

УДК 004.056

Каримов М.М, Исломов Ш.З, Бекмирзаев О.Н, Зокиров О.Ё.

ЮЗЛАРНИ ТАНИБ ОЛИШ САМАРАДОРЛИГИНИ ОШИРИШ УСУЛЛАРИ

Ушбу мақолада юзларни таниб олишнинг классик усул ва алгоритмларидаги муаммолар ва уларни таниб олиш самарадорлигини ошириш усуллари асосида мавжуд камчиликларни бартараф этиш ва хатоликларни камайтириш келтирилган. Юзни таниб олиш тизимларида ёлғондан қабул қилиш ва рад этиш хатоликлари мавжуд бўлиб, уларни юзларни нормаллаштириш усули орқали камайтириш таклиф этилган. Таниб олиш тезлигини ва аниқлигини юз ошириш учун тармоқларни мужассамлашган ҳолда қўллаш ва филтерлар ўлчамини оптималлаштириш ишлаб чиқилган.

Калит сўзлар: юзни таниб олиш, хатолик, самарадорлик, нормаллаштириш, Deep Learning, тармоқлар, сиқиш, кўзгагиш, бошланғич, йўқотиш функцияси.

Кириш

Юзни таниб олиш юз бўйича идентификациялаш жараёнининг асосий босқичларидан бири бўлиб, тизимга кирувчи тасвирдан олинган юз базасидаги юзлар билан таққосланади ва унинг ким эканлиги тахмин қилинади.

Идентификациялаш жараёнидан олинган тахминий таққослаш рост ёки ёлғон эканлиги тизим томонидан тасдиқланади.

Шу сабабли ўз вақтида ва самарали Юзларни таниб олиш жараёнида юз, кўз, бурун ва оғиз хусусиятлари асосий катталиклар ҳисобланади. Бошқа томондан тест намунанинг ҳажми асосий ўрин тутди. Унинг ҳажми катталиги аниқликни оширади - тезликни камайтиради, кичиклиги эса, тезлик юқори – аниқлик паст бўлади. Намуналар сонининг кўплиги тизим фаолиятининг сифатини оширишга хизмат қилади.

Юзларни таниб олиш усул ва алгоритмларининг ўзига ҳослиги шундан иборатки, барчасида ички тузилишидан келиб чиқиб, юз хусусиятлари ажратиш олинадилар ва рўйхатдан ўтган ҳолатдаги билан таққосланади.

Юз хусусиятларини ажратиш ва уни базадаги кийматлар билан таққослаш юзни таниб олиш жараёнининг асосини ташкил этади. Кўпчилик ҳоллардан юз хусусиятларини ажратиш ва таниб олиш босқичлари битта қисм сифатида ўрганилади.

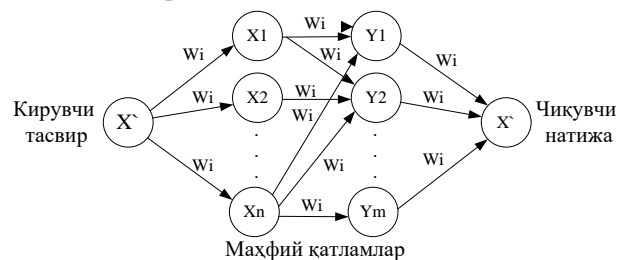
Ҳозирда юзларни таниб олиш соҳасида кўплаб тижорат корхоналари ва ташкилотлар чуқур илмий изланиш олиб боришмоқда. Улар қаторига NEC, Morpho, Toshiba, 3M, Cognitec, Neurotechnology ва ҳ. ларни олиш мумкин [1]. Юзларни таниб олишнинг самарадорлигини оширишда икки ёки ундан ортик алгоритмларнинг бирлашмасидан фойдаланиш юқори самара бериши яққол келтирилган. Масалан, SVM ва PCA алгоритмларининг уч турдаги AR, ORL ва YALE юз базаларида олинган натижаларини келтириш мумкин. Аммо, реал вақтга назар ташлайдиган бўлсак, юз ҳолатлари билан шундай муаммолар мавжудки, юзни таниб олиш даражасига етарлича таъсир этади. Бундан ташқари, ўртача хатолик даражаси 3,7% дан юқорилигини келтириш мумкин.

Асосий қисм

Ҳозирги кунда тадқиқотчилар юзларни таниб олиш самарадорлигини оширишда куйидаги усулларни қўллашмоқда.

