

UO'K 004.8, 004.93

AN'ANAVIY STATISTIK VA CHUQUR O'QITISHGA ASOSLANGAN BELGI AJRATISH USULLARI

⁺*Yusupov O.R.¹, Xandamov Y.X.², Xojiakbarov Sh.M.²*

¹ Sharof Rashidov nomidagi Samarqand davlat universiteti, Samarqand, O'zbekiston

² Raqamli texnologiyalar va sun'iy intellektni rivojlantirish ilmiy-tadqiqot instituti, Toshkent, O'zbekiston

⁺ ozodyusupov@gmail.com

Annotatsiya. Maqolada belgi ajratish va o'lchamni qisqartirishga oid to'rtta muhim usul – fisher diskriminant tahlili (FDA), kanonik korrelyatsion tahlil (CCA), chuqur kanonik korrelyatsion tahlil (DCCA) va chuqur ko'p to'plamli kanonik korrelyatsion tahlil (DMCCA) nazariy va amaliy jihatdan qiyosiy tahlil qilingan. Har bir usulning nazariy asoslari, afzalliklari va kamchiliklari batafsil bayon etilgan. Shuningdek, ularning turli sohalardagi qo'llanish imkoniyatlari keltirilgan. Tahlillar shuni ko'rsatadiki, FDA nazoratli o'rganishda samarali bo'lsa, CCA ikki manba orasidagi bog'liqliklarni o'rganishda muhim vositadir. DCCA klassik yondashuvlarni chuqur o'qitish orqali kengaytirib, chiziqlimas strukturalarni ham aniqlash imkonini beradi. DMCCA esa ko'p manbali ma'lumotlar uchun umumiy latent reprezentatsiya shakllantiriladi va zamonaviy sun'iy intellekt tizimlarida yuqori samaradorlik namoyon etadi.

Kalit so'zlar: belgi ajratish, o'lchamni qisqartirish, FDA, CCA, DCCA, DMCCA, latent reprezentatsiya, statistik usullar, chuqur o'qitish, multimodal ma'lumotlar.

1 KIRISH

Statistik belgi ajratish usullari (feature extraction) – bu yuqori o'lchamli ma'lumotlarni kichikroq o'lchamli fazoga proyeksiya qilish va ulardan eng muhim hamda mazmunli belgilarni aniqlab olishga qaratilgan usullar majmuasidir [1, 2]. Ushbu yondashuv mashinaviy o'qitish, ma'lumotlarni intellektual tahlil qilish, ma'lumotlarni qayta ishlash va timsollarni tanib olish tizimlarida muhim ahamiyat kasb etadi. Maqbul belgilarni ajratib olish hisoblash murakkabligini kamaytiradi, klassifikatorlarning aniqligini oshiradi hamda ma'lumotlar tuzilishini yanada chuqur tahlil qilish imkonini beradi. Belgilarni ajratish jarayoni ma'lumotlarning o'lchamini qisqartiradi [3]. Bu esa modellarning ishlash tezligini oshiradi va samaradorligini ta'minlaydi. Masalan, tasvirlar, matnlar yoki sensor ma'lumotlari kabi ko'p manbali katta hajmdagi ma'lumotlarda belgi ajratish usullari orqali murakkab va yuqori o'lchamli axborot ixchamroq hamda mazmunli fazoga proyeksiya qilinadi. Bu jarayon modellarning ishlash tezligi va aniqligini oshirib, umumlashish qobiliyatini yaxshilaydi [4-6].

Belgi ajratish usullari nazoratli (supervised) va nazoratsiz (unsupervised) yondashuvlarga bo'linadi [7-10]. Nazoratli belgi ajratish usullari sinf yorliqlarini inobatga olib, belgilar orasidagi sinflarni ajratuvchi farqlarni hisobga oladi. Nazoratsiz belgi ajratish usullari esa sinf yorliqlaridan foydalanmay, ma'lumotlarning ichki strukturasi (masalan, kovariatsiya, korrelyatsiya yoki umumiy dispersiya) o'rganishga qaratilgan. Masalan, bosh komponentalar tahlili (PCA – Principal Component Analysis) sinf yorliqlaridan foydalanmasdan ma'lumotning umumiy dispersiyasini maksimal aks ettiruvchi yo'nalishlarni aniqlaydi [11, 12]. Aksincha, chiziqli diskriminant tahlil (LDA/FDA – Linear/Fisher Discriminant Analysis) sinfga oid ma'lumotlarni e'tiborga olib, sinflar orasidagi farqni maksimal darajada oshirishga qaratiladi [13]. Agar ma'lumot turli ko'rinishlarda yoki manbalardan olingan bo'lsa, Kanonik korrelyatsion tahlil (CCA – Canonical Correlation Analysis) qo'llanadi. Ushbu usul ikki yoki undan ortiq ma'lumot to'plami o'rtasidagi umumiy yashirin bog'liqliklarni aniqlashga yordam beradi [14-17].

Ushbu maqolada to'rtta asosiy statistik belgi ajratish usullarining nazariy o'rganilishi va tahlili taqdim etiladi: FDA (Fisher diskriminant tahlil), CCA (kanonik korrelyatsion tahlil), DCCA (chuqur kanonik korrelyatsion tahlil) va DMCCA (chuqur ko'p to'plamli kanonik korrelyatsion tahlil). Har bir usulning matematik asosi, ishlash prinsipi, afzalliklari hamda kamchiliklari izchil yoritiladi.

2 USULLAR TAHLILI

Fisher diskriminant tahlil (FDA – Fisher Discriminant Analysis) – nazoratli o‘qitishga asoslangan chiziqli belgilar ajratish usuli bo‘lib, uning asosiy maqsadi turli sinflar orasidagi farqni maksimalashtirishdan iborat. Ushbu usul ma’lumotlarni shunday optimal chiziqli kombinatsiya bo‘yicha proyeksiyalaydiki, natijada sinflararo masofa eng yuqori, har bir sinf ichidagi masofa esa eng past darajaga keltiriladi. Boshqacha aytganda, FDA sinflararo dispersiyani maksimalashtirishga va ayni paytda sinf ichidagi dispersiyani minimallashtirishga intiladi. Shu tariqa, yuqori o‘lchamli belgilar fazosidan kichikroq o‘lchamli yangi fazoga o‘tish orqali sinflarni yanada aniqroq ajratish imkoniyati yaratiladi. Bu esa keyingi tahlil va tasniflash jarayonlarini samaraliroq qilishga xizmat qiladi [18, 19].

Fisher diskriminant tahlilida ma’lumotlar ikki o‘lchamli fazodan bitta chiziqqa proyeksiya qilinadi. Bundan maqsad shundan iboratki, proyeksiyalangan fazoda turli sinflarning o‘rtacha nuqtalari orasidagi masofa maksimal, har bir sinf ichidagi tarqoqlik (dispersiya) esa minimal bo‘lishi talab etiladi. Shu shartni ta’minlovchi optimal yo‘nalish aniqlanganda, ikki sinfni eng samarali ajratadigan chiziq topiladi.

