemas eléctricos, diferenciando claramente las fuentes de alimentación (normal y de emer-

gencia) y los niveles de criticidad (seguridad de vida, cargas críticas y equipos). Asimismo, es indispensable disponer de un inventario detallado de cargas críticas por área clínica, como UCI, quirófanos, emergencias y hospitalización, junto con la correcta identificación del Tablero General Normal (TGN) y del Tablero General Crítico o de Emergencia (TGC/TGE), incluyendo su respectiva matriz de relación entre carga, circuito, tablero y fuente.

De igual forma, se debe garantizar una segregación efectiva entre el TGN y el TGC/TGE mediante el uso de tableros y circuitos dedicados, evitando la mezcla de cargas no esenciales con cargas críticas. Esto implica la liberación o sustitución de tableros en áreas críticas para habilitar circuitos exclusivos, así como la corrección de canalizaciones y empalmes que comprometan la continuidad, la trazabilidad y la seguridad del sistema. También es fundamental la sustitución priorizada de tomacorrientes por dispositivos de grado hospitalario, junto con una identificación visible que distinga claramente entre tomas de energía normal y de emergencia en las áreas de atención al paciente.

Adicionalmente, es necesario reorganizar los alimentadores y la arquitectura del sistema eléctrico de manera que la criticidad de las cargas se refleje en la distribución, evitando que los sistemas esenciales dependan de rutas improvisadas. Se recomienda la instalación de supresores de transientes (DPS/SPD) en configuración en cascada, ubicados en la entrada de servicio, tableros principales y tableros críticos según el nivel de criticidad. En áreas donde el riesgo clínico lo requiera, como quirófanos o espacios de procedimientos específicos, debe considerarse la implementación de paneles de aislamiento conforme a los criterios normativos y de diseño hospitalario. Finalmente, se deben realizar pruebas funcionales documentadas, incluyendo la transferencia a sistemas de emergencia, la verificación de energización de cargas críticas y el registro sistemático de estos procesos en bitácoras técnicas, con el fin de asegurar la confiabilidad y el cumplimiento del sistema eléctrico hospitalario.

RESULTADOS ESPERADOS

Como resultado, se espera contar con una referencia técnica más clara para el análisis de los sistemas eléctricos hospitalarios en El Salvador, tomando como base la comparación entre la IEEE Std 602 y los criterios aplicables del entorno nacional. La propuesta busca fortalecer la continuidad del suministro para cargas críticas, reducir interrupciones localizadas y mitigar riesgos eléctricos en áreas de atención al paciente, que justamente son finalidades centrales de la norma propuesta.

Asimismo, se espera facilitar la organización técnica de los

hospitales mediante la clasificación de áreas y cargas, la definición del sistema eléctrico esencial y del sistema de energía de emergencia, así como la incorporación de pruebas funcionales, bitácoras, mantenimiento preventivo y trazabilidad documental. Esto permitiría que el desempeño del sistema no dependa solo de la experiencia informal del personal, sino de criterios verificables y procedimientos documentados.

Finalmente, se espera que la propuesta sirva como apoyo para la adecuación progresiva de hospitales existentes, ya que plantea mejoras por fases: primero el cumplimiento crítico mínimo, luego la confiabilidad y el ordenamiento, y posteriormente la modernización y redundancia donde sea viable. En términos prácticos, esto puede traducirse en mejor seguridad del paciente, mayor continuidad del servicio y mejores bases para el diseño, evaluación y mejora continua de las instalaciones hospitalarias.

CONCLUSIÓN

La continuidad del servicio eléctrico en hospitales no debe evaluarse solo por el cumplimiento de instalación, sino por su capacidad real de sostener las cargas críticas asociadas a la seguridad del paciente. La arquitectura del sistema debe responder a la criticidad de las cargas, priorizando aquellas vinculadas con soporte vital, atención clínica y seguridad de vida, mediante soluciones de respaldo verificables y medibles. En el contexto salvadoreño, el problema principal no es únicamente la existencia o ausencia de equipos de respaldo, sino la falta de integración técnica del sistema eléctrico hospitalario. La confiabilidad depende de la correcta segregación de cargas, la coordinación entre protecciones, la secuencia funcional entre ATS, generador y UPS, y la aplicación de pruebas y registros documentados que permitan verificar su desempeño real.

La adaptación de la IEEE Std 602-2007 al contexto hospitalario salvadoreño constituye una respuesta técnica viable frente a las brechas identificadas entre la referencia internacional y las condiciones reales de operación de los hospitales. Su principal aporte es orientar el diseño, la verificación y la mejora progresiva de los sistemas eléctricos hospitalarios mediante criterios de criticidad, continuidad, trazabilidad y desempeño comprobable.

La implementación de esta ruta de adecuación permite transformar progresivamente los sistemas eléctricos hospitalarios desde un enfoque basado en cumplimiento de instalación hacia un enfoque basado en desempeño, alineado con los principios establecidos en la IEEE Std 602-2007

Equipos y Laboratorio. (s. f.). Seguridad eléctrica. <https://www.equiposylaboratorio.com/portal/articulo-ampliado/seguridad-electrica>

REFERENCIAS

IEEE, "IEEE Recommended Practice for Electric Systems in Health Care Facilities (IEEE Std 602-2007)," IEEE, 2007.

NFPA, "National Electrical Code (NFPA 70)," National Fire Protection Association, 2017.

A. Farina, "Distribución de la energía eléctrica en instalaciones de potencia," Revista Ingeniería Eléctrica, no. 323, ago. 2017.

Editores, "Por qué elegir un monitor por impedancia en líneas aisladas hospitalarias," 2022. [En línea]. Disponible: https://www.editores.com.ar/empresa/servelec/20220425_por_que_elegir_un_monitor_por_impedancia_en_lineas_aisladas_hospitalarias.

AmcareMed, "Sistemas de llamada de enfermería: BUS/SCS, IP, y inalámbrico." [En línea]. Disponible: <https://amcaremed.com/comprehensive-guide-medical-nurse-call-systems/?lang=es>.

Casalima Group. (s. f.). ¿Qué es un tomacorriente hospitalario? <https://grupocasalima.com/blog/electricidad/que-es-un-tomacorriente-hospitalario/>

Circuito Eléctrico. (s. f.). Conexión equipotencial: Qué es y normativa en baños. <https://circuitoelectrico.com/instalaciones-puesta-tierral/conductores-equipotencialidad/>

Circuito Eléctrico. (s. f.). Interruptor automático (breaker): Curvas, tipos y selectividad. <https://circuitoelectrico.com/elementos-proteccion-electrica/interruptor-automatico/>

Eléctrica Aplicada. (s. f.). Qué significan los grados y tipos en los tomacorrientes eléctricos. <https://electricaplicada.com/que-significan-los-grados-y-tipos-en-los-tomacorrientes-electricos-generales-hospitalarios-federales-etc/>

Ensys. (s. f.). Conectores y puesta a tierra en sistemas eléctricos. <https://ensys.pe/articulos/conector/conectores-11tierra.html>



**UNIVERSIDAD DE EL SALVADOR
FACULTAD DE INGENIERÍA Y ARQUITECTURA**

Ciudad Universitaria "Dr. Fabio Castillo Figueroa", Final Avenida "Mártires Estudiantes del 30 de julio", San Salvador,
El Salvador, América Central.

cti.fia@ues.edu.sv