



COMPUTACIÓN NEUROMÓRFICA EN DISPOSITIVOS IOT: UN SALTO DE EFICIENCIA PARA LA IA PERIMETRAL

NEUROMORPHIC COMPUTING ON IOT DEVICES: A LEAP IN EFFICIENCY FOR EDGE AI

COMPUTAÇÃO NEUROMÓRFICA EM DISPOSITIVOS IOT: UM SALTO DE EFICIÊNCIA PARA A IA DE PONTA

Resumen

MBA. Angel Villarreal Cobeña

angel.villarreal@uleam.edu.ec

Universidad Laica Eloy Alfaro de Manabí

Orcid: [0000-0003-0357-0538](https://orcid.org/0000-0003-0357-0538)

M.Sc. Rocío Mendoza Villamar

rocio.mendoza@uleam.edu.ec

Universidad Laica Eloy Alfaro de Manabí

Orcid: [0000-0002-1277-7162](https://orcid.org/0000-0002-1277-7162)

Maribel Alay Cruz

e1313652909@live.uleam.edu.ec

Universidad Laica Eloy Alfaro de Manabí

Orcid: [0009-0006-3673-2168](https://orcid.org/0009-0006-3673-2168)

Willian Cedeño Bravo

e2300386691@live.uleam.edu.ec

Universidad Laica Eloy Alfaro de Manabí

Orcid: [0009-0002-8981-669X](https://orcid.org/0009-0002-8981-669X)

Esta revisión bibliográfica tiene como objetivo principal evaluar cómo la computación neuromórfica optimiza la eficiencia energética y reduce la latencia en dispositivos IoT para aplicaciones de IA perimetral. Mediante una búsqueda sistemática en bases de datos académicas, se analizaron estudios publicados entre 2020 y 2025. Los resultados muestran que la computación neuromórfica enfrenta desafíos como la escalabilidad y la falta de estandarización; sin embargo, demuestra un gran potencial al reducir el consumo de energía hasta 16 veces (en tareas de procesamiento de secuencias con chips como Loihi) y la latencia hasta 10 veces (en detección de anomalías con memoria analógica in-memory computing). Estos beneficios impactan aplicaciones como el monitoreo medioambiental y las ciudades inteligentes, aunque las limitaciones técnicas impiden una adopción masiva.

Palabras clave: edge computing, eficiencia energética, latencia, redes neuronales de picos, sostenibilidad.

REVISTA TSE'DE

Instituto Superior Tecnológico

Tsa'chila

ISSN: 2600-5557

Abstract

The main objective of this literature review is to evaluate how neuromorphic computing optimizes energy efficiency and reduces latency in IoT devices for edge AI applications. Through a systematic search of academic databases, studies published between 2020 and 2025 were analyzed. The results show that neuromorphic computing faces challenges such as scalability and lack of standardization; however, it demonstrates great potential by reducing energy consumption up to 16 times (in stream processing tasks with chips such as Loihi) and latency up to 10 times (in anomaly detection with analog in-memory computing). These benefits impact applications such as environmental monitoring and smart cities, although technical limitations prevent widespread adoption.

Keywords: Edge computing, energy efficiency, latency, spiking neural networks, sustainability.

Periodicidad Semestral

Vol. 8, núm. 2

revistatsede@tsachila.edu.ec

Recepción: 12-06-2025

Aprobación: 01-09-2025

Publicación: 25-12-2025

URL:

<http://tsachila.edu.ec/ojs/index.php/TSEDE/issue/archive>

Revista Tse'de, Esta obra está bajo una licencia de Creative Commons Reconocimiento-NoComercial-SinObraDerivada 4.0 Internacional.



Resumo

O principal objetivo desta revisão de literatura é avaliar como a computação neuromórfica otimiza a eficiência energética e reduz a latência em dispositivos IoT para aplicações de IA de ponta. Por meio de uma busca sistemática em bases de dados acadêmicas, foram analisados estudos publicados entre 2020 e 2025. Os resultados mostram que a computação neuromórfica enfrenta desafios como escalabilidade e falta de padronização; no entanto, demonstra grande potencial ao reduzir o consumo de energia em até 16 vezes (em tarefas de processamento de fluxo com chips como Loihi) e a latência em até 10 vezes (na detecção de anomalias com computação analógica em memória). Esses benefícios impactam aplicações como monitoramento ambiental e cidades inteligentes, embora limitações técnicas impeçam a adoção generalizada.

