

KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS
SISTEMINĖS ANALIZĖS KATEDRA

Oleg Studenikin

**ATVIRKŠTINIO SKLEIDIMO NEURONINIAI TINKLAI: VAIZDŲ
ATPAŽINIMAS**

Magistro darbas

Darbo vadovas
doc. dr. Vytautas Rudžionis

KAUNAS, 2005

KAUNO TECHNOLOGIJOS UNIVERSITETAS
INFORMATIKOS FAKULTETAS
SISTEMINĖS ANALIZĖS KATEDRA

TVIRTINU
Katedros vedėjas
prof. Rimantas Barauskas
2005-05-23

**ATVIRKŠTINIO SKLEIDIMO NEURONINIAI TINKLAI: VAIZDŲ
ATPAŽINIMAS**

Informatikos mokslo magistro baigiamasis darbas

Kalbos konsultantė

Lietuvių kalbos katedros lektorė

dr. J. Mikelionienė

2005-05-16

Vadovas

doc. dr. Vytautas Rudžionis

2005-05-23

Darbo konsultantai

doc. dr. J. Punys

dr. V. Perlibakas

Recenzentas

doc. dr. M. Tamošiūnaitė

2005-05-23

Atliko

IFM– 9/3gr. stud.

O. Studenikin

2005-05-23

KAUNAS, 2005

Turinys

1. ĮVADAS	4
2. NEURONINIAI TINKLAI	7
2.1. Biologiniai neuroniniai tinklai	7
2.2. Dirbtiniai neuroniniai tinklai	9
2.2.1. Dirbtinis neuronas	10
2.3. Dirbtinių neuroninių tinklų modeliai	11
2.3.1. Vienasluoksnis modelis	13
2.3.2. Daugiasluoksnis modelis	14
2.4. Dirbtinių neuroninių tinklų mokymas	17
2.4.1. Hebb'o taisyklė	19
2.4.2. Delta taisyklė	19
2.4.3. Atvirkštinė skleidimo taisyklė	21
3. ATVIRKŠTINIO SKLEIDIMO DIRBTINIŲ NEURONINIŲ TINKLŲ MOKYMAS	24
3.1. Momentum-Term taisyklė	24
3.2. Svorio redukcija	24
3.3. Aktyvavimo funkcija	24
3.4. Slenkstinės vertės transformacija	25
3.5. Atvirkštinio skleidimo DNT privalumai ir trūkumai	26
4. DNT BEI POŽYMIŲ IŠSKYRIMO METODŲ TAIKYMAS SPRENDŽIANT VAIZDŲ ATPAŽINIMO UŽDAVINIUS	27
4.1. Požymių nustatymas ir išskyrimas	28
4.2. Terpės požymių paskirstymas į sritis, pagrindinių požymių išskyrimas	30
4.2. Radialiniai bazinių funkcijų neuroniniai tinklai	35
4.3. Sąsukiniai neuroniniai tinklai	37
4.5. DNT tipų ir požymių išskyrimo metodų analizė, sprendžiant veidų atpažinimo uždavinius	39
4.6. DNT tipų ir požymių išskyrimo metodų analizės išvados	41
5. PROJEKGINĖ REALIZACIJA	42
5.1. Projektinės dalies tikslas	42
5.2. Reikalavimų specifikavimo dokumentas programinei įrangai „Veidas“	43
5.3. Projektuojamos sistemos architektūra	48
5.4. Sistemos panaudojimo atvejų diagrama (<i>USE CASE</i>)	50
5.5. Atvirkštinio skleidimo algoritmo realizacija	51
5.6. Programinių modulių ir objektų aprašymas	59
5.7. Programinių modulių realizacijos problemos	62
6. TESTAVIMAS	63
6.1. Testavimo eiga	64
6.2. Testavimo išvados	67
7. VARTOTOJO DOKUMENTACIJA	69
7.1. Vartotojo vadovas	69
7.2. Sistemos klaidų vadovas	71
7.3. Sistemos instaliavimo dokumentas	72
8. PŪ PRODUKTO KOKYBĖS ĮVERTINIMAS	73
9. IŠVADOS	75
10. LITERATŪRA	77
11. SANTRAUKA	80
12. TERMINŲ IR SANTRUMPŲ ŽODYNAS	81
13. PRIEDAI	82
13.1. DVD diskas	82
13.2. Darbų perdavimo – priėmimo aktas	83
13.3. Kokybės įvertinimo anketos	84

1. ĮVADAS

Šiuo metu Europos Sąjungoje labai paplito biometrinės žmogaus identifikavimo sistemos. Tradicinės identifikavimo sistemos reikalauja slaptažodžio žinojimo, rakto turėjimo, identifikavimo kortelės, arba kito identifikavimo daikto, kurį galima pamiršti arba pamesti. Be to, biometrinių sistemų pagrindą sudaro unikalios žmogaus biometrinės charakteristikos, kurias sunku pakartoti ir kurios gali nustatyti konkretų žmogų. Prie tokių charakteristikų galima priskirti piršto antspaudus, akies struktūrą. Žmogaus veidas, balsas ir kvapas taip pat yra individualūs.

Vaizdų atpažinimas susipina su veidų atpažinimu. Tokie uždaviniai neturi tikslaus analitinio sprendimo. Be to, reikia išskirti pagrindinius požymius, kurie charakterizuoja regėjimo vaizdą. Reikia taip pat nustatyti požymių svarbumą išrenkant jų svorinius koeficientus ir numatyti ryšius tarp požymių. Iš pradžių šiuos uždavinius atlikdavo žmogus-ekspertas rankiniu būdu, darant eksperimentus, tai užimdavo labai daug laiko ir neužtikrindavo kokybės. Naujesniuose metoduose pagrindinių požymių išskyrimas atliekamas darant apmokyto išskyrimo automatinę analizę, bet vis dėlto daugybė informacijos apie požymius įvedama rankiniu būdu. Naudojant tokių analizatorių automatinį taikymą, išskyrimas turi būti pakankamai didelis ir apimti visas galimas situacijas.

Dirbtinių neuroninių tinklų taikymas žmogaus atpažinimo pagal jo veidą uždaviniui spręsti, yra perspektyvi kryptis, į ką ir nukreiptas pagrindinis šio darbo dėmesys.

Dirbtinių neuroninių tinklų metodai siūlo kitą vaizdų atpažinimo uždavinių sprendimo būdą. Dirbtinių neuroninių tinklų (DNT) architektūra ir analizė turi biologinius pagrindus. Svoriai neuroniniuose tinkluose neapskaičiuojami sprendžiant analitines lygtis, o reguliuojami įvairiais lokaliniais apmokymo metodais (pavyzdžiui, atvirkštinio sklaidymo mokymo algoritmas). Neuroniniai tinklai apmokami tam tikrų pavyzdžių rinkiniu. Tarp įvairių DNT struktūrų, viena iš žinomiausių DNT struktūrų yra daugiasluoksnė struktūra, kurioje kiekvienas iš laisvojo sluoksnio neuronų surištas su prieš tai esančio sluoksnio neuronų aksonais arba, pirmo sluoksnio atveju, su visais DNT įėjimais. Tokie DNT vadinami pilnai surištais. Kai tinkle tik vienas sluoksnis, tai jo apmokymo algoritmas su mokytoju yra akivaizdus, nes vienintelio sluoksnio teisingos neuronų išeities būsenos iš anksto yra aiškios, ir sinaptinių ryšių paderinimas vyksta ta kryptimi, kuri labiausiai minimizuos klaidą tinklo išėjime. Šiuo principu sudaromas, pavyzdžiui, vienasluoksnio perceptrono apmokymo algoritmas [32]. Daugiasluoksniuose tinkluose optimalios neuronų išėjimo reikšmės nėra žinomos, dviejų arba daugiau sluoksnių perceptronų jau neįmanoma apmokyti, vadovaujantis tik klaidų dydžiais DNT išėjime. Vienas iš šios problemos sprendimo variantų – išėjimo signalų rinkinių kūrimas, signalai atitinka įėjimo signalus kiekvienam DNT sluoksniui, kas,

žinoma, yra daug darbo reikalaujančio operacija ir ne visada įvykdoma. Antras variantas – sinapsų svorinių koeficientų dinaminis paderinimas, kurio metu išrenkami labiausiai silpni ryšiai, kurie truputį pasikeičia į tą arba į kitą pusę, o pasilieka tik tie pakeitimai, kurie sukėlė klaidos sumažinimą viso tinklo išėjime. Akivaizdu, kad šis „bandymo“ metodas, nepaisant jo atrodomo paprastumo, reikalauja didelių skaičiavimų. Ir, galiausiai, trečias, labiausiai priimtinas variantas - klaidos signalų skleidimas nuo DNT išėjimų iki DNT įėjimų. Skleidimas vyksta tokia kryptimi, kuri yra atvirkštinė tiesioginiam signalų skleidimui įprasto darbo metu. Šis DNT apmokymo algoritmas vadinamas atvirkštinio skleidimo procedūra. Būtent šiai mokymo procedūrai bus išskirtas ypatingas dėmesys šiame darbe.

DNT mokymo procese vyksta automatinis pagrindinių požymių išskyrimas, jų svarbos ir sąryšių nustatymas. Apmokytas DNT gali pasinaudoti patirtimi, kuri buvo gauta apmokymo procese su nežinomais vaizdais. Per apmokymo procesą naudojamos algoritmo apibendrinimo savybės.

Sprendžiant projektinius uždavinius buvo išskirtos principinės darbo nuostatos:

1) Sprendžiant skirtingus uždavinius, sukurta daugelis algoritmų ir būdų. Bet daugelio šių algoritmų neįmanoma apibūdinti, nusakyti, ar pasiteisins (turima omenyje greitimeika, atpažinimo tikslumas ir t. t.) jų taikymas konkrečiame uždavinyje.

2) Praktiškai galima parinkti keletą algoritmų kiekvienam uždaviniui spręsti, bet labiausiai tinkamo algoritmo pasirinkimas dažniausiai yra pagrįstas euristiniais principais ir testavimo rezultatais.

3) Daugelyje atvejų, sprendžiant konkrečius uždavinius, taikomos skirtingos jau žinomų algoritmų kombinacijos, nes visiškai naujo algoritmo kūrimas reikalauja didžiulės kompiuterinio regėjimo patirties.

4) Metodai, leidžiantys automatizuoti ir suderinti algoritminio aprūpinimo atpažinimo procesus optimaliai sprendžiamai procedūrai gauti, turėtų ypač palengvinti praktinį vaizdų analizės metodų naudojimą.

Šiame darbe aprašyti žmogaus atpažinimo pagal jo veidą metodai, ir galimybė juos taikyti kartu su dirbtinių neuroninių tinklų metodais. Pateikta dirbtinių neuroninių tinklų metodų analizė ir jų taikymas žmogaus veidui bei vaizdams atpažinti. Darbe aprašyti skirtingi vaizdo pateikimo būdai ir jų savybių nustatymas.

Pagal siūlomus sprendimo metodus buvo paruošta publikacija. **Publikacija „Atvirkštinio skleidimo neuroniniai tinklai: veidų atpažinimas“** buvo skaityta 10-ojoje tarpuniversitetinėje magistrantų ir doktorantų konferencijoje. Konferencija vyko KTU, Informatikos fakultete 2005 m.

Šiai problemai spręsti darbas suskirstytas į tokias dalis: *antroje dalyje* apžvelgiama probleminė neuroninių tinklų sritis bei atliekama jų išsami apžvalga, išskiriami pagrindiniai DNT modeliai uždaviniams spręsti, aptariamos DNT mokymo taisyklės, išskiriant jų privalumus bei trūkumus, *trečioje dalyje* įvairiais aspektais aprašomas dirbtinių neuroninių tinklų mokymas panaudojus skirtingus aktyvavimo metodus, *ketvirtoje dalyje* aptariami dirbtinių neuroninių tinklų sprendimo būdai atliekant vaizdų atpažinimą, aptariamas taip pat siūlomas požymių išskyrimo metodas vaizdams apdoroti, atliekama DNT ir požymių išskyrimo metodų analizė, apibendrinami analitinės dalies rezultatai, *penktoje dalyje* atliekama projekcinė realizacija, remiantis analitinėje dalyje pasiūlytais metodais, aprašoma atvirkštinio skleidimo mokymo algoritmo realizacija, pateikimas busimos sistemos funkcionavimo modelis, *šeštoje dalyje* atliekamas realizuoto projekto testavimas, įvertinant biometrinės sistemos atpažinimo kriterijus, *septintoje dalyje* aprašoma realizuotos sistemos dokumentacija, *aštuntoje dalyje* atliekamas PI produkto kokybės įvertinimas, *devintoje dalyje* pateikiamos darbo išvados.

Magistro darbą sudaro 13 skyrių, 10 lentelių, 23 grafinės iliustracijos, 3 priedai, 83 puslapiai.

2. NEURONINIAI TINKLAI


Neuroniniai tinklai – tai biologiniu pagrindu paremtas žmogaus smegenų nervų tinklas. Toliau darbe mes naudosime specialųjį terminą - NT.

NT sudaro daugelis neuronų, kurie tarpusavyje yra susieti. Neuronas yra tarsi procesorius, kuris savarankiškai atlieka savo darbą ir yra nepriklausomas nuo kitų neuronų. Neuronas apdoroja informaciją, kuri buvo gauta iš kitų šalia esančių neuronų, su kuriais jis yra surištas sinaptiniais ryšiais. Neuronas gauna informaciją, ją apdoroja ir perduoda kitiems neuronams.

2.1. Biologiniai neuroniniai tinklai


Kiek žinoma, pirmasis aiškintis informacijos apdorojimo principus gyvuose organizmuose pradėjo Aristotelis, dar 400 metų prieš mūsų erą teigęs, kad atmintis sudaryta iš paprastų elementų, atliekančių įvykių, objektų panašumo, jų sekos laike ir erdvėje nustatymo funkcijas. Elementai sujungti į sudėtingesnes struktūras, atliekančias mąstymo, atminties operacijas. Vėlesniais amžiais esminį indėlį čia įnešė britų materialistai, teigė, kad visas žmogaus elgesys, įskaitant ir sąmonę, turi materialų pagrindą. Jau šiais laikais išaiškinta, jog informaciją gyvuose organizmuose apdoroja specialios ląstelės, pavadintos neuronais. Kaip ir kitos organizmo ląstelės neuronas turi branduolį ir apvaskalą. Tačiau skiriamasis bruožas yra tas, kad kiekvieną neuroną sudaro daugybė (iki tūkstančio ir net daugiau) skaidulų, kuriomis ateina elektriniais impulsais perduodama informacija iš kitų neuronų (žr. 1 pav.). Neuronas ateinančius signalus susumuoja, padaugindamas juos iš tam tikrų teigiamų arba neigiamų svarbumo koeficientų, t. y. atlieka svartinį sumavimą. Jei gauta suma viršija tam tikrą lygį, neuronas pasiunčia didesnę ar mažesnę savo sukurtą impulsą, kitomis skaidulomis perduodamą tolimesniems neuronams.

Bent kiek sudėtingesniuose gyvuose organizmuose tų neuronų labai daug (bitė turi apie 100 tūkst. neuronų, o žmogus — net 10^{12} — 10^{14}). Kadangi neuronų yra daug, jau minėtas skaidulų raizgynas yra panašus į tinklą. Neuronai tarpusavyje sujungiami sinapsiais (žr. 2 pav.). Per sinapsinius ryšius neuronai apsikeičia informacija.



1 pav. Nervų ląstelės struktūra su ląstelės branduoliu viduryje, nervas (aksonas) ir dendritai, kurie gauna informacija nuo kitų ląstelių per sinapsus [29]

- 1 pav.** Nervų ląstelės arba neuronai yra savo ruožtu pagrindiniai smegenų elementai.
- paaiškinimas:** Jie susideda iš 0,25 mm storio ląstelės kūno (somas). Priešingai negu kitos ląstelės, jos turi ataugas. Yra dvi ataugų rūšys:
- Dendritai. Jų paskirtis yra priimti ir perduoti įėjimo signalą ląstelės kūnui.
 - Aksonai. Jie atsakingi už signalų perdavimą nuo ląstelės kūno iki kitų ląstelių arba raumenų.
 - Ataugos skirtos komunikacijai tarp ląstelių ir tarp ląstelių, ir raumenų.



2 pav. Sinapso pjūvis [29]

2 pav. paaiškinimas: Ataugų galuose yra sustorėjimai, taip vadinamieji sinapsai. Jie organizuoja kontaktus tarp tam tikrų nervų arba raumenų ląstelių. Be to, sinapsai yra daugelio hormonų bei psichikos medžiagų sujungimo vieta. Žmogaus neuronai turi nuo 1000 iki 10.000 tokių sinapsų. Kai kurios ląstelės, kaip, pavyzdžiui, Purkinje-ląstelės, kurios yra smegenėlėse, turi apie 150.000 ląstelių.

2.2. Dirbtiniai neuroniniai tinklai


Vienas iš kelių pastarųjų dešimtmečių informatikos pasiekimų yra dirbtinių neuroninių tinklų teorinių pagrindų sukūrimas ir platus jų taikymas įvairiose gyvenimo srityse, visų pirma informacijos apdorojimo industrijoje, ekonomikoje, inžinerijoje, chemijoje, biomedicinoje ir t. t. Populiariai kalbant, dirbtiniai neuroniniai tinklai (sutrumpintai DNT) — tai skaičiavimo mašinos, sukurtos pagal analogiją su žmogaus ar kitų, nors kiek mažesnių gyvų organizmų smegenimis. Trumpai tariant, tai gyvų organizmų nervinių ląstelių

matematinio modeliu paremti informacijos apdorojimo algoritmai ir techninis jų realizavimas šiuolaikinės elektronikos dėka. Viena patrauklių DNT praktinio panaudojimo pusių — juose realizuota juodosios dėžės koncepcija, kur, sudarant informaciją apdorojantį algoritmą, svarbu žinoti tik įėjimus ir išėjimus, ir visai nebūtina žinoti, kas dedasi viduje. Mokslininkai, tiriantys ir tobulinantys „natūralų“ informacijos apdorojimą tiek dirbtiniuose neuroniniuose tinkluose, tiek gyvuose organizmuose, dirba dirbtinio intelekto, fizikos, neurofiziologijos, ekonomikos, lingvistikos, filosofijos ir kitose srityse.

2.2.1. Dirbtinis neuronas

Kaip ir natūralus biologinis neuronas, dirbtinis, dar 1943 m. JAV mokslininkų McCulloch ir Pits pasiūlytasis, irgi susideda iš daugelio įėjimų, kurie susumuojami, padauginus juos iš tam tikrų, svoriais vadinamų koeficientų — tai irgi svertinis sumavimas.

Gauta suma s perduodama į netiesinį, neurono išėjime esantį elementą, kurio išėjimo signalas yra lygus arba artimas nuliui, arba jei s yra neigiamas, ir artimas vienetui, arba jei signalas s yra teigiamas.



3 pav. Dirbtinis arba formalus neuronas

kur $x_1..x_n$ – reikšmės, kurios įeina į neurono įeigas (sinapsai), $w_1..w_n$ – sinapsų svoriai (gali būti kaip mažinantys, taip ir didinančiais), S – įeinančių signalų bendra suma:

$$S = \sum_{i=1}^n w_i x_i - T = (W, X) - T = |W| \cdot |X| \cdot \cos \alpha - T$$

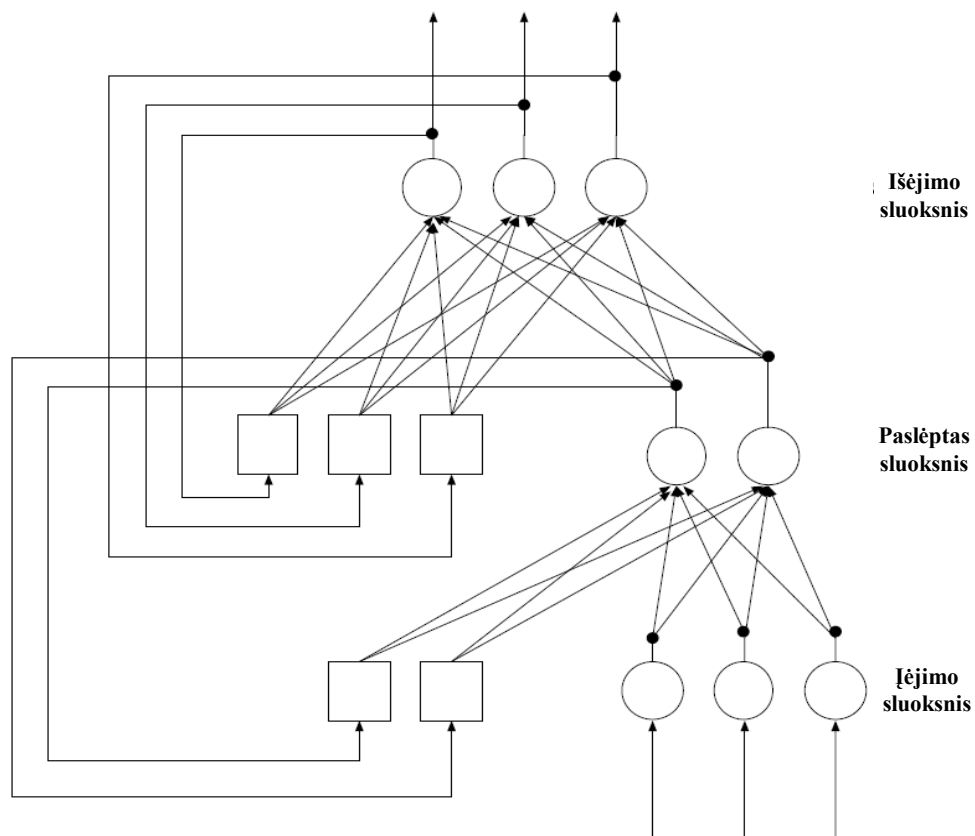
T – neurono slenkstis, daugeliuose modeliuose jo nėra, F – neurono aktyvavimo funkcija, transformuojanti bendrą sumą į išėjimo signalą $y = F(S)$, bendra suma gali būti interpretuojama kaip įeigos vektoriaus projekcija į svarstyklių vektorių, kur α - kampas tarp šių vektorių.

Formalus neuronas atrodo kaip jo biologinis prototipas. Dirbtiniai neuroniniai tinklai gali atlikti bet kurias logines operacijas ir apskritai bet kokius transformavimus, kurie realizuojami diskrečiais įrankiais su baigtine atmintimi (kitas aspektas, kaip suderinti tokio tinklo svorius). Neuronai natūraliuose neuroniniuose tinkluose daug sudėtingesni, jų funkcionavimas paremtas sudėtingesniais procesais, kurie dar priklauso nuo laiko. Be to, manoma, kad smegenys turi kvantinę struktūrą, o mąstymo proceso pagrindą sudaro kvantiniai efektai. Žmogaus smegenys sudaro 10 trilijonų (10^{11}) neuronų, surištų tarpusavyje 10^{14} sinapsiais. Tokios apskaičiavimo galios dabartinei apskaičiavimo technikai dar nepasiekiamos. Smegenų struktūra jau sudaryta genetiškai nuo pat gimimo, o ryšiai tarp neuronų vystosi ir modifikuojami per visą gyvenimą. Tai reiškia, kad savo intelektualią patirtį žmogus gauna per mokymo procesą. Tokiu būdu, tai sako apie dirbtinių neuroninių tinklų vystymosi perspektyvas.

2.3. Dirbtinių neuroninių tinklų modeliai

Kitas labai svarbus aspektas nagrinėjant dirbtinių neuroninių tinklų struktūrą yra sąryšių ir sluoksnių tvarka tarp pagrindinių DNT elementų - neuronų.


Daugelis modelių yra paremta tam tikra tinklo architektūra. Visų pirma ieškomi tokie tinklai, kurie turi paprastą neuronų struktūrą. Kaip taisyklė, dažniausiai neuronai grupuojami į sluoksnius. Šiuose sluoksniuose yra numatyti įėjimai, tarpiniai sluoksnai ir išėjimai. Kiekvienas iš sluoksnio turi savo numerį. Galimas DNT variantas yra pateiktas 5 pav. Paveikslėlyje pateiktas tiesioginio ryšio (angl. *feedforward*) DNT, kuriame visi ryšiai nukreipti viena kryptimi, šį ryšio santykį mes aptarsime plačiau. Egzistuoja dar kitas sąryšių variantas, kur ryšiai turi grįžtamąjį santykį (angl. *feedback*) [žr. 4 pav.]. Tokio santykio tinkluose mokymo imtis pereina per visą DNT. Išėjimo rezultatai nukreipiami vėl į DNT įėjimus. Ta procedūra tęsiasi iki tol, kol DNT rezultatai bus stabilūs. Žemiau pateiktas grįžtamojo ryšio DNT.



4 pav. Grįžtamojo ryšio DNT

Modelyje, pavaizduotame 5 pav. nėra grįžtamojo ryšio santykių. Apskritimai yra neuronai, kiekvienas iš neuronų gauna iš priešankstinio sluoksnio informaciją. Neuronai priima signalus tik iš vienos pusės. Išėjimo sluoksnis negali tiesiogiai gauti signalo iš įėjimo sluoksnio, taip bus pažeistas DNT funkcionavimo principas. Signalas, perduotas per įėjimo sluoksnį būtinai turi būti perduotas per visus DNT sluoksnius. Šiuo metu yra išskiriamos du DNT modelių tipai:

- **vienasluoksnis** DNT modelis;
- **daugiasluoksnis** DNT modelis.




5 pav. Neuronų išsidėstymas DNT

2.3.1. Vienasluoksnis modelis

Paprasčiausia DNT struktūra sudaryta iš vieno įėjimo ir vieno išėjimo sluoksnio. Tokio vienasluoksnio modelio DNT pavyzdys yra perceptronas. Šio neurono tipą sukūrė Rosenblatt [22]. Perceptronų teorija sudarė pagrindą daugeliui DNT formuotis. Vienasluoksnis perceptronas sugeba atpažinti paprasčiausius vaizdus. Atskiras neuronas apskaičiuoja įėjimo signalo elementų sumą ir perteikia rezultatą per slenkstinę funkciją, kurios išėjimas yra lygus +1 arba -1:

- +1 – įėjimo signalas priklauso A klasei;
- -1 – įėjimo signalas priklauso B klasei.

