



Kauno technologijos universitetas

Informatikos fakultetas

**Vaizdų apdorojimo technologijų taikymo asmens tapatybės
dokumentų atpažinimo uždaviniui tyrimas**

Baigiamasis magistro projektas

Andrius Šulskis

Projekto autorius

doc. dr. Agnė Paulauskaitė-Tarasevičienė

Vadovė

Kaunas, 2021



Kauno technologijos universitetas

Informatikos fakultetas

Vaizdų apdorojimo technologijų taikymo asmens tapatybės dokumentų atpažinimo uždaviniui tyrimas

Baigiamasis magistro projektas

Programų sistemų inžinerija (kodas 6211BX011)

Andrius Šulskis

Projekto autorius

**doc. dr. Agnė Paulauskaitė-
Tarasevičienė**

Vadovė

doc. Dalia Čalnerytė

Recenzentė

Kaunas, 2021



Kauno technologijos universitetas

Informatikos fakultetas

Andrius Šulskis

Vaizdų apdoravimo technologijų taikymo asmens tapatybės dokumentų atpažinimo uždaviniui tyrimas

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdamas kitų asmenų autoriaus ar kitų teisių, laikydamasis Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu;
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalintas iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Andrius Šulskis

Patvirtinta elektroniniu būdu

Šulskis, Andrius. Research of Image Processing Technology for Identity Documents Recognition Master's thesis in Software Engineering / supervisor doc. dr. Agnė Paulauskaitė-Tarasevičienė; The Faculty of Informatics, Kaunas University of Technology.

Study field and area: Computing, Software Engineering.

Keywords: Image classification, image processing technology, identity documents, convolutional neural networks.

Kaunas, 2021. 78 pages.

Summary

When providing a remote identity service, a big problem is the errors customers make during authentication. To solve this problem, the company UAB "Identifikaciniai projektai" has formed a task to automate the choice of document type and country in order to reduce the number of errors made by users and improve the user experience of using the system.

This document and the software developed: an intelligent identification system for identity documents to solve the customer's problem by classifying documents by type and country.

The main purpose of this software engineering project was to apply the classification algorithm to determine the type and country of identity documents from visual material, using high classification accuracy methods. Convolutional Neural Networks (CNN) have been used to implement document classification, which allows achieving the highest results for solving image classification problems in comparison with other algorithms such as random forests, decision trees, Support Vector Machines (SVM). The analyzes were performed to find out the current situation, used technologies, machine learning algorithms, and detailed convolutional neural networks. The relevance of the problem is presented by analyzing the causes and assessing the need for the system. The task was solved using CNN proposed architecture by changing the number of layers and hyperparameters. The speed and accuracy of the system are evaluated and the research results are presented. Other convolutional network architectures, such as VGG16, VGG19, ResNet50, ResNet152, Inception V3, are also used in the experimental study. To validate the accuracy of the classification, the model was validated and tested using cross-validation. Experiments were performed to evaluate the performance of the models using poor-quality photos. The characteristics of different architectural models are compared: the size of the trained model, the time of testing and training, the number of parameters, and the accuracy. After analyzing the research results, the most appropriate model for solving the task of classifying identity documents using visual material was determined.

Turinys

1. Įžanga	10
1.1. Dokumento paskirtis.....	10
1.2. Santrauka	10
2. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos analitinė dalis	11
2.1. Įvadas.....	11
2.1.1. Esama situacija	11
2.2. Naudojamos technologijos	13
2.2.1. Bankinis pavedimas.....	13
2.2.2. Bankinės kortelės pridėjimas.....	13
2.2.3. Elektroninis parašas.....	13
2.2.4. Vaizdo skambutis	13
2.2.5. Rankinis asmens tapatybės dokumentų tikrinimas.....	13
2.2.6. Automatinis asmens tapatybės patvirtinimas naudojant biometrinius duomenis.....	14
2.3. Įrankio alternatyvos	14
2.3.1. Nanonets	14
2.3.2. Smartengines	14
2.3.3. Regula.....	15
2.3.4. Įrankio alternatyvų išvados.....	15
2.4. Temos aktualumas ir tikslingumas	15
2.5. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos projekto tikslas ir uždaviniai	18
2.6. Galimų sprendimų apžvalga	19
2.6.1. Skaitmeninis vaizdas	19
2.6.2. Mašininio mokymo algoritmai	19
2.6.3. Dirbtiniai neuroniniai tinklai	21
2.6.4. Konvoliuciniai neuroniniai tinklai.....	21
2.6.5. Sprendimų medžiai.....	26
2.6.6. Atsitiktiniai miškai	27
2.6.7. Vektorinės atramos mašinos.....	28
2.7. Įgyvendinimo problemos.....	29
2.8. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos realizacijai pasirinkti sprendimai	29
2.8.1. Metodiniai aspektai	29
2.8.2. Techniniai aspektai.....	29
2.9. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos analitinės dalies išvados	30
3. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos projektinė dalis	32
3.1. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos panaudojimo atvejais	32
3.2. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos funkciniai reikalavimai.....	35
3.3. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos nefunkciniai reikalavimai ...	36
3.4. Sistemos architektūra	37
3.4.1. Sistemos statinis vaizdas	37
3.5. Sistemos dinaminis vaizdas.....	38
3.6. Sistemos funkcijos.....	41
3.6.1. Apie sistemą	41
3.6.2. Pagrindinės sistemos funkcijos.....	41
3.6.3. Modelio apmokymas	42

3.6.4.	Apmokyto modelio pasirinkimas	42
3.6.5.	Testavimo rezultatai	43
3.6.6.	Dokumento tikrinimas	43
3.7.	Konvoliucinių neuroninių tinklų architektūra	44
3.8.	Vektorinės atramos mašinos veikimas	45
3.9.	Projektinės dalies išvados.....	46
4.	Intelektinės asmens tapatybės dokumentų atpažinimo sistemos tyrimo dalis.....	47
4.1.	Tyrimo tikslas.....	47
4.2.	Tyrimo aprašymas ir eiga	47
4.3.	Sistemos testavimas.....	48
4.3.1.	Testuojama programų sistema.....	48
4.3.2.	Sąsajos	48
4.3.3.	Testavimo strategija.....	48
4.3.4.	Vienetų testavimas.....	48
4.3.5.	Integravimo testavimas.....	48
4.3.6.	Priėmimo testavimas	49
4.3.7.	Aukšto lygio testavimas	49
4.3.8.	Testavimo ištekliai.....	49
4.3.9.	Testavimo rezultatai	49
4.3.10.	Testavimo įrankiai ir aplinka.....	49
4.3.11.	Testavimo rezultatai ir išvados.....	49
4.4.	Metodų palyginimas	50
4.5.	Greitaveikos įvertinimas.....	52
4.6.	Sistemos kokybės vertinimas	52
4.7.	Tyrimo rezultatai	53
4.8.	Kokybės tobulinimo galimybės.....	53
4.9.	Tyrimo dalies išvados.....	53
5.	Intelektinės asmens tapatybės dokumentų atpažinimo sistemos eksperimentinė dalis	54
5.1.	Eksperimentinio tyrimo tikslas.....	54
5.2.	Eksperimentinio tyrimo aprašymas ir eiga	54
5.3.	Eksperimentinio tyrimo rezultatai	54
5.4.	Eksperimentinės dalies išvados	60
6.	Išvados	61
7.	Literatūra	62
8.	Terminų ir santrumpų žodynas	68
9.	Priedai.....	69

Lentelių sąrašas

3.1 lentelė PA „Nustatyti sistemos parametrus“ specifikacija	32
3.2 lentelė PA „Nurodyti duomenų rinkinio parametrus“ specifikacija	33
3.3 lentelė PA „Nurodyti mokymosi parametrus“ specifikacija	33
3.4 lentelė PA „Apmokyti modelį“ specifikacija.....	33
3.5 lentelė PA „Testuoti modelį“ specifikacija.....	33
3.6 lentelė PA „Peržiūrėti modelio rezultatus“ specifikacija.....	33
3.7 lentelė PA „Pradėti dokumento tipo nustatymą“ specifikacija	34
3.8 lentelė PA „Pradėti dokumento šalies nustatymą“ specifikacija.....	34
3.9 lentelė PA „Ištrinti ištreniruotą modelį“ specifikacija	34
3.10 lentelė PA „Nustatyti kelis iki duomenų“ specifikacija.....	34
3.11 lentelė PA „Pasirinkti dokumento nuotrauką“ specifikacija.....	34
3.12 lentelė PA „Pasirinkti aplanką su nuotraukomis“ specifikacija.....	34
3.13 lentelė FR-1 specifikacija.....	35
3.14 lentelė FR-2 specifikacija.....	35
3.15 lentelė FR-3 specifikacija.....	35
3.16 lentelė FR-4 specifikacija.....	35
3.17 lentelė FR-5 specifikacija.....	35
3.18 lentelė NFR-1	36
3.19 lentelė NFR-2.....	36
3.20 lentelė NFR-3.....	36
3.21 lentelė NFR-4.....	36
3.22 lentelė NFR-5.....	37
3.23 lentelė SVM algoritmo naudojami nustatymai	45
4.1 lentelė Konvoliucinio neuroninio tinklo algoritmo rezultatai aptinkant dokumento tipą.....	50
4.2 lentelė Vektorinės atramos mašinos algoritmo rezultatai aptinkant dokumento tipą.....	50
4.3 lentelė Konvoliucinio neuroninio tinklo algoritmo rezultatai aptinkant paso šalį.....	50
4.4 lentelė Vektorinės atramos mašinos algoritmo rezultatai aptinkant paso šalį.....	51
4.5 lentelė Konvoliucinio neuroninio tinklo algoritmo rezultatai aptinkant dokumento tipą.....	51
4.6 lentelė Vektorinės atramos mašinos algoritmo rezultatai aptinkant dokumento tipą.....	51
4.7 lentelė Kriterijai	53
5.1 lentelė Eksperimentinio tyrimo naudojamų duomenų informacija.....	54
9.1 lentelė CNN modelių testavimo rezultatai	69
9.2 lentelė SVM modelių testavimo rezultatai.....	69
9.3 lentelė Dokumento tipo atpažinimo uždavinio eksperimentinio tyrimo rezultatai	70
9.4 lentelė Asmens tapatybės kortelės šalies atpažinimo eksperimentinio tyrimo rezultatai	71
9.5 lentelė Paso šalies atpažinimo uždavinio eksperimentinio tyrimo rezultatai.....	71
9.6 lentelė Dokumento tipo modelių testavimo rezultatai, naudojant visus testavimo duomenis	73
9.7 lentelė Dokumento tipo modelių testavimo rezultatai, naudojant blogos kokybės nuotraukas ..	74
9.8 lentelė Asmens tapatybės kortelės šalies nustatymo modelių testavimo rezultatai, naudojant visus testavimo duomenis	75
9.9 lentelė Asmens tapatybės kortelės šalies nustatymo modelių testavimo rezultatai, naudojant tik blogos kokybės nuotraukas.....	75
9.10 lentelė Paso šalies nustatymo modelių testavimo rezultatai, naudojant visas nuotraukas	76
9.11 lentelė Paso šalies nustatymo modelių testavimo rezultatai, naudojant tik blogos kokybės nuotraukas.....	77

Paveikslų sąrašas

2.1 pav. Šalies pasirinkimo langas užsakovo įmonės sistemoje	16
2.2 pav. Dokumento tipo pasirinkimo langas užsakovo įmonės sistemoje.....	17
2.3 pav. Mašininio mokymo algoritmų klasifikavimas [26]	20
2.4 pav. CNN veikimo principas [42]	22
2.5 pav. „LeNet – 5“ tinklo architektūra [47]	22
2.6 pav. „AlexNet“ tinklo architektūra [48].....	23
2.7 pav. „ResNet“ tinklo architektūra [50].....	23
2.8 pav. „VGG-16“ tinklo architektūra [52]	24
2.9 pav. „VGG-19“ tinklo architektūra [53]	25
2.10 pav. „GoogLeNet“ tinklo architektūra [55]	26
2.11 pav. Sprendimų medžio veikimo diagrama [66]	27
2.12 pav. Atsitiktinių miškų diagrama [69]	27
2.13 pav. Atramos vektorių mašinos duomenų klasifikavimas [76].....	28
2.14 pav. Sistemos veikimo logika, asmens tapatybės dokumento tipo ir šalies aptikimui.....	30
3.1 pav. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos panaudojimo atvejų diagrama	32
3.2 pav. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos paketų diagrama	37
3.3 pav. PA „Testuoti modelį“ ir PA „Peržiūrėti modelio rezultatus“ veiklos diagramos.....	38
3.4 pav. PA „Apmokyti modelį“ veiklos diagrama.....	39
3.5 pav. PA „Nurodyti mokymosi parametrus“ ir PA „Nurodyti duomenų rinkinio parametrus“ veiklos diagramos	40
3.6 pav. Kairėje, bendra PA „Pradėti dokumento tipo nustatymą“ ir PA „Pradėti dokumento šalies nustatymą“, o dešinėje . PA „Ištrinti išreniruotą modelį“ veiklos diagrama.....	40
3.7 pav. Modelio pavadinimo įvedimo langas.	42
3.8 pav. Modelio pasirinkimo testavimui langas.	42
3.9 pav. Testavimo rezultatų langas.	43
3.10 pav. Dokumento tikrinimo langas.	44
3.11 pav. CNN architektūra	44
3.12 pav. SVM veikimo diagrama	45
4.1 pav. Skirtingų dokumentų tipo pavyzdžiai	47
4.2 pav. Skirtingų šalių dokumentų pavyzdžiai	47
4.3 pav. Asmens tapatybės dokumentų klasifikavimo rezultatų palyginimas	51
4.4 pav. Aplikacijų programavimo sąsajos (angl. <i>API</i>) apkrovos testavimo rezultatai	52
5.1 pav. Eksperimentinio tyrimo rezultatai: modelių parametrų kiekis	55
5.2 pav. Eksperimentinio tyrimo rezultatai: apmokytų modelių dydis	55
5.3 pav. Eksperimentinio tyrimo rezultatai: apmokymo ir testavimo laikas dokumento tipo nustatymui	56
5.4 pav. Eksperimentinio tyrimo rezultatai: visų ir tik blogos kokybės nuotraukų aptikimo tikslumas dokumento tipo nustatymui	57
5.5 pav. Eksperimentinio tyrimo rezultatai: apmokymo ir testavimo laikas asmens tapatybės kortelės šalies nustatymui	57
5.6 pav. Eksperimentinio tyrimo rezultatai: visų ir tik blogos kokybės nuotraukų aptikimo tikslumas asmens tapatybės kortelės šalies nustatymui	58
5.7 pav. Eksperimentinio tyrimo rezultatai: apmokymo ir testavimo laikas paso šalies nustatymui	59

5.8 pav. Eksperimentinio tyrimo rezultatai: visų ir tik blogos kokybės nuotraukų aptikimo tikslumas paso šalies nustatymui	59
9.1 pav. Eksperimentinio tyrimo rezultatai: modelių tikslumas dokumento tipo nustatymui	72
9.2 pav. Eksperimentinio tyrimo rezultatai: modelių tikslumas asmens tapatybės kortelės šalies nustatymui	72
9.3 pav. Eksperimentinio tyrimo rezultatai: modelių tikslumas paso šalies nustatymui	73
9.4 pav. Sistemos įdiegimo aktas	78

1. Įžanga

1.1. Dokumento paskirtis

Šis dokumentas yra skirtas, programų sistemos inžinerijos, magistro studijų metu sukurtos asmens tapatybės dokumentų atpažinimo sistemos, naudojant vaizdų atpažinimo technologijas, tyrimui. Rengiant šį dokumentą ir atliekant tyrimus siekiama asmens tapatybės dokumentų atpažinimo uždaviniui pritaikyti tinkamiausią sprendimą užtikrinantį greitaveiką ir tikslumą. Analitinėje dokumento dalyje nurodomi galimi sprendimai ir atliekama jų apžvalga, argumentuojama, kodėl buvo pasirinktos tokios technologijos. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos projektinėje dalyje išsamiai pateikiami sistemos dokumentacijos pagrindiniai aspektai. Sistemos tyrimo dalyje norima įvertinti klasifikavimo metodų tikslumą naudojant vaizdus, iškeltam uždaviniui atlikti. Eksperimento metu siekiama pateikti sistemos galimybių ir tikslumo tyrimą, atliekant patobulinimų tyrimą, bei naudojant kitas algoritmų architektūras. Išvados pateikiami apibendrinti pagrindinės dokumento dalys, taip siekiant nurodyti svarbiausius ir apibendrintus rezultatus, kurie reikalingi vykdyti tolimesniems tyrimams vaizdų klasifikavimo uždaviniams spręsti.

1.2. Santrauka

Teikiant nuotolinę asmens tapatybės paslaugą didelė problema yra klientų atliekamos klaidos tapatybės patvirtinimo metu. Šiai problemai spręsti įmonė UAB „Identifikaciniai projektai“ suformavo uždavinį, automatizuoti dokumento tipo ir šalies pasirinkimą, siekiant sumažinti vartotojų atliekamų klaidų skaičių ir taip pagerinti vartotojų pajautimą naudojantis sistema.

Šis dokumentas ir sukurta programinė įranga: intelektinę asmens tapatybės dokumentų atpažinimo sistemą, skirta užsakovo problemai spręsti, klasifikuojant dokumentus pagal tipą ir šalį.

Darbo tikslas – klasifikavimo algoritmo pritaikymas asmens tapatybės dokumentų tipo bei šalies nustatymui iš vaizdinės medžiagos, panaudojant aukšto klasifikavimo tikslumo metodus. Dokumentų klasifikavimo uždaviniui spręsti buvo naudojami konvoliuciniai neuroniniai tinklai (CNN). Naudojant šį algoritmą galima pasiekti aukščiausius rezultatus sprendžiant klasifikavimo uždavinius naudojant vaizdus. Kiti algoritmai, tokie kaip atsitiktiniai miškai, sprendimų medžiai, vektorinės atramos mašinos (SVM), neleidžia pasiekti tokio aukšto tikslumo. Darbe atlikta esamos situacijos, naudojamų technologijų, mašininio mokymo algoritmų ir detalizuota konvoliucinių neuroninių tinklų analizė. Pateikiamas problemos aktualumas analizuojant priežastis ir įvertinant sistemos reikalingumą. Užduoties sprendimui naudota CNN Siūloma architektūra architektūrą pakeičiant ir sluoksnių skaičių ir keičiant hiper parametrus. Įvertinta sistemos greitaveika bei tikslumas ir pateikiami tyrimo rezultatai. Atliekant eksperimentinį tyrimą naudojamos ir kitos konvoliucinių tinklų architektūros, tokios kaip: „VGG16“, „VGG19“, „ResNet50“, „ResNet152“, „Inception V3“. Klasifikavimo tikslumui įvertinti atliktas modelio validavimas ir testavimas naudojant kryžminę patikrą. Atlikti eksperimentai siekiant įvertinti modelių veikimą naudojant blogos kokybės nuotraukas. Palyginti skirtingų architektūrų modelių charakteristikos: apmokyto modelio dydis, testavimo ir apmokymo laikas, parametrų skaičius bei tikslumas. Išanalizavus tyrimo rezultatus nustatytas tinkamiausias modelis asmens tapatybės dokumentų klasifikavimo uždaviniui spręsti naudojant vaizdinę medžiagą.

2. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos analitinė dalis

2.1. Įvadas

Keičiantis kasdieniniam gyvenimui, vis daugiau veiklų persikelia į internetą, lieka vis mažiau tik fiziškai prieinamų paslaugų, todėl labai svarbu verslams turėti galimybę patvirtinti klientų tapatybę prieš atliekant įvairias operacijas, įrodant, kad tai tikrai yra tas žmogus ir atitinka keliamus reikalavimus. Todėl tapatybei patvirtinti naudojamos nuotraukos tiek asmens tapatybės dokumento tiek žmogaus veido, jog būtų galima užtikrinti tapatybę.

Vaizdų atpažinimo uždaviniai pastaruoju metu yra taikomi labai plačiai, pramonėje, medicinoje, transporto srautų valdymui, saugumui [1].

Didėja šių technologijų naudojimas priimant sprendimus, kur siekiama automatizuoti ir sukurti išmanesnę sistemų valdymą. Dėl šios priežasties uždavinys yra iškeltas ir įmonės teikiančios asmens tapatybės patvirtinimą nuotoliniu būdu paslauga, siekiant automatizuoti rankinį žmogaus procesą, jį pagreitinti, nes šiuo metu, žmogus turi rankiniu būdu pasirinkti savo asmens tapatybės dokumento tipą ir šalį, o tai sukelia daug klaidų, klientams nepatogu, dažnai neteisingai vartotojai supranta ir pasirenka neteisingai, dėl šios priežasties negali pereiti tapatybės patvirtinimo proceso. Šia sistema automatizuojamas žmogaus rankinis darbas, tai leistų pagreitinti procesą, sumažinti klaidų skaičių ir padaryti procesą kuo paprastesnį vartotojams. Šio darbo automatizavimas yra reikalingas, kadangi pati įmonė išskėlė tokią problemą, uždavinys yra realus, ši problema yra ne tik dokumento tipo ir šalies pasirinkimo tačiau yra ir daugiau problemų, kurias būtų galima išspręsti minimaliai pakeičiant šią sistemą arba naudojantis įrankiu apmokyti reikiamus modelius, kurie aptiktų norimus objektus.

2.1.1. Esama situacija

Asmens tapatybei patvirtinti nuotoliniu būdu naudojama įvairiausių būdų, tokie kaip pokalbis telefonu, informacijos pateikimas elektroniniu paštu, prisijungus su socialinėmis paskyromis, tačiau dažnai to neužtenka ir reikia atlikti bankinį pavedimą ar bent pridėti banko kortelę prie paskyros, tačiau tai neidentifikuoja, koks asmuo tai atlieka, kadangi tai gali padaryti ir kitas žmogus pasisavinęs kito asmens duomenis, kad to būtų išvengta naudojama asmens tapatybės identifikacija nuotoliniu būdu, tai gali būti pateikiamos tik nuotraukos dokumento ir veido arba gali būti atliekamas vaizdo skambutis kur agentas paprašo parodyti dokumentą ir atsakyti į tam tikrus klausimus, jog galėtų užtikrinti tapatybę [2].

Šiuo metu vienas iš dažniausiai naudojamų būdų nuotoliniu būdu nustatyti tapatybę tai yra naudojant biometrinius duomenis, tokius kaip veidas, pirštų anspaudai, rainelė, tinklainė, balsas, rankų geometrija [3].

Taip pat naudojamas ir NFC metodas informacijai iš asmens tapatybės gauti, ne tik nuotraukos, tai reikalauja, jog mobilusis įrenginys turėtų NFC funkciją ir identifikacijos metu galėtų asmens dokumentą pridėjęs prie įrenginio gauti informaciją iš dokumento, kurią suklastoti yra daug sudėtingiau [4].

Kadangi įmonė kuri užsakė projektą dirba su asmens tapatybės patvirtinimu ir naudoja veido biometrinius duomenis nustatyti asmens tapatybę iš kliento pateiktų tiek veido tiek asmens tapatybės dokumento nuotraukų. Didžiausia problema kyla dėl netikrų, padirbtų veidų ir dokumento nuotraukų, taip pat dažnai bandoma prisijungti su kito asmens dokumentu ir būtina tinkamai patikrinti veidus,

jog nepraleisti skirtingų asmenų. Tačiau problema kyla ir dėl netinkamos nuotraukų kokybės, apšvietimo, kurie trukdo sėkmingai identifikuoti žmogų [5].

Atliekant tapatybės patvirtinimą naudojant nuotraukas ir iš jų paimant veido biometrinius duomenis susiduriama su vartotojų klaidomis ir nepatogiu vartotojų patyrimu.

Asmens tapatybės dokumento tipo ir šalies pasirinkimas užima klientų laiko ir reikalauja tikslumo, kadangi įvykus klaidai, klientai negali atlikti asmens tapatybės patvirtinimo ir negali naudotis norimomis paslaugomis. Ypač tai svarbu vartotojams turintiems mažiau kompiuterinio raštingumo ar atliekantiems asmens tapatybės patvirtinimą nuotoliniu būdu pirma kartą. Taip pat problema dažnai iškyta ir asmenims esantiems kitose šalyse, nors dokumentas yra išduotas ne toje šalyje kur asmuo dabar yra ir tokiu atveju klientai dažnai renkasi ne dokumento išdavimo šalį, bet šalį kurioje yra šiuo metu, tokiais atvejais įmonės sistema negali sėkmingai nuskaityti dokumento informacijos, kadangi dokumento informacijai nuskaityti naudojamas kiekvienos šalies ir kiekvieno dokumento tipo šablonas kuriame sužymėta kur yra kokia informacija, klientui pasirinkus netinkamą šalį ar dokumento tipą sistema nesugeba nuskaityti arba nuskaito netaisyklingai informaciją [6].

Jungtinės karalystės šalies ir Jungtinių Amerikos Valstijų piliečiams ši problema dar aktualesnė, kadangi pas juo kaip ID kortelė laikomos vairuotojo teisėmis priešingai nei kitose šalyse ir jie dažnai pasirenka ID kortelę nors rodo vairuotojo pažymėjimą ir tokiais atvejais jie negali praeiti sėkmingai verifikacijos automatiškai, tuomet reikalauja papildomo darbo žmogaus, kad klientas kreipiasi į įmonę, praneša, kad negali patvirtinti tapatybės ir tuomet įmonės darbuotojas turi rankiniu būdu suvesti informaciją ir patvirtinti klientą tai ilgai užtrunka, brangiai kainuoja ir problema iškyta esant dideliems srautams, jog reikia net ne vieno žmogaus, kurie patvirtintų rankiniu būdu suvedę informaciją iš dokumento tai ir sukelia dažnai klientų pyktį ir nepasitenkinimą sistema, nors ir jie padarė klaidą [7], [8].

Šie veiksmai reikalaujami visose sistemose kur reikalingas asmens tapatybės patvirtinimas ir tai iš dalies atrodo yra tik keli papildomi mygtukų paspaudimai, tačiau kiek tai problemų sukelia klientams ir esant dideliems srautams įmonė dėl to patiria didelius nuostolius, nes ir ne visus klientus patvirtina, kuriuos būtų, jei klientas būtų gerai pasirinkęs, o kitiems patvirtinti reikia rankinio žmogaus įsikišimo kas brangiai kainuoja ir ilgai užtrunka.

2.2. Naudojamos technologijos

Naudojama skirtingų technologijų kaip nuotoliniu būdu patvirtinti tapatybę asmenims norintiems atlikti tam tikras operacijas. Dažniausios operacijos atliekamos klientų, tokios kaip įsigyti prekių, pasiimti paskolą, žaisti azartinius žaidimus ir įvairiausių sričių, kur tik verslams reikia nustatyti klientų tapatybę, amžių banko sąskaita, išvengti pasikartojančių paskyrų ar apsisaugoti nuo nusikaltėlių, kurie be jokios tapatybės patvirtinimo galėtų atlikti šiuos veiksmus. Naudojama įvairiose srityse tokiose kaip finansinės, medicinos, įdarbinimo, telekomunikacijų, žaidimų, oro uosto ir daugelyje kitų institucijų [9].

2.2.1. Bankinis pavedimas

Vienas iš tapatybės patvirtinimo būdų yra bankinis pavedimas į nurodytą banko sąskaita su nurodyta suma, taip asmuo pateikia savo duomenis, vardą, pavardę, asmens kodą ir banko sąskaita, tai pakankamai patikimas būdas. Turėti netikrą banko sąskaita net ir nusikaltėliams yra sudėtinga, šio tipo minusas, jog tą pavedimą gali atlikti kitas žmogus turintis priėjimą prie sąskaitos duomenų ir taip nėra užtikrinama, kad būtent tas pats žmogus, kuris nori naudotis paslauga atlieka tokį tapatybės identifikavimą [10].

2.2.2. Bankinės kortelės pridėjimas

Bankinės kortelės pridėjimas prie paskyros yra dažnai naudojamų autentifikacijos būdų, kad įrodytų savo unikalią tapatybę. Dažniausiai naudojama mažesnio saugumo reikalaujančiose sistemose, užtikrinti, jog nebūtų sukuriama pasikartojančių paslaugų leidžiančių pasinaudoti tik vienam asmeniui ir nustatytą laiką. Šis būdas nėra tiek saugus, kadangi nusikaltėliai gali lengvai nelegaliai nusipirkti pavogtus bankinės kortelės duomenis ir juos panaudoti [11].

2.2.3. Elektroninis parašas

Elektroninis parašas yra populiarus ir dažnai naudojamas patvirtinti tapatybei kartu su asmens tapatybės dokumentu. Naudojant specialų įrenginį kuris nuskaito dokumente esančią informaciją ir taip patvirtina tapatybę. Problema yra, kad nereikia įrodyti, kad būtent tas pats žmogus atlieka pasirašymą jei turi priėjimą prie duomenų, net nereikia parodyti savo veido, jog atlieka identifikaciją [12].

2.2.4. Vaizdo skambutis

Tai ilgiausiai trunkantis ir nepatogiausias būdas, tačiau leidžiantis užtikrinti asmens tapatybę. Patvirtinama, jog atlieka tas asmuo, kuris ir nori pasinaudoti paslauga. Parodo tikrą dokumentą, tačiau šio vaizdo skambučio metu reikia parodyti dokumentą ir veidą, taip pat atsakyti į užduodamus klausimus. Tai yra nepatogus procesas, nes esant didesniam klientų srautui gali tekti ilgai laukti skambučio, kadangi vidutiniškai taip trunka apie 10 minučių ir agentas privalo pats tai atlikti ir šis procesas yra mažiausiai automatizuotas [13].

2.2.5. Rankinis asmens tapatybės dokumentų tikrinimas

Tai dabar vis mažiau naudojamas procesas, kadangi yra labai brangus ir lėtas, reikalauja tikslumo, kadangi informaciją nurašo žmogus išlieka klaidos faktorius didesnis nei tai atliekant automatizuotai, kadangi žmogui daro įtaką ir nuovargis, emocijos, skubėjimas, ypač esant didesniam srautui gali būti padaroma daugiau klaidų, kas turėtų didelių pasekmių, jei neteisingai įrašytam asmens kodui

išduodama paskola ir tai nėra lankstus būdas. Todėl įmonės vis mažiau tai atlieka rankomis ir ieško automatizuotų sprendimų [14].

