

VEKTORLANGAN HISOBLASH, NORMALLASHTIRISH VA STANDARTLASHTIRISH: ZAMONAVIY MA'LUMOTLARNI QAYTA ISHLASHDA FUNDAMENTAL YONDASHUVLAR.

Tojimamatov Israil Nurmamatovich

Fargʻona davlat universiteti Amaliy matematika
va informatika kafedrası katta oʻqituvchisi

E-mail: israiltojimatov@gmail.com

A'zamova Sevinch Umid qizi

Fargʻona davlat universiteti Amaliy matematika
yoʻnalishi 3-bosqich 23.08-guruh talabasi

E-mail: ahmadjonovadilafruz4@gmail.com

ANNOTATSIYA: Ushbu tadqiqot ishida zamonaviy ma'lumotlarni qayta ishlash va mashinali o'qitish algoritmlarida muhim ahamiyat kasb etuvchi vektorlangan hisoblash, normallashtirish va standartlashtirish usullari to'liq tahlil qilingan. Vektorlangan hisoblash katta hajmdagi ma'lumotlar bilan ishlashda hisoblash samaradorligini sezilarli oshiradi va parallel operatsiyalar orqali qayta ishlash vaqtini qisqartiradi. Normallashtirish va standartlashtirish usullari ma'lumotlarni oldindan qayta ishlashda asosiy rol o'ynaydi va modellarning aniqligini hamda barqarorligini ta'minlaydi. Tadqiqotda vektorlangan operatsiyalarning matematik asoslari, ularning dasturlash tillarida amalga oshirilishi va turli algoritmlar bilan integratsiyasi chuqur o'rganilgan. Normallashtirish usullarining turli xillari, ularning qo'llanish sohalari va har birining afzalliklari hamda cheklovi batafsil tahlil qilingan. Standartlashtirish jarayonining statistik asoslari va amaliy tatbiqlari ko'rsatilgan. Olingan natijalar ma'lumotlarni samarali qayta ishlash va yuqori sifatli mashinali o'qitish modellari yaratish uchun amaliy yo'riqnoma vazifasini bajaradi.

Kalit so'zlar: vektorlangan hisoblash, normallashtirish, standartlashtirish, ma'lumotlarni oldindan qayta ishlash, NumPy, parallel hisoblash, xususiyatlarni shkalalash, mashinali o'qitish, hisoblash samaradorligi

ANNOTATION: This research paper provides a comprehensive analysis of vectorized computation, normalization, and standardization methods that are critically important in modern data processing and machine learning algorithms. Vectorized computation significantly enhances computational efficiency when working with largescale datasets and reduces processing time through parallel operations. Normalization and standardization methods play a fundamental role in data preprocessing and ensure the accuracy and stability of models. The study thoroughly examines the mathematical foundations of vectorized operations, their implementation in programming languages, and integration with various algorithms. Different types of normalization methods, their application domains, and the advantages and limitations of each are analyzed in detail. The statistical foundations of the standardization process and its practical applications are demonstrated. The obtained results serve as a practical guide for efficient data processing and creating high-quality machine learning models.

Keywords: vectorized computation, normalization, standardization, data preprocessing, NumPy, parallel computing, feature scaling, machine learning, computational efficiency

АННОТАЦИЯ: В данной исследовательской работе проведен всесторонний анализ методов векторизованных вычислений, нормализации и стандартизации, которые имеют критическое значение в современной обработке данных и алгоритмах машинного обучения. Векторизованные вычисления значительно повышают вычислительную эффективность при работе с крупномасштабными наборами данных и сокращают время обработки посредством параллельных операций. Методы нормализации и стандартизации играют фундаментальную роль в предварительной обработке данных и обеспечивают точность и стабильность моделей. В исследовании глубоко изучены математические основы

векторизованных операций, их реализация в языках программирования и интеграция с различными алгоритмами. Детально проанализированы различные типы методов нормализации, области их применения, а также преимущества и ограничения каждого из них. Продемонстрированы статистические основы процесса стандартизации и его практические применения. Полученные результаты служат практическим руководством для эффективной обработки данных и создания высококачественных моделей машинного обучения.

