

**VILNIAUS UNIVERSITETO
FIZIKOS FAKULTETO
FOTONIKOS IR NANOTECHNOLOGIJŲ INSTITUTAS**

**Laurynas Endriukaitis
Terahercinių bangų ruože veikiančio difrakcinio neuroninio tinklo kūrimas ir
tyrimas**

MAGISTRO STUDIJŲ BAIGIAMASIS DARBAS

Fotonikos ir Nanotechnologijų studijų programa

Studentas

Laurynas Endriukaitis

Darbo vadovas

dr. Ignas Grigelionis

Recenzentas

prof. dr. Vincas Tamošiūnas

Instituto vadovas

prof. dr. Ramūnas Aleksiejūnas

Vilnius 2022

Turinys

Padėka	3
1. Įžanga	3
2. Literatūros apžvalga	5
2.1. Dirbtinis intelektas	5
2.2. Mašininis mokymasis	7
2.3. Gilusis mokymasis	9
2.3.1. Pilnai sujungtų sąryšių neuroninis tinklas	9
2.3.2. Konvoliucinis neuroninis tinklas	12
2.4. Difrakcinis neuroninis tinklas	13
2.5. Kampinio spektro metodas	15
2.6. Terahercinė spinduliuotė	17
2.7. 3D spausdinimo technologija	19
3. Tyrimo metodika	20
4. Tyrimų rezultatai bei jų aptarimas	27
4.1. Difrakcinio neuroninio tinklo modeliavimas bei optimalių parametrų nustatymas	27
4.1.1. Objektų sutinkamų kasdienėje aplinkoje klasifikavimas	27
4.1.2. Difrakcinio neuroninio tinklo objektų klasifikavimo rezultatų priklausomybė nuo difrakcinių plokštelių skaičiaus	30
4.1.3. Difrakcinio neuroninio tinklo galimybės klasifikuoti objektus keičiant atstumą tarp plokštelių	32
4.1.4. MNIST duomenų rinkinio klasifikavimas	34
4.2. Fiziškai realizuoto difrakcinio neuroninio tinklo testavimas	35
5. Išvados	38
6. Šaltiniai	39
7. Summary	43

Padėka

Noriu padėkoti darbo vadovui dr. Ignei Grigelioniui už nuolatinę pagalbą bei kuravimą magistrantūros studijų metu. Taip pat dėkoju dr. Andrzej Urbanowicz už atliktus medžiagų parametrų matavimus, be kurių nebūtų pavykę sukurti tikslaus neuroninio tinklo modelio. Galiausiai, noriu padėkoti doktorantei Rusnei Ivaškevičiūtei-Povilauskienei už puikiai trimačiu spausdintuvu pagamintas difrakcines plokšteles su kuriomis ir buvo atliktas fizinio neuroninio tinklo testavimas.

1. Įžanga

Mašininis mokymasis yra viena iš sparčiausiai augančių bei labiausiai tiriamų dirbtinio intelekto (DI) šakų^[1]. Pats mašininis mokymasis yra duomenų analizės metodas, pagrįstas idėja, kad galima sukurti algoritmus, kurie mokytųsi iš jiems pateiktų duomenų – atpažintų juose esančius svarbius aspektus ir galėtų atlikti pateiktą užduotį be žmogaus įsikišimo. Pagrindinė priežastis kodėl mašininis mokymas, o ypač dirbtiniai neuroniniai tinklai pradėjo dominuoti dirbtinio intelekto srityje pastarąjį dešimtmetį yra ta, jog buvo parodyta, kad pasitelkiant dirbtinius neuroninius tinklus galima atlikti daugelį užduočių, kurių nėra pavykę išspręsti jokiais kitais dirbtinio intelekto algoritmais ir net kai kurias sudėtingas užduotis atlikti palyginamai arba net geriau už žmones, dirbančius toje srityje. Gilusis mokymas padarė perversmą skaitmeninėje nuotraukų analizėje^[2, 3], kalbos atpažinime ir jos vertime^[4]. Didelis neuroninių tinklų potencialas taip pat gali būti panaudojamas atliekant įvairius mokslinius tyrimus^[5] ar net atrandant naujas medžiagas^[6]. Dirbtinių neuroninių tinklų universalumas ir sugebėjimas spręsti net ir pačias sudėtingiausias užduotis yra paaiškinamas didelio skaičiaus neuronų bendradarbiavimo jungtimis, kas leidžia aproksimuoti bet kokią matematinę funkciją^[7].