Машина ўрганиши сунъий интеллект усулларининг асосини ташкил этади. Ўрганиш тасвирлар сони кўплиги юзни таниб олиш ва аниқлаш жараёни юқори аниқликда бажарилишини таъминлаб беради. Шунинг учун бир юзнинг турли кўринишдаги тасвирлари (8-20 та) ўрганилади. Ушбу тасвирларни саралаш ва ўрганиш машина ва инсоннинг юқори иштирокини талаб этади. Шу каби муаммоларни ҳал этиш ва инсон иштирокини камайтириш мақсадида машина ўрганиши алгоритмлари

ва технологиялари ишлаб чиқилган [2].



1-расм. Нейронлар ва уларнинг оғирлиги

Нейрон тармоқлар машина ўрганишининг асосий усулларидан бири ҳисобланади [3]. У аниқ ва ноаниқ, ҳамда, чизикли ва чизиксиз маълумотлар оқимини синфлаш учун энг самарали усуллардан ҳисобланади.

Deep Learning (DL). DL свёртка, пулинг, кўпиш ёки айириш (padding) ва тўлиқ уланган қатламлардан ташкил топган. Свёртка қатлами CNN ва Deep CNN учун асосий босқич бўлиб, у филтерлар асосида барча соҳалардан хусусиятларни ажратиш олишга қаратилган. Ҳар бир филтер бўйи ва энидан келиб чиқиб, кичик кийматларга эга. i -хусусиятлар тўпламини тасвирлаш учун $x_i^{(l)}$ дан фойдаланилади.

$$x_j^{(l+1)} = s\left(\sum_i F_{ij}^{(l)} * x_i^{(l)} + b_j^{(l)}\right)$$

Бу ерда, $x_j^{(l+1)}$ – чикувчи киймат, $F_{ij}^{(l)}$ - $x_i^{(l)}$ га боғланган филтер, l – сатҳ, $b_j^{(l)}$ - j -чикувчи хусусиятлар тўплами учун оғиш вектори (bias), $s()$ – 2D рақамли свёрткани ифодаловчи чизиксиз функция [4]. DL асосида яратилган юзни аниқлаш тизими 140x140 ўлчамли тасвирлардан 97,45% аниқликда юзларни аниқлай олади. СОСО функциясида фойдаланиб яратилган, DL юзни аниқлаш усули 99,86% аниқликни таъминлайди [5].


Параллел ҳисоблаш. Юз қисмларини алоҳида ҳисоблаш процессорларида ҳисоблаш параллел ҳисоблаш имкониятларидан фойдаланган ҳолда амалга оширилади. $M \times N$ ўлчамли юзни ўрганишда тасвир $p \times p$ ўлчамли ойналарга ажратилади, CPU ва GPUнинг имкониятидан келиб чиққан ҳолда, бир нечта қисмларга бўлиб, параллел ҳисоблаш бажарилади. Мазкур усул таниб олиш аниқлигини оширмасда, жараён учун сарфланган вақтни камайтиради. 1-жадвалда турли ўлчамдаги тасвирлардан юзни аниқлаш ва таниб олиш вақтлари келтирилган [6].

Юзни нормаллаштириш. Юзларни таниб олиш алгоритмларининг ишлаш самарадорлигини тестлашда қўлланиладиган юз базаларида юзда мавжуд тўсиқлар эътиборга олинган. Аммо, юзни таниб олишда тасодифий пайдо бўладиган тўсиқлар ҳам мавжудки, уларнинг барчасини юз базаларида тўплаш имконияти мавжуд эмас.

1-жадвал. Турли ўлчамдаги тасвирлардан юзни аниқлаш ва таниб олиш вақти

Сарфланган вақт (мс)	Тасвир ўлчами					
	480*360		650*400		700*580	
	GPU	CPU	GPU	CPU	GPU	CPU
Юзни аниқлаш	102	780	160	900	350	1406
Юзни таниб олиш	90	207	127	279	312	300

Шунинг учун таниб олиш жараёнини бошлашдан олдин, аниқланган юзни қайта ишлаш лозим. Бунинг учун аниқланган юз PCA [7] алгоритми асосида нормаллаштирилади (2-расм).



2-расм. PCA алгоритми асосида нормал юзларни генерациялаш

PCA асосида юзни нормаллаштириш.

1. Аниқланган юзни 3-расм асосида қайси синфга тегишли эканини аниқлаймиз. Бунинг учун аниқланган юздан кўзлар орасидаги масофаларни ҳисоблаш лозим.

Агар, $\frac{a}{b} = [0,8 - 1,2]$ бўлса, биринчи ҳолат қаралади.
 Агар, $\frac{a}{b} > 1,2$ бўлса, иккинчи ҳолат қаралади.
 Агар, $\frac{a}{b} < 0,8$ бўлса, учинчи ҳолат қаралади.



