

VEKTORLANGAN HISOBLASH, NORMALLASHTIRISH VA STANDARTLASHTIRISH

Mirsaid Yusupov Abdulaziz o'g'li

*Farg'ona davlat universiteti Amaliy matematika
va informatika kafedrası o'qituvchisi*

E-mail: mirsaidbeky@gmail.com

Botiriva Maftuna Alisher qizi

*Farg'ona davlat universiteti Amaliy matematika
yo'nalishi 3-bosqich 23.07-guruh talabasi*

E-mail: xmmf1183@gmail.com

Annotatsiya: Bu ilmiy maqola Vektorlangan hisoblash, Normalizatsiya va Standartlashtirishning nazariy asoslari hamda amaliy qo'llanilishiga bag'ishlangan. Asosiy e'tibor, ma'lumotlarni oldindan qayta ishlashning ushbu usullari sun'iy intellekt tizimlarining samaradorligi va barqarorligini oshirishdagi hal qiluvchi rolini tahlil qilishga qaratilgan. Vektorlash jarayoni yirik hajmli ma'lumotlar to'plamlarini parallel va tezkor qayta ishlash imkoniyatini beruvchi hisoblash paradigmlarining rivojlanishidagi asosiy omil sifatida ko'rib chiqiladi. Normalizatsiya va standartlashtirish usullari, ayniqsa, turli masshtabdagi va tarqalishdagi xususiyatlar mavjud bo'lganda, gradient tushish kabi optimallashtirish algoritmlarining yaqinlashish tezligi va aniqligiga qanday ta'sir qilishini chuqur ilmiy tahlil qiladi. Maqolada ushbu uch kontseptsiya orasidagi o'zaro bog'liqlik ko'rsatilib, ular Mashinani o'rganish modellarining sifatini oshirish uchun birgalikda qo'llanilishi lozim bo'lgan kompleks yondashuv sifatida asoslab beriladi.

Kalit so'zlar: Vektorlangan hisoblash, Normalizatsiya, Standartlashtirish, Mashinani o'rganish, Ma'lumotlarni oldindan qayta ishlash, Sun'iy intellekt.

Abstract: This scholarly article is dedicated to the theoretical underpinnings and practical applications of Vectorized Computation, Normalization, and Standardization. The primary focus is on analyzing the crucial role these data preprocessing techniques play in enhancing the efficiency and stability of artificial intelligence systems. The vectorization process is examined as a key driver in the evolution of computational paradigms, enabling the parallel and rapid processing of large datasets. The paper provides an in-depth scientific analysis of how normalization and standardization methods influence the convergence speed and accuracy of optimization algorithms, such as gradient descent, particularly in the presence of features with varying scales and distributions. It demonstrates the interconnectedness of these three concepts, arguing for a complex approach where they are jointly applied to significantly improve the quality of Machine Learning models.

Keywords: Vectorized Computation, Normalization, Standardization, Machine Learning, Data Preprocessing, Artificial Intelligence.

Аннотация: Данная научная статья посвящена теоретическим основам и практическому применению Векторизованных вычислений, Нормализации и Стандартизации. Основное внимание уделено анализу критической роли, которую эти методы предобработки данных играют в повышении эффективности и устойчивости систем искусственного интеллекта. Процесс векторизации рассматривается как ключевой фактор развития вычислительных парадигм, позволяющий параллельно и быстро обрабатывать крупномасштабные наборы данных. В работе представлен углубленный научный анализ того, как методы нормализации и стандартизации влияют на скорость сходимости и точность алгоритмов оптимизации, таких как градиентный спуск, особенно при наличии признаков с различными масштабами и распределениями. Статья демонстрирует взаимосвязь этих трех концепций, обосновывая комплексный подход, при котором они применяются совместно для существенного улучшения качества моделей машинного обучения.

Ключевые слова: Векторизованные вычисления, Нормализация, Стандартизация, Машинное обучение, Предобработка данных, Искусственный интеллект.