Ikki sinfli holatda Fisher diskriminant tahlili maqsad funksiyasi sifatida Fisher mezonidan foydalanadi. Ushbu mezon quyidagi nisbatni maksimal qilishga qaratilgan,

$$J(w) = \frac{w^T S_B w}{w^T S_W w},$$

bu yerda, w – proyeksiya yo‘nalishini ifodalovchi birlik vektor, S_B – sinflararo kovariatsiya matritsasi, S_W esa sinf ichidagi kovariatsiya matritsasi. Ular ko‘rinishida aniqlanadi:

$$S_B = \sum_{i=1}^C n_i (\mu_i - \mu)(\mu_i - \mu)^T, \quad S_W = \sum_{i=1}^C \sum_{x \in D_i} (x - \mu_i)(x - \mu_i)^T,$$

bu yerda, C – sinflar soni, n_i – i -sinfidagi obyektlar soni, D_i – i -sinfga tegishli obyektlar to‘plami, μ_i – i -sinfning o‘rtacha vektori, μ – umumiy o‘rtacha vektor.

Mezonni maksimalashtiruvchi w ni yechimi $S_W^{-1} S_B$ umumiy xos son masalasini yechish orqali topiladi. Bu yechimning murakkabligi va natijasi tahlil qilinayotgan sinflar soniga bevosita bog‘liq. Ikki sinfli holatda w ni analitik ko‘rinishi mavjud bo‘lib, u sinflarni bir-biridan optimal tarzda ajratuvchi yagona yo‘nalishni ifodalaydi. Ko‘p sinfli holatda (sinflar soni $C > 2$) esa, FDA ma’lumotlarni proeksiyalash uchun bitta chiziq o‘rniga $C-1$ o‘lchamli fazoni hosil qiladi. FDA asl ajratish uchun eng informativ bo‘lgan $C-1$ tagacha yangi, chiziqli bog‘lanmagan komponentlarni yaratadi.

Fisher LDA algoritmi quyidagi bosqichlarda amalga oshiriladi:

1-qadam. Fisher LDA algoritmi har bir sinf uchun alohida statistik belgilarini (o‘rtacha vektor μ_i va kovariatsiya) baholanadi.

2-qadam. S_B va S_W matritsalarini hisoblash amalga oshiriladi.

3-qadam. $S_W^{-1} S_B$ uchun umumiy xos son masalasi yechilib, eng katta xos sonlarga mos xos vektorlar tanlab olinadi.

4-qadam. Ma’lumotning har bir nuqtasi w lar bo‘yicha proyeksiya qilinib, yangi belgilar to‘plami olinadi.

LDA yordamida hosil qilingan yangi, quyi o‘lchamli proyeksiya fazosida sinflar bir-biridan sezilarli darajada yaxshi ajraladi. Bu xususiyat, o‘z navbatida, LDA natijasida olingan chiziqli diskriminant funksiyalardan nafaqat o‘lchamni qisqartirish, balki bevosita tasniflashda ham foydalanish imkonini beradi. Xususan, yangi obyektning ushbu funksiyalar yordamida hisoblangan proyeksiya qiymatlarini oldindan belgilangan chegaralar bilan solishtirish yoki almashtirishdan keyingi fazodagi eng yaqin sinf markazini topish orqali uning qaysi sinfga mansubligini yuqori aniqlik bilan aniqlash mumkin.

Fisher diskriminant tahlilining asosiy afzalligi shundaki, u sinflararo farqlanishni maksimal darajada ta’minlovchi optimal proyeksiya yo‘nalishlarini aniqlaydi. Shu sababli u tasniflash masalalarida samarali o‘lchamni qisqartirish usuli sifatida keng qo‘llaniladi [19]. Mazkur yondashuv nazoratli bo‘lib, sinf yorliqlaridan foydalanadi hamda ma’lumotlardagi muhim statistik farqlarni hisobga oladi. Natijada, sinflararo farqlanish maksimal darajada ta’minlanadi. Shuningdek, FDA yordamida hosil qilingan kichik o‘lchamli fazo odatda tahlil qilishni yengillashtiradi, ya’ni sinflar orasidagi ajratishni aniqroq aks ettiradi.

Kamchiliklari sifatida quyidagilarda keltirish mumkin. FDA faqat chiziqli ajratishni amalga oshira oladi. Shu sababli, sinflar chiziqli ravishda ajratib bo‘lmaydigan hollarda uning samaradorligi keskin kamayadi. Bunday vaziyatlarda yadro LDA kabi kengaytirilgan usullardan foydalanish talab etiladi. Bundan tashqari, algoritm Gauss taqsimoti va kovariatsiyalarning tengligi kabi statistik farazlarga

asoslanadi. Ushbu farazlar buzilganda FDAning aniqligi sezilarli darajada kamayishi mumkin. Yana bir muhim muammo shundaki, kichik tanlash sharoitida, ya'ni belgilar soni kuzatuvlar sonidan ko'p bo'lganda, S_W matritsasi singulyar bo'lib qolishi va natijada to'g'ridan-to'g'ri yechim topish qiyinlashadi. Bunday hollarda matritsani regulyarizatsiya qilish yoki avval o'lchamni PCA yordamida kamaytirish zarur bo'ladi. Shuningdek, FDAning yana bir cheklovi shundaki, ko'p sinfli holatda u faqat $C-1$ o'lchamli proyeksiya fazosini hosil qila oladi (bu yerda, C – sinflar soni). Chunki maksimal ajratish yo'nalishlari soni mavjud sinflar soni bilan chegaralanadi.

Kanonik korrelyatsion tahlil (CCA) – ikki xil belgilar to'plami o'rtasidagi o'zaro bog'liqlikni o'rganishga mo'ljallangan statistik usuldir. 1936-yilda Harold Hotelling tomonidan taklif etilgan ushbu yondashuv nazoratsiz o'qitish turkumiga kiradi va ikki ma'lumotlar manbasidan olingan belgilarni chiziqli modellashtirish orqali ularning korrelyatsiyasini tahlil qiladi. Usulning asosiy maqsadi – birinchi belgilar to'plami X va ikkinchi to'plam Y lardan mos ravishda olingan chiziqli kombinatsiyalar $u = a^T X$, $v = b^T Y$ larni o'rtasidagi Pearson korrelyatsiya koeffitsiyentini maksimal qilishdir [20]. Ya'ni, CCA bu ikki belgilar fazosi orasidagi eng kuchli korrelyatsion bog'liqlikni ochib beruvchi proyeksiyalarni izlaydi.

