

Desarrollo de un prototipo basado en Inteligencia Artificial para el reconocimiento eficiente de momentos de inactividad en laboratorios de computadoras**Development of an Artificial Intelligence-based prototype for the efficient recognition of inactivity periods in computer laboratories**

Ivan Leonel Acosta Guzmán, Mario Alfredo Sebastián Sánchez Delgado, Angel Marcel Plaza Vargas, Letsy Geanela Piloza Rodríguez & Fernando Antonio Cox López

PUNTO CIENCIA.**julio - diciembre, V°6 - N°2; 2025****Recibido:** 20-11-2025**Aceptado:** 24-11-2025**Publicado:** 27-11-2025**PAIS**

- Ecuador, Guayaquil
- Ecuador, Guayaquil
- Ecuador, Guayaquil
- Ecuador, Guayaquil
- Ecuador, Guayaquil

INSTITUCION

- Universidad de Guayaquil
- Universidad de Guayaquil
- Universidad de Guayaquil
- Universidad de Guayaquil
- Universidad de Guayaquil

CORREO:

- ✉ ivan.acostag@ug.edu.ec
- ✉ mario.sanchezd@ug.edu.ec
- ✉ angel.plazav@ug.edu.ec
- ✉ letsy.pilozor@ug.edu.ec
- ✉ fernando.coxl@ug.edu.ec

ORCID:

- 🌐 <https://orcid.org/0000-0002-1589-1825>
- 🌐 <https://orcid.org/0000-0002-3490-4628>
- 🌐 <https://orcid.org/0000-0002-4617-153X>
- 🌐 <https://orcid.org/0009-0003-9250-386X>
- 🌐 <https://orcid.org/0000-0002-3068-8323>

FORMATO DE CITA APA.

Acosta, I., Sánchez, M., Plaza, A., Piloza, L. & Cox, F. (2025). Desarrollo de un prototipo basado en Inteligencia Artificial para el reconocimiento eficiente de momentos de inactividad en laboratorios de computadoras. *Revista G-ner@ndo*, V°6 (N°2). Pág. 3210 – 3222.

Resumen

El consumo innecesario de energía y la falta de mecanismos automáticos para gestionar la inactividad en laboratorios universitarios representan un reto relevante para la sostenibilidad y eficiencia operativa. Con el objetivo de abordar este problema, se desarrolló un prototipo de software basado en Aprendizaje Profundo (Deep Learning) que integra modelos LSTM y CNN para el análisis multimodal combinado de datos computacionales e imágenes captadas en tiempo real, permitiendo reconocer periodos de inactividad y automatizar el apagado seguro de los equipos. La validación experimental se realizó en laboratorios de la Universidad de Guayaquil, empleando una metodología de investigación cuantitativa y metodología de Ciencia de Datos CRISP-DM, se recolectaron los datos localmente. Entre los principales hallazgos, el sistema logró una reducción significativa en el consumo energético (estimada entre el 10% y el 17%), un F1-score superior a 0.98 en la detección, y una aceptación positiva por parte de más del 70% de los usuarios encuestados. Se concluye que la solución desarrollada aporta una herramienta robusta y adaptable para la gestión eficiente de recursos en entornos educativos universitarios, evidenciando su potencial como alternativa transferible y escalable. Futuras líneas de trabajo contemplan la expansión del prototipo a otros contextos institucionales y la integración de módulos avanzados de monitoreo y reporte automático.

Palabras clave: Visión por computadora, Aprendizaje Profundo, Eficiencia Energética, Automatización, Gestión de Laboratorios.

Abstract

Unnecessary energy consumption and the lack of automatic mechanisms to manage inactivity in university laboratories present a significant challenge for sustainability and operational efficiency. To address this problem, a software prototype based on Deep Learning was developed, integrating LSTM and CNN models for multimodal analysis of both computational data and real-time captured images, enabling the recognition of inactivity periods and the automated, safe shutdown of equipment. Experimental validation was conducted in laboratories at the University of Guayaquil using a quantitative research methodology and the CRISP-DM Data Science standard, with data collected locally. Key findings include a significant reduction in energy consumption (estimated between 10% and 17%), an F1-score above 0.98 for inactivity detection, and positive acceptance by more than 70% of surveyed users. It is concluded that the developed solution provides a robust and adaptable tool for the efficient management of resources in university educational environments, evidencing its potential as a transferable and scalable alternative. Future work will focus on expanding the prototype to other institutional contexts and integrating advanced monitoring and automated reporting modules.