Kirish

Zamonaviy Ma'lumotlar Ilmi (Data Science) va Sun'iy Intellect (Artificial Intelligence) sohalarining jadal rivojlanishi ma'lumotlarni qayta ishlashning tezkor va barqaror usullariga bo'lgan talabni yanada kuchaytirdi. Hozirgi kunda modellar o'rganayotgan ma'lumotlar to'plamining hajmi misli ko'rilmagan darajada o'sib bormoqda, bu esa hisoblash samaradorligi va optimallashtirish barqarorligini ta'minlovchi chuqur fundamental yondashuvlarni talab qiladi. Ushbu ilmiy ish, aynan shu ikki asosiy yo'nalishni qamrab oluvchi, ya'ni Vektorlangan Hisoblashning tezlikni oshirishdagi rolini hamda Normalizatsiya va Standartlashtirishning modelning aniqligi va barqarorligini ta'minlashdagi markaziy ahamiyatini tahlil qiladi.

Vektorlangan hisoblash — bu ma'lumotlarni parallel ravishda qayta ishlashga imkon beruvchi hisoblash paradigmalarining asosi bo'lib, xususan, neyron tarmoqlarni o'qitishda muhim hisoblanadi. U matrisali algebra va tenzor amallaridan samarali foydalanishga asoslanadi, bu esa markaziy protsessor (CPU) va, ayniqsa, grafik protsessor (GPU) resurslaridan maksimal darajada foydalanishni ta'minlaydi.

Biroq, faqat tezlikning o'zi yetarli emas. Mashinani o'rganish modellarining optimallashtirish jarayoni ma'lumotlarning sifatiga va xususiyatlarning taqsimlanishiga nihoyatda sezgir. Xususiyatlar (features) turli masshtablarga yoki o'rtacha qiymatlarga ega bo'lganda, gradient tushish (Gradient Descent)

algoritmalarining yaqinlashishi sekinlashadi yoki beqaror bo'lib qoladi. Aynan shu nuqtada Normalizatsiya va Standartlashtirish usullari hal qiluvchi rol o'ynaydi. Ular ma'lumotlar masshtabini yagona tizimga keltirib, optimallashtirishning samarali kechishini ta'minlaydi.

Ushbu maqolaning maqsadi vektorlangan hisoblashni ma'lumotlarni oldindan qayta ishlashning ushbu ikki usuli bilan qanday qilib birgalikda qo'llash orqali, Mashinani o'rganish tizimlarining umumiy samaradorligini sifat jihatidan yangi bosqichga ko'tarish mexanizmlarini chuqur ilmiy asoslashdan iborat. Keyingi qismlarda har bir kontsepsiya nazariy va amaliy jihatdan batafsil tahlil qilinadi.

Asosiy Qism

Vektorlangan hisoblash an'anaviy siklli (loop-based) hisoblashga zid ravishda, bir vaqtning o'zida bir nechta ma'lumot elementlariga bitta amaliyotni qo'llashga asoslangan. Bu yondashuv, ayniqsa, chiziqli algebra (Linear Algebra) amallari keng qo'llaniladigan chuqur o'rganish (Deep Learning) modellarida juda muhimdir.

eyron tarmoqdagi bitta qatlamdagi neyronlarning kirish qiymatlarini hisoblash amali odatda matritsani matritsaga ko'paytirish (Matrix Multiplication) amali bilan amalga oshiriladi. Vektorlash orqali, millionlab hisoblashlar bir vaqtning o'zida, parallel konveyerlarda (pipelinelarda) bajariladi. Bu jarayon GPU kabi ixtisoslashgan apparat ta'minotining arxitekturasiga juda mos keladi, bu yerda minglab kichik yadro (core) mavjud bo'ladi.

Vektorlash nafaqat tezlikni, balki kodning o'qilishi va qisqaligini ham oshiradi, an'anaviy ichki sikllar o'rniga yuqori darajadagi kutubxona funksiyalaridan foydalanish imkonini beradi. Bu Mashinani o'rganish tadqiqotchilari uchun katta hajmli algoritmarni samarali boshqarishda juda qulaylik yaratadi.