Tokia daugybė panaudojimų ir toks universalumas bei vis nauji proveržiai dirbtinių neuroninių tinklų srityje lėmė žymų publikuojamų mokslinių straipsnių šuolį. Recenzuojamų publikacijų skaičius DI srityje per paskutinius 20 metų išaugo apie 12 kartų, o taip pat ir recenzuotų straipsnių dalis dirbtinio intelekto srityje lyginant su visais recenzuotais straipsniais išaugo maždaug 5 kartus^[8].

Nors elektroniniai dirbtiniai neuroniniai tinklai yra vis plačiau integruojami įvairiose srityse ir sugeba atlikti užduotis, kurios ilgą laiką buvo neišsprendžiamos, jie vis tiek turi trūkumų, kurie apsunkina jų panaudojimą. Vienas iš tokių trūkumų ir tas, kad dirbtiniai neuroniniai tinklai dažnai reikalauja didelio kiekio iš anksto surinktų duomenų. Priklausomai nuo užduoties ir duomenų sudėtingumo gali būti reikalinga nuo kelių šimtų iki šimtų tūkstančių ar net kelių milijonų pavyzdžių, tam kad algoritmas

išmokyti atlikti jam paskirtą užduotį. Neretai apmokymo procesas gali užtrukti gana ilgai ir reikalauja didelės skaičiuojamosios galios bei ženklų energijos išteklių tiek paties tinklo apmokymui, tiek jau apmokytam tinklui atliekant užduotis.

Šiuo metu didžioji dalis neuroninių tinklų realizuojami kompiuterių atmintyje, o jų veikimo principas paremtas skaičiavimo operacijomis atliekamomis kompiuterio pagrindiniu (CPU) ar grafiniu (GPU) procesoriais. Tačiau vis daugiau dėmesio yra skiriama fiziškai apčiuopiamiems neuroniniams tinklams, kadangi dažnu atveju jie būna energetiškai taupesni^[9, 47]. Pasitelkus fotonus bei jų sąveiką su medžiagomis, įmanoma sukurti alternatyvios architektūros pasyvius fiziškai apčiuopiamus neuroninius tinklus - optinius neuroninius tinklus, kurie pasižymi sugebėjimu atlikti daugybę paralelinių skaičiavimų šviesos greičiu naudojant tik kritusių fotonų energiją ir jų tarpusavio sąveiką^[9]. Vienas iš tokių optinių neuroninių tinklų variantų yra pastaraisiais metais intensyviai tiriamas optinis difrakcinis neuroninis tinklas, kuris yra ypač aktualus terahercinių dažnių ruože, dėl patogumo kuriant fizinius optinio difrakcinio neuroninio tinklo elementus bei plačiai pritaikomų terahercinių bangų savybių^[9, 10, 11]. Difrakcinis neuroninis tinklas veikia pasitelkdamas tik elektromagnetinę spinduliuotę, o apmokymo dalis yra atliekama naudojant kompiuterinį modeliavimą.

Šio darbo tikslas buvo sumodeliuoti ir pasigaminti giliojo difrakcinio neuroninio tinklo elementus bei ištirti tokio tinklo galimybes klasifikuoti pasirinktus objektus. Pagrindiniai darbo uždaviniai siekiant užsibrėžto tikslo buvo: a) kompiuteriu sukurti ir apmokyti gilųjį difrakcinį neuroninį tinklą tiksliai klasifikuoti pasirinktus objektus, nustatyti koks yra optimalus tinklo elementų skaičius bei elementų išdėstymas; b) pagal minėto kompiuterinio tinklo parametrus pasigaminti fizinio giliojo difrakcinio neuroninio tinklo elementus bei ištirti jo objektų klasifikavimo galimybes.