Palavras-chave: Computação de ponta, eficiência energética, latência, redes neuronais de pico, sustentabilidade.

Introducción

Los dispositivos IoT presentan un desafío crítico debido a la necesidad de procesar datos en tiempo real con recursos limitados, como baterías pequeñas en sensores inteligentes y wearables, lo que restringe su autonomía y rendimiento. La pregunta central de esta investigación es: ¿Cómo puede la computación neuromórfica optimizar la eficiencia energética y reducir la latencia en dispositivos IoT para aplicaciones de IA perimetral? El objetivo general es evaluar, mediante una revisión sistemática de la literatura, el potencial y las limitaciones de esta tecnología para fomentar su adopción en entornos sostenibles.

La computación neuromórfica surge como una solución innovadora al simular el cerebro humano, integrando procesamiento y memoria en un solo chip, con el fin de reducir el consumo de energía y prometer menor latencia y mayor eficiencia. Esto la hace ideal para aplicaciones especializadas en la salud, ciudades inteligentes y el monitoreo ambiental. Según Acharya (2024), el uso de la energía se puede reducir en un 80% comparado con las arquitecturas tradicionales; además, esto la convierte en una opción clave para la sostenibilidad de la IA perimetral en IoT.

El desarrollo acelerado de los dispositivos IoT denota una necesidad de soluciones para la eficiencia energética. Según Behrens et al. (2016), se estimaba que para 2025 existirían más de 75 mil millones de dispositivos conectados, muchos de ellos en áreas como la salud y ciudades inteligentes, permitiendo el procesamiento local de datos y eliminando la necesidad de enviar información a la nube. Esto reduce el consumo energético y prioriza la privacidad como un factor clave en aplicaciones sensibles. Los

wearables médicos pueden asegurar un monitoreo continuo sin precedentes para la seguridad del usuario.

Aunque existen mejoras significativas y beneficios, la integración masiva de la computación neuromórfica contempla desafíos técnicos. Para Ametic (2024), la escalabilidad de una simulación sin barreras para un desarrollo a gran escala puede presentar dificultades debido a la ausencia de estándares, lo que dificulta comparar su desempeño con tecnologías existentes. Sin embargo, iniciativas como el proyecto LANTERN de Schubert (2025), en colaboración con PUCV, muestran la viabilidad de aplicaciones prácticas para el monitoreo en adultos mayores mediante chips de bajo consumo. Estos avances indican un futuro prometedor al superar las limitaciones actuales.

Las bases técnicas radican en las redes neuronales de picos (SNNs); la computación neuromórfica procesa los datos de forma asíncrona basada en eventos, a diferencia de la arquitectura de von Neumann, que separa la memoria y el procesamiento. Las SNNs eliminan el cuello de botella energético. Caballar y Stryker (2024) señalan que los sensores y drones que integran la tecnología de IoT son ideales para la eficiencia cuando esta es crítica. La capacidad de emular el procesamiento neuronal mejora el rendimiento en tareas, convirtiéndolo en una solución prometedora para la IA perimetral en entornos con restricciones energéticas.

Según Intel (2025) Grandes empresas tecnológicas como Intel y BrainChip han impulsado el desarrollo del hardware neuromórfico; los chips Loihi 2 y Akida facilitan el aprendizaje en el límite, esencial en aplicaciones para vehículos autónomos y dispositivos médicos. Para López (2021), estos sistemas pueden reducir el consumo

energético hasta en un 80% en tareas como el reconocimiento de patrones, lo cual es crucial para dispositivos IoT en ubicaciones remotas, como sensores agrícolas o drones. Esto muestra que la eficiencia energética determina su funcionalidad y redefine las posibilidades de la IA perimetral.

Una implementación masiva presenta obstáculos técnicos y prácticos. Ametic (2024) indica que mapear SNNs en hardware neuromórfico puede incrementar la latencia si no se optimiza adecuadamente. Además, Martínez Polo (2024) señala la compatibilidad con estructuras existentes como un desafío, debido al equilibrio entre demandas computacionales y bajo consumo. Resolver estas tensiones requiere avances en diseños y estandarización de procesos en los chips, lo que aceleraría la integración en el ecosistema IoT.