Ключевые слова: векторизованные вычисления, нормализация, стандартизация, предварительная обработка данных, NumPy, параллельные вычисления, масштабирование признаков, машинное обучение, вычислительная эффективность

KIRISH

Zamonavir ma'lumotlar fani va mashinali o'qitish sohalari tobora katta hajmdagi ma'lumotlar to'plamlari bilan ishlashni talab etmoqda. Millionlab yozuvlardan iborat ma'lumotlar bazalari, yuqori o'lchovli xususiyatlar vektorlari va murakkab hisoblash operatsiyalari kundalik amaliyotning bir qismiga aylangan. Bunday sharoitlarda hisoblash samaradorligi va ma'lumotlarni to'g'ri tayyorlash muhim ahamiyat kasb etadi.

Vektorlangan hisoblash zamonaviy ma'lumotlarni qayta ishlashda inqilobiy yondashuv hisoblanadi. An'anaviy dasturlashda tsikllar yordamida elementlarni birma-bir qayta ishlash o'rniga, vektorlangan operatsiyalar butun ma'lumotlar massivlari ustida bir vaqtning o'zida amallar bajaradi. Bu yondashuv nafaqat kodning o'qilishini osonlashtiradi, balki hisoblash tezligini o'nlab va hatto yuzlab marta oshiradi.

Vektorlangan hisoblashning samaradorligi zamonaviy protsessorlarning arxitekturasidan kelib chiqadi. Hozirgi kunda deyarli barcha protsessorlar SIMD texnologiyasini qo'llab-quvvatlaydi. SIMD bir komanda yordamida bir nechta ma'lumotlar ustida parallel operatsiyalar bajarish imkonini beradi. NumPy, Pandas va boshqa mashhur

kutubxonalar ushbu texnologiyalardan to'liq foydalanadi va dasturchilar uchun qulay interfeys taqdim etadi.

Ma'lumotlarni oldindan qayta ishlash mashinali o'qitish jarayonining muhim bosqichi hisoblanadi. Xom ma'lumotlar ko'pincha turli shkalalarda, turli o'lchov birliklarida va turli taqsimotlarga ega bo'ladi. Ba'zi xususiyatlar nol atrofida taqsimlangan bo'lsa, boshqalari minglab yoki millionlab qiymatlarni qabul qilishi mumkin. Bunday nomuvozanatli ma'lumotlar mashinali o'qitish modellariga salbiy ta'sir ko'rsatadi va algoritmning to'g'ri ishlashiga to'sqinlik qiladi.

Normallashtirish va standartlashtirish usullari ma'lumotlarni bir xil masshtabga keltiradi va ularni algoritmlar uchun mos holatga olib keladi. Normallashtirish odatda ma'lumotlarni ma'lum bir oraliqqa, masalan noldan birga yoki manfiy birdan musbat birgacha siqadi. Standartlashtirish esa ma'lumotlarni o'rtacha qiymati nolga va standart og'ishi biriga ega bo'lgan taqsimotga o'tkazadi. Har ikkala usul ham turli vaziyatlarda qo'llaniladi va o'zining afzalliklari hamda cheklovlariga ega.

Ushbu usullarning ahamiyati nafaqat mashinali o'qitishda, balki statistik tahlil, vizualizatsiya, signal qayta ishlash va boshqa ko'plab sohalarda ham namoyon bo'ladi. Gradient tushish algoritmlari normallashtirish va standartlashtirish mavjudligida tezroq yaqinlashadi. Masofa asosidagi algoritmlar, masalan k-nearest neighbors, faqat to'g'ri shkalalangan ma'lumotlar bilan samarali ishlaydi. Neyron tarmoqlari o'qitishda normallashtirish yoki standartlashtirish qo'llanilmasa, gradientlar yo'qolib ketishi yoki portlashi mumkin.

