

AZƏRBAYCAN RESPUBLİKASI

Əlyazması hüququnda

**FEDERATİV ÖYRƏNMƏDƏ MODEL
PARAMETRLƏRİNİN BİRLƏŞDİRİLMƏSİ ÜÇÜN
ALTERNATİV ÜSULLAR**

İxtisas: 3338.01 - Sistemli analiz, idarəetmə və informasiyanın
işlənməsi (idarəetmə və qərar qəbuletmə)

Elm sahəsi: Texnika elmləri

İddiaçı: **Samir İlqar oğlu Əliyev**

Fəlsəfə doktoru elmi dərəcəsi
almaq üçün təqdim edilmiş dissertasiyanın

AVTOREFERATI

Bakı-2026

Dissertasiya işi Azərbaycan Dövlət Neft və Sənaye Universitetinin “Ümumi və tətbiqi riyaziyyat” kafedrasında yerinə yetirilmişdir.

Elmi rəhbər:

Əməkdar elm xadimi, riyaziyyat üzrə
elmlər doktoru, professor
Araz Rafiq oğlu Əliyev

Texnika üzrə fəlsəfə doktoru, dosent
Nigar Tahir qızı İsmayılova

Rəsmi opponentlər:

Texnika elmləri doktoru, professor
Fazil Həzin oğlu Ələkbərli

Texnika elmləri doktoru, dosent
Yadigar Nəsim oğlu İmamverdiyev

Texnika üzrə fəlsəfə doktoru, dosent
Sevinc Həmzəğa qızı Əliyeva

Azərbaycan Respublikasının Prezidenti yanında Ali Attestasiya Komissiyasının Azərbaycan Dövlət Neft və Sənaye Universitetinin nəzdində fəaliyyət göstərən FD 2.48 Dissertasiya Şurası

Dissertasiya şurasının sədri:

AMEA-nın müxbir üzvü,
texnika elmləri doktoru, professor
Rafiq Əziz oğlu Əliyev

Dissertasiya şurasının
elmi katibi:

Texnika üzrə elmlər doktoru, dosent
Akif Vəli oğlu Əlizadə

Elmi seminarın sədri:

Texnika üzrə elmlər doktoru, professor
Kəmalə Rafiq qızı Əliyeva

**“AZƏRBAYCAN RESPUBLİKASI
ELM VƏ TƏHSİL NAZİRLİYİ
AZƏRBAYCAN DÖVLƏT NEFT
VƏ SƏNAYE UNİVERSİTETİ”
PUBLİK HÜQUQİ ŞƏXSİ
ELMİ -KATİB**



İŞİN ÜMUMİ XARAKTERİSTİKASI

Mövzunun aktuallığı və işlənmə dərəcəsi.

Maşın öyrənməsi (Machine Learning) müasir dövrün ən sürətlə inkişaf edən sahələrindən biridir və geniş tətbiq sahələri ilə elmi tədqiqatlardan biznesə, səhiyyədən mühəndisliyə qədər bir çox sektorda mühüm rol oynayır. Artan məlumat həcmi və hesablama gücünün inkişafı sayəsində maşın öyrənməsi ənənəvi üsullarla həll edilməsi çətin olan problemləri daha effektiv şəkildə həll etməyə imkan yaradır. Bu sahə, verilənlər üzərində analiz apararaq nümunələri öyrənir və bu nümunələr əsasında qərarlar qəbul edə bilər.

Maşın öyrənməsinin aktuallığı onun avtomatlaşdırılmış qərarvermə proseslərində geniş istifadə olunması ilə bağlıdır. Xüsusilə böyük verilənlərdən (Big Data) lazım olan informasiyanı çıxarmaq, mürəkkəb sistemlərdə proqnozlar vermək və insan müdaxiləsini minimuma endirmək üçün bu texnologiyadan geniş şəkildə istifadə olunur. Bank sektorunda şübhəli əməliyyatların aşkarlanması, tibdə xəstəliklərin erkən diaqnostikası, sənayedə avadanlıqların işini optimallaşdırılması və fərdiləşdirilmiş tövsiyə sistemlərinin yaradılması kimi sahələrdə maşın öyrənməsinin təsiri açıq şəkildə görünür.

Süni intellektin əsas istiqamətlərindən biri kimi maşın öyrənməsi təkcə mövcud texnologiyaları təkmilləşdirmir, eyni zamanda yeni innovasiyaların yaranmasına da təkan verir. Alqoritmlərin daha dəqiq və sürətli işləməsi, verilənlərə əsaslanaraq daha effektiv qərarların qəbul edilməsi və kompleks sistemlərin idarə olunması baxımından maşın öyrənməsi müasir dövrdə əvəzolunmaz bir vasitəyə çevrilib. Onun inkişafı ilə birlikdə müxtəlif sahələrdə məhsuldarlıq artır, insan resurslarına olan tələbat optimallaşdırılır və daha ağıllı sistemlər qurulur.

Federativ öyrənmə (Federated Learning) maşın öyrənmənin inkişafı ilə paralel olaraq ortaya çıxan mühüm yanaşmalardan biridir və onun aktuallığı əsasən məxfilik, məlumat təhlükəsizliyi və hesablama resurslarının optimallaşdırılması kimi amillərlə bağlıdır. Ənənəvi maşın öyrənməsi modelləri böyük həcmdə məlumatları

mərkəzləşdirilmiş serverlərə köçürərək onları emal edir. Lakin bu yanaşma bir çox praktiki problemlərlə üzləşir. Xüsusilə fərdi və həssas məlumatların birbaşa serverlərə göndərilməsi məxfi informasiyanın aşkarlanmasını asanlaşdırır. Bununla yanaşı, böyük verilənlərin ötürülməsi şəbəkə yüklənməsinə və əlavə hesablama xərclərinə gətirib çıxarır.

Federativ öyrənmə isə bu problemləri həll etmək üçün təklif olunmuş bir yanaşmadır. Burada model öyrənməsini mərkəzləşdirilmiş şəkildə deyil, birbaşa istifadəçilərin cihazlarında və ya lokal serverlərdə aparılır. Bunun sayəsində məlumatlar cihazdan kənara çıxmadan, istifadəçi məxfiliyini qoruyaraq modelin öyrədilməsi mümkündür. Bu yanaşma səhiyyə, bankçılıq, ağıllı cihazlar və digər sahələrdə geniş tətbiq olunur. Məsələn, xəstəxanalar arası pasiyent məlumatlarının paylaşılmadan analiz edilməsi və ya mobil cihazlarda istifadəçi məlumatları üzərində fərdi modellərin optimallaşdırılması federativ öyrənmənin praktik istifadəsinə aid nümunələrdəndir.

Tədqiqatın obyektı və predmeti. Tədqiqatın obyektı məlumatların gizliliyinin qorunması məqsədilə paylanmış mühitlərdə həyata keçirilən federativ öyrənmə yanaşmalarında klientlər arasında modellərin koordinasiyalı şəkildə öyrədilməsi və aqreqasiya mexanizmləridir. Tədqiqatın predmeti isə federativ öyrənmə prosesində etibarlı öyrənmənin təmin edilməsi üçün klientlərin seçilməsi üçün təklif və tətbiq edilən metodların, o cümlədən qeyri-səlis nəticə çıxarma sistemləri (Fuzzy İnference System- FİS), analitik hierarxiya prosesi (Analytical Hierarchy Process- AHP) , genetik alqoritm və koordinat oxu üzrə enmə üsulunun modellərin öyrənmə keyfiyyətinə, konvergenziyasına və ümumiləşdirmə qabiliyyətinə təsirləridir.

Tədqiqatın məqsədi və vəzifələri. Dissertasiya işinin məqsədi federativ öyrənmə mühitində aqreqatlaşdırma metodlarının təkmilləşdirilməsi, fərqli çəki vermə yanaşmalarının tətbiqi və qeyri-səlis modelləşdirmə üsulları ilə adaptiv çəkiləndirmə mexanizmlərinin işlənməsi, təklif olunmuş üsulların üstünlüklərinin göstərilməsi üçün federativ öyrənmədə mövcud aqreqatlaşdırma metodlarının

məhdudiyətlərinin araşdırılması və daha effektiv, fərdiləşdirilmiş çəki strategiyalarına əsaslanan yeni üsulların müxtəlif verilənlər bazasında tətbiqindən ibarətdir.