Normalizatsiya va Standartlashtirish ma'lumotlar to'plamining sifatini oshirish va uning modelga ta'sirini optimallashtirish uchun zaruriy qadamdir. Modellar turli birliklarga (masalan, yoshi yillar bilan, daromadi ming so'm bilan o'lchangan) ega bo'lgan xususiyatlar bilan ishlayotganda, kattaroq masshtabga ega bo'lgan xususiyatlar modelning xato funksiyasiga (loss function) nomutanosib ravishda ko'proq ta'sir qiladi.

Normalizatsiya (yoki Min-Max masshtablash) ma'lumotlarning barcha qiymatlarini belgilangan oraliqqa, odatda noldan birgacha bo'lgan oralig'iga transformatsiya qilishni o'z ichiga oladi. Normalizatsiyaning asosiy maqsadi, xususiyatlarning eng kichik va eng katta qiymatlari o'rtasidagi farqni bartaraf etib, ularni bir xil maydonga joylashtirishdir. Bu, xususan, K-Eng Yaqin Qo'shni (K-Nearest Neighbors) kabi masofaga asoslangan algoritmalar uchun muhimdir. Biroq, bu usul ma'lumotlar to'plamida o'ta chekka qiymatlar (outliers) mavjud bo'lsa, juda sezgir bo'lib, barcha qolgan ma'lumotlarning tarqalishini siqib qo'yishi mumkin.

Standartlashtirish (yoki Z-qiymati masshtablash) ma'lumotlarning o'rtacha qiymatini nolga va standart og'ishini birga tenglashtirishni maqsad qiladi.

Standartlashtirish orqali, biz xususiyatlarning taqsimlanish shaklini saqlab qolgan holda, ularni yagona birlikda ifodalaymiz. Bu usul o'ta chekka qiymatlarga nisbatan Normalizatsiyaga qaraganda ancha chidamli hisoblanadi, chunki u ma'lumotlarni belgilangan maksimal va minimal qiymatlarga cheklamaydi. Standartlashtirish ayniqsa, gradientga asoslangan optimallashtirish usullari (masalan, neyron tarmoqlarda) qo'llanilganda muhimdir, chunki u optimallashtirish yuzasini simmetrikroq va dumaloqroq shaklga keltiradi, bu esa gradient tushishning tezroq va silliqroq yaqinlashishini ta'minlaydi.

Eng samarali Mashinani o'rganish quvurlari (pipelines) vektorlangan hisoblash samaradorligi bilan normallashtirish/standartlashtirishning barqarorligini birlashtiradi. Uchinchi, Normalizatsiya va Standartlashtirish jarayonlarining o'zi ham vektorlangan operatsiyalar sifatida amalga oshiriladi. Ma'lumotlar to'plamining o'rtacha qiymati va standart og'ishini hisoblash, so'ngra barcha ma'lumot nuqtalariga bu transformatsiyalarni qo'llash matritsali amallar sifatida ifodalanadi. Bu yondashuv, yirik ma'lumotlar to'plamlarida oldindan qayta ishlashni amalda bir zumda bajarish imkonini beradi. Natijada, hisoblash tezligi (vektorlashdan olingan) optimallashtirishning barqarorligi va aniqligi (normalizatsiya/standartlashtirishdan olingan) bilan uyg'unlashadi.

Standartlashtirilmagan xususiyatlar bilan ishlashda, xato funksiyasi (Loss Function) ning yuzasi ellips yoki cho'zilgan vodiy shaklida bo'ladi. Bunday shakldagi yuzada gradient tushish algoritmi minimumga yetish uchun juda ko'p qadam tashlashi kerak bo'ladi, chunki u eng tik tushish yo'nalishi (tez gradient) bo'ylab harakatlanadi, ammo bu yo'nalish har doim ham umumiy minimum tomon yo'naltirilmaydi. Natijada, optimallashtirish yo'li zig-zag ko'rinishida bo'lib, konvergenstiya juda sekinlashadi.

