MARKAZLASHGAN FEDERATIV O‘QITISH USULLARI, ARXITEKTURALARI

Quzibayev Xudayshukur Shavkat o‘g‘li
Texnika fanlari falsafa doktori, Urganch RANCH texnologiyalar universiteti
Email: khudayshukur.kuzibaev@ranch.university
O‘razmatov Tohir Quranboyevich
Texnika fanlari falsafa doktori (PhD) Urganch RANCH texnologiyalar universiteti
Email: tokhir.urazmatov@ranch.university
Beymamatov Xudoybergan Ollobergan o‘g‘li
Urganch RANCH texnologiyalar universiteti o‘qituvchi-stajyori
Email: khudaybergan.beymamatov@ranch.university
Quljanova Shukurjon Zaribovna
Urganch RANCH texnologiyalar universiteti o‘qituvchi-stajyori
Email:quljanova83@gmail.com

Annotatsiya. Federativ o‘rganish (Federated Learning, FL) foydalanuvchi ma’lumotlarini saqlagan holda bilim almashish imkoniyati, maxfiylikni himoyalash, o‘rganish samaradorligini oshirish hamda aloqa (kommunikatsiya) yuklamasini kamaytirish xususiyatlari tufayli tobora ko‘proq e’tiborni tortmoqda. Markazlashtirilmagan federativ o‘rganish (Decentralized Federated Learning, DFL) markaziy federativ o‘rganishdan (Centralized Federated Learning, CFL) farqli ravishda, markaziy serverga bo‘lgan ehtiyojni bartaraf etuvchi markazlashtirilmagan tarmoq arxitekturasiga asoslanadi. DFL mijozlar (klientlar) o‘rtasida bevosita aloqa o‘rnatishni ta’minlab, kommunikatsiya resurslarini sezilarli darajada tejash imkonini beradi.

Kalit sozlar: Federativ o‘qitish, markazlashtirilmagan o‘rganish, tarmoq, maxfiylikni saqlash, buyumlar interneti (Internet of Things, IoT).

Аннотация. Федеративное обучение (Federated Learning, FL) в последние годы привлекает всё большее внимание благодаря своей способности обеспечивать обмен знаниями при сохранении пользовательских данных, защите конфиденциальности, повышении эффективности обучения и снижении коммуникационной нагрузки. В отличие от централизованного федеративного обучения (Centralized Federated Learning, CFL), децентрализованное федеративное обучение (Decentralized Federated Learning, DFL) основано на децентрализованной сетевой архитектуре, исключающей необходимость использования центрального сервера. DFL обеспечивает прямое взаимодействие между клиентами, что позволяет существенно сократить потребление коммуникационных ресурсов.

ISSN 3030-3907

Ключевые слова: федеративное обучение, децентрализованное обучение, сеть, сохранение конфиденциальности, Интернет вещей (Internet of Things, IoT).

Abstract. Federated Learning (FL) has attracted increasing attention due to its ability to enable knowledge sharing while preserving user data, protecting privacy, improving learning efficiency, and reducing communication overhead. Unlike Centralized Federated Learning (CFL), Decentralized Federated Learning (DFL) is based on a decentralized network architecture that eliminates the need for a central server. DFL enables direct communication among clients, thereby significantly reducing communication resource consumption.

Keywords: federated learning, decentralized learning, network, privacy preservation, Internet of Things (IoT).

KIRISH

2020-yilda Google tadqiqotchilari federativ o‘rganish konsepsiyasini federativ tahlil (federated analytics) yo‘nalishigacha kengaytirdilar [4]. Ushbu kengayish natijasida FL faqat o‘rganish vazifalari bilan cheklanmay, balki hamkorlikda hisoblash, ma’lumotlarni tahlil qilish va xulosalar chiqarish (inferensiya) jarayonlarini ham qamrab oldi hamda Google Keyboard tizimida yanada keng miqyosda joriy etildi.

Federativ o‘rganish aqlli transport tizimlari, buyumlar interneti (Internet of Things, IoT), sog‘liqni saqlash, sanoat ishlab chiqarishi, qishloq xo‘jaligi, energetika, masofadan zondlash va boshqa ko‘plab sohalarda o‘zining yuqori samaradorligini namoyon etgan [1]. Shuningdek, FL geografik cheklovlarni bartaraf etib, butun dunyo bo‘ylab samarali hamkorlikni ta’minlaydi. Masalan, tadqiqotchilar federativ o‘rganishdan foydalanib, dunyo bo‘ylab 20 ta institutdan olingan ma’lumotlarni birlashtirgan holda COVID-19 bilan kasallangan bemorlarning klinik natijalarini bashorat qilish uchun universal modelni tayyorlaganlar [8]. Ushbu yondashuv modelning umumlashtirish (generalizatsiya) qobiliyatini oshirib, turli xil ma’lumot manbalaridan olingan bilimlarni qamrab olish imkonini beradi.

B. Markazlashtirilgan Federativ o‘rganishning variantlari

CFLning tarmoq variantlari va kengaytmalari yuqorida bayon etilgan muammolarni bartaraf etish hamda turli real dunyo qo‘llash ssenariylariga moslashish maqsadida ishlab chiqilgan.

1) Ierarxik federativ o‘rganish (Hierarchical FL).

Ierarxik FL klassik va keng qo‘llaniladigan mijoz–edge–bulut (client–edge–cloud) arxitekturasiga asoslanadi. Ushbu tuzilma doirasida model parametrlarining edge va bulut (cloud) o‘rtasida nisbatan kam chastotada uzatilishi kommunikatsiya yuklamasini sezilarli darajada kamaytiradi. Odatda, qo‘shimcha agregatsiya

ISSN 3030-3907

qatlamlarini joriy etish orqali bir nechta edge-serverlar tashkil etiladi, bu esa kommunikatsiya va hisoblash bosimini taqsimlash hamda yagona nosozlik nuqtasi (SPoF) ta'sirini kamaytirishga xizmat qiladi. Ushbu edge-serverlar mijozlarga geografik jihatdan yaqin joylashgan bo'lib, natijada aloqa resurslari sarfi kamayadi va kechikishlar (latency) qisqaradi Bir yoki bir nechta edge-server darajasidagi agregatsiyadan so'ng, edge-serverlar hosil bo'lgan edge global modelni bulutga uzatadi va u yerda yakuniy global model shakllantiriladi.

Kommunikatsiyani optimallashtirishdan tashqari, edge-serverlarning mijozlarga geografik yaqinligi ularning ulangan mijozlarga yaxshiroq moslashuvini ham ta'minlashi mumkin. Edge-serverlar va ularga ulangan mijozlar geografik jihatdan shaxsiylashtirilgan klasterlar sifatida qaralishi mumkin. Masalan, AQShdagi shtatlar bo'yicha edge-serverlar ajratilgan taqdirda, har bir shtat edge-serveri ob-havo sharoitlari, foydalanuvchilar soni, vaqt mintaqasi, etnik tarkib, yosh taqsimoti kabi omillarni inobatga olgan holda tegishli foydalanuvchi ssenariylariga yaxshiroq moslashishi mumkin.

2) Shaxsiylashtirilgan federativ o'rganish (Personalized FL).

