



IKER
GAZTE
NAZIOARTEKO
IKERKETA EUSKARAZ

VI. IKERGAZTE

NAZIOARTEKO IKERKETA EUSKARAZ

2025eko maiatzaren 28, 29 eta 30a
Bilbo, Euskal Herria

ANTOLATZAILEA:
Udako Euskal Unibertsitatea (UEU)



Aitortu-PartekatuBerdin 4.0

INGENIARITZA ETA ARKITEKTURA

**GLow – Flower Ingurunean
Oinarritutako Esamesa bidezko
Ikasketa Estrategia Simulatua**

*Aitor Belenguer,
Jose Antonio Pascual
eta Javier Navaridas*

69-76 or.
<https://dx.doi.org/10.26876/ikergazte.vi.03.08>

ANTOLATZAILEA



BABESLEAK



EUSKO JAURLARITZA
GOBIERNO VASCO



LAGUNTZAILEAK



GLOW – Flower Ingurunean Oinarritutako Esamesa bidezko Ikasketa Estrategia Simulatua

Aitor Belenguer, Jose A. Pascual, Javier Navaridas

Intelligent Systems Group (ISG)
Konputagailuen Arkitektura eta Teknologia Saila (KAT)
Euskal Herriko Unibertsitatea (UPV/EHU)
Manuel Lardizabal Pasealekua 1, 20018 Donostia
aitor.belenguer@ehu.eus

Laburpena

Ikasketa-algoritmo deszentralizatuak garapena hasierako fasean dago. Esamesa bidezko ikasketa estrategia modularrak sortzea ez da erraza, izaera deszentralizatuko sistemen konbergentzia-erronkak direla eta. Gure ekarpenak aukera berritzailea eskaintzen du norberak pertsonalizatutako esamesa bidezko ikasketa sistemak Flower ingurunea erabiliz simulatzeko. GLOW, ikertzaileei agenteen eskalagarritasuna eta konbergentzia aztertzeko aukera emango dien tresna da. Sare-topologia pertsonalizatu ezberdinak erabiltzea ahalbidetuz, hedatze fisiko bat egin aurretik. Flower ingurunea aukeratu da, ikasketa federatuaren ikerketa komunitatean onarpen handia duelako eta simulazioa orientatuta dagoelako. Hala ere, Flower-ek soilik ikasketa federatu estrategia estandarrak biltzen ditu, eta, beraz, ez dago jatorriz agintaritzaren zentralizaturik gabeko simulazioak egiteko diseinaturik. GLOW-ek hutsune hori betetzen du, Esamesa bidezko ikasketa sistemak simulatzeko posible eginez. MNIST eta CIFAR10 datu-multzoetan GLOW-ek lortutako emaitzek, 0,98 eta 0,75-ko zehaztasuna erakutsi dute hurrenez hurren.

Hitz gakoak: algoritmo deszentralizatuak, esamesa bidezko ikasketa, agente topologiak, Flower ingurunea

Abstract

Fully decentralized learning algorithms are still in an early stage of development. Creating modular Gossip Learning strategies is not trivial due to convergence challenges intrinsic in systems of decentralized nature. Our contribution provides a novel means to simulate custom Gossip Learning systems by leveraging the state-of-the-art Flower Framework. Specifically, we introduce GLOW, which will allow researchers to train and assess scalability and convergence of devices, across custom network topologies, before making a physical deployment. The Flower Framework is selected for being a simulation featured library with a very active community on Federated Learning research. However, Flower exclusively includes vanilla Federated Learning strategies and, thus, is not originally designed to perform simulations without a centralized authority. GLOW is presented to fill this gap and make simulation of Gossip Learning systems possible. Results achieved by GLOW in the MNIST and CIFAR10 datasets, show accuracies over 0.98 and 0.75 respectively.