Standartlashtirishdan so'ng, xususiyatlarning dispersiyalari (standart og'ish) birga yaqinlashadi, bu esa xato yuzasini sharsimon (yoki dumaloq) shaklga yaqinlashtiradi. Sharsimon yuzada gradient to'g'ridan-to'g'ri minimum tomon yo'naltiriladi, bu esa optimallashtirish qadamlari sonini tubdan kamaytiradi. Natijada, o'rganish jarayoni tezkor va barqaror bo'ladi. Bu effekt ayniqsa, o'rganish tezligi (learning rate) yuqori bo'lgan paytlarda o'zini yaqqol ko'rsatadi, chunki standartlashtirilgan ma'lumotlar modelning kattaroq qadamlar bilan beqarorlikka tushib qolish xavfini kamaytiradi.

Ushbu bo'limda vektorlangan hisoblashning amaliy jihatlari, xususan, yirik hajmli ma'lumotlar (Big Data) muhitida turli hisoblash platformalari orqali qanday amalga oshirilishi tahlil qilinadi. Zamonaviy Mashinani o'rganish kutubxonalari (masalan, NumPy, TensorFlow, PyTorch) ma'lumotlarni qayta ishlashda xotira-samarador (memory-efficient) tenzorlar (ko'p o'lchovli massivlar) dan foydalanadi. Ma'lumotlarni avval Standartlashtirishdan o'tkazish va uni tenzor formatida saqlash, model o'rganish jarayonida Vektorlangan Hisoblashning to'liq salohiyatidan

foydalanishga imkon beradi. Bu, o'z navbatida, kirish ma'lumotlarini o'qish va yozish vaqtini kamaytirish orqali umumiy ish jarayonining samaradorligini oshiradi.

Yirik ma'lumotlar to'plamlarini qayta ishlashda taqsimlangan hisoblash (Distributed Computing) paradigmalaridan foydalaniladi. Bunday sharoitlarda, ma'lumotlar bir nechta klasterlar yoki qurilmalar o'rtasida taqsimlanadi. Normalizatsiya va Standartlashtirishni amalga oshirish uchun avval butun ma'lumot to'plamining global o'rtacha qiymati va global standart og'ishi hisoblanishi kerak. Vektorlangan hisoblash usullari aynan shu global statistik ko'rsatkichlarni taqsimlangan muhitda tezkor va aniq hisoblash imkonini beradi. Bu esa har bir taqsimlangan tugunda (node) qayta ishlashni izchil va samarali olib borish uchun asos yaratadi.

Ma'lumotlarni masshtablashning zarurati faqat Gradient Tushishga asoslangan modellar bilan cheklanib qolmay, balki turli Mashinani O'rganish arxitekturalarining ichki mexanizmlariga ham bevosita ta'sir ko'rsatadi. Masofaga asoslangan algoritmlar, masalan, K-Eng Yaqin Qo'shni (K-NN) yoki K-O'rtaliklar Klasterlashi (K-Means), ayniqsa standartlashtirish yoki normalizatsiyaga o'ta sezgirdir. Agar ma'lumotlar masshtablanmagan bo'lsa, ma'lum bir xususiyatning kattaroq qiymatlari boshqa xususiyatlarning kichik o'zgarishlariga nisbatan Evklid masofasini hisoblashda nomutanosib ravishda ustunlik qiladi. Bu esa masofa metrikasining ma'lumotlardagi muhim o'zgarishlarni emas, balki faqat o'lchov birligidagi farqlarni aks ettirishiga olib keladi. Binobarin, bu turdagi algoritmlarda ma'lumotlarni masshtablash, ayniqsa Normalizatsiya (Min-Max) muhim, chunki u barcha xususiyatlarning masofa hisoblashda teng darajada ishtirok etishini ta'minlaydi.