Investigaciones actuales exploran aplicaciones prácticas de la computación neuromórfica en IoT. El proyecto LANTERN de Schubert (2025) optimiza el monitoreo en tiempo real de adultos mayores; sin embargo, Caballar y Stryker (2024) destacan sus usos en sensores y drones. Estos casos prácticos demuestran cómo la tecnología mejora tanto la eficiencia energética como el procesamiento local. Aunque los recursos son escasos, la computación neuromórfica ofrece soluciones viables y escalables.

Comparado con tecnologías de edge computing tradicionales y aceleradores de hardware, la computación neuromórfica resalta por su diseño bioinspirado. Mientras que el edge computing reduce la latencia al procesar datos localmente, la computación neuromórfica optimiza el consumo energético al imitar el cerebro humano. Su combinación lo hace ideal para aplicaciones que demandan baja latencia y eficiencia

continua, como la gestión en tiempo real, posicionándolo como una alternativa superior en escenarios específicos de IoT.

Las inversiones económicas para adaptar esta tecnología son significativas, pero los ahorros en consumo energético reducen los gastos en infraestructura en la nube, compensando a largo plazo. Las empresas que manejan grandes volúmenes de datos obtienen ventajas notables; además, la mayor durabilidad de los dispositivos IoT podría reducir los costos de mantenimiento, haciendo la inversión viable en el tiempo. La perspectiva futura de la computación neuromórfica en IoT es prometedora; sin embargo, la estandarización y prácticas de código compartido representan obstáculos. Según Ametic (2024), superar estas barreras es prioritario para su integración en la infraestructura tecnológica global. Dado que la demanda de IA en tiempo real crece, esta tecnología está próxima a liderar la siguiente generación de dispositivos IoT inteligentes.

Metodología

Esta revisión bibliográfica se realizó siguiendo las directrices de Kitchenham (2007) para revisiones sistemáticas en ingeniería de software, adaptadas al contexto de la computación neuromórfica en IoT. Los pasos incluyeron: (1) formulación de preguntas de investigación (e.g., ¿Cómo mejora la computación neuromórfica la eficiencia energética en IoT?); (2) búsqueda sistemática en bases de datos académicas como IEEE Xplore, ScienceDirect, arXiv, Google Scholar, SciELO y Redalyc, restringida a publicaciones entre 2020 y 2025; (3) selección de estudios mediante criterios de inclusión (artículos relevantes sobre aplicaciones neuromórficas en IoT) y exclusión (estudios no académicos o fuera del período); (4) extracción de datos usando fichas

personalizadas en Excel para resumir objetivos, hallazgos y conclusiones; y (5) síntesis cualitativa narrativa para identificar patrones y tendencias, sin análisis estadístico debido a la heterogeneidad de los estudios.

Se identificaron inicialmente 150 estudios; tras revisión de títulos y resúmenes, se excluyeron 100; y finalmente se incluyeron 50 para análisis detallado. La Tabla 1 detalla las estrategias de búsqueda. Se utilizó Zotero para gestionar referencias en formato APA 7ª edición, asegurando replicabilidad.

Mediante términos específicos como “Computación neuromórfica”, “Dispositivos IoT”, “IA perimetral”, “Edge AI” y “eficiencia energética”, las consultas generaron resultados precisos, limitados a artículos para garantizar transparencia. El muestreo no fue probabilístico, basado en relevancia temática y calidad de publicaciones, enfocándose en aportes significativos como hardware neuromórfico y aplicaciones prácticas en IoT. La población de estudio es el conjunto total de literatura académica disponible sobre la computación neuromórfica en IoT, la muestra consistió en artículos seleccionados aplicando los criterios de inclusión y exclusión, para el muestreo no fue probabilístico, se basó en la relevancia temática y la calidad de las publicaciones, identificando filtros representativos para el análisis. Esto permitió un enfoque centrado en aportes significativos al campo como la exploración del hardware neuromórfico y las aplicaciones prácticas en IoT.

La extracción de los datos, se realizó mediante una ficha personalizada que sirvió como instrumento de recolección, proporcionando un resumen de este, con el objetivo de estudio, hallazgos principales y conclusiones. Cada uno de los artículos fue analizado minuciosamente y la información fue estructurada en Excel para facilitar la

organización y comparación de estos. Permitiendo asegurar la consistencia, la eficiencia y los desafíos técnicos relevantes para la revisión.