Intuitiv nuqtai nazardan, Kanonik Korrelyatsion Tahlil (CCA) ikki xil belgilar to'plami (X va Y) orasidagi latent umumiy bog'liqliklarni ochib beruvchi kanonik o'zgaruvchilarni (u va v) topishga qaratilgan. Bu jarayon natijasida hosil qilingan u va v o'zgaruvchilari o'zaro maksimal darajada korrelyatsion bo'ladi.

CCA masalasi quyidagicha ifodalanadi. $X \in R^n$ va $Y \in R^m$ – mos ravishda n va m o'lchamli tasodifiy vektorlar (yoki ularning namunaviy matritsalarini) bo'lsin. Σ_{XX} va Σ_{YY} – mos ravishda X va Y vektorlarning kovariatsiya, Σ_{XY} – X va Y vektorlarning o'zaro kovariatsiya matritsalarini tashkil etsin. U holda CCA masalasini yechimi $Var(a^T X) = 1$, $Var(b^T Y) = 1$ shartlarda quyidagi optimal vektorlar juftligini topishga qaratiladi:

$$(a^*, b^*) = \arg \max_{a \in R^n, b \in R^m} Corr(a^T X, b^T Y).$$

Korrelyatsiya koeffitsiyentini kovariatsiyalar orqali ifodalansa, quyidagicha bo'ladi,

$$\rho(a, b) = \frac{a^T \Sigma_{XY} b}{\sqrt{a^T \Sigma_{XX} a b^T \Sigma_{YY} b}}.$$

Bu shartli optimallashtirish masalasi Lagranj ko'paytuvchilari yordamida umumiy xos son masalasiga keltiriladi. Natijada, a^* va b^* vektorlar $\Sigma_{XX}^{-1} \Sigma_{XY} \Sigma_{YY}^{-1} \Sigma_{YX}$ matritsaning eng katta xos soniga mos keluvchi xos vektorlar sifatida aniqlanadi. Birinchi kanonik juftlik topilgach, keyingi juftliklar ortogonallik shartiga amal qilgan holda bosqichma-bosqich aniqlanadi. Shu tariqa, $k = \min(n, m)$ gacha bo'lgan kanonik proyeksiyalar ketma-ket hosil qilinadi.

Kanonik korrelyatsion tahlil (CCA) ko'p o'zgaruvchilar orasidagi bog'liqliklarni o'rganishda samarali vosita sifatida qo'llaniladi. Uning asosiy afzalliklaridan biri shundaki, ushbu usul ikki ma'lumot to'plamlari orasidagi eng kuchli chiziqli kombinatsiyalarni aniqlash orqali ularning yashirin bog'liqliklarini ochib beradi [21]. Shuningdek, CCA nazoratsiz o'qitish usullaridan biri hisoblanadi. Shu sababli yorliqlangan ma'lumot talab qilmaydi. Bu esa uni manbalararo muvofiqlikni izlash yoki multimodal ma'lumotlarni birlashtirish (masalan, inson ovozi va tasviri orasidagi bog'liqlikni aniqlash) kabi masalalarda samarali qo'llash imkonini beradi. Yana bir muhim jihati shundaki, CCA ko'plab mashhur statistik test va metodlarning umumiy ko'rinishi sifatida qaraladi. Masalan, ayrim kovariatsion tahlil testlarini izohlashda CCA asosiy apparat sifatida xizmat qiladi. Bundan tashqari, ushbu usulning ko'plab kengaytmalari ishlab chiqilgan bo'lib, ular zamonaviy ko'p o'lchovli statistika va ko'p manbali o'rganishning nazariy asosini tashkil etadi. Jumladan, probabilistic CCA, kernel CCA, sparse CCA, shuningdek chuqur o'qitishga asoslangan variantlar – DCCA, MCCA va boshqalar mavjud [22].

Shu bilan birga, CCAning ayrim kamchiliklari ham mavjud. CCA faqat chiziqli bog'liqliklarni aniqlash bilan chegaralanadi. Agar X va Y orasidagi munosabatlar murakkab nochiqli bog'liqliklarga ega bo'lsa, an'anaviy CCA samarali natija bermaydi. Bunday vaziyatlarda kernel CCA yoki chuqur o'qitishga asoslangan yondashuvlardan foydalanish talab etiladi. Ikkinchi muhim cheklov shundaki, klassik CCA faqat ikkita ma'lumotlar to'plami o'rtasidagi kanonik bog'liqlikni izlaydi. Uch yoki undan ortiq manbalarda esa MCCA (Multiset CCA) yoki boshqa kengaytirilgan usullar zarur bo'ladi. Bundan tashqari, CCA yechimining mavjudligi Σ_{XX} va Σ_{YY} kovariatsiya matritsalarining teskari matritsasi bo'lishi shartiga bog'liq. Amaliyotda esa bu shart ko'pincha bajarilmaydi. Ayniqsa obyektlar soni kam, o'lcham esa katta

bo'lganda. Bunday hollarda regularizatsiya yoki o'Ichamni qisqartirish (masalan, PCA orqali) kabi qo'shimcha usullar qo'llanadi. Nihoyat, interpretatsiya masalasi ham cheklovlardan biridir. Birinchi kanonik proyeksiyalar ko'pincha ma'noli tushuntirishga ega bo'lsa-da, keyingi proyeksiyalarni talqin qilish ko'pincha murakkab bo'ladi. Chunki ularning kombinatsiyalari statistik jihatdan to'g'ri bo'lsa ham, mazmunijihatdan izohlash qiyinchilik tug'diradi.

Chuqur kanonik korrelyatsion tahlili (DCCA) – kanonik korrelyatsion tahlilning chuqur o'qitishga asoslangan chiziqlimas kengaytmasi bo'lib, uning asosiy maqsadi ikki xil ma'lumotlar to'plami uchun neyron tarmoqlar yordamida latent representatsiyalarni shakllantirish va ularning o'zaro chiziqli korrelyatsiyasini maksimal darajada oshirishdan iboratdir [23, 24]. An'anaviy CCA faqat chiziqli almashtirish bilan chegaralangan hamda ikki to'plam bilan ishlashga mo'ljallangan [21]. DCCA esa ikki xil ma'lumotdan olinadigan chiziqlimas kombinatsiyalarni ko'p qatlamli neyron tarmoqlar orqali o'rganadi. Natijada neyron tarmoqlarning chiqishlari kanonik korrelyatsiya mezonini bo'yicha maksimal darajada moslashtiriladi [23]. Masalan, tasvir va ovozdan iborat multimodal ma'lumotlar uchun DCCA ikkita mustaqil chuqur neyron tarmoqni o'qitadi va ularning latent fazodagi representatsiyalarini shakllantiradi. Tarmoqlarning oxirgi qatlamlarida olingan chiqishlar esa kanonik korrelyatsiya funksiyasi yordamida yaqinlashtiriladi. Shu asosda DCCA quyidagi optimallashtirish masalasini yechishga qaratiladi:

$$W_1^*, W_2^* = \arg \max_{W_1, W_2} \text{corr}(f_1(X; W_1), f_2(Y; W_2)),$$

bu yerda, $f_1(X; W_1)$ va $f_2(Y; W_2)$ – mos ravishda birinchi va ikkinchi to'plamlar uchun chuqur neyron tarmoqlar tomonidan parametrik o'zgartirishlarni ifodalaydi, W_1 va W_2 – ularning vaznlari.