Keywords: Decentralized Algorithms, Gossip Learning, Agent Topologies, Flower Framework

1 Sarrera eta motibazioa

GLOW (Belenguer et al., 2025), Flower ingurunean (Beutel et al., 2020) eraikitako eta simulazioan oinarritzen den *Esamesa bidezko Ikasketa*¹ (EI), estrategia berria da. Garatutako tresnak ikertzaileei EI sistemen konbergentzia, eskalagarritasuna eta errendimendua aztertzeko aukera ematen diona. Flower, *Ikasketa Federatuaren*² (IF) ikerketak hedatzeko ingurunea da: zerbitzari zentralizatu batean oinarritutako agregazio-estrategiak implementatzen dituen. Hala ere, guk bestelako eszenatoki bat aurreikusten dugu, non, *Gauzen Internetaren* bidez (GI) gailu mota ezberdinak interkonexio-eskema deszentralizatu baten bidez elkarrekin konektatzen diren (agregazio-zerbitzaririk

¹Gossip Learning

²Federated Learning

gabe). GLOW-ek, Flower ingurunearen ezaugarriak aprobetxatzen ditu guztiz deszentralizatua den esamesa bidezko ikasketa ahalbidetzeko. Zehazki, agente bakoitzak bere ikasketa eredu propioa du eta bere auzokideekin parametroak trukatu, ikasketa hobetzea lortzen du. GLOW-en ezaugarri garrantzitsu bat sare-topologia eta agenteen portaera pertsonalizatzeko gaitasuna da, hau da, sistema deszentralizatuak diseinatzeko askatasun-maila handia eskaintzen du. Horrez gain, agentei aurrez definitutako portaera bat jarraitzeko argibideak ematea ahalbidetzen duen metodologia bat proposatzen dugu. Ikasketa sistema deszentralizatuaren bilakaera egokia aztertzeke aukera emanez.

Proba-eredu gisa, GLOW-en errendimendua aztertzeke topologia sinple batzuk proposatu eta esperimentu multzo bat burutu dugu. Lortutako emaitzak *Ikasketa Zentralizatua* (IZ) eta *Ikasketa Federatua* (IF) sortutako pareko sistemekin alderatu ditugu, teknologia bakoitza erabiltzeak dakartzan abantaila eta desabantailak eztabaidatzeko. Esperimentazioan, MNIST (LeCun eta Cortes, 2010) eta CIFAR10 (Krizhevsky et al., 2009) datu-multzoak erabili ditugu, epoka zein agente kopuru aldakorrek; konektibitate maila ezberdinak dituzten hainbat konfigurazio planteatuz: 8 agente 5 topologia, sare deskonektatutik guztiz konektatura. Emaitzek MNIST-en 0,98-ko eta CIFAR10-en 0,75-eko zehaztasunak erakusten dituzte. Hurrengo ataletan deskribatzen den modura, GLOW simulazioan oinarritzen den estrategia modular deszentralizatua da; IZ eta IF sistemekin alderatuta pareko errendimendua lortzen duena.

2 Arloko egoera eta ikerketaren helburuak

2.1 Ikasketa Federatua

Ikasketa Federatua (IF) hainbat agente modu kolektiboan entrenatzea ahalbidetzen duen ikasketa automatiko teknika bat da. IF lehen aldiz Brendan McMahan et al. (2017)-k proposatzen dute (FedAVG). Aurretik, literaturak proposatzen duen teknika *Ikasketa Zentralizatua* (IZ) da. IZ-n, gailu banatuen datuak zuzenean datu-prozesaketa gune batera bidaltzen dira. Datu horiek modu gordinen bidaltzen dira saretik eta ikasketa algoritmo ezberdinak horien gainean zerbitzari jakin batean entrenatu. IZ-k pribatutasun eta eskalagarritasun aldetik egokitasun arazoak aurkeztu ditu. IF-a eragozpen horiei aurre egiteko sortzen den arren, parametroen batez-besteak burutzeko agente zentralizatu baten erabilera eskatzen jarraitzen du. Gaur egun, IF ikerketa-gai beroa bihurtu da, eta hainbat IF sistema sortu dira. Haien izaera eta helburuen arabera, Li et al. (2019) proposatutako eskemaren arabera sailka daitezke: (1) datu-partizio metodoa, (2) entrenatutako ikasketa automatiko eredu, (3) pribatutasun mekanismoa, (4) komunikazio arkitektura, (5) federazioaren eskala, (6) federazioaren motibazioa...