El análisis de los datos fue realizado mediante el método cualitativo ya que el objetivo de este es sintetizar patrones, tendencias y discrepancias en la literatura, identificando temas claves, no se empleó el método de análisis estadístico debido a la heterogeneidad del estudio al no permitir un meta análisis. En cambio, con un enfoque narrativo implementado para integrar los hallazgos, en el campo, permitió una profunda comprensión del estado actual de la computación neuromórfica en IoT.

La adaptación de estrategias de búsqueda incluyó revisiones tecnológicas para una cobertura amplia, modificando términos equivalentes y verificando resultados para evitar sesgos, con énfasis en diversidad bilingüe (predominantemente inglés).

Gracias a la ficha de resumen, como un instrumento de recolección el análisis fue cualitativo, sin embargo, se utilizó Excel para organizar los datos extraídos y Zotero para gestionar las referencias bibliográficas, asegurando un formato consistente según APA 7ma edición, facilitando la sistematización y trazabilidad de la información recopilada. Garantizando la replicabilidad, documentado todos los procesos, como las consultadas de búsqueda, criterios de selección y las bases de datos utilizadas, que detallan los términos y filtros aplicados.

La metodología empleada permitió una revisión completa y actualizada de la computación neuromórfica aplicada a dispositivos IoT para IA perimetral, asegurando la selección de fuentes relevantes y de alta calidad, proporcionando una base sólida para análisis y discusiones subsiguientes.

Tabla 1

Detalles estrategias mediante filtros

| Base de datos | Términos de búsqueda | Filtros aplicados | Período |
|----------------------|--|------------------------------------|----------------|
| IEEE Xplore | Computación neuromórfica, IoT, edge AI | Artículos de revista, conferencias | 2020-2025 |
| ScienceDirect | Neuromorphic computing, IoT, eficiencia energética | Artículos revisados por pares | 2020-2025 |
| arXiv | Neuromorphic computing AND edge AI | Preprints relevantes | 2020-2025 |
| Google Scholar | Computación neuromórfica AND dispositivos IoT | Artículos en inglés y español | 2020-2025 |
| SciELO | Computación neuromórfica, IA perimetral | Publicaciones en español | 2020-2025 |
| Redalyc | IA perimetral, eficiencia energética | Publicaciones en español | 2020-2025 |

Resultados y Discusión

¿Cómo puede la computación neuromórfica mejorar la eficiencia energética en dispositivos IoT?

La optimización de la eficiencia energética en los dispositivos IoT se puede lograr mediante tres mecanismos principales: la integración de memoria y procesamiento en un solo chip, eliminando transferencias de datos que consumen energía. Según Mehonic et al. (2024), utilizar redes neuronales de picos (SNNs) ayuda a procesar datos solo cuando se detectan eventos relevantes, reduciendo así el consumo en periodos inactivos. Además, el procesamiento en paralelo permite la ejecución de múltiples cálculos simultáneos, minimizando el uso de energía. Un estudio empírico con el chip Loihi demuestra que una red neuronal grande consume 4 a 16 veces menos energía que hardware tradicional en tareas de procesamiento de secuencias. Otro

estudio sobre la memoria analógica (AIMC) muestra una reducción de tres órdenes de magnitud en el costo energético para tareas específicas (Dominique et al., 2023). Estas características hacen que la computación neuromórfica sea ideal para dispositivos IoT con restricciones energéticas, como sensores y wearables.

¿Qué beneficios nos ofrece tener una mejor velocidad de procesamiento y latencia?

La computación neuromórfica mejora la velocidad para aplicaciones en tiempo real; su enfoque basado en eventos permite respuestas inmediatas a los datos entrantes, a diferencia de los métodos tradicionales de procesamiento por lotes. Además, el procesamiento en paralelo maneja múltiples flujos de datos simultáneamente, acelerando los cálculos. Un estudio encuentra que la AIMC logra tiempos de cómputo hasta 10 veces más cortos que el hardware convencional en tareas como la detección de anomalías a 40 MHz en el colisionador de hadrones (Dominique et al., 2023). La baja latencia beneficia aplicaciones autónomas y la detección de ciberataques en redes IoT, ya que los retrasos son críticos. El procesamiento local reduce la dependencia de la nube, minimizando la latencia de comunicación. Estas ventajas posicionan a la computación neuromórfica como una solución clave para IoT.

¿Qué aplicaciones del IoT salen beneficiadas de la computación neuromórfica?