Shaxsiylashtirilgan FL ikki asosiy toifaga ajratiladi: global modelni shaxsiylashtirish va shaxsiylashtirilgan model arxitekturasi. Global modelni shaxsiylashtirish odatda umumiy global modeldan boshlanib, keyinchalik mijoz tomonidan ushbu modelni lokal foydalanuvchiga moslashtirishni nazarda tutadi. Bunday shaxsiylashtirish serverdan mustaqil ravishda mijoz tomonidan amalga oshiriladi; bunga global model bilimlarini lokal muhitga ko'chirishga asoslangan federativ transfer o'rganish misol bo'la oladi.

Shaxsiylashtirilgan model arxitekturasi esa an'anaviy FL arxitekturasini o'zgartirish orqali foydalanuvchiga xos bilimlarni o'z ichiga olgan shaxsiy modelni ishlab chiqishga qaratilgan bo'lib, bu jarayon asosan server tomonidan boshqariladi. Ushbu yo'nalishdagi mashhur arxitekturalardan biri klasterlangan federativ o'rganish (clustered FL) bo'lib, u tadqiqotchilar e'tiborini keng miqyosda tortgan. Shaxsiylashtirilgan FL doirasida mijoz modeli foydalanuvchiga yaqinroq bo'lganligi sababli, u yuqori aniqlik va ishonchlilik bilan ajralib turadi. Ayniqsa, mustaqil va bir xil taqsimlanmagan (non-IID) ma'lumotlar sharoitida shaxsiylashtirilgan FL juda samarali yechim hisoblanadi. Agregatsiyalangan global model foydalanuvchi xususiyatlaridan sezilarli darajada chetga chiqqan hollarda, shaxsiylashtirish mexanizmlari modelni moslashtirish va turli geterogenliklarni qoplash imkonini beradi.

3) Split federativ o'rganish (Split FL).

Split FL o'rganish jarayonida modelni bo'lib o'qitishga asoslanadi, bunda model qatlamlarining bir qismi server zimmasiga yuklatiladi. Mijoz tomonidan

ISSN 3030-3907

serverga uzatiladigan yagona axborot modelning kesish qatlamidagi yashirin tasvirlar (hidden representations) yoki gradientlardan iborat bo‘ladi. Ushbu yondashuvda mijoz o‘rganish vazifasining bir qismini serverga ko‘chiradi, biroq foydalanuvchi ma’lumotlarini bevosita ulashmaydi. An’anaviy FL bilan solishtirganda, Split FL o‘xshash aniqlik va kommunikatsiya samaradorligini ta’minlagan holda, mijoz tomonidagi o‘rganish yuklamasini kamaytiradi va maxfiylikni yanada kuchliroq himoya qiladi. Biroq Split FL hozircha rivojlanishning dastlabki bosqichida bo‘lib, bir qator jiddiy cheklovlarga ega, xususan, yuqori aloqa resurslari sarfini talab etadi. Ayniqsa, serverda yagona nosozlik nuqtasi (Single Point of Failure, SPoF) mavjudligi yanada og‘ir oqibatlarga olib kelishi mumkin.

4) Grafik federativ o‘rganish (Graph FL).

Graph FL grafik tuzilishga ega ma’lumotlar bilan bog‘liq ilovalar, masalan, ijtimoiy tarmoqlar, transport tarmoqlari, molekulyar tuzilmalar va shunga o‘xshash sohalar uchun ayniqsa samarali hisoblanadi. Ushbu samaradorlik mijozlarning tugunlar va qirralar o‘rtasidagi boy munosabatlarni aks ettiruvchi lokal yoki mustaqil grafik ma’lumotlarga egaligi bilan izohlanadi. Aniqroq qilib aytganda, Graph FL mijozlar grafik ma’lumotlar haqida ega bo‘lgan tafsilotlar darajasiga qarab uch bosqichni o‘z ichiga oladi: bir nechta mustaqil grafiklar, bir nechta grafiklarning ayrim qismlari hamda bitta grafikning ayrim qismlari. Grafik ma’lumotlar bilan ishlashda graf neyron tarmoqlaridan foydalanishdan tashqari, ayrim tadqiqotchilar mijozlar o‘rtasidagi topologik grafiklarni ham inobatga olganlar. Bunday topologik grafiklar mijozlar va server o‘rtasidagi tarmoq ulanish sharoitlari, mijozlarning ma’lumot va model resurslari mavjudligi, shuningdek, mijozlar o‘rtasidagi o‘xshashlik va ma’lumotlarning umumiyligi kabi omillar asosida shakllantirilishi mumkin.

5) Asinxron federativ o‘rganish (Asynchronous FL).

Asinxron FL modellarning yangilanishini sinxronlashtirishni talab qiladigan an’anaviy FL tizimlarining cheklovlarini bartaraf etish maqsadida ishlab chiqilgan. Ushbu yondashuv real dunyo ssenariylariga juda mos bo‘lib, bunda mijozlarning ma’lumotlari yangilanishi va model o‘qitish jarayonlari sezilarli darajada farqlanadi. Bunday tizimlarda geterogen mijozlar turli hajmdagi ma’lumotlar va hisoblash resurslariga ega bo‘lib, server barcha mijozlarning sinxronlashishini kutmasdan, istalgan vaqtda lokal modellarning o‘qitilishi va yangilanishiga imkon beradi. Asinxron FL ayniqsa dinamik o‘zgaruvchan, mijozlar soni juda katta va geografik jihatdan keng tarqalgan muhitlar uchun mos keladi. Masalan, mobil qurilmalar ko‘pincha foydalanuvchi bilan faol o‘zaro ta’sir vaqtida emas, balki bo‘sh vaqtlarda model o‘qitishni amalga oshirishi mumkin.

ISSN 3030-3907

Hozirgi vaqtda CFLning turli xil noodatiy arxitekturalarga ega variantlari mavjud bo‘lib, ular muayyan muammolarni optimallashtirish va nishonga olish maqsadida yagona server, bir nechta server, quyi serverlar yoki bosh serverlarni o‘z ichiga olishi mumkin. Masalan, Zhang va hammualliflar (Com)²Net nomli keng ko‘lamli taqsimlangan hisoblash platformasini taklif etgan bo‘lib, u fazo–havo–yer (space–air–ground), end–edge–cloud va ko‘p ma’lumotlar markazi muhitlarini qamrab olib, FLda uzluksiz ulanish va hamkorlikda hisoblash imkonini beradi. Turli variantlardan tashqari, FL tizimlarida bir vaqtning o‘zida bir nechta muammolarni hal etish maqsadida turli variantlarni birlashtirish yondashuvi ham keng tarqalgan.

C. Mijoz va Server Ta’rifi

Ushbu maqolada federativ o‘rganishda (Federated Learning, FL) aloqa nuqtalari tomonidan bajariladigan rollarga e’tibor qaratadigan yangi tasnif (taxonomy) taklif etiladi. Biz edge qurilmalar, hisoblash klasterlari, muassasalar va tashkilotlarning rollari mutlaq emas, balki nisbiy ekanligini ta’kidlaymiz. Masalan, universitet o‘z kampusi doirasidagi edge qurilmalarni boshqarishda markaziy server rolini bajarishi mumkin, biroq boshqa universitetlar bilan aloqa qilganda u mijoz sifatida qaralishi lozim.