Paprastasis perceptronas susideda iš trijų dalių: paviršiaus su davikliais, iš tam tikro asociacijos vienetų (AS-vienetai) kiekio ir iš tam tikro atsakymų vienetų (AT-vienetai) kiekio. Kaip taisyklė, AS-vienetai parodo AT-vienetų kryptį (žr 6 pav.).



6 pav. Paprastasis perceptronas

Perceptrono funkcionavimo būdas atrodo tokiu būdu:

- 1 žingsnis** Apskaičiuojamos visos φ_a savybės arba požymiai. Juos galima lengva apskaičiuoti, nes kiekvienas iš požymių priklauso nuo labai mažos apibrėžimų srities AT dalies.
- 2 žingsnis** Sprendimo algoritmas Ω transformuoja 1 žingsnio rezultatus į predikatą Ψ . Ši sprendimo funkcija yra vienerūšė ir yra lengvai realizuojama praktiškai. Kintamųjų $\alpha_1, \alpha_2, \dots, \alpha_n$ reikšmės nustatomos taip, kad $\Psi(X) = 1$ tada ir tik tada, kai $\sum_{\varphi \in \Phi} \alpha_{\varphi} \varphi(X) > \Theta$.

Paprastojo perceptrono savybės:

Iėjimo signalų tipai: binariniai arba analoginiai.

Taikymo sritys: vaizdų atpažinimas, klasifikavimas.

Trūkumai: Primityvūs skirstymo paviršiai leidžia spręsti tik paprastus atpažinimo uždavinius.

Privalumai: Programinės bei techninės realizacijos yra labai paprastos. Paprastas ir greitas mokymo algoritmas.

Sprendimo modifikacijos: Daugiasluksniai perceptronai leidžia sudaryti labiau sudėtingesnius skirstymo paviršius.


2.3.2. Daugiasluksnis modelis

Pats populiariausias gyvųjų organizmų smegenų struktūra paremtas dirbtinis neuroninis tinklas yra daugiasluksnis perceptronas (žr. 7 pav.). Daugiasluksnio dirbtinio neuroninio tinklo (kitas pavadinimas — daugiasluksnis perceptronas, angliškai - *Multilayer Perceptron*, *MLP*) architektūra susideda iš nuosekliai sudarytų sluoksnių, kur kiekvieno

sluoksnio neuronas savo įėjimais surištas su priešankstinio sluoksnio neuronais, o išėjimais — su kito sluoksnio neuronais. Jame atskiri neuronai surikiuoti į sluoksnius, (įėjimo signalai X_1, X_2, \dots, X_p patenka į paslėptojo sluoksnio neuronus. Šių sluoksnių gali būti keli. Iš čia žemesnio sluoksnio signalai keliauja į aukštesnį sluoksnį), kol galiausiai pasiekia išėjimo sluoksnį. Atsižvelgiant į tinklo sudėtingumą daugelį kartų sumuojami bei netiesiškai transformuojami signalai gali suformuluoti paprastas ir sudėtingas sąvokas, pagal DNT įėjimuose esančią informaciją priimti sprendimus, reikalingus tolimesniam dirbtinio neuroninio tinklo darbui. Įprastai daugiasluoksnis DNT sudaromas su vienu paslėptu arba keliais paslėptais sluoksniais bei parenkta slenkstine funkcija. Šios savybės leidžia daugiasluoksniams DNT spręsti labai platų užduočių spektrą. Šis požymis turi labai didelę reikšmę teoriškai ir praktiškai vystant daugiasluoksnius DNT. Tai patvirtina taip pat Minsky ir Papert mokslininkų požiūris [18]. Literatūroje taip pat galima pastebėti aprašomą santykį tarp neuronų skaičiaus paslėptame sluoksnyje ir užduoties atlikimo tikslumo. Šiuo klausimu užsiminėja mokslininkas Baum [3]. Reikėtų nustatyti mažiausią daugiasluoksnį DNT, kuris gali apskaičiuoti tam tikrą funkciją. Anksčiau buvo manyta, kad tai DNT su vienu paslėptu sluoksniu, o būtent su $N-1$ neuronų slenkstine reikšme. Šis DNT gali realizuoti funkciją per DNT su vienu paslėptu sluoksniu, turinčiu $\frac{N}{d}$ neuronų, kur N - neuronų sluoksnių kiekis ir d — jų dydis.

Kitų mokslininkų [12] rezultatai parodo, kad DNT funkcijos realizacijai, turi užtekti mažiausiai $\frac{N_e}{\log_2(N)}$ svorių. Tam DNT reikia mažiausiai $\frac{N_e}{d \log_2(N)}$ svorių paslėptame sluoksnyje.

Aktyvuojančiomis funkcijomis tokiems neuronams laikomi tiesinių, slenkstinių ir sigmoidinių funkcijų variantai. Daugiasluoksnis DNT modelis su vienu sprendžiamu sluoksniu gali formuoti tiesinius atskiriančius paviršius, kas labai susiaurina jais sprendžiamų uždavinių sritį, būtent toks tinklas negalės išspręsti užduoties „išimtis arba“. DNT su tiesine aktyvavimo funkcija ir dviem sprendžiančiais sluoksniais leidžia formuoti bet kokias iškilas sritis sprendimų terpėje, su 3 sprendžiančiais sluoksniais — galima spręsti bet kokio sudėtingumo sritis, tame tarpe ir neaiškias. Be to, DNT nepraranda savo apibendrinimo sugebėjimo. Taip pat naudojant dviejų sluoksnių DNT galima su bent koku tikslumu aproksimuoti bent kokią daugiamačią funkcija atkarpoje $[0;1]$.



7 pav. Daugiasluoksniu perceptrono DNT su 3 paslėptais sluoksniais

Daugiasluoksniu perceptrono savybės:

Įėjimo signalų tipai: tiksliniai arba realūs.

Išėjimo signalų tipai: realūs, pasirenkami iš intervalo, kuris priklauso nuo perduodamos neuronų funkcijos.

Perduodamos funkcijos tipas: sigmoidinė. DNT taikoma per keletą sigmoidinių perduodamų funkcijų variantų: Fermi funkcija (eksponentinė sigmoidė), racionalinė sigmoidė, hiperbolinis tangentas. Šios funkcijos yra vienaparametrinės. Funkcijos reikšmė priklauso nuo argumento ir vieno parametro. Sigmoidinės funkcijos nuolat auga, tuo pačiu užtikrina teisingą DNT funkcionavimą ir mokymą.

Taikymo sritys: vaizdų atpažinimas, klasifikavimas, prognozavimas.

Trūkumai: Kiekvienos iteracijos metu vyksta tinklo parametrų pokyčiai. Toks funkcionavimas padidina mokymo laiką.

Privalumai: Daugiasluoksnis perceptronas yra vienas iš populiariausių ir efektyviausių DNT tipų. Jis leidžia išspręsti daugelį užduočių.

Sprendimo modifikacijos: Daugiasluoksnio perceptrono modifikacijos susietos su skirtingomis paklaidos funkcijomis, skirtingomis krypties nustatymo procedūromis ir žingsnio dydžiu.

2.4. Dirbtinių neuroninių tinklų mokymas

Yra sukurta įvairių DNT mokymo algoritmų. Vieniems būtina žinoti, kokius duomenis atitinka koks rezultatas, kitiems - ne. Vienas iš paprasčiausių algoritmų — yra algoritmas su stvirkštiniu skleidimu (*back-propagation*). Šiam algoritmui būtina žinoti teisingą rezultatą. DNT skiriama užduotis, toliau skaičiuojama paklaida, palyginus tinklo rezultatą su iš anksto žinomu rezultatu. Paklaida verčiama „baudos“ signalais, kurie siunčiami atgal į tinklą. Atsižvelgdami į kanalų pralaidumą, jie išsiskaido. Tuomet kanalai „baudžiami“ — svoris mažinamas tiek, kiek „baudos“ taškų juose susikaupę. Kanalai, prisidėję prie teisingo rezultato, „giriami“ - jų svoriai didinami. Taip kartojama su įvairiais pavyzdžiais iki tol, kol mokytojas nusprendžia, kad tinklas pasiruošęs darbui.

Įrodyta, kad paprasčiausi neurono svorių atsiradimo matematiniai modeliai, naudojami klasifikavimui ir prognozavimui, mokant juos pasitelkus jau minėta iteracinį algoritma, pereidami nuo pačių primityviausių matematine prasme svorių įvertinimo metodų prie vis sudėtingesnių. Teoriškai ištirta įvairių svorių įvertinimo metodų tikslumo priklausomybė nuo panaudoto mokymui duomenų kiekio. Iš to seka, kad, pavyzdžiui, esant mažam duomenų kiekiui, neuroną reikia mokyti trumpai, o turint daug duomenų — ilgai. Šis teorinis rezultatas sudarė prielaidą efektyvesniems DNT mokymo ir panaudojimo metodams pasiūlyti. Kita vertus, darant prielaidą, kad jau minėtas matematinis neurono modelis tikrai egzistuoja gamtoje, seka, jog per pastarąjį šimtmetį dauguma sukurtų įvertinimo ir sprendimų priėmimo metodų, paremtų tikimybių teorija ir matematine statistika parametrų, jau daugelį milijonų metų veikia gamtoje.

Matematiniai modeliai, naudojami neurono mokymo bei jo metu apdorojamam informacijos procesui aprašyti, turi universalumo savybių ir tinka įvairiems reiškiniams, tiriamiems kitose mokslo šakose, aprašyti. Pavyzdžiui, žaliavų, paslaugų, gaminių kainų visuma sudaro daugiamatį vektorių, kuris laikui bėgant kinta. Šį kainų vektoriaus kitimą

galima aprašyti pasitelkus iteracinį mokymo algoritmą, o kainų adaptavimuisi prie besikeičiančios rinkos nagrinėti galima panaudoti jau žinomus matematinius rezultatus. Analogiška situacija ir su gamybinėmis mokymosi kreivėmis. Žinoma, kad gamybai vystantis kiekvieno naujo gaminio (nesvarbu, kas tai bebūtų — televizorius ar atliktas vertimas) savikaina mažėja. Kainos kitimo priklausomybė nuo pagamintų gaminių kiekio vadinama gamybine mokymosi kreive. Aprašius gamybos parametrus daugiamačiu vektoriumi, gamybos tobulėjimą galima analizuoti kaip iteracinį mokymąsi, analogiška tam, kuris naudojamas neurono mokymuisi nagrinėti.

Matome, kad dirbtiniai neuroniniai tinklai gali būti naudingi tiek sprendžiant svarbius praktikos keliamus uždavinius, tiek aiškinant sudėtingas mokslines problemas.

Štai kelios sritys, kuriose neuroninių tinklų mokymas yra taikomas:

- investavimo analizė: pagal ankstesnius duomenis nustatoma prekių apyvarta;
- parašų analizė: vienas pirmųjų neuroninių tinklų pritaikymų;
- -pramoninių procesų valdymas;
- stebėjimas: aviacijoje stebimas variklių vibracijos bei triukšmo lygis ir iš anksto perspėjama apie galimas problemas, Anglijoje panašias sistemas bandoma pritaikyti geležinkeliuose dyzeliniams varikliams stebėti;
- prekyboje.
- Dirbtinių neuroninių tinklų mokymas gali būti pritaikytas:
- kalbos atpažinimo sistemoms;
- vaizdų atpažinimo sistemoms;
- prognozavimo sistemoms;
- klasifikavimo sistemoms.

Pagal ryšių mokymo charakterį DNT gali būti mokami tokiais būdais:

- Mokymas su mokytojo pagalba: ryšiai reguliuojami per mokymo procesą, be to, darbo rezultatų etaloninės reikšmės jau žinomos.
- Savimoka (mokymas be mokytojo) etaloniniai rezultatai nežinomi (nereikalingi), DNT per mokymo procesą turi organizuoti įeigos vaizdus pagal jų panašumą.
- Fiksuoti ryšiai, nulemti sprendžiamo uždavinio charakteriu (pavyzdžiui optimizavimo uždaviniuose).

Taip pat dirbtiniai neuroniniai tinklai gali skirtis įėjimo informacijos tipu (dvejetainė, analoginė ir t. t.) ir jos mokymo metodu.

DNT mokymas skirstomas pagal DNT mokymo būdą bei DNT mokymo tipą. 1 lentelėje pateikti šiuo metu egzistuojantys mokymo būdai, įvertinant DNT sąryšio tipą bei DNT tipą, iš tos lentelės seka, kad DNT mokymo tipų yra žinoma nemažai pagal DNT topologiją ir

mokymo rūšį. Ypatingas dėmesys išskiriamas atvirkštinio skleidimo mokymui [23], nes šis mokymo būdas lengviausiai realizuojamas praktiškai ir turi tvirtus teoretinius pagrindus, kadangi DNT su tiesioginiu ryšiu (angl. *feedforward*) kiekviena iš funkcijų gali būti apmokyta pagal norimą tikslumą, tada ir tik tada, kai DNT yra pakankamai neuronų. [12].

Mokant DNT egzistuoja daug taisyklių, bet daugelis iš jų yra senos Hebbo taisyklės modifikacijos. Skirtingų mokymo taisyklių tyrimai tęsiasi ir šiandien, naujausios idėjos publikuojamos mokslinėse bei komerciniuose publikacijose. Mes pateiksime keletą iš pagrindinių mokymo taisyklių.

2.4.1. Hebbo taisyklė

Hebbo taisyklė [11] buvo viena iš pirmų mokymo taisyklių pagal kurią DNT gali pakeisti savo svorinius koeficientus taip, kad būtų pasiektas norimas rezultatas. Ši taisyklė (žr. 8 pav.) skamba taip: Jeigu neuronas priima įėjimo signalą nuo kito neurono ir abu neuronai yra aktyvūs (matematiškai turi tą patį ženklą), tai svoris tarp neuronų turi būti sustiprintas. Sužadinus vienu metu du neuronus su išėjimais (x , y) tame mokymo žingsnyje, sinapsinio sąryšio svoris tarp jų didėja, priešingu atveju – mažėja, t. y.:

$$\Delta W_{ij}(k) = r \cdot x_j(k) \cdot y_j(k),$$

kur r – mokymo greičio koeficientas.

Hebbo taisyklė gali būti taikoma atliekant mokymą „su mokytoju“ ir „be mokytojo“.

2.4.2. Delta taisyklė


Ši taisyklė yra modifikuota Hebbo taisyklė. Ji grindžiama paprasta idėja, kurios esmė yra nepertraukiamo sinaptinių svorių pokytis skirtumui („delta“) mažinti. Šis skirtumas atsiranda tarp norimo ir esančio neurono išėjimo signalo.

$$\Delta W_{ij} = x_j(d_i - y_i)$$

Remiantis šia taisykle yra minimizuojama vidutinė kvadratinė tinklo paklaida. Kai kur literatūroje ši taisyklė aprašoma kaip Widrowo – Hoffo [28] mokymo taisyklė arba mažiausių vidutinių kvadratų mokymo taisyklė.

1 lentelė. Žinomų mokymo būdų grupavimas pagal DNT sąryšių tipą ir pagal mokymo tipus

Mokymo tipai	DNT sąryšio tipai	Dirbtiniai neuroniniai tinklai	
Mokymas be mokytojo <i>(unsupervised learning)</i>	DNT su grįžtamais ryšiais (feedback)	Grosbergo funkcija	<i>Additive Grossberg (AG)</i>
		Grosbergo lygiagrečioji funkcija	<i>Shunting Grossberg (SG)</i>
		Binarinė adaptyvioji rezonanso teorija	<i>Binary Adaptive Resonance Theory (ART1)</i>
		Analoginė adaptyvioji rezonanso teorija	<i>Analog Adaptive Resonance Theory (ART2)</i>
		Diskretus Hopfieldo tinklas	<i>Discrete Hopfield (DH)</i>
		Pasikartojantis Hopfieldo tinklas	<i>Continuous Hopfield (CH)</i>
		Diskrečioji dupleksinė asociatyvioji atmintis	<i>Discrete Bidirectional Associative Memory (BAM)</i>
		Laikinoji asociatyvioji atmintis	<i>Temporal Associative Memory (TAM)</i>
		Adaptivi dupleksinė asociatyvioji atmintis	<i>Adaptive Bidirectional Associative Memory</i>
		Koheno saviorganizuojantis žemėlapis	<i>Kohonen Self-organizing Map (SOM)</i>
		Koheno topologija – išlaikytas žemėlapis	<i>Kohonen Topology-preserving Map (TPM)</i>
		DNT su tiesioginiais ryšiais (feedforward)	Mokymo matrica
	Sustiprintas mokymas		<i>Driver-Reinforcement Learning (DR)</i>
	Linejinė asociatyvioji atmintis		<i>Linear Associative Memory (LAM)</i>
Optimali linejinė asociatyvioji atmintis	<i>Optimal Linear Associative Memory (OLAM)</i>		
Paskirstyta asociatyvioji atmintis	<i>Sparse Distributed Associative Memory (SDM)</i>		
Neryški asociatyvioji atmintis	<i>Fuzzy Associative Memory (FAM)</i>		
Mokymas su mokytoju <i>(supervised learning)</i>	DNT su grįžtamais ryšiais (feedback)	„Smegenu dėžė“	<i>Brain-State-in-a-Box (BSB)</i>
		Neraiškus kognityvus žemėlapis	<i>Fuzzy Cognitive Map (FCM)</i>
		Boltzmano mašina	<i>Boltzmann Machine (BM)</i>
		Pagrindinio lauko funkcija	<i>Mean Field Annealing (MFA)</i>
		Rekurentinė kaskadinė koreliacija	<i>Recurrent Cascade Correlation (RCC)</i>
		Mokymo vektoriaus kvantavimas	<i>Learning Vector Quantification (LVQ)</i>
	DNT su tiesioginiais ryšiais (feedforward)	Perceptronas	<i>Perceptron</i>
		Ada ir mada linijos	<i>Adaline, Madaline</i>
		Atvirkštinis sklaidymas	<i>Backpropagation (BP)</i>
		Cauchy mašina	<i>Cauchy Machine (CM)</i>
		Adaptyvioji euristika	<i>Adaptive Heuristic Critic (AHC)</i>
		Laiko uždelimo NT	<i>Time Delay Neural Network (TDNN)</i>
		Asociatyviosios sankcijos NT	<i>Associative Reward Penalty (ARP)</i>
		Srautinis filtras	<i>Avalanche Matched Filter (AMF)</i>
Atvirkštinis prasisukimas	<i>Backpercolation (Perc)</i>		
Ornamento žemėlapis	<i>Artmap</i>		
Adaptivus loginis žemėlapis	<i>Adaptive Logic Network (ALN)</i>		
Kaskadinė koreliacija	<i>Cascade Correlation (CasCor)</i>		



8 pav. Mokymo modelis pagal Hebbio taisyklę

Delta taisyklėje paklaida, gauta išėjimo sluoksnyje yra transformuojama per išvestinę funkciją ir sklinda atgal į priešankstinius sluoksnius sinaptiniams svoriams koreguoti. Paklaidų atvirkštinio sklaidimo procesas vyksta iki pirmojo sluoksnio. Šis apskaičiavimo metodas sukūrė labai žinomą paklaidos sklaidimo paradigmą (*Feed Forwarded Back Propagation*).

Naudojant delta taisyklę labai svarbu yra nekeisti įėjimo duomenų aibės tvarkos. Pakeitus mokamos aibės struktūrą, rezultatas gali būti nelabai tikslus ir DNT bus neįmanoma mokyti.

2.4.3. Atvirkštinė sklaidimo taisyklė

Atsiradus šiam metodui buvo vėl sužadintas interesas dirbtiniams neuroniniams tinklams tirti. Rumelhart, Hinten ir Williams [23] sukūrė tokį mokymo būdą, pagal kurį DNT per mokymo procesą gali pakeisti savo svorius paslėptuose sluoksniuose. Norint mokyti DNT pagal atvirkštinio sklaidimo taisyklę, DNT privalo turėti nors vieną paslėptą sluoksnį. Atvirkštinio sklaidimo DNT pripažintas standartine DNT architektūra ir yra naudojamas 80% visų projektų, kuriuose naudojami DNT [7]. Atvirkštinio sklaidimo DNT yra lengvai realizuojami, teisingai išsprendžia problemas ir jų taikymas praktiškai nesusiduria su problemomis.

Panaudojus atvirkštinio sklaidimo taisyklę, mokymo proceso metu apskaičiuojamas kiekvieno svorio lokalinis gradientas kiekvienam stebėjimo kartui. Visi svoriai koreguojami po kiekvieno stebėjimo. Atvirkštinės sklaidimo taisyklė atrodo taip:

$$\Delta W_{ij}(t) = \eta \delta_j o_i + \alpha \Delta \omega_{ij}(t-1) \quad ,$$

Kur η - mokymo greitis;

δ - lokalus klaidos gradientas;

α - inercijos koeficientas;

o_i - i-ojo elemento išėjimo reikšmė.


Slenksčiai formulėje nustatomi svoriais nuo $o_i = -1$.

Atvirkštinio skleidimo DNT keičia savo svorius sąryšiuose, tuo pačiu sumažinadami skirtumą tarp norimos ir laukiamos vektoriaus išeities. Apmokytame DNT paslėptuose sluoksniuose kaupiamos labai svarbios duomenų savybės.

Kalbant apie atvirkštinį skleidimą, turima omenyje, sinaptinę mokymo taisyklę, kuri leidžia sukurti tinkančią vidinę DNT struktūrą skirtingiems uždaviniams spręsti. Ši taisyklė naudojama tik DNT su tiesioginiais ryšiais ir priskiriama prie mokymo su mokytoju (žr. 1 lentelę). Atvirkštinio skleidimo mokymo taisyklė tinka tik tam tikroms DNT struktūroms. Ši taisyklė dažniausiai tinka tokiems DNT, kurių sluoksniai yra griežtai sutvarkyti, t. y. vienas įėjimo sluoksnis, turi tam tikrą paslėptų sluoksnių skaičių ir vieną išėjimo sluoksnį.

Įėjimo sluoksnis priima įėjimo vektorių iš terpės ir perduoda jį tarpiniam sluoksniui. Išėjimo sluoksnis priima signalą iš tarpinio sluoksnio ir išsiunčia atsakymo signalą įėjimo vektoriui. Neuronai tarpiniuose sluoksniuose atlieka reguliavimo funkciją duomenyse. Neuronų svorinės vertės tarpiniuose sluoksniuose perduoda duomenų informacijos turinį.

Atvirkštinio skleidimo DNT mokymas vyksta per du žingsnius. Iš pradžių pasirenkamas duomenų imties įėjimo vektorius, kuris perduodamas įėjimo sluoksniui. Aktyvavimo reikšmės skaičiuojamos tol, kol išėjimo sluoksnio neuronai nesukurs atsakymo. Antrame žingsnyje DNT išėjimo vektorius lyginamas su norimu išėjimo vektoriumi. Jeigu tarp šių reikšmių yra pastebiami skirtumai, tai kiekvienam iš neuronų įėjimo sluoksnis nusiųs klaidos taisymo nurodymus. Taip svoriai pakeičiami iki tol, kol siunčiamas signalas turės mažiausią klaidos dydį (žr. 9 pav.)



9 pav. Aktyvavimo ir klaidos paskirstymas atvirkštinio sklaidimo DNT

3. ATVIRKŠTINIO SKLEIDIMO DIRBTINIŲ NEURONINIŲ TINKLŲ MOKYMAS

Trečiame skyriuje atvirkštinio skleidimo DNT modelis buvo pateiktas jo problematikai tirti. Šioje dalyje mes plačiau apžvelgsime atvirkštinio skleidimo mokymo būdus. Šiuo metu išskiriami 5 būdai atvirkštinio skleidimo mokyme:

- Momentum-Term taisyklė
- Svorio redukcija
- Aktyvavimo funkcija
- Slenkstinės vertės transformacija į rezultatų mazgą
- Rekurentinis atvirkštinis skleidimas

3.1. Momentum-Term taisyklė

Remiantis šia taisykle reikėtų atsižvelgti į paskutinį svorių pokytį. Taip mes galėsime pasiekti greičiausios DNT konvergencijos per mokymo procesą.

Svorio pokytis sluoksnyje l apskaičiuojamas pagal šią formulę:

$$\Delta\omega_{ij}^{(l)}(t) = \eta\delta_i^{(l)}\chi_j^{(l-1)} + \mu\omega_{ij}^{(l)}(t-1),$$

Idėjos esmė yra jungtinis gradientinis metodas, kurio metu atkreipiame dėmesį į paskutinius pastebėjimus norėdami suprasti visą sprendimo sritį.

3.2. Svorio redukcija

DNT, kuris panaudoja atvirkštinio skleidimo mokymo taisyklę, minimizuoja klaidas tarp esamo ir norimo DNT elgesio. Kadangi įvedus aktyvavimo funkciją pasikeičia DNT svoriai, DNT mokymo metu gali suklaidinti vartotoją. Kad to neįvyktų, reikėtų koreguoti svorinius koeficientus pagal formulę:

$$\omega_{ij}^{naujas} = 0.999\omega_{ij}$$

Šios formulės esmė yra konstantos sandauga su skaičiumi mažesniu negu 1.

3.3. Aktyvavimo funkcija

Aktyvavimo funkcija įvertina gautąjį iš neurono signalą. To negali išspręsti kiekviena funkcija. Atliekant linijines aktyvavimo funkcijas DNT su paslėptais sluoksniais galima pakeisti į ekvivalentiškus DNT be tarpinių sluoksnių.

Šiuo atveju panaudojama sigmoidinių funkcijų grupė. Tam tikros sigmoidinės aktyvavimo funkcijos pasirinkimas daro įtaką DNT savybėms. Išskiriamos dvi sigmoidinės funkcijos: logistinė funkcija ir tangento - hiperbolinė funkcija.

Dažniausiai naudojama logistinė funkcija. Jos reikšmių diapazonas yra [0;1]. Ši funkcija apibrėžiama sekančiai:

$$\exp \text{sigm}(x, \text{reikšmė}) = \frac{1}{1 + e^{-\frac{2x}{T}}},$$

kur *reikšmė* yra apskaičiuojamas kintamasis. Tangento - hiperbolinė funkcija naudoja panašią funkciją kaip ir logistinė funkcija, skiriasi tik sprendžiamų reikšmių diapazonas, kuris yra intervale [-1;1]:

$$\tanh(x, \text{reikšmė}) = \frac{1 - e^{-\frac{2x}{T}}}{1 + e^{-\frac{2x}{T}}}$$


3.4. Slenkstinės vertės transformacija

Realizuojant DNT svarbu atkreipti dėmesį į funkcijos sumą, kurią apibrėžiame sekančia formule:

$$v_i^{(l)} = \sum_{j=0}^{n^{(l)}} \omega_{ij}^{(l)} x_j^{(l-1)},$$

kur $\omega_{i,0} = -\Theta_i$ ir $\chi_0 = 1$.

