

CIFNet: Un método eficiente de un solo paso para el aprendizaje incremental por clases

Alejandro Dopico-Castro^{1*}, Oscar Fontenla-Romero¹, Bertha Guijarro-Berdiñas¹, and Amparo Alonso-Betanzos¹

Universidade da Coruña, CITIC, Facultade de Informática, Campus de Elviña, A Coruña, España
{alejandro.dopico2, oscar.fontenla, berta.guijarro, amparo.alonso.betanzos}@udc.es

Abstract

El olvido catastrófico constituye un desafío importante en el aprendizaje automático, especialmente en entornos con recursos limitados. Muchos métodos de aprendizaje incremental por clases (CIL) alcanzan una alta precisión, pero requieren un elevado coste computacional y entrenamiento iterativo, lo que limita su sostenibilidad. Proponemos CIFNet (Class Incremental and Frugal Network), un enfoque CIL eficiente para tareas de visión por computador que combina un extractor de características preentrenado congelado, un búfer de datos comprimido y un clasificador ligero de una sola capa. Este diseño evita el *fine-tuning* y las actualizaciones iterativas, permitiendo la optimización en un único paso sobre características fijas, lo que reduce significativamente tanto la sobrecarga como el tiempo de entrenamiento. Los experimentos con conjuntos de datos de referencia muestran que CIFNet iguala la precisión de los métodos del estado del arte, a la vez que mejora la eficiencia y la sostenibilidad, haciendo el CIL más viable en entornos con recursos limitados.

1 Introducción

El aprendizaje incremental por clases (CIL) aborda la adquisición de conocimiento continuo, particularmente en tareas de clasificación de imágenes, pero los enfoques actuales dependen de un costoso ajuste de su estructura principal, siendo insostenibles en entornos con recursos limitados como la robótica. Proponemos **CIFNet**, un método CIL que prioriza la eficiencia y la sostenibilidad, que combate el olvido catastrófico-la pérdida de rendimiento en clases previamente aprendidas al incorporar nueva-sin optimización iterativa, ofreciendo una solución escalable.

2 Método

CIFNet [1] maximiza la eficiencia en el aprendizaje incremental de clases. Primero, un extractor de características congelado basado en un *backbone* preentrenado (por ejemplo, ResNet) transforma las imágenes en representaciones latentes estables y compactas, eliminando la necesidad de *fine-tuning*, principal fuente de coste computacional en otros métodos. En segundo lugar, la clasificación se realiza mediante una capa ROLANN (Regularized One-Layer Neural Network) [2], que calcula sus pesos de forma analítica mediante una solución en forma cerrada, evitando la optimización iterativa por descenso de gradiente y permitiendo incorporar nuevas clases en un único paso. Por último, un búfer de expansión con sobremuestreo almacena un subconjunto de representaciones latentes de clases previas, de mucho menor tamaño que las imágenes originales, reduciendo así el consumo de memoria. Antes de actualizar la capa ROLANN, se aplica una estrategia de sobremuestreo temporal que equilibra la contribución de

*Investigación financiada por el proyecto FRUGAL (PID2023-147404OB-I100), PILLAR-Robots (GA 101070381, Horizon Europe) y por la Cátedra UDC-Inditex en Algoritmos Verdes, con apoyo del Ministerio de Transformación Digital y Función Pública y fondos NextGenerationEU/PRTR (TSI-100925-2023-1).

clases antiguas y recientes, mitigando el sesgo que favorece el aprendizaje de las recientes frente a las más antiguas, y mejorando la calibración de las neuronas añadidas.

3 Resultados

El rendimiento de CIFNet se contrastó con otros métodos del estado de la técnica sobre los benchmarks CIFAR-100 e ImageNet-100, demostrando un buen equilibrio entre precisión y eficiencia. En CIFAR-100 (Figura 1), con 5 clases por incremento, nuestro enfoque alcanzó una precisión final del **59,3%**, superando a métodos complejos como DER (57,3%), entrenando 7 veces más rápido y consumiendo 11 veces menos energía. La ventaja fue aún más pronunciada en el conjunto de datos a gran escala ImageNet-100. Con incrementos de 5 clases, CIFNet alcanzó una precisión del **78,1%**, más de 15 puntos por encima del siguiente mejor método, con una reducción de 37 veces en el consumo energético.

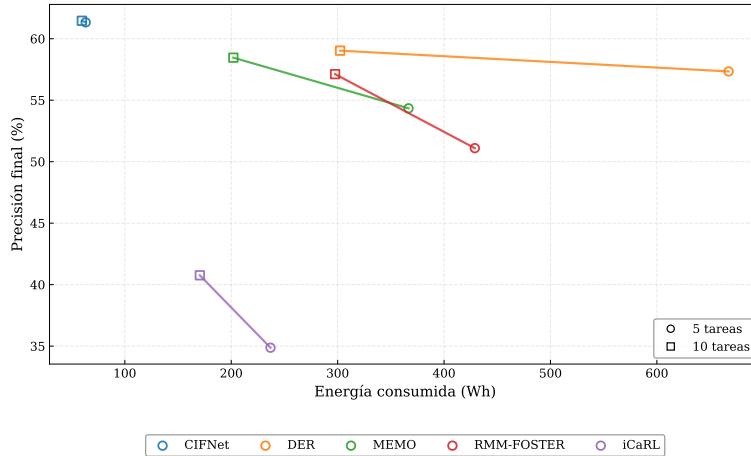


Figure 1: Precisión frente a energía en CIFAR-100 (5 y 10 clases/tarea).

4 Conclusión

CIFNet demuestra que es posible lograr una precisión competitiva en CIL sin una costosa adaptación del *backbone*. Su arquitectura, basada en características congeladas y una actualización en un solo paso, lo posiciona como una solución adecuada para aplicaciones donde la eficiencia computacional y energética es clave, tales como entornos IoT. Su principal limitación aparece en dominios con grandes desviaciones respecto a los datos de preentrenamiento. Futuros trabajos explorarán módulos de adaptación ligeros para ampliar su aplicabilidad manteniendo su diseño eficiente.

References

- [1] A. Dopico-Castro, O. Fontenla-Romero, B. Guijarro-Berdiñas, and A. Alonso-Betanzos. Efficient single-step framework for incremental class learning, 2025.
- [2] O. Fontenla-Romero, B. Guijarro-Berdiñas, and B. Pérez-Sánchez. Regularized one-layer neural networks for distributed and incremental environments. In *Proc. IWANN*, pages 343–355, 2021.