Keywords: Computer Vision, Deep Learning, Energy Efficiency, Automation, Laboratory Management.

Introducción

El uso eficiente de los recursos tecnológicos en instituciones educativas es fundamental para garantizar la sostenibilidad y la adecuada operación de los espacios de aprendizaje (Wilhelm & Wahl, 2024). En los laboratorios universitarios, la presencia de equipos encendidos durante largos periodos sin actividad representa un desafío operativo relevante, pues incrementa el consumo energético y contribuye al desgaste prematuro del equipamiento (Shehabi et al., 2024)

Diversos estudios han subrayado la importancia de implementar mecanismos automatizados inteligentes que permitan gestionar de forma eficiente estos recursos y avanzar hacia una cultura tecnológica institucional responsable (Wei Zhang et al., 2022). A pesar de estos avances, existe una demanda persistente de soluciones que no solo detecten períodos reales de inactividad, sino que sean capaces de integrarse a los flujos académicos y administrativos con mínima intervención humana (Cao et al., 2025).

Frente a este contexto, el presente trabajo aborda el problema del consumo innecesario y la ineficiencia operativa en laboratorios universitarios, proponiendo una solución basada en inteligencia artificial que optimiza el uso de los equipos mediante la automatización de la detección y gestión de la inactividad.

Métodos y Materiales

La investigación se estructuró usando el estándar CRISP-DM para minería y ciencia de datos, recomendable por su flexibilidad y capacidad para guiar desde la comprensión del contexto hasta la validación experimental (Berberi et al., 2025). La recolección de información multimodal, combinando datos digitales y visuales, se ha consolidado como una estrategia eficiente para mejorar la detección y precisión en escenarios de comportamiento de usuarios (Almukadi et al., 2024).

Recolección de datos

Se recopilaron dos tipos principales de datos en laboratorios de la Universidad de Guayaquil:

- Datos digitales: registros temporales de eventos de teclado, mouse, uso de CPU y ventanas activas capturados a intervalos regulares.
- Datos visuales: imágenes obtenidas de cámaras web, categorizadas como “activo” o “inactivo” mediante etiquetado manual, para capturar la presencia o ausencia física del usuario.

Procesamiento y preparación de datos

El preprocesamiento de datos siguió recomendaciones reconocidas sobre limpieza, normalización (Min-Max) y segmentación temporal, aspectos clave para alimentar modelos secuenciales mediante ventanas temporales (Ruhland et al., 2025) (Rainio et al., 2024). Las imágenes fueron aumentadas con técnicas estándar para robustecer el entrenamiento del modelo CNN.

Construcción y entrenamiento de modelos

- LSTM: Entrenado específicamente para detectar patrones de inactividad en series de tiempo provenientes de registros computacionales.
 - CNN: Implementado para el reconocimiento visual de la presencia o ausencia del usuario.
-

Ambos modelos se validaron usando conjuntos de entrenamiento y prueba balanceados, y se combinó su salida en una lógica de fusión multimodal para maximizar la detección y reducir falsos positivos (Baek et al., 2024) (Long-fei & Fisher, 2023).

Implementación y despliegue

El sistema se implementó como un módulo ejecutable, integrando los modelos y procesamiento en Python con librerías especializadas para Deep Learning y visión por computadora, lo cual garantiza reproducibilidad y escalabilidad (Truong, & Delorme, 2025). (Berberi et al., 2025).

Consideraciones éticas

Siguiendo las mejores prácticas y regulaciones actuales, se minimizó la retención de información sensible y se aseguró la transparencia con los usuarios durante la recolección y procesamiento de datos, eliminando imágenes tras la inferencia y aplicando notificaciones informativas (Rescio et al., 2024) (Weerasekara & Smedberg, 2023).

Análisis de Resultados

Los modelos entrenados demostraron un desempeño destacado en la detección automática de inactividad, con métricas principales consistentes con los estándares internacionales en precisión, recall y F1-score (Miller et al., 2024).

En la Tabla 1 se muestran las métricas obtenidas para los modelos LSTM y CNN sobre el conjunto de validación, empleando los valores óptimos de umbral de decisión. El rendimiento conjunto de LSTM y CNN para la tarea fue validado según los métodos y métricas propuestas en la literatura reciente de clasificación digital-visual (Wilhelm & Wahl, 2024) (Baek et al., 2024).