VEKTORLANGAN HISOBLASHNING NAZARIY ASOSLARI

Vektorlangan hisoblash ma'lumotlar massivlari ustida operatsiyalarni parallel bajarish yondashuvidir. Bu konsepsiya zamonaviy hisoblash texnologiyalarining asosiy tamoyillaridan biri hisoblanadi va katta hajmdagi ma'lumotlarni samarali qayta ishlash imkonini beradi.

An'anaviy iterativ yondashuvda ma'lumotlar massivining har bir elementi alohida qarab chiqiladi va ustida amallar ketma-ket bajariladi. Masalan, ikki massivning mos elementlarini qo'shish uchun tsikl ishlatiladi va har bir iteratsiyada bitta qo'shish amali amalga oshiriladi. Bu usul tushunish uchun oson bo'lsa-da, hisoblash jihatidan juda samarasiz hisoblanadi.

Vektorlangan yondashuvda esa butun massivlar bitta operatsiya ob'ekti sifatida qaraladi. Ikki vektorni qo'shish uchun tsikl yozish o'rniga, to'g'ridan-to'g'ri qo'shish operatori qo'llaniladi. Natijada kod qisqaroq va tushunarliroq bo'ladi, hisoblash tezligi esa sezilarli ortadi. Bu tezlik oshishi bir nechta omillar bilan tushuntiriladi.

Birinchi omil zamonaviy protsessorlarning arxitekturasi bilan bog'liq. SIMD texnologiyasi bir komanda bilan ko'p ma'lumotlarni bir vaqtda qayta ishlash imkonini beradi. Oddiy holatda bir qo'shish komandasi faqat ikkita sonni qo'shsa, SIMD kengaytmalari to'rt, sakkiz yoki hatto o'n oltita sonni bir vaqtning o'zida qo'shish imkonini beradi. NumPy va boshqa kutubxonalar ushbu imkoniyatlardan avtomatik foydalanadi.

Ikkinchi omil xotira bilan ishlashning samaradorligi bilan bog'liq. Tsikllarda har bir iteratsiyada indeks tekshiriladi, shartlar baholanadi va nazorat oqimi boshqariladi. Bu qo'shimcha operatsiyalar vaqt talab etadi. Vektorlangan operatsiyalarda esa ma'lumotlar bir yoki bir nechta katta bloklarda yuklanadi va ustida amallar bajariladi. Bu yondashuv kesh xotirasidan samarali foydalanishga olib keladi.

Uchinchi omil kompilyator optimizatsiyalari bilan bog'liq. Vektorlangan operatsiyalar kompilyatorga ko'proq imkoniyatlar beradi. Kompilyator qaysi operatsiyalar parallel bajarilishi mumkinligini aniqlaydi va mos kodlarni generatsiya qiladi. Tsikllarda esa bog'liqliklar va noaniqliklar optimizatsiyani qiyinlashtiradi.

Vektorlangan hisoblashning asosiy elementlari massivlar yoki tensorlardir. Bu ko'p o'lchovli ma'lumotlar strukturalari bo'lib, elementlar bir xil tipga ega va xotirada ketmaket joylashgan. Ketma-ket joylashish xotiraga tez kirishni ta'minlaydi va kesh xotirasidan samarali foydalanishga imkon beradi.

Matematik jihatdan vektorlangan operatsiyalar element bo'yicha operatsiyalar deb ataladi. Ikki vektorni qo'shishda birinchi vektorning birinchi elementi ikkinchi vektorning birinchi elementi bilan qo'shiladi, ikkinchi elementlar bir-biri bilan qo'shiladi va hokazo.

Bu operatsiya parallellashtirilishi mumkin, chunki har bir qo'shish boshqalaridan mustaqildir.