Qoyulan məqsədə nail olmaq üçün dissertasiya işində aşağıdakı məsələlərin həlli müəyyən edilmişdir:

- Mövcud federativ öyrənmə alqoritmlərində aqreqatlaşdırma üsullarının təhlili və onların məhdudiyətlərinin müəyyən edilməsi.
- Fərqli müştərilərin məlumat müxtəlifliyini və hesablama gücünü nəzərə alan yeni çəki vermə metodlarının işlənməsi.
- Nyuton üsulunun (Newton Direction) federativ öyrənmədə tətbiqi və federativ öyrənmədə stoxastik qradiyent üsulunun tətbiqi (FedSGD) ilə müqayisəli təhlili.
- Federativ Fərdiləşdirmə (FedPER) alqoritmində fərqli çəki strategiyalarının təsirinin qiymətləndirilməsi.
- Qeyri-səlis məntiqə əsaslanan çəki təyin etmə mexanizmlərinin modelləşdirilməsi və tətbiqi.
- Genetik alqoritmlər vasitəsilə qeyri-səlis məntiq sistemində qaydaların avtomatik seçilməsi üsulunun işlənilməsi və hazırlanması. Təklif olunan metodların müxtəlif federativ öyrənmə ssenarilərində sınaqdan keçirilməsi və onların effektivliyinin eksperimental şəkildə qiymətləndirilməsi.

Tədqiqat üsulları. İşdə qarşıya qoyulan məqsədə nail olmaq üçün qeyri-səlis nəticə çıxarma sistemləri, qərar qəbuletmə nəzəriyyəsi, genetik alqoritmlər, optimallaşdırma üsulları və maşın öyrənməsi texnikalarından istifadə edilmişdir. Bu yanaşmalar federativ öyrənmədə çəki vermə mexanizmlərinin təkmilləşdirilməsi, fərqli müştərilərin xüsusiyyətlərini nəzərə alan adaptiv metodların işlənməsi və aqreqatlaşdırma prosesinin daha effektiv idarə olunmasına imkan yaratmışdır.

Müdafiəyə çıxarılan əsas müddəalar.

Müdafiəyə çıxarılan əsas müddəalar aşağıdakılardır

- Qeyri-səlis nəticə çıxarma sistemləri, analitik hierarxiya prosesi və genetik alqoritmlərin federativ öyrənmədə tətbiq imkanları araşdırılmış, xüsusilə çəki vermə mexanizmlərinin

optimallaşdırılmasında və müştərilərin fərdi xüsusiyyətlərini nəzərə alan fərdiləşdirilmiş yanaşmaların işlənməsində onların rolunun təhlil edilmişdir;

- Federativ öyrənmədə ədədi orta ilə aqreqatlaşdırma (FedAVG) alqoritminə fərqli çəki vermə üsullarının təsiri analiz edilmişdir;
- FedPER alqoritmində müxtəlif çəki vermə yanaşmalarının effektivliyinin qiymətləndirilməsi;
- Federativ öyrənmədə Nyuton üsulu (FedND) tətbiq olunmuş, FedSGD alqoritmləri ilə müqayisədə daha etibarlı öyrənmə imkanı eksperimentlərlə əsaslandırılmışdır;
- Paylanmış öyrənmə üçün təklif olunan müxtəlif çəkiləndirmə yanaşmalarının federativ maşın öyrənmə alqoritmlərinin performansına təsiri araşdırılmışdır;
- Qeyri-səlis nəticə çıxarma sistemlərində ekspertsiz mühitlərdə qaydaların avtomatik seçilməsi üçün genetik alqoritmlər tətbiq edilmişdir.

Elmi yeniliklər. Tədqiqatın elmi yeniliyi aşağıdakı əsas tapıntılarda özünü göstərir:

- ✓ FİS, AHP, Kordinat oxu üzrə enmə və genetik alqoritmlər kimi çəkiləndirmə yanaşmalarının FedAVG alqoritmində tətbiqi;
- ✓ Federativ Nyuton istiqaməti üsulu ilə serverə qradiyent və hesse matrisini göndərmədən kiber hücumlara qarşı dayanıqlı yanaşma;
- ✓ Genetik alqoritmlər tətbiq edərək, FİS-dəki qaydaların ekspertsiz mühitdə avtomatik seçilməsi.

İşin nəzəri və praktiki əhəmiyyəti və nəticələrin tətbiqi. Modifikasiyalı FİS və AHP kimi çəkiləndirmə yanaşmalarının tətbiqi və təklif edilən alqoritmlər federativ öyrənmə sistemlərinin qeyri-müəyyənlik şəraitində daha yaxşı performans göstərməsini təmin etmək üçün istifadə oluna bilər. Bu yanaşmalar, müxtəlif müştərilər arasında məlumat paylanması və şəbəkə şəraitində qarşılaşılan

problemləri effektiv şəkildə həll etməyə imkan verir. Təklif edilən metodlar həmçinin, federativ öyrənmə sistemlərində müştəri ehtiyaclarına uyğun adaptiv yanaşmaların inkişaf etdirilməsinə xidmət edir, bu da müxtəlif texniki sistemlərin daha çevik və dayanıqlı işləməsinə şərait yaradır.

İşin aprobasiyası.

Elmi tədqiqatların nəticələri Beynəlxalq və Respublika səviyyəli konfrans və simpoziumlarda məruzə edilmiş və müzakirə olunmuşdur:

- Sənaye Tətbiqli İdarəetmə və Optimallaşdırma mövzusunda VIII beynəlxalq elmi konfransda (COIA 2022) (24-26 Avqust 2022, Bakı, Azərbaycan)
- Ümummilli lider Heydər Əliyevin anadan olmasının 100 illik yubileyinə həsr olunmuş gənc tədqiqatçı və doktorantların Respublika Elmi Konfransını (4-5 May 2023, Bakı, Azərbaycan)
- İnformasiya və kommunikasiya texnologiyalarının tətbiqi üzrə 17-ci IEEE beynəlxalq konfransı” (AICT 2023) (18-20 oktyabr, 2023, Bakı, Azərbaycan)
- Ümummilli lider Heydər Əliyevin anadan olmasının 101 illiyinə həsr olunmuş gənc tədqiqatçı və doktorantların Respublika Elmi Konfransını (4-5 May, 2024, Bakı, Azərbaycan)
- Biliyə əsaslanan və intellektual informasiya və mühəndislik sistemləri üzrə 28-ci Beynəlxalq Konfrans (KES-2024)(11-13 Sentyabr 2024, Sevilya, İspaniya)
- Süni İntellekt:Nəzəriyyədən Praktikaya beynəlxalq konfrans (19-20 Sentyabr 2024, Naxçıvan, Azərbaycan)
- İCDSM 2024 (13-14 dekabr 2024, Odişa,Hindistan)
- 6-cı beynəlxalq Boğaziçi elmi araşdırma seminarı (18-19 yanvar 2025, Boğaziçi, Türkiyə)
- Mühəndis problemlərinin həllində idarəetmə və nəzarət məsələsində beynəlxalq konfrans (MaCoSEP2025), (13-14 Mart 2025, Bakı, Azərbaycan).

Elmi nəşrlər. Dissertasiya mövzusu üzrə 9 elmi iş: 5 məqalə, 4 konfrans materialı çap edilmişdir. Bu elmi işlərdən 2-i Scopus bazalarında indekslənen jurnallarda dərc olunmuşdur.

Dissertasiya işinin yerinə yetirildiyi təşkilatın adı. Dissertasiya işi Azərbaycan Dövlət Neft və Sənaye Universitetinin “Ümumi və Tətbiqi riyaziyyat” kafedrasında yerinə yetirilmişdir.

Dissertasiyanın həcmi və strukturu. Dissertasiya giriş, üç fəsil, nəticə və istifadə edilmiş ədəbiyyat siyahısından ibarətdir. İşin əsas məzmunu 128 səhifə, 12 şəkil və 8 cədvəldən ibarətdir. Ədəbiyyat siyahısında 111 adda mənbə göstərilmişdir. Dissertasiya işinin ümumi və struktur bölmələrinin işarə ilə həcmi aşağıdakı qaydada paylanmışdır: Ümumi–174885 işarə, Giriş–18531 işarə, Birinci fəsil–49867 işarə, İkinci fəsil–54913 işarə, Üçüncü fəsil–49515 işarə, Nəticə – 2059 işarə.

İŞİN MƏZMUNU

Girişdə mövzusunun və aparılan tədqiqatların aktuallığı əsaslandırılmış, tədqiqatların məqsədi və istiqamətləri müəyyənləşdirilmiş, tədqiqat obyektı və predmeti, tədqiqat üsulları, müdafiəyə çıxarılan əsas müddəalar, tədqiqat nəticəsində əldə olunan elmi yeniliklər və onların praktiki əhəmiyyəti, işin aprobeiası, dissertasiyanın həcmi və strukturu təqdim edilmişdir.

Birinci fəsil maşın öyrənməsinin yeni və sürətlə inkişaf edən qolu olan federativ öyrənmə haqqında ümumi məlumatlara həsr olunmuşdur. Bu fəsildə mövcud ədəbiyyat sistematik şəkildə təhlil olunaraq federativ öyrənmənin əsas istiqamətləri, tətbiq sahələri, qarşılaşılan problemləri və istifadə olunan aqreqatlaşdırma metodları haqqında geniş informasiya verilmişdir ^{1 2}.

¹ Aliyev, S. A survey on challenges of federated learning // -Baku: Azerbaijan Journal of High Performance Computing, – 2022. 5 (2), – p. 273–285.