Subyektning mijoz sifatida tasniflanishi xom (raw) ma’lumotlarni yaratishi va ushbu ma’lumotlarni lokal darajada saqlashi mezoniga asoslanadi. Masalan, sog‘liqni saqlash muassasasi bemorlarga oid klinik ma’lumotlarni hosil qiladi va ularni boshqa muassasalar bilan ulashmasdan o‘zining ichki ma’lumotlar bazasida saqlaydi.

Shuningdek, mijoz va server rollari o‘zaro mutlaq (mutually exclusive) emas. Masalan, sog‘liqni saqlash muassasasi bir vaqtning o‘zida ham mijoz, ham server vazifasini bajarishi mumkin [5]. Bunday muassasa bemorlar haqidagi xom ma’lumotlarni yaratadi va lokal o‘qitishni amalga oshiradi, shu bilan birga boshqa sog‘liqni saqlash muassasalaridan model parametrlarini qabul qilib, ularni agregatsiya qiladi va yangilangan modelni qayta ulash orqali server rolini ham bajaradi. Amaliy nuqtayi nazardan, bunday tizim DFL doirasida yulduzsimon (star) topologiyaga ega tarmoq sifatida qaralishi mumkin.

CFL o‘rniga yulduzsimon (star) topologiyali tarmoqka e’tibor qaratilishining asosiy sababi federativ o‘rganish (FL) tizimlarida adolatlilik va ishonchlilik bilan bog‘liq muammolarning yanada dolzarb bo‘lishidir, ayniqsa muassasa bir vaqtning o‘zida lokal o‘qitish uchun xom ma’lumotlarga ega bo‘lib, agregatsiya jarayonida server rolini ham bajargan hollarda. Bunday vaziyatda mazkur muassasaning agregatsiya jarayonida o‘zining lokal ma’lumotlariga ustunlik bermasligini ta’minlash ochiq ilmiy muammo bo‘lib qolmoqda. Mashhur

ISSN 3030-3907

ibora bilan aytganda, *“bir shaxs bir vaqtning o‘zida hakam, hay’at va ijrochi bo‘la olmaydi”*. Xuddi shuningdek, bir muassasa ham bir vaqtning o‘zida ham mijoz, ham server rolini bajarishi maqsadga muvofiq emas.

1-jadval

Markazlashtirilmagan Federativ O‘rganish (DFL) tasniflarining ta’riflari va tavsiflari

Tasnif (Taxonomy)	Kategoriya	Tavsif (Description)
Iteratsiya tartibi	Ketma-ket (Sequential)	Mijozlar ma’lum bir tartib asosida birma-bir sinxron tarzda aloqa qiladi.
	Tasodifiy (Random)	Mijozlar tasodifiy tartibda birma-bir sinxron aloqa qiladi.
	Tsiklik (Cycle)	Mijozlar aylana (tsikl) bo‘yicha ketma-ket aloqa qiladi.
	Parallel	Barcha mijozlar asinxron tarzda bir vaqtning o‘zida aloqa qiladi.
Aloqa protokoli	Yo‘naltirilgan (Pointing)	Mijozlar aniq belgilangan bir-mijozdan-bir-mijozga (one-peer-to-one-peer) shaklda aloqa qiladi.
	Gossip	Mijozlar tasodifiy tanlangan qo‘shnilar bilan aloqa qiladi; bu tanlov qo‘shnichilik qoidalari, mijoz modelining versiyasi yoki to‘liq tasodifiylik asosida amalga oshirilishi mumkin.
	Broadcast	Mijozlar bir-mijozdan-barcha-mijozlarga (one-peer-to-all-peers) shaklida aloqa qiladi.
	Broadcast–Gossip	Mijozlar bir-mijozdan-bir-nechta-mijozlarga (one-peer-to-multiple-peers) shaklida aloqa qiladi; bu Gossip va Broadcast yondashuvlarining kombinatsiyasi hisoblanadi.
Tarmoq topologiyasi	Chiziqli (Line)	Mijozlar ketma-ket yo‘naltirilgan aloqa orqali bog‘lanadi.

ISSN 3030-3907

	Shina (Bus)	Mijozlar modelni o‘zidan keyingi barcha mijozlarga ketma-ket uzatadi.
	Halqa (Ring)	Mijozlar aylana shaklida yo‘naltirilgan aloqa qiladi.
	Mesh	Mijozlar barcha boshqa mijozlar bilan to‘g‘ridan-to‘g‘ri aloqa qiladi.
	Yulduzsimon (Star)	Mijozlar faqat markaziy mijoz bilan aloqa qiladi.
	Daraxtsimon (Tree)	Mijozlar o‘zlariga biriktirilgan markaziy tugunlar bilan aloqa qiladi.
	Gibrid	Bir nechta aloqa topologiyalarining kombinatsiyasi.
Paradigma taklifi	Uzluksiz (Continual)	Mijoz oldingi mijozning modelidan bevosita o‘rganishni davom ettiradi.
	Agregatsiyalangan (Aggregate)	Mijoz avvalgi mijozlar modellari agregatsiyasini bajaradi va so‘ng agregatsiyalangan model asosida o‘rganadi.
Vaqt bo‘yicha o‘zgaruvchanlik	Statik	Aloqa arxitekturasi vaqt davomida o‘zgarmaydi.
	Dinamik	Aloqa arxitekturasi tashqi omillar, resurslarni tejash, adolatlilik talablari, konseptual siljish (concept drift) va boshqa omillar ta’sirida o‘zgarishi mumkin.

Shunga qaramay, bunday holat real dunyo sharoitida juda keng tarqalgan. Bir tomondan, ko‘proq xom ma’lumotlarga ega bo‘lgan muassasalar o‘rganish jarayonida kattaroq ta’sir kuchiga ega bo‘lib, ko‘pincha vazifalarni tashabbuskor sifatida boshlaydi. Ikkinchi tomondan esa, katta hajmdagi ma’lumotlarga ega muassasalar odatda yanada boy hisoblash resurslariga ham ega bo‘lib, bu ularni server rolini bajarishga yanada mos qiladi. Bugungi kunda yirik muassasalar ko‘proq resurslarga egaligi va katta ta’sir kuchiga ega ekanligini inobatga olgan holda, kam vakillangan (non-representative) mijozlarning manfaatlari, maxfiyligi va adolatliligini ta’minlash federativ o‘rganish tizimlari uchun muhim va murakkab muammo bo‘lib qolmoqda.