3-расм. Юз ҳолатига боғлиқ ҳолда синфлаштириш

Бу ерда, а-чап кўзнинг ўлчами, b-эса, ўнг кўзнинг ўлчами ҳисобланади.

2. Ҳар бир синфга тегишли 100 тадан юз олинади ва ягона юз тасвири ҳосил қилинади. Унинг кетма кетлиги куйидагича:

а) $M \times N$ ўлчамдаги $Z_i \{Z_1, Z_2, \dots, Z_{100}\}$ тасвирлар тўплами олинади. Тестлаш учун 256×256 ўлчамдаги тасвир олинади ва 65536 ўлчамдаги вектор ҳосил қилинади. Ҳосил бўлган Z_i ($i=100$) тасвирларнинг ўртачаси куйидаги формула асосида аниқланади:

$$\bar{Z} = \frac{1}{N} \sum_{i=1}^N Z_i$$

\bar{Z}_r , \bar{Z}_g ва \bar{Z}_b лар мос ҳолда юқоридаги формула асосида ҳисобланади.

б) вектор қийматларини тарқалиш даражасини аниқлаш учун ўртача қийматларга мос ҳолда ковариацион матрица ҳисобланади:

$$C_m = \frac{1}{N} \sum_{i=1}^N (Z_i - \bar{Z})(Z_i - \bar{Z})^T$$

Бу ерда, T – транспонерланган матрицани англатади. Бизда RGB ранг моделидаги тасвир олинганлиги учун, ковариацион матрица куйидагича ҳисобланади:

$$C_{mr} = \frac{1}{N} \sum_{i=1}^N (Z_{ir} - \bar{Z}_r)(Z_{ir} - \bar{Z}_r)^T$$


$$C_{mg} = \frac{1}{N} \sum_{i=1}^N (Z_{ig} - \bar{Z}_g)(Z_{ig} - \bar{Z}_g)^T$$

$$C_{mb} = \frac{1}{N} \sum_{i=1}^N (Z_{ib} - \bar{Z}_b)(Z_{ib} - \bar{Z}_b)^T$$

Бу ерда, Z_{ir} , Z_{ig} ва Z_{ib} мос ҳолда қизил (red), яшил (green) ва кўк (blue) ранглارнинг қийматлари.

с) Матрицанинг хусусий векторлари (eigenvectors) ва унга мос хусусий қийматлари (eigenvalues) куйидаги формула асосида аниқланади.

$$C_m V = V \lambda$$



4-расм. Snet тармоғининг асосий схемаси

Бу ерда, V - хусусий векторлар тўплами ва λ - хусусий қийматлар. Бунинг учун, хусусий қийматлар детерминантни кенгайтириш усули орқали ҳисоблаб топилади ва олинган қийматлар асосида матрицаларни кўпайтириш орқали хусусий векторлар ҳисобланади [8].

Хусусий қийматларни ҳисоблаш куйидагича амалга оширилади. Бу ерда, I – бирлик вектор.

$$C_m V = V I \lambda$$

$$V(C_m - I \lambda) = 0$$

$$\det(C_m - I \lambda) = 0$$

Ушбу тенгликдан m та λ хусусий қийматлар ва улар асосида хусусий векторлар аниқланади. Мазкур тенглик асосида m та V хусусий векторларга эришамиз. қизил (red), яшил (green) ва кўк (blue) рангларларнинг хусусий қийматлари ва хусусий векторлари мос ҳолда юқоридаги тенглик асосида ҳисобланади.

d) Хусусий векторлар унга мос хусусий қийматлар билан юқоридан пастга қараб сараланади (катта қиймат юқорида, кичик қиймат пастда).

е) Ҳар бир ўртачага марказлаштирилган тасвирлар хусусий соҳалардан фойдаланган ҳолда проекцияланади ва қуйидаги формула ёрдамида ҳисобланади.

$$W_{ir} = V_{ir}^T (Z_{ir} - \bar{Z}_r)$$

$$W_{ig} = V_{ig}^T (Z_{ig} - \bar{Z}_g)$$

$$W_{ib} = V_{ib}^T (Z_{ib} - \bar{Z}_b)$$

3. Иккинчи босқич асосида ҳар бир синф учун алоҳида юзлар ҳосил қилинади. Бунда 3 та нормал тасвир ҳосил бўлади.

Кирувчи тасвирни нормаллаштириши.