² Ismayilov, E., Aliyev, S., Naghiyev, E., Fatullayeva, A. Paralellization of machine learning algorithms for prediction problem using multiprocessing technique // Proceedings of the 8th International Conference on Control and Optimization with Industrial Applications (COIA-2022), – Baku: – 2022, – p. 249–251.

Federativ öyrənmə ənənəvi mərkəzləşdirilmiş maşın öyrənmə metodlarından fərqli olaraq, datanın mərkəzi serverdə saxlanılmasına ehtiyac duymur. Bunun əvəzinə, data mənbələri, yəni klientlər, topladıqları məlumatı öz lokal mühitlərində istifadə edərək öyrənmə prosesini həyata keçirirlər və yalnız öyrənilmiş model parametrlərini serverə göndərirlər. Bu yanaşmanın ən mühüm üstünlüklərindən biri məlumatların məxfiliyinin qorunmasıdır. Çünki bu üsulda məlumatlar heç vaxt mərkəzi serverə ötürülmür və mənbə yerlərində saxlanılır. Bu səbəbdən federativ öyrənmə xüsusilə səhiyyə, maliyyə, sənaye və digər həssas sahələrdə geniş tətbiq olunur^{3 4}.

Bununla belə, federativ öyrənmənin tətbiqi zamanı bir sıra mühüm problemlər ortaya çıxır. Bu problemlərdən biri aqreqatlaşdırma üsullarının seçilməsi və optimallaşdırılmasıdır. Hal-hazırda ən çox istifadə olunan və ən sadə yanaşmalar FedAVG və FedSGD alqoritmləridir. Bu metodlar klientlərdən alınan modelləri birləşdirərkən əsasən hər bir klientin öyrənmə prosesində istifadə etdiyi nümunələrin sayı əsasında çəkilər təyin edir. Yəni daha çox nümunəyə malik klientin modeli daha böyük çəkiyə malik olur. Lakin ədəbiyyatın araşdırılması göstərir ki, bu yanaşma hər zaman optimal nəticə vermir. Çünki federativ öyrənmə mühitində klientlərdə olan verilənlərin sinif paylanması qeyri-bərabər ola bilər, klientlərin hesablama gücləri və şəbəkə bağlantılarının keyfiyyəti fərqlənə bilər. Bu cür heterogenlik amilləri nəzərə alınmadıqda, əldə edilən qlobal modelin performansы zəifləyər bilər.

Federativ öyrənmədə üzə çıxan digər vacib problemlərdən biri də təhlükəsizlik məsələsidir. Federativ öyrənmə datanın birbaşa

³ Drainakis, G., Katsaros, K. V., Pantazopoulos, P., Sourlas, V., Amditis, A. Federated vs. centralized machine learning under privacy-elastic users: A comparative analysis // 2020 IEEE 19th International Symposium on Network Computing and Applications (NCA), – Cambridge, MA: IEEE, – 2020, – p. 1–8.

⁴ Aliyev, S., Gozelov, T., Ceferli, T., Seyidahmedova, A. Federated learning for disease diagnosis dataset // Ümummilli lider Heydər Əliyevin anadan olmasının 100 illik yubileyinə həsr olunmuş gənc tədqiqatçı və doktorantların Respublika Elmi Konfransının Materialları, 4-cü cild. – Bakı: Azərbaycan Dövlət Neft və Sənaye Universiteti, – 2023, – p. 357–361.

ötürülməsinə ehtiyac duymasa da, sistem müxtəlif növ kiberhücumlara qarşı tam müdafiəsiz deyil. Ədəbiyyatda bu sahə üzrə bir çox təhlükə növü təsvir olunmuşdur. Məsələn, qradiyent çevirmə hücumları zamanı klient tərəfindən serverə göndərilən qradiyentlər ələ keçirilə bilər və bu qradiyentlərdən istifadə etməklə hücum edən tərəf ilkin verilənləri təxmin edə və ya onların ümumi xüsusiyyətlərini öyrənə bilər. Bu kimi hücumlar federativ öyrənmənin məxfi və təhlükəsiz hesab olunan təbiətinə ciddi təhlükə yaradır.

Bu səbəbdən federativ öyrənmənin inkişafı ilə yanaşı, həm aqreqatlaşdırma metodlarının təkmilləşdirilməsi, həm də təhlükəsizlik tədbirlərinin gücləndirilməsi istiqamətində araşdırmalar davam etdirilir. Beləliklə, federativ öyrənmə sahəsi həm nəzəri, həm də praktiki baxımdan çoxsaylı tədqiqat imkanları təqdim edir.

İkinci fəsildə federativ öyrənmədə olan aqreqatlaşdırma üsulları barədə daha dərin məlumat verilmiş və onların üstünlükləri və çatışmazlıqları ətraflı şəkildə araşdırılmışdır.

Federativ öyrənmədə FedAVG və FedSGD üsulları

Federativ öyrənmədə model parametrlərinin birləşdirilməsi üçün ən geniş istifadə olunan üsullardan biri FedAVG alqoritmidir. Onun populyarlığının əsas səbəbləri sadə quruluşu, asan tətbiqi və praktiki ssenarilərdə yüksək effektivlik nümayiş etdirməsidir. FedAVG, əslində, FedSGD metodunun inkişaf etdirilmiş forması kimi təklif olunmuşdur və federativ mühitdə optimallaşmanı daha səmərəli şəkildə aparmağı hədəfləyir.

FedSGD metodunun əsas ideyası ənənəvi stoxastik qradiyent enməsi (SGD) yanaşmasının federativ öyrənmə mühitinə uyğunlaşdırılmasıdır. Klassik SGD-də model parametrləri hər dəst üzərində hesablanan qradiyentlərin ortalaması ilə yenilənir. Federativ konfigurasiyada isə hər bir klient öz lokal məlumatları əsasında qradiyentləri hesablayır, bu qradiyentlər serverə ötürülür və serverdə ortalanaraq qlobal model parametrlərinin yenilənməsində istifadə olunur. Bu proses aşağıdakı ifadə ilə formalaşdırılır:

$$w_{i+1} = w_i - \alpha \sum_{k=1}^K \frac{n_k}{n} g_k$$

Burada w_i model parametrlərinin i -ci iterasiyadakı qiymətləri, n_k k -cı klientin təlim datasının ölçüsü, g_k k -cı klientin həmin iterasiyadakı qradiyenti və α öyrənmə sürətidir.

FedAVG metodu, FedSGD-nin çatışmazlıqlarını aradan qaldırmaq məqsədilə təklif olunmuşdur⁵. Bu metodda klientlər sadəcə qradiyentləri deyil, tam model parametrlərini bir neçə epoch boyunca yeniləyir və daha sonra bu parametrləri serverə ötürürlər. Server isə bu lokal parametrləri müvafiq çəkilərlə ortalayaraq yeni qlobal modeli formalaşdırır. Bu yanaşma FedSGD-yə nisbətən kommunikasiya xərclərini əhəmiyyətli dərəcədə azaldır və optimallaşma prosesinin effektivliyini artırır. İfadə aşağıdakı kimidir:

$$\text{Klient } k, w_{t+1}^k \leftarrow w_t^k - \alpha g_k$$

$$\text{Serverdə } w_{t+1} \leftarrow \sum_{k=1}^k \frac{n_k}{n} w_{t+1}^k$$

Federativ öyrənmədə ikinci tərtib üsullar

Nyuton üsulu ikinci tərtib optimallaşdırma metodlarından biri olub, funksiyanın həm qradiyentindən, həm də Hesse matrisindən istifadə edərək daha sürətli və dəqiq minimallaşdırmanı təmin edir. Əsas ideya məqsəd funksiyasını ikinci dərəcəli çoxhədli ilə yaxınlaşdırmaq və bu yaxınlaşma əsasında optimal addımı hesablamaqdır. Verilmiş $f(x)$ funksiyasının lokal minimumunu tapmaq üçün Nyuton iterasiyası aşağıdakı formada ifadə olunur:

$$x_{i+1} = x_i - H^{-1}(x_i) \nabla f(x_i)$$

Burada x_i dəyişənin i -ci iterasiyadakı qiyməti, $\nabla f(x_i)$ qradiyent və $H^{-1}(x_i)$ Hesse matrisinin tərsidir.

Nyuton üsulu federativ öyrənmədə də tətbiq oluna bilər və Federated Nyuton üsulu (FedNM) kimi yanaşmalarda istifadə edilir.

⁵ Gad, G., Fadlullah, Z. Federated learning via augmented knowledge distillation for heterogenous deep human activity recognition systems // Sensors, – 2023. 23 (1) – p. 1-20.

Burada hər bir klient lokal qradient və Hesse matrisini hesablayaraq serverə göndərir. Server bu məlumatları toplayaraq qlobal yenilmə həyata keçirir. Proses aşağıdakı addımları əhatə edir:

- Klientlər lokal qradient və hesse matrisini hesablayır.
- Bu məlumatlar serverə ötürülür.
- Server qlobal qradient və Hesse matrisini vasitəsilə istiqamət vektorunu hesablayır.
- Nyuton iterasiyası tətbiq edilərək yeni qlobal parametrlər əldə edilir.
- Klientlər bu parametrlərlə modellərini yeniləyir.