Slenkstinės vertės transformacija pateikta 10 pav.



10 pav. Slenkstinės vertės transformacija į rezultatų mazgą

3.5. Atvirkštinio skleidimo DNT privalumai ir trūkumai

Privalumai: Panaudojus daugiasluoksnį dirbtinį neuroninį tinklą ir atvirkštinio skleidimo mokymą galima apskaičiuoti bet kurią funkciją. Nurodant įėjimo ir išėjimo parametrus galima atlikti sumavimo skaičiavimus bei slenkstines transformacijas, panaudojus tik IR, ARBA, NE logines funkcijas. Tai pat galima ir šių loginių elementų kombinacija. Tuo pačiu DNT nėra apribotas vien tik dvejetainiais parametrais. Kiekvienos funkcijos realizacija galima laikyti didžiausiu atvirkštinio skleidimo DNT privalumu.

Trūkumai: Visi atvirkštinio skleidimo DNT trūkumai atsiranda atliekant jo mokymą. Visų pirma atvirkštinis skleidimas yra gradientinis mokymo tipas, kuris priskiriamas prie lėčiausiųjų problemos optimizavimo metodų. Todėl iškyla pavojus, kad DNT gali užstrigti atliekant per mokymo procesą. Kad to neatsitiktų, reikėtų nuolat koreguoti mokymo taktus (žingsnius), kurie yra visada pastovūs.

Išvados: Kadangi koreguojant mokymo taktus, klaidos paviršiaus skleidimo kryptis neatitinka gradientinio mokymo krypties, išlieka galimybė gauti optimalius sprendimus. Siekiant užtikrinti optimalaus sprendimo gavimą atvirkštinio skleidimo algoritmas turi būti naudojamas kartu su mažu duomenų kiekiu. Tik tuo atveju mes galėsime pasiekti spartų atvirkštinio skleidimo algoritmo mokymo būdą.

4. DNT BEI POŽYMIŲ IŠSKYRIMO METODŲ TAIKYMAS SPRENDŽIANT VAIZDŲ ATPAŽINIMO UŽDAVINIUS

Dirbtinių neuroninių tinklų metodai, kurių pagrindą sudaro skirtingų tipų mokymo algoritmai, paskutiniu metu labai paplito sprendžiant vaizdų atpažinimo uždavimus. Pagrindiniai uždaviniai, kuriuos padėta išspręsti DNT algoritmai yra tokie:

- Terpės požymių išskyrimas į sritis, kurios atitinka klases (klasifikavimas, klasterizavimas, atpažinimas).
- Pagrindinių charakteristikų išskyrimas, vaizdų suspaudimas ir rekonstrukcija.
- Daug kintamųjų turinčios funkcijos aproksimavimas su bet koku paskirtu tikslumu.
- Laikinių eilių prognozavimas.
- Asociatyvioji atmintis.
- Optizavimo bei kombinavimo uždavinių sprendimas.
- Terpės topologinis sutvarkymo pertvarkymas.
- Atpažinimas atsižvelgiant į terpės topologiją.

Dirbtinio neuroninio tinklo suderinimas tam tikram uždaviniui spręsti atliekamas per apmokymo procesą, naudojant pavyzdžių imties rinkinį. Tokiu būdu nereikia rankiniu būdu nustatyti modelio parametrus (išrinkti pagrindinius požymius, atkreipti dėmesį į jų sąryšį ir t.t.) – DNT priima modelio parametrus automatiškai, geriausiu būdu, kuris buvo pastebėtas apmokymo procese. Toliau lieka tik sudaryti mokymo rinkinį. Klasifikavimo uždaviniuose tuo atveju vyksta pagrindinių požymių išrinkimas tinklo viduje, jų reikšmės ir požymių sąveikos sistemos nustatymas. Šiuo metu sukurti galingi, lankstūs ir universalūs skirtingų DNT tipų apmokymo mechanizmai. Be to, DNT architektūra ir apmokymo procedūros leidžia lanksčiai suderinti konkretų sprendžiamą uždavinį. Daugeliui DNT apmokymo procedūra laikoma euristiniu algoritmu, kas iš vienos pusės suteikiamas gaunamų sprendimų priimtinumas, o iš kitos pusės nereikalaujama didžiulių apskaičiavimo resursų.

Dirbtiniai neuroniniai tinklai turi gerą apibendrinimo sugebėjimą (vieną iš geriausių tarp turimų metodų, pavyzdžiui, daug geresnį negu pas sprendimo medžius). Tai reiškia, kad patirtį, gautą per apmokymą procesą paskutiniame vaizdų rinkinyje galima sėkmingai taikyti visai vaizdų aibei. Išskyrus interpoliacinių apibendrinimo savybių, DNT (pavyzdžiui, daugiasluoksnis perceptronas), gali gerai ekstrapoliuoti, t. y. pritaiko savo patirtį į visiškai kitus vaizdus, negu kurie dalyvavo per bendrąjį išrinkimą.

Dirbtiniai neuroniniai tinklai nereikalauja nei jokio apribojimo taikymo mokymo išrinkimui, nei nesiremia jokiomis apriorinėmis savybėmis, kaip, pavyzdžiui, statistiniai metodai. Nebūtinai joks išankstinis duomenų charakterio nagrinėjimas. DNT priima mokymo rinkinį „kaip yra“ ir mokosi duoti optimaliausią sprendimą, nepretenduojuojant į absoliučią

teisybę. Trumpai tariant, sudaromas geriausias nefizinis modelis, kuris nėra maksimaliausiai tikslus realaus proceso atitikimas, bet duodas jo optimaliausias aproksimavimas. Kai kuriuose atvejuose DNT metodai yra geresni, negu statistiniai metodai. Statistikoje nėra kai kurių neuroninių tinklų metodų, tokių kaip Koheneno žemėlapiai, Bolcmano mašina bei kognitronų.

Natūraliausiu būdu DNT architektūra realizuojama naudojant lygiagrečius skaičiavimo metodus, specializuotos mikroschemos, optiniai ir kvantiniai kompiuteriai. Tai suteikia prielaidą didelioms DNT perspektyvoms ateityje formuotis. DNT charakterizuojami neryškiu ir paskirstytu informacijos saugojimu. Tai reiškia, kad nėra atskiro neurono, kuris būtų atsakingas už kažkokį tai požymį. Be to, šio neurono pašalinimas arba jo darbo pokytis nesukels ryškių pasėkmių.

Bet nepaisant visų privalumų, DNT taikymas, atpažinant vaizdus reikalauja pastangų. Tai priklauso visų pirma nuo sudėtingų vaizdų atributų, o ypač nuo trimačių realaus pasaulio vaizdų, kokiais ir yra žmonių veidai. Vaizdas turi būti prieš tai apdorotas – turi atitikti standartines sąlygas. Bet to, pradinio vaizdo atvaizdavimo išrinkimas (dažnio koeficientai, pagrindiniai komponentai, veivletai, momentai ir t. t.) sudaro atskirą didžiulę temą. Dvimatis vaizdo charakteris, apšvietimo sąlygų pakeitimas, rakurso keitimas ir nuo kitų poveikių topologiniai vaizdo iškrypimai leidžia apsiriboti paprastomis DNT architektūromis, kurios leidžia pasiekti optimalų rezultatą.

Nepaisant visų dirbtinių neuroninių tinklų taikymo būdų žmogui pagal jo veidą atpažinti, yra labai daug darbų [30], kurių tematika susieta su dirbtinių neuroninių tinklų taikymu atpažinant ir apdorojant kitas objektų rūšis.


4.1. Požymių nustatymas ir iškyrimas

Norint gauti duomenys vaizdo atpažinimui, reikia paskirstyti vaizdo atpažinimo procesą į požymių išskyrimą ir į jų klasifikavimą.

Pirmame žingsnyje iš vaizdo bus išskirti tam tikri požymiai. Jeigu tai atliekama su veidu, tai galima jau kalbėti apie biometrinius požymius. Dažniausiai požymiai iškyriami per tokius metodus:

- Šablonų palyginimas
- RGB filtras
- Geometriniai požymiai
- Furje-transformacijos
- Gabor-bangelės
- Elastiniai grafai (elastic bunch graph)

Visų šių metodų, išskyrus RGB metodo, praktinė realizacija gali ilgai užtrukti praktiškai. Ir, kadangi, mūsų darbe pagrindinis dėmesys skiriamas vaizdų atpažinimui, o ne požymių išskyrimui, tai buvo nuspręsta pasirinkti RGB filtro metodą [žr. 11 pav.], kurio realizacija programiškai nėra sunki. Išskiriant požymius RGB filtru galima išskirti ir veido biometrines charakteristikas. Kadangi tam tikrų veido sričių spalva lieka vienoda (antakiai, oda, plaukai, ūsai ir t. t.) Pagal RGB filtro panašius išskirtus požymius galima suformuoti vektorius. Vektorius gali būti formuojamas tik tuo atveju, jeigu pikselio reikšmės žingsnis svyruoja diapazone [-5; +5] pikselio.



R:219	R:214	R:201	R:187	R:176	R:166
G:146	G:140	G:131	G:121	G:111	G:105
B:140	B:137	B:129	B:122	B:115	B:112
R:218	R:214	R:202	R:189	R:178	R:166
G:145	G:140	G:132	G:123	G:113	G:105
B:139	B:137	B:130	B:124	B:117	B:112
R:212	R:209	R:200	R:188	R:178	R:165
G:139	G:135	G:130	G:122	G:113	G:104
B:133	B:132	B:128	B:123	B:117	B:111
R:201	R:200	R:194	R:185	R:176	R:164
G:128	G:126	G:124	G:119	G:111	G:103
B:122	B:123	B:122	B:120	B:115	B:110
R:190	R:191	R:187	R:181	R:174	R:163
G:117	G:117	G:117	G:115	G:109	G:102
B:111	B:114	B:115	B:116	B:113	B:109

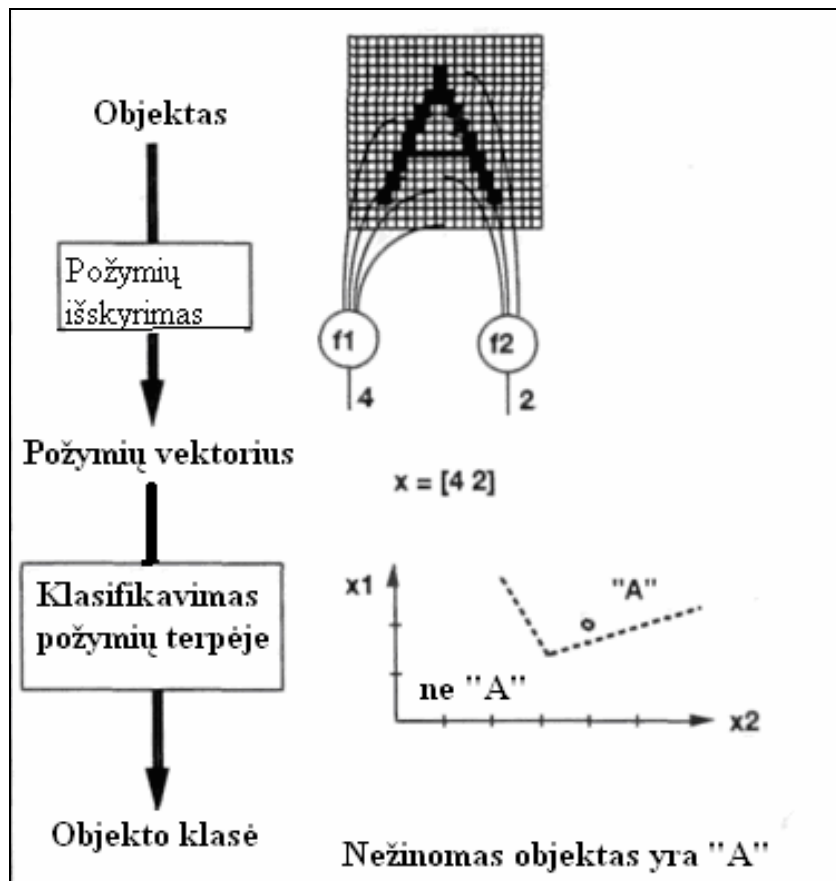
11 pav. Pažymėtos srities RGB požymiai

Gauti vektoriai yra klasifikuojami. Klasifikavimas gali būti atliktas panaudojus tokias komponentes:

- Klaidų suma kvadratu
- Euklidinė norma
- 1-artimiausio-kaimyno-metodas

Klasifikuojant požymius objektai yra grupuojami į klases. Dirbant su vienos klasės požymiais sudaroma prielaida sistemos stabilumui.

Trumpai tariant, požymių išskyrimas yra būtina dalis objekto atpažinimo eigoje, su kuriuo objektas gali būti aprašytas naudojant požymių vektorių metodus ir remiantis savo padėtimi gali būti priskirtas tam tikrai požymių klasei [žr. 12 pav.].



12 pav. Pavyzdžio požymių išskyrimas į klases

Mūsų atvejuje kiekvienas iš pikselių transformuojamas į skaitinį pavidalą, skaičiai sudaro trimačio masyvo elementus, jų reikšmė negali viršyti skaičiaus 255. Pagal požymių atliktą transformaciją, sukuriamas požymių vektorius, naudojant horizontalųjį objekto skenavimą. Vektoriai toliau klasifikuojami požymių terpėje sudarant objektų klases. Pagal požymių klases sistema gali nuspręsti, ar apskritai priklauso tas arba kitas vaizdas turimai vaizdų klasei tam tikroje vaizdų duomenų bazėje.

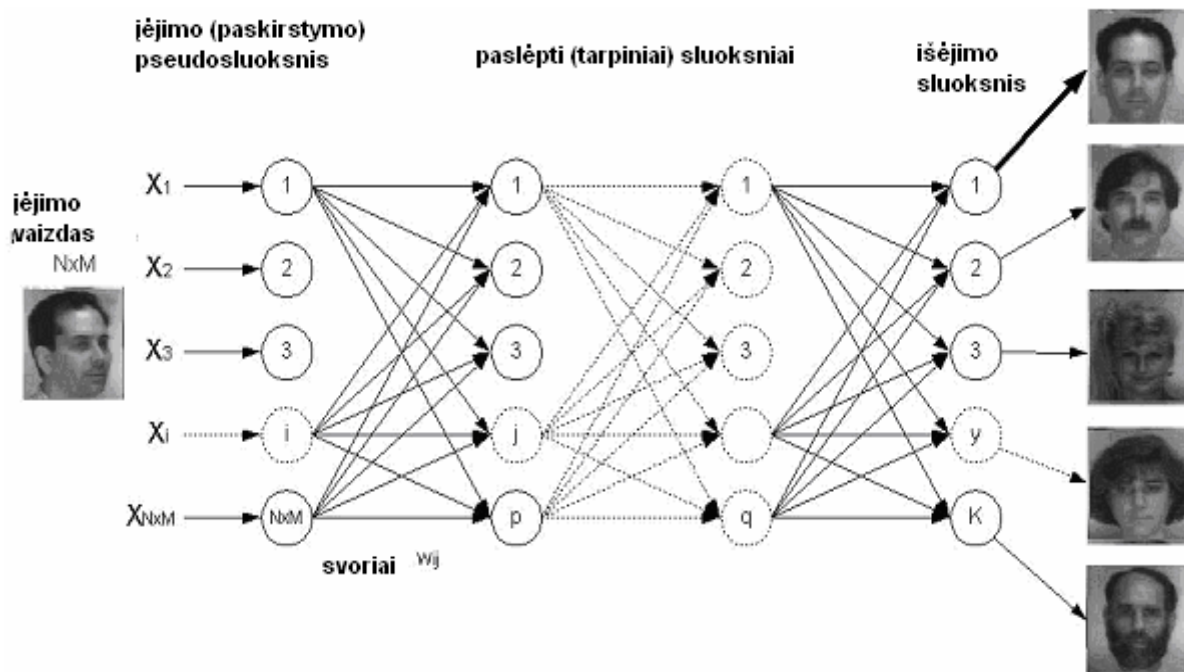
4.2. Terpės požymių paskirstymas į sritis, pagrindinių požymių išskyrimas

Tokiems uždaviniams spręsti skirti daugiasluksniai dirbtiniai neuroniniai tinklai [žr. 13 pav.], neuroniniai tinklai aukšto lygmens ir radialiniai baziniai neuroniniai tinklai.

Atsižvelgiant į tai, kad šie tinklai funkcionuoja pradinėje vaizdų terpėje, tai jiems yra kėlimas kritiškas reikalavimas - vaizdo priešapdorėjimas. Tai vaizdo suvienodinimas prie standartinio tipo (išsidėstymas, mastelis, orientavimas, ryškumo atstatymas), duomenų dydžio sumažinimas, pagrindinių charakteristikų atranka.

Kita pradinėje terpėje operavimo pasekmė yra vaizdo iškreipimo fiksavimas (pavyzdžiui, keičiant vaizdo rakursą), ir todėl mokymo išrinkimas turi turėti reprezentavimo

pavyzdžių rinkinį, kurie yra savo ruožtu yra objektinių vaizdų rinkiniai tame rakursų diapazone ir apšvietimo sąlygose, kur planuojamas vaizdų atpažinimo sistemos taikymas.



13 pav. Daugiasluoksnių neuroninio tinklo architektūra ir jos taikymas vaizdų atpažinimo procese. Neuronas su maksimaliu aktyvumu (čia pirmas) nurodo priklausomybę nuo atpažintos klasės.

Viena iš pagrindinių DNT problemų yra lokalaus minimumo problema: lokalaus minimumo problemos esmė, kaip ir visų gradientinių metodų, yra ta, kad, esant iteraciniam nuleidimui, gali atsirasti toks momentas, kai sprendimas atsiranda lokaliame minimume, iš kurio jis negali išeiti dėl mažos žingsnio reikšmės. Toks lokalus minimumas ne visada gali užtikrinti tinkamiausią uždavinio sprendimą. Išėjimas iš tokios situacijos - stochastinių metodų taikymas.

Kaip teigia Uossermen F. [45], DNT architektūros pasirinkimas (neuronų ir sluoksnių skaičius, ryšių charakteris) lieka svarbiu faktoriumi sprendžiant vaizdų atpažinimo problemas. Su tuo taip pat siejama persimokymo problema, kuri pasireiškia tame, kad tinklas su pertekliniu elementų skaičiumi, praranda apibendrinimo savybę ir gerai veikia tik per mokymo išsirinkimą. Šiuo metu sukurtos skirtingos apriorinės architektūros vertinimo reikšmės.

Apmokymo žingsnio pasirinkimas (apmokymo greitis) yra skirtas tam, kad esant mažam žingsniui apmokymo laikas bus didesnis, taip pat tinklas gali užstrigti lokaliuose minimumuose, o esant dideliems žingsniams galimas apmokymo proceso išsiskyrimas arba tinklo paralyžius. Problema išsprendžiama adaptyviu žingsniu, kuris kiekvienai iteracijai suteikia galimybę padaryti žingsnį, kuris minimizuoja tinklo klaidą šioje iteracijoje. Taip pat

yra metodai, kurie kiekvienoje epochoje analizuoja visą treniravimo išsirinkimą ir išrenka optimalią reikšmę bei žingsnio kryptį.

Išnagrinėsime daugiasluoksnių neuroninių tinklų taikymą atpažinant žmogų pagal jo veidą.

Paprasčiausias vienasluoksniu DNT taikymas (vadinamas automatinė asociatyviaja atmintimi) yra ta, kad apmokamas tinklas atstatytų paduodamus vaizdus. Paduodant į įėjimą nepažįstamą vaizdą, ir, apskaičiavus rekonstruoto vaizdo kokybę, galima apskaičiuoti, kaip tinklas atpažino įėjimo vaizdą. Teigiamos šio metodo savybės yra tos, kai tinklas gali atstatyti iškraipytus ir paveiktus vaizdus, bet rimtesniems tikslams šis metodas netinka.

DNT taip pat naudojamas tiesioginiam vaizdų klasifikavimui – į įėjimus paduodamas vaizdas [žr. 13 pav.] kokiame nors grafiniame pavidale arba anksčiau gautų vaizdo pagrindinių požymių rinkinys, išėjime neuronas su maksimalia aktyvavimo funkcija nurodo priklausomybę prie atpažintos klasės. Jeigu tos aktyvavimo funkcijos reikšmė yra mažesne tam tikros ribos, tai laikoma, kad paduotą vaizdą negalima priskirti ne vienai iš žinomų klasių. Apmokymo procesas nustato atitikimą tarp paduodamų į įėjimą vaizdų, kurie savo ruožtu priklauso tam tikrai klasei. Taip atliekamas apmokymas su mokytoju. Taikant šį metodą žmogaus veido atpažinimo procese, šis metodas efektyvus, kai kalbama apie nedidelę veidų grupę. Toks metodas suteikia galimybę patikrinti norimą vaizdą pagal visus vaizdus tinkle, bet padauginus klasių skaičių, tinklo apmokymas ir darbo laikas išauga eksponentiškai. Todėl tokiems uždaviniams spręsti, kaip panašaus žmogaus paieška didelėje duomenų bazėje, reikalaujama kompaktinio rinkinio pagrindinių charakteristikų ištraukimo, kurių pagrindu galima daryti paiešką.

Veidams klasifikuoti buvo panaudotas daugiasluoksniu perceptronas. Įėjimų duomenų pavyzdžiu buvo panaudoti simetrijos pertvarkymo rezultatai. Naudojant dirbtinių neuroninių tinklų kolektyvą atpažinimo tikslumas tik išaugo. Taip pat tikslumas išaugo prieš tai apdorojant įėjimo duomenis saviorganizuojančiais tinklais. Viskas tai leido pasiekti 0.62% klaidos MIT veidų duomenų bazėje.

Samal D. ir Starovoitovo V. darbe [40] taip pat buvo panaudotas daugiasluoksniu neuroniniu tinklo klasifikavimas. Bet įėjimo duomenimis buvo vaizdas, kurio dydis buvo kelis kartus sumažintas ir jame buvo pritaikytos Gauso filtrų skirtingos variacijos. Toks metodas padėjo pasiekti didelės apibendrinimo savybės, turint apmokymo išrinkime tik vieną žmogaus vaizdą.

Klasifikavimo metodas, naudojant vaizdo dažnines charakteristikas, aprašytas Aizenbergo atliktame tyrime [1]. Buvo panaudotas vienasluoksniu DNT, kurio pagrindą sudarė daugiareikšminiai neuronai, vienasluoksniu DNT gali taip pat sudaryti sudėtingus

atskyrimo paviršius, bet kuriuo principu. Spektraliniai Furje pertvarkymo koeficientai buvo išrenkami pagal „zigzago“ taisyklę, ir rezultatas stabilizavosi jau pirmuose koeficientuose. Pažymėta, kad 97 % atpažinimo tikslumas buvo pasiektas naudojant MIT veidų duomenų bazę.

Tikslumo skirtumas tame buvo nepastebėtinas. Ir nors rekonstrukcijos su tokiais koeficientais atlikti neįmanoma [žr. 14 pav.], atpažinimo tikslumas rekonstrukcijos atvejais sudarė vidutiniškai 96%. Požymiams išskirti buvo panaudota pagrindinių dedamųjų analizė. Pasirinktas DNT – daugiasluoksnis perceptronas. Įėjimai skaičius atitiko pikselių skaičių. Buvo panaudoti 60 ir 80 neuronų paslėptame sluoksnyje (iš viso du sluoksniai, išėjimo sluoksnyje – 40 neuronų, pagal klasių skaičių).



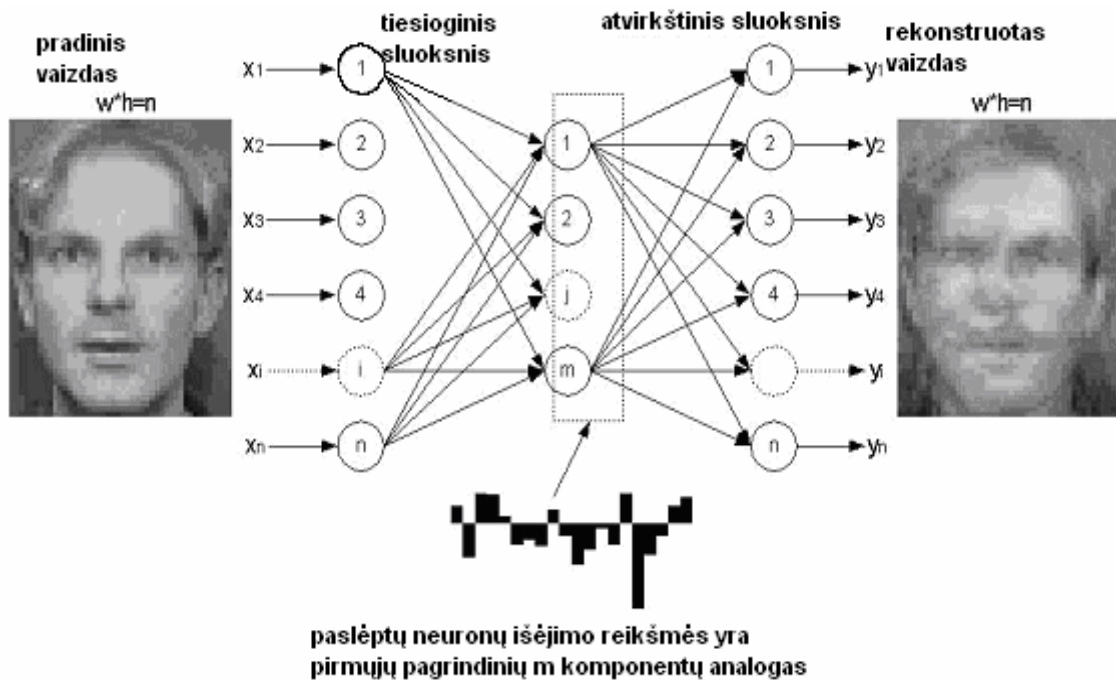
14 pav. Rekonstravimas pagal 28 iš 10304 koeficientų, vaizdas 92x112

DNT taikymas klasifikuojant veidus tokių charakteristikų pagrindu, kaip: tarpo tarp specifinių veidų sričių (nosis, burna, akys) išskyrimas, naudojamas gana dažnai. Šiuo atveju DNT įėjimui buvo pateikiami vektoriai tarp veido elementų. Panaudoti buvo taip pat kombinuoti metodai – pirmame iš jų buvo pateikti DNT įėjimui paslėpto Markovo modelio apdorojimo rezultatai, o antrame – DNT darbo rezultatas buvo pateiktas paslėpto Markovo modelio įėjimui. Antrame atvejuje pranašumų nebuvo pastebėta, tai parodo tai, kad paslėpti Markovo modeliai turi blogesnę atpažinimo charakteristikas negu DNT metodai.