2.2.6. Automatinis asmens tapatybės patvirtinimas naudojant biometrinius duomenis

Asmens tapatybės patvirtinimas nuotoliniu būdu gali būti atliekamas naudojant žmogaus biometrinius duomenis, tokius kaip veidas, pirštų anspaudai, rainelė, tinklainė, balsas, rankų geometrija. Pagal šiuos duomenis galima identifikuoti kiekvieną asmenį ir taip užtikrinti, jog būtent jis atliekų veiksmą, o ne kitas asmuo už jį [15]. Tapatybės patvirtinimui dažniausiai naudojami biometriniai veido duomenys, kadangi juos gauti nereikia papildomos įrangos, tai galima atlikti su vaizdo kamera atlikus vaizdo įrašą ar nuotrauką vėliau iš jos galima gauti veido taškus, kurie ir yra biometriniai duomenys ir pagal juos galima sulygtinti veidą esantį dokumente ir veidą esantį nuotraukoje ar vaizdo įrašė, tai padeda nustatyti asmens tapatybę, tačiau iškyla problema, kad veidai kartais būna labai panašūs ir automatinė sistema gali sulygtinti du panašius veidus, tačiau tai yra skirtingi asmenys, todėl reikia labai daug duomenų apmokyti tokiai sistemai, jog sugebėtų atskirti panašius veidus ir sulygtinti to paties žmogaus veidą skirtingose nuotraukose [16]. Tačiau tokia problema dažnai sprendžiama naudojant ir papildomus modelius, kurie nusako žmogaus amžių, rasę, lytį ir tai padeda tiksliau atskirti veidus [17], [18]. Asmens tapatybės dokumente laikomi biometriniai duomenys kuriuos galima ištraukti naudojant mobiliuosius įrenginius turinčius NFC funkcija [4], kuri leidžia iš dokumento nuskaityti jame užšifruotą informaciją ir ją naudoti asmens tapatybės patvirtinimui [19].

2.3. Įrankio alternatyvos

2.3.1. Nanonets

Šis įrankis naudoja gilų mokymąsi, kad automatizuotų asmens tapatybės kortelių informacijos gavimą, duomenų įvedimą ir peržiūros procedūras, kad būtų pasiektas didesnis efektyvumas. Tikimasi, kad klientas pateiks skaitmeninę dokumentų kopiją, kurią recenzentas peržiūrės, nustatys, ar ji suklastota, išgaus informaciją, pvz., Vardą, adresą ir pan., Ir įves ją į duomenų įvedimo programinę įrangą. Informacijos gavimas - įrankis užfiksuoja visą ID kortelėje pateiktą informaciją ir perduoti tuos duomenis kaip unikalų šaltinį tolesniam naudojimui. Visa informacija, paimta iš užfiksuotos asmens tapatybės kortelės, bus pateikiama paprastu tekstiniu / skaitmeniniu formatu. Didesnis greitis ir efektyvumas - Norint paprasčiausiai nuskaityti asmens tapatybės kortelę ir iš jos gauti visus duomenis, reikia kelių sekundžių. Įrašo duomenis be klaidų - tobulėjant technologijoms ir skaičiavimo galiai, mašinos dabar gali fiksuoti duomenis be daugybės klaidų. Lengvai integruojamas į bet kurią sistemą - skaitmeninius sprendimus galima lengvai integruoti į bet kurią sistemą. Pavyzdžiui, modelį, kuris yra mokomas atpažinti informaciją iš tam tikros asmens tapatybės kortelės, galima pritaikyti svetainėje, kurioje vartotojai įkelia vaizdus dideliais kiekiais, arba jis gali būti naudojamas mobiliuosiuose telefonuose, kur vartotojai spustelėja paveikslėlius ir tokiu būdu informacija išgaunama [19].

2.3.2. Smartengines

Pasirinkus dokumento šalį ir dokumento tipą su šiuo įrankiu galima nuskaityti informaciją iš asmens tapatybės dokumento, palaiko 1500 tipų, naudoja 2200 šablonų ir palaiko daugiau nei 100 kalbų. Šio įrankio trūkumai, kad automatiškai neatpažįsta dokumento šalies [20].

2.3.3. Regula

Šis įrankis nuskaityto dokumento informaciją esančia dokumento priekyje, nuskaityto informaciją ir MRZ zonos, atpažįsta dokumento tipą, atlieka duomenų sutikrinimą, tačiau automatiškai neatpažįsta dokumento šalies [21].

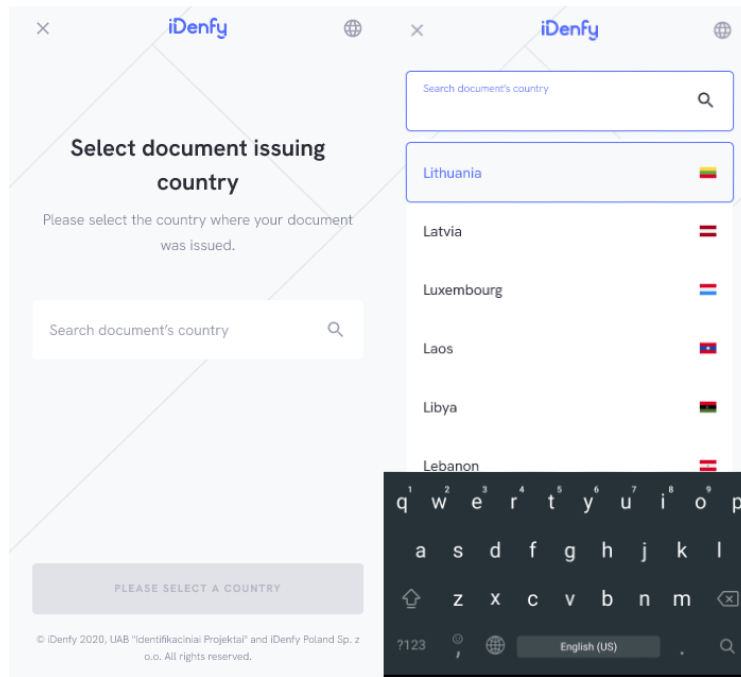
2.3.4. Įrankio alternatyvų išvados

Atlikus panašių įrankių analizę, paaiškėjo, jog specifinio įrankio atliekančio tik reikiamas funkcijas nėra, kadangi visi įrankiai atlieka ir informacijos nuskaitymą, o įmonei užsakančiai šį projektą toks funkcionalumas nereikalingas, kadangi turi savo informacijos nuskaitymo sistemą, todėl per brangu pirkti tokius įrankius ir naudoti tik vieną funkciją. Dėl šios priežasties bus kuriamas atskiras įrankis leidžiantis atlikti norimas įmonės funkcijas esant galimybei lengvai tobulinti ar pridėti naujo funkcionalumo.

2.4. Temos aktualumas ir tikslingumas

Asmens tapatybės dokumentų informacijos nuskaitymas ir atpažinimas yra ypatingai aktualus pastaruoju metu, ypač esant pasauliniai pandemijai, dar daugiau veiklų ir verslų persikėlė į internetą, todėl norint įsigyti atitinkamas paslaugas, reikia patvirtinti ir asmens tapatybę norint išvengti sukčiavimo atvejų ir kiek galima labiau užtikrinti, jog paslauga būtų teikiama būtent tam asmeniui, tai galima padaryti skirtingais būdais, tačiau dažniausiai naudojamas tapatybės nustatymas naudojant asmens tapatybės dokumentą ir pateikia realiu metu atliktą veido nuotrauką. Šią informaciją gali patikrinti ir patvirtinti žmogus, bet norint paspartinti šį procesą, reikalingas automatizavimas. Šiuo metu jau daug įmonių teikia automatizuotą asmens tapatybės patvirtinimą. Tačiau išlieka klientų, žmogiškųjų klaidų faktorius atliekant šį procesą. Dažnai žmonės atlikdami šį procesą nurodo neteisingai dokumento išdavimo šalį ir tipą, o tai automatizuotai sistemai neleidžia tinkamai aptikti dokumento ir nuskaityti jame esančios informacijos, dėl šios priežasties, norint išvengti žmogiškųjų klaidų, įmonė UAB „Identifikaciniai projektai“ užsakė sukurti sistemą, gebančią iš dokumento nuotraukos, nustatyti dokumento šalį ir tipą, šią informaciją perduoti įmonės esamai sistemai ir taip išvengti žmogiškųjų klaidų, pagerinti vartotojo patyrimą naudojantis sistema.

Klaidų priežastys pasirenkant dokumento šalį, dokumento šalies pasirinkimas yra išskleidžiamasis sąrašas (angl. *drop down list*), todėl kai kurie sistemos vartotojai nenorėdami to paspaudžia ant kitos šalies, ne tą kurią nori pasirinkti, ypač problema aktualesnė naudojant mobiliuosius įrenginius, kai vaizdas yra mažesnis ir pirštu atliekant paspaudimus tikslumas yra mažesnis. Užsakovo sistemos vaizdas pateiktas žemiau esančiame paveiksle (2.1 pav.), kaip šalies pasirinkimas atrodo mobiliojo įrenginio ekrane. Vartotojai neteisingai pasirinkę šalį, dažnai to nepastebi, neatkreipia į tai dėmesio ir procesą vykdo toliau.



2.1 pav. Šalies pasirinkimo langas užsakovo įmonės sistemoje

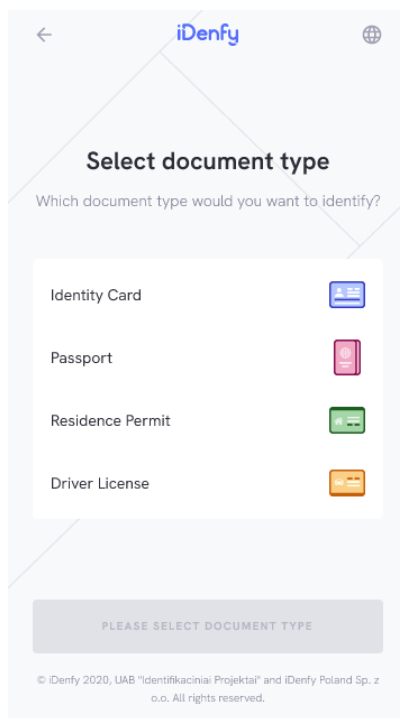
Sąrašė pateikiama pirmoji šalis pagal vartotojo IP adresą, nustatoma, kurioje šalyje yra naudotojas ir pagal tai sąrašo viršuje būna iškelta aptikta šalis, tai dažniausiu atveju klientams labai palengvina šalies pasirinkimą, kadangi nereikia paieškoje vesti šalies pavadinimo, o galima iškart pasirinkti, tačiau problema, jeigu klientai yra išvykę, keliauja, gyvena kitoje šalyje ar naudoja virtualų privatų tinklą (angl. *virtual private network, VPN*), tuomet šalis sąrašo viršuje neatitinka dokumento išdavimo šalies ir taip neatidūs sistemos vartotojai padaro klaidą pasirinkdami netinkamą šalį.

Taip pat, kai kurie sistemos vartotojai sąmoningai renkasi šalį, kurioje šiuo metu yra, nors dokumento išdavimo šalis būna kita, tai dažna problema su emigrantais, kurie išvažiuoti dirbti ir gyventi į kitą šalį ir renkasi dabartinę šalį, nors prašoma pasirinkti dokumento išdavimo šalį.

Klaidų priežastys pasirenkant dokumento tipą, klaidingas dokumento tipo pasirinkimas yra netgi dažniau pasitaikantis atvejis, nei šalies pasirinkimui. Kadangi sistema naudojasi skirtingo amžiaus, išsilavinimo, kompiuterinio raštingumo žmonės, todėl dėl įvairių priežasčių pasirenka netinkamą, dokumento tipą, tokių kaip netyčinis paspaudimas ant ne to dokumento ir automatiškai vartotojas nukreipiamas į sekantį žingsnį, ir nevisi grįžta atgal pasirinkti tinkamą. Dar viena priežastis kodėl klaidingai pasirenką dokumento tipą, nes vartotojai nemato skirtumo ar tiksliai nežino, koks tai dokumentas, dažniausiai klaidingai pateikiami dokumento tipai yra tapatumo patvirtinimo kortelė ir leidimas gyventi, bei tapatumo kortelė ir vairuotojo pažymėjimas, tačiau pasitaiko atvejų, kai pasirenka pasą, bet rodo tapatumo kortelę ir priešingai. Netinkamai pasirenka dokumento tipą, nes skuba ir paspaudžia pirmą pasitaikiusį dokumentą. Kitose šalyse kaip Jungtinėse Amerikos valstijose ir Jungtinėje karalystėje nėra asmens tapatybės kortelės, ten vairuotojo pažymėjimas atstoja tapatybės kortelę ir sistemos naudotojai būtent iš šių šalių daugiausia pateikia vairuotojo pažymėjimą kaip asmens tapatybės kortelę. Taip pat, atvykę gyventi į kitą šalį asmenys ir gavę leidimą gyventi, dažnai traktuoja šį dokumentą, kaip asmens tapatybės kortelę, tačiau tai yra kitas dokumento tipas ir pateikiant kaip asmens tapatybės kortelę, sistema negeba sėkmingai nuskaityti informacijos.

Taip pat, ne visose šalyse ir pasirinktinai pagal nustatymus leidžiami visi dokumento tipai, todėl klientai, negalėdami pasirinkti norimo dokumento tipo, pasirenka bet kurią leidžiamą ir rodo norimą dokumentą, nors pagal šalį ar nustatymus toks dokumentas nėra priimamas.

Žemiau pateiktame paveiksle (2.2 pav.) yra sistemos vaizdas, kaip atrodo dokumento tipo pasirinkimas, paspaudus ant norimo dokumento vartotojas nukreipiamas į kitą žingsnį, tai daugeliui vartotojų yra patogiu, bet atsiranda, kurie dėl to padaro klaidų ir tęsia procesą su neteisingai pasirinktu dokumento tipu.



2.2 pav. Dokumento tipo pasirinkimo langas užsakovo įmonės sistemoje

Kai kurie sprendimai dėl sistemos dizaino ir vartotojo patyrimo yra nuolatos gerinami, jog vartotojai padarytų kuo mažiau klaidų ir kuo patogiau būtų naudotis sistema, tačiau ir tai geriausiu atveju padeda šiek tiek sumažinti klaidas, tačiau dabar naudojamas optimaliausias būdas, pagal patogumą ir mažiausią klaidų skaičių, tačiau vis tiek išlieka labai daug neteisingų pasirinkimų.

Ne visada įmonė valdo šiuos pasirinkimus ir negali kontroliuoti vartotojo patyrimo ir klaidų skaičiaus, dėl to, jog įmonės partnerio sistemoje gali pasirinkti tiek dokumento šalį, tiek tipą ir ateiti į „iDenfy“ sistemą su jau nustatytais pasirinkimais, kurių keisti negali, dėl apribojimų iš partnerio sistemos, tokiais atvejais įmonė negali kontroliuoti vartotojo patyrimo ir analizuoti kodėl buvo atliktos klaidos.

Dokumento šalies pasirinkimas ir dokumento tipas tiek sistemos kūrėjams tiek daugeliui vartotojų atrodo labai paprastas dalykas ir sunku suprasti, jog gali vartotojai daryti tiek klaidų, tačiau esant įvairiausiems vartotojams, kalbos barjerams, žmogiškosioms klaidoms, yra daug atvejų, kai neteisingai pasirenkama informacija ir dėl to užsakovo įmonė patiria daug papildomų išlaidų, kurių galima būtų išvengti, automatizavus ir užkirtus kelią vartotojų klaidoms arba bent sumažinus jų kiekį.

Automatizuota asmens tapatybės patvirtinimo sistema veikia iš vaizdinės medžiagos, kurioje yra asmens tapatybės dokumentas, nuskaito informaciją, ir palygina veidą esantį dokumente, bei veido nuotrauką atlikta realiuoju laiku. Informacijos iš dokumento ištraukimui reikalinga žinoti dokumento

šali ir tipą, kadangi pagal tai yra aprašyti dokumentų šablonai, kur sistemoje yra daugelis dokumentų ir pagal tai nuskaitoma informacija ir žinoma kur kokia informacija yra, pavyzdžiui kurioje vietoje yra dokumento vardas, kurioje pavardė, taip pats ir veido nuotrauka skirtinguose dokumentuose būna skirtingose pusėse ir informacijos vietas skiriasi pagal dokumento tipą ir šalį, todėl automatiniai sistemai svarbu žinoti, teisingą dokumento šalį bei teisingą dokumento tipą. Turint neteisingą dokumento tipą ir šalį automatinė sistema, dažniausiai nesugeba nuskaityti visai jokios informacijos arba mažiau nei reikalaujamas minimalus informacijos kiekis arba retais atvejais nuskaityti informaciją, bet neteisingai, nes pasirinktoje šalyje gali toje vietoje būti dokumento išdavimo data, o rodomame dokumente gimimo data, tuomet gali vartotojas praeiti procesą su neteisinga informacija.

Klaidos taip pat įmonei kainuoja papildomas išlaidas, kiekvienas dokumento nuskaitymas kainuoja ir jeigu klientas darosi kelis kartus neteisingai pateikdamas informaciją, įmonė už šį klientą gali prarasti daugiau pinigų, nei uždirbti, o tai verslui nėra naudinga. Taip pat, dažniausiai šiuos nenuskaitytus dokumentus turi rankiniu būdu patvirtinti įmonės darbuotojai, kas kainuoja gerokai daugiau nei tai padaryti automatiškai, užtrunka daugiau laiko tai atlikti. Tai įmonei teikiančiai asmens tapatybės patvirtinimą nuotoliniu būdu yra didelės išlaidos, kurios gali būti optimizuotos automatizuojant šią informacijos pasirinkimą ir užkertant kelią žmogiškosios klaidoms. Taip būtų ir pagerintas sistemos vartotojų pajautimas naudojantis sistema, jiems reikėtų atlikti mažiau veiksmų ir būtų išvengta klaidų, kai vartotojai neteisingai pasirenka dokumento šalį bei jo tipą.

Atsižvelgiant į temos aktualumą, tikslinga sukurti intelektinę asmens tapatybės dokumentų atpažinimo sistemą, kuri iš vaizdinės medžiagos nustato dokumento tipą ir šalį. Tam naudoti pažangiausi klasifikavimo metodai. Darbe siekiama užtikrinti geriausią tikslumą, todėl atliekamas tyrimas vaizdų apdorojimo technologijų taikymo asmens tapatybės dokumentų atpažinimo uždaviniui spręsti.

2.5. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos projekto tikslas ir uždaviniai

Darbo tikslas yra suformuotas bendradarbiaujant su UAB „Identifikaciniai projektai“, kurios viena iš opiausių problematikų – klientų klaidos atliekant asmens tapatybės patvirtinimą nuotoliniu būdu. Šiuo metu įmonės klientai naudodamiesi sistema turi rankiniu būdu pasirinkti dokumento tipą ir šalį, tai yra ne tik klientams nepatogu, reikalauja atlikti daugiau veiksmų bet ir sukelia labai daug klaidų, kurios sąlygojamos žmogiškojo klaidos faktorius. Šio programų sistemos projekto tikslas sukurti intelektinę dokumento atpažinimo sistemą, kuri leistų automatiškai identifikuoti asmens tapatybės dokumento tipą ir šalį iš vaizdinės medžiagos, tokiu būdu automatizuojant ir pagreitinant asmens tapatybės patvirtinimo procesą ir sumažinant žmogiškųjų klaidų skaičių, bei leisti ją tobulinti patiems įmonės darbuotojams apmokant su naujais duomenimis.

Uždaviniai:

- atlikti asmens tapatybės dokumento atpažinimo sprendimų analizę išskirti jų privalumus ir trūkumus;
- išanalizuoti tinkamiausius vaizdų klasifikavimo metodus ir jų taikymą automatinio dokumento tipo ir šalies identifikavimui;
- susikurti dokumentų nuotraukų duomenų bazę UAB „Identifikaciniai projektai“ įmonėje, siekiant sistemos apmokymui ir testavimui turėti realių duomenų;

- apmokėti klasifikatorius atpažinti skirtingus dokumento tipus ir išdavimo šalis iš vaizdinės medžiagos;
- įvertinti skirtingų vaizdų klasifikavimo metodų tikslumą naudojant realaus pasaulio duomenis;
- sukurti intelektinę asmens tapatybės dokumentų atpažinimo sistemą veikiančią tiek įmonės serveriuose prijungiant prie įmonės sistemos, tiek darbuotojų kompiuteriuose leidžiančią patikrinti bei iš naujo apmokėti modelius. Sistema gebės automatiškai identifikuoti ir nustatyti dokumento tipą ir šalį iš vaizdinės medžiagos;
- įvertinti kokybę bei greitaveiką atliekant sistemos tyrimą;
- atlikti eksperimentinius tyrimus, leidžiančius įvertinti realizuoto algoritmo tinkamumą dokumento tipo iš šalies atpažinimo uždaviniui iš vaizdinės medžiagos spręsti, bei palyginti skirtingų CNN architektūrų modelių rezultatus.

2.6. Galimų sprendimų apžvalga

2.6.1. Skaitmeninis vaizdas

Skaitmeninis vaizdas (angl. *digital image*) yra padaromas atliekant realios aplinkos fotografiją. Nuotrauka yra skaitmenizuotas duomenų rinkinys, kurį gali suprasti ir perskaityti skaitmeninis kompiuteris ar kitas įrenginys. Atlikta nuotrauka yra sudaryta iš taškų – mažų kvadratų, jie sudaro visą vaizdą. Kiekviename pikselyje yra užkoduota informacija, kuri nusako ryškumą ir spalvą, ši informacija yra skaitine raiška pateikta ir patalpinta dvimačiame masyve, atitinkančiame skaitmeninio vaizdo horizontalią ir vertikalią taškų išsidėstymo poziciją [22].

Sprendžiant uždavinį, kur reikalinga naudoti skaitmeninį vaizdą, reikia jį apdoroti kompiuteriui atliekant daug skirtingų operacijų. Pirmiausia, nuotrauka yra dvimatis masyvas, kur kiekviena taško reikšmė pagal pasirinktą spalvų modelį yra aprašoma, jei naudojama RGB spalvų paletė, naudoja 3 masyvų sluoksnius aprašyti kiekvienam taškui [23].

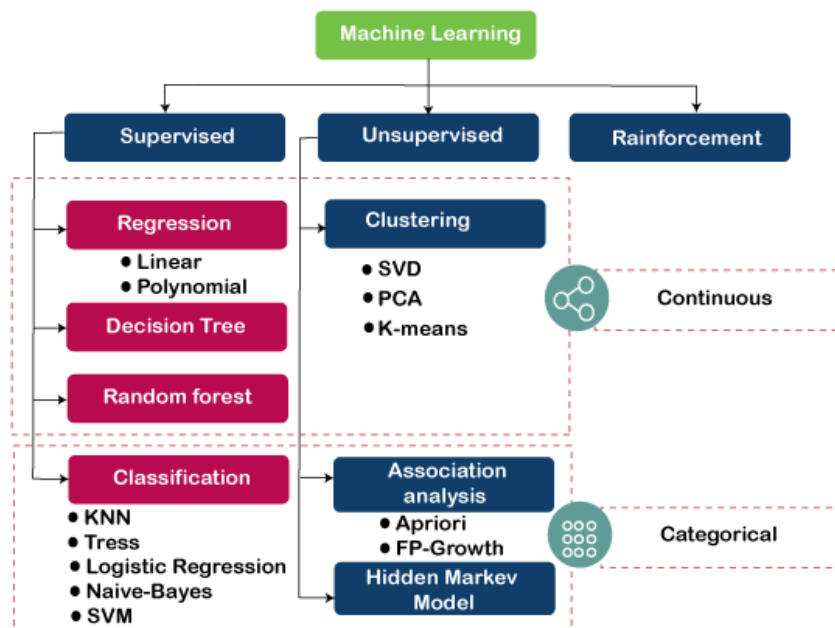
Uždavinių sprendimui dažnai reikalinga apdoroti duomenis, todėl naudojant vaizdus, dažnai keičiamas dydis, pasukimas, pasvirimas, ryškumas, spalvingumas. Daromas vaizdų segmentavimas, randamas slenkstis ir nustatomos briaunos, tuomet jau galima vykdyti objektų atpažinimą išskiriant savybes ir nuotraukoje esantis vaizdas klasifikuojamas į atitinkamą klasę pagal išskirtas savybes [24].

2.6.2. Mašininio mokymo algoritmai

Mašininio mokymo algoritmai (angl. *machine learning algorithms*) sprendimus atlieką iš turimų duomenų ir iš jų mokosi, kad galėtų grąžinti norimą rezultatą. Mašininis mokymas yra skirstomas į du etapus, iš pradžių modelis turi būti apmokomas su duomenimis, o tuomet jau testuojamas su mokymo metu nematytais duomenimis. Apmokymo etape algoritmui paduodami jau transformuoti duomenys, kurie yra apdorojami mašininio mokymo modelio algoritmo ir tuomet duoda rezultatą. Atliekant testavimą, algoritmui nurodomi kiti duomenys, kurie nebuvo pateikti apmokymo metu, ir modelis grąžina rezultatą apdorojus šiuos duomenis [25].

Mašininis mokymas yra skirstomas į tris kategorijas, pagal jo veikimą: prižiūrimo mokymo (angl. *supervised learning*), kita kategorija yra neprižiūrimas mokymas (angl. *unsupervised learning*) ir mokymassu pastiprinimu (angl. *reinforcement*). Sprendžia ir skirtingus uždavinius, todėl pagal duomenų tipą galima priskirti į regresinius ir klasifikavimo uždavinius. Klasifikavimo uždaviniams

spręsti, reikia duomenims priskirti klasę, kuriai duomenys priklauso. Sprendžiant regresijos uždavinius, tiek rezultatai, tiek duomenys dažniausiai yra realiųjų skaičių formato. Žemiau pateiktas vizualus mašininio mokymo algoritmų skirstymas (2.3 pav.).



2.3 pav. Mašininio mokymo algoritmų klasifikavimas [26]

Pirmoji grupė, mokymasis su mokytoju, esminis dalykas, kad kiekviena duomenų imtis turi tikėtiną rezultatą. Algoritmas pastoviai spėja atsakymą naudodamasis turimais duomenis ir šiuos lygina su numatomu atsakymu. Klaidos įvertis yra skaičiuojamas, kiek rezultatas, kuris buvo gautas, neatitinka nuo numatomo rezultato. Modelių mokymas vykdomas tiek, kada yra gaunamas reikiamas modelio tikslumas [27].

Antroji grupė, mokymasis be mokytojo, skiriasi nuo pirmosios, jog apmokymo duomenys nėra sužymėti ir neturi numatomo rezultato. Šio tipo algoritmas nustato šablonus naudodamas tik duomenis įvesčiai ir jie yra sugrupuojami pagal panašumus į grupes, kurias vėliau siekia surasti ir išskirti atitinkamas charakteristikas duomenims. [28].

Trečioji grupė, mokymasis su pastiprinimu, šių algoritmų esmė yra bendravimas tarp mokytojo ir algoritmo, mokytojas algoritmui nusako ar spėjimas buvo teisingas ar ne. Pagal tai ar prognozė buvo teisinga ar neteisinga atitinkamai algoritmas gauna „pagyrimą“ (angl. *reward*) arba „bausmę“ (angl. *penalty*), taip algoritmas žino, ką daro gerai ir ką daro negerai, taip yra didinamas pagyrimų skaičius ir mažinamos bausmės, atitinkamai pasiekiamas ir geresnis rezultatas [29]. Esamo uždavinio sprendimui reikalingas nuotraukų atpažinimas ir klasifikavimas į klases naudojant mašininio mokymo algoritmą. Vaizdų klasifikavimas naudojant mašininį mokymą dažnai sutinkamas daugelyje sistemų. Mašininio mokymo su mokytoju algoritmą kuriamo modelio atveju tikslinga naudoti, kadangi turime realaus pasaulio duomenis su nustatytomis konkrečiomis klasėmis, kokiai duomenų imtis dokumentų tipų klasei priklauso ir kokiai šaliai. . Prižiūrimų ML algoritmų yra daug, vienas iš jų yra dirbtiniai neuroniniai tinklai (angl. *Artificial Neural Networks*), taip pat ir konvoliuciniai neuroniniai tinklai (angl. *Convolutional Neural Networks*), bei sprendimų medžiai (angl. *decision trees*) ir atsitiktiniai miškai (angl. *random forests*), vektorinės atramos mašinos (angl. *Support Vector Machines*) [27]. Remiantis teorija, su kiekvienu iš aukščiau pateiktų algoritmų galima sukurti modelį,

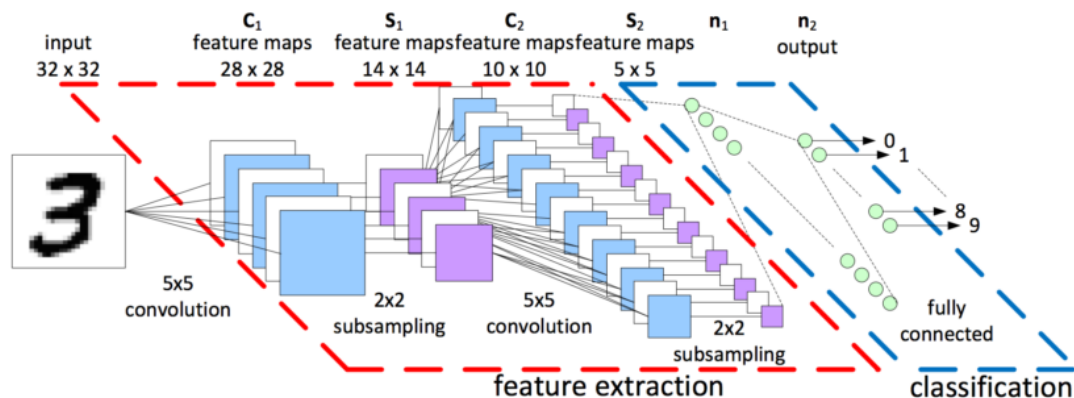
klasifikuoti nuotraukas pagal dokumento tipą ir šalį, tačiau nuo algoritmo priklauso tiek rezultatų tikslumas bei laikas pateikti atsakymui. Vykstant apmokymui ML algoritmai naudojami pateiktais duomenimis ir rezultatai, bandomi skirtingi parametrai, siekia pasiekti įvesties ir išvesties duomenų priklausomybę ir atlikti atitinkamą adaptaciją prie duomenų. Algoritmams turi didelę įtaką duomenų dydis, įvairovė, imtis, nuo to priklauso modelio tikslumas ir vykdymo laikas. Dažniausiai naudojami mašininio mokymosi algoritmai, naudojami nuotraukų klasifikacijai yra pateikti žemiau.

