

TECNOLOGÍAS DIGITALES E IA · EDGE

APRENDIZAJE CONTINUO Y ADAPTATIVO EN EL EDGE.

On-device learning para IA embebida

Los sistemas de IA desplegados en dispositivos edge, como sensores, cámaras o pequeños nodos computacionales, necesitan ser capaces de adaptarse a nuevos datos y condiciones locales sin depender de la nube. El reto es permitir que el modelo aprenda directamente en el dispositivo, de forma continua, sin perder lo que ya ha aprendido y operando con recursos limitados. Este Trabajo Fin de Máster se centrará en explorar y evaluar técnicas de aprendizaje continuo (Continual Learning) y online learning, que permitan adaptar modelos ligeros directamente en dispositivos edge, como Raspberry Pi o NVIDIA Jetson. El trabajo combinará teoría y práctica: se estudiarán técnicas existentes, se implementarán al menos dos enfoques en tareas sencillas (como clasificación incremental), y se evaluarán sus capacidades de adaptación, eficiencia y consumo en hardware real.

● OBJETIVOS

- Entender y comparar los fundamentos de Continual Learning y Online Learning.
- Diseñar y probar un caso de uso representativo donde el aprendizaje local ofrezca ventajas claras.
- Evaluar el impacto en rendimiento, consumo, precisión y uso de recursos en dispositivos reales.
- Elaborar un análisis comparativo con recomendaciones prácticas para futuros despliegues.

● FASES DEL PROYECTO

- 1 Revisión del estado del arte**
 - Técnicas de continual learning (EWC, SI, replay buffers, dual-memory, dynamic expansion).
 - Análisis de online learning y streaming learning en IA embebida.
- 2 Selección de entornos y herramientas**
 - Hardware: Raspberry Pi 5, Jetson Nano, Coral, etc.
 - Frameworks: ContinualAI/avalanche, Scikit-multiflow, torchdistill, TFLite, TVM, etc.
- 3 Implementación de técnicas de aprendizaje local adaptativo**
 - Al menos dos técnicas de Continual/Online Learning sobre clasificación o regresión incremental.
 - Integración en modelos ligeros edge (MobileNet, TinyViT, TCNs...).
- 4 Diseño de experimentos en edge con datos dinámicos**
 - Detección de eventos en streaming sensorial, personalización en tiempo real, adaptación a nuevas clases.
- 5 Evaluación y benchmarking**
 - Métricas: precisión, tiempo de entrenamiento, uso de CPU/RAM, consumo energético, comunicación requerida, estabilidad.
- 6 Análisis crítico y conclusiones**
 - Fortalezas y limitaciones de cada técnica en escenarios edge.
 - Recomendaciones prácticas para futuros despliegues.
- 7 Demo o prueba de concepto aplicada**
 - Sistema que personaliza sus predicciones progresivamente con el uso, sin reentrenamiento global.