Ranganath S. ir Arun K. darbe [21] pateiktas DNT taikymas vaizdams klasifikuoti, kai tinklo įėjimui pateikiami vaizdo dekomponavimo rezultatai, naudojant pagrindinių dedamųjų analizę (*PCA*) [žr. 14 pav.].

DNT naudojami ir tam tikrų objektų aptikimui. Be to, bet koks apmokytas DNT tam tikru būdu gali nustatyti vaizdų priklausomybę nuo „savo“ klasių, DNT galima specialiai apmokyti patikimam tam tikros klasės nustatymui. Šiuo atveju išėjimo klasėmis bus tos klasės, kurios yra priklausomos ir nepriklausomos nuo tam tikrų vaizdų tipų. Petrowski A.,

Dreyfus G. ir Girault C. darbe [20] buvo panaudotas įėjimo vaizde neuroninio tinklo detektorius vaizdo aptikimui. Vaizdas buvo nuskenuotas 20x20 pikselių dydžiu, kuris buvo pateiktas tinklo įėjimui, ir buvo sprendžiama, ar priklauso tam tikras bruožas veidų klasei. Apmokymas buvo atliktas kaip panaudojant teigiamus pavyzdžius (skirtingi veidų vaizdai), taip ir su neigiamais pavyzdžiais (vaizdai, kuriuose nėra veidų). Taip pat apmokymo išrinkime nežymiai svyravo mastelis, veido išsidėstymas ir orientavimas. Atpažinimo patikimumo didinimui buvo panaudotas DNT kolektyvas, kuris buvo apmokytas su skirtingais pradiniais svoriais.



15 pav. Recirkuliavimo neuroninio tinklo architektūra, panaudojus pagrindinių dedamųjų analizę

Kaip jau minėjome, DNT taikomi taip pat vaizdo pagrindinių dedamųjų išskyrimui, kurios vėliau naudojami tolimesniajai klasifikacijai. Golovko savo darbe [34], pateikia pagrindinių dedamųjų metodo realizacijos būdą. Pagrindinių dedamųjų metodo esmę sudaro maksimaliai dekoreliuotas koeficientų gavimas, kurie savo ruožtu charakterizuoja įėjimo vaizdus. Šie koeficientai vadinami pagrindėmis dedamųjų komponentėmis ir naudojami statistiniam suspaudimui bei vaizdo rekonstravimui, kuriame nedidelis koeficientų skaičius naudojamas viso vaizdo atpažinimui. Kiekvienas vaizdas suskaldomas į tiesinę nuosavų vektorių kombinaciją. Nuosavų vektorių vaizdai, kurie yra panašūs į veidus, vadinami nuosavais veidais (*eigenfaces*). Nuosavų vektorių suma, padauginta iš atitinkamos pagrindinių dedamųjų komponentės sudaro vaizdo rekonstravimą.

DNT su vienu paslėptu sluoksniu, su m neuronų skaičiumi, atitinkančių daug didesnę vaizdo dydį $m \ll n$. Apmokytas DNT pagal klaidos atvirkštinio skleidimo metodą, formuoja paslėptų neuronų išėjimuose pirmus m koeficientus, kurie ir naudojami vaizdų palyginimui. Tokio tinklo architektūra vadinama recirkuliuojamu neuroniniu tinklu (RNT), pateikta 15 pav.

Įprastai naudojama nuo 10 iki 200 pagrindinių dedamųjų komponentėčių. Padidinus komponento numerį, jo reprezentavimo savybė staigiai sumažinama ir naudoti dedamasias su dideliais numeriais netenka prasmės. Tiesinių aktyvavimo funkcijų naudojimas neuroniniame tinkle suteikia galimybę gauti paslėpto sluoksnio išėjime, būtent pagrindines pirmų m komponentes, kurios yra analogiškos gaunamiems tokioms komponentėms, kurios atlieka matricų lygčių sprendimus. Naudojant nelineines neuroninių elementų aktyvavimo funkcijas galimas nelineinis dekomponavimas į pagrindines dedamasias. Nelineiškumas padeda tiksliai apibrėžti įėjimo duomenų variacijas, tik tada paslėptų neuronų išėjimai bus panašūs į pagrindines dedamasias. Svoriai, kurie susiformavo esant tokiam apmokymui įėjimo ir išėjimo sluoksnyje, taip pat bus panašūs į savo veidus [25]. Šie svoriai atspindi tokias būdingas charakteristikas, kaip lytis, amžius, emocijos ir t. t. Pirmos komponentės atspindi bendrą veido formą, paskutinios – skirtingus nesmulkius skirtumus tarp veidų. Toks metodas gerai taikomas panašių veidų vaizdų paieškoje didelėse veidų duomenų bazėse. Taip pat šis metodas naudojamas veido veidu nustatymo uždaviniui spręsti. Vertinant įėjimo vaizdo rekonstravimo kokybę galima labai tiksliai nustatyti jo priklausomybę nuo veidų klasės.

RNT taikymo privalumai pagrindinių dedamųjų išskyrimui prieš sprendžiant matricų lygtis, yra aprašytos šiame darbe [42]. Ypatingai išskyrimas RNT apmokymo algoritmo paprastumas ir universalumas. Nelinejinė aktyvavimo funkcija padeda tiksliai rekonstruoti vaizdą. Sprendžiant matricų lygtis darbo pabaigoje iškyla problemos, jei pavyzdžiai yra labai panašūs vienas į kitą, RNT šio trūkumo neturi. Nereikia apskaičiuoti nuosavų vektorių. Tokiu būdu tinklo apmokymo laikas tiesiškai priklauso nuo pagrindinių dedamųjų kiekio. Išankstiniuose eksperimentuose galima naudoti mažesni apmokamų ciklų kiekį, kas sumažina apmokymo laiką.


Pateikta taip pat tolimesnio pagrindinių dedamųjų dydžio sumažinimo galimybė naudojant daugiasluoksnį DNT [26]. Jo esmė yra ta, kad būtų panaudotas didesnis paslėptų sluoksnių kiekis, kurie atsako už vaizdo rekonstravimą ir suspaudimą. Toks pat suspaudimas padeda suprasti sudėtingesnius vaizdų imties dėsningumus, ir, vadinasi, pateikti juos tiksliau ir su mažesniu dedamųjų skaičiumi.

4.2. Radialiniai bazinių funkcijų neuroniniai tinklai

Radialiniai bazinių funkcijų neuroniniai tinklai (RBFNT, angliškai - *Radial Basis Function Network, RBF*) tęsia atvirkštinio sklaidimo algoritmo idėją ir susideda iš dviejų sluoksnių [žr. 16 pav.]. Pirmas sluoksnis turi radialiniai bazinę aktyvavimo funkciją:

$$y = \exp\left(\frac{-S^2}{2\sigma^2}\right), \text{ kur } \sigma \text{ - vidutinis kvadratinis poslinkis, charakterizuojantis funkcijos plotį}$$

(klasterio dydis), S nustatomas kaip atstumas tarp įėjimo ir išėjimo vektoriaus. $S^2 = \|X - W\|^2 = \sum_i (x_i - w_i)^2$, kuris savo ruožtu yra atstumas iki klasterio centro, nustatomo konkrečiu neuronu. Tokiu būdu neuronų sluoksnis yra klasterių rinkinys vaizdų terpėje ir atlieka pirmą įėjimo vaizdo klasterizavimo etapą — kiekvieno neurono aktyvavimo funkcijos reikšmė yra greitai sumažinama, priklausant nuo klasterio centro nutolinimo. Antras neuronų sluoksnis turi linijinę aktyvavimo funkciją, ir atlieka antrą klasterizavimo etapą — paskirsto klasterius pagal klases. RBFNT privalumas: skirtingai nuo Koheneno žemėlapių čia vyksta tų neuronų sunulinimas, kurie neturi maksimalios išėjimo reikšmės, jie visi įneša indėlį į klasterizavimą.



16 pav. Radialinis bazinių funkcijų neuroninis tinklas [33]

RBFNT taip pat gali sudaryti sudėtingas atskyrimo sritis ir aproksimuoti daugiamates funkcijas. Palyginus su daugiasluoksniu neuroniniu tinklu, radialiniai baziniai tinklas apmokamas greičiau, bet turi blogesnę ekstrapoliacinę savybę, t. y. negali dirbti su vaizdais, kurie yra nutolę nuo savo vaizdų pavyzdžių. RBFNT dydis didesnis negu DNT analogiškiems uždaviniams spręsti, ir RBFNT tampa mažai efektyvesnis augant įėjimo duomenų dydžiui.

Apmokamas toks tinklas yra per du etapus. Pirmas etapas realizuojamas be mokytojo, pirmas sluoksnis jame išskiria kompaktiškai išdėstytas klasterių grupes. Tuo atveju koreguojami klasterių centrai. Šiuo metu sukurti efektyvūs algoritmai, kurie leidžia parinkti optimalių klasterių dydį kiekvienam neuronui ir gauti optimalų neuronų skaičių pirmame sluoksnyje. Antrame apmokymo etape, antras sluoksnis apmokamas rūšiuoti įėjimo vaizdus, kurie praledžiami per pirmąjį sluoksnį arba per klases. Informacija apie etalonines išėjimų

reikšmes yra žinoma, kai apmokymas vyksta su mokytoju. Tai galima atlikti matricų metodais, arba atvirkštinio skleidimo algoritmu.

Išnagrinėsime radialinių bazinių neuroninių tinklų taikymą, atpažinant žmogų pagal jo veidą. Rangath S. ir Arun K. darbe [21] buvo panaudoti du pagrindinių dedamųjų išskyrimo metodai ir dvi skirtingos RBFNT architektūros veidų atpažinimui. Pirmame atvejyje charakteristikos turėjo pagrindinių dedamųjų rinkinį, antrame – veivletinių pertvarkymų kompozicijas. Pirmoje architektūroje išėjimų kiekis atitiko klasių kiekį, antroje buvo panaudotas tinklų kolektyvas, kiekvienas iš jų buvo apmokytas atpažinti tik savo klasę. Nustatyti reikšminiai RBFNT klasifikavimo privalumai prieš pagrindinių charakteristikų palyginimą testuojant su MIT veidų duomenų baze.

Panaudotos dvi skirtingos RBFNT architektūros vaizdų klasifikavimui. Į tinklo įėjimą paduodavo visą vaizdą, išėjimuose buvo formuojamas tarpinis klasifikavimas, kuris buvo pateikiamas sprendimo medžiams turinio orientuotam vaizdai atpažinti (pavyzdžiui, surasti visus tam tikro žmogaus veidus, kur žmogus yra su akiniais). Skirtingi tinklai pirmos architektūros grupėje mokėsi klasifikuoti vaizdus su skirtingais pokyčių tipais, antroje architektūros grupėje DNT mokėsi klasifikuoti vaizdus su vienodais pokyčių tipais, bet neuronų kiekis keitėsi per apmokymo procesą. Galutinę išvadą darydavo „teisėjas“, kuris priimdavo sprendimą tinklų grupės balsavimo pagrindu.

Radialiniai baziniai tinklai buvo panaudoti žmogaus veidui arba lyčiai atpažinti, panaudojus jo geometrines charakteristikas. Pradiniai vaizdai buvo 8 bitų gylio spalvos. Pastebėta gera RBFNT savybė išskirti skiriamuosius požymius. RBFNT parodė aukštą atpažinimo rodiklį.

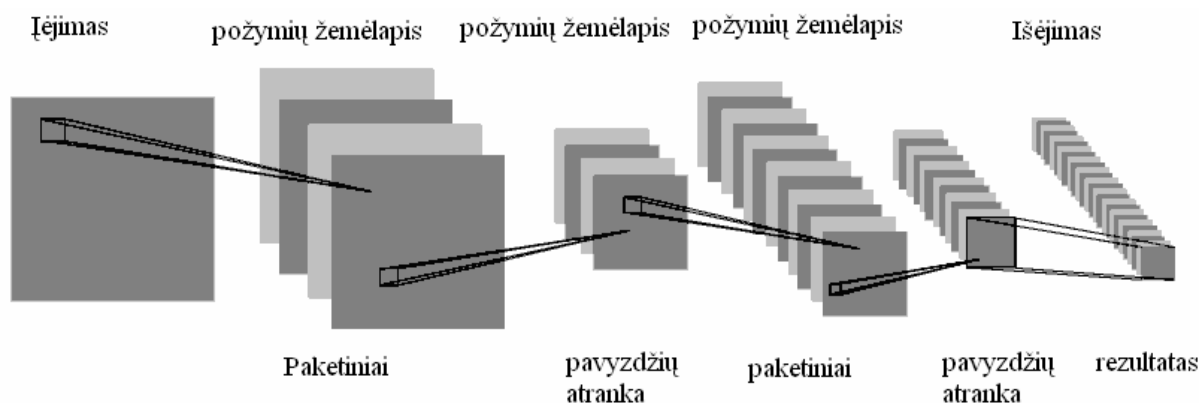
Mūsų atliktame tyrime, mes negalėjome sudaryti tinkamos RBNT architektūros, dėl jos sudarymo sudėtingumo. Todėl atliekant DNT tipų analizę veidui atpažinti [žr. 2 lentelę], buvo pasinaudota duomenimis iš Rangath S. ir Arun K. darbo [21]. Jų darbe tyrimas buvo atliktas su MIT veidų duomenų baze.

4.3. Sąsukiniai neuroniniai tinklai

Klasikiniame daugiasluoksniame neuroniniame tinkle tarpusluoksniai neuroniniai ryšiai yra visiškai surišti ir vaizdas pateikiamas n -mačiame vaizdo pavidale. Pateikiant reikėtų atsižvelgti į lokalų pikselių organizavimą, bet ne į deformavimo galimybes. Paketinio DNT architektūra [žr. 17 pav.], nukreipta į šių trūkumų įveikimą ir grindžiama neokognitrono architektūros principais, kuris supaprastintas ir papildytas atvirkštinio skleidimo apmokymo algoritmu.

Šiame DNT naudojami lokaliniai perceptorių laukai (užtikrina lokalų dvimatį neuronų sąryšį), bendri svoriai (užtikrina kai kurių bruožų atpažinimą bet kurioje vaizdo vietoje) ir hierarchinis organizavimas su erdviniais išrinkimais (*spatial subsampling*).

Sąsukinis DNT (*CN, Convolutional Neural Network*) užtikrina mastelio, poslinkių, sukimų, rakurso pakeitimo ir kitų iškrypimų dalinį pastovumą [14].



17 pav. Paketinio neuroninio tinklo architektūra

Kiekviename sluoksnyje yra kelių plokštumų rinkinys, kuriame vienos plokštumos neuronai turi vienodus svorius, vedančius prie visų priešankstinio sluoksnio lokaliųjų sričių (kaip regimojoje žmogaus žievėje). Priešankstinio sluoksnio vaizdas skenuojamas lygtai nedideliu langu ir praleidžiamas pro svorių rinkinį, o rezultatas atspindimas į tam tikrą esančio sluoksnio neuroną. Tokiu būdu plokštumų rinkinys yra požymių žemėlapis (*feature maps*) ir kiekviena plokštuma randa „savo“ vaizdo sritį bet kurioje priešankstinio sluoksnio vietoje.

Kitas po sąsukinio sluoksnio poatrankinis sluoksnis sumažina plokštumų mastelį naudojant lokalų neuronų išėjimo reikšmių vidurkį.

Tokiu būdu, pasiekama hierarchinė organizacija. Kiti sluoksniai gauna bendresnes charakteristikas, mažiau priklausančias nuo vaizdo iškrypimo.

Sąsukinis DNT apmokama standartiniu atvirkštinio sklaidymo metodu. *MLP* ir *CN* palyginimas parodė paskutinio esminius pranašumus kaip pagal funkcionavimo greitį, taip ir pagal klasifikavimo patikimumą [žr. 2 lentelę]. Gera sąsukinių DNT savybė yra ir ta, kad charakteristikos formuojamos hierarchijos viršutinių sluoksnių išėjimuose, gali būti panaudoti artimo kaimyno metodo klasifikavimui (pavyzdžiui, apskaičiuojant Euklido atstumą), be to sąsukinis DNT gali sėkmingai išgauti tokias charakteristikas ir vaizdams, kurių nėra apmokymo rinkinyje. Sąsukiniam DNT būdingas didelis apmokymo ir darbo greitis. Testuojant sąsukinį DNT su veidų duomenų baze iš ORL, kurioje veidų vaizdai turi nedidelius apšvietimo, mastelio, erdviųjų posūkių, išsidėstymu ir emocijų pakeitimus, parodė 92% - 96% atpažinimo tikslumą [žr. 2 lentelę]. Toks rezultatas daro šią architektūrą

perspektyvia tolimesniuose trimačių vaizdų atpažinimo srities kūrimuose, o būtent, žmogaus veidų atpažinime.

4.5. DNT tipų ir požymių išskyrimo metodų analizė, sprendžiant veidų atpažinimo uždavinius.

Tam tikro veido skirtingi rakursai turi būti siejami su informacija, kuriam asmeniui šie bruožai priklauso. Dažnai atsitinka taip, kad fotografuojant veidą iš skirtingų žvilgsnio kampų, nestebimas DNT elegesys per mokymo procesą, kuris gali klaidingai suklasifikuoti skirtingus veido rakursus. Taip pat gali ilgai tęstis, kol vaizdai bus suklasifikuoti į vieną klasę. Lieka nuspręsti, kada gi turi būti naudojamas automatinis vaizdų apdorojimas, o kada geriau būtų naudoti rankinį apdorojimą. Bendrai tariant, automatinis apmokymas gali būti atliekamas tada, kai yra nežinomas informacijos pobūdis, kuris bus grupuojamas į klasę. Siekiama, kad DNT nustatytų klases per savarankišką organizavimą.

Bet vis dėlto sistemos funkcionavimas rankiniu būdu gali parodyti geresnius rezultatus. Geriau, kai dirbtiniai neuroniniai tinklai naudoja ne savarankišką klasifikavimą, o klaidų toleranciją ir apibendrinimo savybes.

Tam tikslui buvo atlikta kelių DNT tipų bei požymių išskyrimo būdų praktinė analizė. Analizė buvo atlikta panaudojus *Matlab*, *NeuroFace* bei *SNNS* modeliavimo paketus. DNT buvo sudarytas iš 2576 šėjimų (pikselių skaičius), 2 tarpinių sluoksnių ir 40 išėjimų sluoksnių (klasių skaičius). DNT buvo apmokytas per 500 mokymo ciklų. Mokymo diapazonas sudarė [0; 1].

2 lentelėje yra palyginti skirtingi DNT tipai bei požymių išskyrimo metodai veidui atpažinti. Tinklai buvo apmokami pateikiant jiems 5 tam tikro žmogaus vaizdus. Buvo pasinaudota jau paruošta veidų duomenų baze iš *Olivetti Research Laboratory (ORL)*. Ši duomenų bazė turi 40 asmenų 400 vaizdus. Veido apšvietimas, rakursas ir išsidėstymas visur buvo vienodas.

Analizė buvo atlikta Pentium III platformoje, su 800 MHz taktiniu greičiu, 192 RAM.

2 lentelė. Skirtingų DNT tipų bei požymių išskyrimo tipų analizė

	Atpažinimo metodas	Atpažinimo tikslumas procentais (%)	Mokymo laikas	Klasifikavimo laikas
DNT tipai	pagrindinė dėdamųjų analizė + daugiasluoksnis perceptronas	59	-	-
	savaime susiformuojantis žemėlapis + daugiasluoksnis perceptronas	60	-	-
	pagrindinė dėdamųjų analizė + sąsukinis neuroninis tinklas	92	-	-
	savaime susiformuojantis žemėlapis + sąsukinis neuroninis tinklas	96	apie 4 val	<30 s
	tikimybinis, sprendimu pagrįstas neuroninis tinklas	96	20 min	<6 s
	kortežas iš n klasifikatorių	81	0.9 s	2 s
	kortežas iš n nepertraukiamų klasifikatorių	95	0.9 s	20 s
	1-artimiausias - kaimynas radialinių bazinių funkcijų neuroninis tinklas prieš atmetimą [21]	97	0 s	1 s
	radialinių bazinių funkcijų neuroninis tinklas prieš atmetimą [21]	86	-	-
	radialinių bazinių funkcijų neuroninis tinklas po atmetimo [21]	95	-	-
Požymių išskyrimo metodai	paslėpti Markovo modeliai	87	-	-
	pseudo dvimatės grafikos paslėpti Markovo modeliai	95	-	240 s
	išskiriamųjų veido bruožų metodas	89	-	-

Paiškinimas:

-: užtruko ilgai (nėra duomenų)

4.6. DNT tipų ir požymių išskyrimo metodų analizės išvados

Geriausią rezultatą gavo 1-artimiausio-kaimyno tipas, bet šis DNT tipas labiau tinka klasifikavimo uždaviniams spręsti, o ne vaizdų atpažinimui. Panaudojus tipą „savaiame susiformuojantis žemėlapis + sąsukinis neuroninis tinklas“, pasiektas 96 % atpažinimo tikslumas, bet šio metodo realizacija ilgai užtrunka praktiškai, nes tinklo apmokymo laikas, paremtas tinklo savaiame susiformuojančiu žemėlapiu, užima apie 4 valandas. Tikimybinio, sprendimu pagrįstas neuroninio tinklo tipo rezultatai yra geresni negu „savaiame susiformuojantis žemėlapis + sąsukinis neuroninis tinklas“, bet šio tipo taikymo sritis labai siauri ir sunkiai realizuojama praktiškai. Blogiausių rezultatus gavome panaudojus pagrindinių dėdamųjų analizės metodą ir daugiasluoksnio perceptrono realizaciją, atpažinimo tikslumas sudarė 59 %. Šio metodo mokymo ir klasifikavimo laikas užtruko gana ilgai, todėl rezultatų jokių nepateikiame. Tačiau panaudojus „pagrindinė dėdamųjų analizė + sąsukinis neuroninis tinklas“ tipą rezultatas yra žymiai geresnis ir sudaro 92 %. Palyginus „pagrindinė dėdamųjų analizė + daugiasluoksnis perceptronas“ ir „pagrindinė dėdamųjų analizė + sąsukinis neuroninis tinklas“ atpažinimo tipus galime teigti, kad sąsukinio DNT panaudojimas yra pranašesnis negu daugiasluoksnio DNT, atsižvelgiant šiuo atveju kaip į atpažinimo tikslumą, taip ir į klasifikavimo laiką. Gana gerus rezultatus pateikė kortežas iš nepertraukiamų n klasifikatorių, šio metodo atpažinimo tikslumas sudarė 95 %. Taip pat gana greitai buvo atliktas tinklo mokymo bei klasifikavimo laikas. Įvertinant radialinių bazinių funkcijų neuroninių tinklų paplitimą, buvo pasiūlyta įtraukti į testavimus ir juos. Kadangi *Matlab*, *SNNS* ir *NeuroFace* modeliavimo paketuose nepavyko realizuoti radialinius bazinių funkcijų neuroninių tinklų, buvo nuspręsta pasinaudoti tyrimo rezultatais iš Rangath S. ir Arun K. darbo [21]. Jų darbe tyrimas buvo atliktas su *MIT* veidų duomenų baze. Jų darbe tyrimas buvo atliktas prieš atmetant funkciją ir po funkcijos atmetimo. Po funkcijos atmetimo radialinių bazinių funkcijų neuroninis tinklas pateikė gerą atpažinimo tikslumą, kuris sudarė 95 %. Mokymo ir klasifikavimo laiko nebuvo nurodyta. Palyginus DNT tipų metodus su požymių išskyrimo metodais galima teikti, kad DNT tipų metodai duoda šiek tiek geresnius rezultatus. Blogiausią rezultatą parodė paslėpti Markovo modeliai, šio metodo atpažinimo tikslumas sudarė 87 %. Truputį geresni rezultatą gavo išskiriamųjų veido bruožų metodo analizė, šio meto atpažinimo tikslumas sudarė 89 %. Geriausią rezultatą tarp požymių išskyrimo metodų pateikė pseudo dvimatės grafikos paslėptų Markovo modelių metodas, kurio atpažinimo tikslumas sudarė 95 %.

5. PROJEKTINĖ REALIZACIJA

Projektinės realizacijos dalyje aprašoma programinės įrangos projektinė dokumentacija. Projektinėje dalyje pateikiamas realizacijos kelias, pasirinktas analizės dalyje. Joje taip pat turi būti apžvelgta projektuojamos sistemos specifikacija, programuojamos sistemos architektūra, siūlomas programos prototipinis modelis, programinių modulių ir objektų specifikacijos. Projekto pabaigoje bus atliktas išsamus programinės įrangos testavimas.

5.1. Projektinės dalies tikslas

Projektinės dalies tikslas yra vaizdų bei žmogaus veidų atpažinimo sistemos kūrimas naudojant daugiasluoksnį DNT su atvirkštinio skleidimo mokymo algoritmu.

Reikalavimai sistemai:

- funkcionavimas realiu laiku,
- nustatymo lankstumas, taikymo paprastumas ir universalumas,
- pastovumas išorinėms klasinėms veido ir vaizdo variacijoms (apšvietimas, rakursas)
- pastovumas vidinėms klasinėms veido ir vaizdo variacijoms (emocijos, akiniai, barzda, šukuosena ir t. t.)
- programinės įrangos stabilumas klaidoms.
- kuriamo algoritmo paprastumas ir universalumas.

Siekiant pasiekti šiuos tikslus buvo pasirinktas daugiasluoksnis DNT su atvirkštinio skleidimo mokymo algoritmu išskiriant žmogaus veido požymius.

Ryšium su tuo analizės dalyje buvo atlikti sekantys tyrimai:

- Pradinio vaizdo požymių išskyrimas (požymių išskyrimas panaudojus pikselių skenavimą).
- Skirtingų apmokymo algoritmų tyrimas (Momentum-Term funkcija, svorio redukcija, aktyvavimo funkcija, slenkstinės vertės transformacija į rezultatų mazgą, rekurentinis atvirkštinis skleidimas).
- Skirtingų DNT architektūrų tipų bei požymių išskyrimo tipų taikymas vaizdams ir žmogaus veidui atpažinti.
- Specializuotos DNT architektūros sudarymas.

