



Plasticidad sináptica para mitigar el problema del olvido catastrófico durante el aprendizaje continuo en redes neuronales artificiales

Jairo David Campaña Rosero

Tesis de grado para optar al título de Ingeniero de Sistemas

Asesor

Augusto Enrique Salazar Jiménez, Ph.D.

Universidad de Antioquia
Facultad de Ingeniería
Ingeniería de Sistemas
Medellín, Antioquia, Colombia

2023

Cita	J. D. Campaña-Rosero, 2023 [1]
Referencia	[1] J. D. Campaña-Rosero “Plasticidad sináptica para mitigar el problema del olvido catastrófico durante el aprendizaje continuo en redes neuronales artificiales”, Tesis de grado, Ingeniería de Sistemas, Universidad de Antioquia, Medellín, 2023
Estilo IEEE (2020)	



Centro de Documentación de Ingeniería (CENDOI) UdeA

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

Rector: John Jairo Arboleda Céspedes.

Decano/Director Julio César Saldarriaga Molina.

Jefe departamento: Diego José Luis Botia Valderrama.

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Dedicatoria

A mis padres por su amor incondicional y apoyo inquebrantable a lo largo de mi vida. Gracias por creer e inculcar en mi el valor del trabajo duro, la perseverancia y la pasión por el aprendizaje.

A mis hermanos, por ser siempre mi inspiración y por compartir conmigo la alegría de alcanzar nuestros sueños.

A mis amigos y compañeros de estudio, quienes han sido una fuente inagotable de inspiración y motivación durante este viaje; Por los momentos compartidos y las risas que hicieron más ligeros los desafíos.

Esta tesis es un reflejo de todos ustedes y les dedico humildemente este logro.

Agradecimientos

En primer lugar, quiero expresar mi más profundo agradecimiento a mi asesor principal, Ph.D. Augusto Enrique Salazar Jiménez, cuya guía, experiencia y apoyo han sido fundamentales para el desarrollo de esta tesis.

Agradezco a Ph.D. Julián David Arias Londoño, quien me motivo, me inspiró, me apoyó y guió durante las primeras etapas de esta tesis, fue la base fundamental para su definición y planificación. Gracias por su paciencia, conocimiento y voluntad para ayudarme superar mis límites y enfrentar nuevos desafíos.

De igual manera, le agradezco a cada uno de los docentes y administrativos del Departamento de Ingeniería de Sistemas, quienes velaron constantemente para hacer de mi un excelente profesional. De manera personal, le agradezco a Diana Margot López, Carlos Sierra, Gabriel Uribe y Roberto Flórez, por ser mis guías fuera de los cursos, brindarme su amistad, orientarme a reconocer mis capacidades e identificar el tipo de profesional que quiero ser.

Agradezco a mis amigos, compañeros y colegas, por hacer de este viaje una experiencia inolvidable. Particularmente le agradezco a mi mejor amigo, Sebastian Pelaez, por brindarme todo su apoyo y consejos.

También quiero agradecer a mi familia, por ser el pilar en el que siempre he podido apoyarme y por brindarme todo su amor y apoyo incondicional. Gracias por creer en mí y darme la fuerza para seguir adelante.

Muchas gracias a todos por ayudarme a cumplir mis sueños.

TABLA DE CONTENIDO

RESUMEN	11
ABSTRACT	12
INTRODUCCIÓN	13
1 PLANTEAMIENTO DEL PROBLEMA	15
1.1 Antecedentes	15
2 JUSTIFICACIÓN	16
3 OBJETIVOS	17
3.1 Objetivo general	17
3.2 Objetivos específicos	17
4 MARCO TEÓRICO	18
4.1 Olvido Catastrófico	18
4.2 Plasticidad Neuronal	19
4.3 Escenarios de aprendizaje continuo	20
4.4 Bases de datos para Benchmarking	20
4.5 Métricas de evaluación	21
4.5.1 Accuracy	21
4.5.1.1 Accuracy de clasificación por tarea:	22
4.5.2 Forgetting	23
4.5.3 Forward Transfer	23
4.5.4 Backward Transfer	23

4.6	Estrategias de aprendizaje continuo	24
4.6.1	Continual Learning Through Synaptic Intelligence (SI)	24
4.6.2	Learning to Continually Learn (LCL)	26
4.6.3	Estrategia Naive	29
4.6.4	Estrategia Acumulativa	29
5	METODOLOGÍA	30
5.1	Etapa 1 - Investigación conceptual y selección de estrategias	30
5.2	Etapa 2 - Definición de escenarios.	31
5.3	Etapa 3 - Selección y extracción de bases de datos	32
5.3.1	Selección de las bases de datos	32
5.3.2	Extracción de las bases de datos	33
5.4	Etapa 4 - Definición de métricas	34
5.5	Etapa 5 - Diseño Experimental	35
5.5.1	Preparación y procesamiento de los datos	35
5.5.1.1	Procesamiento CIFAR100.	36
5.5.1.2	Procesamiento OMNIGLOT	39
5.5.2	Procedimiento experimental	40
5.5.2.1	Procedimiento para LCL	42
5.5.2.2	Procedimiento para SI	43
5.5.2.3	Procedimiento para Naive y Acumulativo	43
6	RESULTADOS	45
6.1	Resultados en la base de datos CIFAR100	45
6.1.1	Escenario IC	45
6.1.1.1	Configuración de los experimentos	46
6.1.1.2	Resultados	47

6.1.2	Escenario II.	47
6.1.2.1	Configuración de los experimentos	49
6.1.2.2	Resultados	51
6.1.3	Escenario IIC	52
6.1.3.1	Configuración de los experimentos	53
6.1.3.2	Resultados	54
6.2	Resultados OMNIGLOT	57
6.2.1	Escenario IC	58
6.2.1.1	Configuración de los experimentos	59
6.2.1.2	Resultados	60
7	DISCUSIÓN	66
7.1	Desafíos y oportunidades en el aprendizaje continuo	67
8	CONCLUSIONES	68
	REFERENCIAS	70
	APÉNDICES	76
	Apéndice I Resultados de Experimentos OMNIGLOT	76
I.1	Resultados adicionales para escenario IC	76
I.1.1	Análisis de resultados adicionales	76

LISTA DE TABLAS

Tabla I	Experiencias del escenario IC en CIFAR100	37
Tabla II	Experiencias del escenario II para CIFAR100	38
Tabla III	Experiencias del escenario IIC para CIFAR100	40
Tabla IV	Experiencias del escenario IC para OMNIGLOT	41
Tabla V	Arquitectura de la red neuronal SI	44

LISTA DE FIGURAS

Fig. 4.1 Ilustración de las trayectorias de los parámetros durante el entrenamiento de dos tareas en la estrategia SI.	25
Fig. 4.2 Arquitectura ANML	27
Fig. 6.1 Resultados escenario IC para Accuracy en CIFAR100	48
Fig. 6.2 Resultados escenario IC para Forgetting en CIFAR100	49
Fig. 6.3 Resultados escenario IC para Forward Transfer en CIFAR100	50
Fig. 6.4 Resultados escenario IC para Backward Transfer en CIFAR100	51
Fig. 6.5 Resultados escenario II para Accuracy en CIFAR100	53
Fig. 6.6 Resultados escenario II para Forgetting en CIFAR100	54
Fig. 6.7 Resultados escenario II para Forward Transfer en CIFAR100	55
Fig. 6.8 Resultados escenario II para Backward Transfer en CIFAR100	56
Fig. 6.9 Resultados escenario IIC para Accuracy en CIFAR100	57
Fig. 6.10 Resultados escenario IIC para Forgetting en CIFAR100	58
Fig. 6.11 Resultados escenario IIC para Forward Transfer en CIFAR100	59
Fig. 6.12 Resultados escenario IIC para Backward Transfer en CIFAR100	60
Fig. 6.13 Resultados escenario IC para Accuracy en OMNIGLOT - Parte 1	62
Fig. 6.14 Resultados escenario IC para Forgetting en OMNIGLOT - Parte 1	63
Fig. 6.15 Resultados escenario IC para Forward Transfer en OMNIGLOT - Parte 1	64
Fig. 6.16 Resultados escenario IC para Backward Transfer en OMNIGLOT - Parte 1	65
Fig. I.1 Resultados escenario IC para Accuracy en OMNIGLOT - Parte 2	77
Fig. I.2 Resultados escenario IC para Forgetting en OMNIGLOT - Parte 2	78

Fig. I.3 Resultados escenario IC para Forward Transfer en OMNIGLOT - Parte 2 79

Fig. I.4 Resultados escenario IC para Backward Transfer en OMNIGLOT - Parte 2 80

Siglas, acrónimos y abreviaturas

ANN	Red Neuronal Artificial
CF	Olvido Catastrófico
EWC	Elastic Weight Consolidation
GPU	Graphic Card Unit
IC	Incremento de Clases
II	Incremento de Instancias
IIC	Incremento de Instancias y Clases
Ph.D.	Philosophie Doctor
UdeA	Universidad de Antioquia

RESUMEN

Abordar el problema del olvido catastrófico en redes neuronales artificiales (ANNs), es crucial en la liberación de su potencial para adaptarse y aprender continuamente en diferentes contextos y dominios sin perder el conocimiento previamente aprendido. Mitigarlo puede convertir a las ANNs en sistemas óptimos y versátiles.

Este estudio realiza un análisis comparativo de dos estrategias de aprendizaje continuo bio-inspiradas en la plasticidad sináptica: Learning to Continually Learn (LCL) y Continual Learning Through Synaptic Intelligence (SI). Estas estrategias buscan mitigar el problema del olvido catastrófico en el contexto de clasificación de imágenes. La investigación evalúa y contrasta las capacidades de LCL y SI para permitirle a las ANNs aprender continuamente en múltiples tareas y dominios.

Los resultados experimentales muestran como las estrategias se desempeñan en tres escenarios. Pese a su baja capacidad de representación, la estrategia LCL muestra comportamientos interesantes, como tasas de olvido relativamente bajas, permitiéndole aprender nuevas clases o instancias sin afectar negativamente las previamente aprendidas. Por otro lado, la estrategia SI presentó problemas graves de olvido catastrófico al aprender nuevas clases.

Esta investigación ofrece información valiosa sobre el comportamiento de las estrategias LCL y SI, basadas en la plasticidad sináptica, para abordar el problema del olvido catastrófico en las ANNs. Las implicaciones de estos resultados destacan la importancia de investigaciones y desarrollos adicionales, para refinar las estrategias de aprendizaje continuo y ampliar su impacto potencial en diversas aplicaciones de inteligencia artificial. Este estudio contribuye a la búsqueda de modelos de aprendizaje más adaptables y eficientes.

Palabras clave — Aprendizaje Continuo, Machine Learning, Computación neural y evolutiva

ABSTRACT

Addressing the catastrophic forgetting problem in artificial neural networks (ANNs), is essential for unlocking their potential to adapt and learn continuously across various contexts and domains without losing previously acquired knowledge. Mitigating this issue can transform ANNs into more optimal and versatile systems, enabling them to handle dynamic data efficiently and accurately.

This study conducts a comparative analysis of two bio-inspired continuous learning strategies based on synaptic plasticity: Learning to Continually Learn (LCL) and Continual Learning Through Synaptic Intelligence (SI). These strategies aim to mitigate the catastrophic forgetting problem in the context of image classification tasks. The research evaluates and contrasts the ability of LCL and SI to enable ANNs to learn continuously across multiple tasks and domains.

The experimental results demonstrate the performance of both strategies in three distinct scenarios. Despite its low representation capacity, the LCL strategy exhibits intriguing behaviors, such as relatively low forgetting rates, enabling it to learn new classes without negatively affecting previous ones. In contrast, the SI strategy encounters significant catastrophic forgetting issues when incorporating new classes.

This investigation provides valuable insights into the behavior of LCL and SI strategies, based on synaptic plasticity, for addressing the catastrophic forgetting problem in ANNs. The implications of these findings emphasize the need for further research and development to refine continuous learning strategies, enhancing their potential impact across various artificial intelligence applications. The study contributes to the ongoing pursuit of more adaptable and efficient learning models.

Keywords — Continual Learning, Machine Learning, Neural and Evolutionary Computing

INTRODUCCIÓN

El cerebro es uno de los órganos que más ha sido estudiado por la humanidad debido a su gran importancia en el desarrollo de la memoria y la inteligencia en diversos animales. Estos estudios han realizado descubrimientos y desarrollado teorías sobre la importancia de la NeuroPlasticidad (responsable de actuar en el cambio de la composición neuronal interna, permitiendo el crecimiento y la reorganización de las sinapsis de forma funcional y estructural [1]) en la formación de la memoria a través de experiencias [2].

Debido a la necesidad del ser humano de resolver problemas complejos de forma automatizada, tales como la visión por computador o el reconocimiento de voz, se recurrió a la inspiración en la investigación del cerebro, propiciada por las neurociencias, donde se desarrollaron las Redes Neuronales Artificiales (ANN). Estas son simplificaciones de las redes neurales biológicas, capaces de aprender con base en los patrones de la información que se les provea, teniendo como finalidad, la realización de tareas específicas. Sin embargo, en sistemas de aprendizaje continuo, donde la información se obtiene de forma secuencial, las ANN sufren del llamado olvido catastrófico (CF), ocurrido a causa de la degradación total en las representaciones de las tareas previamente aprendidas debido al aprendizaje de nuevas tareas. Este problema se presenta a causa de la baja complejidad sináptica manejada por las ANN, donde éstas son representadas como escalares y presentan un muy alto nivel de plasticidad, razón de la degradación [3], mientras que en los sistemas neuronales biológicos se hace uso de una compleja maquinaria molecular que afecta la plasticidad en diferentes escalas espaciales y temporales [4]. Esta es una de las diferencias que tienen con los sistemas neuronales biológicos, quienes son capaces de aprender sin olvidar catastróficamente.

En los últimos años se han realizado diversos estudios teniendo como objetivo la mitigación del olvido catastrófico en el aprendizaje continuo para las ANN, varios de estos, se han inspirado en el postulado de la asamblea celular o también llamada ley de Hebb [5]; expone como las neuronas que de forma constante se activan juntas, tienden a asociarse mediante una sinapsis y actuar de forma conjunta, a su vez, esta interacción fortalece o debilita la fuerza que hay en el enlace sináptico. Según Hebb, este es uno de los procesos

neuroquímicos importantes para la fundación de la memoria y el aprendizaje. Basados en este postulado, se han construido diversas estrategias de implementación a nivel computacional para las ANN de la nombrada propiedad, teniendo como objetivo el manejo inteligente de la plasticidad en sus pesos. Los resultados de estos estudios, exhiben el cómo se logra mitigar el problema del olvido catastrófico en el aprendizaje continuo en un alto grado en diversos tipos de tareas.

Por lo anterior, el presente trabajo busca evaluar la capacidad de dos estrategias pertenecientes al estado del arte, implementadas haciendo uso de enfoques computacionales de la plasticidad sináptica, para mitigar el problema del olvido catastrófico en aprendizaje continuo. Para ello, se definirá un marco metodológico donde se establecerán los escenarios de evaluación del aprendizaje continuo, las bases de datos compatibles con estos, los experimentos a realizar y las métricas que permitirán evaluar el rendimiento y el nivel de olvido que se presenta en los procesos de entrenamiento de cada estrategia.

Capítulo 1

PLANTEAMIENTO DEL PROBLEMA

Las ANN, se han posicionado como unos modelos de aprendizaje por computador ampliamente usados en diversas aplicaciones, que han facilitado y automatizado una gran lista de tareas que fueron realizadas previamente por el ser humano; desde la visión por computadora, hasta el procesamiento de lenguaje natural. Sin embargo, a pesar de su éxito, las investigaciones se enfrentan a un desafío llamado olvido catastrófico (CF), que limita sus capacidades de adaptación para su uso en diferentes contextos y dominios. El CF implica que las ANN no tengan la capacidad de recordar la información aprendida previamente, luego de que se introduce y se ajusta a una nueva información perteneciente a otro contexto o dominio, lo que dificulta el entrenarlas de forma secuencial y continua.

El problema del CF, causa que las ANN se conviertan en modelos altamente especializados y requieran de nuevos entrenamientos completos para poder expandir sus capacidades de forma progresiva sobre otros contextos o dominios. Por lo que, dada la naturaleza cambiante de los datos, se necesitan explorar soluciones que permitan que los modelos de ANN sean capaces de adaptarse de forma continua y efectiva al cambio de los datos, lo que mejoraría su eficacia en diversas aplicaciones.

1.1 Antecedentes

Se han realizado varias investigaciones que tienen como objetivo aliviar la magnitud del problema expuesto, para lo cual diseñaron diferentes metodologías: el método de repetición de experiencia [6], redes neuronales progresivas [7], redes neuronales pre-entrenadas [8], elastic weight consolidation (EWC) [9], entre otras. Sin embargo, estos métodos, en muchas de las ocasiones, necesitan de una manual selección de parámetros, no funcionan en aprendizaje continuo, o se vuelven a largo plazo costosos computacionalmente, como es el caso de las redes neuronales progresivas.

Capítulo 2

JUSTIFICACIÓN

La investigación en áreas como la inteligencia artificial se encuentran en constante evolución y crecimiento, por tal razón, desarrollo de modelos de ANN con capacidades de aprendizaje y adaptación continua, es crucial para la evolución en este campo. El CF, es un problema importante que causa una gran limitación en la aplicación efectiva de modelos de ANN en diversas áreas [10, 11].

La solución o mejoramiento del CF, supone un cambio del paradigma de los desarrollos de ANNs y sus técnicas, que les permitiría convertirse en sistemas capaces de aprender continuamente durante su tiempo de existencia y convertirse en expertos ejecutando actividades, siendo capaces de aplicar competencias previas en nuevas situaciones, sin olvidar el conocimiento previamente aprendido.

La capacidad de adaptación continua y aprendizaje en modelos de ANNs, es un punto esencial para lograr soluciones eficientes y efectivas en diversas áreas de la inteligencia artificial, por lo que es crucial, abordar el problema del CF y encontrar soluciones efectivas que permitan a modelos de ANN, aprender de forma continua y mejorar su desempeño con el tiempo.

La presente investigación, busca realizar un estudio comparativo entre algunas estrategias de aprendizaje continuo expuestas en el estado del arte, basadas en el concepto neuro-científico de la plasticidad sináptica para mitigar el problema del CF en diversos tipos de escenarios.

Capítulo 3

OBJETIVOS

3.1 Objetivo general

Realizar un estudio comparativo entre estrategias de implementación de la plasticidad sináptica en redes neuronales artificiales, utilizando una metodología de aprendizaje continuo en el contexto de clasificación de imágenes, con el fin de verificar el efecto en la mitigación del olvido catastrófico.

3.2 Objetivos específicos

- Implementar las estrategias de plasticidad sináptica propuestas en los estudios Learning to Continually Learn (LCL) y Continual Learning Through Synaptic Intelligence (SI).
- Diseñar y ejecutar experimentos para medir la capacidad de las estrategias LCL y SI para mitigar el problema del olvido catastrófico y aprender continuamente.
- Evaluar la capacidad de las estrategias para mitigar el problema del olvido catastrófico y aprender continuamente.

Capítulo 4

MARCO TEÓRICO

Desde su desarrollo, las ANN se han convertido en una tecnología imprescindible para el ser humano, ayudando a la realización de múltiples tareas en un dominio específico y, en muchos de los casos, lo supera en la calidad de los resultados generados. Su desarrollo tuvo un alta inspiración biológica en un intento de simular los procesos realizados al interior de un cerebro humano. Sin embargo, los procesos de diseño y principios de aprendizaje y manejo de datos, no cuentan con esta bioinspiración; el proceso de ajuste de los pesos en una ANN, se realiza a través del uso de una cantidad masiva de datos durante la fase de entrenamiento y son congelados al finalizarla, para posteriormente ser usados en tareas de inferencia. Si se requiere re-acomodar los parámetros a nueva distribución de datos, la ANN debe ser reentrenada sobre todos los datos para evitar problemas como el sobre ajuste y olvido catastrófico [4]. Por su parte, el ser humano es capaz de aprender continuamente sobre nueva información, olvidando de forma gradual a largo plazo, sin necesidad de revisar todo lo que ha aprendido durante el transcurso de su vida.

