

Jornadas de Automática

Enfoque de aprendizaje constructivo de sensorización inteligente ligera en dispositivos embebidos

Roxane Pelou^a, Jose-Luis Poza-Lujan^b, Juan-Luis Posadas-Yagüe^{c,*}, Pietro Manzoni^c

^aInstitut Catholique d'Arts et Métiers (ICAM), 75 avenue de Grande Bretagne – CS 97615 – 31076 Toulouse, France.

^bInst. de Automática e Informática Industrial (ai2), Universitat Politècnica de València (UPV), camino de vera, sn, 46022, Valencia, España.

^cDpto. de Informática de Sistemas y Computadores (DISCA), Universitat Politècnica de València (UPV), camino de vera, sn, 46022, Valencia, España.

To cite this article: Pelou, R., Poza-Lujan, J.-L., Posadas-Yagüe, J.-L., Manzoni, P. 2026. Constructive learning approach for minimal intelligent sensing on embedded devices. *Jornadas de Automática*, 47.
<https://doi.org/10.17979/ja-cea.2026.47.13878>

Resumen

La importancia de las acciones de control inteligentes ha aumentado y debe ser abordada en los itinerarios formativos de ingeniería. En este artículo se presenta parte del itinerario formativo práctico para aprender a desarrollar sistemas IoT inteligentes. Para el desarrollo se utiliza TinyML en Arduino Nano 33 BLE Sense como ejemplo de sistema embebido inteligente con recursos limitados. A través de tres bloques prácticos, se aborda el uso de un dispositivo embebido para realizar una tarea de control inteligente. Para ello el estudiante desarrolla tres etapas pedagógicamente validadas: conocimiento del entorno, análisis de señal de una dimensión y análisis de señal de dos dimensiones. Los resultados demuestran la viabilidad de desplegar modelos de inferencia en tiempo real directamente en microcontroladores, permitiendo una automatización eficiente y local. Este enfoque proporciona a los docentes nuevas herramientas metodológicas para introducir la inteligencia artificial embebida en el ámbito de la ingeniería de sistemas y automática.

Palabras clave: Robótica inteligente, Sistemas de control embebidos en red, Educación en control utilizando equipos de laboratorio, Aprendizaje automático, Implementación digital.

Constructive learning approach for minimal intelligent sensing on embedded devices

Abstract

The importance of intelligent control actions has increased and must be addressed within engineering training itineraries. This paper presents part of a practical training itinerary for learning to develop intelligent IoT systems. For this development, TinyML on the Arduino Nano 33 BLE Sense is used as an example of an intelligent embedded system with limited resources. Through three practical modules, the use of an embedded device to perform an intelligent control task is addressed. To achieve this, students progress through three pedagogically validated stages: environmental awareness, one-dimensional signal analysis, and two-dimensional signal analysis. The results demonstrate the feasibility of deploying real-time inference models directly onto microcontrollers, enabling efficient and local automation. This approach provides new teachers with methodological tools to introduce embedded artificial intelligence within the fields of systems engineering and automation.

Keywords: Intelligent robotics, Networked embedded control systems, Control education using laboratory equipment, Machine Learning, Digital implementation.

*Autor para correspondencia: jposadas@disca.upv.es

1. Introducción

La importancia de las acciones de control inteligentes ha aumentado significativamente en los últimos años. Por ello, es necesario que los itinerarios formativos de ingeniería aborden el desarrollo de sistemas IoT inteligentes de forma práctica. El aprendizaje automático en dispositivos con recursos muy limitados, denominado TinyML, representa la frontera actual de la automatización embebida. Incluir la inteligencia en un dispositivo con recursos limitados, implica desarrollar un entrenamiento con cierta complejidad. Esta tecnología permite que microcontroladores económicos ejecuten modelos de inteligencia artificial de manera local y eficiente.

Sin embargo, el uso de la inteligencia artificial en dispositivos embebidos tiene una cierta complejidad. La evolución desde el control lógico elemental hasta el control inteligente avanzado se ve afectado por la dificultad incremental (figura 1).