2.2 Esamesa bidezko Ikasketa

Esamesa bidezko Ikasketa (EI) metodo deszentralizatu bat da, non agente ezberdinek beren bizilagunekin (pareekin) parametroak trukatu eta ereduak asinkronoki, zerbitzari zentral baten beharrik gabe, agregatzen dituzten. Nahiz eta Ormándi et al. (2013)-ek EI algoritmoa (eredu linealen sailkapenerako) aspaldian aurkeztu zuten arren, algoritmo deszentralizatuaren ikerketak ez du hainbesteko arreta bereganatu, *Ikasketa Federatua* (IF) tradizionalarekin alderatuz. Izan ere, EI-k intrintsekoki dakartzan konbergentzia eta antolaketa erronkak nabarmenak dira. Hari berean, Yuan et al. (2023)-ek IF-ren ikuspegi ezberdin bat aurkeztu dute, *IF Zentralizatua* (IFZ) eta *IF Deszentralizatua* (IFD) gisa banatuz; antolaketa-zerbitzari baten existentziaren arabera. Gainera, IFD sistemak sailkatzeko taxonomia bat proposatzen da, non, EI agenteen arteko komunikazio protokolo bat bezala aurkeztu duten. Era berean, Martínez Beltrán et al. (2023)-ek existitzen diren IFD inguruneen buruzko informazioa biltzen duten ekarpenen falta aldarrikatzen dute, hala nola, pertsonalizazio mailaren arabera sailkapen bat proposatu. Nabarmena da TensorFlow Federated (TFF), PySyft edo FedML bezalako inguruneak aipatzen diren arren, Flower (Beutel et al., 2020) erabiltzen duen IFD ikerketarik ez dagoela, nahiz eta IF komunitatean duen erabilera, zabala izan.

2.3 Flower Ingurunea

Flower *kode irekiko* IF ingurunea da, zeinek IF sistemak simulatu, esperimentuak diseinatu eta beren eskalabilitatea neurtzeko baliabideak eskaintzen dituen. Beste era batera esanda, simulazioan egindako ikerketa esperimentaletik gailu heterogeneoetako sistemetara trantsizioa ahalbidetzen du. Beutel et al. (2020)-ek IF ingurune ezberdinen arteko konparaketa bat aurkeztu dute, eta Flower-ek, TFF, Syft, FedScale eta LEAF baino ezaugarri multzo handiagoa eskaintzen duela adierazten dute. Nahiz eta Flower interesgarria izan simulazio, eskalagarritasun eta plataforma anitzeko hedapen propietateei dagokienez; egungo ikerketak eta diseinututako algoritmoak IFZ-ra bideratuta daude, adibidez: FedAVG, FedProx... (Brendan McMahan et al., 2017). Gure ezagutzaren ara-

bera, Flower-en IFD barne hartzen duen ikerketa-lerro baten existentzia garatu gabe dago gaur egun. Ondorioz, GLow-ek duen helburua, EI sistemak simulatzeko estrategia bat Flower ingurunean garatzea da.

3 Ikerketaren muina

3.1 Diseinatutako Estrategia

Aurretik esan bezala, Flower ez dago originalki mekanismo deszentralizatuarekin lan egiteko diseinaturik. Beste era batera esanda, Flower-ek proposatzen dituen estrategia eta simulazioetan zerbitzari zentral (antolatzaile) bat behar da. Hutsune hori betetzeko asmoz, GLow proposatzen dugu, zerbitzari zentralik gabeko EI estrategia bat planteatuz. Izan ere, simulazio bidezko ikasketa-algoritmo bat jorratu dugu, non agente bakoitzak bere bizilagunengandik eskuratzen dituen parametroetatik ikasten duen.

GLow-en iterazio bakoitzean, agente jakin bat zerbitzari (buru) gisa izendatzen da. Hautatutako buruak bere eredu-lokala entrenatuko du – bere datu-base lokaleko instantziak erabiliz. Era berean, bere bizilagunengandik jasotako parametro eguneratuak agregatuko ditu. Sistemaren errendimendua ebaluatzeko, konbergentzia-abiadura eta eskalagarritasunaren arteko konpromisoa kontuan hartzen da – normalean agenteen arteko konexio-grafoak mugatzen duena.