Bu yanaşma yüksək dəqiqlik təmin etsə də, federativ mühitdə bir neçə ciddi problem yaradır. FedNM yanaşmasında əsas problemlərdən biri məxfiliyin risk altında olmasıdır. Belə ki, qradient və Hesse matrisinin ötürülməsi qradient çevirmə kimi hücumlara şərait yarada bilər. Digər mühüm çətinlik hesablama yükü ilə bağlıdır; böyük neyron şəbəkələrində Hesse matrisinin ölçüsü çox böyük olduğundan, onun hesablanması və saxlanması ciddi resurs tələb edir. Bundan əlavə, Hesse matrisinin serverə ötürülməsi şəbəkə trafikini əhəmiyyətli dərəcədə artırır və bu da federativ öyrənmə sistemlərində yüksək kommunikasiya xərcinə səbəb olur.

Federativ fərdiləşdirmə

Ənənəvi federativ öyrənmə alqoritmləri (məsələn, FedAvg) bütün iştirakçılar üçün ümumi bir model öyrətməyə çalışır. Lakin, fərqli istifadəçilərin cihazlarında olan məlumatların fərqli xüsusiyyətlərə malik olması (məsələn, qeyri-bərabər verilənlər paylaşılması) ümumi modelin performansını zəiflədə bilər.

Bu problemi həll etmək üçün fərdi uyğunlaşma (personalization) metodları inkişaf etdirilmişdir. Federativ fərdiləşdirmə -FedPer (Federated Personalization) belə üsullardan biridir və ümumi modelin dərin qatlarını paylaşaraq, lakin hər bir klient üçün fərdi son qatları saxlayaraq fərdiləşdirilmiş modellər yaradır.

FedPer-in əsas ideyası ondan ibarətdir ki, modelin ilkin qatları (ümumi) bütün klientlər tərəfindən paylaşılır və ümumi qlobal model kimi serverdə saxlanılır. Bununla yanaşı, son qatlar (fərdi) hər bir klient üçün özəl saxlanılır və yalnız həmin klientin lokal məlumatları ilə öyrədilir. Bunun səbəbi odur ki, adətən neyron şəbəkələrdə ilk əvvəlki qatlar daha ümumi xüsusiyyətləri, sonrakı qatlar isə daha incə detalları öyrənir. Ümumi xüsusiyyətlər bütün klientlərdə oxşar olduğunu fərz etsək, bu üsul klientlərə imkan verir ki, öz modellərinin xüsusiyyətini qorurayaq eyni zamanda digər klientlər tərəfindən öyrənilmiş ümumi xüsusiyyətlərdən istifadə edə bilsin. Beləliklə, FedPer hibrid öyrənmə yanaşmasını tətbiq edir:

Paylaşılan ümumi dərin qatlar (global layers) qlobal strukturu öyrənir. Klientə məxsus fərdi son qatlar (local layers) isə həmin klientin xüsusi məlumatlarına uyğunlaşdırılır.

Bu yanaşma xüsusilə heterogen klient məlumatlarına sahib sistemlər üçün effektivdir. FedPER alqoritmi aşağıdakı kimi göstərilə bilər: Hər bir klient öz lokal modelini öyrədir. Bu zaman həm ümumi həm şəxsi qatlar iştirak edir. Hər bir klient ümumi qatlarının parametrlərini serverə göndərir. Serverdə ümumi qatlar ortalanır. Ümumi qatlar yenidən hər bir klientə göndərilir və şəxsi qatlarla birləşdirilir.

Bu alqoritmə diqqət yetirməli olduğumuz məqam odur ki, qlobal modelin özünün qərar vermək bacarığı yoxdur. Çünki qərar verməyə istifadə olunan sonuncu çıxış qatı serverdə olmur və hər bir klientin özünə xas olur. İkinci bir qeyd isə ondan ibarətdir ki, bu alqoritm tək qatlı neyron şəbəkələrdə və logistik reqressiya modellərində istifadə oluna bilməz.

Federativ öyrənmədə klientlərə çəkirlərin verilməsi

Federativ öyrənmədə qlobal modelin qurulması üçün müxtəlif klientlərdən əldə olunan lokal modellərin və ya qradientlərin birləşdirilməsi tələb olunur. Bu prosesdə ən mühüm məqamlardan biri hər bir klientin nəticəsinə hansı çəkinin verilməsidir. Ənənəvi yanaşmalarda, məsələn FedAVG alqoritmində, çəkilər əsasən klientin təlimdə istifadə etdiyi nümunələrin sayı əsasında müəyyən edilir. Yəni daha çox nümunəyə sahib olan klientin modeli qlobal modelin

formalaşdırılmasında daha böyük təsirə malik olur. Bu, sadə və intuitiv bir yanaşma olsa da, bəzi hallarda optimal nəticə vermir.

Praktiki federativ öyrənmə mühitlərində klientlərin məlumat paylanmaları qeyri-bərabər ola bilər, sinif balanssızlığı müşahidə oluna bilər, həmçinin onların hesablama gücü və şəbəkə imkanları bir-birindən fərqlənə bilər. Belə hallarda yalnız nümunələrin sayı əsasında çəkilərin təyin olunması qlobal modelin keyfiyyətini zəiflədə bilər. Buna görə də son tədqiqatlarda əlavə meyarların, məsələn, siniflərin paylanması, hesablama gücü, şəbəkə gecikmələri və ya məlumatların keyfiyyəti əsasında çəkilərin dinamik olaraq müəyyən edilməsi təklif olunur.

Bu məsələni həll etmək üçün tədqiqat işində bir sıra metodlardan istifadə olunmuşdur. Bu metodlardan biri qeyri-səlis nəticə çıxarma sistemidir (FİS). FİS nəinki verilənlərin həcmi, həm də klientin hesablama gücü və siniflərin paylanmasını da nəzərə almaq üçün dizayn olunaraq klientlərin çəkiləndirilməsində istifadə olunmuşdur. Digər yanaşma analitik ierarxiya prosesidir ki (AHP), o da FİS-də istifadə olunmuş atributlar vasitəsilə daha optimal çəkiləndirmə üçün istifadə olunmuşdur. Genetik alqoritmlər və Koordinat oxu üzrə enmə alqoritmləri isə, iterativ olaraq hər iterasiyada klientlərin çəkilərinə optimal istiqamətdə yaxşılaşdırır.

Üçüncü fəsildə təklif olunmuş üsulların hiperparamterləri, detalları və əldə edilmiş nəticələr haqqında söz açılmışdır.

FİS

FedAVG metodunda klientlərin çəki dəyərlərini müəyyən edən yeganə amil onların saxladıqları məlumat nümunələrinin sayıdır. Bu isə bəzi hallarda modelin ədalətsiz və qeyri-dəqiq öyrənməsinə səbəb ola bilər. Bu işi təkmilləşdirmək məqsədilə biz FedAVG alqoritmini bir qədər dəyişdirərək əlavə amillər nəzərə almışıq. Belə amillərə məlumat dəstində sinif balansının səviyyəsi və digər faktorlar daxildir.

Bu yeni amillər qeyri-səlis nəticə çıxarma sistemi vasitəsilə qiymətləndirilmiş və müəyyən qaydalar əsasında yeni çəki dəyərləri hesablanmışdır. Bu qiymətləndirmələr klientlərin federativ modelə töhfəsini daha ədalətli bölüşdürməyə imkan verir. Aparılan təcrübələrdə üç əsas faktor olaraq verilənlərin həcmi, siniflərin

paylanması və klientin hesablama gücü nəzərə alınmışdır. Mənsubiyyət funksiyaları şəkil 1,2,3 və 4-də göstərib.

Mənsubiyyət funksiyaları təyin olunduqdan sonra qaydalar seti təyin olunmalıdır. Aparılan eksperimentlər zamanı aşağıdakı qaydalar istifadə olunmuşdur. Bu qaydalar qeyri-səlis nəticə çıxarma sistemində klientlərə verilən çəki dəyərlərinin müəyyən edilməsi üçün tətbiq edilmişdir ⁶.

1. Əgər Verilənlərin həcmi= Kiçik (Small) və Sinif Balansı = Yüksək dərəcədə balanssız (Highly imbalanced) olarsa, klientin çəkisi = Zəif (Weak) təyin edilir.

2. Əgər Verilənlərin həcmi= Böyük (Large) və Sinif Balansı = Balanslı (Balanced) olarsa, klientin çəkisi = Güclü (Strong) təyin edilir.

3. Əgər Verilənlərin həcmi= Kiçik (Small) və Sinif Balansı = Balanslı (Balanced) olarsa, klientin çəkisi = Orta (Mid) təyin edilir.