Tabla 1.

Métricas de desempeño de los modelos LSTM y CNN en la validación de detección de inactividad.

Modelo	Accuracy	Precision	Recall	F1-score
LSTM	0.99	0.99	1	0.98
CNN	0.89	0.9	0.88	0.73

Nota: Métricas de desempeño de los modelos LSTM y CNN

Los resultados generales indican que el LSTM logró un F1-score óptimo de 0.98 y el CNN, tras ajuste de threshold, alcanzó 0.73. Esta combinación permitió construir un sistema robusto para la gestión de inactividad. La Tabla 2 muestra el reporte de clasificación para el modelo LSTM.

Los resultados indican que el LSTM logró un F1-score óptimo de 0.98 y

Tabla 2.

Reporte de clasificación para el modelo LSTM

Clase	Precisión	Recall	F1-score	Soporte
Activo	1	1	1	498
Inactivo	1	1	1	500
Total	1	1	1	998

Nota: Resultados de clasificación binaria para modelo LSTM (Pilozy y Cox, 2025)

Para el modelo CNN, la comparación de métricas bajo diferentes umbrales (0.5 por defecto y 0.10 optimizado) confirmó lo reportado en investigaciones recientes: el tuning cuidadoso del threshold mejora la detección y balance entre precisión y recall en deep learning (Almukadi et al., 2024) (Rainio et al., 2024) (von Stackelberg et al., 2024).

Tabla 3.

Modelo CNN comparación de métricas según el threshold aplicado

Métrica	Threshold 0.5	Threshold 0.10 (óptimo)
Precisión	0.95 / 0.91	0.99 / 0.89
Recall	0.93 / 0.94	0.91 / 0.99
F1 Score	0.94 / 0.93	0.95 / 0.94
Accuracy	0.93	0.94

Nota: Comparación de métricas de modelo CNN según el threshold aplicado (Pilozy y Cox, 2025)

Tabla 4.

Comparación técnica entre modelos LSTM y CNN

Característica	Modelo LSTM	Modelo CNN
Tipo de entrada	Series temporales de 10 vectores	Imágenes RGB (224x224)
Arquitectura	LSTM secuencial + Densa	CNN con 3 bloques convolucionales
Objetivo	Detectar patrones de inactividad	Clasificar imagen como activo/inactivo

Característica	Modelo LSTM	Modelo CNN
Mejor F1-Score (validación)	1	0.73 (con threshold 0.25)
Accuracy	1	0.69
Umbral de clasificación	0.5	Ajustado a 0.25 para mejor rendimiento
Tiempo de inferencia	Bajo (datos vectoriales)	Medio (procesamiento de imagen)
Ventaja principal	Captura secuencias de comportamiento	Evalúa postura corporal y presencia
Limitación principal	No detecta presencia visual	Afectado por condiciones de iluminación

Nota: Resumen de características principales, funciones, métricas de desempeño de LSTM y CNN (Piloso y Cox, 2025)

La integración multimodal de los modelos contribuyó a una reducción significativa de falsos positivos frente a aproximaciones tradicionales que emplean únicamente señales digitales o visuales (Wilhelm & Wahl, 2024) (Weerasekara & Smedberg, 2023). Esto permitió alcanzar un equilibrio entre sensibilidad y especificidad, garantizando que la suspensión automática de equipos solo se produzca bajo alta certeza de inactividad real.

La reducción energética observada (estimada entre un 10% y 17%) está en línea con reportes internacionales sobre el impacto de soluciones inteligentes en la eficiencia energética en laboratorios y centros de datos (Shehabi et al., 2024) (Kahil et al., 2025) (Mili, 2024) (Zhang et al., 2022).

Además, la aceptación positiva recabada en usuarios es coherente con resultados previos sobre percepción y adopción de tecnologías de automatización en entornos académicos (Weerasekara & Smedberg, 2023). (Frontiers in Education, 2025).

Discusión

Los resultados obtenidos por el prototipo híbrido LSTM-CNN demuestran una mejora significativa en la detección precisa de inactividad en laboratorios universitarios respecto a los enfoques basados exclusivamente en monitoreo digital o visual. Estudios recientes muestran que, aunque los modelos individuales LSTM o CNN son efectivos para el análisis de datos temporales o visuales por separado, su desempeño tiende a verse limitado frente a variaciones contextuales o a la presencia de patrones atípicos (Wilhelm & Wahl, 2024) (Baek et al., 2024).