DCCAning asosiy maqsadi – ikki xil ma'lumotlar to'plamidan olinadigan chiqishlar, ya'ni $f_1(X)$ va $f_2(Y)$ latent representatsiyalari o'rtasidagi korrelyatsiyani maksimal darajaga oshiradigan vaznlarni aniqlashdir. Ushbu vaznlar neyron tarmoqlarni o'qitish jarayonida teskari tarqalish (backpropagation) algoritmi yordamida gradiyentlar asosida iterativ tarzda yangilanadi [24].

Andrew va boshqalar [23] tomonidan DCCA ning korrelyatsiya mezonini maksimallashtirish uchun matritsa izi orqali aniqlangan norma asosidagi maqsad funksiya (trace norm objective) maxsus yo'qotish funksiyasi sifatida taklif qilingan. Bu funksiya differensiallanuvchi xususiyati jihatidan CCA ning analitik yechimiga ekvivalent natija beradi, ya'ni korrelyatsiya mezonini bilvosita maksimallashtiradi va teskari tarqalish algoritmi yordamida modelni samarali o'qitish imkonini beradi. Modelni o'qitish uchun (x_i, y_i) ko'rinishidagi moslashtirilgan juft obyektlardan iborat ma'lumotlar to'plami talab qilinadi. O'qitish jarayoni yakunlangach, hosil bo'lgan f_1 va f_2 neyron tarmoqlari nafaqat o'quv ma'lumotlarini, balki yangi, ilgari kuzatilmagan obyektlarni ham maksimal korrelyatsiyalangan latent fazoga tezda proyeksiya qilish qobiliyatiga ega bo'ladi.

DCCA mohiyatan kernel CCA ga muqobil yondashuv bo'lib, ikkala usul ham chiziqlimas bog'liqliklarni aniqlash imkonini beradi. Biroq, DCCA parametrik neyron tarmoqlarga asoslanganligi sababli, katta hajmdagi ma'lumotlarda samaraliroq hamda yangi obyektlar uchun qo'shimcha optimallashtirishsiz tezkor hisoblash imkonini ta'minlaydi [23].

Amaliy jihatdan DCCA ikkita chuqur neyron tarmoqni bir vaqtda o'qitish orqali amalga oshiriladi. Har bir tarmoq mos ravishda o'ziga tegishli kirish belgilarini qabul qilib, bir nechta yashirin qatlamlar orqali yakuniy latent vektorni hosil qiladi [25]. Har bir mini-batch uchun ikki tarmoqning chiqishlari olinib, ular o'rtasidagi kanonik korrelyatsiya hisoblanadi. Keyingi bosqichda tarmoqlarning vaznlari korrelyatsiyani oshirish yo'nalishida yangilanadi. Shu tarzda o'qitilgan model ma'lumotlarni umumiy latent fazoda ifodalaydi va bu fazoda ular o'zaro maksimal darajada bog'liq bo'ladi. DCCA ko'pincha multimodal vazifalarda qo'llanadi. Masalan, matn va tasvirni bitta umumiy vektorga xaritalash, audio va video ma'lumotlarni birlashtirish kabi sohalarida samarali natija beradi. Olingan umumiy representatsiyalar keyinchalik boshqa vazifalar – masalan, bir modalitetdan ikkinchisini bashorat qilish yoki tasniflash uchun – foydalanilishi mumkin. Chunki DCCA turli manbalardagi umumiy axborotni samarali saqlab qoladi [26].

DCCAning eng muhim afzalliklaridan biri shundaki, u neyron tarmoqlar yordamida ma'lumotlar orasidagi murakkab va chiziqlimas bog'liqliklarni samarali tarzda aniqlay oladi. Ushbu xususiyat, ayniqsa, katta hajmli va turli manbali ma'lumotlar (masalan, tasvir va matn) bilan ishlashda alohida ahamiyat kasb etadi. Shuningdek, DCCA parametrik model bo'lgani sababli, o'qitilgan neyron tarmoqlar yangi obyektlarni qo'shimcha optimizatsiyasiz tezkor ravishda umumiy embedding fazoga proyeksiya qila oladi. Bu jihat uni kernel CCA usulidan ustunligini ko'rsatadi. Chunki kernelga asoslangan yondashuvlar yangi obyektlarni hisoblashda butun ma'lumot to'plamidan qayta foydalanishni talab etadi. Natijada, DCCA yuqori masshtablanuvchanlikni ta'minlaydi va amaliy jihatdan samaraliroq hisoblanadi. Bundan tashqari, DCCA o'qitilgan chiqishlarda yuqori korrelyatsiya darajasini kafolatlaydi hamda ko'plab hollarda klassik CCA va kernel CCA metodlaridan ustun natija beradi. Bu ikki manba orasidagi umumiy axborotni

maksimal darajada ajratib olish imkonini beradi. Yana bir muhim afzalligi shundaki, DCCA nazoratsiz o'qitish asosida shakllantirilgan latent fazoni hosil qiladi va ushbu fazo turli masalalarda, jumladan transferli o'qitish jarayonida samarali reprezentatsiya vositasi sifatida qo'llanilishi mumkin.

DCCA bir qator muhim kamchiliklarga ham ega. Avvalo, u asosan ikki manbali (bimodal) ma'lumotlarga mo'ljallangan bo'lib, uch va undan ortiq manbani birgalikda modellashirish imkoniyati cheklangan. Bu esa ko'p manbali (2 tadan ortiq manba) ma'lumotlar bilan ishlashda uning qo'llanish doirasini sezilarli darajada toraytiradi. Ushbu muammoni bartaraf etish maqsadida DCCAdan kelib chiqqan holda uning kengaytirilgan varianti – DMCCA usuli taklif etilgan. DCCAni samarali o'qitish katta hajmdagi o'quv ma'lumotlari va yuqori hisoblash resurslarini talab qiladi. Agar o'quv obyektlarining soni yetarli bo'lmasa, modelning haddan ortiq o'qitilishi (overfitting) xavfi sezilarli darajada ortadi. Shuningdek, DCCA orqali olingan proyeksiyalar qatlamli va chiziqsiz bo'lgani sababli, natijalarni talqin qilish (interpretatsiya) oddiy CCAga nisbatan ancha murakkab. Amaliyotda model ko'pincha "qora quti" sifatida qabul qilinadi va har bir belgining yakuniy natijaga qo'shgan hissasini izohlash qiyin bo'ladi. Bundan tashqari, chuqur neyron tarmoqlar parametrlarining soni katta bo'lgani bois, regulyarizatsiya, muddatidan oldin to'xtatish (early stopping) va boshqa ehtiyot choralarini qo'llash talab etiladi. Aks holda, DCCA yangi ma'lumotlarda kutilgan samarani bermasligi mumkin.