2.6.3. Dirbtiniai neuroniniai tinklai

ANN daug kur taikomi vykdant įvairių klasifikavimo ir prognozavimo uždavinių sprendimus. Tinklai sukurti remiantis žmogaus smegenų veiklą, bandant atkartoti kompiuteryje smegenyse veikiančius biologinius procesus. Pagrindas ANN yra dirbtiniai neuronai, kurie yra abstraktūs biologinių neuronų matematiniai modeliai, paremti konvoliucijos principu. ANN modelių sukurta yra daug [30]. Mažiausiai sudėtingas - tiesioginio sklidimo modelis, tai dirbtinių neuronų rinkinys, kurie sujungti vienas su kitu į paslėptus, išvedimo ir įvedimo sluoksnius. Naudojant tokį tinklo modelį, jame informacija keliauja tik viena kryptimi iš vieno sluoksnio į kitą, pagal eilę ir ten vyksta informacijos apdorojimas [31]. Dirbtiniai neuroniniai tinklai turi skirtingų modifikacijų, kurios ilgą laiką taikomos veidams atpažinti [32], kalbos nustatyme [33], įvairaus teksto kūrimui ir analizavimui, parenkant tikslias reklamas vartotojams ir kitose srityse. Šie tinklai pasižymi dideliu tikslumu, kadangi sudega ranka rašytus skaitmenis atpažinti 97% tikslumu [34]. Dirbtinių neuroninių tinklų metodas taikomas plačiai įvairiems uždaviniams spręsti: orų prognozavimui [35], šablonų atpažinimui [36], saulės energijos sistemų modeliavimui [37], saulės radiacijos nuspėjimui [38], teksto aptikimui [39].

2.6.4. Konvoliuciniai neuroniniai tinklai

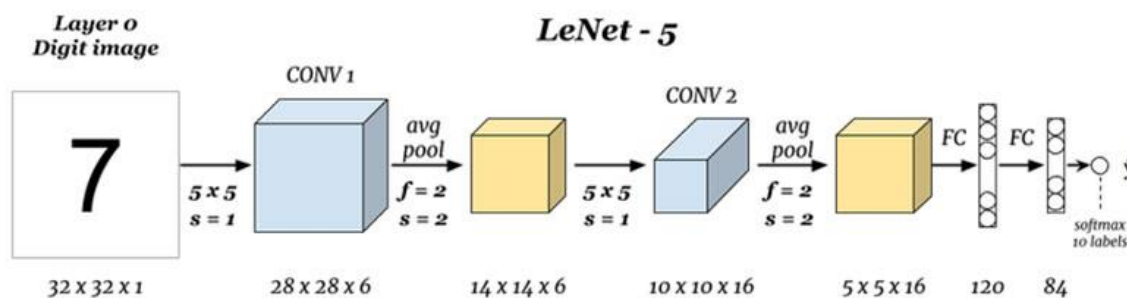
Konvoliuciniai neuroniniai tinklai (angl. *Convolutional Neural Networks*, toliau CNN) dažniausiai naudojamam dirbtinių tinklų modifikacija [40]. Ši modifikacija yra giliojo mokymo (angl. *deep learning*) metodas, kuris leidžia apjungti savybių gavimo ir ML etapus. Konvoliuciniai neuroniniai tinklai lyginant su įprastais neuroniniais tinklais sunaudoja mažiau darbinės atminties ir yra paprasčiau apmokomi bei galima pasiekti didesnę tikslumą, o duomenų netolygumai, kaip duomenis klasifikuojam, turi gerokai mažiau įtakos tinklo rezultatams, tokie kaip skirtingas objektų spalvingumas, šviesa ar dydis [40]. Konvoliucinio neuroninio tinklo veikimas pavaizduotas žemiau pateiktame paveiksle (2.4 pav.) . Svarbiausius bruožus iš vaizdinės medžiagos konvoliucinis sluoksnis. Sumažinimo sluoksnis (angl. *pooling layer*) sumažina vaizdą išsaugant pagrindinę informaciją. Pilnai sujungtas sluoksnis (angl. *fully connected*), apskaičiuoja išvesties rezultatą iš gautų išskirtų pagrindinių bruožų, kurio veikimas yra toks, kaip daugiasluoksnio perceptrono.



2.4 pav. CNN veikimo principas [42]

Didėjant kompiuteriniams resursams ar mažėjant jų kainai, galimybė naudoti galingesnius kompiuterius duomenų apdorojimui, todėl kuriami vis galingesni ir tikslesni neuroninių tinklų modeliai, tai leidžia naudoti blogesnės kokybės nuotraukas. Būtent dėl šių priežasčių konvoliuciniai neuroniniai tinklai dažnai naudojami vaizdų klasifikavimo ir atpažinimo uždaviniams spręsti. Naudojant šį tinklą, galima ranka parašytus skaitmenis atpažinti taip pat gerai, kai taip atlieka žmogus [43]. Klasifikuojant nedidelius dešimties klasių vaizdus iš CIFAR10 duomenų bazės, galima pasiekti beveik 86% procentų tikslumą naudojant tik 2GB darbinės atminties, tačiau neribojant atminties galima pasiekti didesnę nei 93% tikslumą [44]. Naudojant „ImageNet“ apmokytas CNN klasifikatorius su 1.2 milijonų aukštos kokybės nuotraukomis, gali atpažinti 1000 skirtingų klasių 83% procentų tikslumu, šis neuroninis tinklas turi 60 milijonų parametrų ir 650 tūkstančių neuronų [45].


Konvoliucinio neuroninio tinklo architektūros yra kuriamos pastoviai spręsti realaus pasaulio problemas. „LeNet“ buvo pirmoji sėkmingai sukurta architektūra 1990 metais, kuri buvo naudojama skaityti pašto kodus, skaičius ir kitą. Naujausia versija yra „LeNet-5“, kuri turi 5 sluoksnių CNN, taip galima pasiekti 99,2% tikslumą atspausdintų simbolių atpažinime [46]. Žemiau pateiktame (2.5 pav.) paveiksle pavaizduota „LeNet - 5“ tinklo architektūra.



2.5 pav. „LeNet – 5“ tinklo architektūra [47]

Šią architektūrą sudaro du konvoliuciniai sluoksniai, tuomet du mažinimo sluoksniai ir 2 pilnai sujungtų neuronų sluoksniai. Lyginant su šiuolaikinėmis tinklų architektūromis, šios klasinės didžiausias minusas, jog ji priima tik mažas nuotraukas 32x32 pikselių, juodai baltas nuotraukas, dėl to tai geriausiai tinka simbolių atpažinimui.

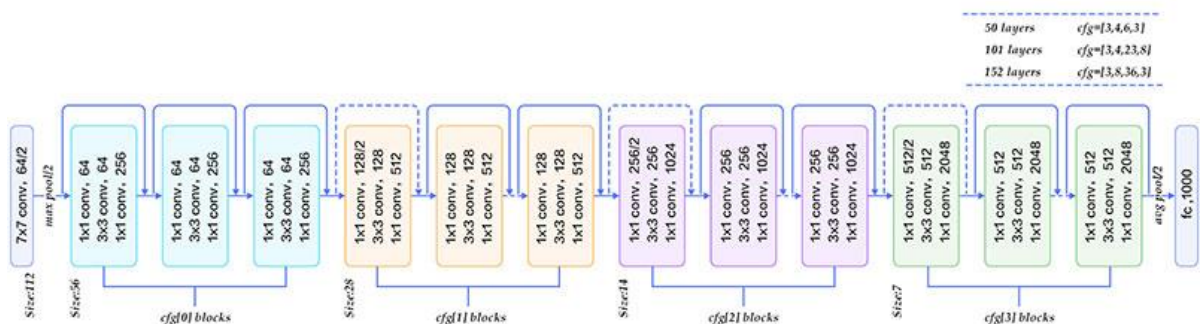
„AlexNet“ gerokai naujesnis ir galingesnis tinklas, kuris 2012 metais laimėjo „ImageNet“ vizualinio atpažinimo konkursą. Žemiau pateikta tinklo architektūra (2.6 pav.).



2.6 pav. „AlexNet“ tinklo architektūra [48]

„AlexNet“ architektūra yra panaši į „LeNet“ tik turi penkis konvoliucinius sluoksnius ir tris pilnai sujungtus neuronų sluoksnius, tik turi 650 tūkstančių neuronų ir 60 mln parametrų. Priima didesnius vaizdus 227x227 pikselių tai leidžia išskirti daugiau bruožų iš nuotraukų taip sprendžiant sudėtingesnius uždavinius. Susidomėjimas ir vystymas CNN padidėjo po „AlexNet“ architektūros atsiradimo [49].

„ResNet“ tinklo architektūra sukurta „Microsoft“, pasiekus 96.6% tikslumą šis modelis 2016 metais laimėjo „ImageNet“ konkursą abiejuose klasifikavimo ir aptikimo uždaviniuose. Žemiau pateiktame paveiksle (2.7 pav.) pavaizduota „ResNet“ tinklo architektūra.




2.7 pav. „ResNet“ tinklo architektūra [50]

Šis tinklas yra ypatingai gilus su 152 sluoksniais. Pagrindinis dalykas norint mokyti tokį gilų tinklą yra praleisti ryšius: į sluoksnį tiekiamas signalas pridodamas į sluoksnį ir taip pat pridodamas prie sluoksnio išvesties, kuris yra šiek tiek aukščiau steko (angl. *stack*). „ResNet“ yra sukurta iš vadinamojo likutinio bloko. Kada naudojamas paprastas neuroninis tinklas, šio modelio svoris yra labai mažas, dėl to, ir rezultatai pateikiami artimi nuliui. Liekamojo bloko tapatybės funkciją lengva išmokyti ir dėl šio praleidimo ryšio (l - sluoksnis, a - aktyvinimas) lengva gauti [l + 2] lygu a [l]. Ir tai reiškia, kad šių dviejų sluoksnių pridėjimas į mūsų neuroninį tinklą tikrai nepakenkia jo sugebėjimui taip pat, kaip ir paprastesniame tinkle be šių dviejų papildomų sluoksnių, nes jam gana lengva išmokyti tapatybės funkciją tik nukopijuojant [l] iki [l + 2], nepaisant šių dviejų sluoksnių pridėjimo. Taigi pridėjus šį liekamąjį bloką kažkur šio didelio neuroninio tinklo viduryje ar gale, tai nepakenks


našumui. Priešingai, tai pagerina našumą. Gilius neuroninius tinklus sunku treniruoti dėl nykstančių ir sprogsančių gradientinių problemų. Bet „ResNet“ su šiomis praleidžiamosiomis jungtimis leidžia perimti suaktyvinimą iš vieno sluoksnio ir staiga jį perduoti į kitą sluoksnį neuroniniame tinkle [84]. Skirstant atgal, pereinamasis ryšys pereis ir gradiento atnaujinimą. Konceptualiai šis atnaujinimas veikia panašiai kaip sintetinio gradiento tikslas. Užtuot laukę, kol gradientas pasklis po vieną sluoksnį, praleisdami ryšio kelią, gradientas gali pasiekti tuos pradinius mazgus didesniu mastu, praleisdamas kai kuriuos sluoksnius tarp jų [51].

„VGG-16“ ir „VGG-19“ tinklo architektūros yra gerokai gilesnės nei „AlexNet“ Paprasčiausias būdas pagerinti neuroninių tinklų veikimą yra jų dydžio padidėjimas. VGG (angl. *Visual Geometry Group*) išrado VGG-16, kuris turi 13 konvoliucinių ir 3 visiškai sujungtus sluoksnius, nešdamas „AlexNet“ „Relu“ aktyvavimo funkciją [84]. Žemiau pateiktame paveiksle (2.8 pav.) pavaizduota „VGG-16“ neuroninio tinklo architektūra.



2.8 pav. „VGG-16“ tinklo architektūra [52]


Be to, jis perėmė sluoksnių kaupimo tradiciją iš „AlexNet“, tačiau naudoja mažesnio dydžio filtrus (2×2 ir 3×3). Jis susideda iš 138 milijonų parametrų ir užima apie 500 MB vietos [84]. Vėliau buvo sukurtas dar gilesnis tinklas vadinamas „VGG-19“ - yra konvoliucinis neuroninis tinklas, kuris yra 19 sluoksnių gylyje ir gali klasifikuoti vaizdus į 1000 objektų kategorijų, tokių kaip klaviatūra, pelė ir daugelis gyvūnų. Modelis treniravosi iš daugiau nei milijono vaizdų iš „ImageNet“ duomenų bazės 92% tikslumu [85]. Žemiau pateiktame paveiksle (2.9 pav.) yra pavaizduota „VGG-19“ tinklo architektūra.



2.9 pav. „VGG-19“ tinklo architektūra [53]

Šią architektūrą sudaro 16 konvoliucinių sluoksnių ir 3 pilnai sujungtų neuronų sluoksniai. Pirmas conv1 turi gylį 64 (3, 3) kvadratinius filtras. Visuose „VGG-19“ konv. Sluoksniuose naudojami (3, 3) filtrai ir kad filtrų skaičius padidėja dviejų (64, 128, 256, 512) galingumu. Visuose „Conv“ sluoksniuose žingsnio ilgis naudojamas 1 (pikselis), o kiekvienoje pusėje - 1 (pikselis). Yra 5 konvoliuciniai sluoksniai. Sluoksnių rinkiniai, 2 iš jų turi 64 filtras, kitame rinkinyje yra 2 konvoliuciniai sluoksniai. Sluoksniai su 128 filtrais, kitame rinkinyje yra 4 konvoliuciniai sluoksniai. Sluoksniai su 256 filtrais, o kituose 2 rinkiniuose yra po 4 konvoliucinius sluoksnius. Sluoksnius su 512 filtrais. Tarp kiekvieno konvoliucinio sluoksnių rinkinio yra maksimalūs kaupimo sluoksniai. maksimaliuose kaupimo sluoksniuose yra 2x2 filtrai, kurių žingsnis yra 2 (taškų). Paskutinio kaupiamąjo sluoksnio išėjimas yra suplotas tiekiamas į visiškai sujungtą sluoksnį su 4096 neuronais. Išėjimas eina į kitą visiškai sujungtą sluoksnį su 4096 neuronais, kurių išvestis yra tiekiamas į kitą visiškai sujungtą sluoksnį su 1000 neuronų. Visi šie sluoksniai yra suaktyvinti ReLU. Galiausiai yra „softmax“ sluoksnis, kuris naudoja kryžminio entropijos praradimą (angl. *Cross-Entropy loss*) [54].

„Inception“ ir „GoogLeNet“ tinklo architektūra, „GoogLeNet“ (arba „Inception v1“) (2.10 pav.) gylis yra 22 sluoksniai. 93,3% tikslumu šis modelis laimėjo 2014 m. „ImageNet“ varžybas abiejų klasifikavimo ir aptikimo užduotyse. Tai buvo labai arti žmogaus lygio pasirodymo, kurį iššūkio organizatoriai dabar buvo priversti įvertinti. Kaip paaiškėjo, tai iš tikrųjų buvo gana sunku padaryti ir tam reikėjo šiek tiek išmokyti žmonių, kad būtų galima įveikti „GoogLeNets“ tikslumą. Po kelių dienų mokymo ekspertas Andrej Karpathy sugebėjo pasiekti 5 geriausių klaidų lygį - 5,1% (vienas modelis) ir 3,6% (bendrai). Tinklas naudojo CNN, panaudojant „LeNet“, tačiau įdiegė naują elementą, kuris yra vadinamas pradiniu moduli. Jis naudojo paketinį normalizavimą, vaizdo iškraipymus ir „RMSprop“ – optimizacijos algoritmą. Šis modulis yra pagrįstas keliomis labai mažomis konvulsijomis, kad būtų galima smarkiai sumažinti parametų skaičių. Jų architektūra susidėjo iš 22 sluoksnių gylio CNN, tačiau sumažino parametų skaičių nuo 60 milijonų („AlexNet“) iki 4 milijonų [87].



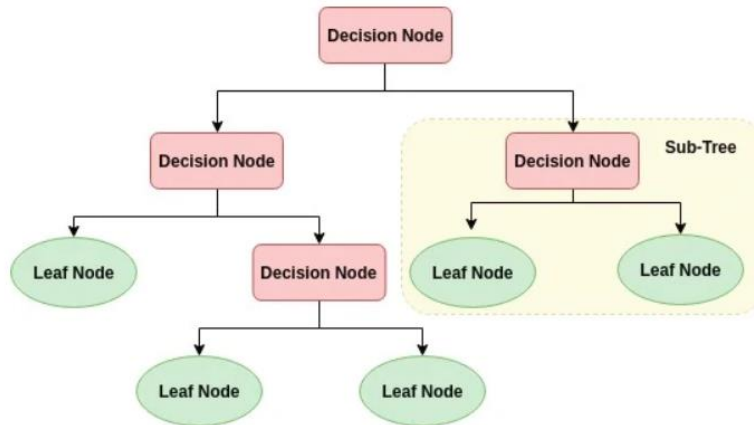
2.10 pav. „GoogLeNet“ tinklo architektūra [55]

Šios pagalbinių klasifikatorių architektūrinės detalės: Vidutinis 5×5 dydžio filtro ir 3 žingsnio sujungimo sluoksnis. 1×1 konvekcija su 128 filtrais matmenų mažinimui ir „ReLU“ aktyvavimui. Visiškai prijungtas sluoksnis su 1025 išėjimais ir „ReLU“ aktyvavimu Atmetimo reguliavimas, kai atmetimo koeficientas = 0,7 „Softmax“ klasifikatorius, turintis 1000 klasių, išleidžiamas panašiai kaip pagrindinis „softmax“ klasifikatorius [56].

Vaizdų atpažinimo uždaviniai šiai dienai yra taikomi labai plačiai, pramonėje, medicinoje, transporto srautų valdyme, saugume 1. Konvoliuciniai neuroniniai tinklai plačiai taikomi įvairiems uždaviniams spręsti, net tik vaizdų atpažinimo uždaviniams: autonomiam vairavimui [57], didelės greitaveikos ranka rašytų Kinų simbolių atpažinimui pasiekia 96.74% tikslumą [58], objektų sekimui iš vaizdinės medžiagos [59], hiper spektrinio vaizdo klasifikacijai [60], medicinoje atliekamų nuotraukų segmentavimui [61], ypač plačiai naudojama veidų atpažinimui iš nuotraukų ar „CCTV“ – vaizdo stebėjimo kamerų [62], asmens tapatybės dokumentų klasifikavimui ir lokalizavimui [63] ir taip pat teksto atpažinimo uždaviniams spręsti [64].

2.6.5. Sprendimų medžiai

Sprendimų medžiai naudojami prognozavimo ar klasifikavimo uždaviniams spręsti, yra populiarus ir galingas metodas. Sprendimų medis sudarytas iš pagrindinės, sprendimo ir lapinės viršūnių. Visi duomenys yra pagrindinėje viršūnėje (angl. *root node*). Duomenys padalinami į dvi ar daugiau dalių, jei viršūnės dar skirstosi į daugiau viršūnių, tuomet šios tampa sprendimų viršūnėmis. Žemiausiai yra lapinės viršūnės (angl. *leaf nodes*), kai daugiau jau nesidalina [65]. Sprendimų medžio veikimo principo pavyzdys pateiktas (2.11 pav.).




2.11 pav. Sprendimų medžio veikimo diagrama [66]

Pateiktame paveiksle pavaizduotas sprendimų medis duomenų klasifikavimui, kiekvienas medžio lapas nusako konkretų bruožą, kuris buvo atrinktas sprendimo mazge ir taip nuo viršaus einama žemyn kol prieinama iki konkretaus lapo, kuris nusako atitinkamą bruožą. Sprendimų medis tinka spręsti duomenų klasifikavimo uždavinius. Sprendimų medžio metodas dažnai naudojamas įvairiems uždaviniams spręsti: Parkinsono ligai nustatyti naudojant balso įrašą [67], gedimų nustatymui saulės fotovoltinėse matricose [68].

2.6.6. Atsitiktiniai miškai

Keli sprendimų medžiai sudaro atsitiktinius miškus. Nustatyti kuri yra klasė galima apskaičiuojant medžių rezultatų vidurkį arba naudojamas balsavimo principas, kuris yra gerokai sudėtingesnis, tuomet išvesties klasė nustatoma paskaičiuojant kuri klasė kartojasi daugiausiai sprendimų medžiuose, pavyzdys pateiktas (2.12 pav.).




2.12 pav. Atsitiktinių miškų diagrama [69]

Paveiksle pateikta, jog duomenys išskirstyti po lygiai sprendimų medžiams ir iš kiekvienos imties gaunami rezultatai, kai gaunami visi rezultatai apskaičiuojamas vidurkis, ir atitinkamai perskaičiuojami rezultatai, juos padarant vienodai svarbiais taip nusprendžiamas galutinis atsakymas,

kurie rezultatai pasikartoja daugiausiai. Duomenys išskaidomi į homogenines aibes, yra padalinami į dvi ar daugiau homogeninių aibių, remiantis pačiu svarbiausiu įvesties duomenyse esančiu skyrikliu. Sprendimo medžiai, kurie yra bendri, mokomi padalinant kiekvieną viršūnę, sumažinant pasiskirstymą klasių. Atsitiktinis miškas iš pradžių išskiria bruožus ir tai naudoja rezultatui gauti vykdant balsavimą [70]. Atsitiktinių miškų metodas taikomas duomenų klasifikavimo uždaviniams spręsti: miško pelkių klasifikavimui [71], žemės dangos klasifikavimui [72], sveikų ir alkoholio priklausomybę turinčių žmonių skirstymas naudojant ramybės būsenos „MRT“ rezultatus [73], kenkėjiškų programų - virusų aptikimas „Android“ įrenginiuose [74].

2.6.7. Vektorinės atramos mašinos

Vektorinės atramos mašinos (angl. *Support Vector Machines*) taikomos regresijos, objektų klasifikavimui ir atpažinimui uždavinių sprendimui. Atraminio vektoriaus mašina konstruoja hiper plokštumą ar hiper plokštumų rinkinį didelės arba begalinės dimensijos erdvėje, kuri gali būti naudojama klasifikacijai, regresijai ar kitoms uždavimams. Intuityviai gerą atskyrimą pasiekia hiper plokštuma, turintis didžiausią atstumą iki artimiausio bet kurios klasės mokymo duomenų taško (vadinamasis funkcinis skirtumas), nes apskritai kuo didesnė marža, tuo mažesnė klasifikatoriaus apibendrinimo klaida [75], [86]. Žemiau pateiktas vektorinės atramos mašinos duomenų klasifikavimo pavyzdys (2.13 pav.) hiper plokštumoje klasifikatorius bando surasti tiesę (sprendimo ribą) tokią, kuri turėtų didžiausią atstumą tarp jos ir taškų priklausančių skirtingoms klasėms. Atraminiais vektoriai, tai šie taškai, pagal kuriuos yra priimamas sprendimas.



2.13 pav. Atramos vektorių mašinos duomenų klasifikavimas [76]

Dažnai skirtingų klasių duomenys negali būti tiesiškai atskirti, todėl reikia naudoti įvairias branduolio funkcijas, su kuriomis galima duomenis paversti į kitą erdvę, kurioje galima atskirti į dvi klases tiesiškai [77]. Vaizdų klasifikavimui naudojant vektorines atramos mašinas, galima pasiekti beveik 90% tikslumą [78].

Vektorinės atramos mašinos metodas taikomas daugelyje duomenų klasifikavimo uždavinių: EMG signalų klasifikavimui neuromuskulinių sutrikimų diagnostikai [79], iš vaizdinės medžiagos kenkėjų nustatymas [80], homogeniškų duomenų klasifikavimui [79] scenarijaus teksto simbolių atpažinimui [81], automobilių aptikimui [82], asmens tapatybės dokumentų klasifikavimui [83].

2.7. Įgyvendinimo problemos

Dokumentai daugelyje šalių yra panašūs, todėl gali iškilti problemų tiksliai nustatant dokumento šalį. Dokumento tipų skirtingų yra daug ir kiekvienoje šalyje yra ne po vieną, gali neužtekti duomenų tinkamai apmokyti visose norimose šalyse.

Nuotraukų kokybė gali turėti įtakos sprendimo priėmimui, todėl sudėtinga gali būti užtikrinti teisingą nustatymą, kai nuotraukų kokybė yra prasta. Gali būti naudojami seni dokumentai, kurie yra dar galiojantys, bet jų įmonė turi labai mažai ir gali nepavykti aptikti šių dokumentų.

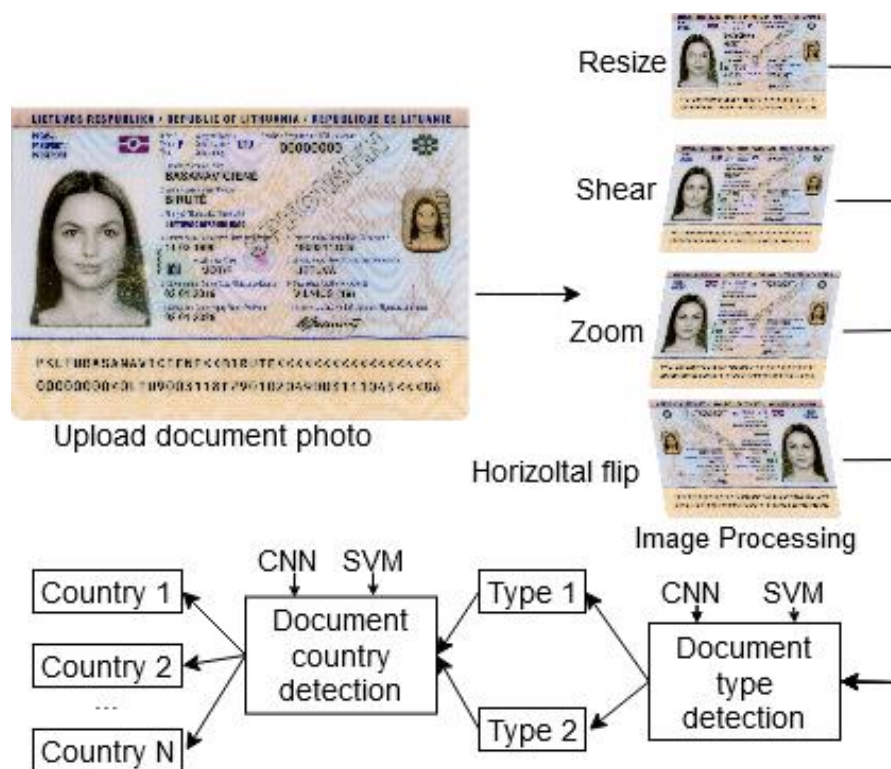
2.8. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos realizacijai pasirinkti sprendimai

2.8.1. Metodiniai aspektai

Kuriant intelektinę asmens tapatybės dokumentų atpažinimo sistemą, siekiant nustatyti dokumento tipą ir šalį iš vaizdinės medžiagos ir norint praktiškai įvertinti skirtingų vaizdų klasifikavimo metodų tinkamumą dokumentų klasifikavimo uždaviniui spręsti. Pasirinkta realizuoti atsitiktinių miškų, sprendimų medžio, CNN ir SVM metodus. Išskirti du uždaviniai, pirmas nustatyti dokumento tipą, antras, jau žinant dokumento šalį nustatyti dokumento šalį ir šią informaciją gražinti į užsakovo sistemą ar grafinę vartotojo sąsają.

2.8.2. Techniniai aspektai

Iš užsakovo sistemos ar grafinės vartotojo sąsajos gaunama nuotrauka, kurioje pateiktas asmens tapatybės dokumentas. Iš pradžių yra nustatome, koks tai dokumento tipas yra ID kortelė ar pasas, vėliau pagal aptiktą dokumento tipą nustatoma dokumento šalis. Vartotojas naudodamas sistemos grafinę versiją, gali ne tik sužinoti dokumento tipą ir šalį, bet ir naudoti skirtingus mašininio mokymo algoritmus, skirtingus ištreniuotus modelius, šiuos modelius ištestuoti pasirinkus testavimo duomenis. Yra galimybė peržiūrėti sistemos greitaveiką bei kiekvieno spėjimo rezultatus bei pažiūrėti nuotrauką, taip patikrinti ar sistema nustatė sėkmingai, pagal tai atitinkamai galima ištreniuoti naują modelį su atrinktais duomenimis ir vėl testuoti, taip siekiant leisti sistemos naudotojui, net ir po sistemos sukūrimo, pačiam nesunkiai tobulinti sistemos veikimą, apmokant modelius su naujais duomenimis. Žemiau pateiktame paveiksle (2.14 pav.) pavaizduotas sistemos veikimas, nustatant iš vaizdinės medžiagos dokumento tipą iš šalį.



2.14 pav. Sistemos veikimo logika, asmens tapatybės dokumento tipo ir šalies aptikimui

Kaip pateiktame paveiksle, pirmiausiai yra įkeliamas nuotrauka, kurioje yra pateiktas asmens tapatybės dokumentas, tuomet vykdomas nuotraukos apdorojimas, pakoreguota nuotrauka pateikiama pirmajam modeliui, kur atitinkamai pagal pasirinktą algoritmą naudojamas konvoliucinio neuroninio tinklo ar vektorinės atramos mašinos ištreniruotas modelis, tuomet nustatytas dokumento tipas ir nuotrauka yra perduodama kitam modeliui, kuris nustato šalį ir taip sistema pateikia dokumento šalį ir tipą esančio nuotraukoje.