Programa turi būti realizuota su C++ kalba. C++ kalboje bus aprašytos funkcijos, kurios nuskaitys vaizdus, išskirs požymius, atliks požymių transformaciją ir perduos programos branduoliui tam tikrą požymių formatą.

Programos testavimas turi būti atliktas su autoriaus sudaryta veidų duomenų bazė. Programos atpažinimo tikslumas turi būti nustatytas naudojant ROC, FAR bei FRR įvertinimo metodus.

5.2. Reikalavimų specifikavimo dokumentas programinei įrangai „Veidas“

Dokumento tikslas – pateikti reikalavimus vaizdų ir žmogaus veidų atpažinimo sistemai, kuri diegiama įmonėje GmbH „Babylono“.


Projektą užsakė juridinis asmuo – UAB „Insaris“ ir GmbH (Bendrovė su ribota atsakomybė) „Babylono“. GmbH „Babylono“ firmos centrinė buveinė yra Vokietija. Ši Lietuvos-Vokietijos įmonė užsiima apsaugos sistemomis. GmbH „Babylono“ firmos direktorius – H. Schloenis, UAB „Insaris“ firmos direktorius – Anatolijus Guželis.

Projekto vykdytojas yra Kauno Technologijos universiteto, Informatikos fakulteto, IFM 9/3 grupės studentas – Oleg Studenikin.

Programinio produkto vartotojas yra prieigos sistemos administratoriai bei apsaugos skyriaus darbuotojai. Programa gali naudotis visos įmonės bei institucijos, kur pašalinis asmuo nėra pageidaujamas.

Kuriamas produktas –prieigos sistemos kūrimas naudojant žmogaus veido atpažinimo analizę. Numatomas projekto realizavimo terminas yra 5 mėnesiai. Laiko įvertinimui kiekvienam iš darbų buvo panaudotas Ganto grafikas (žr. 3 lentelę):

3 lentelė. Ganto grafikas



Projekto finansavimas vyks iš Europos Sąjungos fondų. Šiam tikslui buvo pasiūlyta „Leonardo“ fondo programa. Pagal šio fondo taisykles, projektui realizuoti bus išskirta 70 % jam reikiamų lėšų. Kuriamas produktas turi turėti taip pat mokslinę vertę, nes kitaip lėšos nebus skirtos. 30 % lėšų išskirs organizacija, kur šis projektas bus realizuotas. Šiuo atveju tai yra GmbH „Babylono“ ir UAB „Insaris“. Projekto dalyviai kartu yra suinteresuotos projekto šalys.

Bendras tikslas – sukurti šiuolaikinę biometrinių identifikavimo sistemą bei pasiūlyti naują vaizdų atpažinimo metodą naudojant atvirkštinio sklaidimo neuroninius tinklus.

Numatomo produkto funkcijos:

1. Vaizdo įvedimas
2. Duomenų apdorojimas (biometrinių charakteristikos)
3. Paruošimas
4. Kokybės patikrinimas, sprendimas ir normalizavimas
5. Duomenų apdorojimas, biometrinių savybių skaičiavimas
6. Palyginimas ir sprendimo priėmimas
7. Rezultato išvedimas

Produkto našumas priklausys nuo turimo vaizdų skaičiaus duomenų bazėje. Nes tam tikro veido požymius reikės tikrinti su visais kitais veidų požymiais esančioje duomenų bazėje.

Laiko apribojimai:

Projekto realizavimo laikas yra 5 mėnesiai ir projektas turi būti pristatytas laiku.

Produkto kūrimo metu buvo įvertinti ir kiti panašios paskirties programiniai produktai.

Kiti produktai rinkoje. Šiuo metu yra žinomi tokia biometrinių programinių įrangų rinkoje:

ASID, EBS, Identi-Kit, įmonė Smith&Wesson

BioID, įmonė DCS

BS-Control, Visec-FIRE, įmonė Berninger Software

digitech::face, įmonė Digitech Projects

FaceGuardian, įmonė Keyware

FaceID, įmonė ImageWare Software

FaceIt, įmonė Visionics

FaceSnap, įmonė C-VIS

FaceVACS, įmonė Plettac electronics

Identica, įmonė Aurora Computer Services

Morphomatic, įmonė Agma

Mixed-Mode Circuits for Implementing an Integrated Face Recognition System, įmonė Neuraware

TrueFace, įmonė Miros

UnMask, įmonė Visionsphere

Visual Casino, įmonė Biometrica Systems

ZN-Face II, Phantomas, įmonė ZN

Viisage PROOF 1.0, įmonė Viisage

Projekto išlaidų ir pelno santykis:

Projektas jokio materialiojo pelno neduos, nes jis bus pritaikytas vienintelėje įmonėje. Bet užtat po tyrimo pabaigos, pasiūlytas mokslui vaizdų ir žmogaus veidų atpažinimo metodas turėtų būti naudingas.

Projektavimo nesėkmės tikimybė yra gana didelė, nes ne vienas iš tokio tipo sukurtų pasaulyje produktų, nebuvo suprojektuotas taip, kad sistema veiktų 100% veidų atpažinimo tikslumu, t. y. vaizdų ir žmogaus veidų atpažinimo tikslumas nėra 100%.

Pasekmės projektavimo nesėkmės atveju:

- ✓ Papildomos išlaidos saugumui įmonėje GmbH „Babylono“ ir UAB „Insaris“;
- ✓ Papildomų lėšų paieška projektui realizuoti;
- ✓ Projektinė dalis nebus įvykdytas laiku.

Pageidautini techniniai ir sisteminiai reikalavimai:

Personaliniai kompiuteriai: 2,4 GHz taktinis greitis, 512 Mb RAM, Pentium IV Hyper-Threading platforma, 120 Gb atminties kietieji diskai su 7200 rpm.

Spausdintuvai: lazeriniai

Kameros: skaitmeninės

Skeneriai: 48 bit, skenavimo geba 1200*3600 dpi.

Darbo vietos apšvietimas 150 W

Projektavimui bus panaudoti šie projektavimo įrankiai: *Rational Rose*, *MS Visio 2000 Enterprise Editon* ir *MS Project 2003*. Šie įrankiai turėtų sumažinti klaidų santykį projektuojant sistemą. *MS Visio 2000 Enterprise Editon* padės sukurti sistemos bazinį modelį. *MS Project 2003* užtikrins projekto įvykdymą laiku.

Sistemoje informacija bus saugojama grafiniu bei skaitiniu pavidalu, nes informacijos pradiniai duomenys yra vaizdas gaunamas iš Web-Life skaitmeninės kameros. Web-Life skaitmeninės kameros PĮ aplinkoje vaizdas paverčiamas iš analoginio į skaitmeninį. Taip pat vaizdas gali būti gautas iš žmogaus veido nuotraukos. Rekomenduojamas pateikiamos nuotraukos dydis yra 300×350 dpi. Toliau kiekvienas vaizdas analizuojamas programoje, tai yra iš pradžių išskiriamos kiekvieno žmogaus veido biometrinių charakteristikų informaciją.

Biometrinės charakteristikos transformuojamos į skaitmeninę informaciją. Gauta informacija (skaičiai) paduodama į neuroninio tinklo įėjimus. Neuroninis tinklas apdoroja informaciją, tai yra lygina su kitų veidų biometrinėmis charakteristikomis. Rezultatas išvedamas į ekraną. Rezultato forma – tekstinė, su loginiu atsakymu: pateikiamas identifikuoto vaizdo arba žmogaus vardas.

Sistemai turi būti būtinai sukurtas prototipinis modelis. Sukurtas modelis padės geriau pažinti sistemą. Tuo pačiu tai padės projekte dalyvaujantiems specialistams geriau suprasti sistemos atliekamas funkcijas bei darbo eigą.

Sistemos saugumas. Antivirusinės bazės turi būti nuolat atnaujinamos. Kiekviename kompiuteryje turi būti įdiegta ugniasienė. Operacinės sistemos modifikavimas bus užblokuotas visiems vartotojams, išskyrus sisteminio programuotojo ir sisteminio administratoriaus. Visi saugojami duomenys bus dubliuojami RAID masyvo principu. Priėjimą prie duomenų turės sisteminis programuotojas ir sisteminis administratorius.

Programos patikimumas. Sistemos administratoriui bus nuolat pranešama apie nesklandumus sistemoje. Remiantis šiais duomenimis sistema bus nuolat tobulinama.

Programos reikalavimai sistemos palaikymui. Sisteminis programuotojas ir sistemos administratorius turi mokėti atlikti kito specialisto pareigas, kad nebūtų taip, kad vienam iš jų “dingęs”, visa sistemų sustotų. Visi pakeitimai sistemoje turi būti įrašomi į žurnalą.

Sistemos perkeliamumas. Sistema negali būti laisvai perkelta iš vieno kompiuterio į kitą. Tam turi būti reikalingas sistemos administratoriaus leidimas.

Sistemos išplėtimo reikalavimai. Sistema turi būti lanksti modernizavimui, kaip iš techninės, taip ir iš programinės pusės.

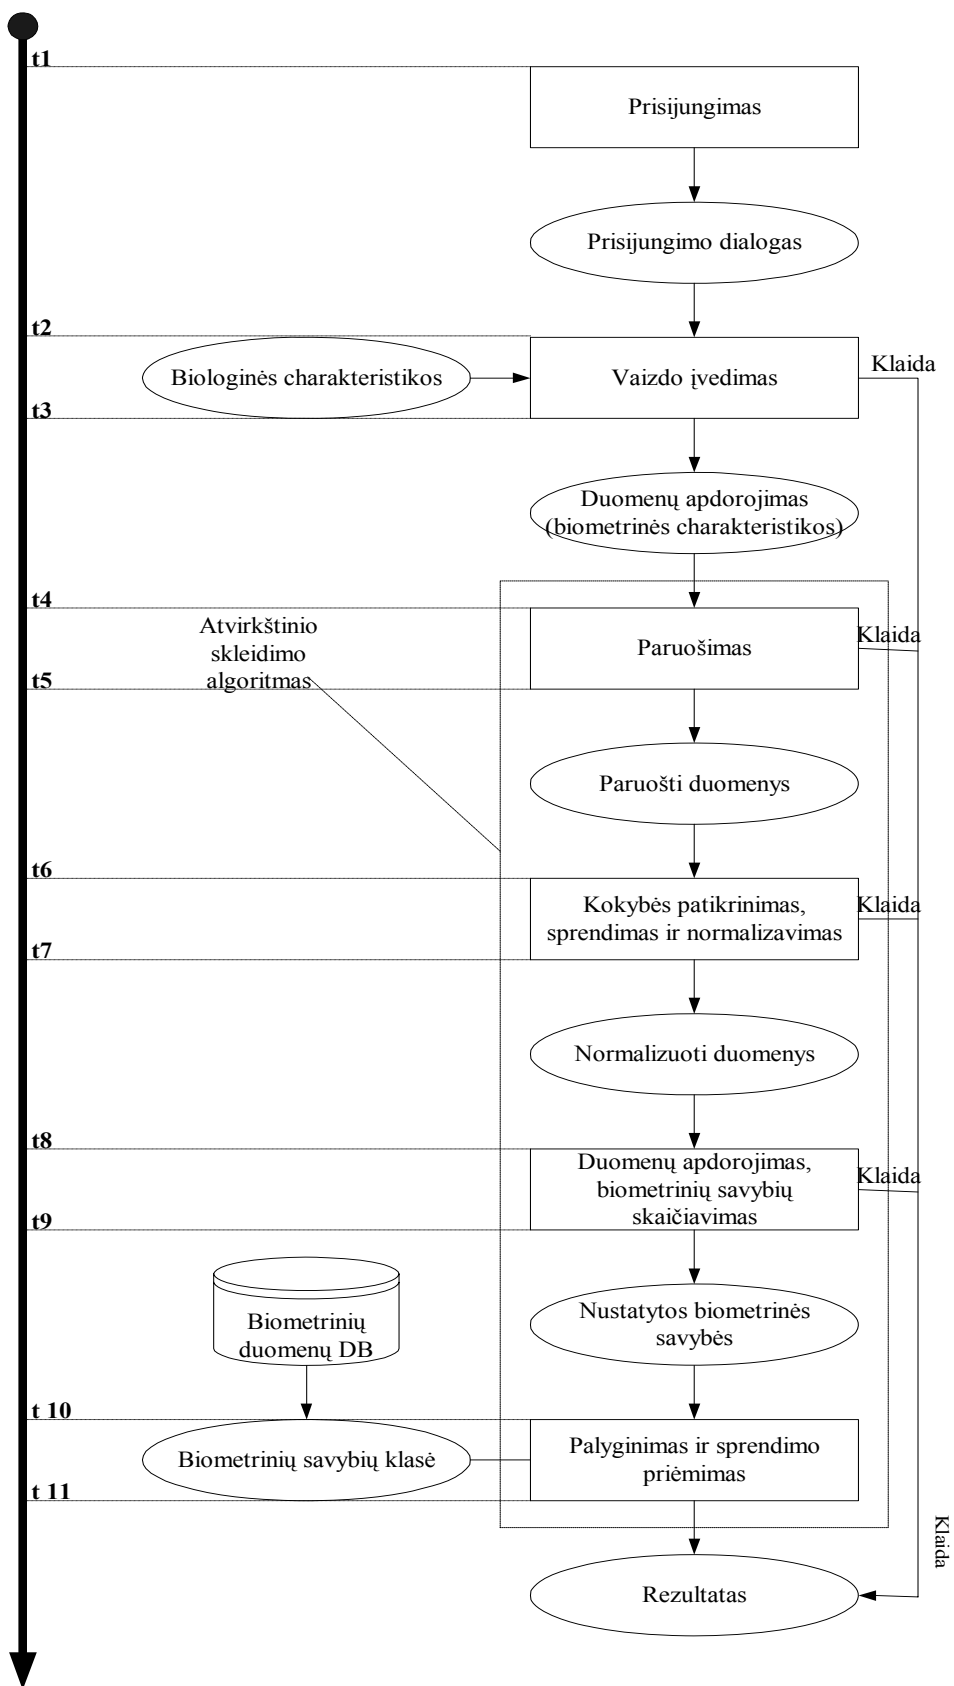
Programos pakartotinio panaudojimo reikalavimai. Pakartotiniuose panaudojimuose turi būti atsižvelgta į anksčiau padarytas klaidas bei praneštus atsiliepimus iš vartotojo pusės, klaidų pakartojamas ateityje negali būti leistinas.

Taikomųjų programų suderinamumas – programos turi atitikti Windows šeimos techninę bei programinę platformą. Už taikomųjų programų suderinamumą atsakingas – sisteminis programuotojas.

GUI – grafinė vartotojo sąsaja. Visas vartotojo grafinės sąsajos realizavimas turi būti atliktas meniu, langų bei mygtukų pagalba. Meniu punktai turi būti labai konkretūs ir turėti hierarchinę duomenų atvaizdavimo struktūrą. Pagrindiniame meniu esantys mygtukai skirti naudojimui palengvinti. Formose esantys mygtukai palengvina vartotojo darbą, suteikia vaizdumo ir susieja kelias formas.

CLI – komandinės eilutės sąsaja: per komandinės eilutės sąsają išvedami sisteminiai pranešimai bei palaikomas dialogas su vartotoju.

5.3. Projektuojamos sistemos architektūra



18 pav. Programos prototipinis modelis. Vaizdų ir veidų atpažinimo procesas

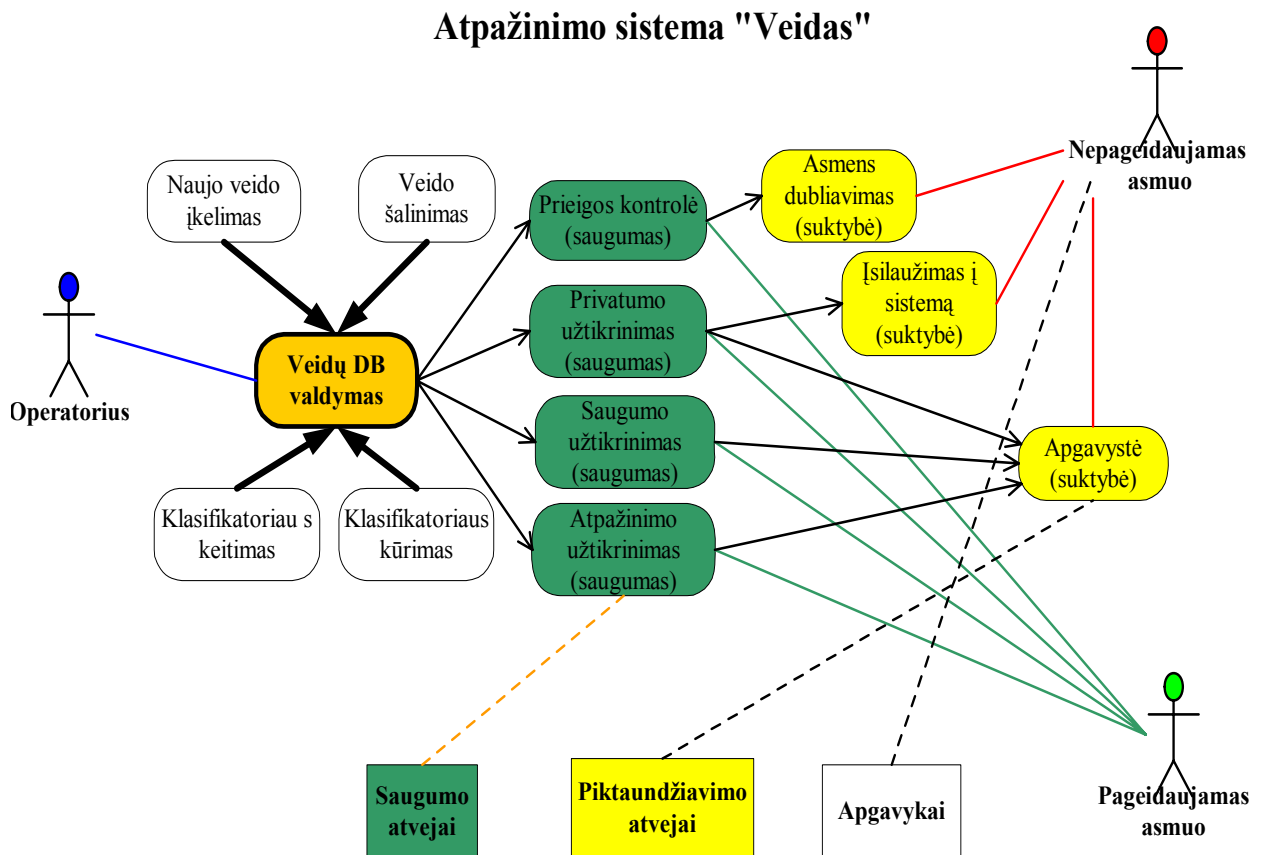
18 pav. iliustruoja siūloma prototipinį modelį veidams atpažinti. Šis modelis taip pat gali būti pritaikytas ir vaizdams atpažinti.

Modelį sudaro 4 moduliai:

- P-modulis: paruošimas;
- K- modulis: kokybės patikrinimas (normalizavimas);
- S – modulis: biometrinio parašo apskaičiavimas, naudojant požymių išskyrimo metodą (signalų apdorojimas, biometrinių savybių skaičiavimas);
- D – modulis: patikrinimas ir sprendimas, naudojant klasifikavimo metodą.

P – modulyje numatoma apdoroti biometrinė informacija, išskiriant per RGB fitravimą veido arba vaizdo požymius. Po to informacija perduodama K – moduliui. Šis modulis skirtas kokybei patikrinti ir atlieka normalizavimą taip, kad visa biometrinė informacija taptų panašaus formato. Šiame modulyje yra sudaromi požymių vektoriai. Jeigu kokybės patikrinimas praėjo gerai, normalizuoto vaizdo informacija perduodama S—moduliui, kur iš biometrinių požymių sudaromas „parašas“. Taip pat reikia paminėti, kad dėl duomenų saugos, iš parašo negali būti vėl ištraukti biometriniai požymiai veidui rekonstruoti. Klasifikuoti požymiai matricos pavidalu bus įrašyti į biometrinių duomenų DB. Požymių matricos bus nukreipiamos į DNT įėjimus, DNT bus apmokytas pagal atvirkštinio skleidimo procedūrą. DNT išėjimuose gausime vaizdo požymių klasę. Pagal požymių klasę galėsime nusakyti objekto savininką.

5.4. Sistemos panaudojimo atvejų diagrama (USE CASE)



19 pav. Programos prototipinis modelis. Vaizdų ir veidų atpažinimo procesas

Nagrinėjant kuriamos sistemos panaudojimo atvejus buvo išskirta sistemos panaudojimo sritis. Sistema „Veidas“ gali būti naudojama tuose atvejuose, kur yra reikalingas asmens identifikavimas kažkokiai tai prieigos funkcijai užtikrinti. Identifikatorius šiuo atveju yra žmogaus veidas, pagal kurį sistema turi suteikti tam tikras teises veido savininkui.

19 pav. iliustruoja esminius skirtumus tarp normalių panaudojimo atvejų, saugumo atvejų ir sukybės atvejų. Normaliu veikimo būdu programoje „Veidas“ galima įkelti naują veidą į duomenų bazę, pašalinti veidą iš jos, sukurti veidų DB klasifikatorių, keisti veidų DB klasifikatorių. Šios visos funkcijos padeda valdyti veidų DB, užtikrinant pageidaujama asmeniui prieigos kontrolę, privatumo užtikrinimą, saugumo užtikrinimą ir atpažinimo užtikrinimą. Keturių saugumo atvejų rezultatai (prieigos kontrolė, privatumo užtikrinimas, saugumo užtikrinimas, atpažinimo užtikrinimas) kelia reikalavimus visai „Veidas“ sistemai. Atsižvelgiant į šiuos reikalavimus sistema turi būti taisoma ir modifikuojama.

Sukybių atvejais sistema yra pažeidžiama. Nepageidaujamas asmuo gali pasistengti pakartoti pageidaujamo asmens veido charakteristikas (akiniai, barzda, ūsai). Tokiems atvejams sistema turi būti maksimaliai atspari.

5.5. Atvirkštinio skleidimo algoritmo realizacija

Šioje dalyje mes apžvelgsime neuroninio tinklo apmokymo algoritma naudojant atvirkštinio skleidimo algoritma, ryšium su tuo aprašyta klasių biblioteka su C++.

Iš įvairių dirbtinių neuroninių tinklų (DNT) struktūrų, viena žinomiausių yra DNT struktūra – daugiasluoksnė struktūra, kurioje kiekvienas laisvojo sluoksnio neuronų surištas su prieš tai esančio sluoksnio neuronų aksomais arba, pirmo sluoksnio atveju, su visais DNT įėjimais. Tokie DNT vadinami visiškai surištais. Kai tinkle tik vienas sluoksnis, tai jo apmokymo algoritmas su mokytoju yra akivaizdus, nes vienintelio sluoksnio teisingos neuronų išeities būsenos jau iš anksto yra aiškios, ir sinaptinių ryšių derinimas vyksta ta kryptimi, kuri labiausiai minimizuos klaidą tinklo išėjime. Šiuo principu sudaromas, pavyzdžiui, vienasluoksnio perceptrono apmokymo algoritmas [36]. Daugiasluoksniuose tinkluose optimalios neuronų išėjimo reikšmės nėra žinomos, dviejų arba daugiau sluoksnių perceptronų jau neįmanoma apmokyti, vadovaujantis tik klaidų dydžiais DNT išėjime. Vienas šios problemos sprendimo variantų – išėjimo signalų rinkinių kūrimas, signalai atitinka įėjimo signalus kiekviename DNT sluoksnyje, kas, savaime suprantama, yra daug darbo reikalaujanti ir ne visada įvykdoma operacija. Antrasis variantas – sinapsų svorinių koeficientų dinaminis paderinimas, kurio metu išrenkami patys silpniausi ryšiai, kurie šiek tiek kinta į vieną ar kitą pusę; pasilieka tik tie pakeitimai, kurie sukėlė klaidos sumažinimą viso tinklo išėjime. Akivaizdu, kad šiam „bandymo“ metodui, nepaisant susidariusio išpūdžio, kad tai paprasta, būtini išsamūs skaičiavimai. Trečiasis, labiausiai priimtinas variantas, – klaidos signalų skleidimas nuo DNT išėjimų iki DNT įėjimų. Skleidimas vyksta atvirkštine kryptimi tiesioginiam signalų skleidimui įprasto darbo metu. Šis DNT apmokymo algoritmas vadinamas atvirkštinio skleidimo procedūra. Būtent jį ir nagrinėsime šioje dalyje.

Pagal mažiausių kvadratų metodą, minimizuojantis DNT funkcijos klaidos dydis yra šis:

$$E(w) = \frac{1}{2} \sum_{j,p} (y_{j,p}^{(N)} - d_{j,p})^2 \quad (1),$$

kur $y_{j,p}^{(N)}$ – reali neurono j išėjimo būsena neuroniniame tinkle išėjimo sluoksnyje N , paduodant p -ąjį vaizdą į tinklo įėjimus; $d_{j,p}$ – ideali (norima) šio neurono išėjimo būsena.