Boshqa tomondan, Qaror Daraxtlari (Decision Trees) va Tasodifiy O'rmonlar (Random Forests) kabi yog'ochga asoslangan modellar, masshtablashga nisbatan ancha befarqdir. Chunki bu modellar ajratish nuqtalarini aniqlash uchun Gini Nopokligi yoki Axborot Oqimi kabi metrikalardan foydalanadi, ular esa xususiyatlarning o'zining mutlaq qiymatiga emas, balki ularning ichki tartiblanishiga va ma'lumotlarni qanday ajratishiga bog'liqdir. Shunday bo'lsa-da, ba'zi optimallashtirilgan ilovalar va Gradientni Kuchaytirish (Gradient Boosting) kabi murakkab ansambl usullarini samaraliroq hisoblash uchun ma'lumotlarni avval vektorlangan holda qayta ishlash va masshtablash (Standartlashtirish) jarayonlarini qo'llash hisoblash tezligini oshirishi mumkin, bu esa katta massivlar bilan ishlashda katta amaliy afzallik beradi.

Zamonaviy Chuqur O'rganish (Deep Learning) tizimlari asosan Tenzorlar (ko'p o'lchovli massivlar) muhitida ishlaydi, bu yerda Vektorlangan Hisoblash nafaqat tezlikni ta'minlaydi, balki arxitekturaning o'zi uchun ham fundamental hisoblanadi. Tenzorli hisoblash kutubxonalari (masalan, TensorFlow va PyTorch) ichki jihatdan apparat ta'minotining o'zida (ayniqsa, GPU larda) bir vaqtning o'zida minglab elementlar ustida bir xil arifmetik amallarni bajarishga mo'ljallangan.

Bu yerda Standartlashtirish jarayoni muhim ahamiyat kasb etadi, chunki katta ma'lumotlar to'plamini to'g'ridan-to'g'ri qayta ishlash o'rniga, model ko'pincha kichik to'plamlar (mini-batches) da o'qitiladi. Shuning uchun, har bir kichik to'plamdagi ma'lumotlar to'plamning umumiy taqsimlanishiga qarab normalizatsiya qilinishi kerak. To'plamni Normalizatsiyalash (Batch Normalization) deb nomlangan usul aynan shu muammoni hal qiladi: u neyron tarmoqning har bir qatlamidagi chiqishlarni (aktivatsiyadan oldin yoki keyin) o'rtacha qiymati nol va standart og'ishi birga teng bo'lishini ta'minlaydi. Bu jarayonning o'zi ham yuqori darajada vektorlangan bo'lib, har bir kichik to'plamning statistik ko'rsatkichlarini tezkor hisoblash va ularni darhol transformatsiya qilish imkonini beradi. To'plamni Normalizatsiyalash nafaqat optimallashtirishni tezlashtiradi, balki o'rganish tezligini yuqoriroq o'rnatishga imkon beradi va shu bilan birga, tarmoqning o'ta moslashish (overfitting) ehtimolini kamaytiradi.

Vektorlangan hisoblash faqat hisoblash tezligini oshirish vositasi emas, balki murakkab matematik funksiyalarni samarali shaklda ifodalash usuli hamdir. Mashinani O'rganish algoritmlaridagi Xato Funksiyasi (Loss Function) va Gradient hisoblash amallari, avvalo, bir nechta individual elementlarga ketma-ket qo'llaniladigan amallardan iborat bo'lgan. Vektorlangan yondashuv ushbu barcha amallarni bitta matritsa operatsiyasiga aylantiradi.

Masalan, Chiziqli Regressiya modelidagi bashoratlarni o'z ichiga olgan oddiy ko'paytmani barcha ma'lumot nuqtalari uchun bitta ichki ko'paytma (Dot Product) amali orqali ifodalash mumkin. Bu matematik soddalashtirish, dasturlash tilida bitta qator kodga to'g'ri keladi va apparat ta'minotida esa millionlab hisoblashlarni bir vaqtning o'zida parallel bajarishni ta'minlaydi. Bu, ayniqsa, Teskari Tarqalish (Backpropagation) algoritmini amalga oshirishda juda muhimdir, bu yerda gradientlar barcha og'irliklar va siljishlar bo'yicha hisoblanadi. Vektorlangan Gradientlarni tezkor hisoblash va yangilash, butun o'rganish jarayonining vaqtini sezilarli darajada qisqartiradi, bu esa Chuqur Neyron Tarmoqlarni amaliy jihatdan o'qitish mumkinligini ta'minlaydi. Shunday qilib, vektorlash matematik nazariyani amaliy hisoblash samaradorligi bilan bog'laydigan asosiy ko'prikdir.