4.1 Olvido Catastrófico

El olvido catastrófico, es uno de los principales problemas presentes para las ANN usadas en el llamado aprendizaje continuo, en donde toda nueva información aprendida interfiere con el conocimiento previo. Uno de los estudios más representativos sobre este fenómeno es el de M. McCloskey y N. J. Cohen [12], quienes aseguran que dicha interferencia ocurre cuando los nuevos aprendizajes alteran los pesos en las ANN que representan los antiguos, además, se afirma que entre más grande sea el nuevo aprendizaje, mayor será la disrupción del conocimiento previo. Por su parte, R. Ratcliff [13] en su estudio encontró que en grandes o pequeñas redes neuronales de propagación hacia atrás, la información correctamente aprendida fue catastróficamente olvidada a medida que se ingresó nueva información, y esta es representada, modificando los pesos de las neuronas previamente usadas.

4.2 Plasticidad Neuronal

El avance en las neurociencias ha permitido un mayor entendimiento y desarrollo de las teorías sobre el cerebro y su manera de representar el conocimiento, donde se identifica como uno de los componentes fundamentales la llamada plasticidad neural, encargada de manejar la interacción entre neuronas mediante sus conexiones sinápticas, siendo de esta forma capaz de crearlas, potenciarlas o deprimirlas [2]. Uno de los más grandes exponentes de las neurociencias, Donald Hebb, propone en su teoría de la asamblea celular [5] que la plasticidad neural es uno de los procesos neuroquímicos más importantes para la fundación de la memoria y el aprendizaje, a partir de esto, se puede considerar que el conocimiento es representado por una vasta red de circuitos neurales interconectados. De manera conjunta, estas nuevas teorías han labrado el camino para el planteamiento de nuevas estrategias buscando que el diseño de las ANN sea capaz de manejar de forma adaptativa las interacciones plásticas en sus conexiones.

La plasticidad neuronal presenta dos vertientes que definen su comportamiento: neuroplasticidad estructural y funcional. La neuroplasticidad estructural, es encargada de la creación o destrucción de las sinapsis formadas entre neuronas, mientras que la funcional o también llamada plasticidad sináptica, se refiere a la alteración de la eficacia en la transmisión electroquímica de las sinapsis, en otras palabras, la alteración de la fuerza en las sinapsis existentes [14]. Las nuevas metodologías de diseño de ANN, han tomado inspiración principalmente en la plasticidad sináptica, dado que su funcionamiento es compatible con los dispositivos de cálculo de matrices existentes a la fecha (GPU) para realizar los procesos de propagación hacia adelante y hacia atrás. Por otro lado, las metodologías basadas en la plasticidad estructural, requieren sistemas más especializados debido a la alta mutabilidad de sus estructuras neuronales y sinápticas, proceso que es incompatible con estos dispositivos, presentando de esta manera, altos costos computacionales y en tiempo.

4.3 Escenarios de aprendizaje continuo

Una basta cantidad de investigaciones previas sobre el aprendizaje continuo, han compartido como su principal objetivo, la mitigación del olvido catastrófico durante el aprendizaje de nuevas representaciones o tareas. Sin embargo, hacer uso de únicamente este escenario no es idóneo para evaluar las capacidades de estas estrategias en el aprender continuamente. Con la finalidad de evaluarlas de una forma más amplia, el trabajo de V. Lomonaco y D. Maltoni [15], define tres escenarios que representan el aprendizaje continuo: incremento de clases, incremento de instancias e incremento de instancias y clases.

Incremento de clases (IC): Se cuenta con datos compuestos por una cantidad significativa de clases diferentes. La estrategia deberá ser capaz de aprender nuevas representaciones sin olvidar catastróficamente las previamente aprendidas.

Incremento de instancias (II): Se cuenta con nuevos datos pertenecientes a representaciones ya aprendidas por la estrategia (clases), que cuentan con nuevas condiciones u orientaciones (fondo, oclusión, ángulo, iluminación, etc.). Bajo este escenario, una estrategia debe ser capaz de mejorar sus capacidades de generalización sobre las clases que ya se conocen previamente mediante los nuevos datos sin olvidar catastróficamente lo previamente aprendido.

Incremento de instancias y clases (IIC): Se cuenta con datos pertenecientes tanto a nuevas clases como a las ya existentes; se presenta la unión de los dos escenarios previamente nombrados. Una estrategia debe ser capaz de consolidar su conocimiento sobre las clases conocidas y aprender las nuevas clases sin olvidar catastróficamente.

4.4 Bases de datos para Benchmarking

Frecuentemente, para los procesos de benchmarking de las estrategias de aprendizaje continuo en imágenes, se han usado bases de datos comunes en el estado del arte, como lo son CIFAR100 [16] u OMNIGLOT [17]. Estas bases de datos cuentan con atributos requeridos para la evaluación de la capacidad del aprendizaje continuo y mitigación del olvido catastrófi-

co, que son diversidad de clases y en dominio de estas. La base de datos CIFAR100 contiene imágenes de objetos o animales y está compuesta por 50000 muestras en formato RGB de resolución 32x32, donde existen 100 clases y 500 muestras por clase, estas clases están contenidas en 20 superclases. Un ejemplo del presente sistema de agrupaciones es la superclase mamífero acuático, que contiene imágenes de las clases castor, delfín, nutria, foca y ballena. Por otra parte, la base de datos de OMNIGLOT se compone por 1623 caracteres escritos a mano provenientes de 50 distintos alfabetos y escritos por 20 diferentes personas, cuenta con imágenes de resolución de 105x105, se encuentra enfocado en aprendizaje continuo, meta aprendizaje y aprendizaje de pocas iteraciones (few shot learning).

4.5 Métricas de evaluación

Durante el desarrollo de estrategias para el aprendizaje continuo se encuentra la necesidad de definir métricas de evaluación, que ayudaran a medir las capacidades de cada una de estas para cumplir el objetivo de aprender continuamente y mitigar el CF. Uno de los estudios más relevantes expone el marco de trabajo CLEVA-Compass [18], que define métricas enfocadas en evaluar la capacidad del aprendizaje continuo en cualquier estrategia, teniendo como objetivo el propiciar la transparencia, compatibilidad y la reproducibilidad de las investigaciones que lo apliquen. Este marco de trabajo cuenta con métricas para medir: la precisión de cada estrategia durante cada proceso de evaluación post-entrenamiento secuencial y el nivel de olvido que presenta cada estrategia durante el aprendizaje de un nuevo conocimiento mediante las métricas: Forgetting, Forward Transfer y Backward transfer.

Para el entendimiento de las siguientes formulaciones matemáticas, se establece a t como las tareas observables en $t = 1, \dots, T$.

4.5.1 Accuracy

Para la evaluación de la capacidad de las estrategias para aprender continuamente, se debe medir la precisión que mantienen durante el transcurso del tiempo y para cada una de sus

clases o tareas. Por lo que, se define el cálculo para accuracy por clase o tarea como a_T , el perteneciente a la nueva tarea aprendida Ω_{new} (4.3), el perteneciente a la primera tarea aprendida luego de que algunas tareas fuesen aprendidas Ω_{base} (4.2) y el calculado sobre todas las tareas aprendidas hasta la última secuencia de entrenamiento Ω_{all} (4.4). Finalmente, el accuracy offline en el conjunto base de testeo α_{ideal} [18].

4.5.1.1 Accuracy de clasificación por tarea:

Inicialmente, se define la matriz de accuracy $a \in \mathbb{R}^{TxT}$ donde $a_{i,j}$ es el accuracy de clasificación de testeo del modelo en la tarea j -ésima, luego de observar la última muestra de la tarea i . Se define el accuracy promedio final como (4.1). [18]

$$a_T = \frac{1}{T} \sum_{t=1}^T a_{T,t} \quad (4.1)$$

Accuracy “base” de clasificación:

$$\Omega_{base} = \frac{1}{T-1} \sum_{t=2}^T \frac{\alpha_{base,t}}{\alpha_{ideal}} \quad (4.2)$$

Accuracy “new” de clasificación:

$$\Omega_{new} = \frac{1}{T-1} \sum_{t=2}^T \alpha_{new,t} \quad (4.3)$$

Accuracy “all” de clasificación:

$$\Omega_{all} = \frac{1}{T-1} \sum_{t=2}^T \frac{\alpha_{all,t}}{\alpha_{ideal}} \quad (4.4)$$

4.5.2 Forgetting

Mide la diferencia entre el máximo conocimiento obtenido en cada una de las tareas durante el proceso de entrenamiento y el conocimiento que tiene actualmente. Se define el olvido de la j -ésima tarea, luego de ser entrenado hasta la tarea t como (4.5) y el olvido medio luego de que la tarea t ya hubiese sido aprendida como la ecuación (4.6) [18]

$$f_j^t = \max_{i \in \{1, \dots, t-1\}} a_{i,j} - a_{t,j}, \forall j < t \quad (4.5)$$

$$F_t = \frac{1}{t-1} \sum_{j=1}^{t-1} f_j^t \quad (4.6)$$

4.5.3 Forward Transfer

Se define como la influencia en el rendimiento para tareas futuras $j > t$ cuando el modelo está aprendiendo t . Se representa mediante la ecuación (4.7). [18]

$$FWT_{t,j} = a_{t-1,j} - \bar{b}_j \quad (4.7)$$

, donde \bar{b}_j es el accuracy en la tarea j de una línea base aleatoria. La media de esta métrica se define como (4.8)

$$FWT_t = \frac{1}{t-1} \sum_{j=2}^{t-1} FWT_{j-1,j} \quad (4.8)$$

4.5.4 Backward Transfer

Se define como la influencia en el rendimiento del modelo para la tarea previa $j < i$ cuando el modelo está aprendiendo la tarea t . Este se representa por la ecuación (4.9) y su media por la ecuación (4.10). [18]

$$BTW_{t,j} = a_{t,j} - a_{j,j} \quad (4.9)$$

$$BTW_t = \frac{1}{t-1} \sum_{j=1}^{t-1} BTW_{t,j} \quad (4.10)$$

4.6 Estrategias de aprendizaje continuo

Durante el transcurso de esta sección se explorarán a profundidad diversas estrategias de aprendizaje continuo que se inspiran en la plasticidad sináptica, ofreciendo una visión detallada de su funcionamiento y procedimientos. Estas estrategias buscan simular el proceso natural de adaptación y cambio en las sinapsis de las redes neuronales para mejorar sus capacidades de aprender continuamente.

Entre las estrategias abordadas se incluyen las propuestas por los estudios Continual Learning Through Synaptic Intelligence (SI) [4] y Learning to Continually Learn (LCL) [19] y dos estrategias de línea base que permitirán comparar sus capacidades con los procedimientos estándares de entrenamiento de ANN (Naive) y una primera solución para el aprendizaje continuo (Acumulativa).

Cada una de estas estrategias presenta enfoques y métodos únicos utilizados para abordar este problema, permitiendo a los modelos de ANN adaptarse y mejorar a medida que se enfrentan a nuevos datos y tareas. Su objetivo es desarrollar sistemas de aprendizaje más robustos y eficaces, capaces de enfrentarse a los retos cambiantes en el mundo.

4.6.1 Continual Learning Through Synaptic Intelligence (SI)

El trabajo de Zenke et al. [4] se establece como una variante a EWC, enfocada en cumplir la tarea de aprendizaje continuo mediante la propuesta de calcular de forma online, durante cada etapa de optimización, la importancia de cada sinapsis. Donde su finalidad es la penalización de cambios drásticos que puedan provocar la pérdida de información sobre tareas previamente aprendidas (fig. 4.1).

Con el fin de cumplir con este objetivo se establece el término de error surrogado, definido por la expresión (4.11)

$$\tilde{L}_\mu = L_\mu + c \underbrace{\sum_k \Omega_k^\mu (\tilde{\theta}_k - \theta_k)}_{\text{error surrogado}} \quad (4.11)$$

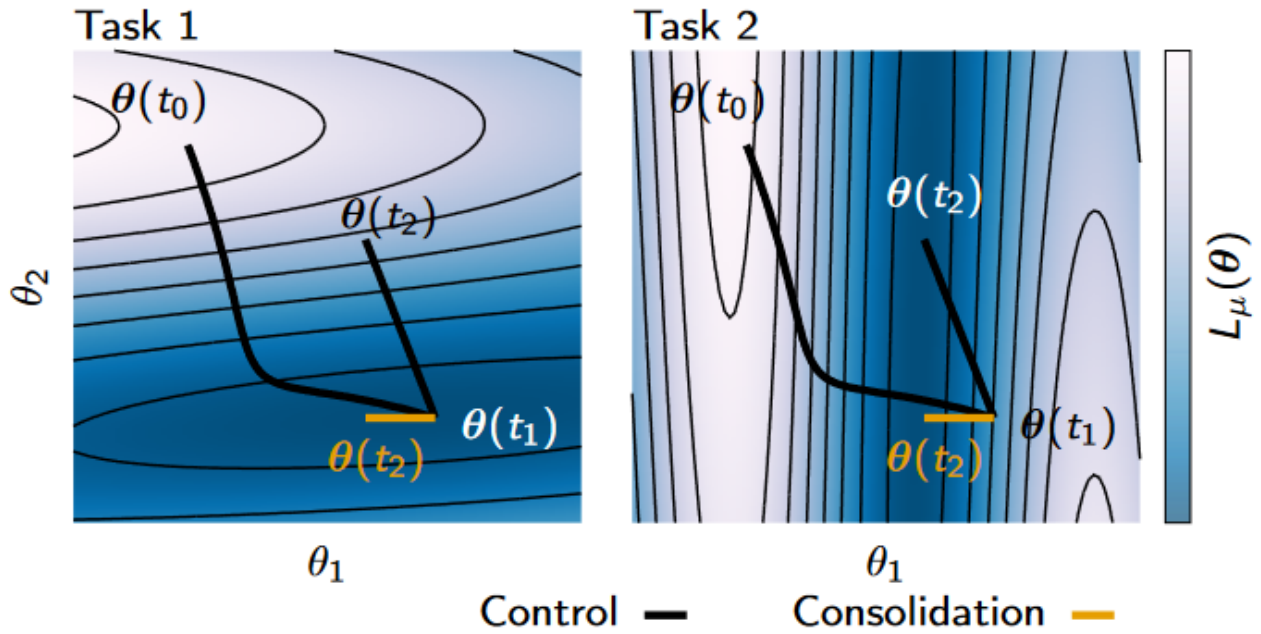


Fig. 4.1. Ilustración de las trayectorias de los parámetros durante el entrenamiento de dos tareas en la estrategia SI.

El valor de cada función de costo L_μ se muestra como un mapa de calor. El gradiente descendente en la tarea 1 induce el movimiento de los parámetros desde t_0 a t_1 . Por consiguiente el entrenamiento de la tarea supone el movimiento de los parámetros hacia el punto t_2 representado en color blanco, que implica la degradación del conocimiento aprendido durante la tarea 1 dado el aumento del error, por lo tanto, existe un punto secundario, representado en color naranja, que logra un cambio mínimo en el error de ambas tareas. Este punto puede ser encontrado mediante la penalización de cambios drásticos en los parámetros.

Tomada de [4]

donde θ_k son los pesos para la tarea actual y $\tilde{\theta}_k$ se refiere a los mismos en la tarea previa. Por otro lado, la importancia de los pesos se representa mediante Ω_k^μ en la expresión (4.12),

$$\Omega_k^\mu = \sum \frac{w_k}{\beta^2 + \xi} \quad (4.12)$$

$$w_k = \Delta\theta_k \cdot \frac{\partial L}{\partial \theta_k} \quad (4.13)$$

en el cual β^2 es el movimiento total de peso θ_k durante el entrenamiento de la etapa, y ξ es una constante muy pequeña que tiene como objetivo resolver problemas de división por 0. Finalmente w_k se define en la ecuación (4.13), siendo interpretada como a contribución

especifica de un parámetro en el cambio del error total.

4.6.2 Learning to Continually Learn (LCL)

Beaulieu1 et al. [19] propusieron una nueva estrategia para aprendizaje continuo llamada A Neuromodulated Meta-Learning Algorithm (ANML). Compuesta por un clasificador de imágenes y un componente que es nombrado como “neuromodulador”, encargado de manejar la interacción de la plasticidad en los pesos o sinapsis que conectan los nodos (fig. 4.2). Para la realización del proceso de entrenamiento se tomó inspiración el trabajo realizado por K. Javed y M. White [20], a partir de donde, se toma su función objetivo, definida como OML, encargada de minimizar la interferencia al aprender nuevas tareas y maximizar la rápida adaptación a ellas. Además, se realiza una variación a la metodología de entrenamiento propuesta por Finn et al.[20] model-agnostic meta-learning algorithm (MAML), en donde implementa el concepto de meta-aprendizaje, en la cual, existen dos procesos de entrenamiento llamados meta-train y meta-test. El primer proceso se encarga de inicializar los pesos de la red neuronal principal y entrenar el componente neuromodulador, que sirve como una compuerta selectora del nivel de plasticidad usado en las neuronas para generar representaciones del conocimiento. Durante el segundo proceso, se hace uso del componente neuromodulador ya entrenado, para entrenar la última capa de la red neuronal principal con las nuevas tareas seleccionadas. Este componente es capaz de realizar una representación sináptica dispersa, a nivel neuronal, con las actividades que se aprenden. Permitiendo de esta forma, que las nuevas no interfieran con el conocimiento previo.

Para comprender la función de costo utilizada durante las etapas de entrenamiento de la estrategia LCL, es necesario analizar primero la formulación propuesta en el artículo presentado por K. Javed y M. White [20]. Inicialmente, se define a T como un flujo interminable de muestras en forma de pares de entrada y objetivo, que pueden provenir de diversas tareas o distribuciones, es decir, $(X_1, Y_1), (X_2, Y_2), \dots, (X_t, Y_t), \dots$, donde las entradas X_t provienen del conjunto X y los objetivos Y_t provienen del conjunto Y . Además, se define S como una trayectoria de longitud k muestreada del problema T . Se denota como

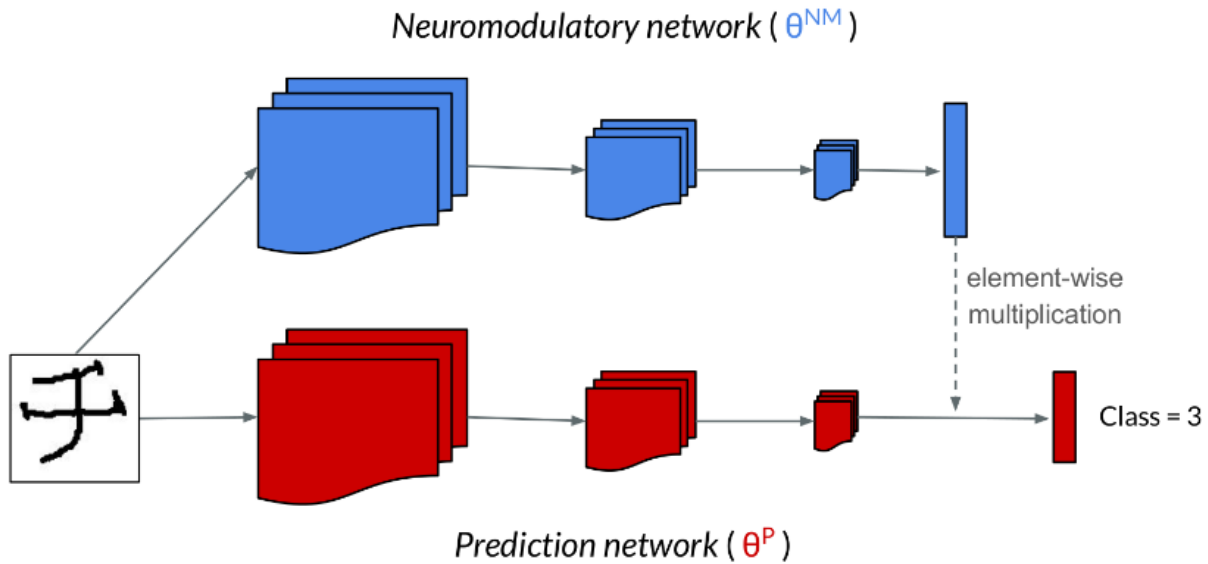


Fig. 4.2. Arquitectura ANML

La red de predicción (θ^P), es una red neuronal normal que es optimizada por un algoritmo como gradiente descendente estocástico. La red neuromoduladora (θ^{NM}) produce una máscara seleccionadora para cada activación de la red de predicción, permitiendo una plasticidad selectiva que afecta la forma en como se actualizan los gradientes de la red de predicción.