Sumuojama visuose išėjimo sluoksnio neuronuose ir visuose tinklu apdorojamuose vaizduose. Minimizuojama gradientinio nuleidimo metodu, o tai reiškia svorinių koeficientų paderinimą šiuo būdu:

$$\Delta w_{ij}^{(n)} = -\eta \cdot \frac{\partial E}{\partial w_{ij}} \quad (2)$$

čia w_{ij} – sinaptinio ryšio svorinis koeficientas, jungiantis sluoksnio $n-1$ i -ąjį neuroną su neuroninio sluoksnio n j -uoju neuronu, η – apmokymo greičio koeficientas, $0 < \eta < 1$. Kaip pateikta [24],

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{ds_j} \cdot \frac{\partial s_j}{\partial w_{ij}}$$

Čia po y_j reikšme, kaip ir anksčiau, mes numanome neurono j išėjimą, o po s_j reikšme – jo įėjimo signalų svorinę sumą, t. y. aktyvavimo funkcijos argumentas. Kadangi daugiklis dy_j/ds_j yra šios funkcijos išvestinė pagal jos argumentą, tai reiškia, kad aktyvavimo funkcijos išvestinė turi būti apibrėžiama visoje abscisės ašyje. Todėl ir pavienio šoktelėjimo funkcija, ir kitos aktyvavimo nevienarūšės funkcijos netinka apžvelgiant DNT. Jose taikomos tokios sklandžios funkcijos, kaip hiperbolinis tangentas arba klasinė sigmoidė su eksponente. Hiperbolinio tangento atveju:

$$\frac{dy}{ds} = 1 - s^2 \quad (4)$$

Trečias daugiklis $\partial s_j / \partial w_{ij}$, akivaizdu, kad yra lygus neuronų išėjimui prieš tai esančiame sluoksnyje $y_i^{(n-1)}$. Pirmojo daugiklio (3) formulėje jis lengvai skaidomas šiuo būdu [24]:

$$\frac{\partial E}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot \frac{\partial s_k}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \cdot \frac{dy_k}{ds_k} \cdot w_{jk}^{(n+1)} \quad (5)$$

Čia sumavimas pagal k reikšmę atliekamas tarp sluoksnio $n+1$ neuronų. Įvedant naują kintamąjį:

$$\delta_j^{(n)} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{ds_j} \quad (6)$$

gauname sluoksnio n rekursyvinę formulę reikšmių skaičiavimui $\delta_j^{(n)}$ iš reikšmių $\delta_k^{(n+1)}$ vyresnio sluoksnio $n+1$.

$$\delta_j^{(n)} = \left[\sum_k \delta_k^{(n+1)} \cdot w_{jk}^{(n+1)} \right] \cdot \frac{dy_j}{ds_j} \quad (7)$$

Išėjimo sluoksniui:

$$\delta_l^{(N)} = (y_l^{(N)} - d_l) \cdot \frac{dy_l}{ds_l} \quad (8)$$

Dabar galima užrašyti (2) formulę atskleistame pavidale:

$$\Delta w_{ij}^{(n)} = -\eta \cdot \delta_j^{(n)} \cdot y_i^{(n-1)} \quad (9)$$

Kartais suteikiant svorių korekcijos procesui truputį inertiškumo, sulyginančio ryškius šoktelėjimus, veikiančius pagal tikslinę funkciją, formulė (9) papildoma svorio pakeitimo reikšme pirmesnėje iteracijoje:

$$\Delta w_{ij}^{(n)}(t) = -\eta \cdot (\mu \cdot \Delta w_{ij}^{(n)}(t-1) + (1-\mu) \cdot \delta_j^{(n)} \cdot y_i^{(n-1)}) \quad (10),$$

kur μ – inertiškumo koeficientas, t – esančios iteracijos numeris.

Tokiu būdu, DNT apmokymo algoritmas panaudojant atvirkštinio sklaidimo algoritmą sudaromas taip:

1. Pateikti į tinklo įėjimus vieną iš galimų vaizdų ir apskaičiuoti NT įprasto funkcionavimo metu sklaidimo signalus, kai signalai sklinda nuo įėjimų prie išėjimų. Reikėtų paminėti, kad

$$s_j^{(n)} = \sum_{i=0}^M y_i^{(n-1)} \cdot w_{ij}^{(n)} \quad (11),$$

kur M – neuronų skaičius sluoksnyje $n-1$, įskaitant ir neuroną su pastovia išėjimo būseną, kuri užduoda poslinkį $+1$; $y_i^{(n-1)} = x_{ij}^{(n)}$ – sluoksniu n neurono j i-asis įėjimas.

$$y_j^{(n)} = f(s_j^{(n)}), \text{ kur } f() \text{ – sigmoidė} \quad (12)$$

$$y_q^{(0)} = I_q, \quad (13),$$

kur I_q – q -įėjimo vaizdo vektoro q -oji komponentė.

2. Apskaičiuoti $\delta^{(N)}$ išėjimo sluoksniui pagal formulę (8).

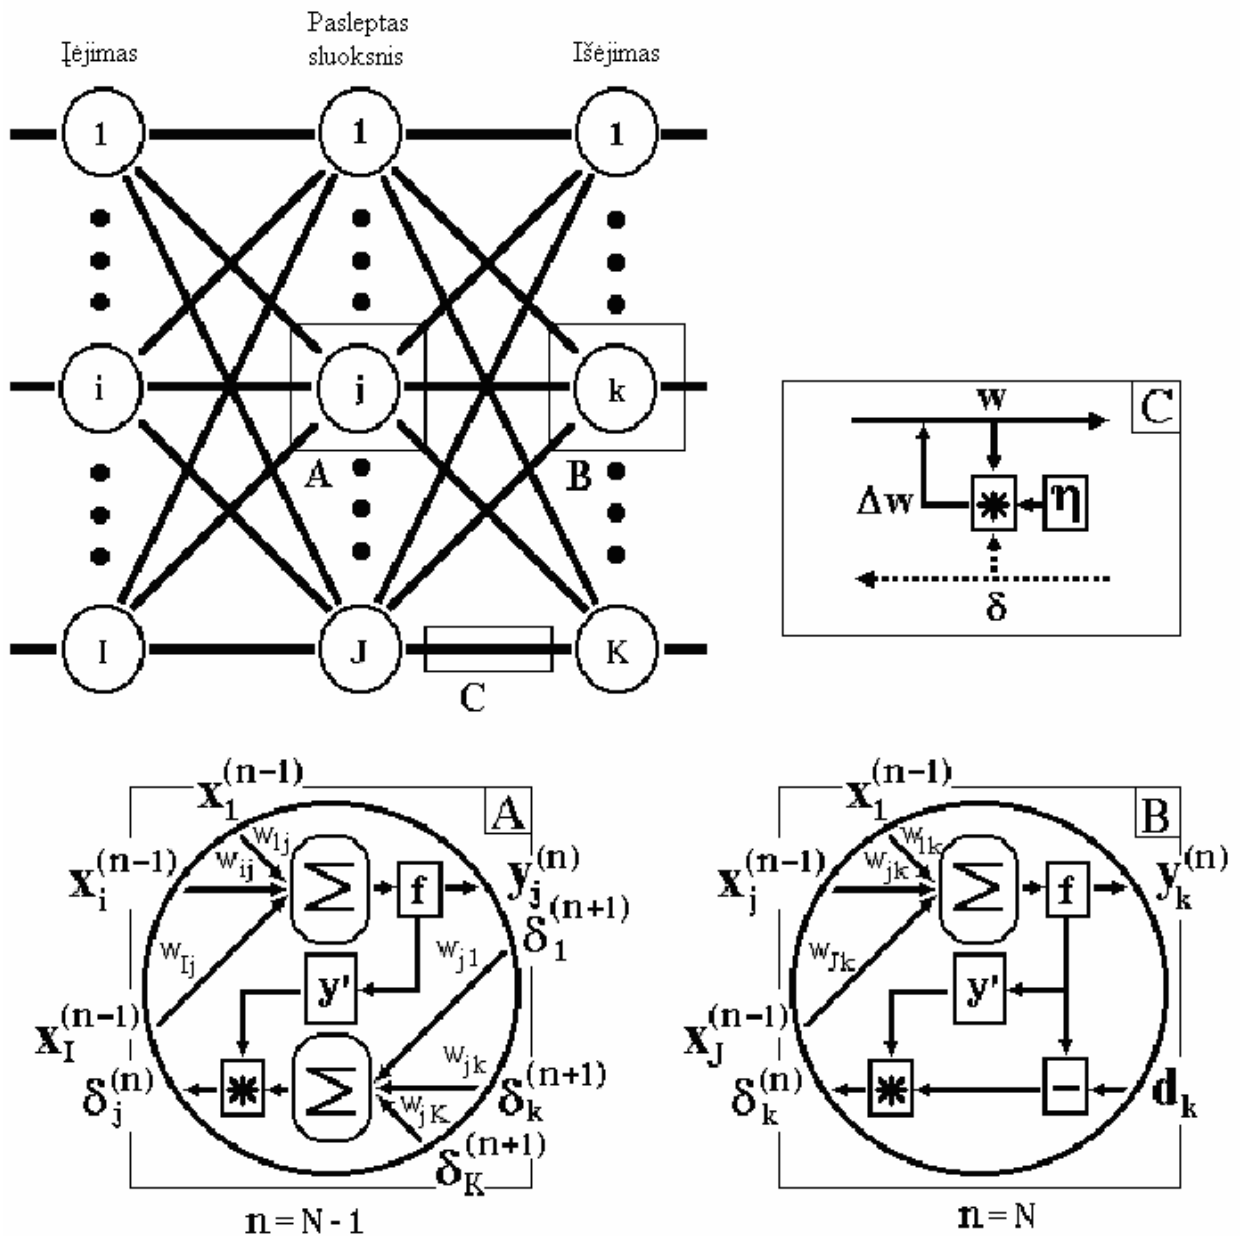
Apskaičiuoti pagal formulę (9) arba (10) svorių pokyčius $\Delta w^{(N)}$ sluoksnyje N .

3. Apskaičiuoti pagal formules (7) ir (9) (arba (7) ir (10)) atitinkamai $\delta^{(n)}$ ir $\Delta w^{(n)}$ visiems likusiems sluoksniams, $n=N-1, \dots, 1$.

4. Pakoreguoti visus svorius neuroniniame tinkle.

$$w_{ij}^{(n)}(t) = w_{ij}^{(n)}(t-1) + \Delta w_{ij}^{(n)}(t) \quad (14)$$

5. Jeigu klaidų santykis gana didelis, pereiti prie 1 žingsnio. Priešingu atveju – pabaiga. Jei klaidų santykis minimalus – šiuo atveju darbą baigiame.



20 pav. Signalų diagrama tinkle atliekant apmokymą pagal atvirkštinio sklaidymo algoritmą [34]

Pirmame žingsnyje tinklui atsitiktinai pateikiami visi treniravimo vaizdai, tam, kad tinklas nepamirštų senų išsiminant naujus vaizdus. Algoritmą iliustruoja 20 pav.

Iš formulės (9) seka: kai $y_i^{(n-1)}$ išėjimo reikšmė siekia nulio, apmokymo efektyvumas ryškiai mažėja. Esant dvejetainiems vektoriams vidutiniškai pusė svorinių koeficientų nebus koreguojama [28], todėl neuronų išėjimo galimų reikšmių sritis $[0,1]$ geriausiai paslinkti iki $[-0.5,+0.5]$, to galima pasiekti paprastai modifikuojant logines funkcijas. Pavyzdžiui, sigmoidė su eksponente galima paversti į tokią formulę:

$$f(x) = -0.5 + \frac{1}{1 + e^{-\alpha x}} \quad (15)$$

Dabar aptarsime NT talpumo klausimą, t. y. pateikiamą vaizdų kiekį į tinklo įėjimus, kurių tinklas turės išmokti atpažinti. Tinklams, turintiems daugiau negu du sluoksnius, sluoksnis lieka atidarytu. Kaip pateikta [28], DNT su dviem sluoksniais, t. y. su vienu išėjimo ir vienu paslėptu sluoksniu, deterministinis tinklo talpumas C_d įvertinamas sekančiai:

$$N_w/N_y < C_d < N_w/N_y \cdot \log(N_w/N_y) \quad (16)$$

kur N_w – priderinamų svorių skaičius, N_y – neuronų skaičius išėjimo sluoksnyje.

Reikėtų pabrėžti, kad ši išraiška gauta įskaitant kai kuriuos apribojimus. Pirma, įėjimo N_x skaičius ir neuronų atvirame sluoksnyje N_h skaičius turi atitikti nelygybei $N_x + N_h > N_y$. Antra, $N_w/N_y > 1000$. Bet aukščiau pateiktas įvertinimas buvo atliekamas tinklams su neuroninio slenksčio aktyvavimo funkcija, o tinklų talpumas su lygiais aktyvavimo funkcijomis, pavyzdžiui, pagal formulę (15), yra paprastai didesnis [4]. Be to, reikšmė „deterministinis“ reiškia, kad talpumo gautas įvertinimas tinka absoliučiai visiems įėjimo vaizdams, kurie gali būti patekti į N_x įėjimus. Iš tikrųjų įėjimo sluoksnių paskirstymas turi tam tikrą reguliarumą, kas leidžia DNT atlikti apibendrinimą ir, tokiu būdu, padidinti realųjį talpumą. Vaizdų paskirstymas, bendru atveju, dvigubai viršija deterministinį talpumą.

Toliau kalbant apie DNT talpumą, logiškai būtų apžvelgti klausimą dėl DNT reikalaujamos galios tinklo išėjimo sluoksnyje, kuris atlieka galutinį vaizdų klasifikavimą. Problema yra ta, kad skaidant daugelį įėjimo vaizdų, pavyzdžiui, dviem klasėms reikia tik vieno išėjimo. Tuo pačiu metu kiekvienas loginis lygmuo – „1“ ir „0“ – žymės atskirą klasę. Dviejuose išėjimuose galima užkoduoti jau 4 klases ir taip toliau. Bet tinklo darbo rezultatai, organizuoti tokiu būdu nėra labai patikimi. Klasifikavimo patikimumo didinimui reikėtų įvesti perteklišumą, t. y., išskiriant kiekvienai iš klasių po vieną neuroną išėjimo sluoksnyje arba, kas dar būtų geriau, kelis neuronus, kiekvienas iš kurių apmokomas vaizdo priklausomybei tam tikroje klasėje pagal savo tikimumo lygį nustatyti, pavyzdžiui, aukšta, vidutinė ir žema. Tokie DNT leidžia atlikti įėjimo vaizdų klasifikavimą, kurie apjungti į neryškias aibes. Ši savybė priartina NT prie realaus gyvenimo sąlygų.

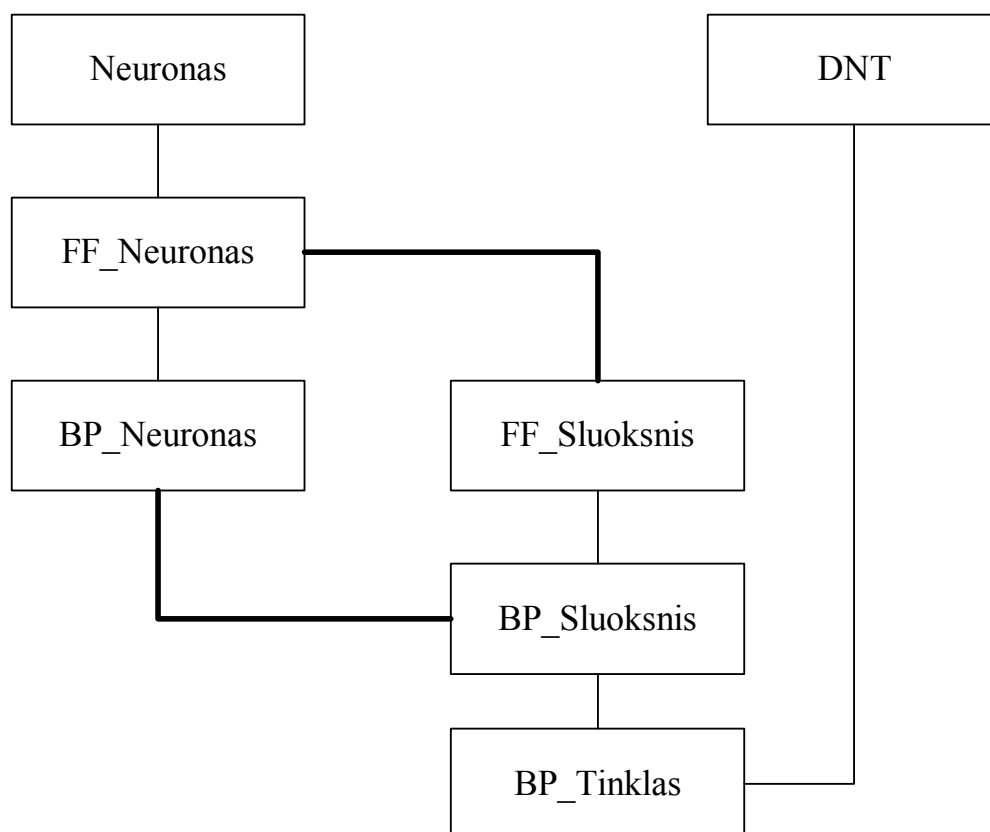
Dabar mes galime pereiti tiesiogiai prie DNT programavimo. Reikėtų pažymėti, kad užsienietiškos publikacijose labai retai apžvelgiama programinė DNT realizacija palyginus su gausybe darbų apie dirbtinius neuroninius tinklus. Galbūt tai atsitinka dėl to, kad užsienyje į programavimą yra požiūris kaip į amatą negu kaip į mokslą.

Kaip mes galime pastebėti iš aukščiau aprašytų formulių, aprašančių DNT funkcionavimo bei apmokymo algoritmą, visas šis procesas gali būti aprašytas, o vėliau ir užprogramuotas naudojant matricos operacijas, kas padaryta, pavyzdžiui darbe [27]. Toks būdas greičiausiai užtikrins greitesni ir kompaktiškesni DNT realizavimą, negu tinklo

realizavimas panaudojant objektiškai - orientuoto (OO) programavimo koncepcijas. Bet pastaruoju metu vyrauja būtent OO realizavimo būdas, net gana dažnai tam kuriamos specialios kalbos DNT programavimui [35]. Nors universalios OO kalbos, pavyzdžiui C++ ir Java, buvo sukurtos kaip tik tam, kad visos kitos OO kalbos nebūtų kuriamos.

Bet visgi, DNT programavimas naudojant OO kalbas turi savo privalumus. Pirma, sukuriama lanksti, laisvai priderinama DNT modelių hierarchija. Antra, toks realizavimas labiausiai skaidrus programuotojui, ir leidžia sukurti DNT net nemokantiems programuoti. Trečia, programavimo abstrakcijos lygis, kurį turi OO kalbos, ateityje, greičiausiai augs, ir DNT realizavimas panaudojus OO leis išplėsti jų galimybes. Taigi, remiantis aukščiau pateiktais argumentais, buvo realizuota klasių bei programų biblioteka, realizuojanti pilnai surištus DNT su atvirkštinio skeidimo algoritmu. naudojant OO realizavimo koncepcijas. Toliau bus išvardinti pagrindiniai realizavimo momentai.

Visų pirma reikėtų pabrėžti, kad nors biblioteka buvo realizuota ir naudojama vaizdų atpažinimo tikslui, ją būtų galima taip pat panaudoti ir kitose DNT srityse. Klasių hierarchija pateita 21 pav.



21 pav. Bibliotekos klasių hierarchija atvirkštinio skeidimo procedūroje (paprasta linija – paveldėjimas, paryškinta linija – įėjimas)

Šeši pagrindiniai parametrai, charakterizuojantys DNT darbą, iškelti į globalinį lygmenį, kas palengvina operacijų atlikimą su jais: *Neuronas*, *FF_Neuronas*, *BP_Neuronas*, *FF_Sluoksnis*, *BP_Sluoksnis*, *BP_Tinklas*. Parametras *SigmoideTipas* nusako aktyvavimo funkcijos rūšį. Metode *FF_Neuronas::Sigmoide* išvardintos kai kurios jo reikšmės, kurių makroapibrėžimai atlikti antraštės faile. Punktai *G_LIMIT* ir *SLENKSTIS* pateikiami apibendrinančiai, bet negali būti panaudoti atvirkštinio skleidimo algoritme, nes atitinkantys jiems aktyvavimo funkcijos turi išvestines su tam tikrais taškais. Tai atsispindi išvestinės skaičiavimo metode *FF_Neuronas::Sigmoide*, iš kurio šie du atvejai pašalinti. Kintamasis *Sigmoide_A* užduoda sigmoidės *ORIGINAL* iš (15) formulės parametą α . *ParmMiu* ir *ParmNiu* – atitinkamai reikšmių μ ir η parametrai paimti iš formulės (10). Parametras *Sigma_d* emuliuoja klaidų sandarumą, kuris sukuria papildomus vaizdus apmokant DNT. Tai leidžia generuoti iš „švarių“ įėjimo vaizdų neribotą klaidingų vaizdų kiekį. Tai atsitinka todėl, kad norint nustatyti optimalias svorinių koeficientų reikšmes, DNT laisvųjų lygmenų skaičius - N_w turi būti mažesnis negu uždedamų apribojimų skaičius – $N_y \cdot N_p$, kur N_p – vaizdų kiekis, pateikiamas DNT apmokymo metu. Faktiškai, parametras *Sigma_d* lygus įėjimo skaičiui, kurie bus invertuojami dvejetainio vaizdo atveju. Jeigu *Sigma_d* = 0, tai klaidos neįvedame.

Metodai *ATSITIKTINIS* leidžia prieš pradedant apmokymą atsitiktinai nustatyti svorinius koeficientus diapazone [-nuo,+iki]. Metodai *SKLEIDIMAS* atlieka skaičiavimus pagal formules (11) ir (12). Metodas *BP_Tinklas::Klaida* apskaičiuoja δ dydžius remiantis masyvu, kurį sudaro teisingos (norimos) DNT išėjimo reikšmės. Metodas *BP_Tinklas::Mokymas* apskaičiuoja svorių pasikeitimus pagal formulę (10), metodai *Update* atnaujina svorinius koeficientus. Metodas *BP_Tinklas::Ciklas* apjungia savyje vieno apmokymo ciklo visas procedūras, įskaitant įėjimo signalų nustatymą *BP_Tinklas::Iejimai* Metodas *BP_Sluoksnis::Rodyti* leidžia kontroliuoti procesų eigą DNT, bet jų realizavimas neturi principinės reikšmės, ir paprastos procedūros iš bibliotekos gali būti perrašytos, pavyzdžiui, grafiniame režimui. Tą galima pateisinti tuo, kad abecelės-skaitmeniniu būdu patalpinti informaciją ekrane apie palyginus didelį DNT jau nepavyksta.

Tinklai gali būti konstruojami naudojant *BP_Tinklas (unsigned)* konstruktorių, po to DNT reikia užpildyti anksčiau sudarytais sluoksniais, panaudojus tam metodą *BP_Tinklas::Sluoksnis*, arba su konstruktoriumi *BP_Tinklas (unsigned, unsigned,...)*. Paskutiniu atveju sluoksnių konstruktoriai iškviečiami automatiškai. Sinoptinių ryšių nustatymui tarp sluoksnių iškviečiamas metodas *BP_Tinklas::Sujungtas*.

Po tinklo apmokymo, tinklo esančią būseną galima įrašyti į failą (metodas *BP_Tinklas::Savee*), o po to atstatyti, naudojant metodą *BP_Tinklas::Load*, kuris taikomas ką tik sukonstruotam tinklui *::Load (void)*.

Jeigu vaizdų bylose laisvas plėtinys, tai įėjimo ir išėjimo vektoriai užrašomi pakaitomis: eilutė su įėjimo vektoriumi, eilutė su jam atitinkamu išėjimo vektoriumi ir t. t. Kiekvienas vektorius yra tikrojo skaičiaus seka diapazone $[-0.5,+0.5]$, kuri atskirta laisvų tarpų skaičiumi. Jeigu failas turi plėtinį IMG, tai įėjimo vektorius pateikiamas matricos pavidale dydžiu $dy \times dx$ (dydžiai dx ir dy turi būti prieš tai nustatyti metodu *FF_Sluoksnis::Rodyti* iki nulinio sluoksnio), be to simbolis „x“ atitinka lygį 0,5, o taškas – atitinka lygį $-0,5$, tai yra IMG failai, kurie šioje pateiktoje bibliotekos versijoje yra binariniai. Kai tinklas funkcionuoja normaliu režimu, o nėra apmokamas, eilutės su išėjimo vektoriais gali būti tuščios. Metodas *DNT::Mokymas* užduoda perėjimų skaičių palyginant su vaizdų byla, kas kartu su klaidos papildymu leidžia gauti rinkinį iš keliolikos dešimčių ir net iš šimto tūkstančių skirtingų vaizdų.

Reikėtų būtinai pabrėžti tokį aspektą, kad nagrinėjamoje DNT klasių bibliotekoje nėra priderinamo slenksčio realizavimo kiekvienam iš neuronų. Tinklas, trumpai tariant, gali veikti ir be slenksčio, bet dėl to sulėtėja apmokymo procesas [44]. Paprastas, nors ir neefektyviausias būdas yra tas, kad būtų galima įvesti kiekvieno sluoksnio neuronams reguliuojamąjį poslinkį, kas buvo padaryta programiškai. Į klasę *FF_Neuronas* buvo įtrauktas metodas *Poslinkis*, kuris priverstinai nustatytų neurono išėjimą į prisotinimo būseną $ax = 0,5$, iššaukiant šį metodą kokiam nors vienam neuronui, pavyzdžiui, paskutinio sluoksnio neuronui, kur funkcijos pabaiga nustatoma pagal *FF_Sluoksnis::Skleidimas*. Žinoma, kad konstrukcijos eigoje kiekvieną iš DNT sluoksnių, išskyrus išėjimo sluoksnio, reikėtų papildyti vienu papildomu neuronu. Šis neuronas, praktiškai negali turėti nei sinapsų, nei svorių pakeitimo masyvo ir nekviesti metodo *Skleidimas* metodo *FF_Sluoksnis::Skleidimas* viduje.

Apžvelgtas aukščiau ir realizuotas programoje algoritmas yra atvirkštinės skleidimo procedūros klasinis variantas, bet taip pat žinomos jo kitos modifikacijos. Pakeitimai liečiami kaip skaičiavimų metodų [17][9], taip ir DNT konfigūravimo [27][20]. Būtent [27] posluoksninis tinklo organizavimas pakeistas į magistralinį, kai visi neuronai turi tam tikrą numerį ir kiekvienas surištas su prieš tai esančiais.

DNT realizuotas programiškai. Šis tinklas buvo apmokytas atpažinti dešimt vaizdų (testavime tai buvo raidės), vaizdai buvo pateikti matricos 6×5 taškų pavidale per 500 apmokymo ciklą, kuriuos kompiuteris Pentium 3 800 MHz, Ram 196 atliko per kelias sekundes. Apmokytas tinklas sėkmingai atpažino vaizdus, kurie buvo užtrikšminti stipriau, negu tie, kurie dalyvavo apmokant tinklą.

Programa buvo sukompiliuota *Borland C++ 6.0* aplinkoje.

Pasiūlyta klasių biblioteka leis sukurti tinklus, kurie galės spręsti labai platų uždavinių spektrą, tokius kaip: ekspertinės sistemos sudarymas, informacijos suspaudimas ir daugelį

kitų. Šių uždavinių išėties sąlygos gali būti sugrupuotos pagal porinius, įėjimo ir išėjimo duomenų rinkinius.