4. Əgər Verilənlərin həcmi= Orta (Mid) olarsa, klientin çəkisi = Orta (Mid)

5. Əgər Verilənlərin həcmi= Böyük (Large) və Sinif Balansı = Yüksək dərəcədə balanssız (Highly imbalanced) olarsa, klientin çəkisi = Orta (Mid) təyin edilir.

6. Əgər Hesablama Gücü (Cpower) = Zəif (Bad) olarsa, klientin çəkisi = Zəif (Weak) təyin edilir.

7. Əgər Hesablama Gücü (Cpower) = Orta (Mid) olarsa, klientin çəkisi = Orta (Mid) götürülür.

8. Əgər Hesablama Gücü (Cpower) = Yaxşı (Good) olarsa, klientin çəkisi = Güclü (Strong) təyin edilir

⁶ Aliyev, S., Ismayilova, N. FL2: Fuzzy logic for device selection in federated learning // IEEE Publisher: Application of Information and Communication Technologies, Proceedings – 2023, – p. 1–6.

FİS əsaslı birləşdirmə üsulu üçün İF-THEN qaydalarının avtomatik seçilməsi

FİS-dən istifadə edərkən ən əsas çətinliklərdən biri qaydaların düzgün seçilməsidir. Ekspertsiz mühitlərdə bu proses həm çox vaxt aparır, həm də subyektiv yanaşmalar nəticəsində qeyri-sabit nəticələrə gətirib çıxara bilər. Bu problemin həllinə yönəlmiş yanaşmalardan biri kimi genetik alqoritm tətbiq olunmuşdur. Məqsəd qaydalar setinin avtomatik şəkildə generasiya olunması və təkmilləşdirilməsi olmuşdur.

Genetik alqoritmə hər bir fərd qaydalar toplusunu təmsil edir və bu toplular müəyyən sayda qaydadan ibarət olur. Qaydaların sayı dinamik olaraq dəyişdirilmiş, iki ilə on arasında məhdudlaşdırılmışdır. İlkin qaydalar seti təsadüfi olaraq yaradılmış, lakin nəzərə alınmışdır ki, eyni set daxilində olan qaydalar bir-biri ilə təzad təşkil etməsin. Hər nəsildə qaydalar seti daha yaxşı performans göstərmək üçün seçmə, çarpazlama və mutasiya əməliyyatlarından keçirilmişdir. Bu çərçivədə seçmə mərhələsində rulet təkəri, çarpazlamada tək nöqtəli çarpazlama, mutasiyada isə təsadüfi seçilmiş qaydanın dəyişdirilməsi istifadə olunmuşdur.

Ekspərimentlər Titanic məlumat dəsti üzərində aparılmışdır. Məlumat dəstinin sütunları FIS üçün giriş dəyişənləri kimi qəbul edilmiş və hər bir dəyişən üçün müvafiq mənsubiyyət funksiyaları müəyyən edilmişdir. Başlanğıc populyasiya təxminən 33% dəqiqliklə başlamış, genetik alqoritmin tətbiqindən sonra isə dəqiqlik 66%-ə qədər yüksəlmişdir. Bu, modelin öyrənmə qabiliyyətində əhəmiyyətli bir irəliləyişi nümayiş etdirir. İterasiyalar üzrə dəqiqliyin artmasını göstərən öyrənmə əyrisi Şəkil 5-də təqdim olunur.

Əldə olunan nəticələr təsdiq edir ki, genetik alqoritmlər qaydaların avtomatik seçilməsi və optimallaşdırılması üçün güclü potensiala malikdir ⁷. Bu yanaşma, ekspert biliklərinin məhdud olduğu və ya qeyri-müəyyənlik səviyyəsinin yüksək olduğu federativ

⁷ Aliyev, S., Ismayilova, N, Zanni-Merk, C.. Improvement of the rules selection process in FIS with genetic algorithms /-Amsterdam: Procedia Computer Science, – 2024. Volume 246, – p. 1690–1699.

öyrənmə sistemləri kimi mühitlərdə xüsusilə faydalı ola bilər və bununla da FIS əsaslı metodların effektivliyini artırır.


AHP

Analitik İerarxik Proses klientlərin çəkiləndirilməsi üçün təklif olunan alternativ bir metod olaraq tətbiq edilmişdir. Bu metodun əsas məqsədi, FedAVG metodunda olduğu kimi yalnız məlumatların miqdarını nəzərə almaq əvəzinə, sinif paylanması və hesablama gücü kimi əlavə amilləri də çəki hesablamalarında nəzərə almaqdır. AHP metodunun üstün cəhəti ondan ibarətdir ki, fərqli kriteriyaların nisbi əhəmiyyətini müəyyənləşdirməyə və onları riyazi əsaslandırılmış şəkildə çəki bölgüsünə inteqrasiya etməyə imkan yaradır. Bu yanaşma daha balanslı və optimal çəki bölgüsü təmin edərək, modelin ümumi performansını artırmağa yönəlmişdir.


Bu metodun tətbiqi zamanı üç əsas atribut—verilənlərin ölçüsü, siniflərin paylanması və hesablama gücü—əsas kriteriyalar kimi götürülmüşdür. Hər bir kriteriyanın nisbi əhəmiyyətini müəyyən etmək üçün üstünlük matrisi qurulmuşdur⁸. AHP metodologiyasına uyğun olaraq, bu matris ekspert biliklərinə və məntiqi əsaslandırmalara əsasən tərtib edilmişdir. Daha sonra isə, bu matris əsasında hər bir faktorun yekun çəkisi hesablanmış və klientlərə çəki dəyəri kimi təyin edilmişdir.

Tədqiqat zamanı bir neçə müxtəlif üstünlük matrisi sınaqdan keçirilmiş və ən yaxşı matris sonda digər üsullarla müqayisə olunmuşdur. Nəticələr göstərdi ki, siniflərin balansı ən önəmli faktor, ondan az fərqlə isə verilənlərin həcmi ikinci faktor hesab olunmuşdur. Hesablama gücünün əhəmiyyəti isə digər iki kriteriyadan geri qalmışdır.


⁸ Aliyev, S. Application of AHP for weighting clients in federated learning // - Baku: Azerbaijan Journal of High Performance Computing, – 2023. 6 (2), – p. 153–162.




Şəkil 1. Verilənlərin həcmi dəyişəni üçün mənsubiyyət funksiyası




Şəkil 2. Sınıf balansı dəyişəni üçün mənsubiyyət funksiyası



Şəkil 3. Hesablama gücü dəyişəni üçün mənsubiyyət funksiyası



Şəkil 4. Klientin çəkisi dəyişəni üçün mənsubiyyət funksiyası



Şəkil 5. Genetik alqoritmin öyrənmə əyrisi

Tətbiq edilən üstünlük matrisi aşağıdakı formada müəyyən olunmuşdur:

	Verilənlərin həcmi	Siniflərin balansı	Hesablama gücü
Verilənlərin həcmi	1	0.3	7
Siniflərin balansı	3	1	9
Hesablama gücü	0.14	0.11	1

Koordinat oxu üzrə enmə

Koordinat oxu üzrə enmə təklif olunan metodlardan biridir və onun digər metodlardan əsas fərqi ondan ibarətdir ki, burada ekspert biliyinə və ya klientlərin məlumatları haqqında ilkin biliklərə ehtiyac duyulmur. Bu metod sırf riyazi optimallaşdırmaya əsaslanır və çəkilərin müəyyən olunması üçün funksiyanın optimal qiymət aldığı istiqaməti taparaq, həmin istiqamətə yaxınlaşma prinsipinə əsaslanır.

İlkin olaraq, çəkilər klassik FedAVG metoduna uyğun olaraq verilənlərin həcminə əsasən müəyyən edilir. Daha sonra koordinat oxu üzrə enmə iterativ şəkildə tətbiq edilir ⁹. Bu proses aşağıdakı kimi işləyir:

- Hər bir iterasiya üçün, bütün klientlərin çəkiləri ayrı-ayrılıqda nəzərdən keçirilir.
 - Müəyyən bir klient üçün, onun çəkisi kiçik bir əmsalla α artırılır və yeni çəkilər qiymətləndirmə setində test edilir.
 - Əgər dəqiqlik artırsa, həmin istiqamətdə davam edilir. Əks halda, çəkisi α qədər azaldılır və yenidən qiymətləndirilir.
 - Əgər həm artım, həm də azalma nəticəsində performansın yaxşılaşmadığı müşahidə edilərsə, həmin klientin çəkisi dəyişdirilmir.
- Bu proses bütün klientlər üçün tətbiq edildikdən sonra iterasiya başa çatır və yeni dövrə başlanılır.
- Növbəti iterasiyada yenə ən birinci klientdən başlayaraq eyni proses təkrarlanır.
- Metod iterativ olaraq funksiyanın minimumuna yaxınlaşana qədər davam etdirilir.

Eksperimentlərin nəticələri

Bu bölmədə yuxarıda qeyd olunmuş üsullardan alınmış nəticələr və onların müqayisəli analizi aparılır. Eksperimentlər MAGIC Gamma telescope verilənlərinin üzərində aparılmışdır.