$S_k = (X_{j+1}Y_{j+1}), (X_{j+2}Y_{j+2}), \dots, (X_{j+k}, Y_{j+k})$. Esta trayectoria contiene muestras independientes e idénticamente distribuidas, que mejoran el aprendizaje continuo, ya que los datos pueden presentar correlaciones o llegar de manera secuencial.

Posteriormente, basado en las definiciones anteriores, se presenta la función de costo para el problema de aprendizaje continuo en la tarea T_i , en el cual se mide el desempeño del modelo para la tarea en función de la calidad de las predicciones realizadas. El objetivo es minimizar la función de pérdida para mejorar la precisión y la capacidad de adaptación rápida del modelo en el contexto del aprendizaje continuo, como se define en la ecuación 4.14. Este término simboliza la expectativa del error entre la predicción realizada por el modelo $f_{W,\theta}(X)$ y el objetivo real Y . Aquí, ℓ es una función que define el error entre una predicción $\hat{y} \in Y$ y el objetivo real y . $p(y|x)$ es la distribución desconocida de los objetivos Y_t condicionados a las entradas X_t . $\mu(x)$ es una función que refleja la densidad marginal de cómo se observan

las entradas X en el problema.

$$L_{CLP}(W, \theta) = \mathbb{E}[\ell(f_{W, \theta}(X), Y)] = \int \left[\int \ell(f_{W, \theta}(x), y) p(y|x) dy \right] \mu(x) dx \quad (4.14)$$

La función de costo objetivo OML busca minimizar la interferencia y maximizar la adaptación rápida en el proceso de meta-aprendizaje, es decir, aprender una función de representación que se adapte rápidamente a nuevas tareas y, al mismo tiempo, reduzca la interferencia entre ellas. Esta se encuentra definida en la ecuación 4.15. Aquí, T_i son las tareas muestreadas de la distribución de problemas $p(T)$, S_k^j son trayectorias de longitud j muestreadas de la distribución de trayectorias $p(S_k|T_i)$, y L_{CLP_i} es la función de pérdida para el problema de aprendizaje continuo en la tarea T_i (ecuación 4.14). $U(W, \theta, S_j^k)$ representa una función de actualización de los parámetros W después de realizar k pasos de descenso de gradiente estocástico en la trayectoria S_j^k utilizando los parámetros θ .

$$\min_{W, \theta} \sum_{T_i \sim p(T)} OML(W, \theta) = \sum_{T_i \sim p(T)} \sum_{S_k^j \sim p(S_k|T_i)} [L_{CLP_i}(U(W, \theta, S_k^j))] \quad (4.15)$$

Finalmente, teniendo en cuenta lo anterior, los autores de LCL definen la función de costo usada durante los procesos de entrenamiento de meta-train train y meta-test train como la ecuación 4.16. Donde, θ_i^P representa los parámetros de la red de predicción en la iteración i . θ_{i-1}^P representa los parámetros de la red de predicción en la iteración anterior ($i - 1$). β es la tasa de aprendizaje utilizada para actualizar los parámetros. $\nabla_{\theta_{i-1}^P}$ denota el gradiente con respecto a los parámetros de la red de predicción θ_{i-1}^P . $L(\theta_{NM}, \theta_{i-1}^P, S_{traj})$ es la función de costo OML (ecuación 4.15) que depende de los parámetros de la red neuromoduladora θ_{NM} , los parámetros de la red de predicción θ_{i-1}^P , y la trayectoria de entrenamiento S_{traj} .

$$\theta_i^P \leftarrow \theta_{i-1}^P - \beta \nabla_{\theta_{i-1}^P} L(\theta_{NM}, \theta_{i-1}^P, S_{traj}) \quad (4.16)$$

Esta formulación de la función de costo en el enfoque LCL, se centra en mejorar la capacidad del modelo para adaptarse rápidamente a nuevas tareas y reducir la interferencia entre ellas, reduciendo de esta manera el olvido catastrófico. Por medio de este proceso, el modelo puede aprender a generalizar de manera efectiva en situación de aprendizaje continuo.

4.6.3 Estrategia Naive

La estrategia Naive para aprendizaje continuo es un enfoque básico que se utiliza como punto de partida o baseline en la comparación de diferentes estrategias de aprendizaje continuo. A pesar de ser útil para entrenar modelos de forma convencional, esta estrategia es altamente propensa al olvido catastrófico, ya que no tiene en cuenta los eventos de aprendizaje continuo y puede provocar una rápida degradación de los pesos del modelo. Como lo señalan V. Lomonaco et al. [21], la metodología Naive se centra simplemente en continuar el entrenamiento utilizando el método de optimización de gradiente descendente sobre los lotes de entrenamiento. Su única medida de control de olvido es el proceso de parada temprana en la optimización.

4.6.4 Estrategia Acumulativa

Existen metodologías que pueden utilizarse en los enfoques básicos de entrenamiento y que sirven como estrategia para el aprendizaje continuo. Una de estas, es la estrategia acumulativa [21], la cual es capaz de alcanzar buen rendimiento con respecto a la métrica precisión (Accuracy), dado que su funcionamiento se basa en el uso de los datos referentes al lote actual de entrenamiento y todos los datos que fueron usados durante experiencias previas, de forma acumulativa. Esto la convierte una estrategia capaz de aprender de manera continua; sin embargo, presenta un alto costo a nivel computacional debido a la necesidad de reentrenar los modelos utilizando toda la información del pasado, que con el tiempo, puede volverse inmanejable.

Capítulo 5

METODOLOGÍA

Este capítulo describe la metodología que fue empleada en este trabajo investigativo para alcanzar los objetivos planteados, que incluyen la implementación de estrategias de plasticidad sináptica, el diseño y ejecución de experimentos, y la evaluación de la capacidad de las estrategias para mitigar el problema del olvido catastrófico y aprender continuamente.

A continuación, se presenta un enfoque sistemático y riguroso para abordar estos objetivos, comenzando por procesos de revisión y consulta del estado del arte realizados con la finalidad seleccionar las estrategias de plasticidad, escenarios, bases de datos y métricas; procesos de ejecución como lo son la preparación de experimentos mediante el uso de las bases de datos e implementación de estrategias de aprendizaje continuo; y la definición de procedimientos para la evaluación de los experimentos.

Se presentarán cinco etapas en las que se detallan los diferentes aspectos de la metodología empleada, que proporciona una base sólida para llevar a cabo un estudio comparativo y efectivo de las estrategias de aprendizaje continuo en el contexto de clasificación de imágenes.

5.1 Etapa 1 - Investigación conceptual y selección de estrategias

Se llevó a cabo una revisión bibliográfica exhaustiva sobre el estado del arte en la mitigación del olvido catastrófico y el aprendizaje continuo, enfocándose en estudios que han obtenido resultados exitosos mediante la implementación de estrategias basadas en la bioinspiración de la plasticidad sináptica en el contexto de clasificación de imágenes. Se efectuó un análisis detallado de: metodologías de implementación, las bases de datos y métricas utilizadas en la evaluación de las capacidades del modelo para aprender continuamente. Esta información se utilizó para llevar a cabo el estudio comparativo, con el objetivo de verificar el efecto en la mitigación del olvido catastrófico que pueden tener las estrategias adaptativas en el manejo de pesos, basadas en la plasticidad sináptica.

Se eligieron dos estudios para evaluar sus capacidades en el aprendizaje continuo y

mitigar el problema del olvido catastrófico. El primero es el trabajo realizado por Zenke et al. [4], que propone el enfoque llamado “Continual Learning Through Synaptic Intelligence (SI)”, una estrategia que se enfoca en el cálculo de la importancia de las sinapsis durante cada etapa de optimización, con el fin de penalizar los cambios drásticos que provocan la pérdida de la información aprendida previamente. El segundo estudio es el de Beaulieu et al. [19](LCL) que presenta la estrategia “A Neuromodulated Meta-Learning Algorithm (ANML)”, donde se desarrolla un clasificador de imágenes y un componente llamado “neuromodulador”, que se encarga de manejar la interacción de la plasticidad en los pesos o sinapsis de la red neuronal, de tal forma que almacena sus representaciones y nuevos conocimientos de forma dispersa, evitando la pérdida de información.

Para la selección de estos estudios se tuvo en cuenta su relevancia y su estrategia novedosa basada en la bioinspiración de la plasticidad sináptica. Esto proporcionó una base sólida para realizar experimentos y evaluaciones detalladas en los escenarios de aprendizaje continuo planteados para este estudio.

5.2 Etapa 2 - Definición de escenarios

En esta etapa, se puntualizaron los escenarios sobre los cuales se le dio un entendimiento al problema del aprendizaje continuo. Se identificaron tres tipos de escenarios principales: Incremento de Clases (IC), Incremento de Instancias (II) e Incremento de Instancias y Clases (IIC). Estos permitieron establecer un marco controlado para el diseño experimental que posibilitó medir la capacidad de las metodologías seleccionadas en el aprendizaje continuo.

Los escenarios IC, II e IIC, presentan una perspectiva más amplia de lo que comúnmente es conocido como aprendizaje continuo en la literatura, que generalmente se centra en las actividades de incremento de clases o tareas. La inclusión de estos escenarios en el estudio busco proporcionar una metodología de evaluación más rigurosa y realista de las estrategias en el contexto del aprendizaje continuo.

Para cada escenario, se diseñaron experimentos que abordan sus desafíos particulares. Como ejemplo, en el escenario IC, se diseñó un experimento donde se tuvo como objetivo

hacer que las estrategias aprendan sobre nuevas representaciones de clases, sin olvidar las previamente aprendidas durante cada iteración del proceso. Similarmente, en los escenarios II e IIC, se diseñaron experimentos que probaran las capacidades de las estrategias para mejorar la generalización en clases conocidas y aprender nuevas clases sin olvidar lo aprendido previamente.

5.3 Etapa 3 - Selección y extracción de bases de datos

En esta etapa, se abordó el proceso de identificar y obtener las bases de datos adecuadas para los experimentos de aprendizaje continuo. A continuación, se describen los criterios de selección, las bases de datos seleccionadas y el proceso de extracción de los datos.

5.3.1 Selección de las bases de datos

Con el propósito de realizar experimentos para medir la capacidad de las estrategias en el contexto del aprendizaje continuo, se seleccionó una base de datos apropiada para el desarrollo de los escenarios planteados previamente. Como criterios de selección fueron considerados los siguientes:

1. La base de datos seleccionada fue comúnmente usada como benchmarking en investigaciones sobre aprendizaje continuo.
2. La composición de clases cuenta con dos niveles de refinamiento que permita el diseño de experimentos tipo IC, II y IIC.
3. Las bases de datos seleccionadas cuentan con un mediano nivel de complejidad en sus representaciones para evaluar la capacidad del modelo para enfrentar la diversidad en los datos.

Se seleccionaron dos bases de datos: CIFAR100 [16] y OMNIGLOT [17]. CIFAR100 contiene imágenes de objetos y animales, agrupados en clases y superclases. Esta se puede

considerar una base de datos de alta complejidad en sus representaciones, debido a sus formas y colores. Por otro lado, OMNIGLOT, fue seleccionada para mantener la comparabilidad con la estrategia propuesta por Beaulieu et al. [19] en el escenario IC. Esta se encuentra compuesta por caracteres escritos a mano, provenientes de diversos alfabetos, y se puede considerar como una base de datos de un bajo nivel de complejidad, dado que sus representaciones son en blanco y negro, y de formas relativamente simples.

5.3.2 Extracción de las bases de datos

Una vez seleccionadas las bases de datos, se continúa con el proceso para la extracción y toma de los datos. Para ello, se investigaron las fuentes proveedoras de los datos, priorizando la facilidad de extracción y manejo de los mismos, así como la fiabilidad de la fuente de donde se obtuvieron.

Se utilizó la herramienta Continuum [22], diseñada para facilitar el procesamiento de información y el diseño de experimentos, como fuente de información para la extracción de ambas bases de datos. Esta herramienta, desarrollada por los autores A. Douillar y T. Lesort, obtiene las bases de datos directamente de los repositorios de Pytorch [23], asegurando su fiabilidad y facilidad de manejo.

Es importante mencionar que CIFAR100 cuenta con una división predefinida de entrenamiento y prueba, y OMNIGLOT cuenta con una división para meta-entrenamiento, y otra para entrenamiento y prueba. En el caso de CIFAR100, se cuenta con un total de 54000 muestras, de las cuales, 45000 (aproximadamente el 83.33 % del total) están destinadas para el conjunto de entrenamiento, y las 9000 restantes (aproximadamente el 16.67 % del total) se usan para el conjunto de prueba.

En cuanto a la base de datos OMNIGLOT, se cuenta con un total de 13800 muestras, de las cuales 9885 (aproximadamente el 75 % del total) se destinan para el conjunto de meta-entrenamiento. Dada su naturaleza, los 3295 restantes (aproximadamente el 25 % del total) se usan para entrenamiento y prueba. Estas divisiones tienen la particularidad de que cada una de ellas contiene clases que la otra no; donde la primera división se conforma de 963

clases y la segunda por 660 clases, cada clase cuenta con 20 imágenes.

5.4 Etapa 4 - Definición de métricas

Por consiguiente, para evaluar las capacidades de las estrategias de aprender continuamente y mitigar el olvido catastrófico, se llevó a cabo una revisión exhaustiva del estado del arte en busca de métricas apropiadas. El objetivo fue seleccionar métricas que aborden aspectos clave del problema, como el nivel de olvido, la retención de conocimiento y la generalización de conocimiento en nuevos aprendizajes.

Durante la revisión del estado del arte, se tuvieron en cuenta los siguientes criterios que permitieron la selección de las métricas:

1. Relevancia: Las métricas deben ser relevantes para evaluar las capacidades de las estrategias seleccionadas en la mitigación del olvido catastrófico en fomento del aprendizaje continuo.
2. Aplicabilidad: Las métricas deben ser aplicables a los diferentes escenarios de aprendizaje continuo que fueron considerados durante la presente investigación.
3. Comparabilidad: Las métricas deben permitir la comparación de las estrategias y escenarios de aprendizaje continuo con otros enfoques presentes en el estado del arte.

Siguiendo estos criterios, se optó por utilizar el marco de trabajo CLEVA-Compass [18], debido a su enfoque en la transparencia, compatibilidad y reproducibilidad de las investigaciones que lo aplican. Este marco de trabajo aborda aspectos clave del aprendizaje continuo, como el nivel del olvido, la retención de conocimiento y la generalización del conocimiento de nuevos aprendizajes. Se tomaron las métricas Accuracy, Forgetting, Forward Transfer y Backward Transfer.

La aplicación de estas métricas permitió el evaluar de forma efectiva las capacidades de las estrategias en función de sus desempeños para mitigar el problema del olvido catastrófico y fomentar el aprendizaje continuo. Además, permiten la facilidad de comparación con otros enfoques presentes en el estado del arte que lo implementan.

5.5 Etapa 5 - Diseño Experimental

En esta etapa se abordan los detalles de los experimentos llevados a cabo, relacionados con su configuración y ejecución, con el fin de evaluar las capacidades de las estrategias seleccionadas en los diferentes escenarios de aprendizaje continuo definidos previamente en la etapa 2. Esta incluye detalles relacionados con los procesos de preparación, el procesamiento y la configuración de las bases de datos, la implementación de estrategias y rutinas de procesamiento, así como una descripción detallada de los procesos de entrenamiento y el cálculo de métricas. El objetivo de esta etapa es establecer un marco sólido y riguroso para la realización de los experimentos, que posteriormente posibilitara el análisis comparativo de los resultados obtenidos en cada experimento en función de las métricas seleccionadas.

Durante la ejecución de esta etapa, se realizaron experimentos con cada una de las bases de datos CIFAR100 y OMNIGLOT en los escenarios IC, II, IIC. Donde se abordaron los desafíos particulares de cada escenario, adaptando las configuraciones de las redes neuronales y ajustando parámetros según fuera necesario. Esto permitió una evaluación exhaustiva del desempeño de las estrategias seleccionadas y una mejor comprensión de como son capaces de mitigar el olvido catastrófico. Adicionalmente, cada uno de los escenarios se ejecutó sobre 2 estrategias que permite realizar una comparación con respecto las estrategias de partida; la estrategia naive y la estrategia acumulativa.

5.5.1 Preparación y procesamiento de los datos

Durante este proceso se recrearon los escenarios de aprendizaje continuo para los casos de IC, II, IIC. Para cada uno se diseñó un proceso específico de transformación en la base de datos de referencia CIFAR100, que permitió llevar a cabo los experimentos con las estrategias de aprendizaje continuo seleccionadas. Para el caso de OMNIGLOT, se mantuvo la configuración de la base de datos presentada por la estrategia LCL. Durante el proceso se garantizó la reproducibilidad de los procedimientos de transformación, mediante la definición de una semilla aleatoria.

Debido a la necesidad de la metodología LCL de realizar una inicialización de los pesos en su ANN, se tuvo la necesidad de separar una división especial en cada base de datos para únicamente ese propósito. Los detalles se especificarán a continuación, junto a la metodología para el diseño de cada escenario.

5.5.1.1 Procesamiento CIFAR100

En esta etapa se presentarán los detalles relacionados con el procesamiento de imágenes para la base de datos CIFAR100, teniendo como objetivo realizar los experimentos necesarios para probar las capacidades de las estrategias seleccionadas en los tres escenarios definidos: IC, II y IIC.

Escenario IC

Para el diseño del primer escenario IC, se dividió la base de datos de entrenamiento y prueba en 10 experiencias. Cada una de estas, se compone de 10 clases finas que se unen para crear una clase objetivo que fue usada en los experimentos de aprendizaje incremental de clases. Esta división, basada en experiencias, es realizada con la finalidad de efectuar evaluaciones constantes luego de la finalización del proceso de entrenamiento de cada experiencia. Cabe resaltar que la primera experiencia se reserva exclusivamente para ser usada en el proceso de inicialización de pesos de la estrategia presentada por LCL.

La distribución de las clases finas en cada experiencia es aleatoria, asegurando que en cada experimento se contenga una representación equilibrada y diversa de las clases. Fue importante asegurar que en cada experiencia no existiera una superposición de clases, de modo que cada nueva experiencia presentara un desafío incremental para el modelo de aprendizaje continuo.

La tabla I muestra una configuración detallada de estas divisiones y sus relaciones, incluyendo la asignación de clases finas a cada experiencia y la estructura de las clases objetivo para los experimentos de aprendizaje incremental de clases.

TABLA I
EXPERIENCIAS DEL ESCENARIO IC EN CIFAR100

Experiencia	Clases finas	Clase objetivo	Muestras de entrenamiento	Muestras de prueba
Reservado LCL	0, 1, 2, 3, 4, 5, 6, 7, 8, 9	-	5000	1000
1	10, 11, 12, 13, 14, 15, 16, 17, 18, 19	0	5000	1000
2	20, 21, 22, 23, 24, 25, 26, 27, 28, 29	1	5000	1000
3	30, 31, 32, 33, 34, 35, 36, 37, 38, 39	2	5000	1000
4	42, 43, 44, 45, 46, 47, 48, 49, 40, 41	3	5000	1000
5	50, 51, 52, 53, 54, 55, 56, 57, 58, 59	4	5000	1000
6	60, 61, 62, 63, 64, 65, 66, 67, 68, 69	5	5000	1000
7	70, 71, 72, 73, 74, 75, 76, 77, 78, 79	6	5000	1000
8	80, 81, 82, 83, 84, 85, 86, 87, 88, 89	7	5000	1000
9	90, 91, 92, 93, 94, 95, 96, 97, 98, 99	8	5000	1000

Escenario II

Durante la preparación del escenario II, se buscó configurar la base de datos de manera que cada experiencia incrementara el dominio de sus clases, enfocándose en las clases gruesas o super clases. Dado que cada una de estas, tiene relacionadas 5 clases finas, este marco resulta ideal para la preparación de 5 experiencias de aprendizaje. Cada experiencia contiene una clase fina perteneciente a cada una de las clases gruesas presentes. De este modo, como se puede observar en la tabla II, el modelo que se entrene sobre estas experiencias aprenderá en

cada una de sus etapas, las 20 clases gruesas, pero en cada experiencia aumentara el dominio de cada una de ellas.