Debido al impacto en las aplicaciones del IoT su eficiencia energética y baja latencias, gracias a esto la salud y proyectos como LANTERN (Schubert, 2025) utilizan chips neuromórficos para el monitoreo en tiempo real de adultos mayores, mejorando la privacidad al procesa datos localmente. Además, aprovechan la baja latencia para

tareas como detección de objetos, estas aplicaciones destacan el potencial transformado de la computación neuromórfica en IoT (Muir y Sheik, 2025).

¿Cuáles son los desafíos para una adopción en IoT?

La adopción enfrenta desafíos técnicos y prácticos, el diseño y la fabricación del hardware neuromórfico es complejo y costoso, requiriendo materiales para replicar la arquitectura cerebral (Caballar y Stryker, 2024). El desarrollo de software y los algoritmos compatibles son un obstáculo, debido que los modelos tradicionales no son aplicables. La falta de benchmarks estandarizados dificulta la comparación e integración en sistemas existentes (Ametic, 2024). La compatibilidad con sistemas heredados requiere una reestructuración significativa, estos desafíos deben abordarse para lograr una adopción masiva en IoT (Martínez Polo, 2024).

Tabla 2

Beneficios y desafíos de la computación neuromórfica en el IoT

| Aspectos | Beneficios | Desafíos |
|-----------------------|--|--|
| Eficiencia energética | Reducción de hasta 16 veces el consumo energético | Alto costo y complejidad en diseño de hardware |
| Latencia | Tiempos de cómputo hasta 10 veces más cortos | Escalabilidad limitada para redes grandes |
| Aplicaciones | Monitoreo médico, ciudades inteligentes y seguridad. | Falta de benchmarks estandarizados |
| Perspectivas futuras | Mercado proyecta de \$47.3 mil millones para 2034 | Necesidad de nuevos modelos en programación |

Conclusiones

La computación neuromórfica representa un avance bioinspirado que optimiza el procesamiento en dispositivos IoT con restricciones energéticas, contribuyendo al conocimiento existente al sintetizar evidencia de 2020-2025 sobre su aplicación en IA perimetral. Esta revisión destaca su potencial para reducir el consumo energético y la

latencia, pero identifica brechas en escalabilidad y estandarización que limitan su adopción. En términos de impacto, facilita una IA más sostenible, mejora la privacidad mediante procesamiento local y reduce costos a largo plazo en sectores como la salud (e.g., monitoreo continuo), transporte (e.g., vehículos autónomos) y ciudades inteligentes. Futuras investigaciones deberían enfocarse en hardware asequible e integración con frameworks como Lava, ampliando así las capacidades de IoT y promoviendo innovaciones económicas y ambientales.

Inspirada en la estructura y funcionamiento del cerebro humano para poder procesar información de manera eficiente, esto es ideal para dispositivos IoT, aunque con limitaciones de energía, siendo crucial para la IA, donde los dispositivos operan localmente para reducir latencia y consumo energético (Schuman et al., 2022). Evidenciando que pueden consumir menos energía que los hardware tradicionales y reducir la latencia hasta 10 veces, siendo especialmente útil donde la duración de una batería es crítica (Dominique et al., 2023).

A pesar de sus beneficios, la computación neuromórfica enfrenta muchos desafíos, principalmente enfocados al diseño y la fabricación de los componentes de este, requiriendo muchos materiales, el desarrollo del software y los algoritmos que ya no son aplicables destacan problemas para la escalabilidad en redes IoT grandes, mientras que la falta de estandarización dificulta la integración e identifica tensiones en sistemas heredados, requiriendo un reestructuración en torno a la escalabilidad y los costos que generan sobre su viabilidad, las opiniones divididas entre un futuro prometedor y las barreras técnicas.

La IA perimetral y su futuro en el mercado facilitan el desarrollo de aplicaciones neuroinspiradas gracias a las neuronas y frameworks como Lava, sugieren que la integración podrías ampliar sus capacidades, recomendando que la investigación futura se centre en desarrollar hardware más asequible y escalable. Explorando la integración con otras tecnologías emergentes abren nuevas oportunidades, beneficios con una mayor sostenibilidad, mejoras en la privacidad y el rendimiento con un impacto económico significativo, especialmente en sectores como la salud, transporte y ciudades inteligentes.