5.6. Programinių modulių ir objektų aprašymas.

Atliekant projektą mes pasinaudojome kai kuriomis komercinėmis programinės įrangos bibliotekomis, kurios mums leido pasinaudoti tam tikromis funkcijomis apdorojant vaizdus. *Common Vision Blox (CVB)* bibliotekos panaudojimas šiame darbe leido mums tinkamai realizuoti veido nustatymo funkcionalumą. *CVB* turi vaizdų nustatymo biblioteka, jos pavadinimas yra *CVB Manto*. Ši biblioteka remiasi daugialypės skiriamosios gebos filtru skirta požymiams išskirti ir transformuoti.

Veidų atpažinimas yra vaizdų atpažinimo sritis. Vaizdų atpažinimas gali būti apibudintas kaip vaizdų bei signalų atpažinimas ir įvertinimas. Vaizdų atpažinimo taikymas apima automatinį netrūkstančių signalų klasifikavimą kaip diskrečiosiose klasėse taip ir kompleksinėje analizėje. Vaizdų atpažinimo specifika remiasi dirbtiniu intelektu, kuris, savo ruožtu, yra panašus į žmoniškąjį suvokimą.

Vaizdų atpažinimo eigą galima pateikti toki būdu: klasifikavimas yra šiuo atveju pagrindinė veidų atpažinimo dalis, kuri remiasi atlikta mokymo eiga. Per mokymo eigą išskiriami tam tikri požymių klasių duomenys. Požymiai vaizduose gali būti įvairūs, pvz., pilki bei spalvoti vaizdai, veido rakursas, gradientas, tekstūra arba pikselių forma. Klasifikavime panaudotų požymių kiekis atitinka požymių srities apimtį. Jeigu mes atidžiau nagrinėsime vaizdų požymius, priklausančius vienai bendrai klasei, tai galėsime greitai pastebėti, kad jie priklauso vienas kitai, kas galime pavaizduoti grafiškai.

Skirtumas tarp veido nustatymo ir veido atpažinimo:

- Veido nustatymas

Šiame etape programa turi nuspręsti, ar grafinėje byloje yra veidas, ar jo nėra. Pateikus vaizdą, specialiai apmokytas dvejetainio tipo klasifikatorius turi nuspręsti, ar šis vaizdas turi veidą arba jo neturi. Jeigu veidas yra surastas, turi būti pateikta veido sritis. Šis žingsnis yra savo ruožtu pradinė atrama tolimesniam asmens atpažinimui.

- Veido atpažinimas

Šiame žingsnyje atliekamas asmens identifikacija pagal jo nustatytą veidą. Klasifikatorius pateiktam vaizdai priskiria tam tikrą vardą. Toliau duomenys pateikiami neuroniniam tinklui, kuris atlieka veidų paiešką.

Veidų nustatymo modulis realizuotas remiantis *CVB Manto* modulių, o būtent dinaminė biblioteka (*DLL*). Šio modulio praktinė realizacija galėjo būti atlikta panaudojant įvairias OO tipo programavimo kalbas. Veidų nustatymo bei atpažinimo modulių realizacijai

buvo atlikta su C++ kalba. Tam buvo pasirinkta *Microsoft Visual Studio 2003* programinė aplinka. Veidų nustatymas ir atpažinimas yra tarpusavyje susieti. Išskirti veido bruožai yra transformuojami į matematinius skaičius, toliau šie skaičiai yra pateikiami atpažinimo moduliui. Turint veidų atpažinimo modulio dinamines bibliotekas ir siekiant užtikrinti programinio kodo tapatumą, buvo nutarta anglišku pavadinimų dinaminiuose bibliotekose nekeisti. Programa susideda iš 2 programinių objektų:

- *Sample Image List (SIL)* (Vaizdų imties sąrašas)
- *Manto Classifer (MCF)* (Manto klasifikatorius)

Šie du objektai papildo vienas kitą savo metodais, kurie yra reikalingi atliekant vaizdų atpažinimą. SIL tipo bylose kaupiama visa informacija, kurią vėliau mes galėsime panaudoti klasifikavimo arba mokymo uždaviniams spręsti. Vaizdų sąrašo kūrimo principas yra paremtas šia funkcija:

```
CreateImageList ( int Width, int Height, int X, int Y, int Dimension, int MaxDAlpha, int MaxDX, int MaxDY, SIL& IL )
```

Šiuo atveju vaizdų imties sąrašas apibrėžia tam tikrą vaizdų sritį iš kurių turi būti išskirti tam tikri požymiai. Funkcijos parametrai perima tokias savybes kaip: ilgis, aukštis, dydis. Toliau, remiantis pateiktu vaizdu, SIL-objektas sudaro prielaidą vaizdų imčiai formuoti. Tai atsitinka dėl tam tikrų postūmių arba vaizdo sukimosi. Taip formuojant vaizdų imtį yra užtikrinamos įvairios vaizdo lokalizacijos.

MCF objektas atlieka klasifikatoriaus funkciją, sudaryta iš SIL reikšmės. Panaudojus *MCF* objektą galima nustatyti ir vaizdą pagal jo SIL reikšmę. Kai *MCF* objekte yra sukuriamas klasifikatorius, *MantoControlWorld* nustato daugialypės gebos filtrą požymiams išskirti.

```
CreateMCFFromImageList( SIL ImageList, PCHAR MantoControlWord, TMantoNotify Notify, void* NotifyData, TDecisionBoundary Boundary, MCF& M )
```

DecisionBoundary funkcija atskiria požymių klases. Kiekvienas iš požymių klasių yra klasifikuojamas atskirai.

Į *VeidasProcessing* klasę yra perduodami visi duomenys iš vartotojo sąsajos aplinkos. Tai įvyksta per kelius CString-masyvus.

```
VeidasProcessing ( CVeidasDlg* dlg, CString* csImageNames, CString* csClassFaces, CString*csClassPersons, int* iSampleX, int* iSampleY, int nCount )
```

Pirmame masyve *csImageNames {}* yra kaupiami visų vaizdų pavadinimai. Šie vaizdai toliau perduodami klasifikavimo masyvui *csClassFaces {}*. Šiame masyve randuosi klasifikatorius kiekvienam iš masyvo *csImageNames {}* kintamųjų. Klasifikatoriuje taip pat įrašyta informacija apie vaizdą, pvz., ar tai yra veidas arba ne. *csClassPersons {}* masyve yra nurodomas žmogaus vardas, kuris masyve *csClassFaces {}* priskirtas prieš skilties „Veidas“, kitaip būtų „Vaizdas“. Masyvuose *iSampleX {}* ir *iSampleY {}* yra saugomos kiekvieno vaizdo keturkampio veido koordinatės. Koordinatinių nulinė reikšmė yra kairiajame vaizdo pateikimo kampe. *nCount* kintamasis nurodo duomenų skaičių.

Po to, kai jau visi duomenys yra žinomi iš karto yra sukuriamas SIL klasifikatorius *CreateImageList ()* klasėje. Tam naudojamas nekintamas vaizdo keturkampis, kurio matmenys yra 160×192 pikselių bei *MaxDAlpha* kintamasis, kurio reikšmė yra lygi 10. Šis kintamasis nurodo SIL metodui *SetImageListSamplesPerImage ()* atvaizdų kiekį vienam pateiktam vaizdai. Tai reiškia, kad kiekvienam vaizdai yra sukuriami 10 skirtingų atvaizdų keičiant kampą +/-10 laipsnių.

VeidasProcessing () klasė sudaryta iš dviejų metodų – *TrainFaces ()* ir *TrainPersons ()*, kurie gali būti iškviešti paspaudus „Mokyti NT“ mygtuką. Pasirinkus opciją „Veidų atpažinimas“ galėsime iškviešti tik *TrainPersons ()* metodą. Mokymas vyksta abiejuose metoduose pagal tą patį principą. Iš pradžių atidaroma grafinė byla ir apdorojama pagal SIL klasifikatorių.

AddImageListItem (SIL IL, IMG Image, int x, int y, PCHAR ClassID)

Šis SIL metodas laukia klasifikavimo eilutės *ClassID* kaip parametro, kuris perduodamas arba iš *csClassFaces* arba iš *csClassPersons* masyvų. Jeigu visi vaizdai yra SIL formato, tai klasėje *CreateMCFFromImageList* sukuriamas *MCF* objektas.

Po sėkmingos mokymo proceso pabaigos gali būti atitinkamai suklasifikuotos kitos grafinės duomenų bylos. Tai viskas įvyksta per *VeidasProcessing ()* klasės metodus.

VaizduKlasifikavimas (MCF mcf, CString csImgName, char szClassID, CRect* aoi, double* qty)*

Šie metodai paruošia informaciją prieš tai sukurtam *MCF* klasifikatoriui ir vaizdo vardui. Šių metodai išėjimo informacija yra klasifikavimo kintamieji, atpažinta sritis (keturkampio sritis) ir kokybės atitikimas, arba koreliacija. *VaizduKlasifikavimas ()* metodas iškviečia *MCF* metodą.

```
MCSearch( MCF MC, IMG AImage, int Left, int Top, int Right,  
int Bottom, bool Vote, bool DotSensitivity,  
bool CreateResultImage, double& XPos, double&  
YPos, double& Quality, PCHAR ClassID, IMG&  
ResultImage )
```

5.7. Programinių modulių realizacijos problemos

Programinės įrangos „Veidas“ kūrimo metu iškilo kai kurios problemos. Nuo pat pradžios sunku buvo suderinti tarpusavyje kai kurias programas kintamuosius: vaizdo dydis, kiekis ir įvairovė. Taip pat reikia nustatyti optimalųjį parametą daugialypės gebos filtrui. Šiuo atveju padėjo kai kurios *Manto* bibliotekos iš *CVB* programinės aplinkos.

Toliau mes susidūrėme su kita problema. Testavimo metu, veidų atpažinimo modulis su įdiegtu veidų nustatymu moduliu pateikdavo blogesnius rezultatus, negu testuojant vien tik su veidų atpažinimo moduliu. Mūsų darbe mes susijome du modulius tarpusavyje, nes vienas kitą papildo. Net teoriškai kalbant apie tokią galimybę, sunku išivaizduoti, kaip tai viskas galėtų būti įvykdoma. Norėdami identifikuoti veidą tam tikroje grafinėje byloje, mes iš pradžių turime nustatyti visos grafinės bylos turinį. Gali atsitikti ir taip, kad šioje grafinėje byloje nėra jokio veido. Veidų nustatymo modulio kūrimo metu buvo nuspręsta apriboti veido paieškos sritį, nes šis modulis nustato ne vien tik veido buvimą, bet ir perduoda vaizdo koordinates (žr. *VaizduKlasifikavimas ()* metodo aprašymą). Nagrinėjant blogius programos rezultatus buvo nustatyta, kad veido nustatymo modulis perduodavo blogas koordinates veidų atpažinimo moduliui ir todėl kai kurie požymiai likdavo už paieškos srities. Tai galėjo atsitikti ir dėl netinkamo veido išsidėstymo arba jo rakurso. Kai kuriose nuotraukose matėsi tik pusė veido, kas labai klaidindavo programos darbą. Geresni rezultatai buvo pasiekti tik tada, kai pateikiami vaizdai buvo vienos rūšies, tai yra veidas visose nuotraukose buvo per centrą. Santykinis veido dydis visai nuotraukai buvo 1:3.

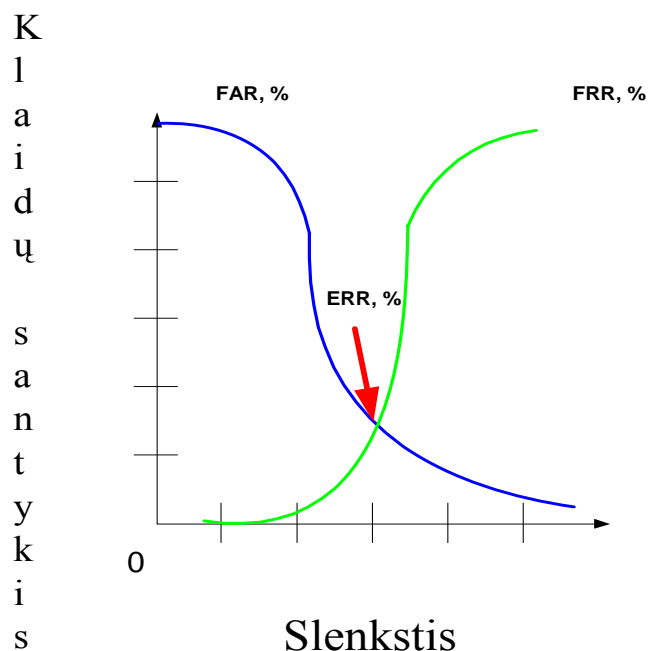
6. TESTAVIMAS

Atliekant testavimą buvo įvertintos biometrinės reikšmės ROC , FAR ir FRR , kurios nustato pateikiamo algoritmo efektyvumą vaizdams bei veidams apdoroti.

Biometrinio algoritmo panaudojimo rezultatai į skirtingus to pačio požymio priėmimus (pavyzdžiui, skirtingos akies rainelės nuotraukos) nėra 100% identiški, bet rezultatai nuolat yra šalia vienas kito. Todėl biometrinis algoritmas turi sugebėti atpažinti to pačio požymio savybes. Panašios savybės bus interpretuojamos kaip “identiškos“, bet jų skirtumas bus įvertintas kaip „skirtingi“. Šių tolerancijos rėmų įtvirtinimas įtakos biometrinį algoritmą. Jeigu šie rėmai bus dideli, tai gali būti daugiau klaidų, jei rėmai bus per siaurus, gali atsitikti taip, kad net biometrinio parašo savininkas bus nekorektiškai atpažintas (pvz., jeigu vaizdo duomenys blogos kokybės). Ryšium su tuo yra du biometrinių algoritmų tipai: FAR ir FRR programoms testuoti.

False Acceptance Rate (FAR). Nurodo biometrinio parašo klaidingų paskirstymų santykį jo savininko atžvilgiu. Kuo aukštesnis FAR , tuo didesne tikimybė, kad apgavikas arba sukčius galės sėkmingai identifikuotis.

False Rejection Rate (FRR). Nurodo biometrinio parašo neteisingai išsipildžiusių paskirstymų santykį. Yra didelė tikimybė, kad autorizuotas vartotojas gali nepraeiti identifikavimo.



22 pav. Autorizuoto ir neautorizuoto prisijungimo klaidų santykis priklausant nuo tolerancijos vertės.

Reikšmės FAR ir FRR priklauso viena nuo kitos [žr. 22 pav.]. Vienos reikšmės pagerinimas, reiškia kito sublogėjimas. Jeigu tolerancijos rėmai bus sumažinti, tai FAR

reikšmė taps mažesne, nes vaizdo atpažinimo kriterijus bus sugriežtintas, to pasėkoje kils *FRR*, nes požymio priėmimas išaugs. *FAR* ir *FRR* persikirtimo taške klaidos santykis tampa lygus, toks santykis vadinamas *ERR* (*Equal Error Rate*). Pagal *FAR* ir *FRR* klaidų santykius nustatomas taip vadinamas operuojamos charakteristikos imtuvo kreivė (*Receiver Operating Characteristic* (*ROC*)). Šis rodiklis gali tiksliai nusakyti klaidos dydį (*ERR*).

6.1. Testavimo eiga

Įvertinant veidų atpažinimą (%) buvo atliktas testavimas rankiniu ir automatiniu būdu, t. y. apmokant DNT su mokytojo ir be mokytojo pagalbos. Testavimas atliktas su autoriaus sukurta spalvota veidų DB, kadangi atliekamų darbų biudžetas neleido įsigyti komercinę veidų DB. Taip pat buvo dėtos pastangos ieškant laisvai prieinamos veidų DB, tačiau pavyko rasti tik nespalsvota ORL veidų DB, kurią praktinėje realizacijoje mes pritaikyti negalėjome. Autoriaus spalvota veidų DB buvo kuriami siekiant užtikrinti vienodą veidų apšvietimą bei vienodą veido rakursą. Veido rakurso poslinkis neturėtų būti didesnis negu 20°. Nuotraukų kiekis - 10, matmenys - 300×350 *dpi*, spalvų gylis – 24 bitai. Veido apšvietimas visur buvo vienodas. DNT apmokymas pagal atvirkštinio skleidimo algoritimą užimdavo 25-30 s.

Testavimas buvo atliktas Pentium 4 platformoje, HT technplogijos palaikymu, su 2,4 GHz, 512 RAM.

Gauti rezultatai pateikti 4, 5, 6 ir 7 lentelėse:

4 lentelė. Veidų atpažinimo tikslumas naudojant automatinį ir rankinį apmokymą

Veido numeris	Rankinio mokymo atpažinimo tikslumas (%)	Automatinio mokymo atpažinimo tikslumas (%)
01	78	78
02	82	82
03	82	84
04	87	85
05	80	81
06	84	84
07	81	88
08	85	82
09	84	82
10	82	82
Atpažinimo vidurkis (%):	82,5	82,8

Vidutiniškai programos testavimas parodė **82,5%** - rankiniu mokymo būdu ir **82,8%** – automatinio mokymo būdu, atpažinimo tikslumą. Vidutinis atpažinimo tikslumas paremtas bendrojo atpažinimo tikslumo vidurkiu. Nors automatinio mokymo rezultatas nedaug skiriasi nuo rankinio mokymo rezultato, bet galima teigti, kad jis šiuo atveju yra pranašesnis. Automatinis mokymas pranašesnis dėl vienos priežasties, nes veido skenavimo sritis apibrėžiama automatiškai ir turi mažesnę plotą, negu plotas, nustatytas rankiniu būdu. Įvertinus automatinio mokymo pranašumą buvo nuspręsta tolimesniuose testavimuose naudoti būtent automatinį mokymo būdą.

Toliau buvau įvertintas sistemos atsparumas užtriukšmintiems veidams. Veidų užtriukšminimas usdarė 80 % viso veido dydžio. Veidai buvo užtriukšminti, panaudojus *Cartoonist* programą.

5 lentelė. Veidų atpažinimo tikslumas, naudojant užtriukšmintus veidus

Veido numeris	Rankinio mokymo atpažinimo tikslumas (%)
01	86
02	82
03	78
04	82
05	atpažino kaip 02
06	atpažino kaip 02
07	atpažino kaip 08
08	82
09	atpažino kaip 02
10	atpažino kaip 02
Atpažinimo vidurkis (%):	41

Šiame testavimo žingsnyje programa kai kuriuos veidus atpažino neteisingai dėl didelio užtriukšminimo lygio. Neteisingai atpažintas veidas buvo įvertintas - **0%**. Pagal 5 lentelę FAR = 60 ir % FRR=20 %.

Kitame žingsnyje mes įvertinome veidų atpažinimą, esant veido pasikeičiusioms charakteristikoms (barzda, ūsai, akiniai). Užtriukšminant veidus, pasinaudojame programa *Virtual Cosmopolitan*.

6 lentelė. Veidų atpažinimo tikslumas, naudojant kelių veido charakteristikų užtriukšminimą

Veido numeris	Rankinio mokymo atpažinimo tikslumas (%)
01	83
02	atpažino kaip 08
03	80
04	atpažino kaip 02
05	77
06	82
07	atpažino kaip 08
08	88
09	84
10	atpažino kaip 08
Atpažinimo vidurkis (%):	49,4

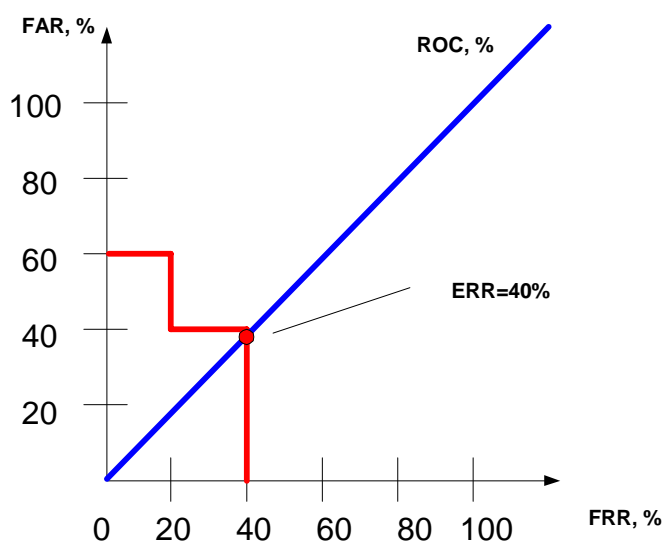
Šiuo atveju buvo užtriukšminti keli veidų fragmentai. Neteisingai atpažintas veidas buvo įvertintas - **0%**. Pagal 5 lentelę FAR = 60 % ir FRR=20 %. Pagal 6 lentelės rezultatus atpažinimo rezultato vidurkis yra geresnis, negu 5 lentelėje. Kitame testavimo žingsnyje buvo nuspręstą užtriukšminti tik vieną veido charakteristiką, tai buvo akys.

7 lentelė. Veidų atpažinimo tikslumas, naudojant vienos veido charakteristikos užtriukšminimą

Veido numeris	Veidų atpažinimas pagalakių sritį (%)
01	85
02	84
03	89
04	84
05	84
06	82
07	87
08	89
09	84
10	78
Atpažinimo vidurkis (%):	84,6

Po šio testavimo sistema parodė geriausią atpažinimo rezultatą, kuris sudarė **84,6%**. Užtriukšmintą veido sritį buvo akys.

Nustačius *FAR* ir *FRR* charakteristikas buvo nupieštas atitinkamas grafikas [žr. 23 pav.]. Pagal šio grafiko kreivę buvo nustatytas bendras santykinis klaidos dydis *ERR*, kurio reikšmė yra ***ERR* = 40%**.



23 pav. ROC grafikas, FAR ir FRR reikšmių klaidos santykis

6.2. Testavimo išvados

Sistema testavimo metu parodė gerą veidų atpažinimo rezultatą, kuris sudarė vidutiniškai **82,5%** - rankiniu mokymo būdu ir **82,8%** – automatiniu mokymo būdu, atpažinimo tikslumą. Pastebėta, kad atpažinimo rezultatas automatinio mokymo metu yra pranešesnis, negu rezultatas gautas rankinio mokymo būdu. Tai parodo programos geresnį funkcionavimą esant mažesniai požymių išskyrimo sričiai.

Pateikiant sistemai visiškai užtriukšmintus (80 % veido) arba dalinai užtriukšmintus veidus (keičiant kelias veido charakteristikas), buvo gauti blogi rezultatai, kurie svyruoja tarp **41% - 49,4%**. Tai parodo sistemos nestabilumą besikeičiančiai vaizdo aplinkai. Pagal 21 pav. buvo nustatytas sistemos klaidos santykis atpažįstant visiškai arba dalinai užtriukšmintus veidus. Šis santykis sudarė ***ERR* = 40%**.

Geriausius rezultatus sistema demonstruoja pateikiant jai dalinį (akys) veido užtriukšminimą. Šiuo atveju atpažinimo rezultatas sudarė **84,6%**, kai visi veidai buvo teisingai atpažinti. Šis rezultatas yra arti pirminio testavimo rezultato be užtriukšminimo. Toks rezultatas parodo sistemos stabilumą, esant mažam vaizdo pasikeitimui.

7. VARTOTOJO DOKUMENTACIJA

Tam, kad PĮ įtiktų įvairiems vartotojams, kartu su PĮ sistema yra pateikiama vartotojo dokumentacija.

7.1. Vartotojo vadovas

Grafinė vartotojo sąsaja

Programos „Veidas“ vartotojo sąsaja panaudoja intuityvų dialogą su vartotoju, t. y. lieka tik tie elementai aktyvūs, kurie šiame kontekste yra leistini. Paleidus programą, aktyviu tampa tik mygtukas „Atidaryti“. Paspaudus šį mygtuką atsiranda grafinių bylų arba klasifikatoriaus pasirinkimo langas.

Mokymas su grafinėmis bylomis.

Atliekant veidų atpažinimą yra būtina, kad į sistemą būtų pakrauti testavimo duomenys, t. y. grafinės bylos su veidais. Šioms byloms turi būti iš anksto priskirti žmonių vardai, kuriems šie veidai priklauso. Programa „Veidas“ galės atpažinti tik tuos vaizdus, kurie dalyvavo per mokymo procesą. Mokymas atliekamas tokiu būdu:

1. Paspaudus mygtuką „Atidaryti“, atsidaro bylų pasirinkimo dialogas, kuriame Jus galite pasirinkti medžiagą imties mokymui. Taip pat yra numatyta galimybė pasirinkti keletą bylų ne eilės tvarka, tam reikia bylų pasirinkimo metu paspausti mygtukus *Shift* arba *Ctrl*.
2. Pasirinkus bylas, jų vardai pasirodys bylų sąrašė. Ten galima nustatyti bylas bet kuria tvarka, paspaudus ant bylos pavadinimo, kairiajame programos lange bus atvaizduotas grafinės bylos vaizdas. Ši byla dabar turi būti apdorota programiškai.
3. Pasirinktų bylų klasifikavimas atliekamas per 2 etapus. Iš pradžių reikėtų pasirinkti, ar grafinėje byloje yra veidas arba jo nėra, tam reikia paspausti mygtukus „Veidas“ arba „Vaizdas“. Jeigu grafinėje byloje yra pateiktas žmogaus veidas, tai ši grafinė byla turi būti pavadinta žmogaus vardu. Priskirus vaizdui tam tikrą vardą, iš karto yra aktyvuojamas mygtukas „Veidas“.
4. Po visų grafinių bylų klasifikavimo, mygtukas „Mokyti NT“ tampa aktyviu, kas leidžia atlikti dirbtinio neuroninio tinklo apmokymą pasirinktais duomenimis.

Grafinių bylų testavimas

Po sėkmingo grafinių bylų mokymo galima pradėti atpažinimo procesą. Atpažinimo metu gali būti panaudoti tie patys vaizdai, kurie dalyvavo per mokymo procesą arba panašūs modifikuoti vaizdai su tam tikrais triukšmais. Atpažinimo bei testavimo procesas atliekamas tokiu būdu:

1. Prieš pradėdant testavimą arba veidų atpažinimą reikėtų spragtelėti ant „Ijungti testavimą“ mygtuko.
2. Prieš pradėdant testavimą arba veidų atpažinimą, reikėtų atidaryti jau paruoštą grafinių bylų medžiagą. Ši medžiaga turi plėtinį „*.clf“.
3. Testavimo arba atpažinimo metu pasirinkus bet kurią grafinę bylą atliekamas jos klasifikavimas. Vaizdų atpažinimo rezultatas pateikiamas dešiniajame programos lange. Programa bandys nuspręsti, kam priklauso pateiktas veidas, ar toks veidas duomenų bazėje yra arba jo nėra.