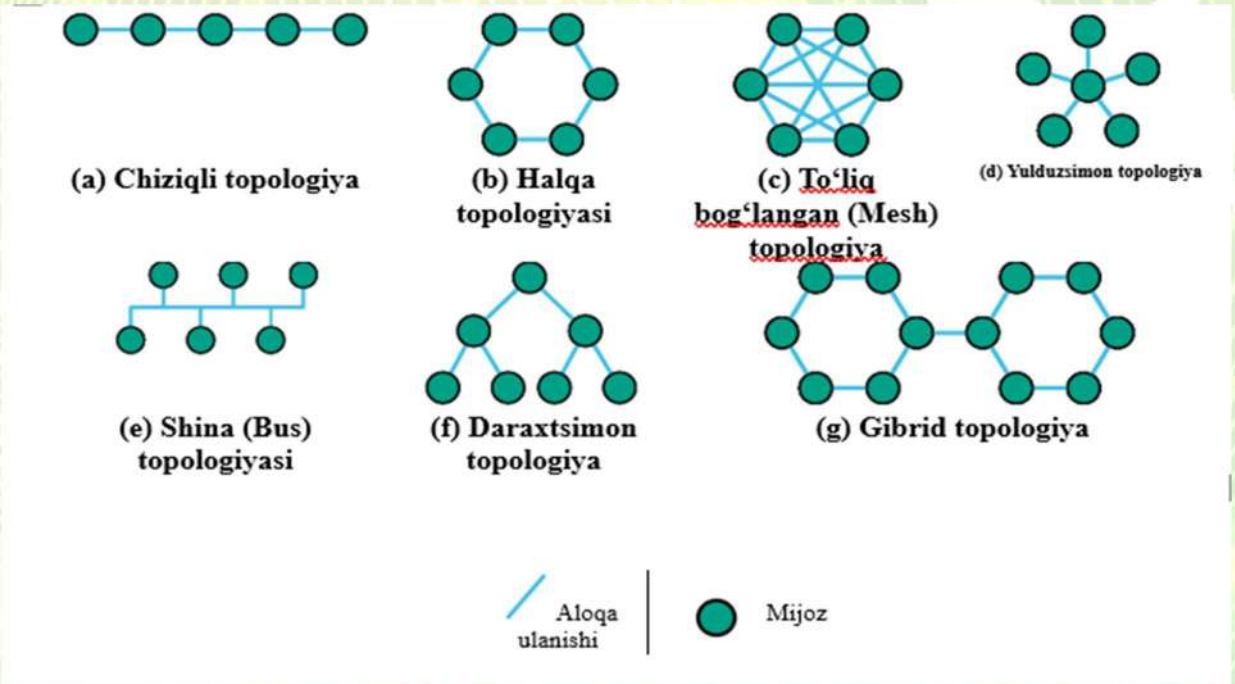
B. Aloqa protokollari

ISSN 3030-3907

Markazlashtirilmagan federativ o‘rganish (Decentralized Federated Learning, DFL) — bu barcha mijozlar bo‘yicha optimal modellarni hosil qilish maqsadida yo‘naltirilgan (pointing), gossip yoki broadcast protokollari asosida model og‘irliklarini almashishga mo‘ljallangan tarmoq arxitekturasidir. Yo‘naltirilgan (pointing) protokol ikki teng huquqli tugun (peer) o‘rtasida bir yo‘nalishli, bir-biriga, va aniq belgilangan aloqa munosabatini o‘rnatishning eng sodda va bevosita shakllaridan biridir.

Gossip va broadcast algoritmlari tarmoqlarda qo‘llash uchun allaqachon yaxshi shakllangan va keng o‘rganilgan. Gossip protokoli mohiyatan mijozlar o‘rtasida tasodifiy bir-mijozdan-bir-mijozga aloqa orqali bilimlarni almashish, tarqatish va o‘rganishni ta’minlaydigan stoxastik kommunikatsiya usulidir [6]. U DFL doirasida standart aloqa protokoli sifatida qaraladi va hozirda faol rivojlanish bosqichida. Broadcast protokoli esa bir-mijozdan-barcha-mijozlarga (one-peer-to-all-peers) aloqa qilishni nazarda tutib, mijozga o‘z modelini barcha boshqa mijozlarga bir vaqtning o‘zida uzatish imkonini beradi.

Hozirgi vaqtda gibrid protokollar kengroq qo‘llanilmoqda. Turli ssenariylar va cheklovlarni hisobga olgan holda, gossip, broadcast hamda ularning kombinatsiyalariga asoslangan aloqa tuzilmalari ishlab chiqilmoqda. Aysal va hammualliflar [3] gossip va broadcast protokollarini birlashtirgan yondashuvni taklif etgan bo‘lib, u bir-mijozdan-qo‘shni-mijozlarga (one-peer-to-neighbor-peers) aloqa qilish shakli sifatida qaraladi; bunda mijoz avval qo‘shnilariga broadcast amalga oshiradi, so‘ngra gossip mexanizmi orqali almashuvni davom ettiradi.



1-rasm.Kommunikatsiya tarmog‘i topologiyalarining sxematik tasviri.

ISSN 3030-3907

Bellet va hammualliflar [2] esa agentlarni asinxron rejimda ishlatadigan hamda o‘xshash mijozlar o‘rtasida broadcast asosidagi aloqa mexanizmini qo‘llaydigan algoritmni taqdim etganlar. Ushbu yondashuvning asosiy maqsadi shaxsiylashtirilgan lokal modellarni samarali tarzda hosil qilishdan iborat.

C. Tarmoq topologiyasi

Markazlashtirilmagan federativ o‘rganish (Decentralized Federated Learning, DFL) tarmoqlari turli xil tarmoq topologiyalaridan ilhomlangan bo‘lib, bu borada manbalarda batafsil ma’lumotlar keltirilgan. Nedić va hammualliflar panjara (grid), yulduzsimon (star) va to‘liq bog‘langan (fully connected) topologiyalarni o‘z ichiga olgan bir qator tarmoq tuzilmalari uchun konvergensiya isbotlarini taqdim etganlar. Serverga asoslangan moslashuv, boshqaruv va tarqatish cheklovlarining mavjud emasligi sababli, DFL tarmoqlari 1-rasmda ko‘rsatilganidek, turli xil va moslashuvchan konfiguratsiyalarni namoyon etadi.

Graph FL kontsepsiyalaridan kelib chiqqan holda, DFL tarmoqlari graf shaklida ifodalanishi mumkin, bunda mijozlar tugunlar (nodes), ularning o‘zaro aloqalari esa qirralar (edges) sifatida qaraladi. DFLda grafga asoslangan ushbu yondashuv mijozlar o‘rtasidagi bog‘liqliklarni, masalan, geterogenlik darajasi va kommunikatsiya xususiyatlariga asoslanib miqdoriy baholash imkonini beradi; bu esa o‘rganish samaradorligini oshirish va modelning barqarorligini kuchaytirishga xizmat qiladi. Shuni ta’kidlash lozimki, rasmda tasvirlangan chiziqli bog‘lanishlar mijozlar o‘rtasidagi ulanishni ifodalaydi va ular bir yo‘nalishli yoki ikki yo‘nalishli bo‘lishi mumkin. Mijozlar o‘rtasida uzatiladigan ma’lumotlar faqat ularning joriy modellaridan iborat bo‘lmay, balki avvalgi o‘zaro ta’sirlardan olingan modellarni ham o‘z ichiga olishi mumkin. Bundan tashqari, har bir mijozning hisoblash doirasi lokal o‘rganish bilan bir qatorda agregatsiya jarayonlarini ham qamrab olishi mumkin.