Sistemai realizuoti buvo pasirinkta „Python“ programavimo kalba ypač populiari naudojant mašininio mokymo algoritmus. Naudojant šią programavimo kalbą atitinkamai buvo pasirinkta programavimo aplinkos įrankis „Pycharm“ ypač galingas ir populiarus, leidžiantis greitai ir patogiai rašyti programinį kodą, bei greitai rasti klaidas. Serverio daliai kaip programavimo karkasas buvo pasirinktas „Django“ naudojamas HTTP užklausoms siųsti ir jas priimti. Kliento daliai, sukurti grafinę vartotojo sąsają pasirinktas taip pat „Python“ programavimo kalbos karkasas „PyQt“ tinkamiausias šios kalbos karkasas norint sukurti kliento dalį vartotojo kompiuteryje vykdomą programą. Mašininio mokymo algoritmų realizavimui naudota „TensorFlow“ ir „Keras“ atviro kodo bibliotekos, lyderiaujančios tarp „Python“ mašininio mokymosi bibliotekų.

2.9. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos analitinės dalies išvados

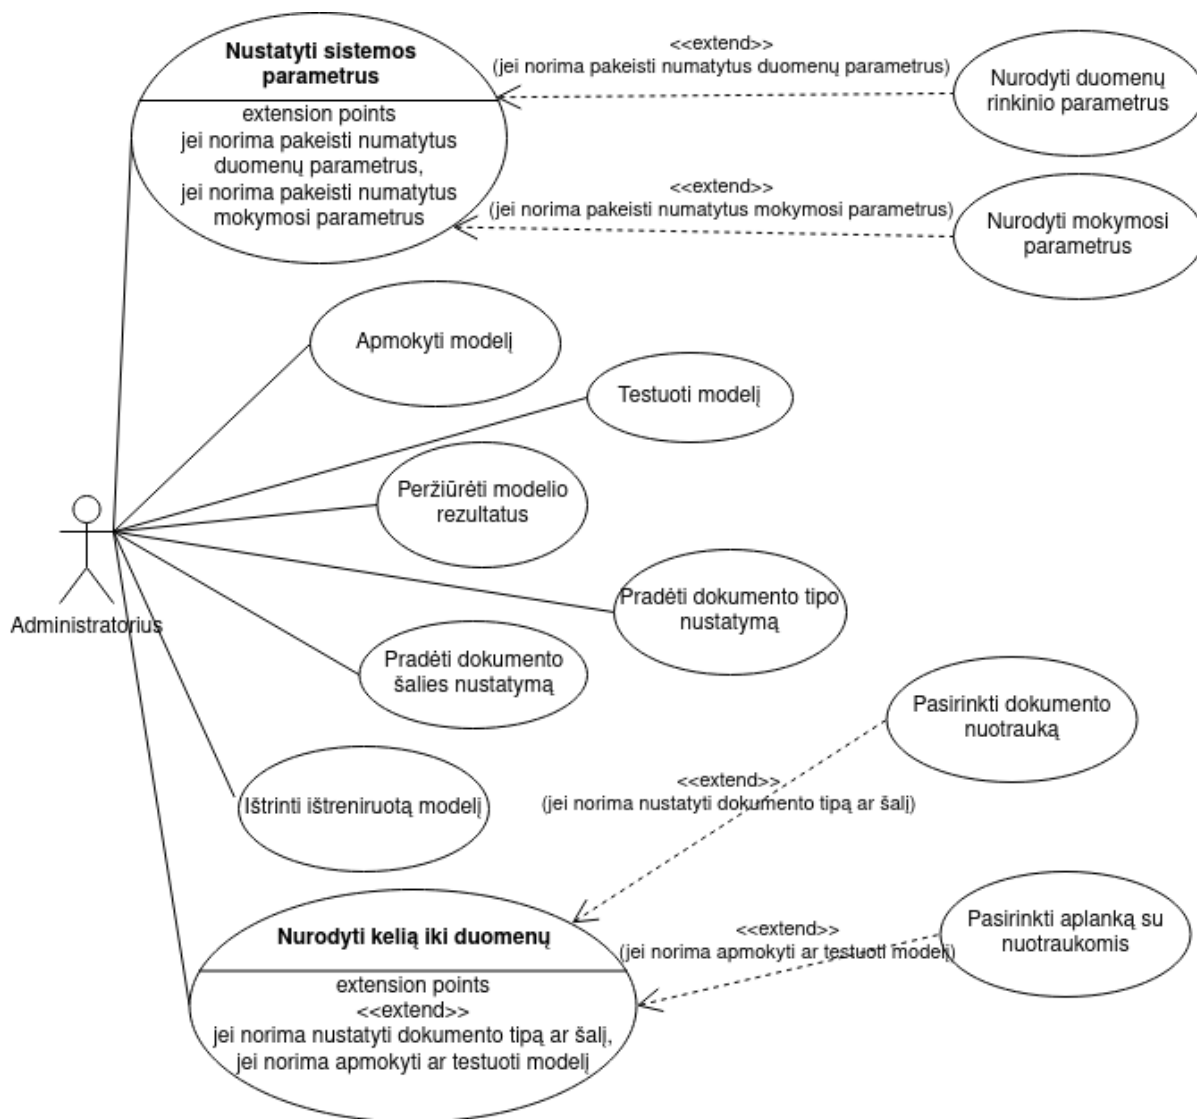
1. Išanalizavus temos tikslumą ir aktualumą, suformuotas intelektinės asmens tapatybės dokumentų atpažinimo sistemos projekto tikslas, ir pateikti uždaviniai.
2. Atlikus užsakovo sistemos analizę, nustatius dažniausias klaidas bei įvertinus galimus sprendimus, nustatytas pagrįstas poreikis kuriamos sistemos bei svarbiausios sistemos savybės.
3. Įvertinus mašininio mokymo algoritmų analizės rezultatus, numatyti atlikti praktinį CNN, SVM, atsitiktinių miškų ir sprendimų medžio metodų palyginimą sprendžiant asmens tapatybės dokumentų klasifikavimo uždavinį.

4. Atsižvelgiant į konvoliucinių neuroninių tinklų modelio apmokymo laiką sistemai pasirinkta naudoti eksperimentiniu keliu sudarytą architektūrą ir modifikuojant kuo geriau pritaikyti uždaviniui spręsti atsižvelgiant į modelio dydį, tikslumą ir apmokymo laiką, keičiant ne tik hiper parametrus bet ir sluoksnius ar jų skaičių.
5. Išanalizavus pagrindines šio uždavinio sprendimo problemas, buvo nuspręsta išskaidyti klasifikavimą į du etapus, pirmiausiai nustatant dokumento tipą, o vėliau dokumento šalį, taip sistemai leidžiant pasiekti didesnę rezultatų tikslumą.
6. Pasirinkti intelektinės asmens tapatybės dokumentų atpažinimo sistemos realizacijai techniniai ir metodiniai ir techniniai aspektai.

3. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos projektinė dalis

3.1. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos panaudojimo atvejais

Intelektinė asmens tapatybės atpažinimo sistemos kūrimo metu, numatyta dvylika panaudojimo atvejų, kurie pavaizduoti žemiau pateiktoje diagramoje (3.1 pav.). Šie panaudojimo atvejai detalizuoti žemiau pateiktose 3.1 – 3.12 lentelėse.



3.1 pav. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos panaudojimo atvejų diagrama

3.1 lentelė PA „Nustatyti sistemos parametrus“ specifikacija

<p>1. PANAUDOJIMO ATVEJIS: Nustatyti sistemos parametrus Vartotojas/Aktorius: Administratorius Aprašas: Administratorius gali nustatyti sistemos parametrus. Prieš sąlyga: Sistema yra paleista; Sužadinimo sąlyga: Administratorius nori pakeisti numatytuosius sistemos parametrus. Po-sąlyga: Sistema leidžia pasirinkti duomenų rinkinio ar apmokymo parametrus norima keisti.</p>
--

3.2 lentelė PA „Nurodyti duomenų rinkinio parametrus“ specifikacija

2. PANAUDOJIMO ATVEJIS: Nurodyti duomenų rinkinio parametrus
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali nustatyti duomenų rinkinio parametrus.
Prieš sąlyga: Administratorius turi būti pasirinkęs nustatyti sistemos parametrus;
Sužadinimo sąlyga: Administratorius nori pakeisti duomenų rinkinio parametrus.
Po-sąlyga: Sistema treniruoja modelį su naujais duomenų rinkinio parametrais.

3.3 lentelė PA „Nurodyti mokymosi parametrus“ specifikacija

3. PANAUDOJIMO ATVEJIS: Nurodyti mokymosi parametrus
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali pakeisti mokymosi parametrus
Prieš sąlyga: Administratorius turi būti pasirinkęs nustatyti sistemos parametrus;
Sužadinimo sąlyga: Administratorius nori pakeisti mokymosi parametrus. Po-sąlyga: Sistema treniruoja modelį su naujais parametrais.

3.4 lentelė PA „Apmokyti modelį“ specifikacija

4. PANAUDOJIMO ATVEJIS: Apmokyti modelį
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali apmokyti modelį su naujais duomenimis.
Prieš sąlyga: Sistema yra paleista ir pasirinktas mašininio mokymo algoritmas;
Sužadinimo sąlyga: Administratorius pasirenka apmokymą.
Po-sąlyga: Sistema apmoko naują modelį.

3.5 lentelė PA „Testuoti modelį“ specifikacija

5. PANAUDOJIMO ATVEJIS: Testuoti modelį
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali ištestuoti bet kurią ištreniruotą sistemoje esantį modelį.
Prieš sąlyga: Sistema yra paleista ir pasirinktas mašininio mokymo algoritmas;
Sužadinimo sąlyga: Administratorius pasirenka testavimą.
Po-sąlyga: Gaunami testavimo rezultatai.

3.6 lentelė PA „Peržiūrėti modelio rezultatus“ specifikacija

6. PANAUDOJIMO ATVEJIS: Peržiūrėti modelio rezultatus
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali pažiūrėti testavimų istoriją kiekvieno modelio kiek buvo testuota, laikas, duomenų kiekis gauti rezultatai ir atskiri failai analizei.
Prieš sąlyga: Pasirinktas mašininio mokymo algoritmas;
Sužadinimo sąlyga: Administratorius pasirenka rezultatų peržiūra.
Po-sąlyga: Atvaizduojami testavimo rezultatai.

3.7 lentelė PA „Pradėti dokumento tipo nustatymą“ specifikacija

7. PANAUDOJIMO ATVEJIS: Pradėti dokumento tipo nustatymą
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali pasirinkti dokumento tipo nustatymą.
Prieš sąlyga: Pasirinktas algoritmas;
Sužadinimo sąlyga: Pasirenkamas dokumento tipo nustatymas.
Po-sąlyga: Grąžinamas dokumento tipas.

3.8 lentelė PA „Pradėti dokumento šalies nustatymą“ specifikacija

8. PANAUDOJIMO ATVEJIS: Pradėti dokumento šalies nustatymą
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali pasirinkti dokumento šalies nustatymą. Prieš sąlyga: Pasirinktas algoritmas;
Sužadinimo sąlyga: Pasirenkamas dokumento šalies nustatymas.
Po-sąlyga: Grąžinama dokumento šalis.

3.9 lentelė PA „Ištrinti ištreniuotą modelį“ specifikacija

9. PANAUDOJIMO ATVEJIS: Ištrinti ištreniuotą modelį
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali pasirinkti ištreniuoto modelio pašalinimą;
Sužadinimo sąlyga: Pasirenkamas modelio pašalinimas.
Po-sąlyga: Ištrinamas pasirinktas modelis.

3.10 lentelė PA „Nustatyti kelią iki duomenų“ specifikacija

10. PANAUDOJIMO ATVEJIS: Nustatyti kelią iki duomenų
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali pasirinkti kelią savo kompiuteryje iki duomenų;
Sužadinimo sąlyga: Pasirenkamas duomenų įkėlimas
Po-sąlyga: Atidaromas failo ar aplanko pasirinkimo langas.

3.11 lentelė PA „Pasirinkti dokumento nuotrauką“ specifikacija

11. PANAUDOJIMO ATVEJIS: Pasirinkti dokumento nuotrauką
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali pasirinkti dokumento nuotrauką;
Sužadinimo sąlyga: Pasirenkamas nuotraukos pasirinkimas.
Po-sąlyga: Nuotrauka įkeliami į sistemą.

3.12 lentelė PA „Pasirinkti aplanką su nuotraukomis“ specifikacija

12. PANAUDOJIMO ATVEJIS: Pasirinkti aplanką su nuotraukomis
Vartotojas/Aktorius: Administratorius
Aprašas: Administratorius gali pasirinkti duomenis apmokymui;
Sužadinimo sąlyga: Pasirenkamas duomenų apmokymui ar testavimui įkėlimas.
Po-sąlyga: Įkeliami į sistema pasirinkti duomenys.

3.2. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos funkciniai reikalavimai

Žemiau pateiktose lentelėse (3.13 – 3.17) nurodyti intelektinės asmens tapatybės dokumentų atpažinimo sistemos funkciniai reikalavimai.

3.13 lentelė FR-1 specifikacija

Reikalavimas	FR-1	Reikalavimo tipas	V	PA	5,6,7,8
Aprašymas	Turi būti galimybė administratoriui ištrinti jo apmokytus naujus modelius, kad jei tik bandėsi, jog neprisikauptų per laiką labai daug.				
Pagrindimas	Šis funkcionalumas bandyti įvairius apmokymus ir pašalinti nepavykusius bandymus				
Šaltinis	Užsakovas				
Atitikimo kriterijus	Galima ištrinti apmokytus modelius.				

3.14 lentelė FR-2 specifikacija

Reikalavimas	FR-2	Reikalavimo tipas	V	PA	1
Aprašymas	Sistemoje turi būti galimybė permokyti modelį su naujais duomenimis, jog sistema veiktų ir su naujais dokumentais, pridėdant daugiau tipų ar šalių.				
Pagrindimas	Šis funkcionalumas leistu nesunkiai atnaujinti sistemos veikimą, kadangi pasikeitus dokumentams, norint nustatyti daugiau tipų ar apmokyti su daugiau duomenų, sistemai apmokyti reikėtų tik naujų duomenų iš naujo perdaryti nereikėtų.				
Šaltinis	Užsakovas				
Atitikimo kriterijus	Sistemą galima apmokyti iš naujo po jos sukūrimo				

3.15 lentelė FR-3 specifikacija

Reikalavimas	FR-3	Reikalavimo tipas	V	PA	5,6,7,8
Aprašymas	Administratorius turi galėti pakartotinai atlikti identifikavimą				
Pagrindimas	Šis funkcionalumas leistu pakartotinai identifikuoti tipą ir šalį iš nuotraukos.				
Šaltinis	Užsakovas				
Atitikimo kriterijus	Galima iš naujo identifikuoti tą patį dokumentą.				

3.16 lentelė FR-4 specifikacija

Reikalavimas	FR-4	Reikalavimo tipas	V	PA	2
Aprašymas	Visų testavimų rezultatai turėtų būti saugomi istorijoje.				
Pagrindimas	Administratorius turi turėti galimybę peržiūrėti jau darytus testavimus ir palyginti rezultatus..				
Šaltinis	Užsakovas				
Atitikimo kriterijus	Administratorius gali matyti testavimų rezultatus				

3.17 lentelė FR-5 specifikacija

Reikalavimas	FR-5	Reikalavimo tipas	V	PA	8
--------------	------	-------------------	---	----	---

Aprašymas	Sistema nustatydamą tipą ir šalį informaciją, turi gražinti JSON formatu.
Pagrindimas	Šis funkcionalumas leistu iškart pateikti suprantamai informaciją įmonės sistemai.
Šaltinis	Užsakovas
Atitikimo kriterijus	Informacija gražinama nustatytu formatu.

3.3. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos nefunkciniai reikalavimai

Sistemai nustatyti nefunkciniai reikalavimai pagal *Volere* šabloną pateikti žemiau esančiose 3.18 – 3.22 lentelėse.

3.18 lentelė NFR-1

Reikalavimas	NFR-1	Reikalavimo tipas	V10	PA	1-4
Aprašymas	Vartotojo sąsaja turi būti aiški ir kuo mažiau papildomos informacijos.				
Pagrindimas	Kad administratoriui norint apmokyti sistemą ar atlikti testavimą iki jo būti atlikta kuo mažiau veiksmų, kad administratorius ilgai neužtruktų.				
Šaltinis	Sistemos užsakovas.				
Atitikimo kriterijus	Turėtų būti 2 žingsniai pasirinkti testavimą arba apmokymą.				

3.19 lentelė NFR-2

Reikalavimas	NFR-2	Reikalavimo tipas	V11	PA	1-3
Aprašymas	Sistema turi būti lengva naudotis.				
Pagrindimas	Jeį sistema sunku naudotis administratorius ilgai užtruks testuodamas ar apmokydamas sistemą.				
Šaltinis	Sistemos užsakovas.				
Atitikimo kriterijus	Visas procesas iki testavimo ar apmokymo pradžios turėtų vykti nuosekliai, kad nebūtų praleidžiamas žingsnis.				

3.20 lentelė NFR-3

Reikalavimas	NFR-3	Reikalavimo tipas	V12	PA	5-8
Aprašymas	Sistema negali analizuoti nuotraukos ilgiau nei 7s.				
Pagrindimas	Sistema turi veikti greitai.				
Šaltinis	Sistemos užsakovas.				
Atitikimo kriterijus	Nuotrauka išanalizuojama per mažiau nei 7s.				

3.21 lentelė NFR-4

Reikalavimas	NFR-4	Reikalavimo tipas	V12	PA	5
Aprašymas	Sistema turėtų apdoroti jpeg ir png formato nuotraukas.				
Pagrindimas	Palaikyti daugiau nei vieną formatą, jog neapriboti sistemos.				
Šaltinis	Sistemos užsakovas.				
Atitikimo kriterijus	Sistema priima jpeg ir png nuotraukas				

3.22 lentelė NFR-5

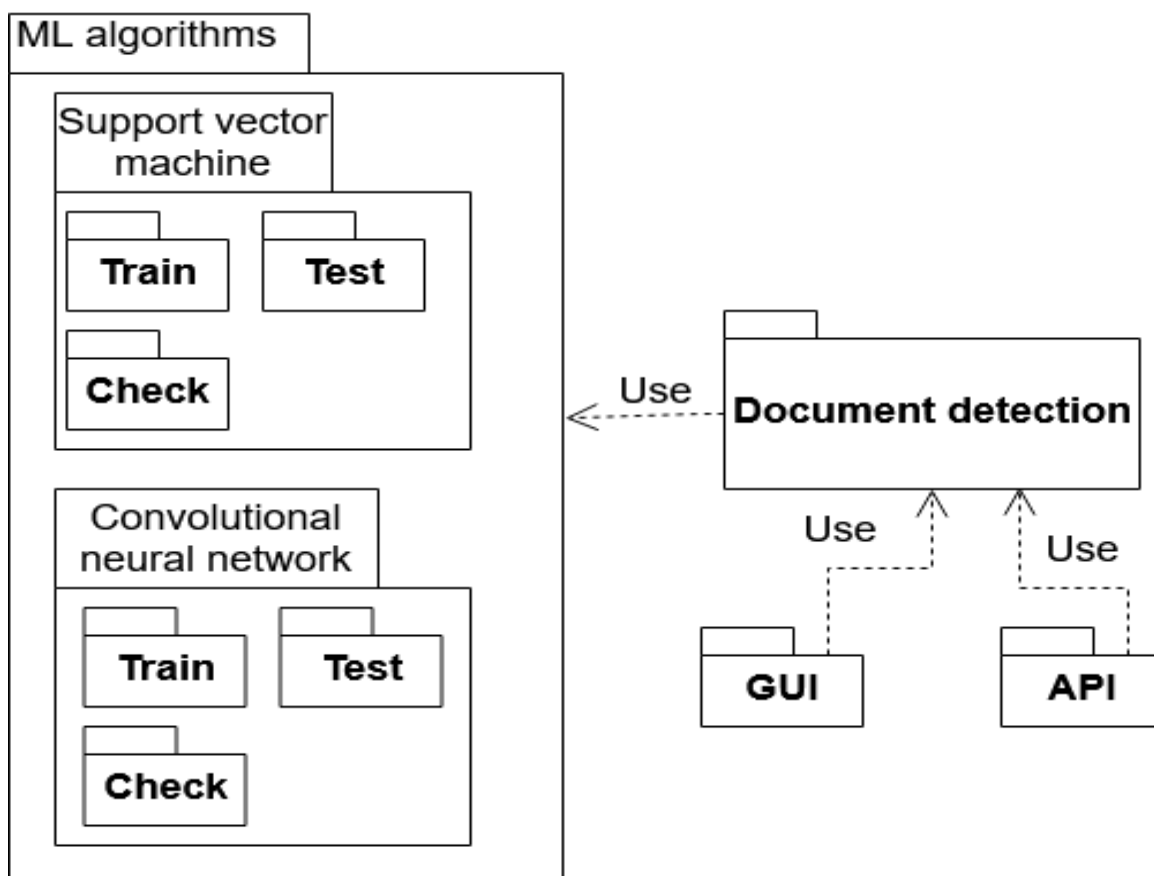
Reikalavimas	NFR-5	Reikalavimo tipas	V12	PA	1-3
Aprašymas	Sistema turėtų priimti tik nustatytus nuotraukų formatus				
Pagrindimas	Sistema turi būti atspari klaidoms.				
Šaltinis	Sistemos užsakovas.				
Atitikimo kriterijus	Jeigu nuotraukos yra kito formato, sistema turėtų konvertuoti paveikslėlį, o jei nepavyksta parodyti klaidą ir gražinti tuščius rezultatus.				

3.4. Sistemos architektūra

Šiame poskyryje pateikiama intelektinės asmens tapatybės dokumentų atpažinimo sistemos architektūra, žemiau skyreliuose pateikta detalizuota architektūros informacija.

3.4.1. Sistemos statinis vaizdas

Intelektiniai asmens tapatybės dokumentų atpažinimo sistemai realizuoti numatyti keturi paketai, kurie atvaizduoja atskiras sistemos dalis: grafinė, serverio dalis, dokumentų aptikimo ir mašininio mokymo algoritmų paketai (3.2 pav.).



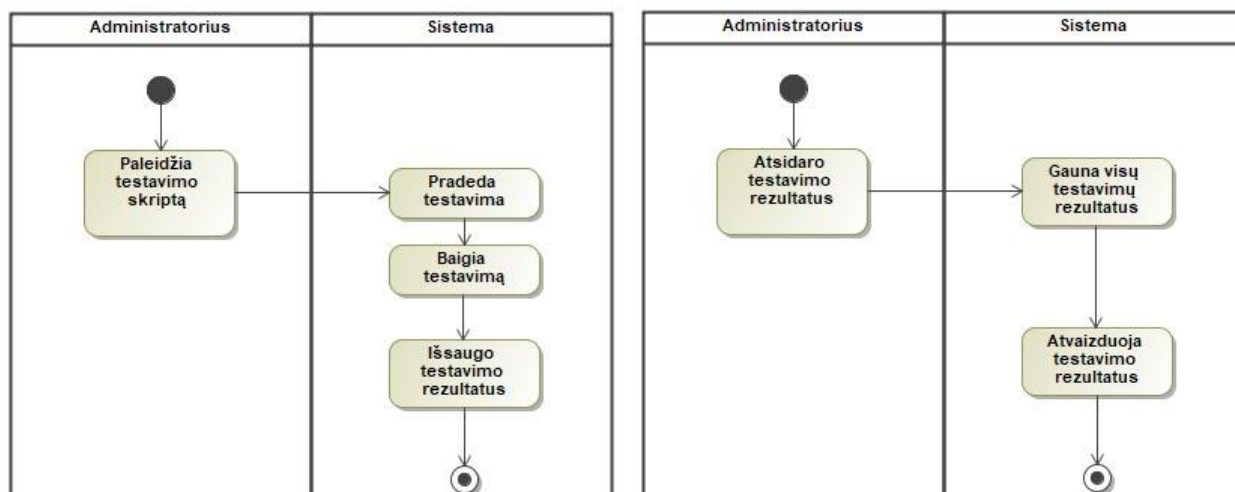
3.2 pav. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos paketų diagrama

3.5. Sistemos dinaminis vaizdas

Sistemos naudotojas įsijungęs sistemos grafinę sąsają gali apmokyti nauja mašininio mokymo modelį parinkęs naujus duomenis, taip pat gali pasirinkęs testavimo duomenis paleisti pasirinkto algoritmo ir ištreniuoto modelio veikimą. Po testavimo, vartotojas gali peržiūrėti, kiek laiko užtruko testavimas, koks gautas tikslumas ir peržiūrėti kiekvieną sistemos spėjimą ir kokia buvo nuotrauka. Atliekant modelių apmokymą, vartotojas gali keisti įvairius sistemos parametrus atitinkamai nuo pasirinkto mašininio mokymo algoritmo, ištreniuotus modelius, kurie neatitiko poreikio, vartotojas gali ištrinti. Taip pat grafinėje sąsajoje, kaip ir serverio dalyje atliekamas pagrindinis sistemos funkcionalumas, įkėlus nuotrauką nustatomas dokumento tipas ir šalis.

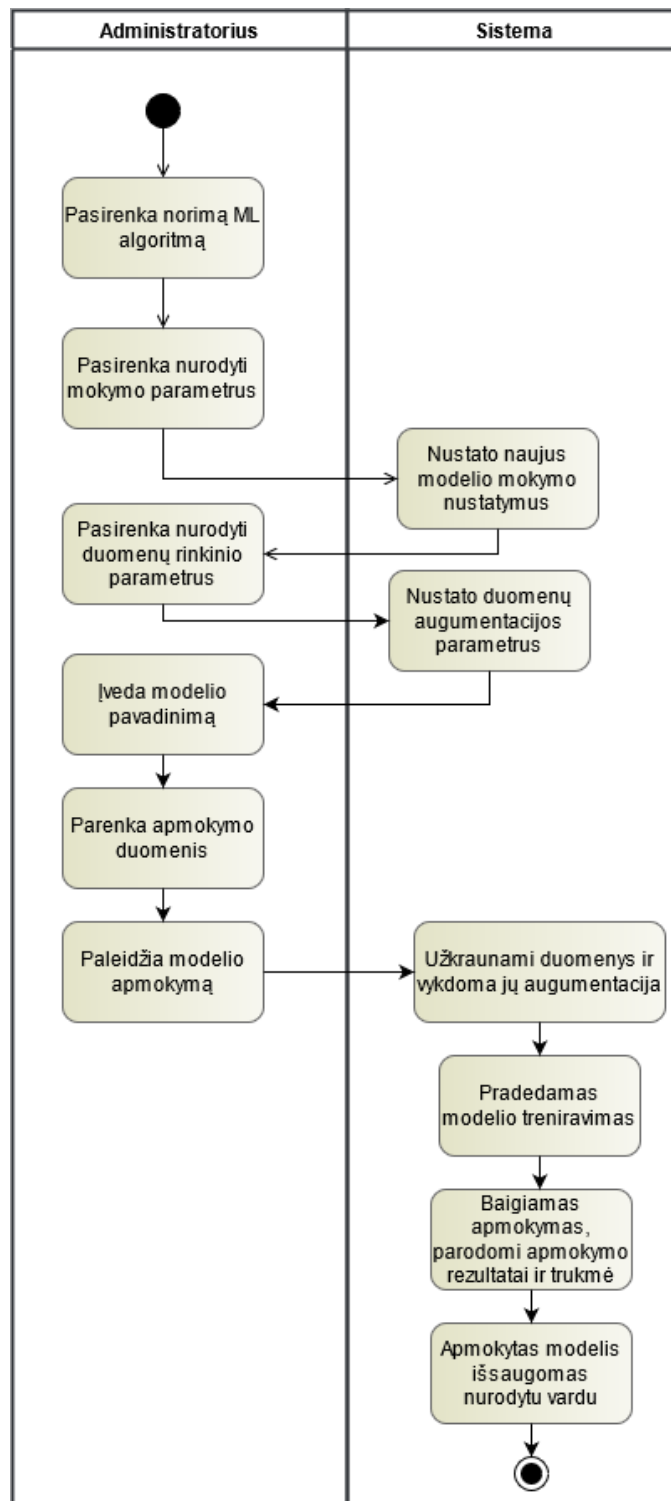
Dinaminis sistemos vaizdas pateiktas veiklos diagramomis. Šios pateikia sistemos panaudojimo atvejų vykdymo scenarijus (3.3 – 3.6 pav.), kurie atspindi pagrindinį sistemos funkcionalumą.

Žemiau esančiame paveiksle (3.3 pav.) nurodomos PA „Testuoti modelį“ ir PA „Peržiūrėti modelio rezultatus“ veiklos diagramos. Pirmoji nurodo, kai vyksta modelio testavimas, administratorius paleidęs testavimą, po kurio laiko mato testavimo rezultatus, šiuos rezultatus gali peržiūrėti naudodamas grafinę sąsają pasirinkdamas rezultatų langą ir pasirinkęs konkretaus testavimo rezultatus mato duomenų kiekį, testavimo trukmę ir gautą rezultatą, tikslumą, taip pat, gali peržiūrėti kiekvieną nuotrauką ir matyti modelio spėjimą.



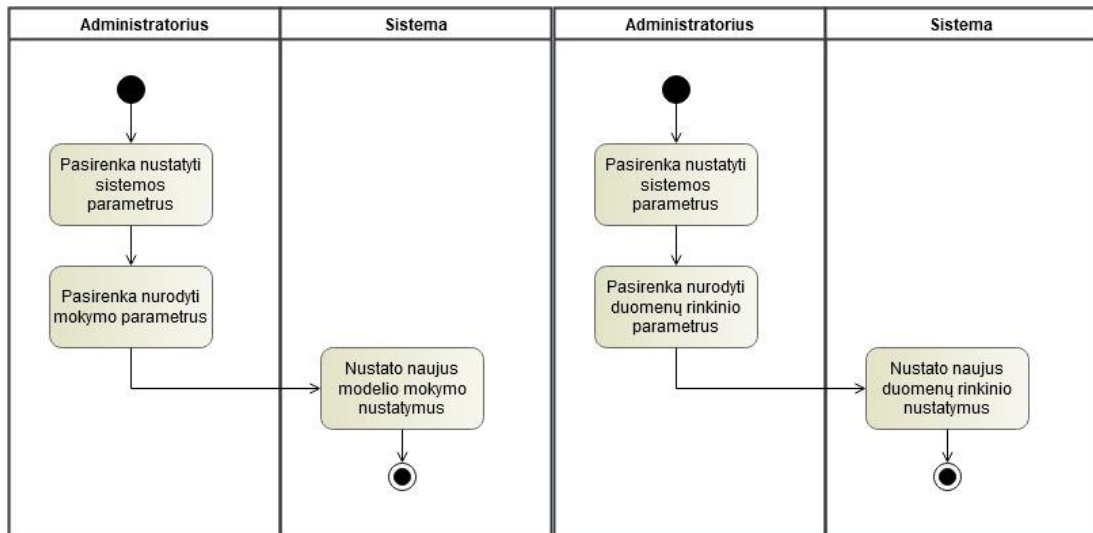
3.3 pav. PA „Testuoti modelį“ ir PA „Peržiūrėti modelio rezultatus“ veiklos diagramos

3.4 pav. pateikta PA „Apmokyti modelį“ veiklos diagrama nurodanti kaip yra apmokomas mašininio mokymo algoritmo modelis. Administratorius pirmiausia pasirenka ML algoritmą, nurodo apmokymo ir augmentacijos nustatymus, įveda modelio pavadinimą, parenka duomenis ir paleidžia apmokymą, tuomet sistema užkrauna duomenis, vykdo augmentaciją, pradeda apmokymą, pabaigus grąžina rezultatus administratoriui ir išsaugo ištreniuotą modelį nurodytu vardu.