⁹ Aliyev, S., Ismayilova, N. Coordinate descent optimization for device weighting in federated learning // -Baku: Proceedings of Azerbaijan High Technical Educational Institutions, – 2025. 48 (6) – p. 488–499.

Eksperimentləri həyata keçirmək üçün verilənlər manual olaraq 5 klient arasında bölüşdürülmüşdür.

Bu verilənlərin klientlər üzrə necə paylanması cədvəl 1-də öz əksini tapmışdır. Cədvəldə göstərilən Gini əmsalı sinif balanssızlığını təsvir edən mühüm göstəricilərdən biridir.

Bu qiymətlər AHP və FİS ilə çəkiləndirmə zamanı istifadə olunmuşdur. AHP zamanı onların giriş vektoru (datanın ölçüsü, siniflərin paylanması, hesablama gücü) üstünlük vektoruna vurularaq sonda alacağı çəki hesablanmışdır. FİS alqoritmində isə onlar FİS-ə giriş dəyişəni kimi verilmişdir:

Cədvəl 1

MAGIC Gamma telescope datasının paylanması

Klientlər	Ölçü	G sinifi	H sinifi	Gini	Hesablama gücü
1	4000	2000	2000	0.5	4.5
2	6300	4500	1800	0.4	3.0
3	3500	2000	1500	0.48	1.5
4	1100	500	600	0.49	4.5
5	4120	3332	788	0.31	3.0

Cədvəl 2-də original, FİS və AHP alqoritmi üzrə əldə olunmuş klient çəkiləri göstərilmişdir.

Müxtəlif alqoritmlərin klientlərə verdiyi çəkilər

Klientlər	1	2	3	4	5
Original	0.21	0.33	0.18	0.05	0.21
FİS	0.28	0.16	0.17	0.21	0.16
AHP	0.24	0.20	0.17	0.22	0.15

Cədvəl 3-də müxtəlif klientlər üzrə fərqli metodların təsiri qiymətləndirilib və həm dəqiqlik, həm də F1-qiymət göstəriciləri üzrə nəticələr təqdim olunub. Dörd fərqli metod - orijinal FedAVG, FİS, AHP və koordinat oxu üzrə enmə (KA) - müqayisə edilib. Cədvəldə hər bir klient üçün bu metodların nəticələri göstərilib və həm ümumi klient ortalaması, həm də serverdə əldə olunan nəticələr qeyd olunub¹⁰.

Ümumilikdə bu nəticələr göstərir ki, fərqli metodlar fərqli klientlər üçün fərqli nəticələr verir. Orta hesabla, FİS metodu həm dəqiqlik, həm də F1-qiymət göstəricilərində ən yaxşı nəticəni təmin edib. AHP metodu isə bir qədər geridə qalsa da, ümumilikdə güclü performans göstərib. KA metodu bəzi fərdi klientlər üçün yaxşı nəticə versə də, ümumi ortalama baxımından bir qədər zəif çıxış edib. Lakin serverdə əldə edilən nəticələrə görə, KA metodu burada ən yaxşı performansını göstərib. Bu, KA metodunun fərdi klientlərdə daha zəif çıxış edə bilsə də, ümumilikdə daha yaxşı ümumiləşdirmə qabiliyyətinə malik ola biləcəyini göstərir.


Koordinat oxu üzrə enmə alqoritminin öyrənmə əyrisi aşağıdakı şəkil 6-da göstərilmişdir.

¹⁰ Aliyev, S. Comparative analysis of different client weighting algorithms in federated learning // VII ISARC 6th International Boğaziçi Scientific Research Congress. – Istanbul: – 2025, – p. 1309–1316.

Cədvəl 3

**MAGİC Gamma telescope verilənləri üzərində alınmış
nəticələr**

Klient	Dəqiqlik				F1 Qiyməti			
	Orijinal	FİS	AHP	KA	Orijinal	FİS	AHP	KA
1	0.75	0.77	0.78	0.77	0.74	0.78	0.76	0.77
2	0.81	0.8	0.81	0.76	0.76	0.81	0.80	0.73
3	0.78	0.79	0.79	0.78	0.76	0.79	0.78	0.78
4	0.72	0.75	0.75	0.78	0.72	0.75	0.73	0.78
5	0.84	0.83	0.82	0.78	0.72	0.82	0.83	0.70
Klient ortalaması	0.78	0.80	0.79	0.77	0.74	0.79	0.78	0.75
Server	0.74	0.77	0.76	0.79	0.74	0.77	0.77	0.79




Şəkil 6. MAGİC Gamma telescope verilənləri üzərində kordinat oxu üzrə enmə algoritminin öyrənmə əyrisi

Qrafikdən görüldüyü kimi, modelin ilkin dəqiqlik qiyməti təxminən 0.745 olmuşdur. Təlimin ilk mərhələlərində kəskin artım

müşahidə olunur ki, bu da modelin başlanğıcda yüksək öyrənmə qabiliyyətinə sahib olduğunu göstərir. İlk iterasiyalarda dəqiqlik göstəricisinin sürətlə yüksəlməsi modelin verilənlərdən effektiv şəkildə öyrəndiyini təsdiq edir. Qrafikdəki qırmızı vertikal xətlər isə xüsusi bir məqamı göstərir: bu məqamda beş klientin heç birində dəyişiklik baş vermədiyi üçün öyrənmə parametri azaldılır. Bu yanaşmanın məqsədi konvergensiyani daha dəqiq idarə etmək və öyrənmə prosesində stabilliyi təmin etməkdir. Parametrlərin azaldılmasından sonra dəqiqlik göstəricisi əlavə olaraq təxminən 0.05 artmış və nəticədə modelin yekun dəqiqliyi 0.791-ə çatmışdır.

Bundan əlavə, KA metodu Viskonsin Süd Vəzi Xərçəngi verilənləri üzərində də sınaqdan keçirilmişdir. Bu verilənlər MAGIC Gamma Telescope verilənlərindən əhəmiyyətli dərəcədə kiçik olduğuna görə, serverdə saxlanılan bəzi nümunələr klientlərdə təkrarlanan nümunələrlə üst-üstə düşmüşdür. Bu eksperimentdə KA metodu orijinal FedAVG alqoritmi ilə müqayisə edilmişdir.

Şəkil 7-də göstərilən öyrənmə əyrisi nəticələrin daha sürətli yığılmasını təsdiq edir. Belə ki, model ən yaxşı nəticəsini hələ 20-ci iterasiyaya çatmadan əldə etmişdir. Bunun nəticəsində öyrənmə parametri cəmi bir dəfə azaldılmış və daha az iterasiya ilə yüksək dəqiqlik təmin olunmuşdur. Bu isə KA metodunun kiçik həcmli verilənlərdə də effektiv şəkildə işlədiyini nümayiş etdirir.



Şəkil 7. Viskonsin Süd Vəzi Xərçəngi verilənləri üzərində kordinat oxu üzrə enmə alqoritminin öyrənmə əyrisi

Alınmış nəticələr aşağıdakı cədvəl 4-də öz əksini tapmışdır.

Cədvəl 4

Süd vəzi xərcəngi veriləni üzərində alınmış nəticələr

Klient	Dəqiqlik		F1 qiyməti	
	Orijinal	KA	Orijinal	KA
1	0.93	0.93	0.93	0.93
2	0.91	0.97	0.97	0.97
3	0.93	0.93	0.93	0.93
4	0.94	0.94	0.94	0.94
5	0.92	0.96	0.92	0.96
Klient ortalaması	0.926	0.946	0.926	0.946
Server	0.95	0.98	0.95	0.98

Burada da, koordinat oxu üzrə enmə alqoritmi ilə 0.946 dəqiqlik alınmışdır ki, bu da orijinal metodun 0.926-lıq nəticəsindən yüksəkdir. Xüsusilə ikinci və beşinci klientlər üçün KA metodunun nəticələri orijinal metoddan daha yaxşıdır. Server səviyyəsində isə KA metodu 0.98-lik nəticə ilə orijinal metodun 0.95-lik göstəricisini üstələyib.

Bu nəticələr göstərir ki, KA metodu ümumi olaraq daha yaxşı performans nümayiş etdirir və həm klient, həm də server səviyyəsində daha dəqiq və balanslı nəticələr əldə etməyə kömək edir. Xüsusilə bəzi klientlər üçün nəzərəcarpacaq dərəcədə üstünlük təmin etdiyi müşahidə olunur. Serverdə isə bu metodun daha yüksək dəqiqlik və F1-qiymət əldə etməsi onun ümumi model performansını yaxşılaşdırdığını göstərir.

FedSGD vs FedND

Federativ Nyuton üsulunun mənfə cəhətlərindən biri onun hər əlaqə mərhələsində həm qradiyent vektorunun həm də, Hesse matrsinin serverə göndərilməsidir ki, bu əlaqə zamanı yüklənməyə səbəb olur. Bundan əlavə olaraq qradiyentin serverə göndərilməsi bu üsulu qradiyent çevirmə hücumlarına qarşı həssas edir. Qradiyent çevirmə hücumları zamanı hücumçu qradiyentlərdən istifadə edərək verilənlərin böyük hissəsini yenidən bərpa edə bilir. Bu isə öz

növbəsində federativ öyrənmənin nail olmağa çalışdığı məxfiliyin qorunması məsələsinin pozulmasına gətirib çıxarır.