Markazlashtirilgan federativ o‘rganishda (CFL) barcha mijoz modellarining markaziy serverda jamlanishi sababli, agregatsiya (ya’ni, barcha model parametrlarini o‘rtachalash) bilimlarni integratsiyalashning asosiy va eng ommabop usuli hisoblanadi. Biroq DFL sharoitida vaziyat ancha murakkabdir. Birinchidan, tarmoq topologiyalari xilma-xildir: har bir aloqa raundida mijozlar bir yoki bir nechta boshqa mijozlarga modellarni uzatishda turli protokollarga amal qilishi mumkin. Ikkinchidan, modelning turli versiyalari mavjud bo‘ladi. Sinxron DFLdan tashqari, boshqa DFL yondashuvlarida modelning bir nechta versiyalari muqarrar bo‘lib, o‘rganish jarayonida keyingi mijozlar avvalgi mijozlarga nisbatan ko‘proq bilimni o‘zida mujassam etgan modellarga ega bo‘ladi. Uchinchi jihat — barcha mijozlar bilimlarini to‘liq qo‘lga kiritishning murakkabligi. Hamkorlikda boshqaruvchi markaziy server mavjud bo‘lmagani sababli, keyingi mijozlar odatda

ISSN 3030-3907

faqat bevosita oldingi mijozlarning bilimlariga kira oladi (masalan, 1-rasm (a) dagi holat), barcha avvalgi mijozlarning bilimlarini to‘liq olish esa qiyinlashadi. Shu sababli, agregatsiyaga to‘liq mos kelmaydigan mavjud FL paradigmasini to‘ldiruvchi va kengaytiruvchi muqobil paradigmaga bo‘lgan ehtiyoj dolzarb hisoblanadi.

D. Paradigma takliflari

Ushbu bo‘limda markazlashtirilmagan federativ o‘rganish (Decentralized Federated Learning, DFL) uchun ikki asosiy paradigmadan iborat innovatsion tasnif taklif etiladi: Uzluksiz (Continual) va Agregatsiyalangan (Aggregate). Ushbu ikki paradigma o‘rtasidagi asosiy farqlar mijozlar o‘rtasida almashiniladigan model yangilanishlari soni hamda agregatsiya jarayonining mavjud yoki mavjud emasligi bilan belgilanadi. Paradigmalar o‘rtasidagi tafovutlar o‘rganish tezligi (learning rate) kabi boshqa sozlamalarda ham farqlarni keltirib chiqaradi.

Agregatsiyalangan paradigma an’anaviy federativ o‘rganish algoritmining tipik shaklini ifodalaydi. Bu yondashuvda har bir mijoz boshqa mijozlardan modellarni qabul qiladi, ularni agregatsiya qiladi va so‘ngra agregatsiyalangan model asosida lokal o‘rganishni amalga oshiradi. Aksincha, Uzluksiz paradigma doirasida har bir mijoz faqat bitta teng huquqli mijozdan (peer) modelni qabul qiladi va bevosita ushbu model asosida o‘rganishni davom ettiradi.

Uzluksiz o‘rganish (continual learning), ba’zan inkremental o‘rganish deb ham ataladi, mazkur uzluksiz paradigma uchun mustahkam va nazariy asoslangan poydevor taqdim etadi. So‘nggi adabiyotlarda federativ uzluksiz o‘rganish bo‘yicha bir qator tushunchalar va algoritmlar taklif etilgan bo‘lib, ular real dunyoda ma’lumotlarning dinamik ravishda yig‘ilishini hisobga olgan holda non-IID ma’lumotlar, kontseptual siljish (concept drift) va katastrofik unutish (catastrophic forgetting) kabi muammolarni hal etishga qaratilgan.

DFL sharoitida uzluksiz o‘rganishning roli yanada kengroq bo‘lib, u quyidagi afzalliklarni ta’minlaydi:

- Keyingi mijoz bevosita avvalgi mijozning modeli asosida o‘rganadi. Lokal o‘rganish va agregatsiyalangan paradigma bilan solishtirganda, bu yondashuv yanada shaxsiylashtirilgan modelni hosil qilish imkonini beradi hamda aloqa, hisoblash va saqlash resurslarini tejaydi.
- Saqlash resurslari cheklangan tizimlarda mijozlar qo‘shimcha model parametrlarini saqlashga majbur bo‘lmaydi.
- Hisoblash resurslari cheklangan sharoitlarda mijozlar agregatsiya hisob-kitoblari uchun qo‘shimcha hisoblash quvvatini sarflamaydi.

ISSN 3030-3907

• Mijozlar tomonidan yangi ma’lumotlarning uzluksiz hosil bo‘lishi tabiiy tarzda qo‘llab-quvvatlanadi va ular barcha ma’lumotlar yig‘ilishini kutmasdan lokal o‘rganishni boshlashi mumkin.

•Kontseptual siljish ehtimoli mavjud bo‘lgan vazifalarda mijozlar doimo modelning eng so‘nggi versiyasi bilan ta’minlanadi.

III-jadval ushbu ikki paradigmaning ichki xususiyatlari, algoritmik tuzilishi, afzalliklari, muammolari hamda tarmoq topologiyasini tahlil qiladi va umumlashtiradi. Ushbu ikki paradigma o‘rtasidagi farq ketma-ket yo‘naltirilgan chiziqli (sequential pointing line) DFL misolida yaqqol namoyon etiladi.

Uzluksiz (Continual) paradigmada keyingi mijozga uzatiladigan yagona axborot — bu o‘qitilgan modeldir. Keyingi mijoz mazkur model asosida o‘rganishni bevosita davom ettiradi; bu jarayon 2-jadval (a) da tasvirlangan.

Agregatsiyalangan (Aggregate) paradigmada esa oldingi mijoz nafaqat o‘qitilgan lokal modelni, balki barcha avvalgi modellarni ham keyingi mijozga uzatadi. Natijada, keyingi mijoz tomonidan bajariladigan o‘rganish jarayoni ikki bosqichga ajratiladi: avvalo agregatsiya, so‘ngra o‘rganish amalga oshiriladi. Ushbu jarayon 2-jadval (b) da ko‘rsatilgan.

Uzluksiz (Continual) va Agregatsiyalangan (Aggregate) paradigmalar o‘rtasidagi farqlarni, shuningdek yo‘naltirilgan (pointing), gossip va broadcast protokollari hamda turli tarmoq topologiyalarini qiyosiy tahlil qilish va yaqqol tasvirlash maqsadida 1-algoritm va 2-algoritm keltirilgan. 1-algoritm ketma-ket yo‘naltirilgan chiziqli (sequential pointing line) DFL topologiyasida ikki paradigmani namoyish etsa, 2-algoritm yo‘naltirilgan halqa (pointing ring) Uzluksiz paradigmasi hamda broadcast mesh Agregatsiyalangan DFLni ko‘rsatadi.