Кирувчи тасвир PCA асосида юзни нормаллаштиришнинг 1-босқичи асосида қайси синфга тегишли эканлиги аниқланади. Синфга мос нормал тасвир ва унинг ўлчамига тенглаштирилган кирувчи тасвирлар пикселларининг ўртача қийматлари ҳисобланади.

$$NT_i = \frac{(W_i + Z_i)}{2}$$

Бу ҳисоблаш барча пикселлар учун амалга оширилади ва натижада бир хил ўлчамдаги нормаллашган тасвир ҳосил бўлади. Бу ерда, NT_i – нормаллаштирилган тасвир, W_i – нормал тасвир, Z_i – кирувчи тасвир.

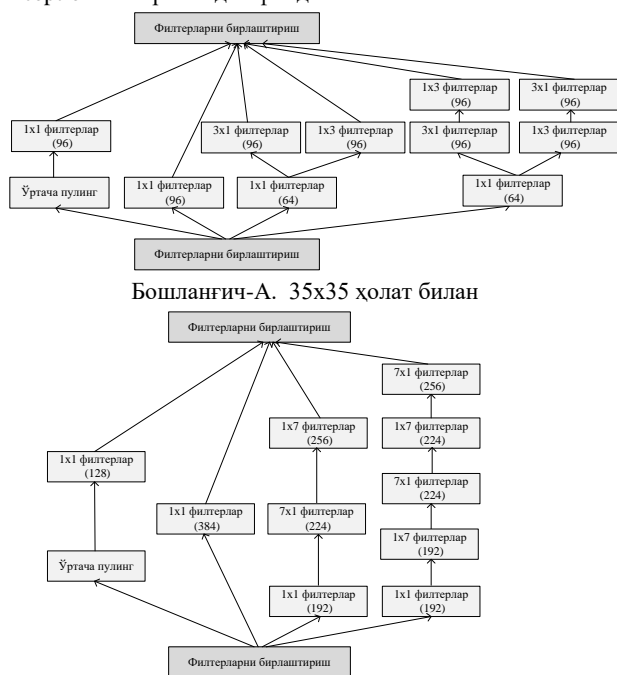
Классик усуллари мужассамлашган ҳолда қўллаш натижасида таниб олиш кўрсаткичини 99% гача ошириш мумкин, аммо, ўртача хатоликни 3 % гача камайтиришга

3-жадвал. ILSVRC 2012 тармоғидан олинган 50 000 та тасвирнинг натижалари

Тармоқ	Топ-1 хатолик	Топ-5 хатолик
Inception-v3	18,9	4,3
Inception-ResNet-v1	18,8	4,3
Inception-v4	17,7	3,8

Inception-v4 тармоғи [13].

Ҳисоблаш самарадорлигини ошириш ва ҳисоблаш қурилмаларига тушадиган юкланишни камайтириш учун Inception-v4 тармоғидан фойдаланиш лозим.



эришилган. Шунинг учун, хатоликларни камайтиришда DL усулларида фойдаланиш мақсадга мувофиқ.

SEnet тармоғи асосида юзни таниб олиши.

Нормаллаштирилган юз тасвирини хусусиятларни ажратиб олиш учун SEnet (сиккиш ва кўзғатиш) тармоғидан фойдаланиш мақсадга мувофиқ ҳисобланади. Чунки, ILSVRC-2017 танловида ғолиб бўлгани ва топ-5 хатолик даражасини ўртача ҳисобда 2,3% (2-жадвал) га туширганлини келтириш мумкин. Олдинги тадқиқотларда хатолик қиймати 2,9% гача туширилган [9].

2-жадвал. Таниб олиш хатолиги

Тармоқ номи	Хатолик даражаси
SEnet	0,0227
Dual Path Network [10]	0,027
ResNeXts [11]	0,032
PyramidNets [12]	0,033

SEnet икки қисмдан ташкил топган (4-расм):

S (Squeeze) – сиккиш босқичи.

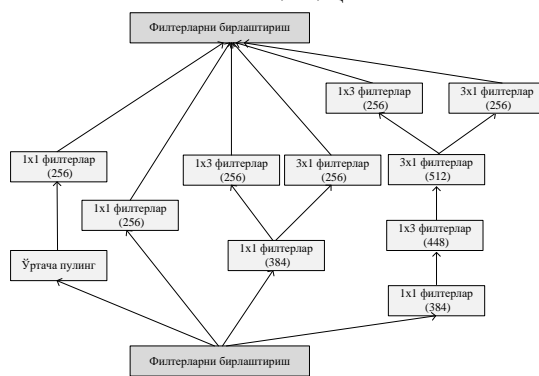
E (Excitation) – кўзғатиш босқичи.