1 Algoritmoa GLow-en Simulazio Prozedura

Require: Aukeratutako k agente buruaren ereduaren pisuak W_H^k , buruaren auzokide den i agente bakoitzeko, eredu-lokalen pisuak W_L^i ; $txanda_totalak$, $E \in \mathbb{Z}^+$

Ensure: Agregatutako eredu buruaren pisuak $W_H^{k'}$

- 1: **for** *iterazio bakoitzeko* 1etik *iterazio_kopuru_totalera* **do**
 - 2: $k = \text{iterazio} \bmod K$
 - 3: $W_L^{k'} = k$ agenteak entrenamendu lokala E aldiz egiten du
 - 4: k agenteak $W_L^{i'}$ pisuak $\mathcal{N}_k$ auzokide bakoitzetik eskuratzen ditu
 - 5: $W_H^{k'} = \sum_{i \in \mathcal{N}} W_L^{i'}$
 - 6: **end for**
-

1. Algoritmoak GLow-en simulazio-prozedura erakusten du: (1) agente-burua txandakatze (*round-robin*) moduan hautatzen da uneko iterazioaren modulua erabiliz³ – beste algoritmo batzuk, hala nola ausa edo lehentasuna, erraz inplementa litezke, (2) hautatutako buruak entrenamendu lokala egiten du E epokaz, instantzia lokalak erabiliz, (3) agente-buruak, bizilagunei beren eredu-lokalen uneko pisuak $W_L^{i'}$ eskatzen dizkie, (4) agregazioa (batez-besteko ponderatua) egiten da entrenamendu lokaleko eta bizilagunen parametroen artean, buruaren ereduak $W_H^{k'}$ eguneratuz.


3.2 Esperimentazioa

GLow Flower-en oinarritutako EI estrategia berri bat da. Nahiz eta natura ezberdineko sistemak ebaluatu eta konparatzeak erronka bat suposatzen duen, IZ, IF eta GLow sistemak erabiltzeak dakartzan abantaila eta desabantailak aztertzeak proba ingurune komun bat diseinatu dugu.

GLow-en errendimendua ebaluatzeko, bi konfigurazio ezberdin prestatu dira – irudi sailkapen ataza bat burutuz. Zehazki, MNIST (LeCun eta Cortes, 2010) eta CIFAR10 (Krizhevsky et al., 2009) datu-multzoak erabili dira. Sistemaren konbergentzia 8 agenteekin probatu da. Agente bakoitzaren ikaskuntza-errendimenduan interkonexio-mailak duen eragina aztertu dugu. Hau da, esperimentuak sare deskonektatu baten *Ikasketa Berezkotik* (IB), sare guztiz konektatu batera dauden tarteko topologiak ikertu ditugu. Proposatutako eszenatokitik, 1. Irudian irudikatzen den bezala, topologia bakoitzean agenteek konexio berriak modu progresiboan gehitzen dituzte – hurrengo bi auzokideekin konektatuz. Beste era batera esanda, topologia bakoitzean agente bakoitzari bi ertz ez-zuzendu gehitzen zaizkio; hau da, 0 topologian agenteek ez dute auzokiderik, 2 topologian 2 auzokide dituzte, eta hala jarraituz, n topologian n auzokide izango dituzte. Beraz, 8 agenteko kasuan, 5 topologia aztertzen dira, sare guztiz deskonektatutik guztiz konektatutako grafora.

³Iterazioak, sistema deszentralizatuen komunikazio-txandak simulatzeko ondorioa dira, hau da, agente guztien komunikazio-txanda asinkronoen batura adierazten dute.

1. Irudia: Topologiak, 8+2 agente konfigurazioan, guztiz deskonektatutako grafo batetik, guztiz konektatutako grafo batera – agente bakoitza hurrengo bi auzokideetara konektatuz. Datu lokalak dituzten agenteak puntu urdinez errepresentatuta daude eta datu lokalik gabekoak puntu zuriz.



Bestalde, lan honetan, ikasketa-sistema deszentralizatu baten portaera zuzena ebaluatzeko agente berezien metodologia aurkezten dugu. 1. Taulak agente bakoitza *kode* eta *kolore-taldearen* arabera multzokatzen du. Agente bakoitzari kolore-kode bat esleitzen zaio 3. eta 4. irudietan erabiliko dena gero. Hurrengo agente bereziak proposatzen ditugu zehazki: (1) datu lokalik ez dituzten agenteak eta saretik deskonektatuta daudenak, hau da, HD motakoak; ausazko portaerarekin jokatu beharko lukete, (2) datu lokalak dituzten eta deskonektatuta dauden agenteak, hau da, D motakoak; datu lokalak dituzten eta konektatuta dauden agenteek baino emaitza baxuagoak eskuratu beharko lituzkete, (3) datu lokalik ez baino bizilagunekin konektatuta dauden agenteak (H – Hutsa), pareetatik jasotako parametroetatik ikasi eta konbergentzia maila egoki bat lortu beharko lukete. Gainontzeko agenteek datuak dituzte eta konektatuta daude (A – Arrunta), konbergentzia maila altuenak lortu beharko lituzkete.