NORMALLASHTIRISH USULLARI VA ULARNING QILLANMALARI

Normallashtirish ma'lumotlarni ma'lum bir oraliqqa keltirish jarayoni hisoblanadi. Bu usul turli shkalalarda o'lchangan xususiyatlarni bir xil masshtabga o'tkazadi va algoritmlarning samarali ishlashini ta'minlaydi. Normallashtirish usullarining turli xillari mavjud bo'lib, har biri o'zining afzalliklari va qo'llanish sohalariga ega.

Min-Max normallashtirish eng oddiy va keng tarqalgan usullardan biridir. Bu usulda ma'lumotlar berilgan oraliqqa, odatda noldan birgacha, chiziqli transformatsiya orqali o'tkaziladi. Har bir qiymat minimal qiymat ayiriladi va maksimal bilan minimal qiymatlar ayirmasi ustiga bo'linadi. Natijada barcha qiymatlar berilgan oraliqdagi joylashadi.

Min-Max normallashtirishning asosiy afzalligi shundaki, u ma'lumotlarning asl taqsimotini saqlab qoladi. Agar asl ma'lumotlarda chetki qiymatlar bo'lmasa, normallashtirish barcha qiymatlarni teng taqsimlaydi. Shuningdek, bu usul tushunish va amalga oshirish uchun oddiy hisoblanadi.

Lekin Min-Max normallashtirish chetki qiymatlarga juda sezgir. Agar ma'lumotlarda bitta juda katta yoki juda kichik qiymat mavjud bo'lsa, barcha boshqa qiymatlar juda kichik oraliqqa siqiladi. Masalan, agar aksariyat qiymatlar o'ndan yuzgacha, lekin bitta qiymat mingga teng bo'lsa, normallashtirish natijasida aksariyat qiymatlar nolga yaqin bo'lib qoladi.

Robast normallashtirish chetki qiymatlarga kam sezgir usul hisoblanadi. Bu usulda o'rtacha va standart og'ish o'rniga mediana va kvartillararo oralig ishlatiladi. Har bir

qiymatdan mediana ayiriladi va kvartillararo oraliqqa bo'linadi. Chetki qiymatlar mediana va kvartillarga kuchli ta'sir ko'rsatmaydi, shuning uchun ushbu usul barqarorroq natijalar beradi.

AMALIY DASTURLARDA QO'LLASH

Vektorlangan hisoblash, normallashtirish va standartlashtirish zamonaviy ma'lumotlar fani loyihalarining deyarli har bir bosqichida qo'llaniladi. Ularning to'g'ri va samarali qo'llanilishi loyihaning muvaffaqiyatini ta'minlaydi.

Ma'lumotlarni yuklash va dastlabki qayta ishlash bosqichida vektorlangan operatsiyalardan foydalanish tezlikni sezilarli oshiradi. Katta hajmdagi CSV fayllarni o'qishda, ma'lumotlarni filtrlashda va asosiy statistikalarini hisoblashda NumPy va Pandas kutubxonalari vektorlangan operatsiyalardan foydalanadi. Millionlab qatorli ma'lumotlar to'plamini bir necha soniyada qayta ishlash mumkin.

Xususiyatlarni yaratish jarayonida vektorlangan operatsiyalar yanada muhimroq bo'ladi. Mavjud xususiyatlardan yangi xususiyatlar yaratish, o'zaro ta'sirlarni hisoblash, agregatsiyalar bajarish kabi operatsiyalar tez-tez uchraydi. Vektorlangan yondashuv bu operatsiyalarni tez va samarali amalga oshirish imkonini beradi.