Referencias Bibliográficas

Acharya, P. (2024). *Computación neuromórfica: Principio, retos y orientaciones futuras*. Ediciones Nuestro Conocimiento.

Ametic. (2024). *Ametic*. ametic: <https://ametic.es/wp-content/uploads/2024/01/DOCUMENTO-NEUROCOMPUTACION-02.pdf>

Ametic. (2024). *Observatorio IA*. ObservatorioIA: <https://observatorio-ametic.ai/es/inteligencia-artificial-en-investigacion/neurocomputacion>

Behrens, S., Hartmann, E. y Cramer, C. (2016). *Statista*. statista: <https://www.statista.com/statistics/471264/iot-number-of-connected-devices-worldwide/>

Caballar, R. y Stryker, C. (2024). *ibm*. ibm: <https://www.ibm.com/es-es/think/topics/neuromorphic-computing>

Dominique J., K., Kortman, B. A., Boybat, I., Ferro, E., Dolas, S., de Austri, R., . . . H. Mentink, J. (2023). Benchmarking energy consumption and latency for

neuromorphic computing in condensed matter and particle physics. *arXiv*, 2(1), 7. <https://doi.org/https://doi.org/10.1063/5.0116699>

El Qasem, R. (2025). *Atos*. <https://atos.net/en/blog/neuromorphic-computing-the-future-of-ai-and-beyond>

Furber, S. (2023). Tecnología neuromórfica digital: perspectivas actuales y futuras . *academic.oup.com*, 11(5), 2. <https://doi.org/https://doi.org/10.1093/nsr/nwad283>

Intel. (2025). *Intel*. Neuromorphic computing and engineering with AI: <https://www.intel.com/content/www/us/en/research/neuromorphic-computing.html>

Kamble, G. U., Patil, C. S., Alman, V. V., Kundale, S. S. y Hyeok Kim, J. (2024). Computación neuromórfica: avances de vanguardia y direcciones futuras. *IntechOpen*. <https://doi.org/10.5772/intechopen.1006712>

Kumar, V. R. y Priya, M. V. (2024). Comparación de THD en un sistema de energía conectado a la red con un novedoso controlador de lógica difusa sintonizado UPQC y sin UPQC conectado a la red. *AIP Publishing*. <https://doi.org/https://doi.org/10.1063/5.0198766>

Lei, D., Tang, H. y Roy, K. (2024). Comprender y cerrar la brecha entre la computación neuromórfica y el aprendizaje automático. *Frontiers*, 2. <https://doi.org/https://doi.org/10.3389/fncom.2024.1455530>

- Lopéz, J. (2021). *Xataka*. <https://www.xataka.com/investigacion/computacion-neuromorfica-mejor-que-le-ha-pasado-a-inteligencia-artificial-como-funciona-que-hace-prometedora>
- Maddula, S., Gupta, H. y Shaik Mohammad, J. (2024). Computación neuromórfica impulsada por IA para la detección de anomalías energéticamente eficientes en redes IoT. *Revistas IRE*, 8(3), 122-129.
- Martínez Polo, A. (2024). *Ideas.pwc*. Ideas.pwc: <https://ideas.pwc.es/archivos/20240705/que-es-la-computacion-neuromorfica/>
- Mehonic, A., Lelmini, D., Roy, K., Mutlu, O., Kvatinsky, S., Serrano Gotarredona, T., . . . Ghazi Sarwat, S. (2024). *AIP Publishing*. AIP Publishing: <https://doi.org/10.1063/5.0179424>
- Muir, D. y Sheik, S. (2025). The road to commercial success for neuromorphic technologies. *Nature Communications*, 16, 12. <https://doi.org/https://doi.org/10.1038/s41467-025-57352-1>
- Schubert, E. (2025). *pucv*. pucv: <https://www.pucv.cl/uuaa/mediante-computacion-neuromorfica-que-imita-a-las-neuronas-crean>
- Schuman, C., R. Kulkarni, S., Parsa, M., J. Parker, M., Prasanna, F. y Kay, B. (2022). Publisher Correction: Opportunities for neuromorphic computing algorithms and applications. *nature computational science*, 2(3), 205. <https://doi.org/https://doi.org/10.1038/s43588-021-00184-y>

The Black Box Lab, (2025). *The Black Box Lab*. The Black Box Lab;:
<https://theblackboxlab.com/computacion-neuromorfica/>