3.3 Konfigurazioa

GLow-en agenteen eskalagarritasuna neurtzeko, 8+2 agenterekin esperimentu batzuk definitu ditugu – 8 agente konektatu eta 2 deskonektatu. Esperimentuetan, komunikazio-txandek, agente bakoitza buru bezala aukeratua izan den aldi kopuru totala adierazten dute. Beraz, 1. Algoritmoan erabilitako iterazio kopuru totala agente kopurua bider komunikazio-txandak izango da. Hautatutako datu-multzoaren arabera, komunikazio-txanda kopuru ezberdina ezartzen da: 24 komunikazio-txanda agente bakoitzeko MNIST-en, eta 101 komunikazio-txanda agente bakoitzeko CIFAR10-en. Erabilitako datu-multzoaren konplexutasuna dela eta, komunikazio-txanda kopuru ezberdinak erabili ditugu.

Esperimentuak 5 aldiz jaurti dira, agente bakoitzari dagokion entrenamendu lokalaren epoka kopurua kontuan hartuta; 2, 4, 8, 16 eta 32 epoka. Horrela, agente bat buru gisa hautatzen denean, epoka kopuru jakin batez bere eredu-lokala entrenatuko du. Ondoren, bere bizilagunei parametroak eskatu eta lokalekin agregatuko ditu.

1. Taula: GLow-en existitzen diren agente moten laburpena.

Konfigurazioa	Kodea ^a	Kolore-Taldea	Agente IDa
8+2	A	Urdin-Morea	1, 2, 3, 4, 5, 6, 7
8+2	D	Berde Argia	8
8+2	H	Laranja-Horia	0, 4
8+2	HD	Gorri-Ilun Gorria	9

^a A: Arrunta (konektatua eta datu lokalekin), D: Deskonektatua, H: Hutsa (datu lokalik ez), HD: H+D (ausazko portaera) – konektibitatea 2 topologiatik aurrera hasiko da.

3.4 Emaitzak

Atal honetan, GLow estrategiaren bideragarritasuna ebaluatuko dugu IZ eta IF-rekin alderatuz. Ebaluazio sakona burutu dugu⁴, topologia ugari eta epoka kopuru ezberdinarekin (ikus 3.2 Atala). Hala ere, labur eta ulergarri izan dadin, emaitza esanguratsuenetan jarriko dugu arreta.

⁴Esperimentazio guztia eskuragarri dago: <https://github.com/AitorBl6/GLow>


Lehenik eta behin, IZ eta IF sistemek lortutako emaitzak erreferentzia gisa hartu ditugu. Ondoren, GLow erabiliz, sare-topologia bakoitzaren konektibitate-mailak errendimenduan duen eragina aztertu dugu. Emaitzak sinple erakustearren, zehaztasuna (*accuracy*) eta galeraren bilakaera (*loss evolution*) izan dira aukeratutako metrikak. 2. Taulan, hiru sistemetan lortutako emaitzak erakusten dira, esperimentu bakoitza exekutatu ondoren, lortutako batez besteko zehaztasuna erakutsiz. GLow-en kasuan, estrategia guztiz deszentralizatua denez, konektatuta dauden agenteek (A eta H) lortutako zehaztasunaren batezbestekoa egin dugu, hau da, deskonektatuta dauden agenteak (D eta HD) IB egiten ari direnez, ez ditugu EI-ren parte bezala kontsideratu (paretatik informaziorik eskuratzen ez dutelako). 2. Taulan agertzen diren GLow-en emaitzak, 4. topologia (eraztun bikoitza) konexio-ereduan lortutakoak dira. Arrazoi nagusia, A eta H agente guztiek konbergentzia-maila antzekoak lortzen dituzten lehen topologia izatea da – konektibitate aldetik. Hala ere, GLow-ek bi erronka nagusiri egin behar die aurre. Alde batetik, GLow-en erabiltzen den datu-multzoaren zati bat agente deskonektatueta geratzen denez, konektatuta dauden agenteen instantziak elkartuko bagenitu, hasierako datu-multzoaren azpimultzo bat osatuko dutela esan daiteke. Bestetik, GLow-ek daturik ez dituzten agenteak barneratzen ditu, ereduaren zehaztasuna kaltetzeko arriskua areagotuz.