Tasvirlarni qayta ishlashda vektorlangan operatsiyalar muhim rol o'ynaydi. Tasvir pikseller matritsasi sifatida ifodalanadi va ustida turli xil transformatsiyalar bajariladi. Yorqinlikni o'zgartirish, kontrastni sozlash, filtrlar qo'llash kabi operatsiyalar vektorlangan shaklda amalga oshiriladi. Kompyuter ko'rishi loyihalarida minglab tasvirlar ustida real vaqt rejimida operatsiyalar bajariladi.

Matn tahlilida vektorlangan operatsiyalar so'zlar chastotasini hisoblash, TF-IDF qiymatlarini aniqlash va o'xshashlikni baholashda qo'llaniladi. Matn vektorlarga aylantiriladi va ustida matematik operatsiyalar bajariladi. Bu yondashuv tabiiy tilni qayta ishlash vazifalarini tezlashtiradi.

Vaqt qatorlarini tahlil qilishda vektorlangan operatsiyalar o'rtacha qiymatlarni hisoblash, tendensiyalarni aniqlash va bashoratlash uchun ishlatiladi. Moliyaviy ma'lumotlar, ob-havo ma'lumotlari, sensor ma'lumotlari kabi vaqt qatorlari bilan ishlashda samaradorlik muhim ahamiyat kasb etadi.

HISOBLASH SAMARADORLIGI VA OPTIMIZATSIYA

Vektorlangan hisoblashning asosiy maqsadi tezlik va samaradorlikni oshirishdir. Lekin maksimal samaradorlikka erishish uchun ba'zi prinsiplar va usullarni bilish zarur.

Xotira joylashuvi hisoblash tezligiga katta ta'sir ko'rsatadi. Ma'lumotlar xotirada ketma-ket joylashganda, protsessor kesh xotirasidan samarali foydalanadi. Keraksiz nusxalashdan qochish va ma'lumotlarni to'g'ri tartibda saqlash muhimdir. NumPy massivlari sukut bo'yicha C tartibida saqlanadi, bu ko'pchilik operatsiyalar uchun optimal hisoblanadi.

In-place operatsiyalar xotira sarfini kamaytiradi va tezlikni oshiradi. Yangi massiv yaratish o'rniga, mavjud massivni o'zgartirish samaraliroq. Lekin in-place operatsiyalar asl ma'lumotlarni o'zgartiradi, shuning uchun ehtiyotkorlik talab qiladi. Ba'zi hollarda asl ma'lumotlarni saqlash muhim va nusxalash zarur.

Broadcasting to'g'ri qo'llanganda juda samarali, lekin noto'g'ri ishlatilganda ortiqcha xotira sarfiga olib kelishi mumkin. Broadcasting qoidalarini tushunish va qachon u qo'llanishini bilish muhimdir. Ba'zan massivlarni oldindan to'g'ri shaklga keltirish foydaliroq bo'ladi.

Parallel hisoblash katta hajmli ma'lumotlar uchun zarurdir. NumPy ba'zi operatsiyalarda avtomatik parallel hisoblashdan foydalanadi, lekin ba'zi hollarda qo'lda parallellashtirish kerak. Joblib, Dask va boshqa kutubxonalar parallel hisoblash uchun qulay vositalar taqdim etadi.

TURLI ALGORITMLAR BILAN INTEGRATSIYA

Vektorlangan hisoblash, normallashtirish va standartlashtirish turli mashinali o'qitish algoritmlari bilan qanday integratsiya qilinishi muhim ahamiyat kasb etadi. Har bir algoritm o'zining talablariga ega va to'g'ri yondashuv samaradorlikni oshiradi.

Chiziqli regressiya va logistik regressiya standartlashtirishdan katta foyda ko'radi. Bu algoritmlar xususiyatlar bo'yicha og'irliklarni o'rganadi va turli shkalalardagi xususiyatlar noto'g'ri og'irliklarga olib keladi. Standartlashtirish gradient tushishni tezlashtiradi va regularizatsiyani to'g'ri ishlashini ta'minlaydi. L1 va L2 regularizatsiya standartlashtirilmagan ma'lumotlarda xususiyatlarni noto'g'ri jazolaydi.