Биринчи навбатда F_{tr} функцияси ёрдамида $H' \times W' \times C'$ ўлчамидаги тасвир $H \times W \times C$ ўлчамидаги тасвирга қуйидаги формула асосида келтирилади:

$$u_c = v_c * X = \sum_{s=1}^{c'} v_c^s * x^s$$

Бу ерда, $v_c = [v_c^1, v_c^2, \dots, v_c^{c'}]$ – кернел филтерлари, $X = [x^1, x^2, \dots, x^{c'}]$. F_{tr} функцияси ўрнида Inception-v4 тармоғини қўллаш таниб олиш самарадорлигини ошириш, ҳисоблаш қурилмаларига тушадиган юкланишни камайтириш ва чизиксиз функциялардан фойдаланиш имкониятларини тақдим этади.

Бошланғич-В 17x17 ҳолат билан



Бошланғич-С 8x8 ҳолат билан

5-расм. Inception-v4 тармоғининг А, В, С турлари ва мос ўлчам ҳолатлари

Ушбу тармоқ учта бошланғич тармоқости қисмларидан ташкил топган бўлиб, ҳисоблаш тезлигини ошириш учун 1x1 филтерларидан фойдаланилган. Бундан ташқари катталикларнинг чизикли кетма-кетлигини чизиксиз кўринишга ўтказиш мақсадида турли қадамлардан фойдаланилган. 5-расмда учта бошланғич тармоқости қисмлари тасвирланган бўлиб, унда ҳисоблаш учун сарфланадиган вақт ва ҳисоблашлар сонини камайтириш мақсадида, $n \times n$ филтер ўрнида $1 \times n$ ва $n \times 1$ филтерларни кетма-кет қўллаш мақсадга мувофиқ. Бунда


хисоблашлар $n^2 - 2n$ га камаяди.

Бу ерда, $n_x n_y$ филтер ўлчами бўлиб, свёртка қадамидан кейин тасвир ўлчами куйидаги формула оркали хисобланади:

$$\text{Чик. тасвир} = \left(\frac{n_x + 2p - f}{s} + 1 \right) \times \left(\frac{n_y + 2p - f}{s} + 1 \right)$$

Бу ерда, n_x ва n_y кирувчи тасвир ўлчами, p – паддинг (бизда қўлланилмаган), f – филтер ўлчами, s – кадам.

Insertion-v4 ва унинг бошланғич А, В ва С тармоқларида чизиксиз хусусиятларга эришиш мақсадида

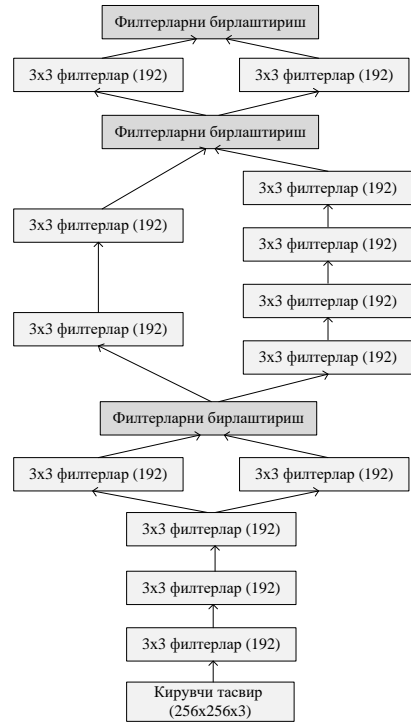


Insertion-v4 тармоғининг схемаси

параллел хисоблашлар қўлланилган. Икки параллел свёрткалар филтерларни бирлаштириш функцияси ёрдамида бирлаштирилади ва чизиксиз қийматларни ҳосил қилиш учун яна параллел хисоблашга ўтилади.

Тармоқда энг катта ва ўртача пулинг қўлланилган бўлиб, белгиланган соҳадаги энг катта ва ўртача қийматларни олишни аниқлатади.

Insertion-v4 тармоғидан чиққан натижа SEnet тармоғининг сиқиш босқичига жўнатилади.



Асос тармоқининг қисми

6-расм. Insertion-v4 тармоғининг умумий схемаси

Сиқиш функцияси ёрдамида $H \times W \times C$ ўлчамидаги тасвир F_{sq} функцияси ёрдамида $1 \times 1 \times C$ ўлчамга келтирилади. F_{sq} функцияси куйидаги формула асосида хисобланади:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j)$$

Кейинги босқичда қўзғатиш функцияси хисобланади. Унинг ёрдамида векторнинг ўлчами камайтириш ва ошириш функциялари ёрдамида чизиксизлиги таъминланади. У куйидаги формула асосида хисобланади.