Figura 1: Evolución del control desde el nivel lógico elemental hasta el control inteligente embebido

Este aprendizaje debe ser constructivo y progresivo para asegurar que el estudiante asimile los conceptos firmemente. En la Fase A, el estudiante comienza con el control lógico utilizando señales escalares de baja complejidad y procesamiento basado en funciones lógicas. A continuación, se avanza a la Fase B, que introduce el control avanzado mediante el análisis de series temporales. En esta etapa, el alumno aprende a procesar múltiples sensores simultáneamente, como vectores de datos. El salto hacia la inteligencia artificial se produce en las siguientes fases. La Fase C introduce el control inteligente con señales continuas de baja complejidad, donde el estudiante aprende a reconocer tramas temporales. Finalmente, la Fase D aborda señales continuas de alta complejidad en las que se requiere que un controlador realice un análisis complejo de tramas para clasificar formas o patrones directamente en el dispositivo.

Tras esta introducción, la sección 2 expone la metodología, la cual se divide en el enfoque de aprendizaje constructivista y el desarrollo incremental de las prácticas. La sección 3 aborda la implementación técnica del itinerario utilizando plataformas como Arduino y ESP32, o similar, para el desarrollo de sistemas IoT inteligentes con recursos limitados. Finalmente, la sección 4 presenta las conclusiones sobre la viabilidad de desplegar modelos de inferencia en tiempo real y el valor de estas herramientas metodológicas para la docencia de ingeniería.

2. Metodología

2.1. Enfoque de aprendizaje

Nuestro modelo educativo se fundamenta en el constructivismo (Vygotsky and Cole, 1978), entendiendo el aprendizaje como un proceso que va más allá de la transmisión y asimilación de información. El enfoque dado a las prácticas se basa en un proceso continuo de desarrollo (Johri and Olds, 2011). En el modelo constructivista, el estudiante asume un rol activo: construye su propio aprendizaje integrando la nueva información con sus conocimientos y experiencias previas, actualizando así sus esquemas mentales (Jonassen, 1996).

Debido a la complejidad natural de las disciplinas técnicas, es fundamental no saturar la capacidad de asimilación del alumno. Por ello, y siguiendo los principios de la Teoría de la Carga Cognitiva (Sweller et al., 1998), el enfoque de aprendizaje aplica la técnica de chunking o fragmentación de la información. Esta técnica consiste en organizar los contenidos en módulos breves, específicos y bien delimitados para evitar la sobrecarga de la memoria de trabajo (Franklin, 2026). Combinando constructivismo y fragmentación, se facilita al estudiante que mantenga la atención, procese la información de forma ágil, y logre consolidar un conocimiento duradero a largo plazo (Paas et al., 2003).

2.2. Desarrollo incremental

El diseño de este itinerario se basa en una trayectoria acumulativa donde cada nuevo esquema conceptual se construye sobre las bases cognitivas establecidas en fases previas. Para gestionar la complejidad técnica de los diferentes modelos de control, se aplica la técnica de chunking o fragmentación de la información. Esta metodología organiza los contenidos en módulos breves y específicos, permitiendo una transición fluida desde la lógica de control tradicional hacia la inteligencia artificial embebida. La progresión se estructura en cuatro niveles de dificultad creciente.

La Fase A (Figura 2) representa el control lógico basado en señales escalares. El estudiante se inicia con señales de baja complejidad y procesamiento mínimos.




Figura 2: Procesamiento de señales escalares mediante control lógico.

La Fase B (Figura 3) define el control avanzado donde aparecen las series temporales.




Figura 3: Control avanzado mediante el análisis de series temporales y fusión de sensores.

En esta fase, se introducen vectores de datos provenientes de múltiples sensores, como la IMU. Aquí el alumno aprende a procesar flujos de datos temporales.

La Fase C (Figura 4) inicia el control inteligente basado en señales de baja complejidad.



Figura 4: Control inteligente aplicado a señales continuas monocanal.

En esta etapa intermedia, se aborda el análisis de tramas de audio monocanal. El estudiante utiliza herramientas de clasificación para reconocer patrones en los que la ventana temporal implica un análisis complejo.