2. Literatūros apžvalga

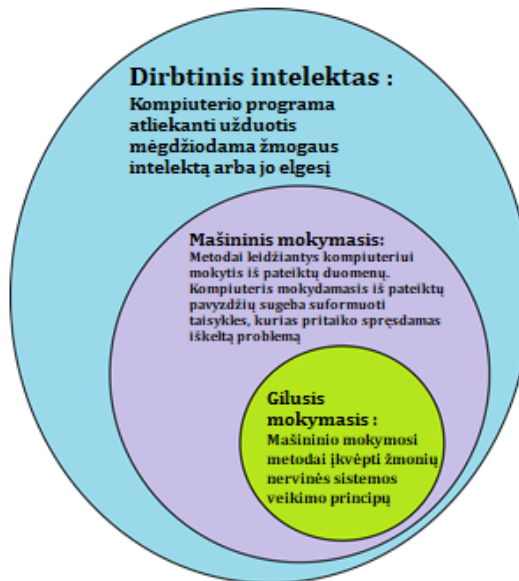
2.1. Dirbtinis intelektas

Dirbtinis intelektas turi daug skirtingų ir vienodai teisingų apibrėžimų. Kompiuterių mokslo specialistai dirbtinio intelekto sąvoką apibrėžia kaip bet koki prietaisą, kuris suvokia savo aplinką ir imasi atitinkamų veiksmų, tam kad galėtų kiek įmanoma tiksliau atlikti jam paskirtą užduotį. Kitose disciplinose dirbtinis intelektas dažnai yra apibrėžiamas gerokai platesne sąvoka - kaip kompiuteris, sugebantis atlikti užduotis, kurios įprastai siejamos su žmogiškuoju intelektu. Net pačioje kompiuterių atsiradimo pradžioje, apie 1950 metus, jau buvo pademonstruota, kad kompiuteriai gali atlikti net ir labai sudėtingas, „mąstymo“ reikalaujančias užduotis – įrodyti tam tikras matematinės teoremas ar net žaisti šachmatais^[12].

Įprastai ankstyvajame dirbtinio intelekto laikotarpyje buvo naudojami analitiniai metodai, kurie remiasi vienareikšmėmis iš anksto žmogaus sugalvotomis instrukcijomis, kurias sekdamas kompiuteris : a) sukuria įvaizdį, kad imituoja žmogaus veiksmus, arba b) tikrina visus variantus, kol suranda teisingą atsakymą^[13]. Tokio dirbtinio intelekto pavyzdys yra algoritmas MiniMax^[14], kurį naudodamas kompiuteris „Deep – Blue“ pirmą kartą istorijoje įveikė šachmatų pasaulio čempioną^[15]. Nors šis algoritmas iš tiesų tiesiog tikrina visas įmanomas šachmatų ėjimų kombinacijas ir jų tinkamumą įvertina pagal žmogaus iš anksto pateiktas instrukcijas, jis taip gerai atlieka jam paskirtą perrinkimo užduotį, kad atrodo, jog kompiuteris iš tikrųjų turi intelektą. Tačiau bandant išspręsti abstrakčias problemas, labai sunku sukurti teisingą taisyklių rinkinį, kuris užtikrintų didelį kompiuterio tikslumą atliekant užduotį. Pavyzdžiui, žmonės gali lengvai atskirti šunį nuo katės tiksliai nesuprasdami kokiomis taisyklėmis vadovavosi. Sudėtinga tiksliai apibrėžti būtent kokie skirtumai tarp šuns ir katės mums leidžia juos taip gerai atskirti, o dar sunkiau yra tai pateikti kompiuteriui.

Būtent dėl tokių analitinių dirbtinio intelekto algoritmų apribojimų buvo sugalvoti naujo tipo algoritmai, kurie nesiremia iš anksto pateiktomis instrukcijomis, o bando patys suprasti kaip atskirti šunį nuo katės, imituodami žmogaus mokymosi procesą. Žmogus sugeba atlikti tam tikrą užduotį jau po kelių bandymų atkreipdamas dėmesį į savo veiksmus proceso metu ir kaip jie atsiliepia galutiniam užduoties rezultatui. Pavyzdžiui, žmonės sugeba atskirti šunį nuo katės dėl to, kad matė daugybę skirtingų gyvūnų ir išsivystė intuiciją kaip juos vieną nuo kito atskirti. Kitaip sakant žmogus mokosi iš sukauptos patirties ir ja remdamasis sprendžia kylančias problemas. Remiantis šiais bendrais principais sukurti algoritmai, kuriems nereikia pateikti griežtai apibrėžto taisyklių rinkinio, o jie patys mokydami iš pateiktų

pavyzdžių sugeba suformuoti taisykles, kurias pritaiko sprenddami iškeltą problemą. Taip veikiantys algoritmai yra priskiriami mašininio mokymosi šakai^[16] (1 pav.).