TABLA II
EXPERIENCIAS DEL ESCENARIO II PARA CIFAR100

Experiencia	Clases	Muestras de entrenamiento	Muestras de prueba
Reservado LCL	0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19	10000	2000
1	0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19	10000	2000
2	0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19	10000	2000
3	0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19	10000	2000
4	0, 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19	10000	2000

Escenario IIC

En el escenario IIC, se buscó como objetivo simular la interacción del incremento de clases y sus instancias. Por lo tanto, se optó por centrarse en las clases gruesas, similar al procesamiento realizado en el escenario II. Se crearon 100 experiencias, la misma cantidad que clases finas. De forma aleatoria, cada experiencia contiene una clase fina que dio lugar a la aparición de una clase objetivo o gruesa si es desconocida por el modelo, o resultó en el incremento del

su dominio si ya es conocida. Los detalles del orden de los experimentos y su relación con las clases finas y gruesas se encuentra en la tabla III. Las clases finas y gruesas restantes, que no se muestran en la tabla, son reservadas para la primera fase de entrenamiento de la estrategia LCL.

5.5.1.2 Procesamiento OMNIGLOT

Adicionalmente, se realizó la preparación de la base de datos OMNIGLOT para efectuar la recreación del experimento ejecutado por los autores de LCL, en el cual se aplica el escenario IC. Este mismo se aplicó para garantizar la comparabilidad de ambas estrategias en una base de datos previamente formulada por el estado del arte.

Escenario IC

Se mantuvieron las configuraciones propuestas por los autores de LCL, donde se reserva el primer conjunto de datos, compuesto por 963 clases, para ser usadas en el proceso de inicialización de pesos de su estrategia.

Por otro lado, se prepara el segundo conjunto de 660 clases para los procesos de entrenamiento continuo de las estrategias. En un primer enfoque se propuso mantener el esquema establecido por los autores de LCL para perseverar la comparabilidad de esta base de datos con sus experimentos, sin embargo, se decidió realizar un cambio debido a las limitaciones de las otras estrategias y el equipo de hardware que se tuvo disponible. En esta variante se propone modificar la cantidad de clases finas como objetivo de aprendizaje, por el conjunto de los vocabularios existentes en el dataset que las categorizan. Se divide cada una de las clases de este segmento de la base de datos en dos conjuntos: entrenamiento y prueba. En el último, se incluyó el 25 % de las imágenes por vocabulario. El detalle del procesamiento se encuentra en la tabla IV.

TABLA III
EXPERIENCIAS DEL ESCENARIO IIC PARA CIFAR100

Exp.	C_T	F_T	Tr./Te.	Exp.	C_T	F_T	Tr./Te.	Exp.	C_T	F_T	Tr./Te.
1	7	19	500/100	28	3	24	500/100	55	15	69	500/100
2	11	29	500/100	29	11	78	500/100	56	9	99	500/100
3	0	0	500/100	30	9	45	500/100	57	11	93	500/100
4	10	11	500/100	31	6	49	500/100	58	2	94	500/100
5	1	86	500/100	32	13	56	500/100	59	5	68	500/100
6	14	90	500/100	33	5	76	500/100	60	8	34	500/100
7	6	23	500/100	34	15	89	500/100	61	4	88	500/100
8	7	31	500/100	35	3	14	500/100	62	8	63	500/100
9	1	39	500/100	36	3	6	500/100	63	1	40	500/100
10	13	96	500/100	37	2	20	500/100	64	9	26	500/100
11	5	17	500/100	38	10	98	500/100	65	14	48	500/100
12	6	71	500/100	39	12	36	500/100	66	9	79	500/100
13	14	8	500/100	40	4	43	500/100	67	15	85	500/100
14	4	97	500/100	41	0	51	500/100	68	11	44	500/100
15	12	80	500/100	42	10	35	500/100	69	3	7	500/100
16	12	74	500/100	43	0	83	500/100	70	5	12	500/100
17	13	59	500/100	44	6	33	500/100	71	10	2	500/100
18	1	87	500/100	45	11	27	500/100	72	15	41	500/100
19	2	84	500/100	46	0	53	500/100	73	5	37	500/100
20	8	64	500/100	47	12	50	500/100	74	14	13	500/100
21	13	52	500/100	48	7	15	500/100	75	2	25	500/100
22	4	42	500/100	49	3	18	500/100	76	0	57	500/100
23	13	47	500/100	50	10	46	500/100	77	2	5	500/100
24	12	65	500/100	51	8	75	500/100	78	6	60	500/100
25	7	21	500/100	52	7	38	500/100	79	4	3	500/100
26	1	22	500/100	53	8	66	500/100	80	14	58	500/100
27	15	81	500/100	54	9	77	500/100				

EXP. REPRESENTA LA EXPERIENCIA. C_T ES LA CLASE GRUESA Y C_T ES LA CLASE FINA.
TR./TE. SON LAS MUESTRAS DE ENTRENAMIENTO Y PRUEBA

5.5.2 Procedimiento experimental

Esta sección detalla los procedimientos experimentales realizados sobre las estrategias para la ejecución los escenarios de aprendizaje continuo establecidos en las secciones previas.

TABLA IV
EXPERIENCIAS DEL ESCENARIO IC PARA OMNIGLOT

Experiencia	Clase objetivo	Muestras de entrenamiento	Muestras de prueba
1	0	300	100
2	1	390	130
3	2	390	130
4	3	390	130
5	4	390	130
6	5	390	130
7	6	675	225
8	7	675	225
9	8	615	205
10	9	390	130
11	10	705	235
12	11	600	200
13	12	450	150
14	13	675	225
15	14	690	230
16	15	420	140
17	16	345	115
18	17	375	125
19	18	630	210
20	19	390	130

Para la ejecución del proceso experimental, previamente se escogió que las estrategias a usar durante todo el proceso experimental fueron SI y LCL, adicionalmente se incluyen dos estrategias tradicionales conocidas como Naive y Acumulativa, que sirvieron para trazar una línea base sobre la cual poder comparar los resultados. Como uno de los parámetros iniciales, se buscó realizar la menor cantidad de modificaciones posibles que cambiaran la idea de la estrategia, por lo que, el proceso se limitó primordialmente a la variación de algunos hiperparámetros como: tasas de aprendizaje, cantidad de épocas, lotes de entrenamiento y valores de regularización específicos de cada metodología. Además, se varían capas de ingestión de datos para adaptarse a las imágenes de la base de datos y cambios en las formas

de procesamiento de las imágenes de entrada. Por ejemplo, el uso de las imágenes con un solo canal de color o con los tres, pertenecientes al RGB. Algunos procedimientos de la implementación de cada estrategia debieron ser modificados debido a limitaciones en cuanto a hardware.

Se diseñaron dos procedimientos de experimentación para las bases de datos en cada escenario, dadas las necesidades particulares de cada una de las estrategias. Estas se detallarán a continuación.

5.5.2.1 Procedimiento para LCL

La estrategia LCL tiene como particularidad su proceso de entrenamiento compuesto por dos etapas: meta-train train y meta-test train. La primera está enfocada en entrenar la red neuromodulatoria e inicializar los pesos de la red de predicción, y la segunda se enfoca en entrenar la capa de salida de la red de predicción sobre cada una de las experiencias con el objetivo de aprender continuamente, revise la figura 4.2.

El proceso de meta-train train inicia por de la selección, sobre el conjunto de datos reservados para la inicialización de pesos, de 80 imágenes de una clase escogida aleatoriamente; para el caso de los experimentos con CIFAR100 y 20 imágenes por clase para el caso de OMNIGLOT. Durante cada iteración del proceso, se realizan dos etapas de optimización; la primera optimiza imagen a imagen usando el algoritmo gradiente descendente estocástico, que se encarga de aprender las representaciones de las clases en la red neuromodulatoria y la capa densa de salida de la red de predicción. Por consiguiente, el segundo proceso de optimización busca ajustar los pesos de la red entera haciendo uso de las imágenes seleccionadas para el primer optimizador y 64 imágenes aleatorias pertenecientes a cualquier clase, a lo que se le llama el conjunto de recuerdo. Finalmente, se usa un optimizador de tipo Adam con el conjunto entero de recuerdo para optimizar los pesos de la ANN entera. La selección de la cantidad de imágenes en el primer conjunto de entrenamiento se realizó teniendo en cuenta lo masivo de los datos en las clases de cada una de las bases de datos de referencia y la robustez del algoritmo de optimización por sus altas necesidades en consumo de memoria

de GPU, debido al almacenamiento de múltiples grafos de derivadas acumulados durante el proceso.

Por su parte, el proceso de meta-test train busca ajustar la capa densa de salida con la finalidad de aprender sobre las clases particulares de cada una de las experiencias que se le enviaron. Para este proceso, se destinaron los datos de entrenamiento y testeo de cada uno de los escenarios que fueron definidos previamente, luego de cada etapa de entrenamiento sobre cada experiencia se realizó un proceso evaluativo para medir los rendimientos del modelo, teniendo en cuenta las métricas Accuracy, Forgetting, Forward Transfer y Backward Transfer.

5.5.2.2 Procedimiento para SI

Para llevar a cabo los experimentos para la estrategia SI, se utilizó la arquitectura de red neuronal mostrada en la tabla V. Esta arquitectura fue tomada de los experimentos realizados y descritos en el trabajo de F. Zenke et al. [4] para la misma base de datos en un escenario de incremento de tareas, en el cual la capa de salida tiene múltiples cabeceras, una para cada tarea. No obstante, debido a las necesidades de los escenarios propuestos, se reemplazó esta capa por una llamada clasificador incremental, en la que las neuronas se incrementan de acuerdo con el aumento de clases durante los procesos de entrenamiento.

Por otro lado, para llevar a cabo el procedimiento de entrenamiento se utilizaron las experiencias diseñadas para los escenarios de cada una de las bases de datos, para las cuales, su finalidad fue el entrenamiento y prueba de estos. Además, posterior al entrenamiento de una nueva experiencia, se realizó una etapa de evaluación donde se calcularon las métricas Accuracy, Forgetting, Forward Transfer y Backward Transfer con el objetivo de generar los reportes pertinentes.

5.5.2.3 Procedimiento para Naive y Acumulativo

Con la finalidad de mantener los resultados comparables con el estado del arte en el tópico de aprendizaje continuo para las metodologías tradicionales, se incluyeron experimentos en los

TABLA V
ARQUITECTURA DE LA RED NEURONAL SI

Operación	Kernel	Stride	Filtros	Dropout	Nodos	No linealidad
Conv2d	(3, 3)	(1, 1)	32	No	-	ReLU
Conv2d	(3, 3)	(1, 1)	32	No	-	ReLU
MaxPool2d	(2, 2)	(2, 2)	-	0.25	-	-
Conv2d	(3, 3)	(1, 1)	64	No	-	ReLU
Conv2d	(3, 3)	(1, 1)	64	No	-	ReLU
Flatten	-	-	-	-	-	-
Linear	-	-	-	0.5	512	ReLU
IncrementalClassifier	-	-	-	No	Variable	No

que se emplean las estrategias Naive y Acumulativo. Para estas dos estrategias, se configuró la arquitectura de la red neuronal de la misma forma que como fue configurada para el caso de SI, como se muestra en la tabla V. Esto se hizo con el objetivo de conservar un equilibrio comparable en cuanto a la complejidad de los modelos.

El procedimiento para llevar a cabo los experimentos fue el mismo realizado para los experimentos de SI, usando las mismas definiciones para el procesamiento de las bases de datos para cada escenario y calculando las mismas métricas.

Capítulo 6

RESULTADOS

Durante este capítulo, se presentan y analizan los resultados obtenidos en la ejecución de los experimentos realizados con la aplicación de la metodología, utilizando las estrategias de aprendizaje continuo LCL, SI y las tradicionales, Naive y Acumulativo. Los experimentos se llevaron a cabo en los escenarios IC, II e IIC para la base de datos CIFAR100 y el escenario IC para OMNIGLOT, con el propósito de evaluar y comparar el rendimiento de las metodologías en términos de las métricas Accuracy, Forgetting, Forward Transfer y Backward Transfer, que miden sus capacidades para aprender de manera continua y mitigar el olvido catastrófico. A continuación, se describen los resultados obtenidos, agrupados por su base de datos y escenario ejecutado.

6.1 Resultados en la base de datos CIFAR100

A continuación, se discuten los resultados obtenidos para la base de datos CIFAR100 en los diferentes escenarios de aprendizaje continuo. Primero, se describirá brevemente el proceso experimental y las definiciones realizadas con el fin de obtener los resultados sobre las estrategias de aprendizaje continuo. Luego, se presentarán los resultados en forma de gráficos y finalmente, se analizan y comparan los desempeños de las estrategias LCL, SI, Naive y Acumulativa.

6.1.1 Escenario IC

Para realizar los experimentos del escenario IC en la base de datos de referencia CIFAR100, se tuvo principalmente en cuenta el proceso de transformación definido para esta; detallado en la tabla I. Donde se definen 9 experiencias de entrenamiento, para 9 clases objetivo que agrupan 5 clases finas cada una. El objetivo del proceso de entrenamiento es el aprendizaje secuencial de todas las clases, mitigando el olvido catastrófico.

6.1.1.1 Configuración de los experimentos

Para llevar a cabo esta categoría de experimentos, se configuraron todas las estrategias experimentalmente. Una condición impuesta sobre este procedimiento fue el no variar los procesos característicos de las estrategias y sus arquitecturas, pero permitiendo variar sus hiperparámetros, de tal forma que no perdieran su idea inicial de funcionamiento y su comparabilidad con los resultados del estado del arte. Sin embargo, los efectos que tuvo la variación de estos últimos fue mínima con respecto a los resultados; por lo que a continuación se especificaran los detalles de las mejores configuraciones.

Inicialmente, la estrategia LCL fue entrenada para su proceso de meta-train durante 5000 iteraciones, siguiendo el proceso descrito en la sección Procedimiento para LCL de la estrategia. Por otro lado, para el proceso de meta-test train, que es el proceso de entrenamiento secuencial, se configuró el tamaño del lote de entrenamiento a un valor de 15, con el fin de simular el comportamiento del proceso original con la base de datos OMNIGLOT y aumentar la cantidad de iteraciones que el optimizador tiene en el modelo, debido a la gran diferencia en la cantidad de datos por cada clase objetivo. Además, se mantuvo la tasa de aprendizaje en un valor de 0.0001 y se cambió la capa de entrada para permitir el ingreso de 3 canales, correspondientes al RGB de CIFAR100. Finalmente, el proceso de entrenamiento se ejecutó por 20 épocas para cada experiencia.

La estrategia SI, se configuró con una tasa de aprendizaje de 0.001 y el hiperparámetro c (ecuación 4.11), que regula el error subrogado, se estableció en 1. El término ϵ y el tamaño del lote de entrenamiento se configuraron de la misma forma que proponen los autores, valores de 0.1 y 256, respectivamente. El proceso de entrenamiento consto de 60 épocas por cada experiencia nueva.

Las estrategias Naive y Acumulativa, fueron configuradas en sus hiperparámetros comunes, de la misma forma como se encuentra configurada SI.

6.1.1.2 Resultados

Tras el proceso de entrenamiento, se calcularon las métricas establecidas para medir las capacidades de aprendizaje continuo y compararlo de forma rigurosa para estas estrategias. En las figuras [6.1, 6.2, 6.3, 6.4] se pueden observar los resultados obtenidos para este proceso.

En primer lugar, se puede observar en las figuras [6.1, 6.2], como las cuatro estrategias fueron incapaces de aprender de una forma adecuada sobre las representaciones de sus clases y, al mismo tiempo, evitar el olvido catastrófico. Como era de esperarse, la estrategia que mejor se comportó en este escenario fue la Acumulativa, ya que presentó la mejor relación entre un alto Accuracy y un nivel de olvido catastrófico bajo. Sin embargo, esto es posible debido a que siempre se reentrena con toda la información de entrenamiento, un proceso que resulta costoso computacionalmente y que se busca evitar en el aprendizaje continuo.

Adicionalmente, se encuentra que para todos los casos, la estrategia SI se comportó de la misma forma que la Naive en todas las métricas, lo que demuestra que, su estrategia de aprendizaje continuo no fue efectiva para el incremento de clases debido al olvido catastrófico total que se presentó durante el entrenamiento secuencial de cada una de las clases.

Por último, la estrategia LCL, a pesar de no haber sido capaz de representar la información y obtener un alto Accuracy, presenta un comportamiento interesante en las demás métricas. Su nivel de olvido es gradual y, varios casos, durante el entrenamiento de cada clase, muestra aportes positivos que impactan tanto a las clases previamente aprendidas como a las que serán aprendidas en un futuro, indicado en las métricas de backward y forward transfer. Esto demuestra que esta estrategia es capaz de aprender las representaciones generales de la tarea y ajustarlas para los casos particulares.

6.1.2 Escenario II

Para los experimentos del escenario II en la base de datos CIFAR100, se tuvo en cuenta el proceso de transformación detallado en la tabla II. Se definen 4 experiencias de entrenamiento, para 20 clases gruesas que contienen 4 instancias o clases finas. cada experiencia cuenta con

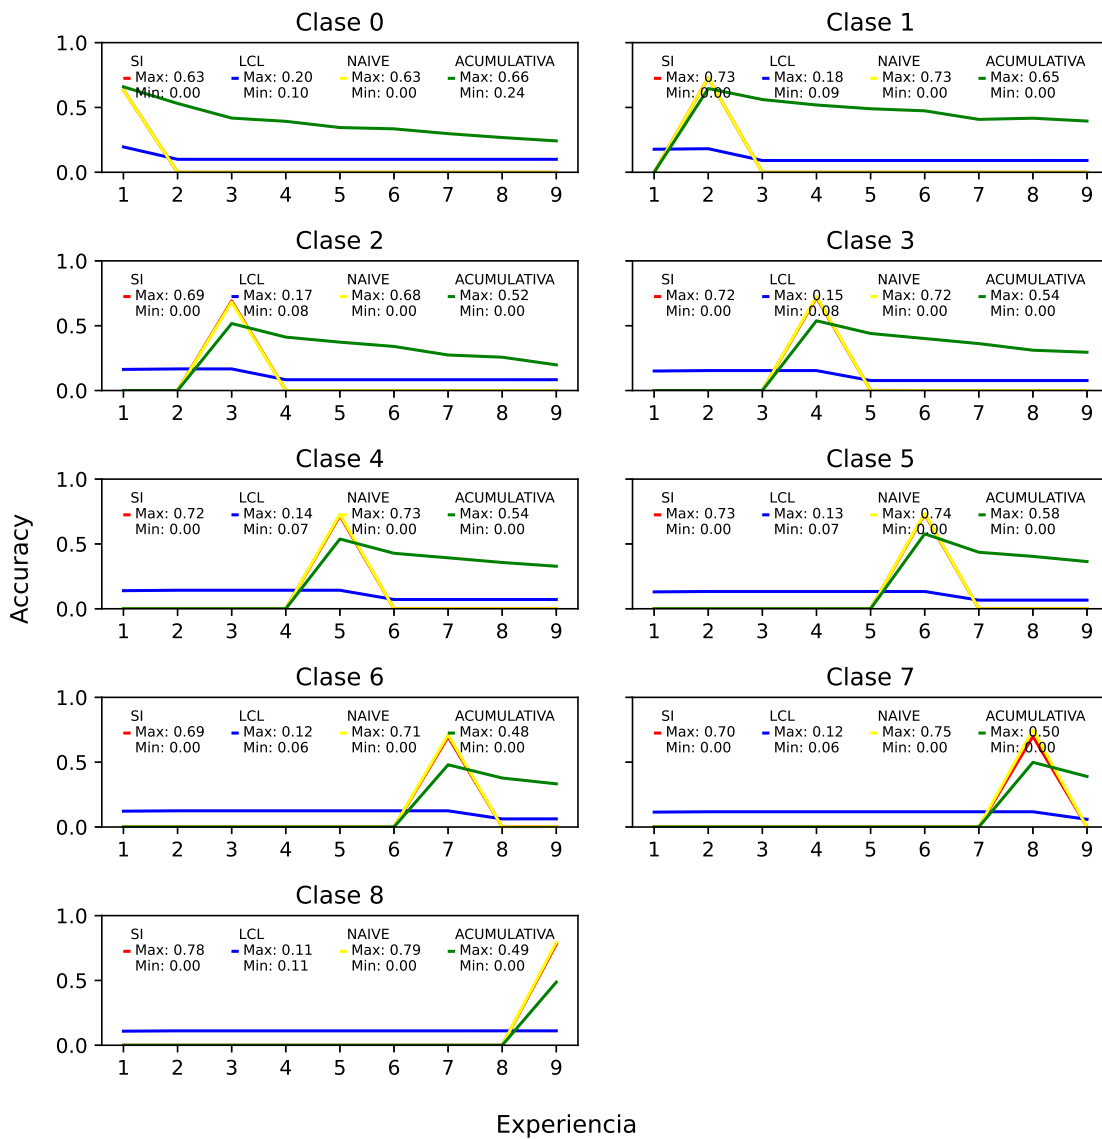


Fig. 6.1. Resultados escenario IC para Accuracy en CIFAR100

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Accuracy

una instancia diferente de cada clase gruesa objetivo. Es importante destacar que la primera instancia de cada clase esta reservada para el proceso de meta-train train de la estrategia LCL. El objetivo de este proceso de entrenamiento es el incremento secuencial del dominio de cada clase gruesa aprendida durante la primera experiencia.