Automatinis mokymas

Mokymo metu priskiriamas byloms taip vadinamas klasifikatorius – tai yra specialioji komponentė perimta iš vaizdų nustatymo modulio. Šis objektas įprastu būdu gali būti išsaugotas ir neturi būti kiekvieną kartą sukuriamas iš naujo. Bet, kadangi mes savo darbe naudojame šio modelio demonstracinę versiją, mes turime jį atidaryti prieš pradėdant darbą su programa. Tam programai yra numatyta galimybė eksportuoti mokytas duomenis į bylą su plėtiniu „*.clf“. Tokiu būdu mes galėsime atlikti automatinį grafinių bylų mokymą.

1. Atlikus visus žingsnius po mygtuko „Mokyti NT“ paspaudimo, tampa aktyviu mygtukas „Išsaugoti“.
2. Paspaudus mygtuką „Išsaugoti“ atsiranda duomenų išsaugojimo dialogas. Dialogo metu apmokytas bylas galima išsaugoti į bylą su plėtiniu „*.clf“. Tokiu būdu duomenys išsaugojami į duomenų bylą, turintį tokį formatą: grafinės bylos numeris, veidas/vaizdas, žmogaus vardas.
3. Kiekvieną kartą paleidus programą galėsime pasirinkti apmokytą bylą paspaudus mygtuką „Atidaryti“. Po clf-bylos pasirinkimo galėsime iš karto pereiti prie atpažinimo arba testavimo operacijų.

Opcijos

Programoje yra numatytos keturios opcijos, kurios gali būti panaudotos dirbant su programa. Opcijos yra šios:

- *Ijungti testavimą.* Ši opcija yra skirta vaizdų arba veidų atpažinimui bei testavimui.
- *Veidų atpažinimas.* Pasirinkus šią opciją bus atliekamas tik žmonių atpažinimas, nepasirinkus prieš tai veido zonos. (skirtumas tarp veidų nustatymo ir veidų atpažinimo).
- *Visų vaizdų paieška.* Pažymėjus šią opciją bus atliekama paieška visoje vaizdų bei veidų duomenų bazėje. Tokiu būdu mes gausime ne labiausiai atitinkantį vaizdą, o visų vaizdų sąrašą, kuris yra artimas pateiktam vaizdai.

- *Keturkampio pateikimas.* Po šios opcijos pasirinkimo, mokymo metu atsiranda keturkampis ant vaizdo, kuris žymi sritį, dalyvaujančią per mokymo procesą. Keturkampis gali būti pastumtas taip, kad jo kampai apytiksliai apibrėžtų veido formą. Be tokio pastūmimo, keturkampis automatiškai pasirodys per vaizdo vidurį ir liks nematomu. Testavimo ar atpažinimo metu keturkampis pasirodys vėl ir pažymės vaizdo sritį, dalyvavusią per mokymo procesą.

7.2. Sistemos klaidų vadovas

Šioje dalyje aprašytos sistemos pranešimai apie klaidas. Apačioje lentelėje yra pateikiamas klaidų sąrašas su nuorodomis, kaip atstatyti galimus klaidų padarinius. Sistemoje yra numatyti 7 klaidų pranešimai (žr. 8 lentelę):

8 lentelė. Sistemos klaidų aprašymai

Klaidos pranešimas	Klaidos aprašymas	Sprendimo būdas
Klaida įtraukiant vaizdą!	Pasirinktas netinkamas grafinės bylos formatas	Paderinkite grafinės bylos gebą. Skiriamoji geba turi atitikti 300×350 dpi. Grafinė byla turi būti spalvota
Klaida: Nepavyko prisijungti prie VeidasProcessing () modulio !	Įvyko klaidą paleidžiant failą. Virtualiosios atminties trūkumas	Paleiskite programą iš naujo
Jus išsirinkote negrafinę bylą!	Išsirinktoje byloje nėra grafikos konteksto	Išsirinkite tinkamą grafinę bylą
Klaida apdorojant veidą::VeidasNustatymas()!	Įvyko klaida išskiriant vaizdo požymius. Išskiriama požymių sritis yra per didelę	Bandykite sumažinti požymių išskyrimo sritį. Sumažinkite keturkampio apdorojimo sritį
Klaida VeidasProcessing modulyje::VeidasAtpazinimas()!	Blogai transformuoti požymių duomenys	Grįžkite prie požymių nustatymo žingsnio. Bandykite sumažinti požymių išskyrimo sritį. Sumažinkite keturkampio apdorojimo sritį
Klaida VeidasProcessing modulyje::Mokyti Vaizdus()!	Įvyko klaidą atvirkštinio skleidimo algoritme. Perduodamas per didelis informacijos kiekis	Bandykite sumažinti požymių išskyrimo sritį. Sumažinkite keturkampio apdorojimo sritį
Neteisinga .clf byla!	Pažeista arba neteisingai išsaugota *.clf byla	Perrašykite arba iš naujo išsaugokite *.clf bylą

7.3. Sistemos instaliavimo dokumentas

Šis dokumentas skirtas sistemos administratoriams. Jame yra nurodytos detalės, kaip konkrečioje aplinkoje instaliuoti PĮ sistemą. Šioje dalyje aprašytos sistema sudarančios bylos, minimali techninės įrangos konfigūracija.

Prieš paleidžiant programą „Veidas“ turėtų būti įdiegta *ImageManager* taikomoji programa iš *Common Vision Blox* PĮ paketo. Nukopijuokite iš pateikto DVD disko direktoriją „Veidas“ į pageidaujama Jums vietą. Įsitikinkite, kad kartu nusikopijavo visos dinaminės bibliotekos (DLL). *Veidas.exe* yra pagrindinė programos „Veidas“ byla. Norint paleisti programą spragtelkite du kartus ant *Veidas.exe* bylos.

Reikalavimai programinei įrangai: MS Windows XP Service Pack 2, Manto biblioteka iš *Common Vision Blox* PĮ paketo.

Minimalus reikalavimai techninei įrangai: P3 platforma, 800 MHz, 256 Mb RAM, 32 MB vaizdo plokštė, 500 MB laisvos atminties kietajame diske.

8. PĮ PRODUKTO KOKYBĖS ĮVERTINIMAS

PĮ „Veidas“ diegimas buvo atliktas UAB „Insaris“ įmonėje. PĮ testavimas buvo atliktas su autoriaus sukurta veidų duomenų baze. PĮ testavimo rezultatai praktiškai sutapo su rezultatais, atliktais PĮ alfa - testavimo metu, t. y. veidų atpažinimo tikslumas vidutiniškai sudarė **82 %**. Programa teisingai reagavo į visas pasirenkamas komandas. Siekiant gauti objektyvesnį PĮ įvertinimą, buvo nutarta atlikti anketavimą su kontroline vartotojų grupe. Tam tikslui buvo sukurtos specialios anketos [žr. priedus 12.3.]. Kiekvieno punkto įvertinimas, atliktas pagal 5 balų skalę. Anketos klausimai buvo paskirstyti į dvi darbuotojų grupes: vartotojai ir specialistai.

Anketavimo tikslas – įvertinti siūlomos PĮ sistemos atitikimą įmonės poreikiams bei jos atitikimą vartotojų poreikiams. Anketavimo metu buvo pasirinkti 3 vartotojai, susiję su sistema. PĮ sistemos „Veidas“ įvertinimas, pateiktas 9 lentelėje. 10 Lentelėje pateikiami PĮ „Veidas“ anketavimo rezultatai.

9 lentelė. PĮ „Veidas“ kokybės įvertinimas

PĮ „Veidas“			
<i>Charakteristika</i>	<i>Įvertinimų procentinis pasiskirstymas</i>		
Funkcionalumas	Tinkamumas	40%	34%
	Atitikimas standartams	20%	
	Sąveika su kitomis sistemomis	10%	
	Saugumas	10%	
	Tikslumas	20%	
Patikimumas	Tolerancija klaidoms	30%	25%
	Užbaigtumas	40%	
	Atstatomumas	30%	
Patogumas	Įsisavinimas	40%	10%
	Vykdyto savybės	40%	
	Suprantamumas	20%	
Efektyvumas	Išteklių naudojimas	50%	15%
	Laiko parametrai	50%	
Priežiūros savybės	Analizės savybės	40%	10%
	Pakeitimų galimybės	45%	
	Stabilumas	10%	
	Testavimo savybės	5%	
Perkeliamumas	Pritaikomumas	10%	5%
	Tinkamumas pakeitimui	10%	
	Įdiegimo savybės	40%	
	Prisitaikymas prie kitos aplinkos	40%	
Kita			1%
Bendras įvertinimas:			100%

10 lentelė. PĮ „Veidas“ kokybės įvertinimas

PĮ „Veidas“			
<i>Charakteristika</i>	<i>Įvertinimų balinis pasiskirstymas</i>		
Funkcionalumas	Tinkamumas	0,68	1,7
	Atitikimas standartams	0,34	
	Sąveika su kitomis sistemomis	0,17	
	Saugumas	0,1581	
	Tikslumas	0,317	
Patikimumas	Tolerancija klaidoms	0,375	1,25
	Užbaigtumas	0,45	
	Atstatomumas	0,3375	
Patogumas	Įsisavinimas	0,2	0,5
	Vykdyto savybės	0,2	
	Suprantamumas	0,1	
Efektyvumas	Išteklių naudojimas	0,375	0,75
	Laiko parametrai	0,375	
Priežiūros savybės	Analizės savybės	0,2	0,5
	Pakeitimų galimybės	0,18	
	Stabilumas	0,045	
	Testavimo savybės	0,025	
Perkeliamumas	Pritaikomumas	0,025	0,25
	Tinkamumas pakeitimui	0,0225	
	Įdiegimo savybės	0,09	
	Prisitaikymas prie kitos aplinkos	0,09	
Kita	-		0,05
Bendras įvertinimas:	4,7551		5

Atlikus anketavimą, visų anketavimo dalyvių anketos buvo apdorotos. Rezultatai buvo susumuoti ir padalinti iš dalyvių skaičiaus. Pagal gautus vidurkius buvo sudaryta 10 lentelė. Remiantis 10 lentelės bendru balų įvertinimu, PĮ „Veidas“ paslaugų kokybės įvertinimas sudarė 4,7551 balų iš 5 galimų balų, procentiniu santykiu PĮ kokybė išreiškiama kaip **95,1 %**. Pagal gautą kokybės vertinimo santykį, PĮ „Veidas“ buvo įvertinta kaip labai gera. PĮ „Veidas“ darbų perdavimo ir priėmimo aktas pateiktas prieduose [žr. Priedai 12.2.].

9. IŠVADOS

Atlikus darbo probleminės srities analizę, išnagrinėjus teorinius bei praktinius DNT funkcionavimo aspektus, nustatius atvirkštinio skleidimo algoritmo privalumus ir trūkumus, realizavus vaizdų ir veidų atpažinimo programinę sistemą, galime padaryti tokias darbo išvadas:

1. Darbe pateikta nemažai DNT metodų sprendžiant vaizdų atpažinimo uždavinius. Pateikta žinomų DNT metodų bei požymių išskyrimo metodų apžvalga ir palyginimas atpažinimo, mokymo bei klasifikavimo atvejais. Atlikus pradinį vaizdų modeliavimą su veidų duomenų baze iš *Olivetti Research Laboratory (ORL)* pastebėti sąsukinių DNT, sprendimu paremtų DNT ir 1-artimiausio-kaimyno DNT privalumai. Šios DNT rūšys parodė aukšta atpažinimo tikslumą – apie 96-97 %. Iš požymių išskyrimo metodų geriausią atpažinimo rezultatą gavo pseudo dvimatės grafikos paslėptų Markovo modelių metodas, atpažinimo tikslumas sudarė – apie 95 %.
2. Išlieka vieningų atpažinimo metodų bei testavimo aplinkų poreikis. Atlikus daugelį tyrimų, pastebėta, jog sunku ar kai kuriais atvejais neįmanoma objektyviai įvertinti gautų testavimo rezultatų. Tai sąlygoja didelė vaizdų atpažinimo algoritmų įvairovė, įvairūs jų mokymo būdai. Kol nėra vieningų tyrimo metodų, testavimo rezultatų tikslumą negalima įvertinti absoliučiais dydžiais ir jų taikymas galimas tik tam tikroje srityje.
3. Atliktas atvirkštinio skleidimo algoritmo taikymo tyrimas veidams atpažinti. Išnagrinėtos įvairios mokymo taisyklės bei išskirti šio algoritmo privalumai ir trūkumai. Žinoma, kad algoritmas yra universalus įvairiems uždaviniams spręsti. Pastebėtas algoritmo trūkumas jo mokymo metu dėl galimo duomenų pertekliaus. Atvirkštinio skleidimo algoritmu mokomas DNT gali būti paraližuotas.
4. Pasiūlytas atvirkštinio skleidimo algoritmo spartinimo būdas ir požymių išskyrimo metodas. Požymių išskyrimas pagal RGB vaizdo filtravimą: pikseliai transformuojami į vektorius pagal mažai besikeičiančiu reikšmių dydžius, vektoriai savo ruožtu klasifikuojami į klases. To pasėkoje, atvirkštinio skleidimo algoritmas priima mažiau duomenų, kurie yra jau naudingi atpažinimui.
5. Remiantis atvirkštine skleidimo procedūra sukurtas prototipinis modelis automatizuotam veidų atpažinimui. Išskirti pagrindiniai jo moduliai, atskiriantys veidų nustatymo bei atpažinimo ypatumus. Tai leidžia paprasčiau suderinti visos realizuotos sistemos darbą.
6. Naudojant įvairius DNT tipus, iškyla problemos su veido rakursu, vaizdo ryškumu arba vaizdo apšvietimu. Esant pateikiamo vaizdo dideliems nukrypimams nuo etaloninio vaizdo, DNT metodai negali atpažinti pateikiamų jiems vaizdų. Siekiant užtikrinti geresnę

atpažinimą, siūloma vaizdus parinkti su mažai besikeičianiu išsidėstymu bei su vienu arba normalizuotu apšvietimu.

7. Realizavus pasiūlytą modelį praktiškai, pasiektas didelis neužtriukšmintų veidų atpažinimo tikslumas, kuris vidutiniškai sudarė **82,5%**, naudojant rankinį mokymo būdą ir **82,8%** atpažinimo tikslumą, panaudojus automatinį mokymo būdą.
8. Siūlomas metodas gana nestabilus, jei vaizdai yra visiškai arba yra didžiąja dalimi užtriukšminti. *ERR* reikšmė, paremta *FAR* ir *FRR* reikšmių klaidos santykiu yra gana didelė ir sudaro **40%**. O tai rodo metodo neatsparumą visiškai arba dalinai užtriukšmintiems vaizdams.
9. Pastebėtas siūlomo metodo efektyvumas su mažai užtriukšmintais veidais, tai buvo veido papildymas akiniais. Pateikiant sukurtai sistemai dalinį veido užtriukšminimą (akiniai), sistema jį atpažįsta, rodant labai gerą atpažinimo tikslumą. Šiuo atveju atpažinimo tikslumas sudarė **84,6%**, su išlyga, kai visi veidai buvo teisingai atpažinti. Šis rezultatas artimas pirminiam testavimo rezultatui be užtriukšminimo. O tai rodo sistemos stabilumą, esant mažam vaizdo pasikeitimui.
10. Ateityje tikimasi užtikrinti sistemos stabilumą besikeičiant veido rakursui bei jo apšvietimui. Siūloma šioje srityje tęsti tyrimus ir toliau, kad pasiekiamų metodų efektyvumas užtikrintų siūlomo metodo panaudojimą plačiame uždavinių spektre.

10. LITERATŪRA

1. Aizenberg N. N., Krivosheev G.A. Multi-valued and Universal Binary Neurons: Learning Algorithms, Applications to Image Processing and Recognition // Lecture Notes in Artificial Intelligence - Machine Learning and Data Mining in Pattern Recognition, 1999. p. 21-35.
2. Bartlett, Stewart M. Face Image Analysis by Unsupervised Learning, Kluwer Academic Publishers, 2001.
3. Baum E. On the Capabilities of Multilayer Perceptrons. Academic Press, 1988, p. 193-215.
4. Biometric Authentication Research Group. *Biometrik in der Gesellschaft*, Hamburgo universitetas, 2002, [žiūrėta 2004-03-02]. Prieiga per Internetą: <<http://agn-www.informatik.uni-hamburg.de/hct/biomtrie.pdf>>
5. Bleumer G. Biometrische Ausweise : *Datenschutz und Datensicherheit*, 3(23), 1999.
6. Brömme A. Politik-gewollte Anwendungen der Biometrik. Hamburgo universitetas, 2001 m. lapkritis. - [žiūrėta 2004-04-05]. Prieiga per Internetą: <<http://agn-www.informatik.uni-hamburg.de/papers/pub2001.htm>>
7. Caudill M. ir Butler C. Understanding Neural Networks: Computer Explorations, Vol. 1, MIT, 1992.
8. Caudill M. ir Butler C. Understanding Neural Networks: Computer Explorations, Vol. 2, MIT, 1992, p. 72.
9. Drucker H., Yann Le Cun. Improving Generalization Performance Using Backpropagation //IEEE Transactions on Neural Networks, Vol.3, N5, 1992, p. 991-997.
10. Gael de La Croix Vaubois, Moulinoux C., Derot B. The N Programming Language //Neurocomputing, NATO ASI series, vol. F68, p.8 9-92.
11. Hebb D. O. The Organisation of Behavior. Cambridge, MIT Press, 1988, p. 43-46.
12. Hornik K., Stinchcombe M. ir White H. Multilayer Feedforward Networks are Universal Approximators, 1989, p. 359-166.
13. Koleski A. Praktische Anwendbarkeit künstlicher neuronaler Netze für die Gesichtserkennung in der biometrischen Authentikation. Universität Hamburg, 2002 m. gruodis.
14. Lawrence S., Giles C. L., Tsoi A. C., Back A. D. Face Recognition: A Convolutional Neural Network Approach // IEEE Transactions on Neural Networks, Special Issue on Neural Networks and Pattern Recognition, 1997. p. 1-24.
15. Lovell D. R., Downs T., Tsoi A. C. An Evaluation of The Neocognitron // University of Queensland, Australia: Technical Report, 16 p.

16. Lovell D. R., Tsoi A. C. The Performance of the Neocognitron with Various S-Cell and C-Cell Transfer Functions // University of Queensland, Australia: Technical Report, 1992, 10 p.
17. Malki H.A., Moghaddamjoo A. Using the Karhunen-Loe've Transformation in the Back-Propagation Training Algorithm //IEEE Transactions on Neural Networks, Vol.2, N1, 1991, p. 162-165.
18. Minsky M. и Papert S. Percepsions. Cambridge, MIT Press, 1988, p. 157-169
19. Pan Z., Rust A. G., Bolouri H. Image Redundancy Reduction for Neural Network Classification using Discrete Cosine Transforms // Proceedings of the IJCNN, 2000. Vol. 3, p. 149-154.
20. Petrowski A., Dreyfus G., Girault C., Performance Analysis of a Pipelined Backpropagation Parallel Algorithm //IEEE Transactions on Neural Networks, Vol.4, N6, 1993, p. 970-981.
21. Ranganath S. and Arun K. Face recognition using transform features and neural networks // Pattern Recognition 1997. Vol. 30. p. 1615-1622.
22. Rosenblatt. F. The perceptron: a probabilistic model for information storage and organization in the brain. Cambridge, MIT Press, 1988, p. 89-113.
23. Rumelhart E., Hinton E. G. и Williams R. J. Learning representations by back-propagating errors. 1986, p. 533-536.
24. Sankar K. P., Sushmita M., Multi Layer Perceptron, Fuzzy Sets, and Classification //IEEE Transactions on Neural Networks, Vol.3, N5, 1992, p. 683-696.
25. Valentin D., Abdi H. Can a Linear Autoassociator Recognize Faces From New Orientations? // The University of Texas at Dallas, 1995, 11 p.
26. Valentin D., Abdi H., O'Toole A. J. and Cottrell G. W. Connectionist models of face processing: a survey // IN: Pattern Recognition 1994. Vol. 27, p. 1209-1230.
27. Werbos J., Backpropagation Through Time: What It Does and How to Do It //Artificial Neural Networks: Concepts and Theory, IEEE Computer Society Press, 1992, p. 309-319.
28. Widrow. B., Lehr. A., 30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation //Artificial Neural Networks: Concepts and Theory, IEEE Computer Society Press, 1992, p. 327-354.
29. Zell, A. Simulation Neuronaler Netze. 1. edition. Addison-Wesley, 1994.
30. Абламейко С., Лагуновский Д. Обработка изображений: Технология, методы, применение. – Мн., 1999. 300 p.
31. Галушкин А. Теория нейронных сетей. - М.:ИПРЖР, 2000. 416 p.

32. Глазунов А. Компьютерное распознавание человеческих лиц // Открытые Системы, №03, 2003 м. - [žiūrēta 2003-12-27]. Prieiga per Internetą: <<http://www.osp.ru/os/2004/01/>>
33. Головкин В. Нейроинтеллект: Теория и применения. Книга 1. Организация и обучение нейронных сетей с прямыми и обратными связями - Брест:БПИ, 1999. 260 p.
34. Головкин В. Нейроинтеллект: Теория и применения. Книга 2. Самоорганизация, отказоустойчивость и применение нейронных сетей - Брест:БПИ, 1999. 228 p.
35. Горбань А., Дунин-Барковский В., Кирдин А. и др. Нейроинформатика. Новосибирск: Наука. Сибирское предприятие РАН, 1998.
36. Короткий С. Нейронные сети: основные положения. – [žiūrēta 2004-09-29]. Prieiga per Internetą: <<http://lii.newmail.ru/index.htm>>.
37. Панканти Ш, Болле Р., Джейн Э. Биометрия: будущее идентификации // Открытые Системы, №03, 2000. - [žiūrēta 2004-01-05]. Prieiga per Internetą: <<http://www.osp.ru/os/2004/01/>>
38. Пентланд А., Чаудхари Т. Распознавание лиц для интеллектуальных сред // Открытые Системы, №03, 2000. - [žiūrēta 2004-01-05]. Prieiga per Internetą: <http://www.osp.ru/os/2003/12/>
39. Самаль Д., Старовойтов В. Выбор признаков для распознавания на основе статистических данных// Цифровая обработка изображений. Минск. Ин-т техн. киберн. НАН Беларуси. 1999. p.105-114.
40. Самаль Д., Старовойтов В. Подходы и методы распознавания людей по фотопортретам. Минск, ИТК НАНБ, 1998. 54 p.
41. Самаль Д., Старовойтов В. Методика автоматизированного распознавания людей по фотопортретам// Цифровая обработка изображений. Минск. Ин-т техн. киберн. НАН Беларуси. 1999. p.81-85.
42. Старовойтов В. Локальные геометрические методы цифровой обработки и анализа изображений. Мн., 1997. 284 p.
43. Старовойтов В., Талей М. Методы сегментации цветных изображений. Минск, ИТК НАНБ, 1999. 44 p.
44. Уоссермен Ф. Нейрокомпьютерная техника: Теория и практика, 1992. 184 p.
45. Уоссермен Ф., Нейрокомпьютерная техника, Москва, 1992.

11. BACKPROPAGATION NEURAL NETWORKS: PATTERN RECOGNITION

Summary

In this Master's degree work artificial neural networks and back propagation learning algorithm for human faces and pattern recognition are analyzed.

In the second part of work artificial neural networks and their architecture and structures models are analyzed. In the third part of article the backpropagation procedure and procedures theoretical learning principle are analyzed. In the fourth part different kinds of ANN methods and patterns extracting methods in recognition, learning and classification use were researched. In this part RGB method for patterns features extraction was described. In the fifth part the requirements specification, prototype model, use case diagram, system architecture, programs modules and objects project for software realization were created. In the same part backpropagation procedures running principle was realized. After the project part was completed, a face and patterns recognition system "Veidas" was created. In the sixth part the created software system was tested. According to the testing results software's "Veidas" recognition rate is 82,5 % using supervised learning and 82,8 % using unsupervised learning. We found using the FAR and FRR rates the ERR rate, which was 40 %. While doing the testing with changed human characteristics, the system showed 84,6 % recognition rate. This rate shows very good work of the system by a little bit changed human characteristics. Systems realization was evaluated by users as very good one. In the seventh part software's "Veidas" system documentation and users manual is represented. A copy of software "Veidas" was written on the DVD.

12. TERMINŲ IR SANTRUMPŲ ŽODYNAS

1. 1-NN: 1-artimiausias-kaimynas;
2. CN: convolutional network (sąsukinis neuroninis tinklas);
3. DB – duomenų bazė;
4. DBVS – duomenų bazių valdymo sistema;
5. DNT – dirbtiniai neuroniniai tinklai;
6. GHz - kompiuterio taktinis greitis, milijonai taktų per sekundę;
7. GmbH – *Gemeinschaft mit beschränkter Haftung* (Bendrovė su ribota atsakomybe);
8. IT - informacinės technologijos;
9. Mhz – kompiuterio taktinis greitis, milijonai taktų per sekundę;
10. MIT – Masačuseto Technologijos Institutas (*Massachusetts Institute of Technology*);
11. MLP: multi layer perceptron (daugiasluoksnis perceptronas);
12. MS – Microsoft kompanija;
13. Nr. – numeris;
14. OO – objektiškai – orientuotas;
15. p.-puslapis;
16. pav. – paveikslėlis;
17. PCA: principal components analysis (pagrindinė dėdamųjų analizė);
18. PDBNN: probabilistic, decision-based neural network (tikimybinis, sprendimu pagrįstas neuroninis tinklas);
19. PĮ – programinė įranga;
20. PK – personalinis kompiuteris;
21. RAM – operatyvinė atmintis;
22. RBF: radialinių bazinių funkcijų neuroninis tinklas;
23. rpm - kietojo disko apsisukimo skaičius per minutę;
24. t. y. – tai yra;
25. t. t. – taip toliau;
26. UAB – uždaroji akcinė bendrovė.

13. PRIEDAI

13.1. DVD diskas

DVD diske yra pateikta autoriaus sukurta PĮ „Veidas“ bei jai reikalingos paleidimo bibliotekos.

13.2. Darbų perdavimo – priėmimo aktas

13.3. Kokybės įvertinimo anketos