1 pav. Dirbtinio intelekto skirstymas ir jų apibrėžimai.
Paimta iš [33]

Keli mašininio mokymosi algoritmų pavyzdžiai^[16] :

- Mašininio mokymosi algoritmai (Machine Learning):
 - Sprendimų medžiai
 - K-artimiausi kaimynai (k-Nearest neighbour)
 - Pagalbinės vektorių mašinos (Support Vector Machines)

Dalis mašininio mokymosi algoritmų buvo įkvėpti žmonių nervinės sistemos veikimo principų, tokie algoritmai yra priskiriami giliojo mokymosi šakai :

- Giliojo mokymosi algoritmai (Deep Learning):
 - Pilnai sujungtų sąryšių neuroniniai tinklai
 - Konvoliuciniai neuroniniai tinklai
 - Atsikartojantys neuroniniai tinklai

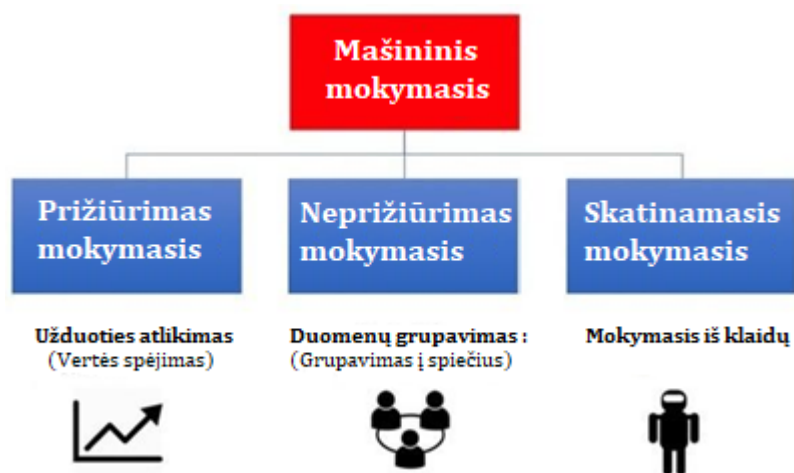
Taigi, dirbtinis intelektas yra plati sąvoka, kurios viena iš sričių yra vadinama mašininio mokymosi, o šios srities šaka gilusis mokymasis ir yra taikomas šiame darbe.

2.2. Mašininis mokymasis

Mašininis mokymasis yra skirstomas į tris kategorijas (2 pav.). Prižiūrimo mokymosi (supervised learning) algoritmai naudoja duomenis, kurių kiekvienas pavyzdys turi prisegtą atsakymą (label), kurį algoritmas turėtų pateikti, jeigu jis teisingai atlieka paskirtą užduotį. Šio tipo algoritmai yra populiariausi nors ir reikalauja daugiau mokymosi duomenų, nes kiekvienam pateiktam pavyzdžiui reikia nurodyti teisingą atsakymą. Prižiūrimo mokymo algoritmai gali atlikti klasifikavimo (atskirti šunį nuo katės) ir regresijos (pateikti tikslų skaičių) užduotis^[13].

Antra kategorija yra neprižiūrimas mokymasis (unsupervised learning) – čia duomenys pateikiami be teisingų atsakymų. Tokie algoritmai įprastai suranda bendrus dėsningumus tarp pateiktų duomenų ir priskiria duotus pavyzdžius skirtingoms grupėms, kitaip tariant išmoksta juos sugrupuoti^[13].

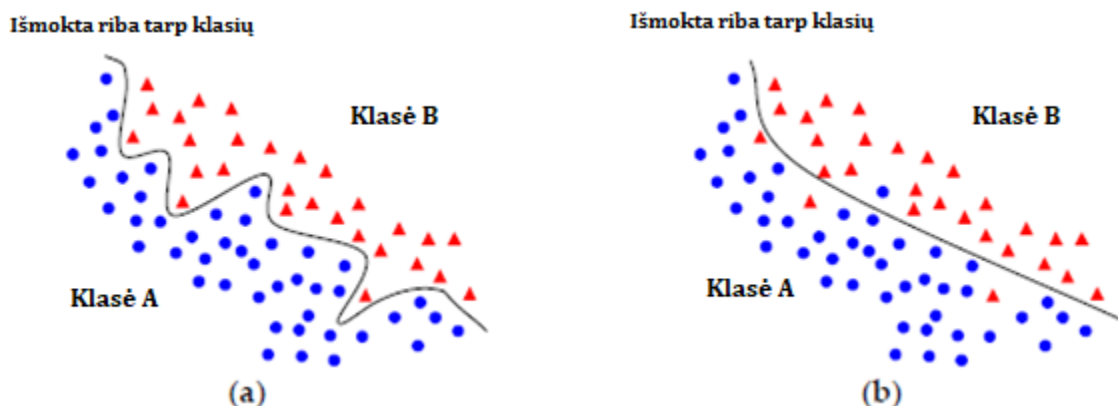
Trečia kategorija, skatinamasis mokymasis (reinforcement learning), skiriasi nuo dviejų jau paminėtų kategorijų tuo, jog šio tipo algoritmams nereikia pateikti jokių išankstinių duomenų: algoritmas juos generuoja pats, pats atlikdamas bandymus ir mokydamasis iš klaidų. Skatinamojo mokymosi algoritmai dažniausiai taikomi apmokant kompiuterį žaisti įvairius žaidimus^[17].