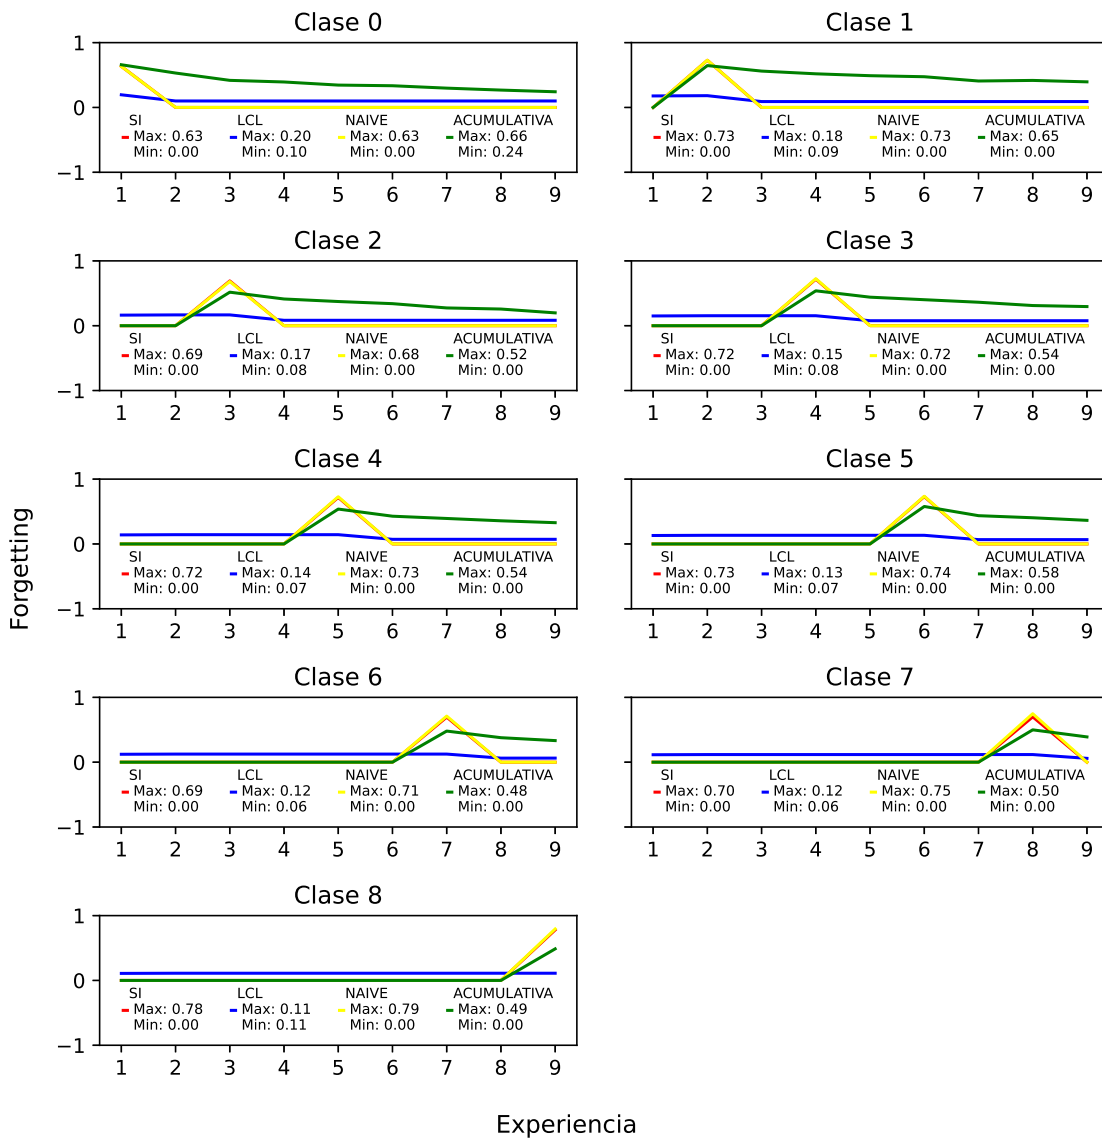


Fig. 6.2. Resultados escenario IC para Forgetting en CIFAR100

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Forgetting

6.1.2.1 Configuración de los experimentos

La configuración de las estrategias para esta categoría de experimentos, se realizó de la misma manera que para el escenario IC. Se mantuvieron las configuraciones para las dos etapas de




Fig. 6.3. Resultados escenario IC para Forward Transfer en CIFAR100

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Forward Transfer

entrenamiento de LCL, para la estrategia SI, Naive y Acumulativa.




Fig. 6.4. Resultados escenario IC para Backward Transfer en CIFAR100

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Backward Transfer

6.1.2.2 Resultados

A partir del proceso de entrenamiento, se calcularon las métricas establecidas para medir las capacidades de aprendizaje continuo y comparar de forma rigurosa estas estrategias. En

las figuras [6.5, 6.6, 6.7, 6.8] se pueden observar los resultados obtenidos para el proceso de entrenamiento continuo.

Para estos experimentos, se observan mejores resultados, principalmente, en la métrica de Accuracy para todas las estrategias, en comparación con el escenario IC. Estos pueden deberse a que las estrategias no necesitan aprender nuevas clases después de la primera experiencia, lo que a su vez no provoca una gran variación en los valores de los parámetros de cada modelo durante cada entrenamiento secuencial.

De manera similar a lo ocurrido durante el escenario IC, se muestra que la estrategia Acumulativa presenta el mejor rendimiento para aprender de manera continua y mitigar el problema del CF (figuras [6.5, 6.6]). Además, las estrategias SI y Naive se comportan de manera similar. Con respecto a la métrica Forward transfer, estas tres estrategias presentan capacidades similares para transferir el conocimiento de instancias previas a instancias futuras, siendo esta capacidad positiva para las instancias 1 y 2 de cada clase durante las experiencias 2 y 3. Por otro lado, el aprendizaje de nuevas instancias para cada clase afecta negativamente lo aprendido previamente, como se ve en la figura (6.8).

Al igual que en el escenario anterior, la estrategia LCL no pudo representar correctamente la información de los datos, lo que resultó en un Accuracy bajo durante la clasificación en cada etapa. Además, esta estrategia tuvo un alto grado de olvido para las instancias 1 y 2 durante las experiencias 2 y 3, como lo demuestran las métricas de backward y forward transfer, lo que indica que la estrategia no se comportó de manera estable durante el aprendizaje continuo en este escenario. Esto sugiere que esta estrategia enfrenta problemas al aprender sobre los cambios a nivel de dominio.

6.1.3 Escenario IIC

Los experimentos del escenario IIC para la base de datos de referencia CIFAR100, tuvieron en cuenta principalmente el proceso de transformación definido para esta, detallado en la tabla III. Se definen 80 experiencias de entrenamiento para 16 clases gruesas objetivo, donde las experiencias cuentan con una clase fina diferente para una única clase objetivo aleatoria.

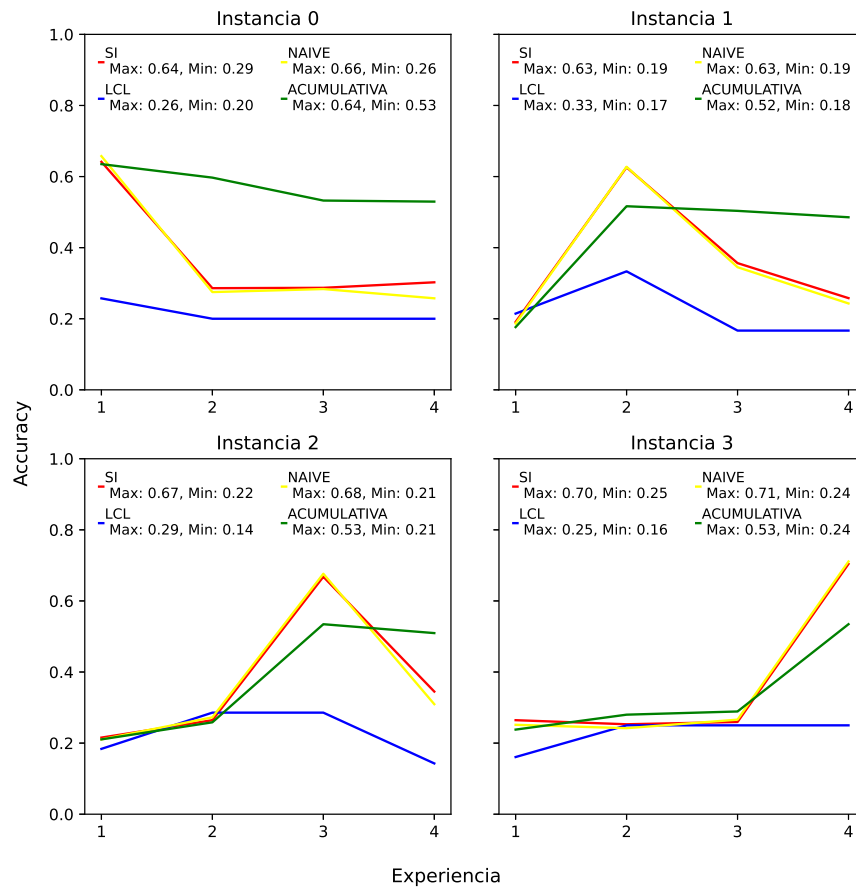


Fig. 6.5. Resultados escenario II para Accuracy en CIFAR100

Gráfico comparativo del escenario II entre estrategias SI, LCL, Naive y Cumulative con 20 clases a las cuales se les amplio su dominio durante 4 experiencias usando la métrica de Accuracy

Cada clase gruesa objetivo tiene 5 distintas experiencias. La finalidad de este proceso de entrenamiento es el incremento secuencial de las clases y el dominio de estas.

6.1.3.1 Configuración de los experimentos

La configuración de las estrategias para esta categoría de experimentos se realizó de la misma manera que para los escenarios IC e IIC. Se mantienen las configuraciones para las dos etapas de entrenamiento de LCL, para las estrategias SI, Naive y Acumulativa.




Fig. 6.6. Resultados escenario II para Forgetting en CIFAR100

Gráfico comparativo del escenario II entre estrategias SI, LCL, Naive y Cumulative con 20 clases a las cuales se les amplio su dominio durante 4 experiencias usando la métrica de Forgetting

6.1.3.2 Resultados

Los experimentos realizados en el escenario IIC muestran un panorama similar al encontrado en los experimentos del escenario IC. Donde en promedio, las estrategias no fueron capaces de alcanzar una alta precisión al momento de aprender nuevas clases o instancias durante cada etapa experimental, como se observa en las figuras [6.9 y 6.10]. Las estrategias Naive, SI y Acumulativa presentaron una alta inestabilidad al momento de aprender las representaciones de cada clase. El olvido es positivo y aumenta durante cada experiencia, demostrando cómo




Fig. 6.7. Resultados escenario II para Forward Transfer en CIFAR100

Gráfico comparativo del escenario II entre estrategias SI, LCL, Naive y Cumulative con 20 clases a las cuales se les amplio su dominio durante 4 experiencias usando la métrica de Forward Transfer

el aprendizaje se pierde de forma acelerada. Por otro lado, al igual que lo encontrado en escenarios anteriores, LCL presenta una mayor estabilidad en su aprendizaje, mostrando bajos niveles de desviación en la métrica de Accuracy y niveles de olvido, con algunas excepciones, cercanos a cero y negativos.

Como se puede observar en el gráfico 6.11, las estrategias SI, Acumulativa y Naive tienen valores principalmente cercanos a cero o negativos para la métrica Forward Transfer. Esto demuestra cómo no tienen un efecto notorio o tienen un efecto negativo sobre las clases que se aprenderán posteriormente. Para este grupo de estrategias, Naive y Acumulativa son

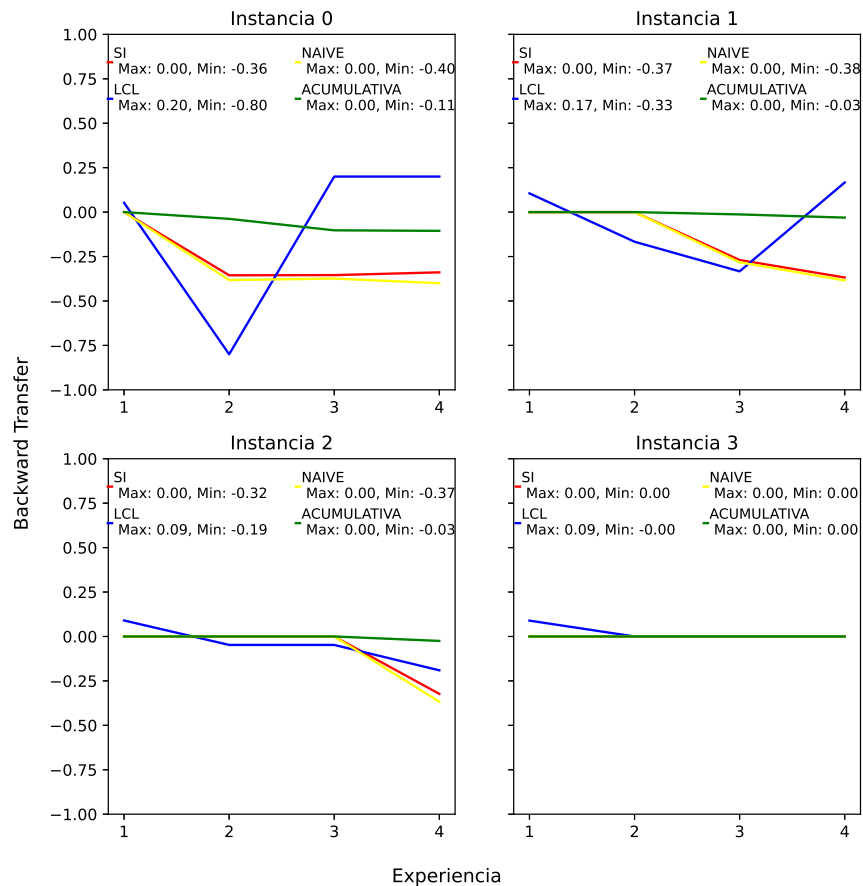


Fig. 6.8. Resultados escenario II para Backward Transfer en CIFAR100

Gráfico comparativo del escenario II entre estrategias SI, LCL, Naive y Cumulative con 20 clases a las cuales se les amplió su dominio durante 4 experiencias usando la métrica de Backward Transfer

las únicas que, durante las últimas 20 etapas de entrenamiento, muestran una transferencia positiva de lo aprendido. Por otro lado, la estrategia LCL, muestra resultados en su mayoría positivos o cercanos a cero, con algunas excepciones, y bajos niveles de variabilidad para cada experiencia. Esto muestra cómo, de manera similar a lo ocurrido en el escenario IC, esta estrategia en menor medida es capaz de transferir el conocimiento para afectar positivamente las clases que serán aprendidas en el futuro.

Finalmente, para el caso de las estrategias SI, Acumulativa y Naive, la métrica de Backward Transfer (figura 6.12) expone cómo estas degradan el conocimiento previamente

aprendido, a medida que aprenden nueva información en cada experiencia. Adicionalmente, LCL cuenta con un impacto positivo sobre las clases previas a medida que aprende sobre cada nueva experiencia, dando a entender que gradualmente generaliza sobre una representación común de los datos.