2. Taula: Eskuratutako emaitzen laburpena IZ, IF eta GLow sistemetan.

Sistema	Datu-multzoa	Agente kopurua	Komunikazio-Txandak	Epoka-Lokalak ^a	Batezbesteko Zehaztasuna ^b
IZ	MNIST	-	-	24	0,989
IZ	CIFAR10	-	-	101	0,789
IF	MNIST	10	24	32	0,985
IF	CIFAR10	10	101	32	0,791
GLow	MNIST	8+2	24	32	0,987
GLow	CIFAR10	8+2	101	32	0,754

^a Ez daude *Komunikazio-Txandarik* IZ-n; *Epoka-Lokalak* sistemaren epoka kopuru totala izango dira. ^b Agente deskonektatuaren emaitzak ez dira kontuan hartuko GLow-en batezbesteko zehaztasuna kalkulatzeko.


2. Irudia: Agente bakoitzak lortutako zehaztasuna GLow simulazioan, topologia bakoitzeko, 8+2 agente konfigurazioan, MNIST (ezker) eta CIFAR10 (eskuin) datu-multzoak erabiliz.



3.5 Eztabaida

MNIST datu-multzoan lortutako zehaztasunari dagokionez, GLow, IZ eta IF-ek antzeko emaitzak lortzen dituzte, GLow estrategia guztiz deszentralizatua izan arren (2. Taulan ikus daitekeen bezala). Bestalde, GLow-en arreta jarritz, HD motako agenteen ausazko portaera espero bezala betetzen da (2. Irudian ikus daitekeen bezala). Izan ere, sistemaren portaera monitorizatzeko agente bereziak sartzearen abantailak nabarmenak dira. Bide batez, hasieran saretik deskonektatuta zeuden eta datu lokalik ez dituzten agenteek (H), behin sarera konektaturik daudenean, beren bizilagunengandik informazioa jasotzen hasten dira. Ondorioz, beren A motako bizilagunen antzera konbergitzen dute. Aurrekoa, diseinatutako 8+2 eszenatokian gertatzen da: (1) eraztun topologian, H agenteak konbergitzen hasten direla ikus daiteke; haien zehaztasunean hobekuntza bat ikusiz, baina oraindik urrun beren A


3. Irudia: Galera-ren eboluzioa 8+2 agente konfigurazioan, 24 komunikazio-txanda (32 epoka-lokal); 0, 2, 4 eta 7 topologientzat, MNIST datu-multzoan.



bizilagunen emaitzengandik. Beste era betara esanda, 3. Irudian ikus daitekeen bezala, H agenteen galera A bizilagunenetatik urrun dago, (2) eraztun bikoitz topologiako konexio-maila sendoagoa da, eta H agenteek A agenteen antzeko portaera erakusten dute, (3) eraztun bikoitzaren portaera konektibitate handiagoko topologietan mantentzen da, baina ez dago zehaztasunari dagokionez hobekuntza nabarmenik; 4 topologiak dagoeneko konektibitate maila nahikoa eskaintzen du. Izan ere, konektibitatea gehitzeak eragin txikia du zehaztasunean – konbergentzia azkartzen laguntzen duen arren. 3. Irudian ikus daitekeen bezala. Konektatutako agenteen galera azkarrago jaisten da komunikazio-txanda gutxiagotan (7 eta 4 topologiak alderatuz). Azkenik, GLow-ek IB-rekin alderatuz dituen abantailak, 8. agentearen portaera erreparatuz ikus daitezke. Zehazki, saretik deskonektaturik egoteak, amaierako galeran eragina du; gainontzeko nodo konektatuek (2, 4 eta 7 topologietan) amaierako galera baxuagoak lortzen dituzte 8. komunikazio-txandatik aurrera ikusten denez.