Ensemble usullari, masalan stacking yoki blending, turli modellarni birlashtirishda normallashtirish muhim rol o'ynaydi. Har bir asosiy model turli shkalalarda bashoratlar berishi mumkin va ularni birlashtirish uchun standartlashtirish zarur. Meta-model kirish sifatida standartlashtirilgan bashoratlarni qabul qilganda yaxshiroq ishlaydi.

Vektorlangan hisoblash sohasida doimiy rivojlanish davom etmoqda va yangi texnologiyalar paydo bo'lmoqda. GPU hisoblash tobora kengroq qo'llanilmoqda va dasturchilar uchun qulayroq vositalar yaratilmoqda. CUDA va OpenCL kabi past darajali texnologiyalar o'rniga, yuqori darajali kutubxonalar mashhurlik qazanmoqda.

Tensor processing units zamonaviy mashinali o'qitishda muhim rol o'ynamoqda. TPU lar maxsus mashina o'qitish vazifalariga moslashtirilgan va juda yuqori samaradorlik ko'rsatadi. Bulutli platformalar TPU lardan foydalanish imkonini beradi va katta hajmli modellarni o'qitish osonlashmoqda.

Avtomatik normallashtirish va standartlashtirish vositalari rivojlanmoqda. AutoML tizimlari ma'lumotlarni tahlil qiladi va optimal normallashtirish usulini tanlaydi. Bu yondashuv tajribaga ega bo'lmagan foydalanuvchilar uchun foydalidir. Lekin professional loyihalarda qo'lda sozlash hali ham zarur.

XULOSA

Ushbu tadqiqot ishida vektorlangan hisoblash, normallashtirish va standartlashtirish usullarining nazariy asoslari, amaliy tatbiqlari va zamonaviy ma'lumotlarni qayta ishlashdagi roli to'liq tahlil qilindi. Olingan natijalar shuni ko'rsatdiki, bu usullar zamonaviy mashinali o'qitish va ma'lumotlar fanining fundamental elementlari hisoblanadi.

Vektorlangan hisoblash ma'lumotlarni qayta ishlash samaradorligini o'nlab va yuzlab marta oshiradi. SIMD texnologiyasi, xotira bilan samarali ishlash va kompilyator optimizatsiyalari tufayli vektorlangan operatsiyalar an'anaviy tsikllarga nisbatan juda tezroq ishlaydi. NumPy, Pandas va boshqa kutubxonalar ushbu texnologiyalardan foydalanib, dasturchilar uchun qulay interfeys taqdim etadi. Broadcasting konsepsiyasi kodning qisqaligini va o'qilishini ta'minlaydi.

Normallashtirish usullari turli xillari va har birining o'ziga xos qo'llanish sohalari aniqlandi. Min-Max normallashtirish oddiy va tushunarliroq bo'lsa-da, chetki qiymatlarga sezgir. Robast normallashtirish mediana va kvartillardan foydalanib, barqarorroq natijalar beradi. L1 va L2 normallashtirish vektorning yo'nalishini saqlaydi va matn tahlilida samarali. Logaritmik transformatsiya keng diapazonli ma'lumotlarni normallashtiradi.

Standartlashtirish statistik asoslarga ega bo'lib, ma'lumotlarni o'rtacha qiymati nol va standart og'ishi bir bo'lgan taqsimotga o'tkazadi. Bu usul gradient tushish algoritmlarida yaqinlashishni tezlashtiradi va chiziqli modellarda barcha xususiyatlarni teng sharoitga qo'yadi. Normal taqsimot bilan ishlashda standartlashtirish ayniqsa samarali va chetki qiymatlarni aniqlashga yordam beradi.