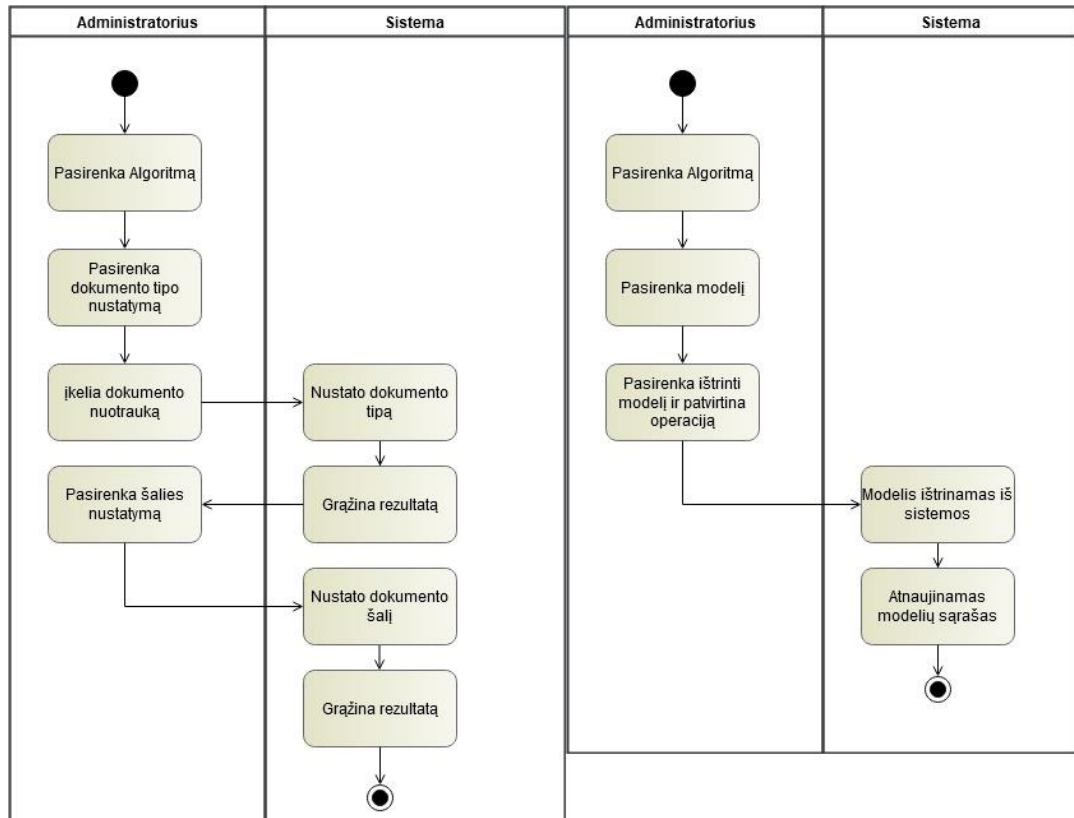
3.4 pav. PA „Apmokyti modelį“ veiklos diagrama

PA „Nurodyti mokymosi parametrus“ ir PA „Nurodyti duomenų rinkinio parametrus“ veiklos diagramos nurodomos 3.5 pav. vaizduoja, kaip administratorius nustato modelio mokymo ir duomenų rinkinio nustatymus.



3.5 pav. PA „Nurodyti mokymosi parametrus“ ir PA „Nurodyti duomenų rinkinio parametrus“ veiklos diagramos

Pateikti panaudojimo atvejai nurodantys veiklos diagrama, kaip atliekamas dokumento atpažinimas. Pirmiausia pasirenkamas ML algoritmas, tuomet pasirenkamas dokumento tipo nustatymas, įkeliama nuotrauka, sistema grąžina dokumento tipą, toliau administratorius pasirenka šalies nustatymą ir sistema pagal anksčiau aptiktą dokumento tipą, aptinką šio tipo šalį ir rezultatą bei aptikimo laiką parodo sistemos naudotojui. Taip pat 3.6 pav. pateikiama, kokie veiksmai reikalingi sistemoje, norint ištrinti jau apmokytą ML modelį.



3.6 pav. Kairėje, bendra PA „Pradėti dokumento tipo nustatymą“ ir PA „Pradėti dokumento šalies nustatymą“, o dešinėje . PA „Ištrinti ištreniruotą modelį“ veiklos diagrama

3.6. Sistemos funkcijos

Šiame poskyryje pateikiama informacija apie sistemą ir jos turimas funkcijas, bei pagrindinių funkcijų grafinės versijos vaizdas (3.7 – 3.10 pav.).

3.6.1. Apie sistemą

Intelektinė asmens tapatybės dokumentų atpažinimo sistema padeda automatizuoti dokumento tipo ir šalies nustatymą prieš atliekant informacijos nuskaitymą, tai labai svarbu įmonės, kuriai kuriama programa, prieš pradėdant informacijos nuskaitymo procesą automatiškai nustatyti dokumento tipą ir šalį. Kadangi dabar įmonėje šiuos veiksmus duodama atlikti patiems klientams, tačiau, klientai dažnai pasirenka netinkamą dokumento tipą ir/ar dokumento šalį ir taip automatiškai nepavyksta nuskaityti dokumento informacijos ir tai turi atlikti žmonės rankiniu būdu, kas atima daug laiko ir kainuoja brangiau, negu, jog tai aptiktų sistema ir būtų išvengta klientų klaidų. Ši sistema nesunkiai gali būti apmokyta su naujais duomenimis, ištestuojama ir taip pat gali būti naudojami keli mašininio mokymo algoritmai. Sistema yra taip paruošta, jog pridėti naują mašininio mokymo algoritmą būtų paprasta ir sistema dinamiškai leistų vartotojui pasirinkti naują algoritmą. Taip pat, naudojantis šia sistema galima apmokyti modelius atpažintis, kad ir visiškai kitus objektus, pavyzdžiui ar nuotraukoje yra dokumentas ar veidas ar tiesiog ar nuotraukoje yra norimas objektas ar kažkas kita. Sistemos pagrindinė funkcija nustatyti dokumento tipą ir šalį, tačiau pritaikyti galima daug plačiau, tik sistemos naudotojui reikia turėti duomenų ir būti susipažinus su sistema. Taip pat sistema naudojama yra skirtingam tikslui, vienas yra vartotojui su grafine sąsaja, kitas yra serveriui kreipiantis į sistemą gauti atsakymą, koks tai dokumento tipas ar šalis, kai jau žinomas dokumento tipas. Sistema su vartotojo sąsaja turi būti įdiegta kompiuteryje, o naudojant integracijai su esama įmonės sistema, patalpinta serveryje, kur sistemos bendraus per HTTP užklausas.

3.6.2. Pagrindinės sistemos funkcijos

Sistemoje yra šios pagrindinės funkcijos:

Dalis su vartotojo sąsaja:

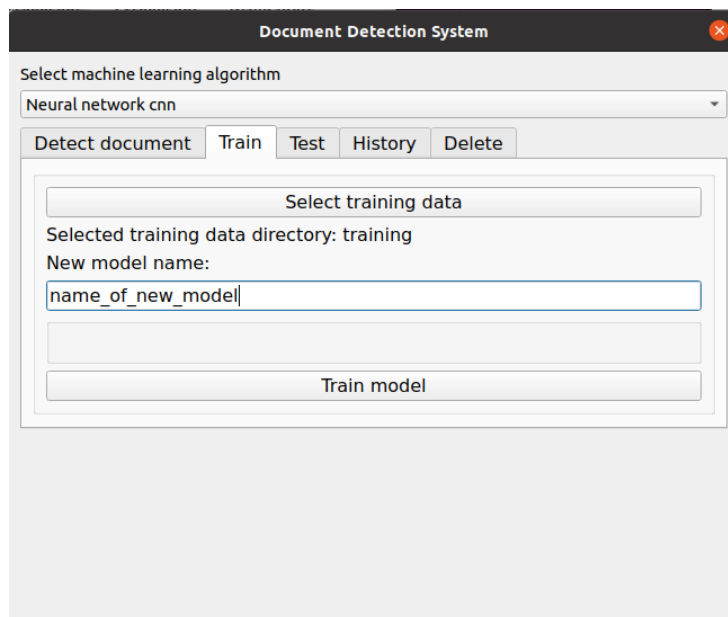
- Dokumento nuotraukos įkėlimas.
- Dokumento tipo nustatymas iš nuotraukos.
- Dokumento šalies nustatymas iš nuotraukos.
- Mašininio mokymo modelio pasirinkimas.
- Sistemos apmokymas su naujais duomenimis.
- Sistemos apmokymas su pasirinktu mašininio mokymo algoritmu.
- Sistemos esamų ar naujų modelių testavimas su pasirinktais duomenimis.
- Sistemos testavimas naudojant skirtingus mašininio mokymo algoritmus.

Serverio dalis:

- Nuotraukos užkrovimas.
- Mašininio mokymo algoritmo pasirinkimas.
- Išreniruoto modelio pasirinkimas.
- Dokumento tipo nustatymas iš nuotraukos.
- Dokumento šalies nustatymas iš nuotraukos.

3.6.3. Modelio apmokymas

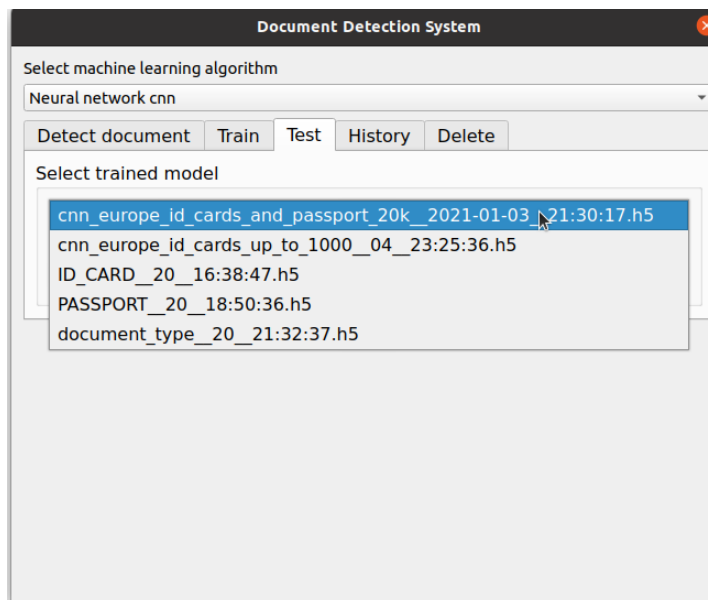
Pasirinkus duomenis, įvedamas norimas pavadinimas naujam modeliui ir spaudžiamas mygtukas „Train model“ (3.7 pav.).



3.7 pav. Modelio pavadinimo įvedimo langas.

3.6.4. Apmokyto modelio pasirinkimas

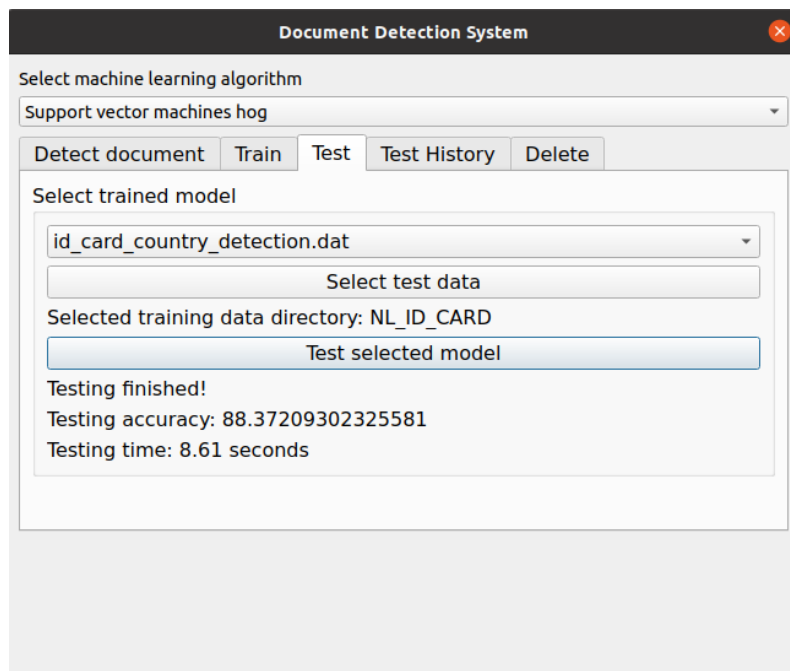
Pasirinkus algoritmą, paspaudus mygtuką „Test“ galima matyti apmokytų modelių pasirinkimą. Pasirinkus modelį galima pasirinkti duomenis testavimui paspaudus mygtuką „Select data“ (3.8 pav.).



3.8 pav. Modelio pasirinkimo testavimui langas.

3.6.5. Testavimo rezultatai

Paleidus modelio testavimą, kai jis yra baigiamas parodomi testavimo rezultatai ir koks yra modelio tikslumas su pasirinktais duomenimis (3.9 pav.).



3.9 pav. Testavimo rezultatų langas.

3.6.6. Dokumento tikrinimas

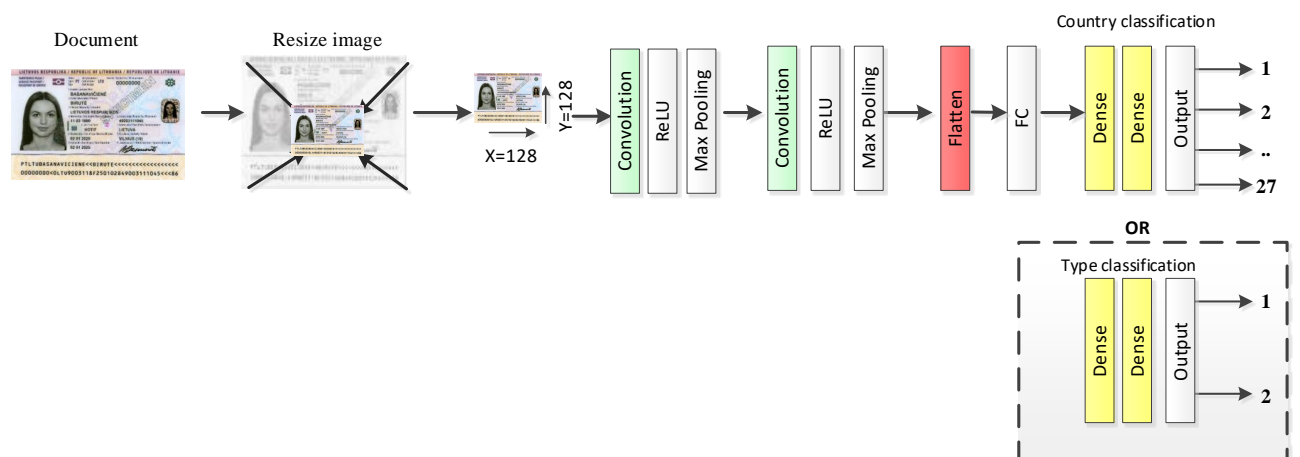
Paspaudus mygtuką „Detect document“ atidaromas nuotraukos pasirinkimo langas ir atsiranda mygtukas „Detect document“, kurį paspaudus tikrinamas koks tai dokumento tipas arba pagal pasirinkimus „Detect type“ ir „Detect country“ (3.10 pav.).



3.10 pav. Dokumento tikrinimo langas.

3.7. Konvoliucinių neuroninių tinklų architektūra

Atsižvelgiant į apmokymo laiką, sistemą buvo pasirinkta realizuoti su siūloma CNN architektūra. Žemiau pateiktame paveiksle (3.11 pav.) pavaizduota sistemoje naudojama CNN architektūra.



3.11 pav. CNN architektūra

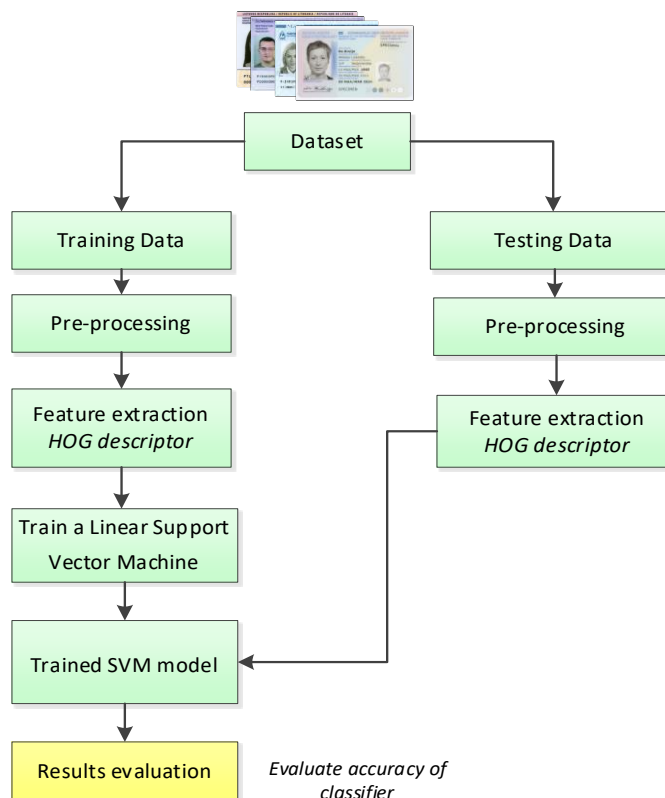
Architektūra sudaryta iš dviejų „Convolution“, „ReLU“ ir „Max Polling“ sluoksnių, tuomet atliekamas „Flatten“, „Fully Connected“ ir dviejų „Dense“ su „softmax“ aktyvacijos funkcija, sluoksnių ir gaunama išvestis. Naudojamas paketo dydis 32 (angl. *batch size*), įvesties dydis 128x128, apmokymui naudojama 30 epochų. Praradimo skaičiavimui naudojama „binary crossentropy“ ir „Adam“ optimizatorius su mokymo žingsniu (angl. *learning rate*) 0.001. Taikytas duomenų imties

didinimas (angl. *data augmentation*), naudojant parametrus: „rescale=1./255“, „shear_range=0.25“, „zoom_range=0.15“, „horizontal_flip=True“.

Modelio rezultatai yra atitinkamai arba dokumento tipo klasės arba dokumento šalys.

3.8. Vektorinės atramos mašinos veikimas

Žemiau pateiktame paveiksle (3.12 pav.) pavaizduota SVM metodo diagrama.



3.12 pav. SVM veikimo diagrama

Pirmiausiai duomenų imtis padalinama į mokymo ir testavimo imtis, vėliau atliekamas nuotraukų apdorojimas, tuomet išskiriami bruožai naudojami „HOG“ deskriptorių. Išskyrus bruožus atliekamas SVM modelio apmokymas, naudojant linijinį (angl. *linear*) branduolį (angl. *kernel*), tuomet naudojant testavimo duomenis patikrinamas modelio veikimo tikslumas ir pateikiami rezultatai.

3.23 lentelė SVM algoritmo naudojami nustatymai

Parametras	Reikšmė	Paaiškinimas
winStride	8,8	Slankaus lango žingsnio dydis
padding	8,8	Pikselių skaičius slankaus lango
locations	(10,20)	Taško vektorius
winSize	96,96	Aptikimo lango dydis
blockSize	16,16	Bloko dydis pikseliais
blockStride	8,8	Bloko žingsnis
cellSize	8,8	Langelio dydis

nbins	9	Skaičius dėžių, naudojamų apskaičiuojant gradientų histogramą
winSigma	4	Gauso lyginimo lango parametras
L2HysThreshold	2.000000000000001e-01	L2-Hys normalizavimo metodo susitraukimas
gammaCorrection	0	Nurodo, ar reikia atlikti išankstinį gama korekcijos apdorojimą, ar ne
nlevels	64	Maksimalus aptikimo lango didėjimo skaičius
kernel	Linear	Algoritmų klasė
kFold	5	Padalina duomenis į k dalių
ImageShape	96,96	Paveikslo dydis

Aukščiau pateiktoje 3.23 lentelėje nurodomi eksperimentiniu keliu nustatyti algoritmo parametrai, naudojant tiesinę branduolio funkciją, tačiau eksperimentai buvo atliekami su Daugianario, Gauso radialinio pagrindo, Sigmoido branduolio funkcijomis ir keičiant kitus parametrus, tačiau geriausi rezultatai gauti naudojant tiesinę funkciją.

3.9. Projektinės dalies išvados

1. Pateikta PAM diagrama, aktorių ir PA sąveikos grafinę diagramą, bei pagrindines PA specifikacijos lentelėse, numatyta ir detalizuota dvylika panaudojimo atvejų sistemai.
2. Iškelti intelektiniai asmens dokumentų atpažinimo sistemai funkciniai ir nefunkciniai reikalavimai.
3. Naudojant sistemos dinaminį ir statinį vaizdą, pateiktos pagrindinės architektūros dalys: sistemos padalinimas į paketus, PA detalizuotos veiklos diagramos.
4. Pateikti pagrindiniai sistemos grafinės vartotojo sąsajos langai, aprašymai, bei bendras sistemos veikimas ir išskirtos funkcijos serverio ir kliento daliai.
5. Nurodyti naudojamų mašininio mokymo algoritmų aprašymai bei diagramos, kaip realizuoti šie metodai sistemoje.

4. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos tyrimo dalis

4.1. Tyrimo tikslas

Tyrimo tikslas - įvertinti intelektinės asmens tapatybės dokumentų atpažinimo, sistemos, kokybę. Tyrimo metu siekiama nustatyti sistemos realizacijai pasirinktų vaizdų klasifikavimo metodų tikslumą asmens tapatybės dokumentų tipo ir šalies nustatymo uždaviniui spręsti.

4.2. Tyrimo aprašymas ir eiga

Intelektinėje asmens tapatybės dokumentų atpažinimo sistemoje numatyti du pagrindiniai veiksmi. Pirmasis yra iš vaizdinės medžiagos nustatyti nuotraukoje esančio asmens tapatybės dokumento tipą. Žemiau pateiktame paveiksle (4.1 pav.) pavaizduoti dokumentų pavyzdžiai: Lietuvos paso ir asmens tapatybės kortelės.



4.1 pav. Skirtingų dokumentų tipo pavyzdžiai

Nustačius dokumento tipą, sistemą gali nustatyti, kokios tai šalies yra dokumentas, žemiau pateiktame paveiksle (4.2 pav.) pavaizduoti skirtingų šalių asmens tapatybės kortelių pavyzdžiai: Lenkijos, Latvijos ir Lietuvos.



4.2 pav. Skirtingų šalių dokumentų pavyzdžiai

Sistemai iš nuotraukos nustačius dokumento tipą ir šalį atitinkamai rezultatai grąžinami serveriui arba vartotojui grafiniėje sąsajoje.

Šiam uždaviniui išspręsti buvo naudojama 20 tūkstančių asmens tapatybės dokumentų nuotraukų. Modelių apmokymui buvo naudojama po dešimt tūkstančių nuotraukų dokumento tipo atskyrimui ir po 370 nuotraukų kiekvienai dokumentų šaliai atpažinti. Testavimui buvo naudojama 50 tūkstančių nuotraukų. Po 25 tūkstančius patikrinti dokumento tipo nustatymo tikslumą ir po 925 nuotraukas kiekvienai dokumento šaliai. Siekiant kuo objektyviau įvertinti sistemos veikimą, bei kiekvieno pasirinkto metodo tikslumą atskiriems uždaviniams spręsti, buvo tyrimui pasirinkta daugiau duomenų nei apmokymui.

Siekiant atlikti kuo objektyvesnį pasirinktų metodų vertinimą iš testavimo duomenų nebuvo pašalintos susiliejusios, nepilnai matomo dokumento, labai tamsios ar šviesios nuotraukos. Taip siekiant užtikrinti, jog tyrimo metu gauti rezultatai skirtųsi kuo mažiau realiame pasaulyje veikiančioms sistemai.

Tyrimo metu atliekamas bendras sistemos testavimas, CNN ir SVM metodų rezultatų palyginimas, aplikacijų serverių sąsajos apkrovos testavimas bei bendras sistemos kokybės vertinimas bei nustatomos patobulinimų galimybės.

4.3. Sistemos testavimas

4.3.1. Testuojama programų sistema

Testuojama programinė įranga yra skirta vykdyti asmens tapatybės informacijos nuskaitymą. Susideda ir daugiau funkcijų tokių kaip dokumento radimas nuotraukoje ir pagal tai nustatomas dokumento tipas ir šalis.

4.3.2. Sąsajos

Kuriamas įrankis yra „Python“ programa, turinti paprasta vartotojo sąsają, kuri leidžia lengviau patikrinti sistemos veikimą bei ją ištestuoti, bei naudoti rankiniu būdu patikrinti dokumentą, ne tik kaip aplikacijų programavimo sąsaja (angl. API). Funkcijos kurios gali būti įvykdomos grafinėje sąsajoje:

- nuotraukos įkėlimas;
- dokumento tipo nustatymas;
- dokumento šalies nustatymas;
- apmokymas;
- testavimas;
- istorijos peržiūra ir analizė;
- apmokytų modelių pašalinimas.

4.3.3. Testavimo strategija

Žemiau pateiktuose poskyriuose pateikiamos visų naudojamų testavimo metodų strategijos.

4.3.4. Vienetų testavimas

Vienetų testavimas naudojamas patikrinti funkcinis vienetus, klases, modelius, atskirus metodus ar funkcijas. Atliekant šį testavimą bus patikrinti kokie rezultatai yra gaunami, juos lyginant su tais rezultatais, kuriuos turėtume gauti, kad užtikrintume atskirų funkcinių vienetų taisyklingą veikimą. Svarbiausioms funkcijoms bus parašomi testai pilnai padengiantys visus funkcijos skirtingus atvejus, kitoms funkcijoms bus naudojamas juodosios dėžės testavimas, patikrinant tik rezultatus.

4.3.5. Integravimo testavimas

Integracinio testavimo metu tikrinamas programinės įrangos klasių ar modulių tarpusavio sąveikos korektiškumas. Pavienės klasės apjungiamos į komponentus, o tie komponentai – į posistemas ir testuojamas jau ne pavienis metodas, o visos posistemės veikimas bei posistemų tarpusavio sąveika.

4.3.6. Priėmimo testavimas

Priėmimo testavimo metu projekto uęsakovas tikrina ar programinė įranga atitinka reikalavimų specifikaciją ir jo poreikius. Šio testavimo metu labiau tikrinamas ne kodo korektiškumas, o programinės įrangos naudojimo patogumas ir veikimo teisingumas, reikalavimų specifikacijos atitikimas.

4.3.7. Aukšto lygio testavimas

Aukšto lygio testavimo metu atliekamas galutinis sistemos testavimas, sistema perduodama uęsakovui. Šio testavimo metu didelis dėmesys teikiamas nefunkciniams sistemos reikalavimams ištestuoti.

4.3.8. Testavimo ištekliai

Testavimui reikalingų programinių ir techninių resursų sąrašas:

- įrankis skirtas asmens tapatybės dokumentų aptikimui ir informacijos nuskaitymui. Bus naudojamas kaip programa kompiuteriuose ir kaip atskiras komponentas įmonės serveryje;
- apie 50 000 dokumento nuotraukų;
- „PyCharm IDE professional“;
- 16GB RAM;
- 512GB SSD atminties diskas.

4.3.9. Testavimo rezultatai

Saugomų testavimo rezultatų struktūra:

Rezultatai bus saugomi tekstu.

Data ir laikas, tikslumas, greیتaveika, rezultatai.

4.3.10. Testavimo įrankiai ir aplinka

Testavimui bus naudojamas „Pycharm“ įrankis ir vienetų testavimo biblioteka, leidžianti lengviau parašyti testus. Vartotojo sąsaja bus testuojama rankiniu būdu.

4.3.11. Testavimo rezultatai ir išvados

Vykdam testavimą paaiškėjo silpniausios sistemos dalys, kurios buvo iškart atnaujintos ir sutvarkytos, daugiausia buvo sistemos funkcijose paleidus vienetų testavimą tai buvo sutvarkyta. Taip pat sistemos tikslumas buvo nustatytas mažesnis nei reikalauja projekto uęsakovo, todėl buvo apmokyta naujas modelis su daugiau duomenų ir duomenys buvo peržiūrėti ir pašalinti netinkamai, tai padidintas sistemos dokumentų atpažinimo tikslumas. Sistemos dokumentų nuskaitymo greitis irgi buvo didesnis nei nustatyta, tad buvo įvykdytas pakeitimas, kad mašininio mokymo modeliai būtų užkrauti paleidus programą, o ne tik paleidus dokumento aptikimą, tai sutaupo apie 7 sekundes laiko, tad toks sprendimas buvo priimtas, jog testavimas praeitų sėkmingai.

Testuojant vartotojo sąsają įmonės darbuotojam buvo sulaukta neigiamų atsiliepimų, jog neaišku, nesuprantama, dizainai labai senoviškas atrodo, todėl buvo priimtas sprendimas atnaujinti grafinę vartotojo sąsają, kuri jau yra aiškesnė, modernesnė ir uęsakovo įmonės darbuotojai įvertino kaip tinkamą dirbti jiems.