El sistema desarrollado en este trabajo logró superar estas limitaciones al integrar ambos enfoques en una lógica de decisión robusta, obteniendo métricas superiores a las reportadas en la literatura, particularmente en precisión y robustez ante falsos positivos. En comparación con referentes internacionales, el rendimiento alcanzado es competitivo frente a modelos híbridos reportados para tareas similares, reafirmando el potencial de la arquitectura multimodal como solución preferente para ambientes complejos y dinámicos (Baek et al., 2024) (Uzunhisarcikli et al., 2022).

Adicionalmente, la aceptación del sistema por parte de usuarios fue validada a través de encuestas, evidenciando disposición positiva hacia la adopción de tecnologías de automatización en la gestión de recursos educativos. Este hallazgo coincide con otros trabajos que reportan la relevancia de la percepción social y la interfaz ética en la aceptación de soluciones basadas en inteligencia artificial para el ámbito académico (Weerasekara & Smedberg, 2023).

En síntesis, el presente estudio refuerza que la combinación de modelos secuenciales y visuales, junto con una validación experimental rigurosa e involucramiento del usuario final, representa una estrategia efectiva para avanzar hacia la automatización eficiente y socialmente responsable de los laboratorios universitarios.

Conclusiones

El enfoque multimodal implementado, que integra modelos LSTM y CNN, ha demostrado mayor robustez y precisión en la detección de inactividad en laboratorios universitarios en comparación con sistemas basados únicamente en monitoreo digital o visual. Estudios recientes señalan que los enfoques tradicionales suelen incurrir en falsos positivos elevados o presentan limitaciones en escenarios con alta variabilidad de patrones de uso (Wilhelm & Wahl, 2024) (Baek et al., 2024).

A diferencia de propuestas previas, el sistema desarrollado en este trabajo logró un equilibrio superior entre sensibilidad y especificidad, ofreciendo métricas destacadas y reduciéndose significativamente los falsos positivos. Los resultados son equiparables o mejores que los reportados para modelos híbridos en tareas afines, respaldando el potencial de la arquitectura LSTM-CNN para problemas complejos donde la señal digital y la visual pueden ser complementarias (Baek et al., 2024) (Sain et al., 2023).

Además, el componente de aceptación usuaria ha sido avalado mediante encuestas internas, en concordancia con investigaciones internacionales que resaltan la importancia de la percepción social y la transparencia en la adopción de tecnologías de automatización en entornos educativos (Weerasekara & Smedberg, 2023).

El hecho de contar con una alta aceptación refuerza la viabilidad de implementación y transferencia del sistema desarrollado a otros contextos institucionales.

En conclusión, este estudio confirma que la integración de técnicas avanzadas de Deep Learning y la validación participativa con usuarios finales constituyen una ruta efectiva y ética hacia la automatización inteligente y sostenible en laboratorios universitarios.

Referencias bibliográficas

- Almukadi, W. S., Alrowais, F., Saeed, M. K., Yahya, A. E., Mahmud, A., Marzouk, R. (2024). Deep feature fusion with computer vision driven fall detection approach for enhanced assisted living safety. *Scientific Reports*, 14(1), 71545. <https://doi.org/10.1038/s41598-024-71545-6>
- Baek, J., Kim, D., Choi, B. (2024). Deep learning-based automated productivity monitoring for on-site module installation in off-site construction. *Developments in the Built Environment*, 18, 100382. <https://doi.org/10.1016/j.dibe.2024.100382>
- Berberi, L., Kozlov, V., Nguyen, G., Sáinz-Pardo Díaz, J., Calatrava, A., Moltó, G., Tran, V., & López García, Á. (2025). Machine learning operations landscape: platforms and tools. *Artificial Intelligence Review*, 58(6). <https://doi.org/10.1007/s10462-025-11164-3>
- Cao, M., Wan, J., & Gu, X. (2025). CLEAR: Multimodal Human Activity Recognition via Contrastive Learning Based Feature Extraction Refinement. *Sensors*, 25(3). <https://doi.org/10.3390/s25030896>
- Frontiers in Education (2025). Adoption of artificial intelligence applications in higher education. <https://doi.org/10.3389/educ.2025.1680401>
- Kahil, H., Sharma, S., Vlisuo, P., Elmusrati, M. (2025). Reinforcement learning for data center energy efficiency optimization: A systematic literature review and research roadmap. *Applied Energy*, 389, 125734. <https://doi.org/10.1016/j.apenergy.2025.125734>
- Long-fei, C., Fisher, R. B. (2023). MISO: Monitoring Inactivity of Single Older Adults at Home using RGB-D Technology. *arXiv preprint arXiv:2311.02249*. <https://doi.org/10.48550/arXiv.2311.02249>
- Miller C, Portlock T, Nyaga DM and O'Sullivan JM (2024) A review of model evaluation metrics for machine learning in genetics and genomics. *Front. Bioinform.* 4:1457619. doi: <https://doi.org/10.3389/fbinf.2024.1457619>
- Mili, V. (2024). Next-generation data center energy management: A data-driven decision-making framework. *Frontiers in Energy Research*, 12, 1449358. <https://doi.org/10.3389/fenrg.2024.1449358>
- Cox, F. L., Piloza, R. L. (2025). Desarrollo de un Prototipo Basado en Deep Learning Para la Detección Precisa de Inactividad en Laboratorio de Computadoras. *DSpace Universidad de Guayaquil*. <https://repositorio.ug.edu.ec/browse/author>
- Rainio, O., Teuho, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-56706-x>
-