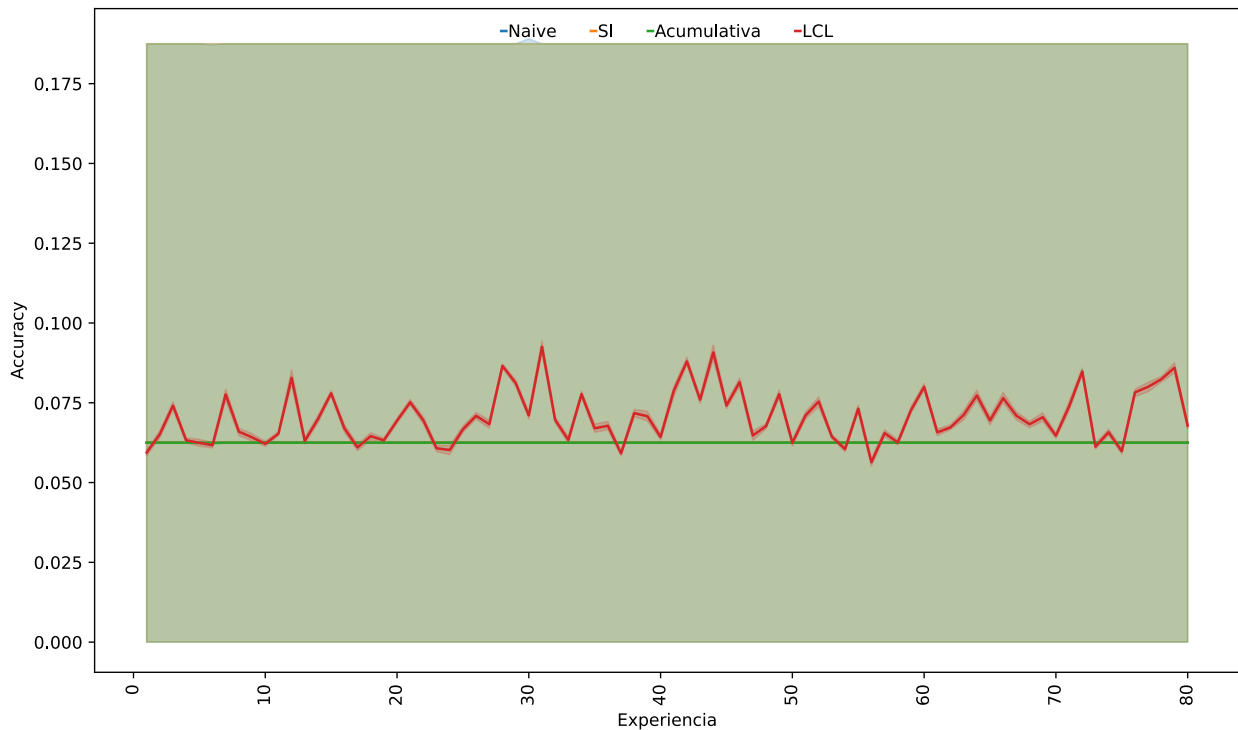


Fig. 6.9. Resultados escenario IIC para Accuracy en CIFAR100

Gráfico resumen comparativo del escenario IIC entre estrategias SI, LCL, Naive y Cumulative para 100 experiencias usando la métrica de Accuracy

6.2 Resultados OMNIGLOT

A continuación, se discuten los resultados obtenidos para la base de datos OMNIGLOT en los diferentes escenarios de aprendizaje continuo. Primero, se describirá brevemente el proceso experimental y las definiciones realizadas con el fin de obtener los resultados sobre la estrategia IC. Luego, se presentarán los resultados en forma de gráficos, y finalmente, se

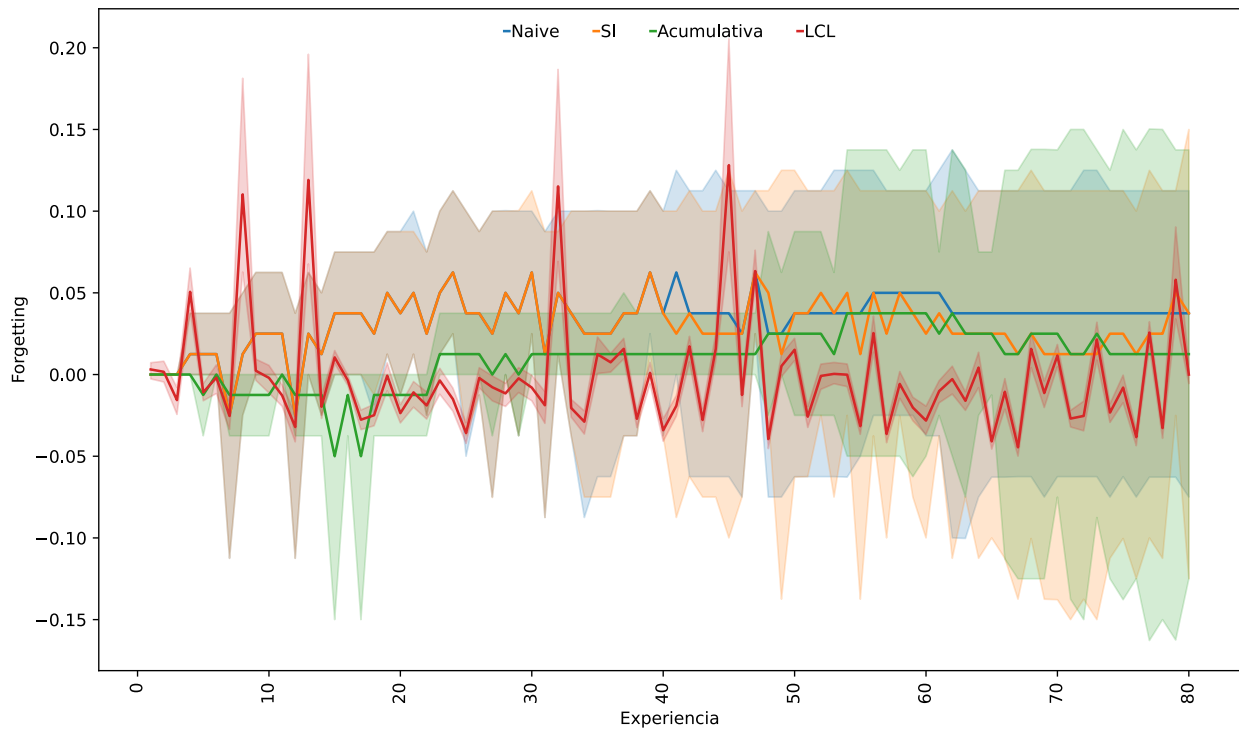


Fig. 6.10. Resultados escenario IIC para Forgetting en CIFAR100

Gráfico resumen comparativo del escenario IIC entre estrategias SI, LCL, Naive y Cumulative para 100 experiencias usando la métrica de Forgetting

analizan y comparan los desempeños de las estrategias LCL, SI, Naive y Acumulativa.

6.2.1 Escenario IC

Para realizar los experimentos del escenario IC en la base de datos de referencia OMNIGLOT, se tuvo principalmente en cuenta el proceso de transformación definido para esta, detallado en la tabla IV. Se definen 20 experiencias de entrenamiento para 20 clases objetivo, que son los vocabularios presentes en la base de datos.

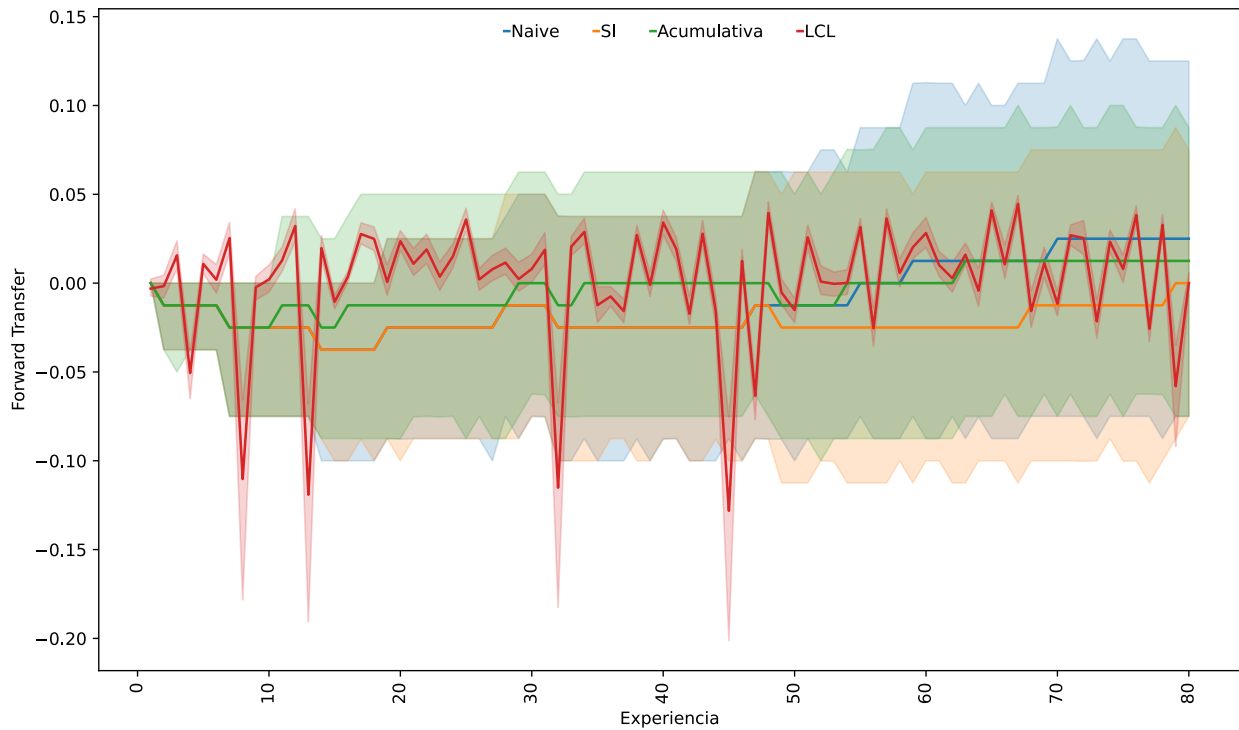


Fig. 6.11. Resultados escenario IIC para Forward Transfer en CIFAR100

Gráfico resumen comparativo del escenario IIC entre estrategias SI, LCL, Naive y Cumulative para 100 experiencias usando la métrica de Forward Transfer

6.2.1.1 Configuración de los experimentos

La configuración de las estrategias inicialmente se realizó de manera similar al procedimiento llevado a cabo en el estado del arte en LCL. Se utilizaron las 963 clases del primer conjunto de datos de OMNIGLOT para el proceso de meta-train de esta estrategia.

Por otro lado, las demás configuraciones de los experimentos se realizaron de la misma manera que lo presentado en el escenario IC durante los resultados de la base de datos CIFAR100. Se mantienen las configuraciones para la etapa meta-test train de LCL, y para las estrategias SI, Naive y Acumulativa.




Fig. 6.12. Resultados escenario IIC para Backward Transfer en CIFAR100

Gráfico resumen comparativo del escenario IIC entre estrategias SI, LCL, Naive y Cumulative para 100 experiencias usando la métrica de Backward Transfer

6.2.1.2 Resultados

Como resultado del proceso de entrenamiento, se calcularon las métricas establecidas para medir las capacidades de aprendizaje continuo y compararlas de forma rigurosa para estas estrategias. En las figuras [6.13, 6.14, 6.15, 6.16] se puede observar una parte de estos resultados obtenidos para el proceso de entrenamiento continuo. Para más detalles y resultados adicionales, consulte el apéndice I.

Para las métricas de Accuracy y forgetting (figuras [6.13, 6.14]) se muestra que las 3 estrategias tienen un comportamiento similar al ocurrido durante el experimento de IC, con la base de datos CIFAR100. La diferencia radica en que las estrategias SI, Naive y Acumulativa fueron capaces de representar mejor la información, lo cual tiene sentido porque las imágenes

de OMNIGLOT son más simples que las de CIFAR100 y se pueden aprender con mayor facilidad. El olvido para las estrategias SI y Naive es total; luego de cada experiencia de aprendizaje, la clase aprendida es olvidada y reemplazada por la nueva. Esto también se puede observar en las métricas Backward Transfer, figura 6.16, donde se muestra que luego del aprendizaje de cada clase, se presenta una afectación negativa total sobre las clases previamente aprendidas.

En el caso de la estrategia acumulativa, como lo sucedido en los escenarios previos, se comporta de manera casi perfecta al momento de aprender continuamente y no olvidar de forma catastrófica. Las clases que presentaron mayor olvido fueron la 2, 4 y 5, donde al final de las 20 experiencias de entrenamiento hubo un olvido mayor a 0.27. Las figuras [6.15 y 6.16], muestran que el entrenamiento de esta estrategia no es capaz de generar representaciones que mejoren el rendimiento de las clases futuras (Forward Transfer), pero sí hay una afectación negativa a las clases pasadas (Backward Transfer) que, finalmente, se puede interpretar como el nivel de olvido.

Por último, en el caso de la estrategia LCL, no se presenta un aprendizaje de las representaciones muy alto. Sin embargo, al igual que en experimentos anteriores, esta estrategia demuestra un olvido que es gradualmente bajo y se va mitigando a medida que se aprenden nuevas clases. La métrica Forward Transfer confirma esto al demostrar que, a mayor entrenamiento de la estrategia, se generan representaciones que mejoran el rendimiento de las clases futuras. Lo mismo sucede con Backward Transfer, donde a mayor entrenamiento, se mitiga el riesgo de afectar negativamente las clases previamente aprendidas y hay una afectación positiva sobre estas.