Užsakovo įmonės darbuotojai atliko priėmimo ir aukšto lygio testavimą ir galutinis sistemos variantas buvo tinkamas kaip užsakytos sistemos.

4.4. Metodų palyginimas

Tyrimo metu atliktas atsitiktinių miškų, sprendimų medžio, CNN ir SVM metodų palyginimas. Kadangi nustatytą tikslumą pavyko pasiekti tik su CNN ir SVM metodais, todėl detalesnis tyrimo ir rezultatai pateikiami tik šių metodų. Detalūs atlikto tyrimo rezultatai pateikti žemiau esančiose 4.1 – 4.6 lentelėse. Geriausias tikslumas gautas naudojant CNN metodą tiek dokumento tipui, tiek šaliai nustatyti. Kadangi šie du metodai jau anksčiau buvo atrinkti kaip tinkamiausi šiam uždaviniui spręsti, jų rezultatai yra pakankamai panašūs. Dokumento tipo atpažinimui CNN pateikia 94,91% tikslumu ištestavus su 25 tūkstančiais duomenų, tą patį uždavinį SVM metodas atlieka 92,19% tikslumu. Atpažinti dokumento šalį abu metodai sugeba atlikti ne taip tiksliai, dėl to, jog daugiau klasių yra klasifikuojant dokumentą. Iš gautų rezultatų matyti, jog paso aptikimas yra šiek tiek tikslesnis nei asmens tapatybės kortelės, CNN metodas paso šalį aptinka 88,42% tikslumu, o SVM 89,58%. Tie patys metodai, asmens tapatybės kortelę, aptinka atitinkamai CNN 87,24% ir SVM 86,6% tikslumu. Iš gautų rezultatų matyti, jog visuose uždaviniuose naudojant CNN algoritmą gauti tikslesni rezultatai.

4.1 lentelė Konvoliucinio neuroninio tinklo algoritmo rezultatai aptinkant dokumento tipą.

CNN vidutinis tikslumas: 94,91 %		Atpažintas dokumento tipas		
		ID kortelė	Pasas	Viso:
Esamas dokumento tipas	ID kortelė	24778	520	25298
	Pasas	750	23952	24702

4.2 lentelė Vektorinės atramos mašinos algoritmo rezultatai aptinkant dokumento tipą.

SVM vidutinis tikslumas: 92,19 %		Atpažintas dokumento tipas		
		ID kortelė	Pasas	Viso:
Esamas dokumento tipas	ID kortelė	24005	832	24837
	Pasas	1120	24043	25163

4.3 lentelė Konvoliucinio neuroninio tinklo algoritmo rezultatai aptinkant paso šalį.

CNN vidutinis tikslumas: 88,42 %		Atpažinta paso šalis		
		Tinkamai	Netinkamai	Viso:
Esama paso šalis		22105	2895	25000

4.4 lentelė Vektorinės atramos mašinos algoritmo rezultatai aptinkant paso šalį.

SVM vidutinis tikslumas: 87,58 %	Atpažinta paso šalis		
	Tinkamai	Netinkamai	Viso:
Esama paso šalis	21895	3105	25000

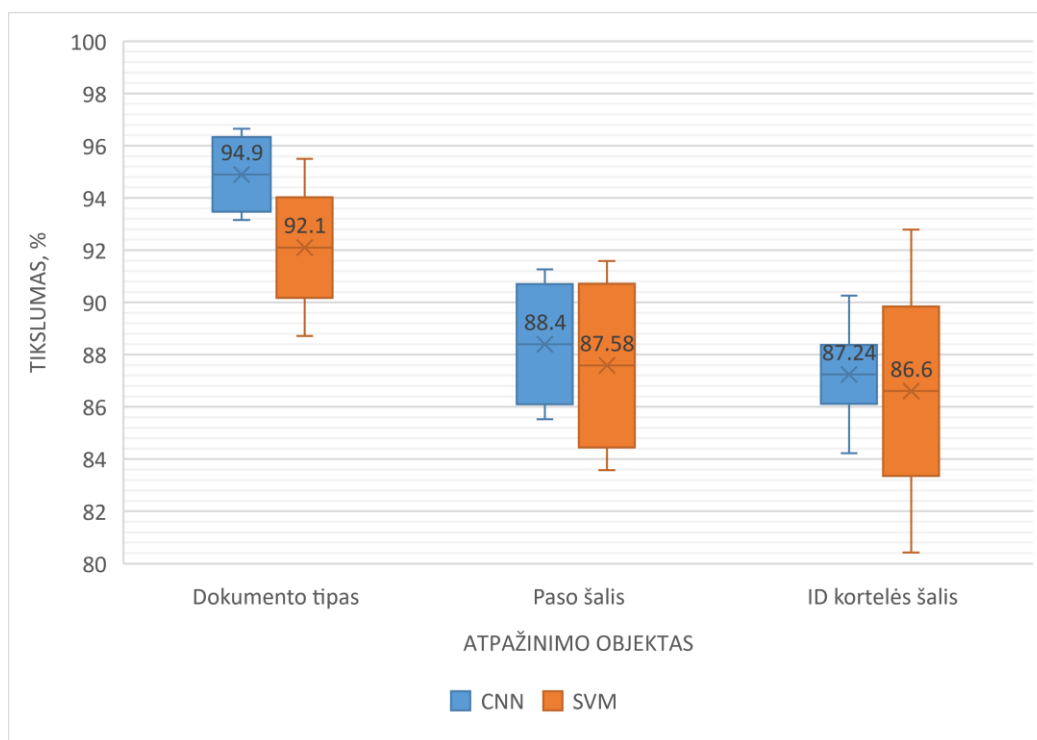
4.5 lentelė Konvoliucinio neuroninio tinklo algoritmo rezultatai aptinkant dokumento tipą.

CNN vidutinis tikslumas: 87,24 %	Atpažinta asmens tapatybės kortelės šalis		
	Tinkamai	Netinkamai	Viso:
Esama asmens tapatybės kortelės šalis	21810	3190	25000

4.6 lentelė Vektorinės atramos mašinos algoritmo rezultatai aptinkant dokumento tipą.

SVM vidutinis tikslumas: 86,6 %	Atpažinta asmens tapatybės kortelės šalis		
	Tinkamai	Netinkamai	Viso:
Esamas asmens tapatybės kortelės šalis	21650	3350	25000

Tikslinga yra tyrimo duomenis palyginti vienoje diagramoje, kad aiškiau matytųsi kiekvieno uždavinio ir algoritmo tikslumas ir rezultatų pasiskirstymas skirtingų dešimties bandymu metu. Žemiau pateiktame paveiksle (4.3 pav.) pateikti trys uždaviniai dokumento tipo nustatymas, paso ir asmens tapatybės kortelės šalies aptikimas ir kokie rezultatai gauti taikant CNN ir SVM algoritmus.

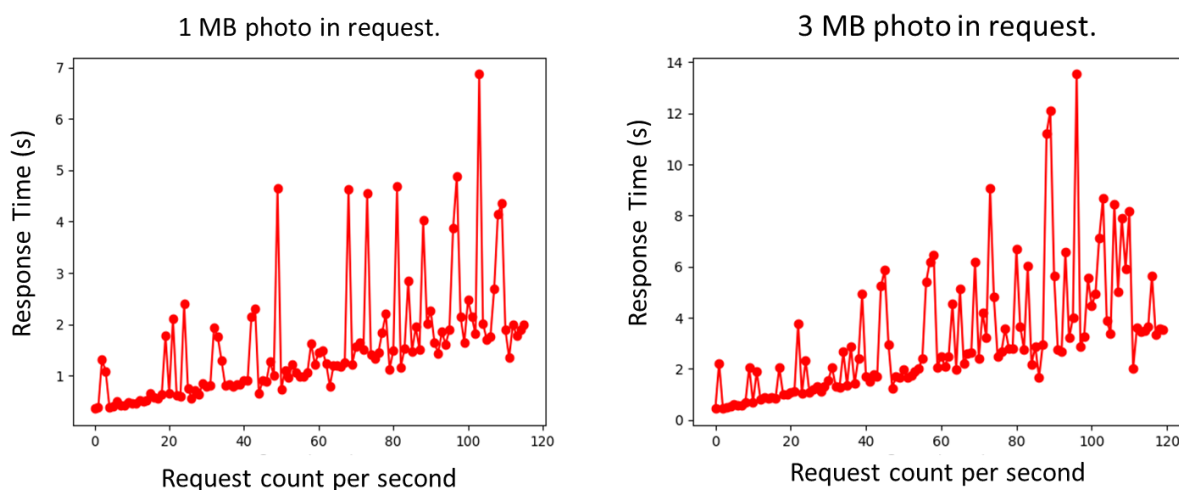


4.3 pav. Asmens tapatybės dokumentų klasifikavimo rezultatų palyginimas

Kaip galime matyti iš aukščiau pateiktos diagramos, geriausiai pavyksta nustatyti dokumento tipą, o sunkiausiai asmens tapatybės kortelės šalį. Stabilumas visuose uždaviniuose didesnis CNN algoritmo lyginant su SVM. Detalesni rezultatai pateikti dokumento prieduose 9.1 – 9.2 lentelėse.

4.5. Greitaveikos įvertinimas

Aplikacijų programavimo sąsajos testavimo metu, nustatytas sistemos pajėgumas, jog vienu metu gali apdoroti virš 100 užklausų siunčiant vidutinio dydžio nuotrauką ir atsakymas gaunamas per nustatytą reikalavimą 7 sekundes. Žemiau pateikti testavimo grafikai (4.4 pav.)



4.4 pav. Aplikacijų programavimo sąsajos (angl. *API*) apkrovos testavimo rezultatai

Kaip galima matyti grafikuose, naudojant 1MB dydžio nuotrauką, galimą siųsti virš 100 užklausų vienu metu ir rezultatus gauti per norimą laiką. Siunčiant didesnes nuotraukas, pavyzdžiui 3MB laikas padvigubėja, tačiau norint didinti galingumą, galimą paleisti keliuose skirtinguose serveriuose, kadangi labiausiai apriboja interneto greitaveika.

4.6. Sistemos kokybės vertinimas

Pateikiamas sistemos ir įrankio, skirto aptikti asmens tapatybės dokumentą ir tipą bei leidžiančio testuoti ir treniruoti jau išmokytus mašininio mokymo modelius pagal pasirinktą algoritmą, kokybės įvertinimas, kaip atitinka užsakovo iškeltus reikalavimus.

Pasikalbėjus su projekto užsakovu apie atliktą projektą buvo aptartas sistemos veikimas, reikalingi pakeitimai, patobulinimai, kuriuos reikėjo atlikti.

Pakeitimų sąrašas:

- atnaujinta grafinė vartotojo sąsaja;
- padaryti keli sistemos prieigos taškai iš sistemos gauti visa reikalingą informaciją.

Sistemos kokybės vertinimas yra pateikiamas lentelėje žemiau esančioje. Sistemos kokybė buvo vertinama pagal projekto paraiškoje iškeltus kriterijus (4.7 lentelė).

4.7 lentelė Kriterijai

Nr.	Kriterijus	Pagrindimas	Vertinimas
1	Iš plečiamumas	Numatytos galimybės nesudėtingai pridėti naują funkcionalumą pakeičiant aptinkamą objektą.	Puikiai
2	Tikslumas	Turi būti ne mažesnis nei 75%	Puikiai
3	Priimti įvairios raiškos vaizdinę medžiagą	Ar sistema gali susidoroti su skirtingos raiškos vaizdine informacija gaunama iš skirtingų kamerų.	Puikiai
4	Greitaveika	Sistema turi nuskaityti informaciją mažiau nei per 7 sekundes	Puikiai
5	Pajėgumas	Vienu metu turi apdoroti daugiau nei 50 užklausų esant vidutiniam užklauso dydžiui 1 MB ir ne mažiau 20 užklausų esant 3 MB užklauso dydžiui.	Puikiai

Įvertinus sistemos kokybę, galime teikti, jog sistema atitinka iškeltus kokybės reikalavimus bei atitinka numatytus funkcinius ir nefunkcinius reikalavimus.

4.7. Tyrimo rezultatai

Sistemos tikslumas naudojant CNN algoritmą aptinkant dokumento tipą 94.9%, vieno dokumento aptikimo laikas naudojant grafinę sąsają 0.04 sekundės. naudojant serverį ir siunčiant HTTP užklausa 1.2 sekundės. Dokumento šalies nustatymo tikslumas naudojant CNN algoritmą 88.1%, aptikimo laikas 0.029 sekundės, serveryje atsakymas grąžinamas per 0.9 sekundės.

Aplikacijų programavimo sąsajos testavimo metu, nustatytas sistemos pajėgumas, jog vienu metu gali apdoroti virš 100 užklausų siunčiant vidutinio dydžio nuotrauką ir atsakymas pareina per nustatytą reikalavimą 7 sekundes.

4.8. Kokybės tobulinimo galimybės

Atlikus intelektinės asmens tapatybės dokumentų atpažinimo sistemos tyrimą, buvo pastebėta, jog galima patobulinti sistemą pagerinant jos kokybę. Išskirtos kelios tobulinamos vietos:

- naudoti sudėtingesnę konvoliucinio neuroninio tinklo architektūrą („VGG16“, „VGG19“, „ResNet50“, „ResNet152“, „InceptionV3“);
- pagerinti realizuotą siūlomą architektūros modelį, siekiant padidinti modelio tikslumą, naudoti kryžminę patikrą užtikrinam geriausią tikslumą.

4.9. Tyrimo dalies išvados

1. Tyrimo metu buvo atliktas intelektinės asmens tapatybės dokumentų sistemos testavimas ir kokybės vertinimas, kurio metu nustatyta, jog sistema atitinka iškeltus užsakovo reikalavimus.
2. Atlikus sistemos realizacijai pasirinktų vaizdų klasifikavimo metodų tyrimą, buvo išsiaiškintas tikslumas ir nustatyta, jog CNN metodas tinkamiausias šiam uždaviniui spręsti, kurio tikslumas nustatant dokumento tipą yra 94.9%, o nustatant dokumento šalį 88,1%. Nors SVM metodo tikslumas ne ženkliai prastesnis, atsitiktinių miškų ir sprendimų medžio metodai nepasiekė nustatyto tikslumo. Eksperimentus tikslinga atlikti naudojant CNN metodą palyginat skirtingas architektūras, kadangi CNN pasiekė ne tik aukštesnius rezultatus, bet ir rezultatai buvo stabilesni atliekant bandymus.
3. Analizuojant sistemą, atliekant testavimą, kokybės vertinimą, metodų palyginimą buvo numatytos sistemos tobulinimo galimybės.

5. Intelektinės asmens tapatybės dokumentų atpažinimo sistemos eksperimentinė dalis

5.1. Eksperimentinio tyrimo tikslas

Eksperimentas vykdomas naudojant intelektinę asmens tapatybės dokumentų atpažinimo sistemą, siekiant įvertinti sistemos veikimą naudojant skirtingas CNN architektūras įvertinant apmokymo laiką, modelio dydį, aptikimo greitį, atpažinimo tikslumą. Atlikti eksperimentą kaip rezultatai priklauso nuo nuotraukų kokybės.

5.2. Eksperimentinio tyrimo aprašymas ir eiga

Eksperimentas atliekamas naudojant siūlomos architektūros modelius ir standartines „VGG16“, „VGG19“, „ResNet50“, „ResNet152“ ir „InceptionV3“ konvoliucinio neuroninio tinklo architektūras. Naudojamų duomenų kiekiai pateikti 5.1 lentelėje.

5.1 lentelė Eksperimentinio tyrimo naudojamų duomenų informacija


Eksperimento duomenys	Kiekis (vienetais)
Apmokymo nuotraukos dokumento tipui aptikti	21440
Apmokymo nuotraukos dokumento šaliai aptikti	10720
Testavimo duomenys dokumento tipui aptikti	51684
Testavimo duomenys dokumento šaliai aptikti	25824
Blogos kokybės testavimo duomenys dokumento tipui aptikti	1458
Blogos kokybės testavimo duomenys dokumento šaliai aptikti	729

Šie duomenys buvo gauti iš sistemos užsakovo įmonės, siekiant atlikti tyrimą naudojant patobulintą CNN modelį bei kitas architektūras.

5.3. Eksperimentinio tyrimo rezultatai

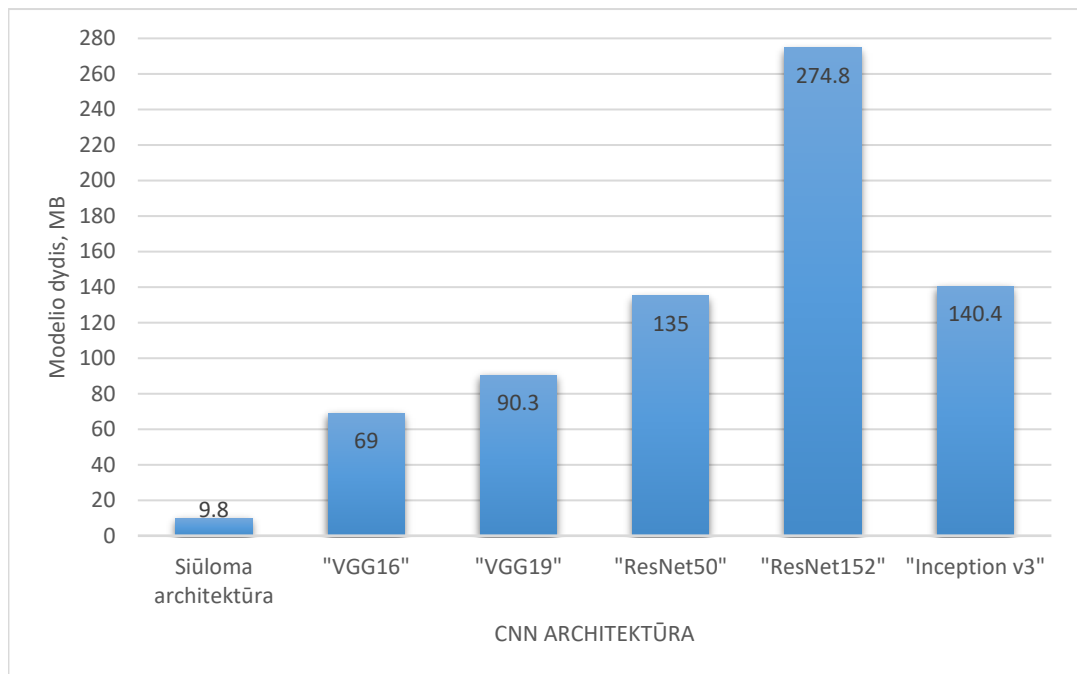
Eksperimentinio tyrimo rezultatai, naudojant skirtingas CNN architektūras yra pateikiami 34 – 41 pav. Šis tyrimas atliktas naudojant realizuotą intelektinę asmens tapatybės dokumentų aptikimo sistemą integruojant naujus modulius, rezultatus įrašant į CSV formato failą.

Skirtingos CNN modelių architektūros turi skirtingą parametrų skaičių, palyginimas pateiktas 5.1 pav. didžiausią parametrų skaičių turi „ResNet152“ architektūra 68.39 mln. Iš kurių apmokomi 10.06 mln., mažiausiai turi siūloma architektūra 813 tūkstančių.



5.1 pav. Eksperimentinio tyrimo rezultatai: modelių parametų kiekis


Apmokyto modelio dydis priklauso nuo parametų skaičiaus, kadangi „ResNet152“ architektūra turi daugiausiai, todėl ir modelis užima daugiausiai 274.8 MB, o tuo tarpu siūlomos architektūros modelio dydis tik 9.8 MB. Modelių dydžių palyginimas pateiktas žemiau esančiame paveiksle (5.2 pav.).



5.2 pav. Eksperimentinio tyrimo rezultatai: apmokytų modelių dydis

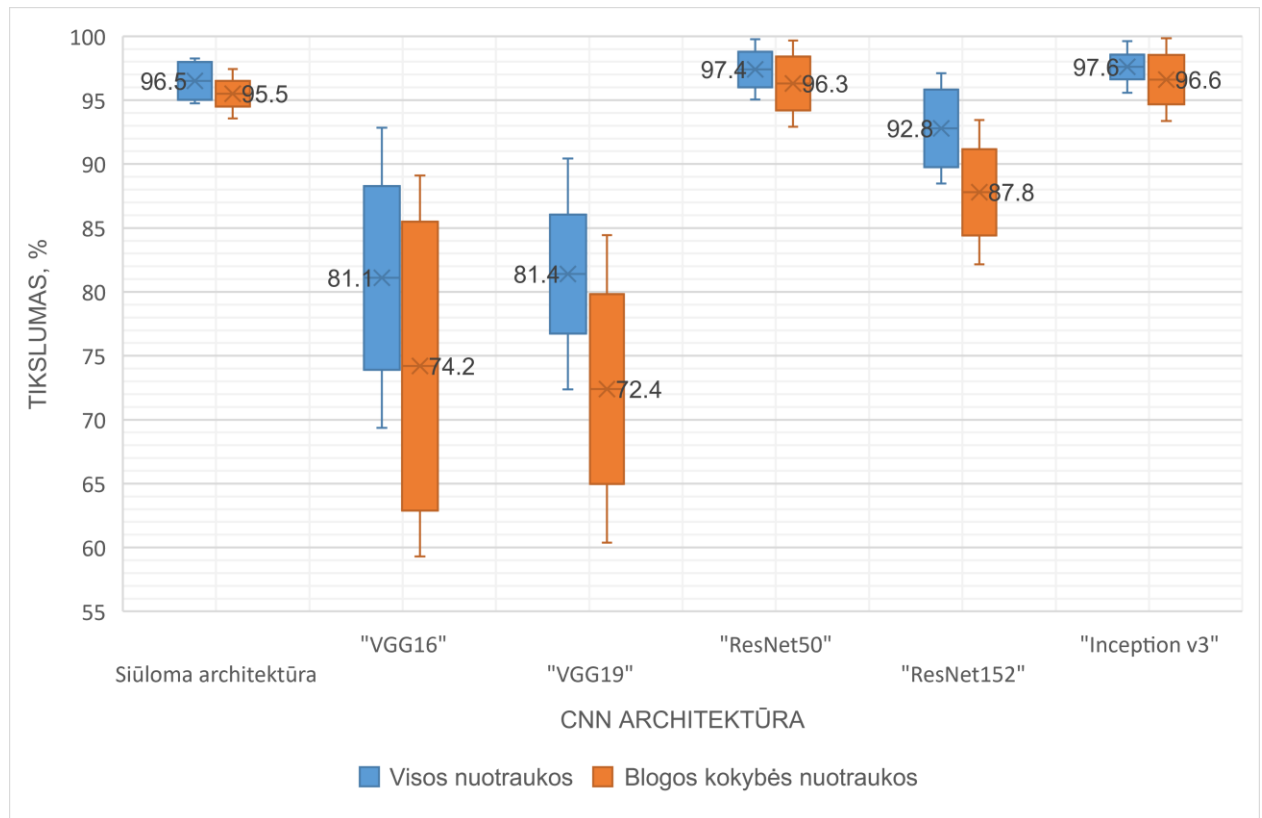
Modelių apmokymo, sprendžiant dokumento tipo nustatymo uždavinį, laikas priklauso taip pat ir nuo apmokomų parametų kiekiu, šiuo atveju turime, jog daugiausia tokių parametų turi „VGG16“ modelis ir jo apmokymo laikas 51.84 tūkstančiai sekundžių, o mažiausiai turi siūlomos architektūros modelis kurio apmokymo laikas truko 11.24 tūkstančių sekundžių. Tačiau testavimo laikas nuo to

nepriklauso ir nuo modelio dydžio, kadangi laikas skaičiuotas tik po modelio užkrovimo, siekiant patikrinti tik nustatymo laiką. Greičiausiai patikrino visus testavimo duomenis „Inception v3“ per 4.7 tūkst. sekundžių, o ilgiausiai truko „VGG16“ 27.8 tūkst. sekundžių, labai panašiai užtruko ir „VGG19“ modelis. Žemiau pateikti visų modelių rezultatai (5.3 pav.).



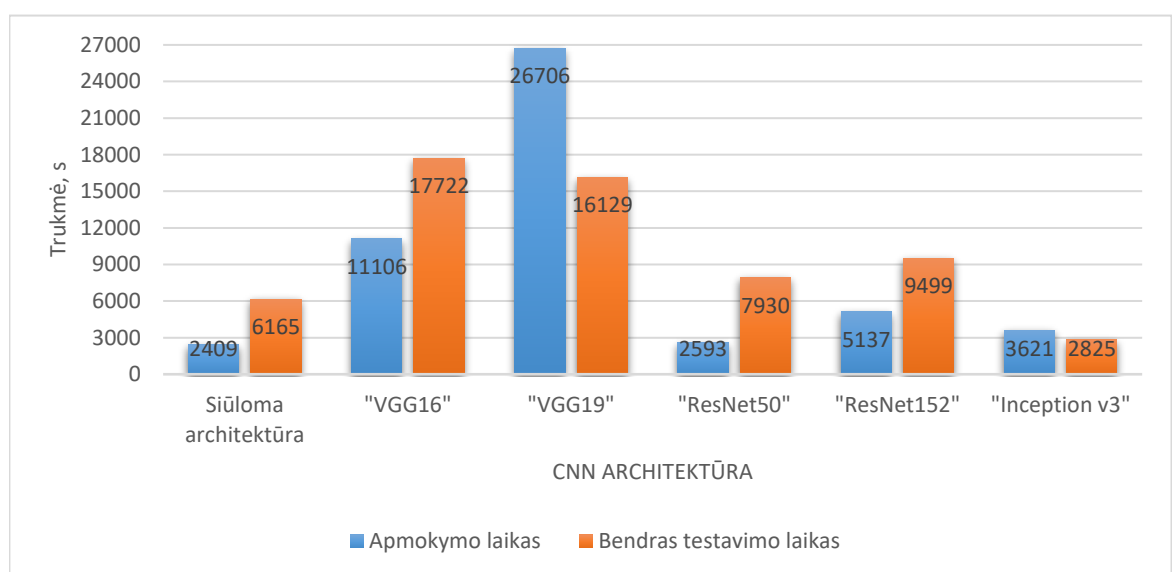
5.3 pav. Eksperimentinio tyrimo rezultatai: apmokymo ir testavimo laikas dokumento tipo nustatymui

Atliktas eksperimentas palyginimui, kaip modeliai veikia su įvairios ir blogos kokybės nuotraukomis. Ištestuoti modelius su visomis nuotraukomis buvo naudojami visi testavimo duomenys, o palyginimui tikslumo su blogos kokybės, buvo atrinktos tik mažos rezoliucijos, susiliejusios, neryškios, su šešėliais, atspindžiais nuotraukos, bet tik tas, kurias yra tikslas nustatyti, nes jeigu nesimaty dokumento ar jis bus matomas tik tiek, jog vėliau jo nebus galima panaudoti tolimesniems užsakovo sistemos analizės etapams. Lyginant rezultatus pateiktus 5.4 pav. galima matyti, jog didžiausias skirtumas matomas tarp „VGG“ modelių. Kitiems modeliams tai neturėjo tiek įtakos, geriausi vidutiniai rezultatai gauti naudojant „Inception v3“ modelį. Vidutinis testavimo tikslumas su visomis nuotraukomis 97.6%, o tik naudojant blogos kokybės gautas tikslumas 96.6%, neženkliai skiriasi ir „ResNet50“ tikslumas, o prasčiausi rezultatai gauti su „VGG19“ modeliu. Tačiau didžiausias stabilumas atliekant skirtingus bandymus pasiektas su siūloma architektūra.



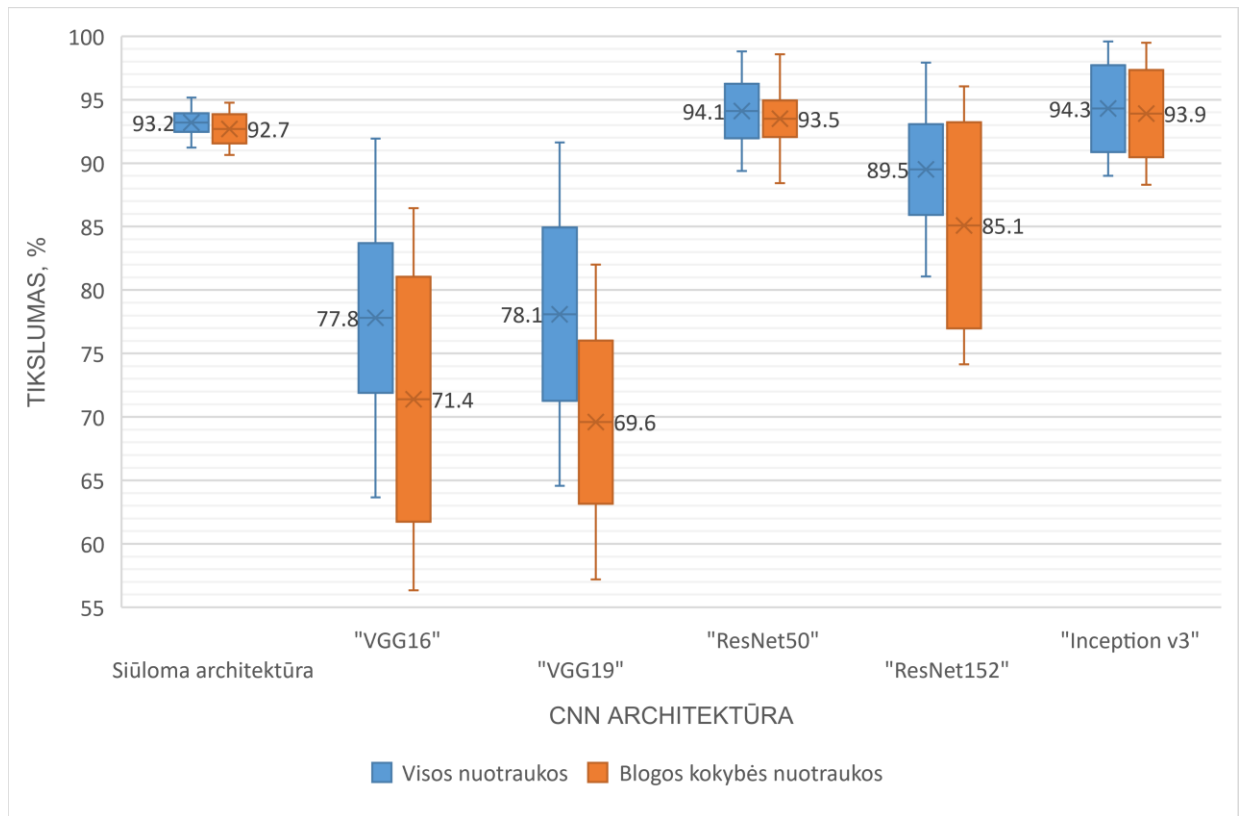
5.4 pav. Eksperimentinio tyrimo rezultatai: visų ir tik blogos kokybės nuotraukų aptikimo tikslumas dokumento tipo nustatymui

Toliau pateikiami eksperimentinio tyrimo rezultatai sprendžiant paso ir asmens tapatybės kortelės šalies nustatymo uždavinius (5.5 – 5.8 pav.). Tendencijos išlieka tos pačios, tačiau apmokymo ir testavimo duomenų kiekiai naudojami mažesni, todėl šie veiksmai atliekami greičiau. Tikslumas yra mažesnis lyginant su dokumento tipo nustatymu, kadangi klasifikuoti reikia į 27 klases, o ne į 2, taip pat, naudojant „Inception v3“ modelį buvo gautas didžiausias tikslumas ir šiems uždaviniams spręsti.