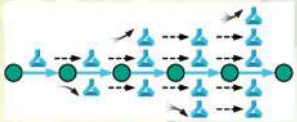
2-jadval

Paradigma	**Uzluksiz (Continual)**	**Agregatsiyalangan (Aggregate)**
Ichki xususiyatlar (Intrinsic)	Mijoz har bir iteratsiyada bitta modelni qabul qiladi. O‘rganish agregatsiyasiz, bevosita qabul qilingan model asosida amalga oshiriladi.	Mijoz har bir iteratsiyada bir nechta modelni qabul qiladi. O‘rganish avval agregatsiya, so‘ng lokal o‘rganish orqali bajariladi.
Algoritm	Har bir mijoz konvergensiyaga erishguncha: 1) Oldingi mijozdan modelni qabul qiladi. 2) Model asosida	Har bir mijoz konvergensiyaga erishguncha: 1) Oldingi mijozdan (pointing, gossip) yoki boshqa mijozlardan (broadcast,

ISSN 3030-3907

	lokal o‘rganishni bajaradi. 3) O‘qitilgan modelni keyingi mijozga uzatadi.	broadcast–gossip) modellarni qabul qiladi. 2) Qabul qilingan modellarni agregatsiya qilib, agregatsiyalangan model asosida lokal o‘rganishni bajaradi. 3) O‘qitilgan modelni (va boshqa modellarni) keyingi mijozga uzatadi (pointing, gossip) yoki barcha mijozlarga tarqatadi (broadcast, broadcast–gossip).
Afzalliklar (Advantage)	Har bir mijoz uchun yuqori aniqlikdagi, shaxsiylashtirilgan va ishonchli lokal model hosil bo‘ladi. • CFL bilan solishtirganda, serverga xos muammolar (masalan, agregatsiya adolatliligi) mavjud emas. Aloqa, hisoblash va saqlash resurslariga bo‘lgan talab kam. • Tuzilishi sodda va deyarli barcha ssenariylar uchun mos.	• Olingan modelning umumlashtirish (generalization) qobiliyati kuchliroq. • Mijozlar tomonidan hosil qilinayotgan yangi bilimlarni tez va samarali integratsiya qilish imkoniyati yuqori.
Muammolar (Challenge)	• Model samaradorligi mijozlar iteratsiya tartibiga kuchli bog‘liq. • Joriy mijoz bilimlarini o‘rganish bilan birga, oldingi bilimlarni unutmaslikni ta’minlaydigan mos yo‘qotish funksiyasi, o‘rganish tezligi va epoch tanlash talab etiladi.	• Oldingi mijozlardan o‘rganishga ortiqcha takrorlanish va haddan tashqari urg‘u berilishi mumkin.

ISSN 3030-3907

	• Katastrofik unutish xavfi mavjud.	
Tarmoq topologiyasi *(ketma-ket yo‘naltirilgan chiziqli DFL misolida)*	 (a) Uzluksiz paradigma	 (b) Agregatsiyalangan paradigma

Uzluksiz va Agregatsiyalangan paradigmalar o‘rtasidagi farq mijoz tomonidan o‘rganishdan oldingi tayyorgarlik (pre-processing) bosqichida hamda o‘rganishdan keyin modelni ulashish jarayonida aniq ko‘zga tashlanadi. Agregatsiyalangan paradigma uchun aloqa, hisoblash va saqlash resurslariga qo‘shimcha talablar mavjudligi alohida ta’kidlangan. Ushbu paradigma sharoitida yo‘naltirilgan va gossip protokollari mijozdan bir vaqtning o‘zida ko‘proq model ma’lumotlarini uzatishni talab qilsa, broadcast va broadcast–gossip protokollari mijozdan modelni yuqori chastotada uzatishni talab etadi.

Halqa (ring) topologiyasi chiziqli (line) topologiyaning tsiklik varianti sifatida qaralishi mumkin bo‘lib, ushbu ikki topologiya ham sodda va tushunarli tuzilishga ega ekanligi sababli tadqiqotchilar tomonidan keng qo‘llaniladi. Chiziqli topologiya yangi bilimlar hosil qilinmaydigan tizimlar uchun yetarli bilim o‘rganish mexanizmini ta’minlaydi. Biroq doimiy ravishda yangi bilimlar yaratiladigan tizimlarda halqa topologiyasi yanada maqbul yechim hisoblanadi. U nafaqat tizimdagi bilimlarni qayta yangilash imkonini beradi, balki katastrofik unutish muammosini bartaraf etish uchun ham samarali va amaliy yechim sifatida xizmat qiladi.

Ushbu ikki paradigma doirasida mijozlar o‘rtasidagi o‘rganish va kommunikatsiya jarayonlarini yanada yaqqolroq ko‘rsatish maqsadida, 1-rasm parametrlar fazosida birinchi mijozdan boshlab yakuniy mijozgacha bo‘lgan o‘rganish jarayonini tasvirlaydi[10]. Shuni alohida ta’kidlash lozimki, bu yerda bir nechta muhim farazlar (assumptions) qabul qilingan. Birinchidan, barcha mijozlarning lokal modellari uchun optimal yechimlar parametrlar fazosida ko‘p o‘lchovli normal taqsimot (multivariate normal distribution)ga bo‘ysunadi, deb hisoblanadi. Ikkinchidan, tizimli va statistik geterogenlikni inobatga olgan holda, ayrim mijozlar sezilarli darajada og‘ishlar (bias) namoyon etishi mumkin. Uchinchidan, mos yo‘qotish funksiyalari va o‘rganish tezliklari tanlangan bo‘lsa-da, modellar har doim ham optimal yechimlarga to‘liq konvergensiya qilmaydi. Shu asosda, Uzluksiz (Continual) va Agregatsiyalangan (Aggregate) paradigmalar doirasidagi kommunikatsiya va o‘rganish jarayonlari quyidagicha tavsiflanadi. 1-

ISSN 3030-3907

bosqich) Har ikkala paradigma o‘rganishni bir xil boshlang‘ich model parametrlari bilan boshlaydi va 1-mijozda bir xil 1-model hosil qiladi. 2-bosqich) Har ikkala paradigma 1-model asosida o‘rganishni davom ettirib, 2-mijozda bir xil 2-modelga erishadi. Shuni ta’kidlash joizki, Agregatsiyalangan (Aggregate) paradigma kamida ikki yoki undan ortiq agregatsiya qilinadigan model mavjud bo‘lgandagina mazmunli hisoblanadi. 3-bosqich Uzluksiz (Continual) paradigmada 3-mijoz bevosita 2-modeldan o‘rganib, 3-modelni hosil qiladi. Agregatsiyalangan paradigmada esa avval 1-model va 2-model agregatsiya qilinadi, so‘ngra 3-mijoz agregatsiyalangan model asosida o‘rganib, 3-modelni oladi. Shuni qayd etish kerakki, Uzluksiz paradigma Agregatsiyalangan paradigmaga nisbatan kamroq murakkab bo‘lib, bu holat rasmda qora strelkaning uzunligi bilan ifodalangan.

Algoritm 1:

Ketma-ket *pointing line Continual* va *pointing line Aggregate* markazlashmagan federativ o‘rganish.

Kirish: Mijozlar to‘plami (C), o‘qitish davri (E), boshlang‘ich model (ω0), yo‘qotish funksiyasi (L), o‘rganish tezligi (η)

Chiqish: Lokal modellar {ωc | c ∈ C}

for c ∈ C in sequence do

Avvalgi mijozdan model nusxalanadi

ωc ← ωc−1

Qabul qilingan modellar agregatsiya qilinadi

ωc ← Aggregation{ω1, ω2, …, ωc−1}

for e = 1 to E−1 do

Lokal model orqaga tarqatish orqali yangilanadi

ωc^{e+1} ← ωc^{e} − η ∇L

end for

Lokal model yakuniy holatga o‘tkaziladi

ωc ← ωc^{E}

Mijoz c modellarni keyingi mijozga yuboradi

end for

(4-bosqich) Agregatsiyalangan paradigmada 4-mijoz tomonidan hosil qilingan agregatsiyalangan model 3-mijoz modeliga nisbatan normal taqsimot markaziga yanada yaqin joylashadi. Shu sababli, keyingi mijozlar uchun o‘rganish jarayoni nisbatan osonroq bo‘lishi kutiladi.