Chuqur ko'p to'plamli kanonik korrelatsion tahlil (DMCCA – Deep Multiset Canonical Correlation Analysis) – kanonik korrelyatsion tahlilning bir nechta ma'lumot to'plamlari uchun chuqur o'qitishga asoslangan kengaytmasi hisoblanadi. Ushbu yondashuv ko'p sonli manbalar (modalitetlar) o'rtasida umumiy latent reprezentatsiyani o'rganishni ta'minlaydi [27, 28].

Agar ma'lumot bir hodisaning turli manbalarda kuzatilgan ko'rinishlaridan iborat bo'lsa (masalan, biometrik tizimda insonning nutqi, yuzi va barmoq izi), DMCCA ushbu K ta manbaning har biri uchun alohida chuqur neyron tarmoqni o'qitadi. Har bir tarmoq mos ravishda o'z manbasidan bir xil o'lchamli latent vektor hosil qiladi. DMCCAning asosiy maqsadi esa barcha chiqishlarni birgalikda maksimal korrelyatsiyaga olib keladigan umumiy latent fazoni shakllantirishdir. DMCCA turli manbalardan olingan ma'lumotlardan "umumiy axborot"ni samarali ajratib olishga intiladi [28].

DMCCAning an'anaviy CCA va MCCA usullaridan asosiy farqi shundaki, u sinf yorliqlarisiz ham ko'p manbalar orasidagi umumiy strukturaning o'zini o'rganadi. Modelning maqsad funksiyasi sifatida manbalararo kovariatsiya va manba ichidagi kovariatsiya nisbatini maksimal qilish taklif etiladi [29]. Bu yondashuv mohiyatan LDA dagi sinflararo va sinf ichidagi dispersiyalar nisbatiga muvofiq keladi. Biroq bu yerda sinflar o'rmini turli manbalar egallaydi. Ya'ni, DMCCA chiqish fazosida shunday sharoit yaratiladiki, bir xil manbaga tegishli nuqtalar bir-biriga yaqin joylashadi (manba ichidagi tarqoqlik kichik), turli manbalarga oid nuqtalar esa bir-biridan uzoqroq joylashadi (manbalararo tarqoqlik katta) [29]. Natijada barcha manbalar uchun yagona bog'langan nazariy tasvir – umumiy reprezentatsiya (shared representation) hosil qilinadi. DMCCAni amalga oshirishda turli xil yondashuvlardan foydalanish mumkin. Masalan, GCCA (Generalized CCA) nazariyasiga asoslanib, barcha manbalarning ko'rinishlarini ularning umumiy reprezentatsiyasi bilan bog'lash va hosil bo'lgan korrelyatsiyalar yig'indisini maksimal darajaga chiqarish mumkin. DMCCAda esa ushbu maqsad differensiallanuvchi yo'qotish funksiyasi shaklida ifodalanadi va tarmoq parametrlari gradient tushish algoritmi orqali o'qitilib, aniqlanadi [28].

DMCCA modelini o'qitish jarayonida bir xil obyektga oid K ta manbadan olingan mos ma'lumot to'plamlari talab qilinadi. Har bir k manba uchun $f_k(X^{(k)}, W_k)$ chuqur neyron tarmog'i belgilanadi. O'qitish jarayonida barcha K ta tarmoqlarning chiqishlari olinib, ular orasidagi umumiy korrelyatsiya mezonini (yoki kovariatsiya nisbatlari) hisoblab chiqiladi. Shu ko'rsatkichni oshirish uchun barcha W_k parametrlar yangilanadi. Natijada, model barcha K ta manbani yagona latent fazoga proyeksiya qiluvchi xarita vazifasini bajaradi. DMCCA amaliy qo'llanilishiga misol sifatida ko'p manbali biometrik tizimlar (bir nechta biometrik belgilarni integratsiya qilish), multimedia sohalari (audio, video va matnli birgalikda tahlil qilish) hamda ko'p sensorli tizimlar (masalan, tibbiyotda turli diagnostik tekshiruvlarni birlashtirish) kiritilishi mumkin. Ilmiy tadqiqotlarda esa DMCCA bir nechta shovqinli manbalar orasidan umumiy axborotni ajratib olishda samarali natija bergani qayd etilgan [27].

DMCCA usuli ko'p manbali ma'lumotlarni birlashtirishda samarali yondashuv sifatida ajralib turadi. Uning bir qancha muhim afzalliklari mavjud. Avvalo, DMCCA bir vaqtning o'zida ikki va undan ortiq manba ma'lumotlarini birlashtirib, ular uchun umumiy bo'lgan latent belgilarni ajratadi. Bu esa juftlik asosidagi oddiy usullarda qo'lga kiritish qiyin bo'lgan natija hisoblanadi. Shuningdek, chuqur neyron tarmoqlar yordamida har bir manba uchun maxsus moslashtirilgan, chiziqsimas va murakkab almashtirishlar o'rganiladi. Bu har bir manbada o'ziga xos belgilar bo'lishiga qaramay, ularni bitta fazoda birlashtirish imkonini beradi. DMCCA to'liq nazoratsiz usul bo'lib, sinf yorliqlarisiz ham umumiy komponentlarni o'rgana oladi [30]. Bu katta hajmli va turli manbali datasetlar uchun juda muhim. Chunki har bir obyektga sinf berish qiyin yoki imkonsiz bo'lishi mumkin. Bundan tashqari, DMCCA kovariatsion yondashuvga asoslanganligi sababli, u bir nechta manbalardagi shovqinli ma'lumotlardan ham umumiy axborotni samarali ajratib bera olishi ko'rsatib berilgan [27].