5.5 pav. Eksperimentinio tyrimo rezultatai: apmokymo ir testavimo laikas asmens tapatybės kortelės šalies nustatymui

Modelių apmokymo laikas asmens tapatybės šaliai nustatyti yra gerokai mažesnis, bet ir apmokymui buvo naudojama per pusę mažiau apmokymų duomenų, kadangi išsiskirsto į pasą ir ID kortelę (5.5 pav.). Greičiausiai apmokytas siūlomos architektūros modelis per 2.4 tūkst. sekundžių, tačiau greičiausiai visus bandymo rezultatus gavo „Inception v3“ modelis, vos per 2.8 tūkstančių sekundžių, kai tuo tarpu abu „VGG“ modeliai užtruko daugiau nei 16 tūkstančių sekundžių tai pačiai duomenų imčiai paskaičiuoti rezultatus.




5.6 pav. Eksperimentinio tyrimo rezultatai: visų ir tik blogos kokybės nuotraukų aptikimo tikslumas asmens tapatybės kortelės šalies nustatymui

Viso testavimo duomenų rinkinio rezultatai, asmens tapatybės šaliai nustatyti ne daug skiriasi nuo tik blogos kokybės nuotraukų testavimo duomenų rinkinio, kuo žemesnis modelių aptikimo tikslumas, tuo mažesnis stabilumas (5.6 pav.). Labiausiai stabilūs rezultatai yra siūlomos architektūros, nors vidutinis tikslumas yra mažesnis 1.1% ir 1.2% atitinkamai pagal visas nuotraukas ir blogos kokybės, tačiau rezultatai mažai svyruoja, lyginant su kitais metodais.



5.7 pav. Eksperimentinio tyrimo rezultatai: apmokymo ir testavimo laikas pasio šalies nustatymui

Pasio šalies nustatymo modelių apmokymas ir bendras testavimo laikas yra mažiausias, nors duomenų kiekis toks pat, kaip ID kortelėm, tačiau laikas mažesnis (5.7 pav.).



5.8 pav. Eksperimentinio tyrimo rezultatai: visų ir tik blogos kokybės nuotraukų aptikimo tikslumas pasio šalies nustatymui

Vidutinis pasio šalių nustatymo tikslumas visų modulių yra mažesnis (5.8 pav.) nei ID kortelių, kadangi apmokymo ir testavimo laikas irgi mažesnis, kilo įtarimas dėl duomenų imties ir atlikus duomenų analizę, paaiškėjo, jog bendra nuotraukų kokybė pasio dokumentų yra geresnė nei ID kortelės tai ir turi įtakos tikslumui bei greitaveikai. Daugiau eksperimentinio tyrimo rezultatų pateikta dokumento priede 9.3 – 9.11 lentelėse ir 9.1 – 9.3 paveiksluose.

5.4. Eksperimentinės dalies išvados

1. Atlikti eksperimentai parodė, jog sukurtą intelektinę asmens tapatybės dokumentų atpažinimo sistemos tikslumą galima patobulinti naudojant CNN „Inception v3“ architektūrą, tačiau didėja rizika, dėl bendro sistemos stabilumo, nes šios architektūros eksperimentinio metu atliktų bandymo rezultatai yra labiau pasiskirstę nei siūlomos architektūros.
2. Eksperimentų metu pastebėta, jog naudojamas sistemos modelis su blogos kokybės nuotraukomis aptinka 95.5%, o su visomis 96.5% tikslumu ir aptikimo rezultatų stabilumas yra aukštas lyginant su kitų architektūrų modeliais.
3. Nustatyta, jog „VGG“ architektūros modeliai yra mažiausiai tinkami šiam uždaviniui spręsti, nes pasiektas mažiausias tikslumas, bei jų apmokymo ir aptikimo laikas yra didžiausias ir bandymo rezultatai daugiausiai pasiskirstę.
4. Už naudojama sistemoje siūlomos architektūros modelį geresnius rezultatus pavyko pasiekti su „ResNet50“ ir „Inception v3“ modeliais, kurių tikslumas atitinkamai 97.4% ir 97.6%, tačiau jų rezultatų stabilumas gerokai mažesnis už siūlomos architektūros.

6. Išvados

1. Atlikta vaizdų klasifikavimo metodų (SVM, CNN, ANN, atsitiktinių miškų ir sprendinių medžio) literatūros analizė, įvertintos šių metodų taikymo galimybės asmens tapatybės dokumentų atpažinimo uždaviniui spręsti.
2. Išskirti trys uždaviniai, siekiant padidinti sistemos tikslumą, atskirti dokumento tipo, asmens tapatybės ir paso šalies nustatymą iš vaizdinės medžiagos.
3. Atlikus sistemos realizacijai pasirinktų vaizdo klasifikavimo metodų tyrimą, naudojant tris skirtingus modelius uždaviniams spręsti, buvo nustatyta, jog SVM ir CNN metodai pasiekė nustatytą tikslumą, daugiau nei 75%, tačiau CNN metodo tikslumas gautas 94.91%, todėl nuspręsta atlikti eksperimentą su skirtingomis CNN algoritmo architektūromis.
4. Įgyvendinus sistemos patobulinimus pavyko pagerinti CNN metodo tikslumą iki 96.5%, iš naujo apmokant modelį su nauja duomenų imtimi ir taikant kryžminę patikrą, taip užtikrinant didžiausią modelio tikslumą ir rezultatų stabilumą.
5. Vykdamas eksperimentinį tyrimą, buvo analizuojamos „VGG16“, „VGG19“, „ResNet50“, „ResNet152“ ir „Inception v3“ CNN architektūros ir palyginti gauti rezultatai. Didžiausią tikslumą pavyko pasiekti 97.6 % naudojant „Inception v3“ architektūrą, mažiausią tikslumą pasiekė „VGG“ architektūrų modeliai, kurių bandymo rezultatai buvo labiausiai pasiskirstę, tai parodo, mažą modelių stabilumą, lyginant su kitų architektūrų modeliais.
6. Vertinant modelių testavimo laiką, geriausiai pasirodė „Inception v3“ per 4.7 tūkst. sekundžių, o ilgiausiai truko „VGG16“ 27.8 tūkst. sekundžių. Apmokymo laikas priklauso nuo modelio parametrų skaičiaus, kadangi „VGG16“ modelis turi daugiausiai 17.24 mln. apmokomų parametrų ir jo apmokymo laikas 51.84 tūkstančiai sekundžių, o mažiausiai 0.81 mln. turi siūlomos architektūros modelis kurio apmokymo laikas truko 11.24 tūkstančių sekundžių.
7. Eksperimentinio tyrimo metu atliktas modelių tikslumo palyginimas naudojant įvairias nuotraukas ir atrinktas, tik blogos kokybės nuotraukas. Rezultatai parodė, jog visų modelių tikslumas yra mažesnis daugiau negu vienu procentu, geriausių trijų modelių tikslumas svyruoja tarp 95.5% ir 96.6%, kai tuo tarpu su visais duomenis gauti rezultatai yra tarp 96.5% ir 97.6%, tačiau rezultatų stabilumas gerokai išsiskiria siūlomos architektūros, kuris yra aukščiausias sprendžiant visus tris uždavinius.
8. Atlikus eksperimentinio tyrimo rezultatų analizę, sistemoje nustatytas siūlomos architektūros apmokytas modelis, nors vidutinis tikslumas nepasiektas didžiausias, tačiau pasiekiantis didžiausią stabilumą klasifikuojant dokumentus pagal tipą ir šalį, o tai ypač svarbu užtikrinant sistemos tinkamą veikimą.

7. Literatūra

1. Valeryia Shchutskaya, „The Most Exciting Uses of Image Recognition That are Already Changing Our Lives“ 2018 metai, [Žiūrėta 2019-12-01]. Prieiga per internetą: <https://indatalabs.com/blog/uses-image-recognition>.
2. P. C. Mondal, R. Deb and M. N. Huda, "Transaction authorization from Know Your Customer (KYC) information in online banking," 2016 9th International Conference on Electrical and Computer Engineering, Dhaka, 523-526 psl. 2016.
3. Matin, F. Mahmud, S. T. Zuhori and B. Sen, "Human iris as a biometric for identity verification," 2016 2nd International Conference on Electrical, Computer & Telecommunication Engineering, Rajshahi, 1-4 psl. 2016.
4. Rana and A. Ciardulli, "Identity verification through face recognition, Android smartphones and NFC," World Congress on Internet Security, London, 162-163 psl. 2013.
5. Robertson, David J. and Fysh, Matthew C. and Bindemann, Markus Face identity verification : five challenges facing practitioners. *Keesing Journal of Documents & Identity*, 59, 3-8 psl. 2019.
6. M. Awal, N. Ghanmi, R. Sicre and T. Furon, "Complex Document Classification and Localization Application on Identity Document Images," 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR), Kyoto, 426-431 psl. 2017.
7. GOV.UK. [Žiūrėta 2020-12-12] Prieiga per internetą: <https://www.gov.uk/browse/driving/driving-licences>.
8. Foreign Nationals Driving in the U.S. 2020. [Žiūrėta 2020-01-05] Prieiga per internetą: <https://www.usa.gov/visitors-driving>.
9. Carla Van Straten. Four industries that are reaping the benefits of biometric identity verification. 2020, [Žiūrėta 2020-12-14] Prieiga per internetą: <https://www.biometricupdate.com/202009/four-industries-that-are-reaping-the-benefits-of-biometric-identity-verification>.
10. Greg Depersio. What to Bring to a Bank to Open a Checking Account. 2020, [Žiūrėta 2020-12-14] Prieiga per internetą: <https://www.investopedia.com/ask/answers/040715/what-should-you-bring-bank-open-checking-account.asp>.
11. How Your Business Can Prevent Credit Card Fraud with ID Verification. 2020. [Žiūrėta 2020-12-1502] Prieiga per internetą: <https://getid.ee/prevent-credit-card-fraud-with-id-verification/>.
12. E-Sign iD-Checker Verification. [Žiūrėta 2020-12-15] Prieiga per internetą: <https://www.e-sign.co.uk/products/id-checker/>.
13. „Guernsey Financial Services Commission. Can video calling be used to verify the identity of individuals?“ 2020. [Žiūrėta 2020-12-15] Prieiga per internetą: <https://www.gfsc.gg/news/article/can-video-calling-be-used-verify-identity-individuals>.
14. „GBG. 9 ways digital document checking beats manual checking“. [Žiūrėta 2020-12-15] Prieiga per internetą: <https://www.gbtplc.com/9-ways-digital-document-checking-beats-manual-every-time/>.
15. Sujatha Kota, Rao P V Nageswara, Rao A Arjuna, Prasad. Biometric Identity Verification using Automatic Speaker Recognition. [Žiūrėta 2020-12-20] Prieiga per internetą: <https://www.infona.pl/resource/bwmeta1.element.ieee-art-000007253813>.
16. Menon N, White D, Kemp RI. Variation in Photos of the Same Face Drives Improvements in Identity Verification. *Perception*. 44(11),2015.

17. L. Du and H. Hu, "Cross-Age Identity Difference Analysis Model Based on Image Pairs for Age Invariant Face Verification. " Transactions on Circuits and Systems for Video Technology. IEEE, 2020.
18. Szczodrak, Maciej, and Andrzej Czyżewski. " Evaluation of Face Detection Algorithms for the Bank Client Identity Verification". Foundations of Computing and Decision Sciences 42.2, 137-148 pal. 2017.
19. Vihar Kurama. ID Card Digitization and Information Extraction using Deep Learning - A Review. 2020. [Žiūrėta 2020-12-15] Prieiga per internetą: <https://nanonets.com/blog/id-card-digitization-deep-learning/>.
20. Smart Engines. The Computer Vision Visionaries. [Žiūrėta 2020-12-18] Prieiga per internetą: <https://smartengines.com/research-development/science/>.
21. Regula. [Žiūrėta 2020-12-18] Prieiga per internetą: <https://mobile.regulaforensics.com/>.
22. "Digital Images." Computer Sciences. [Žiūrėta 2021-04-21] Prieiga per internetą: <https://www.encyclopedia.com/computing/news-wires-white-papers-and-books/digital-images>.
23. DERVINIS, Donatas. Vaizdų apdorojimas. Mokomoji knyga, 2012. 8-11 p., 15-16 p. [Žiūrėta 2020-09-25]. ISBN 978-609-433-107-7. Prieiga per internetą: <https://www.ebooks.ktu.lt/eb/451/vaizdu-apdorojimas/>.
24. H. Jeong, K. Park and Y. Ha, "Image Preprocessing for Efficient Training of YOLO Deep Learning Networks," 2018 IEEE International Conference on Big Data and Smart Computing (BigComp), 2018, pp. 635-637, doi: 10.1109/BigComp.2018.00113.
25. S. Ray, "A Quick Review of Machine Learning Algorithms," 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon), 2019, pp. 35-39, doi: 10.1109/COMITCon.2019.8862451.
26. „Machine Learning Algorithms“. [Žiūrėta 2020-09-18] Prieiga per internetą: <https://www.javatpoint.com/machine-learning-algorithms>.
27. A. Singh, N. Thakur and A. Sharma, "A review of supervised machine learning algorithms," 2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom), 2016, pp. 1310-1315.
28. Långkvist, Martin & Karlsson, Lars & Loutfi, Amy. (2014). A Review of Unsupervised Feature Learning and Deep Learning for Time-Series Modeling. Pattern Recognition Letters. 42. 10.1016/j.patrec.2014.01.008.
29. Fachantidis, Anestis & Taylor, Matthew & Vlahavas, I. (2017). Learning to Teach Reinforcement Learning Agents. Machine Learning and Knowledge Extraction. 1. 10.3390/make1010002.
30. Zhang Z. (2018) Artificial Neural Network. In: Multivariate Time Series Analysis in Climate and Environmental Research. Springer, Cham. https://doi.org/10.1007/978-3-319-67340-0_1
31. Tkáč, M. and R. Verner. "Artificial neural networks in business: Two decades of research." Appl. Soft Comput. 38 (2016): 788-804.
32. M. Coşkun, A. Uçar, Ö. Yildirim and Y. Demir, "Face recognition based on convolutional neural network," 2017 International Conference on Modern Electrical and Energy Systems (MEES), 2017, pp. 376-379, doi: 10.1109/MEES.2017.8248937.
33. Jian Ma, Jun Zhang, Luxin Xiao, Kexu Chen, Jianhua Wu. (2017) Classification of Power Quality Disturbances via Deep Learning. *IETE Technical Review* 34:4, pages 408-415.

34. G. Ou ir Y. L. Murphey, „Multi-class pattern classification using neural networks,“ *Pattern Recognition*, t. 40, nr. 1, p. 4–18, 2007.
35. D. N. Fente and D. Kumar Singh, "Weather Forecasting Using Artificial Neural Network," 2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT), 2018, pp. 1757-1761, doi: 10.1109/ICICCT.2018.8473167.
36. O. I. Abiodun et al., "Comprehensive Review of Artificial Neural Network Applications to Pattern Recognition," in *IEEE Access*, vol. 7, pp. 158820-158846, 2019, doi: 10.1109/ACCESS.2019.2945545.
37. Elsheikh, Ammar & Sharshir, Swellam W. & Elsayed Abd Elaziz, Mohamed & Kabeel, Abd Elnaby. (2019). Modeling of solar energy systems using artificial neural network: A comprehensive review. *Solar Energy*. 180. 622-639. 10.1016/j.solener.2019.01.037.
38. Yadav, Amit & Chandel, Shyam. (2014). Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable and Sustainable Energy Reviews*. 33. 772-781. 10.1016/j.rser.2013.08.055.
39. Liao, Minghui & Shi, Baoguang & Bai, Xiang & Wang, Xinggang & Liu, Wenyu. (2016). TextBoxes: A Fast Text Detector with a Single Deep Neural Network.
40. R. Vinayakumar, K. P. Soman and P. Poornachandran, "Applying convolutional neural network for network intrusion detection," 2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI), 2017, pp. 1222-1228, doi: 10.1109/ICACCI.2017.8126009.
41. Rawat, Waseem & Wang, Zenghui. (2017). Deep Convolutional Neural Networks for Image Classification: A Comprehensive Review. *Neural Computation*. 29. 1-98. 10.1162/NECO_a_00990.
42. „Qualcomm future of AI photography“, „ANDROID AUTHORITY“. [Žiūrėta 2020-03-21] Prieiga per internetą: <https://www.androidauthority.com/qualcomm-future-of-ai-photography-1008994/>.
43. D. Suryani, P. Doetsch and H. Ney, "On the Benefits of Convolutional Neural Network Combinations in Offline Handwriting Recognition," 2016 15th International Conference on Frontiers in Handwriting Recognition (ICFHR), 2016, pp. 193-198, doi: 10.1109/ICFHR.2016.0046.
44. R. C. Çalik and M. F. Demirci, "Cifar-10 Image Classification with Convolutional Neural Networks for Embedded Systems," 2018 IEEE/ACS 15th International Conference on Computer Systems and Applications (AICCSA), 2018, pp. 1-2, doi: 10.1109/AICCSA.2018.8612873.
45. Krizhevsky, Alex & Sutskever, Ilya & Hinton, Geoffrey. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Neural Information Processing Systems*. 25. 10.1145/3065386.
46. Jackel, Larry & Battista, M. & Baird, Henry & Ben, Jan & Bromley, Jane & Burges, Christopher & Cosatto, Eric & Denker, John & Graf, H.P. & Katseff, Howard & Lecun, Yann & Nohl, C. & Sackinger, E. & Shamilian, J. & Shoemaker, T. & Stenard, C. & Strom, I. & Ting, R. & Wood, T. & Zuraw, C.. (1995). *Neural-Net Applications in Character Recognition and Document Analysis*. 10.1007/978-1-4615-2734-3_14.
47. „Classical Convolutional Neural Network-LeNet-5“. [Žiūrėta 2020-03-24] Prieiga prie internetą: <https://www.ivdone.top/article/2150.html>.

48. „AlexNet – ImageNet Classification with Deep Convolutional Neural Networks, „Popular networks“. [Žiūrėta 2020-03-24] Prieiga prie internetą: <https://neurohive.io/en/popular-networks/alexnet-imagenet-classification-with-deep-convolutional-neural-networks/>.
49. Alom, Md. Zahangir & Taha, Tarek & Yakopcic, Christopher & Westberg, Stefan & Hasan, Mahmudul & Esesn, Brian & Awwal, Abdul & Asari, Vijayan. (2018). The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches.
50. Deng L, Chu H-H, Shi P, Wang W, Kong X. Region-Based CNN Method with Deformable Modules for Visually Classifying Concrete Cracks. *Applied Sciences*. 2020; 10(7):2528. <https://doi.org/10.3390/app10072528>.
51. Targ, Sasha & Almeida, Diogo & Lyman, Kevin. (2016). Resnet in Resnet: Generalizing Residual Architectures.
52. Nash, Will & Drummond, Tom & Birbilis, Nick. (2018). A review of deep learning in the study of materials degradation. *npj Materials Degradation*. 2. 10.1038/s41529-018-0058-x.
53. Zheng, Yufeng & Yang, Clifford & Merkulov, Aleksey. (2018). Breast cancer screening using convolutional neural network and follow-up digital mammography. 4. 10.1117/12.2304564.
54. Zisserman, Andrew. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv 1409.1556.
55. Kasim, Nur & Rahman, Nur & Ibrahim, Zaidah & Abu Mangshor, Nur Nabilah. (2018). Celebrity Face Recognition using Deep Learning. *Indonesian Journal of Electrical Engineering and Computer Science*. 12. 476-481. 10.11591/ijeecs.v12.i2.pp476-481.
56. C. Szegedy et al., "Going deeper with convolutions," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, pp. 1-9, doi: 10.1109/CVPR.2015.7298594.
57. M. Al-Qizwini, I. Barjasteh, H. Al-Qassab and H. Radha, "Deep learning algorithm for autonomous driving using GoogLeNet," 2017 IEEE Intelligent Vehicles Symposium (IV), 2017, pp. 89-96, doi: 10.1109/IVS.2017.7995703.
58. Z. Zhong, L. Jin and Z. Xie, "High performance offline handwritten Chinese character recognition using GoogLeNet and directional feature maps," 2015 13th International Conference on Document Analysis and Recognition (ICDAR), 2015, pp. 846-850, doi: 10.1109/ICDAR.2015.7333881.
59. P. Aswathy, Siddhartha and D. Mishra, "Deep GoogLeNet Features for Visual Object Tracking," 2018 IEEE 13th International Conference on Industrial and Information Systems (ICIIS), 2018, pp. 60-66, doi: 10.1109/ICIINFS.2018.8721317.
60. Z. Xiong, Y. Yuan and Q. Wang, "AI-NET: Attention Inception Neural Networks for Hyperspectral Image Classification," IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium, 2018, pp. 2647-2650, doi: 10.1109/IGARSS.2018.8517365.
61. Zhang, Ziang & Wu, Chengdong & Coleman, Sonya & Kerr, Dermot. (2020). DENSE-INception U-net for medical image segmentation. *Computer Methods and Programs in Biomedicine*. 192. 105395. 10.1016/j.cmpb.2020.105395.
62. L. J. Halawa, A. Wibowo and F. Ernawan, "Face Recognition Using Faster R-CNN with Inception-V2 Architecture for CCTV Camera," 2019 3rd International Conference on Informatics and Computational Sciences (ICICoS), 2019, pp. 1-6, doi: 10.1109/ICICoS48119.2019.8982383.
63. A. M. Awal, N. Ghanmi, R. Sicre and T. Furon, "Complex Document Classification and Localization Application on Identity Document Images," 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR), 2017, pp. 426-431, doi: 10.1109/ICDAR.2017.77.

64. Jaderberg, M., Simonyan, K., Vedaldi, A., & Zisserman, A. (2015). Deep Structured Output Learning for Unconstrained Text Recognition. CoRR, abs/1412.5903.
65. Song, Yan-Yan & Lu, Ying. (2015). Decision tree methods: applications for classification and prediction. Shanghai archives of psychiatry. 27. 130-5. 10.11919/j.issn.1002-0829.215044.
66. „Decision Trees for Machine Learning“. [Žiūrėta 2020-03-24] Prieiga prie internetą: <https://devopedia.org/decision-trees-for-machine-learning>.
67. S. Aich, K. Younga, K. L. Hui, A. A. Al-Absi and M. Sain, "A nonlinear decision tree based classification approach to predict the Parkinson's disease using different feature sets of voice data," 2018 20th International Conference on Advanced Communication Technology (ICACT), 2018, pp. 638-642, doi: 10.23919/ICACT.2018.8323864.
68. Y. Zhao, L. Yang, B. Lehman, J. de Palma, J. Mosesian and R. Lyons, "Decision tree-based fault detection and classification in solar photovoltaic arrays," 2012 Twenty-Seventh Annual IEEE Applied Power Electronics Conference and Exposition (APEC), 2012, pp. 93-99, doi: 10.1109/APEC.2012.6165803.
69. Yang, Jaemo & Qin, Gong & Tang, Peifu & Shen, & Liu, Tai-Yi & Gao, Shuai. (2019). Delineation of Urban Growth Boundaries Using a Patch-Based Cellular Automata Model under Multiple Spatial and Socio-Economic Scenarios. Sustainability. 11. 6159. 10.3390/su11216159.
70. H. Zhang et al., "Image Classification Using RapidEye Data: Integration of Spectral and Textual Features in a Random Forest Classifier," in IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 10, no. 12, pp. 5334-5349, Dec. 2017, doi: 10.1109/JSTARS.2017.2774807.
71. Mahdianpari, Masoud & Salehi, Bahram & Mohammadimanesh, Fariba & Motagh, Mahdi. (2017). Random forest wetland classification using ALOS-2 L-band, RADARSAT-2 C-band, and TerraSAR-X imagery. ISPRS Journal of Photogrammetry and Remote Sensing. 130. 13 - 31. 10.1016/j.isprsjprs.2017.05.010.
72. M. Pal, "Random forests for land cover classification," IGARSS 2003. 2003 IEEE International Geoscience and Remote Sensing Symposium. Proceedings (IEEE Cat. No.03CH37477), 2003, pp. 3510-3512 vol.6, doi: 10.1109/IGARSS.2003.1294837.
73. Zhu, Xi & Du, Xiaofei & Kerich, Mike & Lohoff, Falk & Momenan, Reza. (2018). Random Forest Based Classification of Alcohol Dependence Patients and Healthy Controls Using Resting State MRI. Neuroscience Letters. 676. 10.1016/j.neulet.2018.04.007.
74. M. S. Alam and S. T. Vuong, "Random Forest Classification for Detecting Android Malware," 2013 IEEE International Conference on Green Computing and Communications and IEEE Internet of Things and IEEE Cyber, Physical and Social Computing, 2013, pp. 663-669, doi: 10.1109/GreenCom-iThings-CPSCom.2013.122.
75. Evgeniou, Theodoros & Pontil, Massimiliano. (2001). Support Vector Machines: Theory and Applications. 2049. 249-257. 10.1007/3-540-44673-7_12.
76. García-Gonzalo, Esperanza & Fernández-Muñiz, Zulima & Garcia Nieto, Paulino Jose & Sánchez, Antonio & Menéndez, Marta. (2016). Hard-Rock Stability Analysis for Span Design in Entry-Type Excavations with Learning Classifiers. Materials. 9. 531. 10.3390/ma9070531.
77. Gholami, Raouf & Fakhari, Nikoo. (2017). Chapter 27. Support Vector Machine: Principles, Parameters, and Applications. 10.1016/b978-0-12-811318-9.00027-2.

78. Xiaowu Sun, Lizhen Liu, Hanshi Wang, Wei Song and Jingli Lu, "Image classification via support vector machine," 2015 4th International Conference on Computer Science and Network Technology (ICCSNT), 2015, pp. 485-489, doi: 10.1109/ICCSNT.2015.7490795.
79. M. U. Khan, S. Aziz, M. Bilal and M. B. Aamir, "Classification of EMG Signals for Assessment of Neuromuscular Disorder using Empirical Mode Decomposition and Logistic Regression," 2019 International Conference on Applied and Engineering Mathematics (ICAEM), 2019, pp. 237-243, doi: 10.1109/ICAEM.2019.8853684.
80. Ebrahimi, Mohammad & Khoshtaghaza, Mohammad-Hadi & Minaee, Saeed & Jamshidi, Bahareh. (2017). Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*. 137. 52–58. 10.1016/j.compag.2017.03.016.
81. C. Yi, X. Yang and Y. Tian, "Feature Representations for Scene Text Character Recognition: A Comparative Study," 2013 12th International Conference on Document Analysis and Recognition, 2013, pp. 907-911, doi: 10.1109/ICDAR.2013.185.
82. S. Lee, M. Bang, K. Jung and K. Yi, "An efficient selection of HOG feature for SVM classification of vehicle," 2015 International Symposium on Consumer Electronics (ISCE), 2015, pp. 1-2, doi: 10.1109/ISCE.2015.7177766.
83. Sicre, Ronan & Awal, Ahmad Montaser & Furon, Teddy. (2017). Identity Documents Classification as an Image Classification Problem. 602-613. 10.1007/978-3-319-68548-9_55.
84. Emma Amor, „4 CNN Networks Every Machine Learning Engineer Should Know“. [Žiūrėta 2021-01-29] Prieiga per internetą: <https://www.topbots.com/important-cnn-architectures/#:~>
85. Trung Anh Dang „Top 10 CNN Architectures Every Machine Learning Engineer Should Know“. [Žiūrėta 2021-02-13] Prieiga per internetą: <https://towardsdatascience.com/top-10-cnn-architectures-every-machine-learning-engineer-should-know-68e2b0e07201>
86. Selvaraj, Arivazhagan & Shebiah, Newlin & Ananthi, S. & Varthini, S.. (2013). Detection of unhealthy region of plant leaves and classification of plant leaf diseases using texture features. *Agricultural Engineering International: CIGR Journal*. 15. 211-217.
87. Siddharth Das, „CNN Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more...“. [Žiūrėta 2021-03-12] Prieiga per internetą: <https://medium.com/analytics-vidhya/cnns-architectures-lenet-alexnet-vgg-googlenet-resnet-and-more-666091488df5>

8. Terminų ir santrumpų žodynas

Santrumpos:

PA – panaudos atvejis (angl. *use case*);

ML – mašininis mokymasis (angl. *Machine Learning*);

SVM – vektorinės atramos mašinos (angl. *Support Vector Machines*).

CNN – konvoliuciniai neuroniniai tinklai (angl. *Convolutional Neural Networks*);

ANN – dirbtiniai neuroniniai tinklai (angl. *Artificial Neural Networks*);

9. Priedai

Žemiau 9.1 – 9.2 lentelėse pateikiami sistemos testavimo metu gauti rezultatai, naudojant testavimo duomenis, juos padalinant ir matomas modelio veikimo stabilumas aptinkant dokumento tipą ar šalį su CNN ir SVM algoritmais.