Qeyd olunmuş hər iki problemi həll etmək Federativ Nyuton İstiqaməti (FedND) yanaşması təklif olunmuşdur. Buradakı idea ondan ibarətdir ki, hesse matrisi və qradiyent vektorunu serverə göndərilir. Matrisin serverə göndərilməməsi əlaqə xərcini azaldır. Bunun üçün hər bir klient istiqamət vektorunu özü hesablayır.

$$S(x) = H^{-1}(x)\nabla f(x)$$

Əldə edilmiş vektor serverə göndərilir və orada ortalanaraq modelin parametrlərini yeniləyir. Qrادیyentin göndərilməməsi isə bu üsulu qradiyent çevirmə hücumlarına qarşı daha dayanıqlı edir. Bu üsulun da çəkiləndirməsi üçün iki müxtəlif yanaşmadan istifadə olunmuşdur. Əvvəlcə, orijinal çəkiləndirmədə olduğu kimi, hər bir klientə verilənlərinin sayına uyğun olaraq çəki verildi. Daha sonra isə müqayisə üçün təklif olunmuş FİS yanaşmasına uyğun çəkilər sınaqdan keçirildi. Hər iki yanaşma həm FedSGD, həm də FedND üsuluna tətbiq edilmişdir. Üsullar MAGIC Gamma telescope verilənləri üzərində eksperimentlərdən keçirilmişdir.

FedSGD və FedND alqoritmlərinin müqayisəsi çərçivəsində hər iki metodun müxtəlif aspektləri ətraflı təhlil edilmişdir. Bu müqayisənin əsas məqsədi onların ümumi performansını və effektivliyini qiymətləndirmək, eyni zamanda istifadə olunan çəki vermə mexanizmlərinin fərqli xüsusiyyətlərini araşdırmaq olmuşdur. Qiymətləndirmə meyarları kimi dəqiqlik, AUC və F1 göstəriciləri seçilmişdir ki, bu da alqoritmlərin müxtəlif ölçülər üzrə davranışını obyektiv qiymətləndirməyə imkan verir.

Əldə edilmiş nəticələr göstərir ki, FedND alqoritmı bütün meyarlarda FedSGD-dən üstün olmuş və hər bir klient üzrə daha sabit nəticələr təqdim etmişdir. Bu isə onun daha effektiv optimallaşdırma istiqaməti seçməsindən irəli gələ bilər. Digər tərəfdən, FİS ilə çəkiləndirmə tətbiq edildikdə nəticələr fərqli meyarlarda müxtəlif təsirlər göstərmişdir. Belə ki, FedND alqoritmı üçün FİS əsasən yalnız dəqiqlik meyarında əlavə üstünlük təmin etmiş, digər meyarlarda isə orijinal çəkiləndirməyə yaxın nəticələr göstərmişdir. FedSGD-də isə

əksinə, orijinal çəkiləndirmə ümumilikdə FİS ilə çəkiləndirmədən geri qalmış, yalnız F1 qiymətində cüzi üstünlük nümayiş etdirmişdir.

Cədvəl 5-də hər iki alqoritm üçün həm orijinal, həm də FİS ilə çəkiləndirmədən əldə olunmuş nəticələr təqdim edilmiş, əlavə olaraq hər bir klient üzrə ən yaxşı nəticənin hansı konfigurasiyada əldə edildiyi ətraflı göstərilmişdir. Bu da müqayisənin həm qlobal, həm də lokal səviyyədə aparılmasına imkan yaradır.

Cədvəl 5

FedSGD və FedND alqortimlərinin nəticələr. Tünd yazılmış rəqəmlər ən yaxşı nəticəni göstərir

Alqoritm	Meyar	Klient 1	Klient 2	Klient 3	Klient 4	Klient 5	Ortalama
FedSGD orijinal çəkiləndirmə	Dəqiqlik	0.70	0.77	0.69	0.68	0.81	0.73
	AUC qiyməti	0.717	0.714	0.679	0.713	0.684	0.702
	F1 qiyməti	0.71	0.77	0.70	0.69	0.80	0.734
FedSGD – FİS ilə çəkiləndirmə	Dəqiqlik	0.71	0.77	0.71	0.70	0.79	0.736
	AUC qiyməti	0.715	0.713	0.698	0.719	0.678	0.704
	F1 qiyməti	0.71	0.76	0.71	0.71	0.77	0.732
FedND orijinal çəkiləndirmə	Dəqiqlik	0.74	0.81	0.78	0.72	0.84	0.778
	AUC qiyməti	0.763	0.776	0.781	0.762	0.733	0.763
	F1 qiyməti	0.75	0.82	0.78	0.73	0.84	0.784
FedND – FİS ilə çəkiləndirmə	Dəqiqlik	0.76	0.81	0.78	0.74	0.82	0.782
	AUC qiyməti	0.763	0.762	0.768	0.761	0.705	0.751
	F1 qiyməti	0.76	0.81	0.78	0.74	0.81	0.78

FedND alqoritminin mənfi cəhəti Hesse matrsinin tərsinin hər iterasiyada hesablanmasıdır. Baxmayaraq ki Nyuton üsulu daha sürətli yığılır, matrsinin tərsinin hesablanması alqoritmin mürəkkəbliyini artırır. Tədqiqat zamanı Hesse matrisi bir başa hesablanmamış, onun əvəzinə istiqamət vektoru xətti tənliklər sistemini həll etməklə əldə edilmişdir. Bu isə alqoritmin nisbətən sürətli işləməsi ilə nəticələnmişdir. Beləliklə FedND alqoritmindən istifadə zamanı biz həm daha sürətli yığılmaya, həm də qradiyent istifadəsindən imtina edərək qradiyent çevirmə hücumlarına qarşı daha dayanıqlı bir yanaşma əldə etmiş oluruq.

FedPER

Aşağıdakı cədvəl 6-da FedPER alqoritminə FİS və AHP alqoritminin tətbiqindən alınan nəticələr göstərilmişdir.

Cədvəl 6

FedSGD və FedND alqortimlərinin nəticələr.

Metod	Dəqiqlik	Səhihlik	Spesifiklik	F1 qiyməti
Orijinal	0.4125	0.4724	0.4125	0.4412
FİS	0.4325	0.5118	0.4188	0.4616
AHP	0.4325	0.5092	0.4188	0.4613

Bu nəticələr CIFAR-10 verilənləri üzərində əldə edilmişdir. Əvvəlki eksperimentlərdə olduğu kimi, bir neçə fərqli çəkiləndirmə kriteriyası sınaqdan keçirilmiş və əldə olunan nəticələr müqayisə olunmuşdur¹¹. Eksperimental mərhələdə tətbiq olunan qıvrılmış neyron şəbəkəsinin (CNN) arxitekturası fərdiləşdirilmiş federativ öyrənmə prinsiplərinə uyğun olaraq optimallaşdırılmışdır. Bu

¹¹ Aliyev, S., Dadasov, A., Nabiyeva, F. Comparative analysis of different approaches for aggregation step in federated learning // International Conference on Artificial Intelligence: from theory to practice, –Nakhchivan:– 2024. – p. 278–284.

çərçivədə şəbəkənin ilkin qatları (başlanğıc xüsusiyyətlərin çıxarılması qatları) bütün klientlər arasında ortaqlıq bazası kimi paylaşılmış, modelin son üç qatı isə hər bir klientin lokal məlumat xüsusiyyətlərinə uyğunlaşması üçün fərdi şəkildə saxlanılmışdır. Bu cür hibrid struktur həm global biliklərin mənimsənilməsinə, həm də lokal adaptasiyaya şərait yaradır.

Modelin performansı hər bir klientin spesifik test dəstləri üzərində fərdi qaydada yoxlanılmış və yekun nəticələr statistik ortalamaya əsasən qiymətləndirilmişdir. Təhlillər göstərir ki, dörd əsas qiymətləndirmə meyarı üzrə orijinal FedAVG çəkiləndirmə üsulu digər innovativ yanaşmalardan nəzərəcarpan dərəcədə zəif çıxış etmişdir. Xüsusilə qeyd edilməlidir ki, FİS (Qeyri-səlis Məntiq Sistemi) əsaslı yanaşma, qərarvermə prosesindəki qeyri-müəyyənlikləri daha effektiv idarə etdiyi üçün bütün ssenarilərdə AHP (İerarxik Analiz Metodu) ilə çəkiləndirmədən daha üstün nəticələr nümayiş etdirmişdir. Bu empirik sübutlar, fərdiləşdirilmiş federativ öyrənmə mühitlərində intellektual çəkiləndirmə metodlarının həlledici rolunu təsdiqləyir və gələcəkdə bu hibrid modellərin daha mürəkkəb şəbəkə arxitekturalarına inteqrasiyası üçün geniş elmi perspektivlər açır.