Turli mashinali o'qitish algoritmlari normallashtirish va standartlashtirish uchun turli talablarga ega ekanligi ko'rsatildi. Chiziqli modellar, qo'llab-vektor mashinalari va neyron tarmoqlari bu usullardan katta foyda ko'radi. K-nearest neighbors algoritmi uchun normallashtirish zarur. Daraxt asosidagi algoritmlar normallashtirish talab qilmaydi, lekin ba'zi hollarda foydalidir.

Amaliy dasturlarda to'g'ri yondashuvlar va eng yaxshi amaliyotlar tavsiya etildi. Ma'lumotlar oqib ketishining oldini olish, kross-validatsiyada to'g'ri qayta ishlash, yangi ma'lumotlar bilan ishlash va parametrlarni saqlash muhim jihatlari ta'kidlandi. Pipeline konsepsiyasi qayta ishlash bosqichlarini birlashtiradi va xatolar ehtimolini kamaytiradi.

Hisoblash samaradorligi masalalari va optimizatsiya usullari chuqur o'rganildi. Xotira joylashuvi, in-place operatsiyalar, parallel hisoblash va GPU dan foydalanish tezlikni oshirishning asosiy yo'llari hisoblanadi. Profiling vositalari kodning sekin qismlarini aniqlash va maqsadli optimizatsiya qilish imkonini beradi.

FOYDALANILGAN ADABIYOTLAR

1. Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Blondel M, Prettenhofer P, Weiss R, Dubourg V, Vanderplas J, Passos A, Cournapeau D, Brucher M, Perrot M, Duchesnay E. Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*. 2011; 12: 2825-2830.
2. Ioffe S, Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *International Conference on Machine Learning*. 2015; 448-456.
3. Paszke A, Gross S, Massa F, Lerer A, Bradbury J, Chanan G, Killeen T, Lin Z, Gimelshein N, Antiga L, Desmaison A, Kopf A, Yang E, DeVito Z, Raison M, Tejani A, Chilamkurthy S, Steiner B, Fang L, Bai J, Chintala S. PyTorch: An Imperative Style, HighPerformance Deep Learning Library. *Advances in Neural Information Processing Systems*. 2019; 32: 8024-8035.
4. Abadi M, Barham P, Chen J, Chen Z, Davis A, Dean J, Devin M, Ghemawat S, Irving G, Isard M, Kudlur M, Levenberg J, Monga R, Moore S, Murray DG, Steiner B, Tucker P, Vasudevan V, Warden P, Wicke M, Yu Y, Zheng X. TensorFlow: A System for LargeScale Machine Learning. *USENIX Symposium on Operating Systems Design and Implementation*. 2016; 265-283.
5. Van Der Walt S, Colbert SC, Varoquaux G. The NumPy Array: A Structure for Efficient Numerical Computation. *Computing in Science & Engineering*. 2011; 13(2): 22-

30.

6. Géron A. Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media. 2019.
7. Goodfellow I, Bengio Y, Courville A. Deep Learning. MIT Press. 2016.
8. Tojimamatov, I. N., & Saidjamolova, B. M. (2023). BIZNESDA «BIG DATA» TEXNOLOGIYALARI VA ULARNING AHAMIYATI. Лучшие интеллектуальные исследования, 11(4), 56–63.
9. Tojimamatov, I. N., & Azizjon o'g'li, N. A. Z. (2024). The SQL server language and its structure. American Journal of Open University Education, 1(1), 11–15.
10. Tojimamatov, I. N., Topvoldiyeva, H., Karimova, N., & Inomova, G. (2023). GRAFIK MA'LUMOTLAR BAZASI. Евразийский журнал технологий и инноваций, 1(4), 75–84.
11. Tojimamatov, I. N., & Gulhayo, M. (2023). MA'LUMOTLARNI QAYTA ISHLASHDA ERP TIZIMLARI. MA'LUMOTLARNI QAYTA ISHLASHDA SAP TIZIMLARI. Journal of Integrated Education and Research, 2(4), 87–89.