2 pav. Mašininio mokymosi kategorijos.
Paimta iš [34]

Įprastai yra daroma prielaida, jog apmokymo duomenys puikiai atspindi visas bendras savybes, algoritmui reikalingas išmokti spręsti užduotį, tačiau iš tiesų taip nėra, nes pateikiamų duomenų kiekis yra ribotas. Atvejis kai algoritmas išmoksta kai kuriuos ne tokius svarbius aspektus duomenyse ir jais remiasi atlikdamas užduotį yra vadinamas persimokymu. 3 paveiksluke yra matomas persimokymo

pavyzdys, kai užduotis yra priskirti tašką klasei A arba B. Paveiksliuko 3a dalyje matoma riba, kuri geriausiai atskiria abi klases apmokymo duomenyse. Atsižvelgus į tai, jog dalis taškų pasižymi išimtinėmis savybėmis ir neatspindi bendrų klasės bruožų, geresnė riba skirianti A ir B klases yra matoma paveiksliuke 3b. Nors šiuo atveju dalis taškų klasifikuojami neteisingai, tačiau yra geriau atspindimi bendri skirtumai tarp klasių, o tai reiškia, jog taip apmokytas algoritmas geriau klasifikuos naujus, mokymosi metu nematytus duomenis.



3 pav. Klasifikavimo uždavinio persimokymo pavyzdys. (a) riba, kuri geriausiai atskiria dvi klases apmokymo duomenyse. (b) riba, kuri geriausiai atskirs dvi klases klasifikuojant nematytus mokymosi metu duomenis

Paimta iš [16]

Norint išvengti persimokymo idealiu atveju reiktų surinkti kuo didesnę kiekį duomenų, tačiau dažnai tą padaryti yra gana sudėtinga ir nepraktiška. Yra sugalvota nemažai būdų, kurie leidžia dalinai arba kartais net iš viso išvengti persimokymo – parametrų reguliavimas (regularization)^[13], atliekant atsitiktinio praretinimo transformaciją^[18] ar naudojant ansamblio mokymąsi^[19].

Įprastai visi turimi duomenys yra suskirstomi į tris duomenų rinkinius: apmokymo duomenis, validavimo duomenis ir testavimo duomenis. Algoritmas mokosi naudodamas tik apmokymo duomenis. Validavimo duomenys suteikia pirminį supratimą kaip gerai algoritmas atlieka užduotį, o norint pagerinti tikslumą galima pakeisti patį algoritmą kitu arba parinkti geresnius parametrus, taip padedant algoritmui mokytis. Kai naudojant validavimo duomenis yra pasiekiamas norimas algoritmo tikslumas, jam yra pateikiami iki tol nė karto nematyti testavimo duomenys, o gautas rezultatas atspindi realias algoritmo galimybes atliekant pateiktą užduotį. Jeigu kompiuteris sprendžia jam pateiktą problemą padarydamas labai mažai klaidų naudodamas apmokymo duomenis, tačiau pasirodo gerokai blogiau naudodamas validavimo arba testavimo duomenis, tuomet aišku, kad tinklas persimokė ir šią problemą reikia bandyti spręsti anksčiau minėtais metodais.


2.3. Gilusis mokymasis

Gilusis mokymasis – dalis mašininio mokymosi metodų paremtų dirbtiniais neuroniniais tinklais, turinčiais du ar daugiau paslėptųjų sluoksnių^[20].

Neuroninių tinklų konceptas atsirado apie 1940-uosius metus, bet būdas kaip juos efektyviai apmokyti atsirado gerokai vėliau, maždaug po 20 metų, jis vadinamas atgalinio sklidimo metodu (backpropagation). Tačiau net ir sugalvojus efektyvų neuroninių tinklų apmokymo būdą, jie vis tiek nesulaukė didesnio visuomenės dėmesio dėl mokymuisi reikalingo didelio duomenų kiekio, kurį surinkti ilgą laiką buvo beveik neįmanoma užduotis, bei dėl būtinų didelių skaičiavimo pajėgumų, kurie tik palyginus neseniai galėjo būti patenkinti. Milžiniško visuomenės bei mokslininkų dėmesio gilusis mokymasis susilaukė apie 2010 metus, kai šios srities algoritmai pademonstravo, jog sugeba efektyviai išspręsti užduotis, kurios iki tol buvo neįveikiamos jokiais kitais būdais – nuotraukų analizė^[21, 22], kalbų vertimas, garso bei vaizdo sintezė ir generavimas bei daugybė kitų^[23, 24].