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z))$$

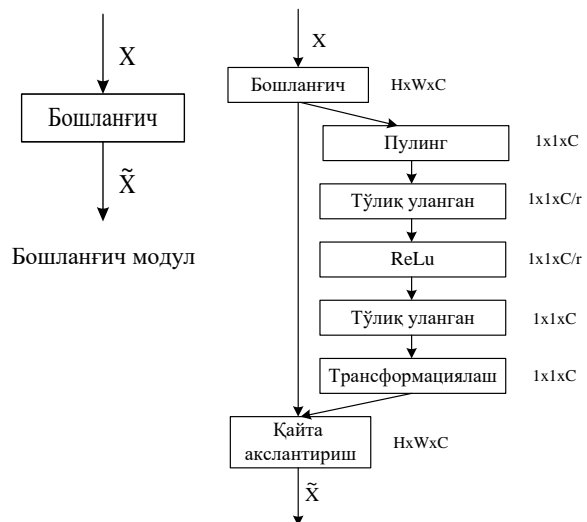
Бу ерда, δ – ReLu [V. Nair and G. E. Hinton, "Rectified linear units improve restricted boltzmann machines," in ICML, 2010.] функцияси хисобланиб, унинг қиймати (0:1) ораликда бўлади. ReLu функцияси куйидагича хисобланади:

$$ReLU = W * x$$

Бу ерда, W нейроннинг оғирлиги, x – эса, нейроннинг қиймати.

$W_1 \in \mathbb{R}^{c \times c}$ – c ва r параметрлари ёрдамида вектор ўлчамини кичиклаштириш. r – камайтириш кўрсаткичи (ишда r параметер учун самарали қиймат сифатида 16 танланган).

$W_2 \in \mathbb{R}^{c \times \frac{c}{r}}$ – c ва r параметрлари ёрдамида вектор ўлчамини катталаштириш.



SEnet тармоғида сиқиш ва қўзғатиш босқичлари

7-расм. SEnet тармоғини Insertion-v4 тармоғида қўллаш босқичлари

Кейинги босқичда чикувчи қиймат U активлаштириш функцияси ёрдамида қайта трансформацияланади.

$$\tilde{x}_c = F_{scale}(u_c, s_c) = s_c \cdot u_c$$

Бу ерда, $u_c \in \mathbb{R}^{H \times W}$.

Келтирилган ҳисоблашларнинг умумий кўриниши 7-расмда батафсил тасвирланган.


Ушбу тармоқдан фойдаланиш бошқаларига нисбатан кўпроқ ҳисоблаш имкониятларини талаб этади (3.87Гфлопс). Шунингдек, ҳисоблаш учун ҳам кўп вақт талаб этилади (167 мс) ва параметерлар сони ҳам кўп.

Юз хусусиятлари орасидаги фарқларни ҳисоблаш усуллари асосида ишлаб чиқилган бир нечта йўқотиш функциялари (loss function) мавжуд бўлиб, улар ёрдамида

4-жадвал. Йўқотиш функциясининг аниқлик даражаси [14]

Йўқотиш функцияси	Усул	Наирир этилган вақт	Тармоқ	Тармоқлар сони	Маълумотлар базаси	Аниқлиги (%)
softmax	DeepFace	2014	Alexnet	3	Facebook	97,35
L-softmax	L-softmax	2016	VGGNet-18	1	CASIA-WebFace	98,71
A-softmax	SphereFace	2017	ResNet-64	1	CASIA-WebFace	99,42
triplet loss	FaceNet	2015	GoogleNet-24	1	Google	99,63
L2-softmax	L2-softmax	2017	ResNet-101	1	MS-Celeb-1M	99,78

8-расмда W_1 ва W_2 оғирликка эга бўлган, икки хусусият ўртасидаги бурчакни аниқлаш келтирилган. У θ билан белгиланади.



8-расм. Softmax йўқотиш функциясининг тасвирланиши [15]

Умумий ҳолатда Softmax йўқотиш функцияси куйидаги формула асосида ҳисобланади.

$$L = \frac{1}{N} \sum_i -\log \left(\frac{e^{\|x_i\| \cos(\theta_{y_i,i})}}{\sum_j e^{\|x_i\| \cos(\theta_{j,i})}} \right)$$

Бу ерда, x_i – хусусиятнинг қиймати, θ_{y_i} – y_i -катламдаги хусусиятлар оғирлиги орасидаги бурчак, j – хусусиятлар синфи ва оғиш вектори нолга тенг деб қаралган.

$$\|x_i\| = \sqrt{x_i^T * x_i}$$

Оғирликлар орасидаги бурчак $\theta(0: \pi/m)$ ораликда бўлади.