9.1 lentelė CNN modelių testavimo rezultatai

Atpažinimo objektas Bandymas	Dokumento tipas	Paso šalis	Asmens tapatybės kortelės šalis
Pirmas	93.5%	85.5%	86.2%
Antras	96.3%	91.3%	88.3%
Trečias	94.9%	87.1%	87.2%
Ketvirtas	94.9%	89.7%	87.3%
Penktas	94.3%	86.6%	85.8%
Šeštas	95.5%	90.2%	88.7%
Septintas	93.2%	90.9%	87.4%
Aštuntas	96.7%	85.9%	87.1%
Devintas	93.3%	90.6%	84.2%
Dešimtas	96.6%	86.2%	90.3%

9.1 lentelėje pateikiami visų 10 sistemos bandymų rezultatai CNN algoritmu, šis modelis pateikė geriausius rezultatus iš visų vykdytų testų iki eksperimentinės dalies. Visų bandymu metu dokumento tipas buvo aptiktas tiksliausiai, o šalies nustatymo tikslumas mažesnis dėl didesnio klasių skaičiaus ir nuotraukų panašumo.

9.2 lentelė SVM modelių testavimo rezultatai

Atpažinimo objektas Bandymas	Dokumento tipas	Paso šalis	Asmens tapatybės kortelės šalis
Pirmas	92.0%	87.2%	83.4%
Antras	92.2%	87.9%	89.8%
Trečias	91.2%	84.3%	87.2%
Ketvirtas	93.0%	90.8%	86.0%
Penktas	95.5%	83.6%	92.8%

Šeštas	88.7%	91.6%	80.4%
Septintas	90.3%	89.4%	89.5%
Aštuntas	93.9%	85.8%	83.8%
Devintas	94.3%	84.5%	90.0%
Dešimtas	89.9%	90.7%	83.2%

Pateikti SVM algoritmo realizuoto sistemoje testavimo rezultatai (9.2 lentelė), kur galima matyti visų 10 bandymų gautus rezultatus.

Žemiau esančiose 9.3 – 9.5 lentelėse pateikti trijų skirtingų uždavinių, atpažinti iš nuotraukos dokumento tipą, asmens tapatybės kortelės ir paso šali, eksperimentinių tyrimų rezultatai.

9.3 lentelė Dokumento tipo atpažinimo uždavinio eksperimentinio tyrimo rezultatai

	Siūloma architektūra	"VGG1 6"	"VGG1 9"	"ResNet 50"	"ResNet1 52"	"Inception v3"
Modelio dydis, MB	9.8	69	90.3	135	274.8	140.4
Parametrų kiekis, mln.	0.813217	17.24399	22.553686	33.643414	68.38735	34.930486
Apmokomų parametrų kiekis, mln.	0.813217	17.24399	2.529302	10.055702	10.055702	13.123702
Testavimo laikas, s	10276	27867	26882	13217	15832	4709
Vidutinis testavimo tikslumas, %	96.5	81.1	81.4	97.4	92.8	97.6
Testavimo duomenų kiekis	51684	51684	51684	51684	51684	51684
Apmokymo laikas, s	11246	51844	24657	18267	24464	17246
apmokymo praradimas (angl. <i>training loss</i>)	0.2423	0.0318	0.009	0.0067	5.35	0.016
Apmokymo tikslumas	95.8	99.3	99.8	99.8	85.9	99.6
Validavimo praradimas (angl. <i>validation loss</i>)	0.1618	0.0152	0.0524	0.0427	1.5349	0.0897
Validavimo tikslumas, %	96.4	99.7	98.6	99.1	89.1	97.4
Apmokymo duomenų kiekis	21440	21440	21440	21440	21440	21440
Blogos kokybės nuotraukų aptikimo tikslumas, %	95.5	74.2	72.4	96.3	87.8	96.6
Blogos kokybės testavimo nuotraukų kiekis	1458	1458	1458	1458	1458	1458

Lentelėje (9.3 lentelė) pateikti dokumento tipo nustatymo modulių eksperimentinio tyrimo rezultatai.

9.4 lentelė Asmens tapatybės kortelės šalies atpažinimo eksperimentinio tyrimo rezultatai

	Siūloma architektūra	"VGG1 6"	"VGG1 9"	"ResNet 50"	"ResNet1 52"	"Inception v3"
Testavimo laikas, s	6165	17722	16129	7930	9499	2825
Vidutinis testavimo tikslumas, %	93.2	77.8	78.1	94.1	89.5	94.3
Testavimo duomenų kiekis	25824	25824	25824	25824	25824	25824
Apmokymo laikas, s	2409	11106	26706	2593	5137	3621
apmokymo praradimas (angl. <i>training loss</i>)	0.0678	0.0042	0.0048	0.0028	5.7691	0.2145
Apmokymo tikslumas	92.5	99.3	98.9	99.6	82.6	92.5
Validavimo praradimas (angl. <i>validation loss</i>)	0.2025	0.0137	0.0129	0.0105	1.8259	0.1024
Validavimo tikslumas, %	93.6	96.4	96.6	98.1	85.8	93.6
Apmokymo duomenų kiekis	10720	10720	10720	10720	10720	10720
Blogos kokybės nuotraukų aptikimo tikslumas, %	92.735	71.45	69.67	93.53	85.11	93.9
Blogos kokybės testavimo nuotraukų kiekis	729	729	729	729	729	729


Asmens tapatybės kortelės šalies nustatymo modulių rezultatai pateikti 9.4 lentelėje.

9.5 lentelė Paso šalies atpažinimo uždavinio eksperimentinio tyrimo rezultatai

	Siūloma architektūra	"VGG1 6"	"VGG1 9"	"ResNet 50"	"ResNet1 52"	"Inception v3"
Testavimo laikas, s	5651.8	15495.35	14785.1	7269.35	8707.6	2589.95
Vidutinis testavimo tikslumas, %	92.7	77.3	77.6	93.5	89.0	93.7
Testavimo duomenų kiekis	25824	25824	25824	25824	25824	25824
Apmokymo laikas, s	1911	8352	23587	1977	4158	2931
apmokymo praradimas (angl. <i>training loss</i>)	0.2423	0.0072	0.0074	0.0045	6.35	0.016
Apmokymo tikslumas	91.7	98.5	98.6	99.6	81.8	95.5
Validavimo praradimas (angl. <i>validation loss</i>)	0.1618	0.0292	0.0254	0.0192	1.5349	0.0897
Validavimo tikslumas, %	92.78	92.02	92.1	94.79	84.98	93.31
Apmokymo duomenų kiekis	9072	9072	9072	9072	9072	9072
Blogos kokybės nuotraukų aptikimo tikslumas, %	92.1	71.1	69.3	93.2	84.7	93.5
Blogos kokybės testavimo nuotraukų kiekis	729	729	729	729	729	729

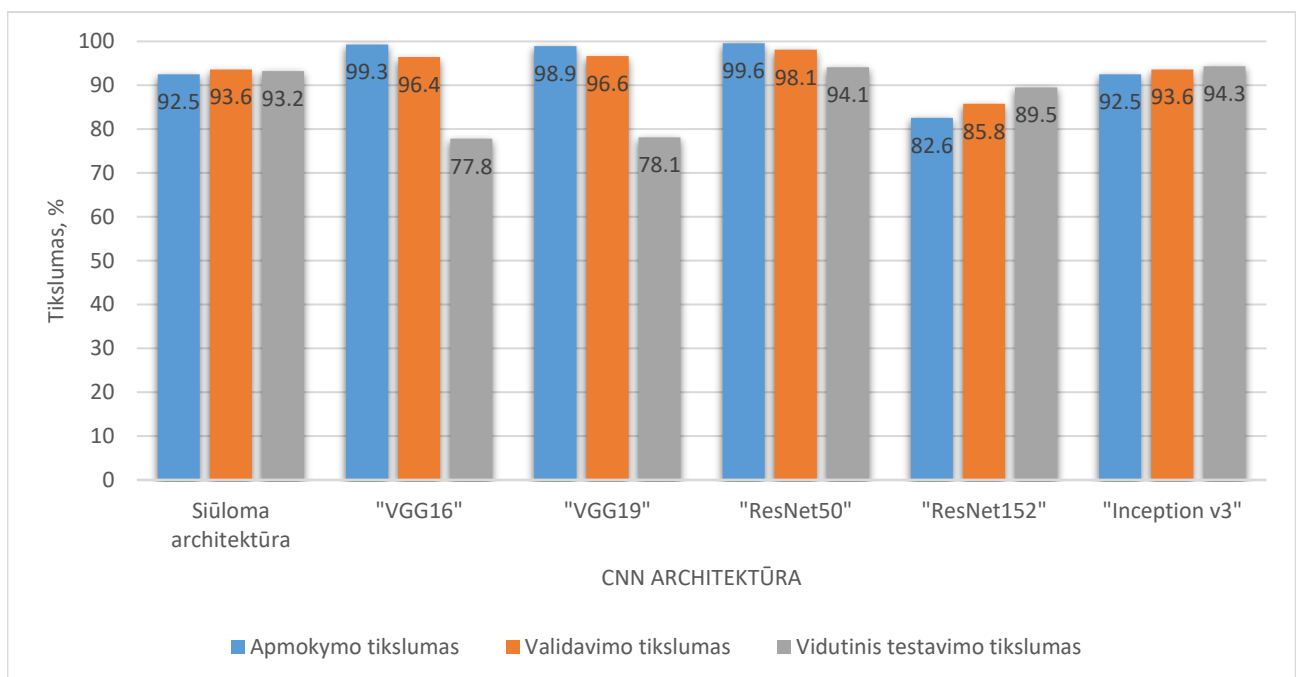
Paso šalies nustatymo skirtingų modulių eksperimentinio tyrimo rezultatai pateikti 9.5 lentelėje.

Žemiau esančiuose paveiksluose (9.1 – 9.3 pav.) pateikti trijų skirtingų uždavinių, atpažinti iš nuotraukos dokumento tipą, asmens tapatybės kortelės ir paso šalį, eksperimentinių tyrimų rezultatai modelių apmokymo, validavimo ir testavimo tikslumui palyginti.



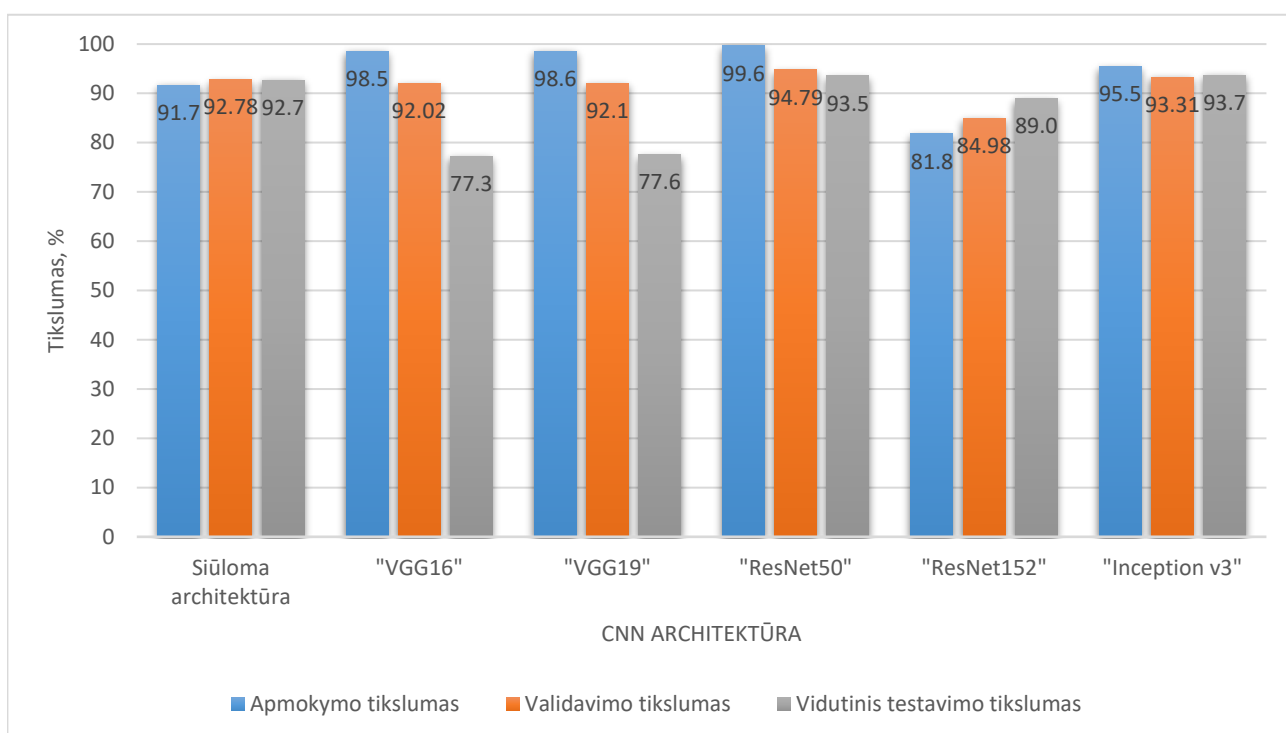
9.1 pav. Eksperimentinio tyrimo rezultatai: modelių tikslumas dokumento tipo nustatymui

Kaip pateikta 9.1 pav. galima matyti, jog didžiausias vidutinis tikslumas gautas su „Inception v3“ architektūra, o mažiausias su „VGG“ architektūromis, kur apmokymo ir validavimo tikslumai yra gan aukšti, tačiau atlikus testavimą su dideliu duomenų kiekiu rezultatai matomi kitokie.



9.2 pav. Eksperimentinio tyrimo rezultatai: modelių tikslumas asmens tapatybės kortelės šalies nustatymui

Asmens tapatybės šalies nustatymo modulių rezultatai pateikti 9.2 pav. kur galima matyti, jog tiek apmokymo ir testavimo rezultatai šalies nustatymui yra mažesni nei dokumento tipo nustatymui.



9.3 pav. Eksperimentinio tyrimo rezultatai: modelių tikslumas paso šalies nustatymui

Kaip pateikta 9.3 pav. galima pastebėti, jog paso šalies nustatymo tikslumas yra visų modulių mažesnis nei ID kortelės, tai yra dėl to, jog pasai tarpusavyje panašesni nei ID kortelės, todėl ML algoritmams sunkiau klasifikuoti šiuos dokumentus.

Žemiau pateiktose 9.6 – 9.11 lentelėse pateikti eksperimentinio tyrimo metu atliktų bandymų rezultatai pagal kiekvieną architektūrą atskirai. Aukščiau pateiktose diagramose (9.1 – 9.3 pav.) matomi tik vidutiniai rezultatai, o šiose rezultatuose, kiekvieno bandymo metu gauti rezultatai. Visi testavimo duomenys buvo padalinti ir atliekami bandymai patikrinti modelių stabilumui.

9.6 lentelė Dokumento tipo modelių testavimo rezultatai, naudojant visus testavimo duomenis

Architektūra \ Bandymas	Siūloma architektūra	"VGG16"	"VGG19"	"ResNet50"	"ResNet152"	"Inception v3"
Pirmas	96.4%	85.1%	78.8%	96.3%	97.0%	97.4%
Antras	96.7%	77.1%	84.0%	98.5%	88.6%	97.8%
Trečias	97.9%	75.6%	80.7%	98.8%	92.6%	96.5%
Ketvirtas	95.1%	86.6%	82.2%	96.0%	93.0%	98.7%
Penktas	94.9%	71.5%	85.2%	95.0%	96.4%	97.3%
Šeštas	98.1%	90.7%	77.6%	99.8%	89.2%	97.9%
Septintas	98.0%	88.9%	74.7%	98.8%	88.5%	97.3%
Aštuntas	95.0%	73.4%	88.1%	96.0%	97.1%	97.9%
Devintas	94.8%	90.9%	87.5%	98.8%	96.2%	97.5%
Dešimtas	98.3%	71.3%	75.3%	96.0%	89.4%	97.7%

Vienuoliktas	97.8%	69.4%	86.3%	97.1%	94.8%	99.6%
Dvyliktas	95.2%	92.9%	76.5%	97.7%	90.9%	95.6%
Tryliktas	95.7%	80.3%	73.5%	96.0%	89.3%	96.1%
Keturioliktas	97.3%	81.9%	89.3%	98.8%	96.3%	99.1%
Penkioliktas	95.1%	81.0%	90.4%	99.6%	92.6%	98.1%
Šešioliktas	97.9%	81.2%	72.4%	95.2%	93.0%	97.1%
Septynioliktas	94.8%	71.2%	81.4%	95.3%	93.3%	96.1%
Aštuonioliktas	98.3%	91.0%	81.4%	99.5%	92.3%	99.1%
Devynioliktas	98.0%	81.1%	85.0%	97.9%	91.3%	95.8%
Dvidešimtas	95.0%	81.1%	77.8%	96.9%	94.3%	99.4%

Dokumento tipo modelių testavimo rezultatai, naudojant visus testavimo duomenis, pateikiami 9.6 lentelėje.

9.7 lentelė Dokumento tipo modelių testavimo rezultatai, naudojant blogos kokybės nuotraukas

Architektūra Bandymas	Siūloma architektūra	"VGG16"	"VGG19"	"ResNet50"	"ResNet152"	"Inception v3"
Pirmas	93.9%	59.3%	81.3%	94.6%	84.0%	96.0%
Antras	97.1%	89.1%	63.5%	98.0%	91.6%	97.3%
Trečias	95.6%	87.3%	82.8%	94.6%	88.0%	97.9%
Ketvirtas	95.4%	61.2%	62.0%	98.0%	87.6%	95.3%
Penktas	95.5%	88.8%	84.4%	93.5%	92.0%	93.6%
Šeštas	95.5%	59.6%	60.4%	99.1%	83.7%	99.6%
Septintas	96.5%	86.2%	76.7%	92.9%	84.1%	99.4%
Aštuntas	94.5%	62.2%	68.1%	99.7%	91.5%	93.9%
Devintas	95.3%	82.9%	76.5%	99.0%	89.0%	96.5%
Dešimtas	95.7%	65.6%	68.3%	93.6%	86.6%	96.7%
Vienuoliktas	96.7%	88.9%	79.2%	98.2%	82.7%	99.8%
Dvyliktas	94.3%	59.5%	65.6%	94.4%	92.9%	93.4%
Tryliktas	93.6%	80.8%	84.2%	98.5%	86.9%	99.7%
Keturioliktas	97.4%	67.7%	60.7%	94.1%	88.7%	93.5%
Penkioliktas	94.8%	83.5%	66.5%	95.0%	90.1%	94.5%
Šešioliktas	96.3%	64.9%	78.3%	97.6%	85.5%	98.7%
Septynioliktas	94.0%	70.3%	64.8%	93.4%	93.5%	98.0%
Aštuonioliktas	97.0%	78.1%	80.0%	99.2%	82.2%	95.2%
Devynioliktas	94.6%	79.3%	78.7%	94.4%	86.4%	96.8%
Dvidešimtas	96.4%	69.1%	66.1%	98.2%	89.2%	96.4%

Dokumento tipo modelių testavimo rezultatai, naudojant tik blogos kokybės nuotraukas, pateikiami 9.7 lentelėje.

9.8 lentelė Asmens tapatybės kortelės šalies nustatymo modelių testavimo rezultatai, naudojant visus testavimo duomenis

Architektūra Bandymas	Siūloma architektūra	"VGG16"	"VGG19"	"ResNet50"	"ResNet152"	"Inception v3"
Pirmas	93.9%	84.3%	85.1%	97.5%	87.6%	98.0%
Antras	92.5%	71.3%	71.1%	90.7%	91.4%	90.6%
Trečias	95.2%	84.4%	80.9%	96.0%	97.9%	89.0%
Ketvirtas	91.2%	71.2%	75.3%	92.2%	81.1%	99.6%
Penktas	94.4%	72.1%	91.6%	97.9%	97.3%	99.1%
Šeštas	92.0%	83.5%	64.6%	90.3%	81.7%	89.5%
Septintas	94.0%	71.8%	84.4%	92.8%	84.0%	97.0%
Aštuntas	92.4%	83.8%	71.8%	95.5%	95.0%	91.6%
Devintas	92.6%	83.0%	83.6%	98.8%	89.4%	95.5%
Dešimtas	93.8%	72.6%	72.6%	89.4%	89.6%	93.1%
Vienioliktas	92.9%	72.5%	91.6%	95.9%	90.0%	89.6%
Dvyliktas	93.5%	83.2%	64.6%	92.3%	89.0%	99.0%
Tryliktas	91.5%	78.9%	88.8%	98.5%	85.6%	95.5%
Keturioliktas	94.9%	76.7%	67.4%	89.7%	93.4%	93.1%
Penkioliktas	92.9%	63.7%	84.2%	94.4%	97.6%	92.4%
Šešioliktas	93.6%	91.9%	72.0%	93.8%	81.4%	96.3%
Septynioliktas	92.8%	68.2%	70.8%	93.0%	87.2%	98.2%
Aštuonioliktas	93.6%	87.4%	85.5%	95.2%	91.8%	90.5%
Devynioliktas	94.1%	78.0%	80.3%	91.9%	86.9%	91.9%
Dvidešimtas	92.3%	77.6%	75.9%	96.3%	92.1%	96.7%

Asmens tapatybės kortelės šalies nustatymo modelių testavimo rezultatai, naudojant visus testavimo duomenis, pateikiami 9.8 lentelėje.

9.9 lentelė Asmens tapatybės kortelės šalies nustatymo modelių testavimo rezultatai, naudojant tik blogos kokybės nuotraukas

Architektūra Bandymas	Siūloma architektūra	"VGG16"	"VGG19"	"ResNet50"	"ResNet152"	"Inception v3"
Pirmas	91.5%	81.7%	61.6%	95.1%	93.9%	97.3%
Antras	93.9%	61.1%	77.6%	91.9%	76.3%	90.5%
Trečias	93.4%	68.7%	65.6%	94.5%	76.9%	92.0%
Ketvirtas	92.0%	74.1%	73.6%	92.5%	93.3%	95.9%
Penktas	91.1%	60.2%	75.3%	98.6%	77.3%	97.9%
Šeštas	94.3%	82.6%	63.9%	88.4%	92.9%	89.9%
Septintas	90.7%	66.6%	59.9%	93.9%	95.7%	90.5%
Aštuntas	94.7%	76.2%	79.4%	93.1%	74.5%	97.4%

Devintas	92.1%	63.7%	82.0%	90.3%	75.1%	94.3%
Dešimtas	93.3%	79.1%	57.2%	96.7%	95.1%	93.5%
Vienuoliktas	94.8%	82.8%	65.4%	94.1%	96.0%	94.3%
Dvyliktas	90.6%	60.0%	73.8%	93.0%	74.2%	93.6%
Tryliktas	93.5%	74.4%	75.1%	96.5%	87.3%	93.4%
Keturioliktas	91.9%	68.4%	64.1%	90.5%	82.9%	94.4%
Penkioliktas	93.8%	60.8%	63.0%	94.2%	90.4%	90.0%
Šešioliktas	91.6%	82.0%	76.2%	92.8%	79.8%	97.8%
Septynioliktas	93.3%	86.5%	61.1%	93.4%	86.0%	99.5%
Aštuonioliktas	92.1%	56.3%	78.1%	93.6%	84.2%	88.3%
Devynioliktas	90.7%	72.9%	63.7%	98.4%	83.3%	99.4%
Dvidešimtas	94.7%	69.9%	75.5%	88.6%	86.9%	88.4%

Asmens tapatybės kortelės šalies nustatymo modelių testavimo rezultatai, naudojant tik blogos kokybės nuotraukas, pateikiami 9.9 lentelėje.

9.10 lentelė Paso šalies nustatymo modelių testavimo rezultatai, naudojant visas nuotraukas

Architektūra Bandymas	Siūloma architektūra	"VGG16"	"VGG19"	"ResNet50"	"ResNet152"	"Inception v3"
Pirmas	90.7%	78.3%	77.7%	93.3%	81.7%	95.5%
Antras	94.7%	76.3%	77.5%	93.7%	96.3%	92.0%
Trečias	93.8%	67.5%	66.9%	97.0%	81.0%	89.5%
Ketvirtas	91.7%	87.1%	88.3%	90.0%	97.1%	97.9%
Penktas	90.8%	88.1%	71.7%	99.6%	80.9%	93.7%
Šeštas	94.6%	66.6%	83.5%	87.4%	97.1%	93.7%
Septintas	91.3%	65.5%	65.3%	93.2%	93.1%	99.3%
Aštuntas	94.1%	89.1%	89.9%	93.8%	84.9%	88.1%
Devintas	93.9%	76.1%	85.1%	92.4%	80.3%	98.7%
Dešimtas	91.5%	78.5%	70.1%	94.6%	97.7%	88.7%
Vienuoliktas	91.4%	90.7%	73.6%	95.1%	89.1%	95.3%
Dvyliktas	94.0%	63.9%	81.6%	91.9%	88.9%	92.1%
Tryliktas	92.5%	71.1%	80.0%	88.5%	80.3%	91.2%
Keturioliktas	92.9%	83.5%	75.2%	98.5%	97.7%	96.2%
Penkioliktas	92.3%	67.5%	69.4%	96.4%	94.0%	93.2%
Šešioliktas	93.1%	87.1%	85.8%	90.6%	84.0%	94.2%
Septynioliktas	91.6%	69.4%	72.9%	92.9%	95.6%	91.7%
Aštuonioliktas	93.8%	85.2%	82.3%	94.1%	82.4%	95.7%
Devynioliktas	93.6%	92.3%	79.6%	95.2%	91.1%	97.9%
Dvidešimtas	91.8%	62.3%	75.6%	91.8%	86.9%	89.5%

Paso šalies nustatymo modelių testavimo rezultatai, naudojant visus testavimo duomenis, pateikiami 9.10 lentelėje.

9.11 lentelė Paso šalies nustatymo modelių testavimo rezultatai, naudojant tik blogos kokybės nuotraukas

Architektūra Bandymas	Siūloma architektūra	"VGG16"	"VGG19"	"ResNet50"	"ResNet152"	"Inception v3"
Pirmas	93.5%	59.0%	55.8%	94.4%	80.6%	92.5%
Antras	90.7%	83.2%	82.8%	92.0%	88.8%	94.5%
Trečias	92.9%	74.0%	68.8%	90.1%	78.5%	93.7%
Ketvirtas	91.3%	68.2%	69.9%	96.3%	90.9%	93.3%
Penktas	90.4%	74.4%	63.2%	94.2%	95.6%	99.0%
Šeštas	93.9%	67.8%	75.4%	92.2%	73.8%	88.0%
Septintas	90.7%	67.1%	56.3%	87.8%	76.1%	93.9%
Aštuntas	93.5%	75.1%	82.3%	98.6%	93.3%	93.2%
Devintas	91.4%	64.5%	68.7%	89.7%	84.9%	90.5%
Dešimtas	92.8%	77.7%	69.9%	96.7%	84.5%	96.5%
Vienuoliktas	91.6%	77.6%	59.8%	93.4%	85.3%	90.8%
Dvyliktas	92.6%	64.6%	78.8%	93.0%	84.1%	96.2%
Tryliktas	94.2%	83.6%	75.6%	94.7%	94.8%	93.2%
Keturioliktas	90.0%	58.6%	63.0%	91.7%	74.6%	93.8%
Penkioliktas	91.5%	82.1%	63.7%	88.5%	74.9%	96.2%
Šešioliktas	92.7%	60.1%	74.9%	97.9%	94.5%	90.8%
Septynioliktas	90.2%	81.5%	66.7%	91.8%	92.7%	87.8%
Aštuonioliktas	94.0%	60.7%	71.9%	94.6%	76.7%	99.2%
Devynioliktas	90.5%	68.3%	60.8%	92.4%	85.2%	98.9%
Dvidešimtas	93.7%	73.9%	77.8%	94.0%	84.2%	88.1%

Paso šalies nustatymo modelių testavimo rezultatai, naudojant tik blogos kokybės nuotraukas, pateikiami 9.11 lentelėje.

Žemiau esančiame paveiksle (9.4 pav.) pateiktas realizuotos intelektinės asmens tapatybės atpažinimo sistemos perdavimo ir aprobavimo aktas.

PROGRAMŲ SISTEMOS PERDAVIMO IR APROBAVIMO AKTAS

UAB „Identifikaciniai projektai“
Įmonės kodas 304617621
Baršausko g. 59, LT-51423 Kaunas
Tel. +37064084466
Tinklapis: <https://www.idenfy.com>

PROGRAMŲ SISTEMOS PERDAVIMO IR APROBAVIMO AKTAS

2020 m. gruodžio 28 d.

Programų sistemos pavadinimas Intelektinė asmens tapatybės dokumentų atpažinimo sistema.

Kūrinio tipas Intelektinė asmens tapatybės dokumentų atpažinimo sistemos programinė įranga.

Programų sistemos sukūrimo data 2020 m. gruodžio 21 d

Kūrinio įteikimo UŽSAKOVUI data 2020 m. gruodžio 25 d.

Užsakovo arba trečiojo asmens Kūrinio aprobavimo rezultatas:

Programų sistemos „Intelektinė asmens tapatybės dokumentų atpažinimo sistema“ paskirtis – nustatyti asmens tapatybės dokumento šalį ir tipą ir vaizdinės medžiagos, nuotraukų. Programų sistemos parengta tiek sistemos sąsaja tiek ir įrankis naudojamas asmeniniame kompiuteryje, kurio pagalba gali ne tik atlikti dokumento atpažinimą, bet ir apmokyti naujus mašininio mokymo algoritmus, juos testuoti, peržiūrėti testavimų istoriją ir ištrinti nepavykusius bandymus. Reikalingas serveris patalpinti sistemų sąsają (angl. API) Ubuntu 16.04 operacinė sistema su Python 3.8 versija. Įrankis yra naudojamas kaip programavimo projektas, paleidžiant main.py failą. Sistema įdiegta įmonės naudojamuose serveriuose Amazon Web Service (AWS). Laikinas serverio IP: 63.35.175.116 pasiekiamas iki 2021m. sausio 23 dienos.

Kūrinio aprobavimo data 2020 m. gruodžio 27 d.

Kūrinio originalo saugotojas - Domantas Čiuldė

<p>AUTORIUS</p> <p>Andrius Šulskis <i>(vardas, pavardė)</i></p>	<p>UŽSAKOVAS</p> <p>Domantas Čiuldė <i>(vardas, pavardė)</i></p>
--	---

9.4 pav. Sistemos įdiegimo aktas