- Rescio, G., Manni, A., Ciccarelli, M., Papetti, A., Caroppo, A., Leone, A. (2024). A deep learning-based platform for workers stress detection using minimally intrusive multisensory devices. *Sensors*, 24(3), 947. <https://doi.org/10.3390/s24030947>
- Ruhland, J.B. (2025). Enhancing deep neural network training through learnable adaptive normalization layers integrated into neural networks. *Knowledge-Based Systems*, 294, 111013. <https://doi.org/10.1016/j.knosys.2025.113968>
- Sain, M. K., Laskar, R. H., Singha J., Saini, S. (2023). Hybrid deep learning model-based human action recognition in indoor environment. *Robotica*. 41(12), 3788-3817. doi: <https://doi.org/10.1017/S0263574723001327>
- Shehabi, A., Smith, S. J., Hubbard, A., Newkirk, A., Lei, N., Abu Bakar Siddik, M., Holecek, B., Koomey, J., Masanet, E., & Sartor, D. (2024). 2024 United States Data Center Energy Usage Report Energy Analysis & Environmental Impacts Division Citation. https://eta-publications.lbl.gov/sites/default/files/2024-12/lbnl-2024-united-states-data-center-energy-usage-report_1.pdf
- Truong, D. & Delorme, A. (2025). Data Normalization Strategies for EEG Deep Learning. arXiv preprint arXiv:2506.22455. <https://doi.org/10.48550/arXiv.2506.22455>
- Uzunhisarcikli, E., Kavuncuoğlu, E. & Ozdemir, A. (2022). Investigating classification performance of hybrid deep learning models for human activity recognition. *Cognitive Computation and Systems*, 4(2). <https://doi.org/10.1111/coin.12517>
- von Stackelberg, P. et al. (2024). " Comparison of threshold tuning methods for predictive monitoring". *Quality and Reliability Engineering International*. <https://doi.org/10.1002/qre.3436>
- Weerasekara, M., Smedberg, B. (2023). Exploration of user needs and design requirements of a digital stress management intervention for software employees in Sri Lanka: a qualitative study. *BMC Public Health*, 23(1), 15480. <https://doi.org/10.1186/s12889-023-15480-7>
- Wei Zhang, L., Shanmugam, K., Ehsan Rana, M. (2022). IoT Based Intelligent Energy Monitoring System for Computer Laboratories. 2022 International Conference on Decision Aid Sciences and Applications (DASA), Chiangrai, Thailand, 1322–1326. <https://doi.org/10.1109/DASA54658.2022.9765295>
- Wilhelm, S., Wahl, F. (2024). Emergency Detection in Smart Homes Using Inactivity Score for Handling Uncertain Sensor Data. *Sensors*, 24(20), 6583. <https://doi.org/10.3390/s24206583>
- Zhang, L., Shanmugam, K. and Rana, M. (2022). IoT Based Intelligent Energy Monitoring System for Computer Laboratories, 2022 International Conference on Decision Aid
-

Sciences and Applications (DASA), Chiangrai, Thailand, 1322-1326,
<https://doi.org/10.1109/DASA54658.2022.9765295>