Shu bilan birga, DMCCA usulining bir qator kamchiliklari ham mavjud. Bir nechta neyron tarmoqlarni parallel o'qitish talab etilishi sababli modelning hisoblash murakkabligi yuqori bo'ladi. Amaliyotda DMCCAni mini-batch asosidagi optimallashtirish orqali o'qitish mumkin [30]. Biroq tarmoqlar soni ortishi bilan optimallashtirish jarayoni yanada murakkablashadi. Bundan tashqari, barcha K ta manbaning chiqishlarini yagona koordinata fazosida moslashtirish uchun qo'shimcha ortogonallik yoki normallashtirish shartlarini kiritish zarur. Aks holda, ayrim manbalar natijaga nisbatan ustun ta'sir ko'rsatishi mumkin. Model parametrlarining juda ko'pligi haddan ortiq o'qitilish (overfitting) xavfini kuchaytiradi. Manbalar soni ortganda umumiy komponentlarni ishonchli o'rganish uchun katta hajmdagi o'quv namunalari ehtiyoj seziladi. Shuningdek, DMCCA yechimining konvergensiyasi, natijaning yagona emasligi kabi nazariy masalalar hali to'liq o'rganilmagan. Model qanday sharoitlarda optimal yechimga olib borishi va olingan natijaning barqarorligi kabi savollar ochiq turibdi. Shu sababli, amaliy muvaffaqiyatlariga qaramay, DMCCA usulining matematik asoslari va turg'unlik tahlili bo'yicha ilmiy izlanishlar davom ettirilishi zarur.

3 USULLARNI TAQQOSLASH

Yuqorida ko'rib chiqilgan FDA, CCA, DCCA va DMCCA usullari o'zining nazariy asoslari, qo'llanish sohasi hamda amaliy imkoniyatlari bilan bir-biridan sezilarli darajada farqlanadi. Har bir usul ma'lum bir vazifa uchun samarali natija bera olishi mumkin. Biroq boshqa sharoitlarda uning kamchiliklari ham namoyon bo'ladi. Masalan, FDA nazoratli o'qitishga asoslangan bo'lib, sinflarni aniq ajratishda yuqori natija beradi, ammo chiziqli chegaralar bilan cheklanadi. CCA ikki manba orasidagi bog'liqliklarni aniqlashda samarali vosita hisoblanadi. Biroq faqat chiziqli almashtirishni qo'llaydi. DCCA chuqur neyron tarmoqlar yordamida murakkab va chiziqsiz bog'liqliklarni aniqlash imkonini beradi. Lekin katta hajmdagi o'quv ma'lumotlari va yuqori hisoblash resurslarini talab qiladi. DMCCA esa ko'p manbali ma'lumotlarni yagona latent fazoda birlashtirish imkonini beradi. Shu bois multimodal tahlil va zamonaviy sun'iy intellekt tizimlarida keng qo'llaniladi. Ammo modelning murakkabligi va o'qitishdagi nazariy masalalar hali to'liq yechim topmagan. Shu sababli, ushbu usullarni qiyosiy tahlil qilish muhim ahamiyat kasb etadi. 1-jadvalda ularning asosiy xususiyatlari, qo'llanilish shartlari, shuningdek afzallik va kamchiliklari umumlashtirilgan holda keltiriladi. Ushbu qiyosiy tahlil tadqiqotchilarga aniq vazifaga mos usulni tanlashda nazariy asos va amaliy ko'rsatma bo'lib xizmat qiladi.

1-jadval. Usullarning qiyosiy taqqoslanishi

Usul	Tur (nazorat)	Chiziqlilik	Ma'lumot turi	Asosiy maqsad	Ustunliklari	Kamchiliklari
FDA	Nazoratli	Chiziqli proyeksiya	Bitta ma'lumotlar to'plami, sinflangan ma'lumotlar	Sinflararo farqni maksimal qilish (dispersiya nisbatini oshirish)[18]	Sinflarni yaxshi ajratadi, klassifikatsiya uchun optimal chiziqli belgilarni beradi. Past o'lchamli fazoda ham ma'lumotning diskriminativ kuchini saqlaydi	<ul style="list-style-type: none"> - Faqat chiziqli chegaralarni ajrata oladi - Sinf yorliqlari va kovariatsiyalarning normal taqsimlangan bo'lishiga ehtiyoj sezadi - Katta o'lchamli, kam obyektli muhitda S_W singulyar bo'lishi mumkin
CCA	Nazoratsiz	Chiziqsiz	Ikkita ma'lumotlar to'plami (paired data: bir obyektning 2 xil ko'rinishi)	Ikki ma'lumotlar to'plami orasidagi korrelyatsiyani maksimal qilish [20]	<ul style="list-style-type: none"> - Ko'p o'zgaruvchilar orasidagi bog'liqlikni topadi (multi-view learning asosida) - Yorliq yo'q sharoitda ham yashirin umumiy belgilarni ajratadi - Tez va analitik yechimga ega (eigen qiymat muammosi) 	<ul style="list-style-type: none"> - Faqat ikkita to'plam bilan ishlaydi (ko'p ko'rinish uchun kengaytma zarur) - Nochiziqli bog'liqliklarni aniqlay olmaydi - Kovariatsiya matritsalarini singulyar bo'lsa, yechim noaniq
DCCA	Nazoratsiz	Nochiziqli	Ikkita ma'lumotlar to'plami (juft ko'rinish, masalan A va B manbalar)	Ikki ma'lumotlar to'plami uchun transformatsiyalarni o'rgatib, ularning korrelyatsiyasini maksimal qilish[23, 24]	<ul style="list-style-type: none"> - Nochiziqli murakkab bog'liqliklarni ham aniqlaydi (kernel CCA o'rini bosadi) - Katta ma'lumotlar to'plamida o'rgatib, yangi ma'lumotlar uchun tez hisoblay oladi[23] - CCA ga nisbatan yuqoriroq korrelyatsiyali reprezentatsiya beradi [26] 	<ul style="list-style-type: none"> - Faqat 2 ta manba bilan cheklangan[25] - Neyron tarmoqni o'qitish uchun ko'p ma'lumot va vaqt talab etadi - Model interpretatsiyasi murakkab, me'yorida ortiq moslashish xavfi yuqori

DMCCA	Nazoratsiz	Nochiziqli	Bir nechta ($K > 2$) ma'lumotlar to'plami, barcha bir-biriga moslangan (paired K-set)	Ko'p manbalar uchun umumiy fazo o'rgatish, manbalararo kovariatsiya nisbatini oshirish [28]	– Bir nechta turli manbalarni birlashtiradi, hammasiga mushtarak belgi fazo hosil qiladi – Sinf talab qilmaydi, turli manbalardagi umumiy signalni avtomatik ajratadi [30] – Ko'p manbali tizimlarda juda samarali	– Model juda murakkab, K ta tarmoq birga o'qitiladi (hisoblash resursiga talab yuqori) – Optimallashtirish qiyin (koordinatsiya, normalizatsiya muammosi) – Juda ko'p parametrlar sababli me'yoridan ortiq moslashish xavfi katta, nazariy kafolatlar cheklangan
-------	------------	------------	---	---	--	--

4 XULOSA

O'tkazilgan qiyosiy tahlillar shuni ko'rsatdiki, har bir belgi ajratish usuli o'zining kuchli va zaif tomonlariga ega. FDA sinflararo farqlanishni maksimal qilishda samarali, ammo chiziqli chegaralar bilan cheklanadi. CCA ikki manba o'rtasidagi bog'liqlikni o'rganishda klassik vosita bo'lsa-da, faqat chiziqli transformatsiyalar bilan ishlaydi. DCCA chuqur neyron tarmoqlar yordamida nochiziqli va murakkab bog'liqliklarni ham samarali aniqlash imkonini beradi, DMCCA esa ko'p manbali ma'lumotlardan umumiy latent fazoni shakllantirish orqali kengroq qo'llanish imkoniyatini taqdim etadi. Shunday qilib, vazifaga qarab mos metodni tanlash muhim ahamiyat kasb etadi: FDA – nazoratli tasniflash uchun, CCA – ikki to'plam korrelyatsiyasini o'rganishda, DCCA – nochiziqli manbalar juftligi uchun, DMCCA esa ko'p manbali integratsiya zarur bo'lgan hollarda eng samarali yechim hisoblanadi.