Standartlashtirish usulining Normalizatsiyaga nisbatan afzalligi, uning o'ta chekka qiymatlarga (outliers) chidamliligida namoyon bo'ladi, garchi bu usul ham mutlaq immunitetga ega bo'lmasa-da. Ma'lumotlar to'plamidagi bir nechta juda katta yoki juda kichik qiymatlar o'rtacha qiymatni sezilarli darajada siljitib, standart og'ishning nomutanosib ravishda kattalashishiga olib kelishi mumkin. Bu esa, o'z navbatida, o'ta chekka bo'lmagan, muhim ma'lumot nuqtalarining standartlashtirilgan qiymatlari nolga yaqin siqilib qolishiga olib keladi. Natijada, ushbu ma'lumotlarning modelni o'qitishdagi differensial ta'siri sezilarli darajada kamayadi.

Bunday hollarda, standartlashtirishning muqobil variantlari, masalan, Robust Masshtablash (Robust Scaling) usuli qo'llanilishi ilmiy nuqtai nazardan afzal ko'riladi. Robust Masshtablash ma'lumotlarni o'rtacha qiymat sifatida Median (o'rta qiymat) va dispersiya o'lchovi sifatida Kvintillararo Oraliq (Interquartile Range, IQR) yordamida markazlashtiradi. Bu usullar o'ta chekka qiymatlarga nisbatan ancha mustahkam bo'lib, ular taqsimotning asosiy qismini buzmaydi. Vektorlangan hisoblash bu murakkab statistik ko'rsatkichlarni, ayniqsa katta hajmli ma'lumotlar bilan ishlashda, tezkor va samarali hisoblash imkonini beradi.

Mashinani o'rganish quvuridagi ajralmas qadam, ma'lumotlarni qayta ishlashdan so'ng, modelning chiqish natijalarini teskari masshtablash (Inverse Scaling) orqali asl o'lchov birligiga qaytarishdir. Aksariyat hollarda, bizning modellarimiz masshtablangan xususiyatlar bo'yicha bashorat qiladi, ammo natijalarning amaliy qiymati va talqin qilinishi asl o'lchov birligida namoyish etilgandagina tushunarli bo'ladi.

Standartlashtirish yoki Normalizatsiya jarayonida qo'llanilgan transformatsiya parametrlarini (o'rtacha qiymat, standart og'ish, minimal va maksimal qiymatlar) saqlab qo'yish zarur. Chunki teskari transformatsiya faqat ma'lumotlarni masshtablashda ishlatilgan aniq qiymatlar bilan amalga oshirilgandagina model bashoratlarning aniqligi ta'minlanadi. Agar xato transformatsiya parametrlari ishlatilsa, modelning yuqori aniqlikdagi bashorati ham amalda noto'g'ri talqin qilinishiga olib keladi. Bu jarayon, ya'ni teskari transformatsiya, ham yuqori darajada vektorlangan bo'lishi kerak, ayniqsa minglab bashoratlar bir vaqtning o'zida talqin qilinishi talab etiladi. Vektorlangan teskari masshtablash nafaqat tezlikni ta'minlaydi, balki bashoratlar to'plamidagi har bir elementning izchil va bir xil uslubda asl o'lchovga qaytarilishini ham kafolatlaydi.

Normalizatsiya va Standartlashtirish faqat mavjud xususiyatlarning masshtabini o'zgartirishdan iborat emas; ular Xususiyatlarni Loyihalash (Feature Engineering) jarayonining samaradorligiga ham bevosita ta'sir ko'rsatadi. Yangi xususiyatlar (masalan, ikkita mavjud xususiyatning nisbati yoki logarifmi) yaratilganda, ularning masshtabi va taqsimlanishi mutlaqo oldindan aytib bo'lmaydigan darajada o'zgarishi mumkin.