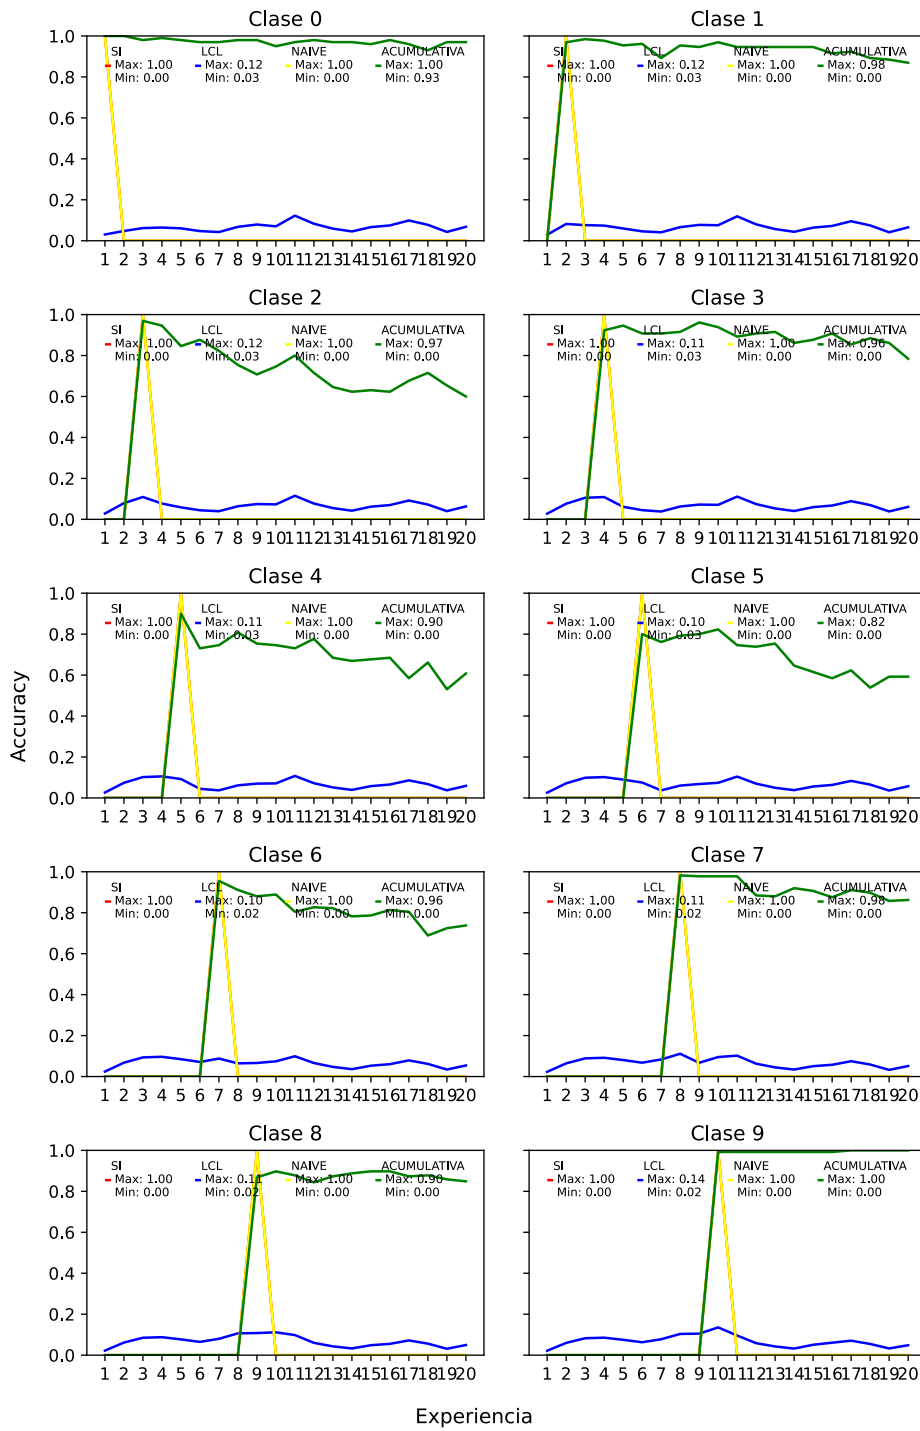


Fig. 6.13. Resultados escenario IC para Accuracy en OMNIGLOT - Parte 1

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Accuracy

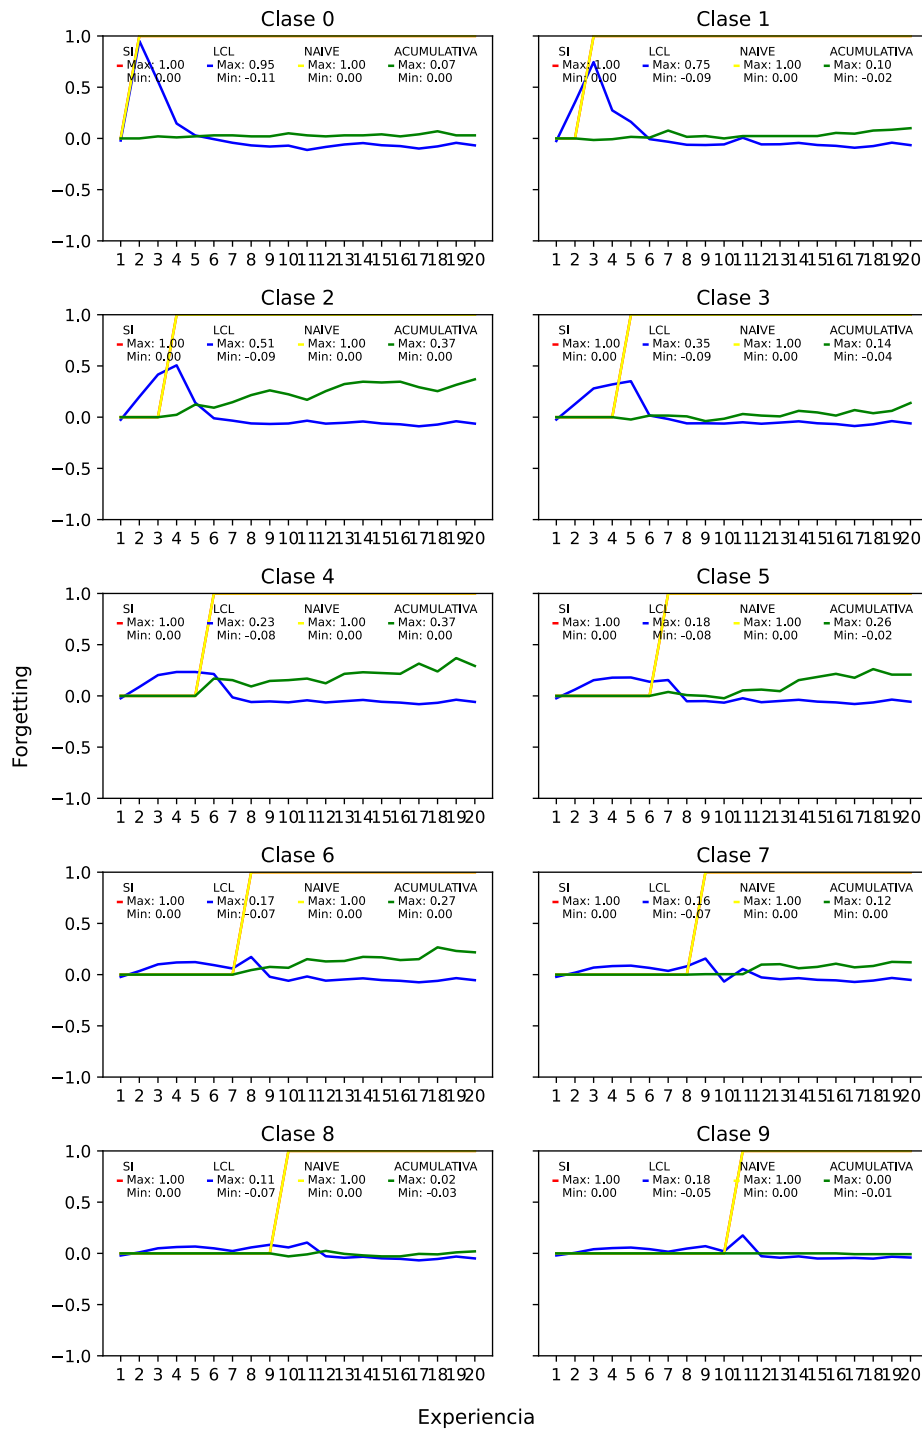


Fig. 6.14. Resultados escenario IC para Forgetting en OMNIGLOT - Parte 1

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Forgetting

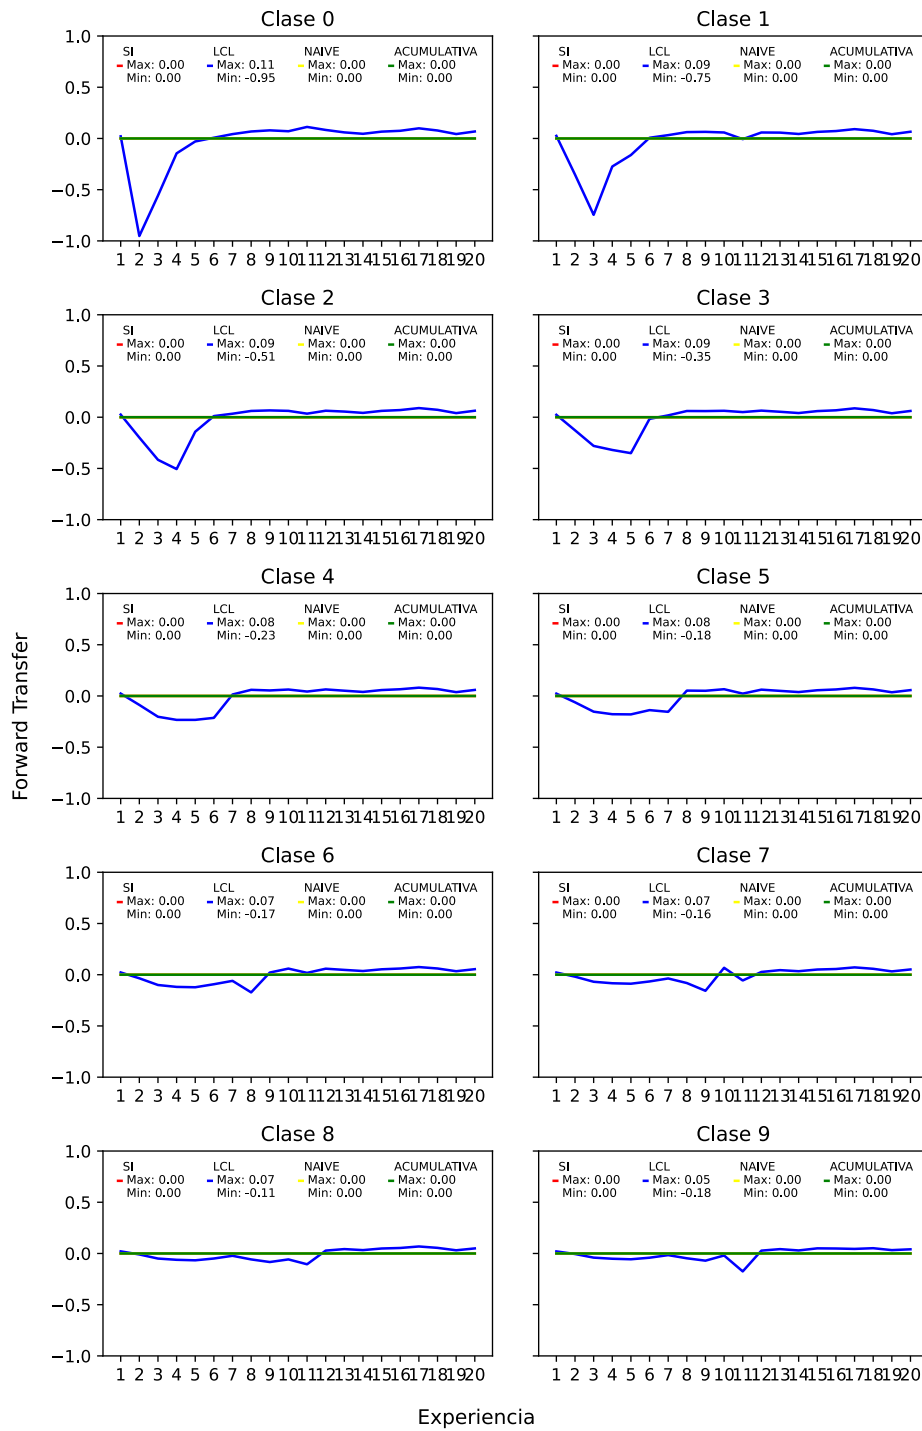


Fig. 6.15. Resultados escenario IC para Forward Transfer en OMNIGLOT - Parte 1

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Forward Transfer

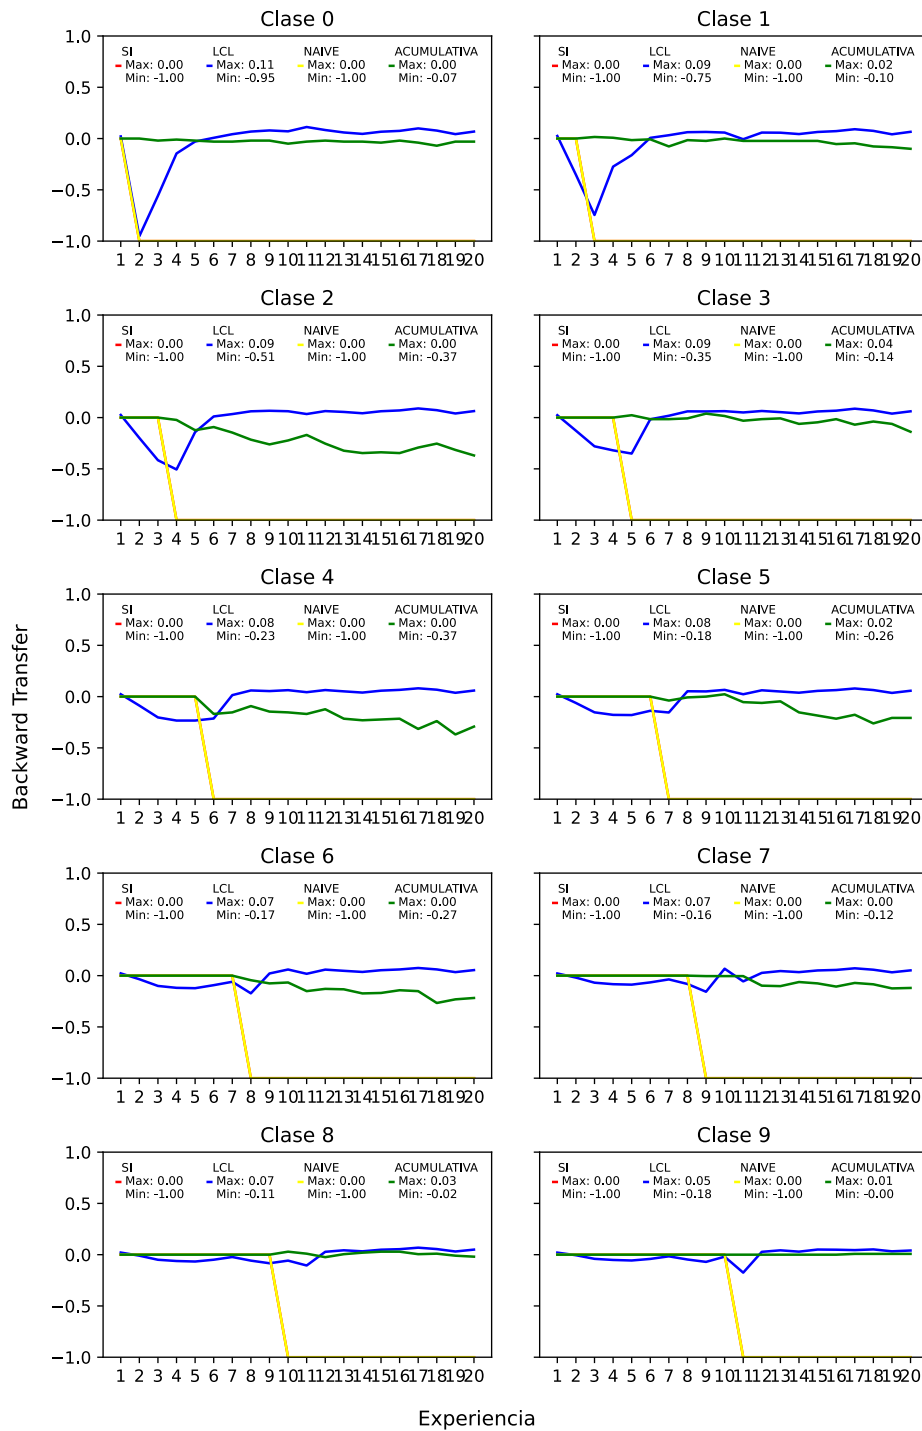


Fig. 6.16. Resultados escenario IC para Backward Transfer en OMNIGLOT - Parte 1

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Backward Transfer

Capítulo 7

DISCUSIÓN

A lo largo de este trabajo, se estudiaron dos estrategias de aprendizaje continuo, Learning to Continually Learn (LCL) y Continual Learning Through Synaptic Intelligence (SI), con el objetivo de mitigar el problema del olvido catastrófico en el contexto de clasificación de imágenes. Se diseñaron y ejecutaron varios experimentos distribuidos en los escenarios IC, II e IIC y ejecutados en dos bases de datos, CIFAR100 y OMNIGLOT, que permitieron evaluar la capacidad de ambas estrategias para aprender de forma continua y efectiva.

Para los 3 escenarios, la estrategia LCL mostró un desempeño interesante a pesar de no presentar un aprendizaje de representaciones mínimo (Accuracy inferior a 0.5), esta estrategia demostró ser capaz de tener un nivel de olvido gradualmente bajo, que se mitigaba a medida que se aprendían más clases. La métrica de Forward transfer explica que a mayor entrenamiento de la estrategia se generaban representaciones que mejoraban el rendimiento de las clases futuras. Lo mismo sucedió con Backward Transfer, donde a mayor entrenamiento se mitigaba el riesgo de afectar negativamente las clases previamente aprendidas. El único caso en el cual este comportamiento fue alterado, es en el escenario de incremento de instancias y puede ser causado muy posiblemente debido al procedimiento de aprendizaje de las clases, donde todas estas se aprendieron durante una sola etapa de entrenamiento y potencialmente sea la causa del no correcto aprendizaje de las representaciones.

Por otro lado, la estrategia SI, mostró un comportamiento diferente en comparación con LCL para los 3 escenarios. Aunque la métrica Accuracy, durante cada etapa de entrenamiento mostraba un desempeño excelente para cada clase e instancia nueva aprendida, el olvido para SI fue total, olvidando lo aprendido en las clases previas, durante las experiencias inmediatamente siguientes a aprenderlas. A lo largo de los incrementos de instancia, SI era capaz de mantener las representaciones y no olvidar catastróficamente. Este comportamiento hizo que su rendimiento sea comparable y similar a la estrategia Naive para los escenarios de IC e IIC.

7.1 Desafíos y oportunidades en el aprendizaje continuo

Los resultados del proceso experimental, resaltan que aún hay desafíos considerables a los que se deben enfrentar las estrategias de aprendizaje continuo, para lidiar con el problema del CF y la transferencia de conocimiento. En particular, los resultados de CIFAR100 en los tres escenarios, muestran cómo las estrategias evaluadas tienen dificultades para mantener una alta precisión y estabilidad en eventos donde se aprenden nuevas clases e instancias de forma continua.

Aunque se han realizado avances significativos en la mitigación del CF mediante el uso de estrategias bioinspiradas en la plasticidad sináptica, como es el caso de las estrategias LCL y SI, aún queda un margen de mejora y optimizaciones adicionales, que podrían mejorar sus capacidades de aprendizaje continuo y convertirlas en sistemas inteligentes de larga duración. Un ejemplo de esto, podría ser el añadir una mayor complejidad en términos de parámetros en las capas posteriores a la neuromodulación en estrategias como LCL o diseñar una función de costo en SI que le permita aprender nuevas clases continuamente. Esto podría permitir que dichas estrategias sean capaces de representar información cada vez más compleja y presentar mejores resultados al aprender sobre nueva información de manera continua.

Capítulo 8

CONCLUSIONES

En este trabajo, se exploraron y evaluaron dos estrategias de aprendizaje continuo, LCL y SI, con el objetivo de abordar el problema del olvido catastrófico en la clasificación de imágenes. Se llevaron a cabo experimentos en tres escenarios diferentes (IC, II e IIC) utilizando las bases de datos CIFAR100 y OMNIGLOT. Los resultados mostraron las ventajas y limitaciones que cada estrategia tiene para cumplir con su tarea en la mitigación del olvido catastrófico y la transferencia del conocimiento.

La estrategia LCL en especial, mostró un desempeño prometedor en términos de mitigación del olvido y transferencia del aprendizaje hacia adelante y hacia atrás en todos los escenarios; sin embargo, su precisión en las representaciones obtenidas fue inferior al 50%. Por otro lado, SI mostró un excelente desempeño al aprender las representaciones, obteniendo altas precisiones al aprender cada clase durante cada experiencia, pero experimentó olvido catastrófico al enfrentarse a nuevos escenarios de clases. Estas diferencias en el desempeño de las estrategias, sugiere que podrían ser adecuadas para diferentes contextos y aplicaciones de aprendizaje continuo o incluso, pueden ser mejoradas en términos de complejidad en sus implementaciones y diseños.

A partir de los resultados obtenidos, se identificaron desafíos y oportunidades para el desarrollo del aprendizaje continuo, incluida la necesidad de mejorar la precisión y estabilidad de las estrategias evaluadas en contextos más allá del incremento de clases o tareas. Para abordar estos desafíos, se propone la exploración de técnicas de aprendizaje profundo avanzadas, como el uso de arquitecturas tipo Transformer,¹ que permitan el aprendizaje de representaciones basadas en la generación de embeddings² que posibiliten controlar una

¹Las arquitecturas tipo Transformer son modelos de aprendizaje profundo basados en atención, exitosos en procesamiento del lenguaje natural y visión por computadora. Para obtener más detalles sobre las arquitecturas tipo Transformer, referase a A. Vaswani et al. [24]

²Los embeddings son representaciones vectoriales de objetos en un espacio de menor dimensión, capturando similitudes semánticas y facilitando el aprendizaje en tareas de Inteligencia Artificial. Para obtener más información revise T. Mikolov et al. [25]

plasticidad local y temporal de las sinapsis en las ANN. Lo anterior podría mejorar las capacidades de las estrategias de aprendizaje continuo, para adaptarse a eventos de aprendizaje en evolución y representar información cada vez más compleja.

En conclusión, este trabajo contribuye al campo del aprendizaje continuo al examinar y comparar las estrategias LCL y SI, proporcionando información sobre sus capacidades y limitaciones en un proceso evaluativo de mayor rigor que el usado comúnmente en el estado del arte. Aunque se han logrado avances significativos en la mitigación del CF y la transferencia del conocimiento, aún existe un gran margen para mejorar las estrategias de aprendizaje continuo. La investigación futura en este campo, debe centrarse en desarrollar enfoques más efectivos y versátiles para abordar los desafíos y limitaciones identificados, lo que permitirá la creación de sistemas de inteligencia artificial más robustos que generalicen sobre la información (AGI), aprendan continuamente y sean de larga duración.

REFERENCIAS

- [1] K. Zilles, “Neuronal plasticity as an adaptive property of the central nervous system,” *Annals of Anatomy - Anatomischer Anzeiger*, vol. 174, pp. 383–391, 10 1992. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0940960211802554>
- [2] J. Palacios-Filardo and J. R. Mellor, “Neuromodulation of hippocampal long-term synaptic plasticity,” *Current Opinion in Neurobiology*, vol. 54, pp. 37–43, 2 2019. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0959438818301041>
- [3] M. Mermillod, A. Bugaiska, and P. Bonin, “The stability-plasticity dilemma: investigating the continuum from catastrophic forgetting to age-limited learning effects,” *Frontiers in Psychology*, vol. 4, p. 504, 2013. [Online]. Available: <http://journal.frontiersin.org/article/10.3389/fpsyg.2013.00504/abstract>
- [4] F. Zenke, B. Poole, and S. Ganguli, “Continual Learning Through Synaptic Intelligence,” 3 2017, uses selective plasticity to resolve the catastrophic forgetting problem. [Online]. Available: <http://arxiv.org/abs/1703.04200>
- [5] D. O. Hebb, *The organization of behavior: A neuropsychological theory*. Psychology Press, 2005.
- [6] T. Schaul, J. Quan, I. Antonoglou, and D. Silver, “Prioritized experience replay,” *arXiv preprint arXiv:1511.05952*, 2015.
- [7] A. A. Rusu, N. C. Rabinowitz, G. Desjardins, H. Soyer, J. Kirkpatrick, K. Kavukcuoglu, R. Pascanu, and R. Hadsell, “Progressive neural networks,” *arXiv preprint arXiv:1606.04671*, 2016.
- [8] K. McRae and P. A. Hetherington, “Catastrophic interference is eliminated in pretrained networks,” in *Proceedings of the 15h Annual Conference of the Cognitive Science Society*, 1993, pp. 723–728.

-
- [9] J. Kirkpatrick, R. Pascanu, N. Rabinowitz, J. Veness, G. Desjardins, A. A. Rusu, K. Milan, J. Quan, T. Ramalho, A. Grabska-Barwinska *et al.*, “Overcoming catastrophic forgetting in neural networks,” *Proceedings of the national academy of sciences*, vol. 114, no. 13, pp. 3521–3526, 2017.
- [10] G. I. Parisi, R. Kemker, J. L. Part, C. Kanan, and S. Wermter, “Continual lifelong learning with neural networks: A review,” *Neural networks*, vol. 113, pp. 54–71, 2019.
- [11] D. Kumaran, D. Hassabis, and J. L. McClelland, “What learning systems do intelligent agents need? Complementary learning systems theory updated,” *Trends in cognitive sciences*, vol. 20, no. 7, pp. 512–534, 2016.
- [12] M. McCloskey and N. J. Cohen, “Catastrophic Interference in Connectionist Networks: The Sequential Learning Problem,” pp. 109–165, 1989. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0079742108605368>
- [13] R. Ratcliff, “Connectionist models of recognition memory: Constraints imposed by learning and forgetting functions.” *Psychological Review*, vol. 97, pp. 285–308, 1990. [Online]. Available: <http://doi.apa.org/getdoi.cfm?doi=10.1037/0033-295X.97.2.285>
- [14] M. Fauth and C. Tetzlaff, “Opposing Effects of Neuronal Activity on Structural Plasticity,” *Frontiers in Neuroanatomy*, vol. 10, p. 75, 6 2016. [Online]. Available: <http://journal.frontiersin.org/Article/10.3389/fnana.2016.00075/abstract>
- [15] V. Lomonaco and D. Maltoni, “COrE50: a New Dataset and Benchmark for Continuous Object Recognition,” in *Proceedings of the 1st Annual Conference on Robot Learning*, ser. Proceedings of Machine Learning Research, S. Levine, V. Vanhoucke, and K. Goldberg, Eds., vol. 78. PMLR, 13–15 Nov 2017, pp. 17–26. [Online]. Available: <https://proceedings.mlr.press/v78/lomonaco17a.html>
- [16] A. Krizhevsky, “Learning Multiple Layers of Features from Tiny Images,” 2009.
- [17] B. M. Lake, R. Salakhutdinov, and J. B. Tenenbaum, “Human-level concept learning

- through probabilistic program induction,” 2015, oMNIGLOT;br/¿. [Online]. Available: www.sciencemag.org
- [18] M. Mundt, S. Lang, Q. Delfosse, and K. Kersting, “CLEVA-Compass: A Continual Learning Evaluation Assessment Compass to Promote Research Transparency and Comparability,” 10 2021. [Online]. Available: <http://arxiv.org/abs/2110.03331>
- [19] S. Beaulieu, L. Frati, T. Miconi, J. Lehman, K. O. Stanley, J. Clune, and N. Cheney, “Learning to continually learn,” *arXiv preprint arXiv:2002.09571*, 2020.
- [20] K. Javed and M. White, “Meta-Learning Representations for Continual Learning,” 5 2019, oML. [Online]. Available: <http://arxiv.org/abs/1905.12588>
- [21] V. Lomonaco, D. Maltoni, and L. Pellegrini, “Rehearsal-Free Continual Learning over Small Non-IID Batches.” in *CVPR Workshops*, vol. 1, no. 2, 2020, p. 3.
- [22] A. Douillard and T. Lesort, “Continuum: Simple Management of Complex Continual Learning Scenarios,” *CoRR*, vol. abs/2102.06253, 2021. [Online]. Available: <https://arxiv.org/abs/2102.06253>
- [23] A. Paszke, S. Gross, F. Massa, A. Lerer, J. Bradbury, G. Chanan, T. Killeen, Z. Lin, N. Gimelshein, L. Antiga, A. Desmaison, A. Kopf, E. Yang, Z. DeVito, M. Raison, A. Tejani, S. Chilamkurthy, B. Steiner, L. Fang, J. Bai, and S. Chintala, “PyTorch: An Imperative Style, High-Performance Deep Learning Library,” in *Advances in Neural Information Processing Systems 32*. Curran Associates, Inc., 2019, pp. 8024–8035. [Online]. Available: <http://papers.neurips.cc/paper/9015-pytorch-an-imperative-style-high-performance-deep-learning-library.pdf>
- [24] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin, “Attention Is All You Need,” *CoRR*, vol. abs/1706.03762, 2017. [Online]. Available: <http://arxiv.org/abs/1706.03762>
- [25] T. Mikolov, I. Sutskever, K. Chen, G. Corrado, and J. Dean, “Distributed

Representations of Words and Phrases and their Compositionality,” *CoRR*, vol. abs/1310.4546, 2013. [Online]. Available: <http://arxiv.org/abs/1310.4546>

APÉNDICES

APÉNDICE I

Resultados de Experimentos OMNIGLOT

En este apéndice, se presentan resultados adicionales de los experimentos realizados con la base de datos OMNIGLOT en el escenario IC. Estos resultados, complementan y respaldan el análisis realizado en la sección principal del documento [6.2.1].