Агар, $m=1$ бўлса, $\theta(0: \pi)$ – оддий Softmax.

Агар, $m=2$ бўлса, $\theta(0: \pi/2)$ – A-Softmax,

$\frac{m-1}{m+1} \theta$ формула асосида аниқланса - L-Softmax деб қаралади. Ушбу ҳолатда, m нинг қиймати қанча катта бўлса аниқлик шунча юқори бўлади [16].

L2-softmax йўқотиш функцияси.

Бошқа softmax йўқотиш функцияларига нисбатан хусусиятлар орасидаги фарқни аниқ кўрсатиш ва ҳисоблаш имкониятини беради. У куйидаги формула асосида ҳисобланади.

тўлиқ уланган катламидан чиққан ўхшаш натижаларни саралашамиз мумкин. 4-жадвалда келтирилган маълумотларга эътибор қаратадиган бўлсак, L2-softmax йўқотиш функциясининг аниқлик даражаси энг яхши ҳисобланади. Шунинг учун тўлиқ уланган қатламдан чиққан хусусиятларни саралаш учун L2-softmax функциясида фойдаланамиз.

Йўқотиш функциялари бир хил хусусиятларни камайтириш ва турли хусусиятлар ўртасидаги фарқни аниқлашга қаратилган.

$$L = \frac{1}{N} \sum_i -\log \left(\frac{e^{\|f(x_i)\|_2 \cos(\theta_{y_i,i})}}{\sum_j e^{\|f(x_i)\|_2 \cos(\theta_{j,i})}} \right)$$

Бу ерда, $\|f(x_i)\|_2 = \sqrt{f(x_i)^T * 2 * f(x_i)}$ асосида ҳисобланади.

Унинг самарадорлиги 4-жадвалда келтирилган.

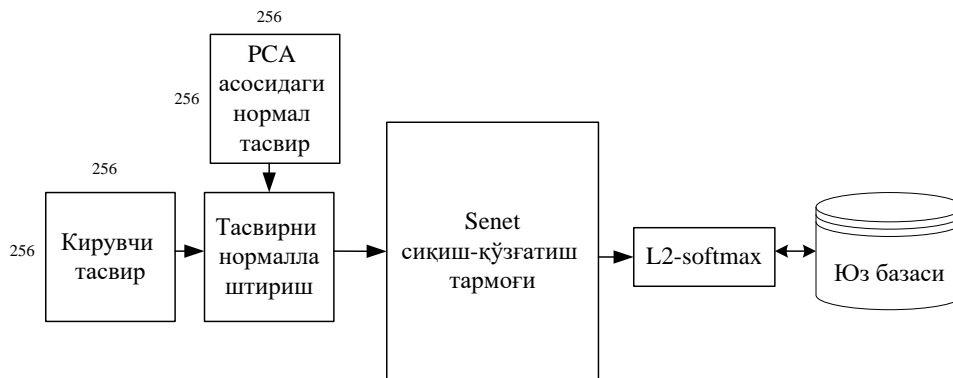
Таниб олиш усулининг умумий схемаси 9-расмда келтирилган.

5-жадвал. SEnet тармоғида қўлланилган параметерларнинг қийматлари

Белгила ниши	Қиймати	Номи	Вазифаси
f	3x3 1x1 7x7=1x7+7 x1 3x3=1x3+3 x1	Филтер	Кирувчи тасвирни тасодифий қийматлар билан қайта ишлайди
s	2	Қадам	Филтер ва пулинг учун қадам узунлиги
r	16	Камайиш кўрсатки чи	Кўзгатиш функциясини ҳисоблашда векторни катталаштириш ва кичиклаштиришда қўлланилади

Таниб олиш самарадорлигини ошириш мақсадида тармоқда қўлланиладиган параметрларга алоҳида эътибор қаратилган. Ушбу параметерларнинг қийматлари 5-жадвалда келтирилган.

Параметерлар сонини камайтириш ва ортиқча ҳисоблаш юкланишини олдини олиш учун 7x7 филтерлар ўрнида 1x7 ва 7x1 филтерларни қўллаш мақсадга мувофиқ. 7x7=49 та параметер. 1x7+7x1=14 та параметер. Яъни ҳисоблаш элементлари сони 2,88 марта камаяди ва натижа ўзгармас.



9-расм. Таниб олиш усулининг умумий схемаси

Ўртача хатоликни 2,3% дан 2,1% гача камайтиришга эришилди.