(n-bosqich) Mijoz navbatning oxiriga yaqinlashgan sari, Uzluksiz paradigmada o‘rganish murakkabligi tasodifiy xususiyat kasb etadi va bu

ISSN 3030-3907

murakkablik oldingi mijoz bilan joriy mijoz o‘rtasidagi og‘ish (deviation) darajasiga bog‘liq bo‘ladi.

Biroq Agregatsiyalangan paradigmada o‘rganish murakkabligi asosan faqat joriy mijozning xususiyatlari bilan belgilanadi, chunki agregatsiyalangan model normal taqsimot markaziga juda yaqin bo‘lishi kutiladi. Yuqorida bayon etilgan farazlar va iterativ jarayonga asoslanib, o‘qitish davomida har ikkala paradigma doirasida mijozlarning aniqligi, yo‘qotish funksiyasi qiymati, konvergensiya xatti-harakati hamda kommunikatsiya murakkabligi bo‘yicha muayyan kutilmalarni shakllantirish mumkin. Shu asosda quyidagi taxminlar ilgari suriladi:

1) Har ikkala paradigmada ham o‘rganish jarayonida yo‘qotish funksiyasi qiymati mijozlar iteratsiyalari bo‘ylab davriy tebranishlarni namoyon etadi va oxir-oqibat konvergensiyaga erishadi.

2) Agregatsiyalangan (Aggregate) paradigmada yo‘qotish funksiyasining konvergensiyasi yanada barqaror bo‘lishi kutiladi. Uzluksiz (Continual) paradigmada esa o‘rganish murakkabligi oldingi mijoz va joriy mijozning lokal ma’lumotlari o‘rtasidagi farq (discrepancy)ga, ya’ni mijozlarning iteratsiya tartibiga bog‘liq bo‘ladi. Normal taqsimot farazi ostida, Agregatsiyalangan paradigmada o‘rganish murakkabligi asosan joriy mijoz ma’lumotlarining geterogenligi bilan belgilanadi; bunda aksariyat mijozlar o‘xshash ma’lumotlar taqsimotiga ega bo‘lishi mumkin.

3) Mijozlar iteratsiyalari davom etgan sari o‘rganish murakkabligining kamayib borishi sababli, Agregatsiyalangan paradigmada yo‘qotish funksiyasining tezroq konvergensiyaga erishishi ham kutiladi. Biroq, ushbu konvergensiya tezlashuvi kommunikatsiya yuklamasining ortishi bilan birga kechadi.

Algoritm 2:

Cycle *pointing ring Continual* va broadcast mesh *Aggregate* markazlashmagan federativ o‘rganish.

Kirish: Mijozlar to‘plami (C), o‘qitish davri (E), boshlang‘ich model (ω0), yo‘qotish funksiyasi (L), o‘rganish tezligi (η)

Chiqish: Lokal modellar {ωc | c ∈ C}

while c ∈ C in cyclic do

Avvalgi mijozdan modelni nusxalash: ωc ← ωc−1

Qabul qilingan modellarni agregatsiya qilish: ωc ← Aggregation{ω1, ω2, …, ωc−1}

for e = 1 to E−1 do

Orqaga tarqatish orqali lokal modelni yangilash: ωc^{e+1} ← ωc^{e} − η ∇L

end for

ISSN 3030-3907

Lokal modelni yakuniy holatda yangilash: ωc ← ωc^{E}

Mijoz c ωc ni keyingi mijozga va barcha boshqa mijozlarga yuboradi.

end while

E. Vaqt bo‘yicha o‘zgaruvchanlik (Temporal Variability)

So‘nggi yillarda markazlashtirilmagan federativ o‘rganish (Decentralized Federated Learning, DFL) tarmoqlarining topologiyasi statik holatdan dinamik holatga o‘tish tendensiyasini namoyon etmoqda, bu esa vaqt bo‘yicha o‘zgarib turuvchi tashqi muhitga moslashishni ta’minlaydi [9]. Tarmoq topologiyalarini ajratish va klasterlash g‘oyasi tabiatda kuzatiladigan guruh xatti-harakatlaridan, masalan, baliqlar to‘dasi va asalari uyurmalari kabi hodisalardan ilhomlangan [7].

Masalan, baliqlar to‘dasi yirtqichga duch kelganda, butun to‘da xavfdan qochish uchun vaqtincha ajraladi. Xuddi shuningdek, asalarilar uyurmasida kam sonli razvedkachi asalarilar butun uyurmani boshqarishi mumkin, bu esa to‘da effekti (herd effect)ni namoyon etadi. Qiziqarli jihati shundaki, ko‘chib yuruvchi qushlar uzoq masofalarga parvoz qilganda energiyani tejash maqsadida V-shaklli saf hosil qiladi va oldingi qatordagi qushlar vaqt o‘tishi bilan almashib turadi, bu esa parvoz charchog‘ini teng taqsimlashga xizmat qiladi.

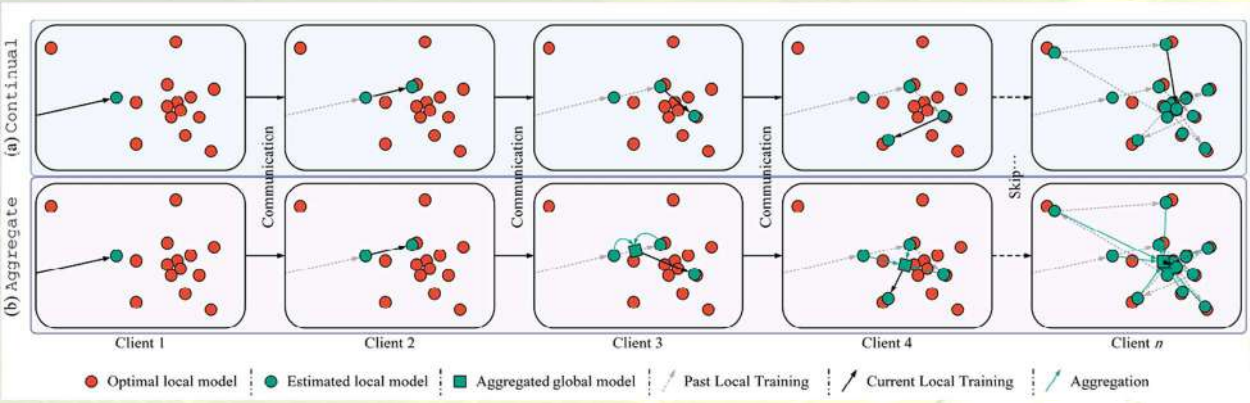
DFL tarmoqlari kontekstida dinamik topologiyalar statik topologiyalarga nisbatan yanada barqaror, adolatlilikni ta’minlovchi va samaraliroq ishlash xususiyatlariga ega bo‘lishi mumkin. DFL tarmoqlarida dinamik topologiyalarni aniqlash va shakllantirishga bir qator omillar ta’sir ko‘rsatadi, jumladan:

Tashqi aralashuvlar. Kuchli va yengib bo‘lmaydigan kommunikatsiya to‘siqlari, yagona nosozlik nuqtasi (SPoF), zararli hujumlar va boshqa tashqi omillar tarmoq topologiyasining o‘zgarishiga olib kelishi mumkin. Butun tarmoqning ishdan chiqishining oldini olish maqsadida topologiyani moslashtirish yoki ayrim ulanishlarni bekor qilish amalga oshiriladi.