ADABIYOTLAR

- [1] *Niu, G.* (2016). *Statistic feature extraction*. In *Data-Driven Technology for Engineering Systems Health Management: Design Approach, Feature Construction, Fault Diagnosis, Prognosis, Fusion and Decisions* (pp. 101-138). Singapore: Springer Singapore.
- [2] *Sh.Fazilov, O.R. Yusupov, Eshonqulov E.Sh.,* Sun'iy yo'ldosh tasvirlarida superpiksel segmentlash yondashuvlari, *Informatika va energetika muammolari*, 6-son, 2023, 25-35-betlar
- [3] *O.R. Yusupov, Eshonqulov E.Sh.,* Superpixel segmentation approaches for remote sensing images, *Abstract of VIII International Scientific conference "Actual problems of applied mathematics and information Technologies-AI-Khwarizmi 2023"*, SamSU, Samarkand-Uzbekistan, 2023-yil, 25-26-September, 292-bet
- [4] *Chen, C. H.* (1976). *On statistical and structural feature extraction*. *Pattern Recognition and Artificial Intelligence*, 135-144.
- [5] *Sh.X.Fazilov, O.R. Yusupov, V.V.Ganchenko, A.V.Inyutin,* Perspektivny ispolzovaniya algoritmicheskix ansambley dlya analiza izobrazheniy DZZ, "Informatika va energetika muammolari" O'zbekiston jurnali. – Toshkent, 2023. 6-son. 3-10 betlar.
- [6] *O.R.Yusupov,* Algoritmilar aralashmasi strategiyasiga asoslangan algoritmik kompozitsiyasi asosida tasniflash masalalari yechish, "Intellectual tizimlarning zamonaviy muammolari" Respublika ilmiy-amaliy konferensiyasi, Jizzax Qozon Federal Universiteti filiali, 2025-yil, 18-19-aprel, 274-278-betlar
- [7] *Sh.Fazilov, O.R. Yusupov, Kh.Abdiyeva, Eshonqulov E.Sh., Z. Malikov,* Construction of a quasi-linear ensemble of algorithms for diagnosing tumors detected from mammography images, 2024 IEEE East-West Design & Test Symposium (EWDTS), November 13, 2024 – November 17, 2024, Yerevan, Armenia
- [8] *O.R.Yusupov, Y.X.Xandamov,* Transferli o'qitishda belgilarni transfer qilish strategiyalari, "Zamonaviy axborot, kommunikatsiya texnologiyalari va AT-ta'lim tatbiqi muammolari" mavzusidagi Respublika ilmiy-amaliy anjumani, Samarqand shahri, 2025-yil 25-26-aprel, 335-337-betlar
- [9] *O.R.Yusupov, Eshonqulov E.Sh.,* Tasvirlardagi sahnani tasniflash uchun ResNet arxitekturasi asoslangan ekspertlar aralashmasi ansamblini qurish, "2-Sun'iy intellekt nazariyasi va amaliyoti: tajriba, muammolar va istiqbollar" Respublika ilmiy-amaliy anjumani, Toshkent Davlat iqtisod Universiteti, 2025-17-18-iyun, 330-334-betlar
- [10] *O.R.Yusupov, Eshonqulov E.Sh.,* Enhancing the accuracy of remote sensing scene classification using transfer learning with densenet, SamDU Ilmiy Axborotnoma, 2025.
- [11] *Sh.Fazilov; O.R.Yusupov, E.Eshonqulov; Kh.Abdieva, Z.Malikov,* YUV Color Model-Based Adaptive Pansharpening with Lanczos Interpolation and Spectral Weights, *Mathematics* 2025, 13, 2868., <https://doi.org/10.3390/math13172868>
- [12] *Kamilov M.M., O.R.Yusupov, Tojiboyev B.M., Ravshanov A.A.,* Masofadan zondlash tasvirlarini intellektual tahlil qilish uchun algoritmik ansamblga asoslangan yondashuv, Boshqaruvda raqamli