CIFAR10 datu-multzoan lortutako emaitzei erreparatuz, IZ eta IF sistemetan lortutako zehaztasuna nahiko parekoa da. GLow-ekin alderatuz, errendimendua IF-ren alde pixka bat hobea dela antzeman daiteke: 0,754 eta 0,791 zehaztasunak hurrenez hurren. Hala ere, EI sistema deszentralizatuak dakartzan orkestrazio erronkak kontuan hartuta, aldea ez da oso nabaria. MNIST-ekin alderatuz, CIFAR10 datu-multzoaren gainean eredu bat ikasteak konplexutasun handiagoa dakarrela ikus daiteke, esperimendu guztietan zehaztasunak baxuagoak baitira. 4 eta 3 Irudiak alderatuz, CIFAR10-ekin egindako esperimenduek izara kaotikoagoa dutela ikus daiteke. Izan ere, 2 Topologiak duen konektibitate mailarekin, agenteek ez dute konbergentzia maila egokia lortzen – galeraren jaitsierak altu jarraitzen du entrenamendua bukatu ostean. Bestalde, eraztun bikoitz eta guztiz konektatutako grafoen arteko galeren jaitsierei erreparatuz, ez da alde nabarmenik nabaritzen. Ondorioz, konektibitate maila egoki bat 4 topologiarekin jada lortzen dela esan daiteke eta hortik aurrera konexioak gehitzeak abantaila nabarmenik ekartzen ez duela.

4. Irudia: Galera-ren eboluzioa 8+2 agente konfigurazioan, 101 komunikazio-txanda (32 epoka-lokal); 0, 2, 4 eta 7 topologientzat, CIFAR10 datu-multzoan.



4 Ondorioak

GLOW simulazioan oinarritutako izaera modularreko esamesa bidezko ikasketa estrategia berri bat da. Agente-topologia, konfigurazioa, eredu eta datu-multzoak, kodean aldaketa minimoak eginez moldaketak egiteko eraikia dago⁵. Flower ingurunean oinarritu gara inplementazioa komunitatearentzat lagungarria eta ikerketarako irekia izan dadin. Aipatzekoa da GLOW topologia ezberdinak sortzeko gai dela, hala nola emaitzak bistartzeko erreminta bat barneratzen duela – agenteen arteko interkonexio-mailaren arabera konbergentzia aztertzeko tresna-multzo sendoa eskainiz. Horrez gain, saretik deskonektatuta dauden IB agenteek (instantzia lokalekin edo gabe), sistema-ren ebaluazioari aberastasun gehiago ematen diote; konektatuta dauden bizilagunen arteko EI egitearen abantailak ikusiz. 8+2 Agenteen eszenatokian, hiru sistemek emaitza oso antzekoak lortzen dituzte MNIST eta CIFAR10 datu-multzoetan – GLOW-en batezbesteko zehaztasuna MNIST-en: 0,987, eta CIFAR10-en: 0,754 delarik. Aipatzekoak dira estrategia deszentralizatu bat erabiltzeak dakartzan abantailak. Zehazki, eskalagarritasun eta akatsen tolerantziari dagokionez IF sistemekin alderatuz. Izan ere, GLOW estrategiak ez baitu antolaketa-zerbitzaririk behar, potentzialki ahulgune bat izan daitekeena ekidinez eta eskalabilitatea areagotuz.

5 Etorkizunerako planteatzen den norabidea

Ikasketa algoritmo deszentralizatuek erronka ugari intrintsekoki dakartzate. Erronka horiek, etorkizuneko GLOW bertsioetan jorratuko dira. Alde batetik, datu ez-homogeneoeekin (Independenteki eta Berdintsu EZ Banatutako Datuekin) lan egiteak konbergentzia arazoak ekar ditzake. Horiek ekiditeko, literaturak proposatzen dituen hainbat irtenbide aztertuko dira: arreta-mekanismoak (Liu et al., 2021) eta agente-multzokatze (Lai et al., 2024) teknikak. Bestalde, GLOW-en simulazio komunikazio-txanda bakoitzean, agente bat buru gisa hautatzen da – eredu-lokala

⁵Kode irekiko biltegia: <https://github.com/AitorBl6/GLOW>

entrenatu eta auzokoen parametroak agregatzen dituen. Zehazki, txandakatze algoritmoa aukeratu dugu buruaren hautaketa egiteko; agente buruaren hautaketa orekatua bermatzen duelako. Etorkizunean, buruaren hautaketa egiteko bestelako algoritmoak diseinatuko dira, haien eragina ikaskuntza-prozesuan aztertuz. Hala nola, ausazko hautaketa eta lehentasunetan oinarritutako hautaketa algoritmoak. Era berean, GLow-en bertsio paraleloa garatzea aurreikusten da, non, hainbat agente buru bezala hautatuak eta ikasketa zein parametro agregazio atazak batera egin daitezkeen. Azkenik, baliabide mugatuak dituzten GI gailuekin lan egiteak ikasketa eredu arinak sortzea eskatzen du. Horretarako, kuantizazio-teknikak (*quantization*) (Kulkarni et al., 2022) erabiltzea interesgarria izan daiteke, eta sistema guztiz deszentralizatueta aplikatzeak ikerketa-lerro berriak ireki ditzake.