La Fase D (Figura 5) representa el control inteligente en el que se procesan señales continuas complejas.




Figura 5: control inteligente aplicado a señales continuas multicanal.

Este nivel representa el nivel máximo de exigencia cognitiva y técnica. Se enfoca en señales multicanal, como el vídeo, que requieren análisis complejos de tramas para la clasificación de patrones.

3. Implementación

La metodología descrita se ha aplicado con estudiantes de últimos cursos del grado en informática y alumnos del máster.


Para las tres primeras etapas del enfoque de aprendizaje, el Arduino Nano 33 BLE Sense ((Sobota et al., 2013)) es una plataforma ideal. Su procesador ARM Cortex-M4F gestiona el control lógico y avanzado de las Fases A y B, donde la frecuencia máxima de muestreo del Arduino es suficiente para muestrear y el procesamiento se limita a mapeos lineales o análisis de series temporales. En la Fase C, centrada en el audio monocanal, el dispositivo demuestra su capacidad para el TinyML; por ejemplo, una inferencia de clasificación de voz consume apenas 3,7 KB de memoria RAM y 26,7 KB de Flash, permitiendo una ejecución local eficiente gracias a la integración del micrófono en la placa.

Sin embargo, la Fase D introduce señales continuas de vídeo multicanal, lo que eleva la complejidad del análisis de tramas y la frecuencia de muestreo. En esta etapa, el Arduino BLE Sense está limitado en ancho de banda y capacidad de memoria para gestionar el flujo de datos de una cámara y el tamaño de los modelos de visión artificial. Por ello, es necesario emplear un ESP32 o similar, en el caso de las prácticas preparadas el XIAO ESP32S3 ((Pradeep, 2023)), el cual ofrece una arquitectura de doble núcleo, mayores velocidades de procesamiento y una gestión de memoria superior para el desarrollo de sistemas IoT inteligentes con visión local. Un ejemplo claro es la necesidad de un buffer de imagen, que requiere recursos de memoria que exceden la capacidad del nRF52840 pero que el XIAO ESP32S3 maneja con fluidez.

3.1. Práctica inicial

Esta práctica constituye la etapa inicial del itinerario formativo. Esta etapa es clave en el aprendizaje constructivista, ya que determina los fundamentos teorico-prácticos con los que el estudiante deberá entender el resto de prácticas.

El objetivo es que el estudiante domine la interacción básica con el hardware y la conectividad antes de introducir modelos de inteligencia artificial. En esta fase, el controlador trabaja con señales escalares de baja complejidad. La naturaleza de la señal consiste en voltajes analógicos continuos que el microcontrolador convierte en valores digitales para determinar el nivel de luminosidad que deberá tener un led.



(a) Montaje físico de sensores en la placa de prototipado (b) Configuración de servicios y características.

Figura 6: Implementación de la Práctica 1 basada en el modelo de Fase A.


Como se muestra en la Figura 6(a), el estudiante realiza el montaje físico sobre una placa de prototipado. El sistema integra un bajo número de sensores, utilizando una fotoresistencia (LDR) y un potenciómetro para ajustar el umbral de control de iluminación. El estudiante programa el sistema para que el LED se encienda automáticamente cuando la lectura del LDR sea superior al umbral marcado.

La práctica finaliza con la integración de comunicaciones Bluetooth Low Energy (BLE) para introducir el concepto de IoT. El Arduino BLE Sense se configura como un dispositivo periférico que publica datos en un "tablón de anuncios" virtual. En la Figura 6(b), se observa el uso de la aplicación móvil LightBlue como dispositivo central. Mediante esta interfaz, el estudiante puede escribir un valor en la característica correspondiente para activar el LED de forma remota. Este ejercicio permite al estudiante comprender la bidireccionalidad de los sistemas inteligentes, así como los aspectos de conectividad y comunicaciones antes de abordar señales de mayor dimensión.