I.1 Resultados adicionales para escenario IC

Esta sección, contiene resultados adicionales obtenidos durante el proceso de entrenamiento en el escenario IC con la base de datos OMNIGLOT para las clases 10 a la 19. Se presentan gráficas adicionales que refuerzan la visión proporcionada en los resultados del documento principal.

I.1.1 Análisis de resultados adicionales

Las gráficas [I.1, I.2, I.3, I.4] muestran fragmentos de las presentadas en la sección principal, proporcionando una confirmación adicional del desempeño de las estrategias de aprendizaje continuo evaluadas en este estudio.

Los resultados adicionales, respaldan y están en línea con los resultados y análisis discutidos en el documento. Por lo tanto, no se proporciona una discusión detallada en este apéndice. Los lectores interesados en examinar estos resultados adicionales, pueden referirse a la sección principal para obtener más detalles sobre el análisis y las conclusiones relacionadas con el desempeño de las estrategias de aprendizaje continuo evaluadas en este estudio.

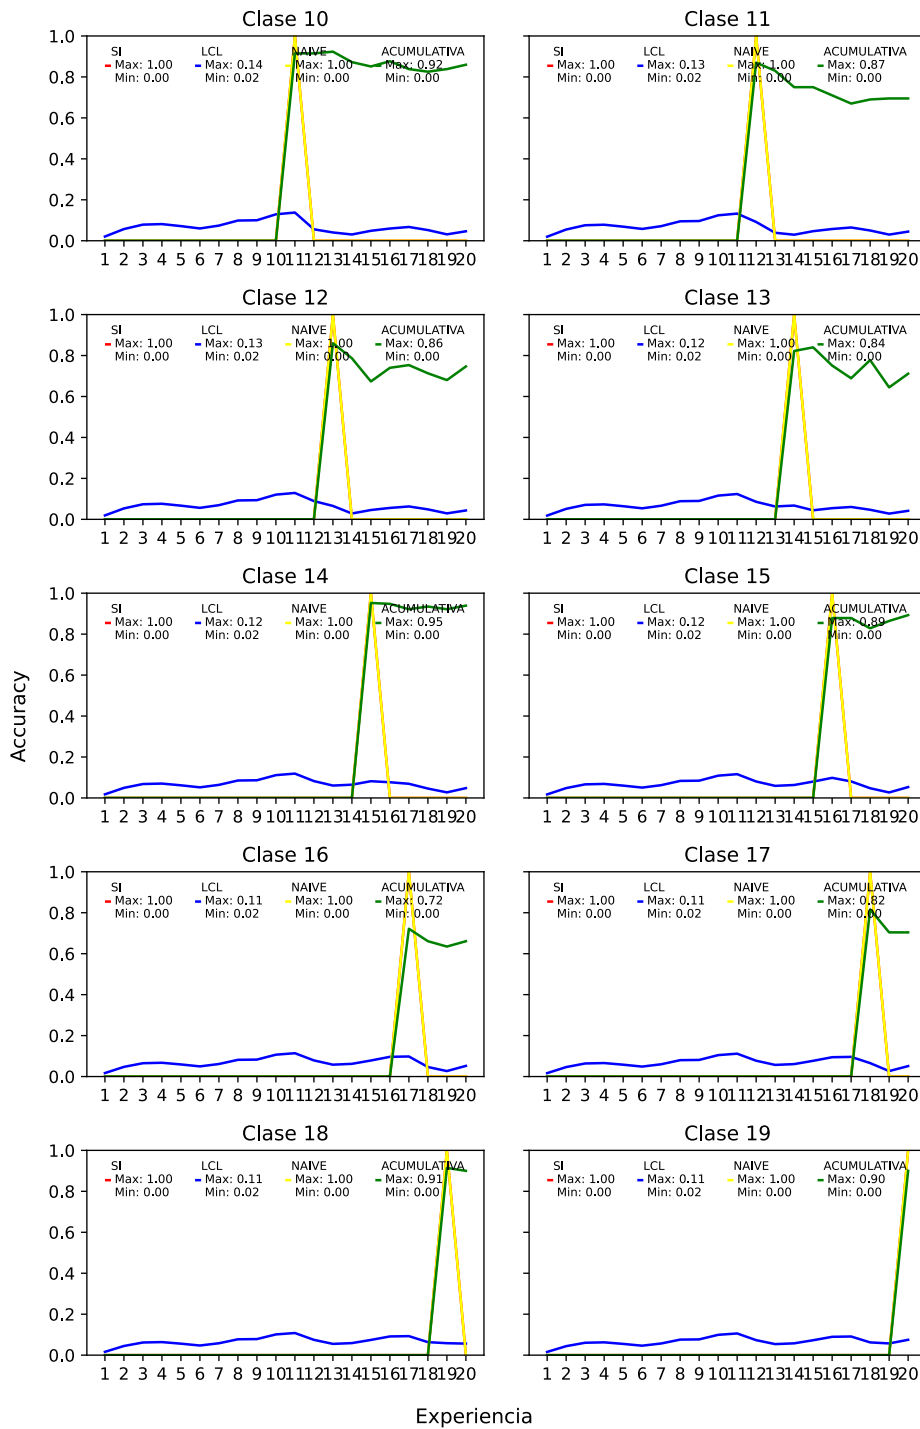


Fig. I.1. Resultados escenario IC para Accuracy en OMNIGLOT - Parte 2

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Accuracy

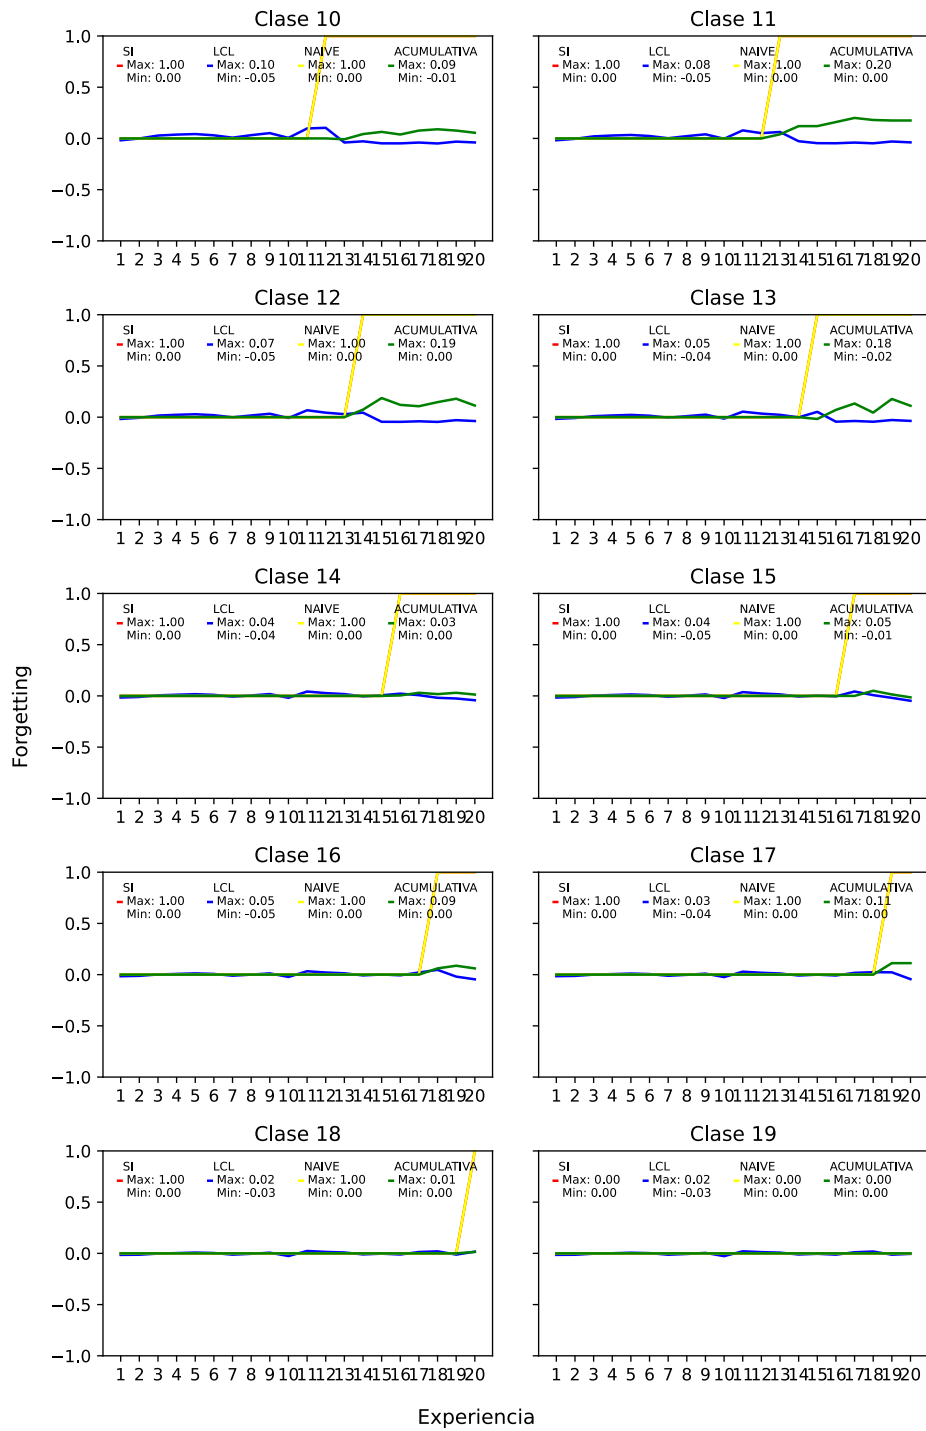


Fig. I.2. Resultados escenario IC para Forgetting en OMNIGLOT - Parte 2

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Forgetting

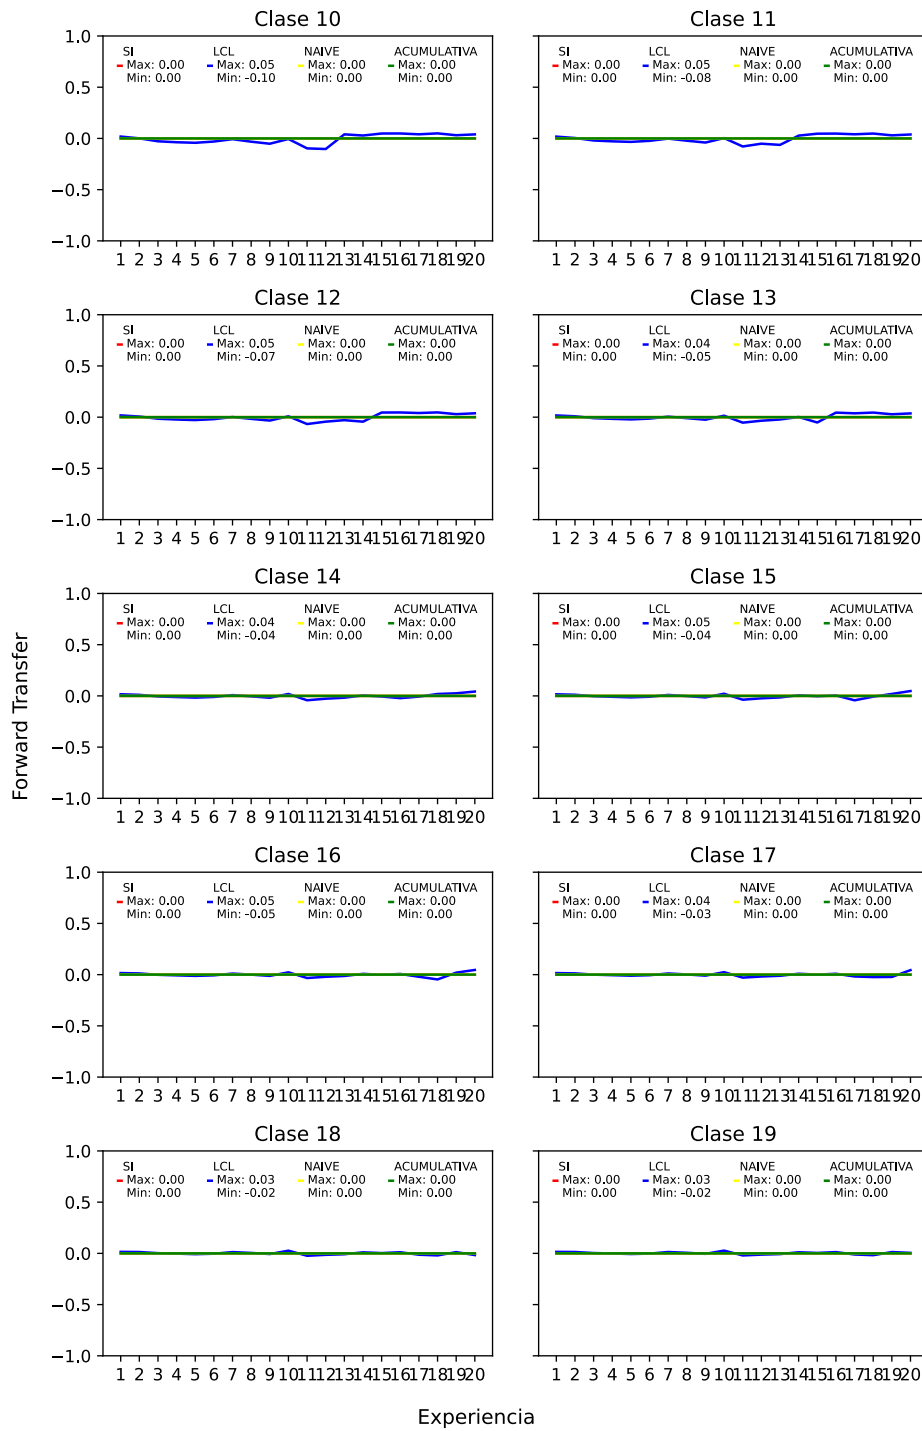


Fig. I.3. Resultados escenario IC para Forward Transfer en OMNIGLOT - Parte 2

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Forward Transfer

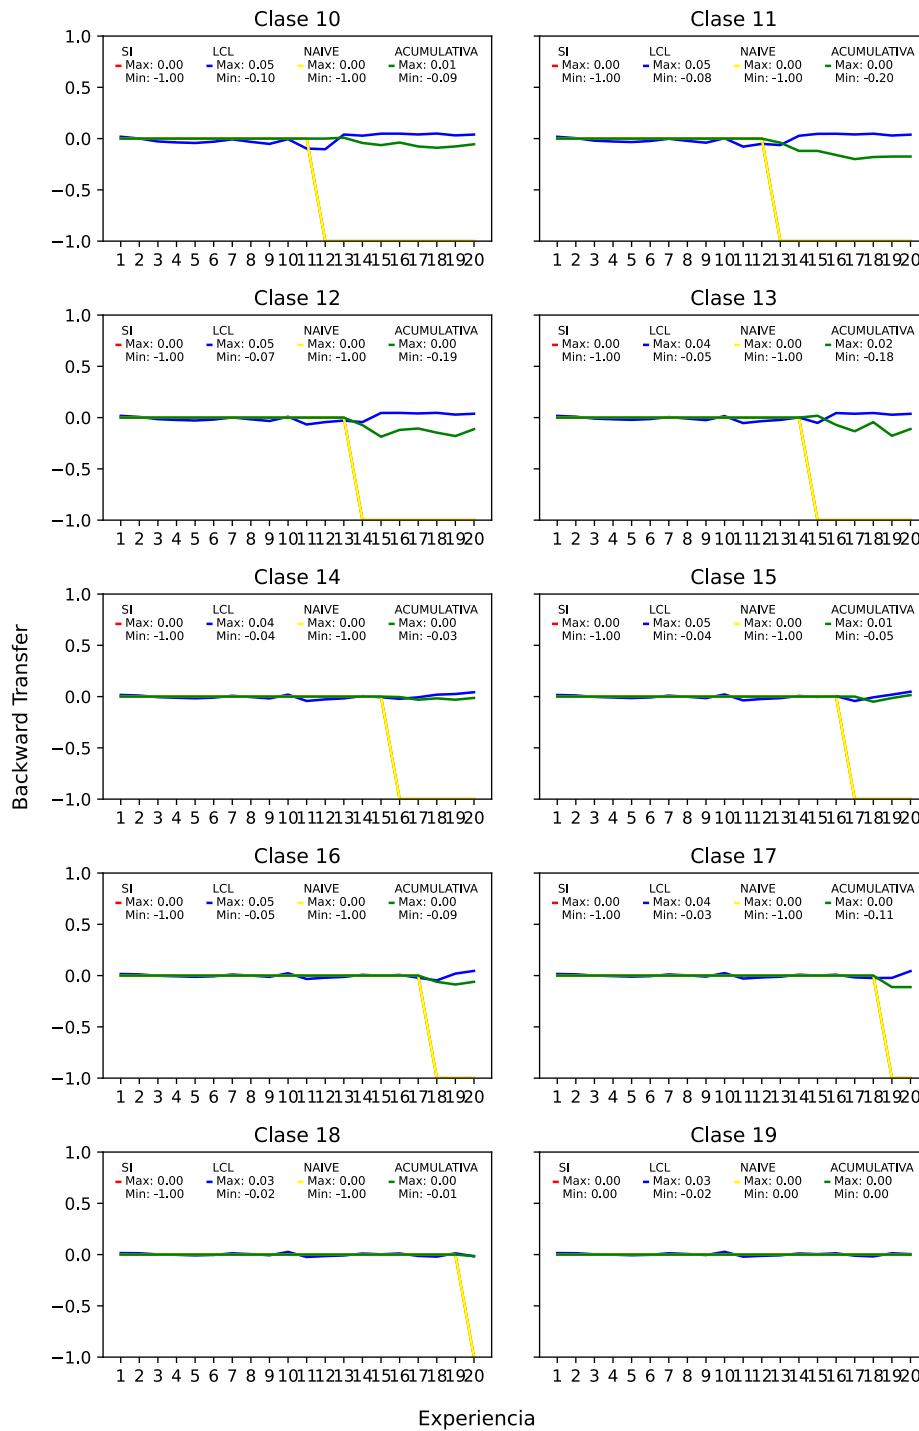


Fig. I.4. Resultados escenario IC para Backward Transfer en OMNIGLOT - Parte 2

Gráfico comparativo del escenario IC entre estrategias SI, LCL, Naive y Cumulative con 9 clases entrenadas secuencialmente durante 9 experiencias usando la métrica de Backward Transfer