- texnologiyalar va sun'iy intellektning tadbirlari: hozirgi holati va kelajagi, Respublika ilmiy-texnik anjumani ma'ruzalar to'plami, Toshkent, 2025-yil 5-6-sentabr, 28-36-b.
- [13] *Tharwat, A., Gaber, T., Ibrahim, A., & Hassani, A. E.* (2017). Linear discriminant analysis: A detailed tutorial. *AI communications*, 30(2), 169-190.
- [14] *O.R. Yusupov, Eshonqulov E.Sh.*, Masofadan zondlash asosida olingan tasvirlarda deskriptorlarni qurish usullarining qiyosiy tahlili, "Raqamli texnologiyalarning nazariy va amaliy masalalari xalqaro jurnali", 2023 №4(6), ISSN 2181-3086, 2023-yil, 102-110-betlar. <https://doi.org/10.62132/ijdt.v6i4.142>
- [15] *O.R. Yusupov, Eshonqulov E.Sh., Y. Xandamov*, Quyi va o'rta darajadagi deskriptorlar asosida masofadan olingan tasvirlarda sahnani tasniflash algoritmlari, "Raqamli texnologiyalarning nazariy va amaliy masalalari xalqaro jurnali", 2025 №8(1), ISSN 2181-3086, 2025-yil, 102-110-betlar, <https://doi.org/10.62132/ijdt.v6i4.142>
- [16] *Rashidov X.Sh., O.R. Yusupov, Xandamov Y.X.*, Relevant belgilarning qism to'plamini tanlashning gibrid yondashuvga asoslangan algoritmi, Boshqaruvda raqamli texnologiyalar va sun'iy intellektning tadbirlari: hozirgi holati va kelajagi, Respublika ilmiy-texnik anjumani ma'ruzalar to'plami, Toshkent, 2025-yil 5-6-sentabr, 73-78-b.
- [17] *O.R. Yusupov, Xandamov Y.X.*, Umumlashgan xos son masalasida singulyar holatlarni yechishning SVD usuliga asoslangan yondashuvi, Boshqaruvda raqamli texnologiyalar va sun'iy intellektning tadbirlari: hozirgi holati va kelajagi, Respublika ilmiy-texnik anjumani ma'ruzalar to'plami, Toshkent, 2025-yil 5-6-sentabr, 84-90-b.
- [18] *Mika, S., Ratsch, G., Weston, J., Scholkopf, B., & Mullers, K. R.* (1999, August). Fisher discriminant analysis with kernels. In *Neural networks for signal processing IX: Proceedings of the 1999 IEEE signal processing society workshop* (cat. no. 98th8468) (pp. 41-48). Ieee
- [19] *Sugiyama, M.* (2006, June). Local fisher discriminant analysis for supervised dimensionality reduction. In *Proceedings of the 23rd international conference on Machine learning* (pp. 905-912).
- [20] *Hotelling, H.* (1992). Relations between two sets of variates. In *Breakthroughs in statistics: methodology and distribution* (pp. 162-190). New York, NY: Springer New York.
- [21] *Hardoon, D. R., Szedmak, S., & Shawe-Taylor, J.* (2004). Canonical correlation analysis: An overview with application to learning methods. *Neural computation*, 16(12), 2639-2664.
- [22] *Yang, X., Liu, W., Liu, W., & Tao, D.* (2019). A survey on canonical correlation analysis. *IEEE Transactions on Knowledge and Data Engineering*, 33(6), 2349-2368.
- [23] *Andrew, G., Arora, R., Balmes, J., & Livescu, K.* (2013, May). Deep canonical correlation analysis. In *International conference on machine learning* (pp. 1247-1255). PMLR.
- [24] *Sun, Z., Sarma, P., Sethares, W., & Liang, Y.* (2020, April). Learning relationships between text, audio, and video via deep canonical correlation for multimodal language analysis. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 34, No. 05, pp. 8992-8999).
- [25] *Qiu, J. L., Liu, W., & Lu, B. L.* (2018, November). Multi-view emotion recognition using deep canonical correlation analysis. In *International conference on neural information processing* (pp. 221-231). Cham: Springer International Publishing.
- [26] *Wang, W., Arora, R., Livescu, K., & Balmes, J. A.* (2015, April). Unsupervised learning of acoustic features via deep canonical correlation analysis. In *2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 4590-4594). IEEE.
- [27] *Somandepalli, K., Kumar, N., Travadi, R., & Narayanan, S.* (2019). Multimodal representation learning using deep multiset canonical correlation. *arXiv preprint arXiv:1904.01775*.
- [28] *Benton, A., Khayrallah, H., Gujral, B., Reisinger, D. A., Zhang, S., & Arora, R.* (2017). Deep generalized canonical correlation analysis. *arXiv preprint arXiv:1702.02519*.
- [29] *Bai, X., Yan, L., & Li, Y.* (2020, September). Seizure detection using deep discriminative multi-set canonical correlation analysis. In *International Conference on Machine Learning and Intelligent Communications* (pp. 129-136). Cham: Springer International Publishing.
- [30] *Somandepalli, K., Kumar, N., Jati, A., Georgiou, P. G., & Narayanan, S.* (2019). Multiview Shared Subspace Learning Across Speakers and Speech Commands. In *INTERSPEECH* (pp. 2320-2324).

Поступила в редакцию 12.05.2025

Citation: *Yusupov O.R., Xandamov Y.X., Xojiakbarov Sh.M.* (2025). An'anaviy statistik va chuqur o'qitishga asoslangan belgi ajratish usullari. Raqamli texnologiyalarning nazariy va amaliy masalalari xalqaro jurnali. 8(3). –B. 101-109. <https://doi.org/10.62132/ijdt.v8i3.293>.

FEATURE EXTRACTION METHODS BASED ON TRADITIONAL STATISTICS AND DEEP LEARNING

⁺Yusupov O.R.¹, Khandamov Y.Kh.², Khojiakbarov Sh.M.²

¹ Samarkand State University named after Sharof Rashidov, Samarkand, Uzbekistan

² Digital Technologies and Artificial Intelligence development Research Institute, Tashkent, Uzbekistan

Abstract. The article presents a theoretical and practical comparative analysis of four important methods related to feature extraction and dimensionality reduction: Fisher Discriminant Analysis (FDA), Canonical Correlation Analysis (CCA), Deep Canonical Correlation Analysis (DCCA), and Deep Multiset Canonical Correlation Analysis (DMCCA). The theoretical foundations, advantages, and disadvantages of each method are discussed in detail. In addition, their applicability across various domains is highlighted. The analyses show that FDA is effective in supervised learning, while CCA serves as an important tool for studying relationships between two sources. DCCA extends classical approaches through deep learning, enabling the identification of nonlinear structures. DMCCA, in turn, constructs a common latent representation for multi-source data and demonstrates high efficiency in modern artificial intelligence systems.

Keywords: feature extraction, dimensionality reduction, FDA, CCA, DCCA, DMCCA, latent representation, statistical methods, deep learning, multimodal data.

МЕТОДЫ ИЗВЛЕЧЕНИЯ ПРИЗНАКОВ, ОСНОВАННЫЕ НА ТРАДИЦИОННОЙ СТАТИСТИКЕ И ГЛУБОКОМ ОБУЧЕНИИ

⁺Юсупов О.Р.¹, Хандамов Й.Х.², Хожиақбаров Ш.М.²

¹ Самаркандский государственный университет имени Шарофа Рашидова, Самарканд, Узбекистан

² НИИ Развития цифровых технологий и искусственного интеллекта, Ташкент, Узбекистан

Аннотация. В статье представлен теоретический и практический сравнительный анализ четырёх важных методов, связанных с извлечением признаков и сокращением размерности: дискриминантного анализа Фишера (FDA), канонического корреляционного анализа (CCA), глубокого канонического корреляционного анализа (DCCA) и глубокого множественного канонического корреляционного анализа (DMCCA). Подробно рассмотрены теоретические основы, преимущества и недостатки каждого метода. Кроме того, приведены возможности их применения в различных областях. Анализ показывает, что FDA эффективно используется при обучении с учителем, тогда как CCA является важным инструментом для изучения взаимосвязей между двумя источниками. DCCA расширяет классические подходы с помощью глубокого обучения, позволяя выявлять нелинейные структуры. В свою очередь, DMCCA формирует общее латентное представление для многоисточниковых данных и демонстрирует высокую эффективность в современных системах искусственного интеллекта.

Ключевые слова: извлечение признаков, сокращение размерности, FDA, CCA, DCCA, DMCCA, латентное представление, статистические методы, глубокое обучение, мультимодальные данные.