3.2. Práctica intermedia

Esta práctica se centra en el control avanzado y supone un incremento en la complejidad de los datos procesados respecto a la fase inicial. En esta fase, el estudiante deja atrás las señales puntuales para trabajar con series temporales y vectores de datos inerciales provenientes de la IMU integrada en la placa de prototipado. La naturaleza de la señal consiste en flujos de datos capturados lo que permite registrar movimientos humanos con precisión. El estudiante utiliza el Arduino BLE Sense para capturar los datos del acelerómetro y enviarlos en formato CSV a través de la conexión USB.

La Figura 7(a) muestra el proceso de captura física, mientras que en la Figura 7(b) se observa la visualización del monitor serie con los resultados de la inferencia en tiempo real.



(a) Montaje Físico



(b) Monitor Serie

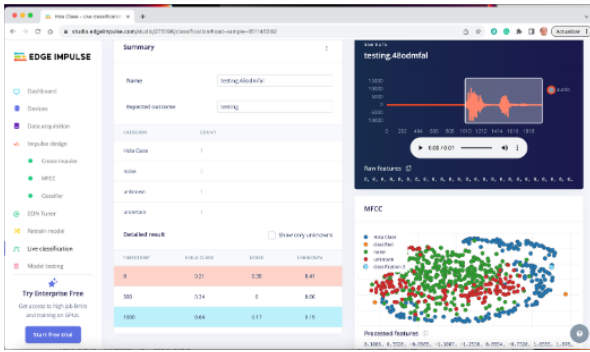
Figura 7: Implementación de la Práctica 2 basada en el modelo de la Fase B.

El procesamiento en esta etapa requiere la normalización de las señales, escalando valores de aceleración y giroscopio entre 0 y 1, para alimentar correctamente una red neuronal. Un ejemplo práctico es la detección automática de gestos: el alumno mueve la placa de lado a lado o en círculos para que el sistema aprenda a reconocer patrones de movimiento estándar.


3.3. Práctica IA monocanal

Esta práctica se introduce formalmente el control inteligente mediante el procesamiento de señales continuas de baja complejidad. En la Fase C, el estudiante trabaja con una entrada de audio monocanal capturada por el micrófono digital MEMS integrado en el Arduino BLE Sense. La naturaleza de la señal consiste en una onda de audio digitalizada que se organiza en tramas temporales para su posterior análisis.

El estudiante utiliza herramientas avanzadas de TinyML generadas por el entrenamiento en Edge Impulse para realizar el análisis de tramas y la clasificación de la señal. La Figura 8(a) muestra la interfaz de captura y procesamiento de características (como los coeficientes MFCC), mientras que en la Figura 8(b) se observa la inferencia en tiempo real en el monitor serie. Un ejemplo práctico es el reconocimiento de una palabra clave como "Hola Clase": el sistema analiza el flujo de audio y, al detectar la coincidencia, activa una señal de confirmación de forma local.



(a) interfaz de entrenamiento y generación del modelo inteligente mediante Edge Impulse



(b) Clasificación local de audio para detección de palabras clave mediante el modelo entrenado.

Figura 8: Implementación de la Práctica 3 basada en el modelo de la Fase C en la que se introduce la inteligencia artificial.


Técnicamente, esta práctica demuestra la eficiencia de los modelos optimizados para sistemas con recursos limitados. Una inferencia de este tipo consume apenas 3,7 KB de memoria RAM y 26,7 KB de memoria Flash. Este despliegue local permite una automatización rápida y segura sin depender de conectividad externa, cumpliendo con los objetivos de aprendizaje sobre automatización eficiente.

3.4. Práctica IA multicanal


Esta práctica constituye la cumbre del itinerario y aborda el control inteligente con señales continuas de alta complejidad. En la Fase D, el estudiante trabaja con entradas de vídeo multicanal. La naturaleza de la señal consiste en ondas de vídeo digitalizadas en tramas temporales. Este nivel de procesamiento requiere un análisis complejo de tramas y frecuencias de muestreo secuenciales elevadas para clasificar formas o patrones directamente en el dispositivo.

El sistema debe gestionar un flujo de datos denso y realizar inferencias en tiempo real. Debido a la elevada demanda de ancho de banda y memoria RAM, esta práctica requiere un cambio de plataforma hacia el ESP32, en concreto el modelo XIAO ESP32S3.