Aloqa resurslarini tejash. Mijozlar har bir aloqa raundida o‘zlariga mos qo‘shni mijozlarni dinamik tarzda tanlash imkoniyatiga ega. Geografik yoki tarmoq jihatidan yaqin bo‘lgan mijozlarni tanlash orqali aloqa resurslaridan yanada samarali foydalanish va ularni tejash mumkin. Bundan tashqari, mijozlar har bir aloqa jarayonida eng markaziy tugunni yetakchi (leader) sifatida dinamik ravishda saylashi mumkin, bu esa tarmoq ichidagi kommunikatsiyaning samaradorligi va natijadorligini oshiradi.

Adolatlilik (Fairness).Mijozlar o‘rtasida adolatlilikni ta’minlash maqsadida, aloqa qilinadigan nishon mijozni aniqlashda tasodifiy tanlash mexanizmi qo‘llaniladi. Ushbu yondashuv muayyan mijozlarga nisbatan har qanday og‘ish yoki ustunlik berilishining oldini oladi hamda barcha ishtirokchilar uchun teng imkoniyatlarni kafolatlaydi.

ISSN 3030-3907



2-rasm. DFLda uzluksiz va agregatsiyalangan paradigmalar

Mazkur omillar asosida shakllantiriladigan dinamik topologik tuzilmalar DFL tarmoqlarini mijozlar o‘rtasida barqaror, samarali va adolatlilikka asoslangan kommunikatsiyani ta’minlashga yo‘naltiradi.

XULOSA

Ushbu maqolada markazlashtirilmagan federativ o‘rganish (Decentralized Federated Learning, DFL) freymvorki keng qamrovli tarzda tahlil qilindi. Xususan, kommunikatsiya protokollari, tarmoq topologiyalari, paradigma takliflari, kengaytirilgan variantlar, asosiy muammolar hamda ehtimoliy yechimlar batafsil muhokama etildi. Mazkur ishning asosiy maqsadi — mavjud adabiyotlar va ta’riflarni tizimlashtirgan holda, aniq belgilangan, izchil va kompleks ilmiy nuqtayi nazarni taqdim etish hamda DFL bilan endigina shug‘ullana boshlagan tadqiqotchilar uchun puxta kirish manbai yaratishdan iborat. DFL jadal rivojlanayotgan tadqiqot sohasi ekanligini inobatga olib, ushbu maqolada besh xil variantni aniqlash va muhokama qilish orqali mustahkam nazariy asos shakllantirildi. Bu nafaqat tadqiqotchilarga ushbu sohani chuqurroq tushunishga yordam beradi, balki yangi g‘oyalar va ilmiy hamkorliklarning yuzaga kelishini ham rag‘batlantiradi. Shuni ta’kidlash joizki, ushbu ish an’anaviy so‘rov (survey) maqolalardan farq qiladi, chunki unda DFL bo‘yicha mualliflarning shaxsiy qarashlari, tahlillari va innovatsion fikrlari ilgari surilgan. Bundan tashqari, maqolada DFL freymvorki doirasida ilgari deyarli o‘rganilmagan bir qator yangi turlar aniqlangan. Masalan, hozirgi kunga qadar mavjud tadqiqotlarda Uzluksiz (Continual) paradigma bilan to‘r (mesh) tarmoq topologiyasini birlashtirgan yondashuv namoyish etilmagan. Kelgusida tadqiqotchilar asinxron DFL yondashuvlarini ko‘rib chiqishi mumkin, bunda mijozlar ma’lumotlarni turli vaqtlarda yig‘ib, o‘rganishni ham turli vaqtlarda amalga oshiradi. Bu esa Uzluksiz paradigmaning va mesh topologiyaning ikki tomonlama afzalliklaridan, jumladan aloqa yuklamasining kamayishi, shaxsiylashtirish va boshqa imkoniyatlardan samarali foydalanish imkonini beradi.

ISSN 3030-3907

Turli foydalanish ssenariylarini hisobga olgan holda, ushbu ish boshqa DFL tadqiqotchilarining ilmiy qiziqishini rag‘batlantirish va kengaytirishni, shuningdek, freymvorkni o‘ziga xos ehtiyojlar va amaliy sharoitlarga moslashtirishga undashni maqsad qiladi.

FOYDALANILGAN ADABIYOTLAR RO‘YXATI

1. Y. Li, J. Luo, Y. Zhang, Y. Tan, J.-G. Yu, and S. Bai, “Learning to holistically detect bridges from large-size vhr remote sensing imagery,”IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024.
2. G. A. Kaissis, M. R. Makowski, D. R¨uckert, and R. F. Braren, “Secure, privacy-preserving and federated machine learning in medical imaging,” Nat. Mach. Intell., vol. 2, no. 6, pp. 305–311, Jun. 2020.
3. A. Durrant, M. Markovic, D. Matthews, D. May, J. Enright, and G. Leontidis, “The role of cross-silo federated learning in facilitating data sharing in the agri-food sector,” Comput. Electron. Agric., vol.193, p. 106648, Feb. 2022.
4. Y. M. Saputra, D. T. Hoang, D. N. Nguyen, E. Dutkiewicz, M. D.Mueck, and S. Srikanteswara, “Energy demand prediction with federated learning for electric vehicle networks,” in 2019 IEEE GlobalCommunications Conference (GLOBECOM). IEEE, 2019, pp. 1–6.
5. L. Yuan, D.-J. Han, V. P. Chellapandi, S. H. ˙ Zak, and C. G. Brinton, “FedMFS: Federated multimodal fusion learning with selective modality communication,” arXiv preprint arXiv:2310.07048, 2023.
6. D. Shi, L. Li, R. Chen, P. Prakash, M. Pan, and Y. Fang, “Towardenergy-efficient federated learning over 5g+ mobile devices,” IEEE Wireless Communications, vol. 29, no. 5, pp. 44–51, 2022.
7. B. Pfitzner, N. Steckhan, and B. Arnrich, “Federated learning in a medical context: a systematic literature review,” ACM Transactions on Internet Technology (TOIT), vol. 21, no. 2, pp. 1–31, 2021.
8. D. C. Nguyen, Q.-V. Pham, P. N. Pathirana, M. Ding, A. Seneviratne, Z. Lin, O. Dobre, and W.-J. Hwang, “Federated learning for smarthealthcare: A survey,” ACM Comput. Surv. (CSUR), vol. 55, no. 3, pp.1–37, 2022.
9. J. Li, Y. Meng, L. Ma, S. Du, H. Zhu, Q. Pei, and X. Shen, “A federated learning based privacy-preserving smart healthcare system,” IEEE Transactions on Industrial Informatics, vol. 18, no. 3, 2021.
10. J. C. Jiang, B. Kantarci, S. Oktug, and T. Soyata, “Federated learning in smart city sensing: Challenges and opportunities,” Sensors, vol. 20, no. 21, p. 6230, 2020.

ISSN 3030-3907