Ba'zi Transformatsiyalar, masalan, Logarifmik Transformatsiya ko'pincha qiyshiq taqsimlangan (skewed distribution) ma'lumotlarni Normal Taqsimotga yaqinlashtirish uchun qo'llaniladi. Bunday holda, ma'lumot avval logarifmik transformatsiya qilinadi, so'ngra Standartlashtirishga duchor qilinadi. Bunday kompleks yondashuv modelga ma'lumotlardan yashirin munosabatlarni aniqroq o'rganishga yordam beradi.

Vektorlangan hisoblash imkoniyatlari Xususiyatlarni Avtomatik Loyihalash (Automated Feature Engineering) usullarini qo'llashda hal qiluvchi ahamiyatga ega.

Bu usullar milliardlab potentsial xususiyatlarni tezkor sinovdan o'tkazishni talab qiladi. Har bir yangi yaratilgan xususiyat to'plami qayta masshtablash (Standartlashtirish)dan o'tkazilishi lozim. Bu jarayonlarning barchasi vektorlangan operatsiyalar sifatida amalga oshirilishi kerak, aks holda bu turdagi murakkab va takrorlanuvchi jarayonlar hisoblash vaqti nuqtai nazaridan amaliyotda foydali bo'lmaydi. Demak, bu uch konsepsiya — vektorlash, normallashtirish va standartlashtirish — nafaqat ma'lumotlarni oldindan qayta ishlashning shartlari, balki Mashinani O'rganish modelining samaradorligini doimiy oshirib borishning zaruriy birlashmasidir.

Xulosa

Ushbu ilmiy maqola Vektorlangan hisoblash, Normalizatsiya va Standartlashtirishning zamonaviy Mashinani o'rganish modellarini yaratishdagi ajralmas va bir-birini to'ldiruvchi ahamiyatini chuqur tahlil qildi.

Vektorlangan hisoblash — bu yuqori samarali hisoblash uchun asos bo'lib, ma'lumotlar hajmining ortib borishi sharoitida modellarimizni o'qitish va ishlatish tezligini ta'minlaydi. U sun'iy intellekt tizimlarining vaqt talab qiluvchi hisoblashlarining amaliy jihatdan mumkin bo'lishining kalitidir.

Shu bilan birga, Normalizatsiya va Standartlashtirish ma'lumotlarning xususiyatlar o'rtasidagi masshtab farqlarini bartaraf etish orqali modelning nazariy jihatdan barqaror va amalda aniq bo'lishini ta'minlovchi zaruriy qadamlardir. Xususan, Standartlashtirish gradient tushish kabi murakkab optimallashtirish jarayonlarining tezroq va samarali yaqinlashishini ta'minlaydi.

Ushbu uchta kontsepsiya birgalikda qo'llanilganda, ya'ni vektorlangan operatsiyalar yordamida tezkor standartlashtirilgan ma'lumotlar bilan ishlovchi modellar yaratilganda, Mashinani o'rganish tizimlarining umumiy ishlash ko'rsatkichlari sezilarli darajada yaxshilanadi. Bu yondashuv yirik hajmdagi ma'lumotlar bilan samarali ishlash va yuqori aniqlikdagi, barqaror sun'iy intellekt yechimlarini yaratish uchun fundamental shart hisoblanadi.

Foydalanilgan Adabiyotlar

1. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. (Chuqur o'rganish, vektorlangan hisoblash va optimallashtirish asoslari bo'yicha fundamental manba).
2. Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer. (Statistik o'rganish va ma'lumotlarni oldindan qayta ishlash nazariyasi bo'yicha klassik asar).
3. Lecun, Y., Bottou, L., Orr, G. B., & Müller, K. R. (2012). *Efficient BackProp*. In *Neural Networks: Tricks of the Trade* (pp. 9–48). Springer. (Gradientga asoslangan optimallashtirish va uning normallashtirishga bog'liqligi haqida).

4. Chollet, F. (2017). *Deep Learning with Python*. Manning Publications. (Vektorlangan hisoblashning amaliy qo'llanilishi va mashinani o'rganish quvurlari bo'yicha).
5. Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer. (Ma'lumotlar taqsimlanishi va standartlashtirishning matematik asoslari).