Como se ilustra en la Figura 9(a), el estudiante utiliza diversos patrones de señales de tráfico como modelos visuales para entrenar la red neuronal. Estos modelos permiten que el sistema aprenda a discriminar entre diferentes formas, como círculos o rectángulos, mediante un proceso de captura y etiquetado previo.



(a) Modelos geométricos empleados para el entrenamiento del sistema visual para reconocer una señal de tráfico. En este caso, se muestran los modelos que se emplean para que la red neuronal pueda discernir exactamente la señal correcta.



(b) Hardware XIAO ESP32S3 con cámara integrada ejecutando el modelo de visión artificial.

Figura 9: Implementación de la Práctica 4 correspondiente al modelo de la Fase D.

En la Figura 9(b) se observa el XIAO ESP32S3 con la cámara integrada empleado para ejecutar el modelo entrenado. Este hardware permite manejar con fluidez el buffer de imagen necesario para la inferencia, superando las limitaciones técnicas de dispositivos con menores recursos.

4. Conclusiones

El itinerario formativo presentado en el artículo, demuestra que es posible enseñar inteligencia artificial embebida de forma efectiva mediante un enfoque constructivista. Desde la perspectiva pedagógica, el desarrollo incremental y la técnica de fragmentación resultan fundamentales para evitar la sobrecarga cognitiva de trabajo en el estudiante. Organizar el contenido en cuatro fases de dificultad creciente facilita que el estudiante asimile conceptos complejos paso a paso. Un ejemplo de esta progresión es consolidar el manejo de señales escalares simples (Fase A) antes de intentar el análisis de múltiples señales escalares (Fase B). A continuación se presenta la necesidad del uso de inteligencia artificial para reconocer una señal monocanal (Fase C), como preámbulo para el reconocimiento de una señal multicanal (Fase D).

Técnicamente, se concluye que la elección del hardware debe ajustarse estrictamente a la complejidad de la señal procesada. El Arduino BLE Sense es una plataforma ideal para señales de una dimensión como el movimiento o el audio monocanal. Sin embargo, el salto a la visión artificial requiere la mayor capacidad de cómputo y memoria del XIAO ESP32S3.

Como principal aportación, este trabajo ofrece una metodología replicable para docentes de ingeniería de sistemas y

automática que deseen integrar TinyML e inteligencia artificial embebida en sus asignaturas. El enfoque práctico garantiza que los estudiantes no solo adquieran conocimientos teóricos, sino que desarrollen competencias para crear sistemas IoT inteligentes reales.

Como trabajo futuro, sería interesante evaluar cuantitativamente el impacto pedagógico del itinerario mediante métricas de aprendizaje, encuestas de satisfacción y análisis comparativos.

Referencias

- Franklin, P.-B., 2026. Microlearning in software engineering education: A systematic review of initiatives and curriculum modernization. *Education Sciences* 16 (3), 487.
- Johri, A., Olds, B. M., 2011. Situated engineering learning: Bridging engineering education research and the learning sciences. *Journal of Engineering Education* 100 (1), 151–185.
- Jonassen, D. H., 1996. Learning with technology: Using computers as cognitive tools. *Handbook of research for educational communications and technology*.
- Paas, F., Renkl, A., Sweller, J., 2003. Cognitive load theory and instructional design: Recent developments. *Educational psychologist* 38 (1), 1–4.
- Pradeep, A., 2023. Enabling iots with esp32 for affordable education. In: 2023 5th International Conference on Inventive Research in Computing Applications (ICIRCA). IEEE, pp. 1368–1373.
- Sobota, J., Pišl, R., Balda, P., Schlegel, M., 2013. Raspberry pi and arduino boards in control education. *IFAC Proceedings Volumes* 46 (17), 7–12.
- Sweller, J., Van Merriënboer, J. J., Paas, F. G., 1998. Cognitive architecture and instructional design. *Educational psychology review* 10 (3), 251–296.
- Vygotsky, L. S., Cole, M., 1978. *Mind in society: Development of higher psychological processes*. Harvard university press.