DİSSERTASIYA İŞİNİN NƏTİCƏLƏRİ

Tədqiqat işi çərçivəsində aparılmış nəzəri və praktiki araşdırmalar nəticəsində aşağıdakı mühüm elmi nəticələr əldə edilmişdir:

1. Federativ öyrənmənin konseptual üstünlükləri və çəkiləndirmə probleminin analizi aparılmışdır. Müasir paylanmış sistemlərdə məlumat məxfiliyinin qorunması mühüm prioritet təşkil edir. Tədqiqat göstərmişdir ki, federativ öyrənmə mərkəzləşdirilmiş yanaşmalardan fərqli olaraq, xam məlumatların ötürülməsinə ehtiyac duymadan modelin lokal cihazlarda öyrədilməsini təmin edir və beləliklə, istifadəçi məxfiliyini fundamental səviyyədə qoruyur. Lakin ənənəvi FedAVG alqoritminin daxili mexanizmi yalnız məlumatın kəmiyyətinə əsaslandığı üçün lokal cihazların keyfiyyət fərqlərini

nəzərə almır. Aparılan analizlər sübut etmişdir ki, sinif balans, qurğuların hesablama resursları və təlim tezliyi kimi amillərin prosesdən kənar qalması modelin ümumi performansını aşağı salır. Bu çatışmazlığı aradan qaldırmaq üçün işdə həm ədalətlik, həm də hesablama effektivliyi prinsiplərinə söykənən yeni çəkiləndirmə strategiyaları təklif edilmişdir.

2. Çoxmeyarlı qərarvermə və optimizasiya metodlarının inteqrasiyası həyata keçirilmişdir. Qeyd olunan struktur problemlərinin həlli üçün dissertasiya işində FİS, AHP, koordinat oxu üzrə enmə və genetik alqoritm kimi fərqli xüsusiyyətlərə malik metodlar tətbiq edilmişdir. FİS və AHP yanaşmaları ekspert rəylərini riyazi modelə çevirərək məlumatın həcmi ilə yanaşı, onun keyfiyyətini və cihazın texniki gücünü də vahid bir çəki əmsalına inteqrasiya edir. Digər tərəfdən, optimallaşdırma əsaslı yanaşmalar olan koordinat oxu üzrə enmə və genetik alqoritm, çəkilərin avtomatik və dinamik şəkildə tənzimlənməsini təmin edərək sistemin insan müdaxiləsindən asılılığını minimuma endirmişdir. Həm FedAVG, həm də fərdiləşdirilmiş FedPER modelləri üzərində aparılan sınaqlar göstərmişdir ki, təklif olunan metodlar dəqiqlik, F1-score və AUC kimi əsas metrikalarda standart üsulları əhəmiyyətli dərəcədə üstələyir.

3. Ekspert biliklərinin avtomatlaşdırılması və qaydalar bazasının avtomatik seçilməsi həyata keçirilmişdir. Ekspert sistemlərinin qurulmasında rast gəlinən ən böyük çətinliklərdən biri subyektivliyin aradan qaldırılması və qaydalar bazasının formalaşdırılmasıdır. Bu problemi həll etmək üçün tədqiqatda genetik alqoritmin imkanlarından istifadə olunaraq qaydaların avtomatik seçilməsi mexanizmi işlənmişdir. Titanic verilənlər bazası üzərində aparılan eksperimentlər bu yanaşmanın effektivliyini təsdiqləmişdir: ilkin mərhələdə təsadüfi qaydalarla cəmi 33% dəqiqlik göstərən sistem, genetik operatorların tətbiqi ilə təkamül edərək dəqiqlik dərəcəsini 66%-ə qədər yüksəltdi. Bu nəticə, qeyri-səlis sistemlərin öz-özünə öyrənmə və adaptasiya qabiliyyətinin artırılmasında genetik alqoritmlərin həlledici rol oynadığını sübut edir.

4. İkincitərtib optimizasiya və kiber-qayıqlıq səviyyəsinin artırılmışdır. Tədqiqatın sonuncu mühüm istiqaməti federativ mühitdə

modelin yığılma sürətinin və təhlükəsizliyinin artırılması ilə bağlıdır. İkinci tərtib optimallaşdırma metodu olan Nyuton istiqaməti üsulunun tətbiqi göstərmişdir ki, bu metod qradiyent əsaslı standart üsullarla müqayisədə daha az iterasiya ilə daha yüksək dəqiqlik həddinə çatmağa imkan verir. Bundan əlavə, bu üsulun məlumat strukturuna həssaslığı sayəsində model zəhərləmə və qradiyent çevirmə kimi kibernetika hücum ssenarilərinə qarşı daha yüksək dayanıqlıq nümayiş etdirdiyi müəyyən edilmişdir. Beləliklə, təklif edilən yanaşma həm modelin öyrənmə sürətini artırır, həm də onu kənar müdaxilələrə qarşı daha etibarlı edir.

Dissertasiyanın əsas müddəaları aşağıdakı elmi işlərdə dərc edilmişdir:

1. Ismayilov, E., Aliyev, S., Naghiyev, E., Fatullayeva, A. Parallellization of machine learning algorithms for prediction problem using multiprocessing technique // Proceedings of the 8th International Conference on Control and Optimization with Industrial Applications (COIA-2022), – Baku: – 2022, – p. 249–251.
2. Aliyev, S. A survey on challenges of federated learning // - Baku: Azerbaijan Journal of High Performance Computing, – 2022. 5 (2), – p. 273–285.
3. Aliyev, S., Gozelov, T., Ceferli, T., Seyidahmedova, A. Federated learning for disease diagnosis dataset // Ümummilli lider Heydər Əliyevin anadan olmasının 100 illik yubileyinə həsr olunmuş gənc tədqiqatçı və doktorantların Respublika Elmi Konfransının Materialları, 4-cü cild. – Bakı: Azərbaycan Dövlət Neft və Sənaye Universiteti, – 2023, – p. 357–361.
4. Aliyev, S., Ismayilova, N. FL2: Fuzzy logic for device selection in federated learning // IEEE Publisher: Application of Information and Communication Technologies, Proceedings. – 2023, – p. 1–6. (**Scopus, WoS**).
5. Aliyev, S. Application of AHP for weighting clients in federated learning // -Baku: Azerbaijan Journal of High Performance Computing, – 2023 6 (2), – p. 153–162.

6. Aliyev, S., Ismayilova, N., Zanni-Merk, C. Improvement of the rules selection process in FIS with genetic algorithms / - Amsterdam: Procedia Computer Science, – 2024. 246, – p. 1690–1699. **(Scopus)**.
7. Aliyev, S., Dadasov, A., Nabiyeva, F. Comparative analysis of different approaches for aggregation step in federated learning // International Conference on Artificial Intelligence: from theory to practice, –Nakhchivan: – 2024. – p. 278–284.
8. Aliyev, S. Comparative analysis of different client weighting algorithms in federated learning // VII ISARC 6th International Boğaziçi Scientific Research Congress, – Istanbul: – 2025, – p. 1309–1316.
9. Aliyev, S., Ismayilova, N. Coordinate descent optimization for device weighting in federated learning // -Baku: Proceedings of Azerbaijan High Technical Educational Institutions, – 2025. 48 (6), – p. 488–499.

Müştərək çap olunmuş işlərdə müəllifin şəxsi rolu:

- [1]- Kompüter simulyasiyası və nəticələrin təhlili;
- [3]- İdeya müəllifi və kompüter simulyasiyası;
- [4]- Kompüter simulyasiyası, verilənlərin ilkin emalı və nəticələrin təhlili;
- [6]- Kompüter simulyasiyası və nəticələrin təhlili;
- [7]- Məsələnin qoyuluşu, kompüter simulyasiyası və nəticələrin təhlili;
- [9]- İdeya müəllifi, verilənlərin ilkin emalı, kompüter simulyasiyası və nəticələrin təhlili;

Dissertasiyanın müdafiəsi 28 Aprel 2026-cı il tarixdə saat 16:00 -da Azərbaycan Dövlət Neft və Sənaye Universitetinin nəzdində fəaliyyət göstərən FD 2.48 Dissertasiya şurasının iclasında keçiriləcək.

Ünvan: AZ 1010 Bakı şəhəri, Azadlıq prospekti 20
e-mail: info@asoiu.edu.az

Dissertasiya ilə Azərbaycan Dövlət Neft və Sənaye Universitetinin kitabxanasında tanış olmaq mümkündür.

Dissertasiya və avtoreferatın elektron versiyaları Azərbaycan Dövlət Neft və Sənaye Universitetinin rəsmi internet saytında yerləşdirilmişdir.

Avtoreferat 17.03. 2026-cı il tarixində zəruri ünvanlara göndərilmişdir.



Çapa imzalanıb. 11.03.2026
Kağız formatı: A5
Həcm: 37583
Tiraj: 100