Erreferentziak

- Belenguer, A., Pascual, J. A., & Navaridas, J. (2025). Glow – a novel, flower-based simulated gossip learning strategy.
- Beutel, D. J., Topal, T., Mathur, A., Qiu, X., Parcollet, T., & Lane, N. D. (2020). Flower: A friendly federated learning research framework. *CoRR*, abs/2007.14390.
- Brendan McMahan, H., Moore, E., Ramage, D., Hampson, S., & Agüera y Arcas, B. (2017). Communication-efficient learning of deep networks from decentralized data. *Proceedings of the 20th International Conference on Artificial Intelligence and Statistics, AISTATS 2017*, 54.
- Krizhevsky, A., Nair, V., & Hinton, G. (2009). Cifar-10 (canadian institute for advanced research).
- Kulkarni, U., Hosamani, A. S., Masur, A. S., Hegde, S., Vernekar, G. R., & Siri Chandana, K. (2022). A survey on quantization methods for optimization of deep neural networks. In *2022 International Conference on Automation, Computing and Renewable Systems (ICACRS)*, 827–834.
- Lai, W., Xu, Z., & Yan, Q. (2024). Clustered federated learning based on client's prototypes. In *2024 27th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, 909–914.
- LeCun, Y. & Cortes, C. (2010). MNIST handwritten digit database.
- Li, Q., Wen, Z., Wu, Z., Hu, S., Wang, N., Li, Y., Liu, X., & He, B. (2019). A Survey on Federated Learning Systems: Vision, Hype and Reality for Data Privacy and Protection. 1–44.
- Liu, Y., Garg, S., Nie, J., Zhang, Y., Xiong, Z., Kang, J., & Hossain, M. S. (2021). Deep Anomaly Detection for Time-Series Data in Industrial IoT: A Communication-Efficient On-Device Federated Learning Approach. *IEEE Internet of Things Journal*, 8(8):6348–6358.
- Martínez Beltrán, E. T., Pérez, M. Q., Sánchez, P. M. S., Bernal, S. L., Bovet, G., Pérez, M. G., Pérez, G. M., & Celdrán, A. H. (2023). Decentralized federated learning: Fundamentals, state of the art, frameworks, trends, and challenges. *IEEE Communications Surveys & Tutorials*, 25(4):2983–3013.
- Ormándi, R., Hegedus, I., & Jelasity, M. (2013). Gossip learning with linear models on fully distributed data. In *Concurrency and Computation: Practice and Experience*, volume 25, 556–571. John Wiley and Sons Ltd.
- Yuan, L., Wang, Z., Sun, L., Yu, P. S., & Brinton, C. G. (2023). Decentralized federated learning: A survey and perspective.

6 Eskerrak eta oharrak

Ikerketa-lan hau Eusko Jaurlaritzak babestu du, KK-2023/00012, KK-2023/00090, KK-2024/00030, KK-2024/00068 eta IT1504-22 proiektuen bidez. Gainera, MICIU/AEI/10.13039/501100011033 erakundearen babesarekin kontatzen du ere, CNS2023-144315 dirulaguntzarekin hain zuzen ere, "European Union NextGenerationEU/PRTR" programaren bidez. Era berean, MICIU/AEI/10.13039/501100011033 erakundearen PID2023-152390NB-I00 dirulaguntzarekin kontatzen du. Dr. Javier Navaridas-ek Ramón y Cajal beka bat du, Espainiako Zientzia, Berrikuntza eta Unibertsitate Ministerioak (MCIN/AEI/10.13039/501100011033) emandakoa; "ESF Investing in your future" edo "European Union NextGenerationEU/PRTR" programaren bidez babestua. Aitor Belenguer Eusko Jaurlaritzaren doktoretza-beka batez babestua dago.