Хулоса

Юзларни таниб олиш тизимларидаги хатоликларни камайтириш учун юзнинг тўсиқлар орқали беркитилган қисмларини нормаллаштириш орқали очиш ва DL тармоқларидан фойдаланган ҳолда, аниқликни ошириш ва хатоликни камайтириш усуллари ишлаб чиқилган. Аниқланган юзни таниб олиш самарадорлигини ошириш учун қўлланилган юзларни нормаллаштириш ҳисоблаш вақтини орттиришга олиб келади ва уни бар்தараф этиш учун самарали филтерлар ўлчамларидан фойдаланиш ишлаб чиқилган.

Фойдаланилган адабиётлар:

- [1] Face Recognition Vendor Test (FRVT). Performance of Face Identification Algorithms NIST Interagency Report 8009. Patrick Grother, Mei Ngan. May 26, 2014.
- [2] Valenti R. et al. Machine learning techniques for face analysis //Machine Learning Techniques for Multimedia. – Springer, Berlin, Heidelberg, 2008. – С. 159-187.
- [3] Rutkovskaya, M. Pilinskiy, L. Rutkovskiy. Neyronne seti, geneticheskie algoritm i nechetkie sistem // Per. s polskogo M.: Goryachaya liniya-Telekom, 2004 – 452 с.
- [4] Lu Z., Jiang X., Kot A. Enhance deep learning performance in face recognition //Image, Vision and Computing (ICIVC), 2017 2nd International Conference on. – IEEE, 2017. – С.
- [5] Liu Y., Li H., Wang X. Rethinking feature discrimination and polymerization for large-scale recognition //arXiv preprint arXiv:1710.00870. – 2017.
- [6] Bhutekar S. J., Manjaramkar A. K. Parallel face Detection and Recognition on GPU //International Journal of Computer Science and Information Technologies. – 2014. – Т. 5. – №. 2. – С.
- [7] Tharwat A. Principal component analysis-a tutorial //International Journal of Applied Pattern Recognition. – 2016. – Т. 3. – №. 3. – С. 197-240.
- [8] Smith L. I. A tutorial on principal components analysis. – 2002.
- [9] Hu J., Shen L., Sun G. Squeeze-and-excitation networks //arXiv preprint arXiv:1709.01507. – 2017. – Т.
- [10] Chen Y. et al. Dual path networks //Advances in Neural Information Processing Systems. – 2017. – С. 4467-4475.
- [11] S. Xie, R. Girshick, P. Dollár, Z. Tu, and K. He. Aggregated Residual Transformations for Deep Neural Networks. In CVPR, 2017.
- [12] D. Han*, J. Kim* and Junmo Kim. "Deep pyramidal residual networks", equally contributed by the authors*,

CVPR 2017.

[13] Szegedy C. et al. Inception-v4, inception-resnet and the impact of residual connections on learning //AAAI. – 2017. – Т. 4. – С. 12.

[14] Mei Wang, Weihong Deng. Deep Face Recognition: A Survey. arXiv:1804.06655v7. 28 Sep 2018.

[15] Liu W. et al. Spheroface: Deep hypersphere embedding for face recognition //The IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2017. – Т. 1. – С. 1.

[16] Liu W. et al. Large-Margin Softmax Loss for Convolutional Neural Networks //ICML. – 2016. – С. 507-516.

Каримов Маджит Маликович

Вазирлар Маҳкамаси ҳузуридаги Давлат тест маркази директори, профессор, т.ф.д.

Тел.: 71-235-19-14

Эл. почта: info@dtm.uz

Исломов Шахбоз Зокир ўғли

ТАТУ Phd талаба

Тел.: +998 (71) 238-65-38

Эл. почта: shaxboz4044@gmail.com

Бекмирзаев Обит Нуралиевич

ТАТУ, Ахборот хавфсизлигини таъминлаш кафедраси ассистенти

Тел.: +998 (71) 238-65-25

Эл. почта: obit.bekmirzaev@gmail.com

Зокиров Одилжон Ёқубжон ўғли

ТАТУ Phd талаба

Тел.: +998 (71) 238-65-25

Эл. почта: z.odil044@gmail.com

Karimov M.M., Isломov Sh.Z., Bekmirzaev O.N., Zokirov O.Y.

Methods of improving efficiency of face recognition

In this article is given problems in classic face recognition methods and algorithms, and reducing errors and current vulnerabilities by methods of improving efficiency of face recognition. There are false positive and negative rates in face recognition and reducing these errors by normalization faces is proposed. For increasing speed and accuracy of recognition is developed using multiple networks and optimization filter size.

Keywords: face recognition, error, efficiency, normalization, Deep Learning, nets, squeeze, excitation inception, loss function.

Тел.: +998998420601

Эл-почта: shaxboz4044@gmail.com