2.3.1. Pilnai sujungtų sąryšių neuroninis tinklas

Dirbtinis neuroninis tinklas yra mokymosi modelis, įkvėptas žmogaus nervinės sistemos veikimo principų^[25]. Neuroninis tinklas yra sudarytas iš daugybės pavienių neuronų (4 pav. a). Šie neuronai yra sugrupuoti į sluoksnius. Neuronas esantis tam tikrame sluoksnyje yra sujungtas su visais neuronais esančiais gretimame sluoksnyje, tačiau neturi sąryšių su kitais tame pačiame sluoksnyje esančiais neuronais. Tokios struktūros neuroninis tinklas yra vadinamas pilnai sujungtų sąryšių neuroniniu tinklu (dense neural network) (4 pav. a). Įvesties sluoksnis turi M neuronų, o išvesties sluoksnis turi L neuronų. Kiekviena jungtis tarp neuronų turi savo atskirą svorio koeficientą w (4 pav. b), kuris mokymosi metu yra optimizuojamas ir nulemia įeinančių duomenų svarbą galutiniam rezultatui. Tai pasiekama sudauginant įvesties duomenis su šiuo koeficientu. Kadangi paslėptajame arba išėjimo sluoksniuose esantis neuronas yra sujungtas su visais neuronais esančiais praeitame sluoksnyje jį pasiekianti vertė gaunama atliekant skaliarinės sandaugos operaciją, t.y. sumuojant visas sandaugas pagal į neuroną ateinančių sąryšių skaičių, o prie gautos sumos dar įprastai yra pridodamas tam tikras laisvasis narys, kuris suteikia galimybę neuronui išėjime turėti reikšmę nelygią 0 net ir tada kai visos sandaugos yra 0.



4 pav. Neuroninio tinklo struktūra bei jame vykstantys procesai. (a) Neuronų sluoksniai sujungti tarpusavyje; (b) procesai vykstantys vieno neurono viduje.

Paimta iš [16]

Atlikus aprašytus veiksmus gaunama įvesties į neuroną vertė z (4 pav. b). Neurono išvestis yra gaunama paveikus įvesties vertę tam tikra funkcija $f(z)$, kuri neuroninių tinklų kontekste yra vadinama aktyvacijos funkcija^[20]. Galima taikyti daugybę skirtingų aktyvacijos funkcijų, o taip pat jos gali skirtis ir kiekvienam iš sluoksnių. Keli dažniausiai naudojamų aktyvacijos funkcijos pavyzdžiai^[16]:

- Sigmoid: $f(z) = \frac{1}{1+e^{-z}}$
- Hiperbolinis tangentas: $f(z) = \tanh(z)$
- Softmax: $f(z) = \frac{e^{z_l}}{\sum_{j=1}^L e^{z_j}}$
- Dalimis tiesinis vienetas $f(z) = \text{relu}(x) = (0, z)$

Beveik visos aktyvacijos funkcijos pasižymi tuo, jog jos yra netiesinės. Aktyvacijos funkcijų netiesiškumas paverčia neuroninį tinklą universaliu aproksimatoriumi^[26].

Sprendžiant klasifikacijos užduotį, išėjties sluoksnio neuronuose dažniausiai naudojama Softmax aktyvacijos funkcija, o kiekvienas neuronas yra susietas su atitinkama klase. Išvesties vertė iš neurono tokiu atveju atspindi tikimybę duotam pavyzdžiui priklausyti tai klasei su kuria neuronas yra susietas. Atliekant regresijos uždavinius išvesties sluoksnyje dažniausiai naudojamos tiesinė arba Sigmoid tipo aktyvacijos funkcijos, o neurono išvesties vertė parodo tam tikros savybės spėjimą vertę.

Neuroniniam tinklui pateikus įvesties duomenis ir palyginus jo gautą išvestį su teisingu atsakymu yra gaunama nuostolių vertė. Pora dažnai naudojamų nuostolių funkcijų:

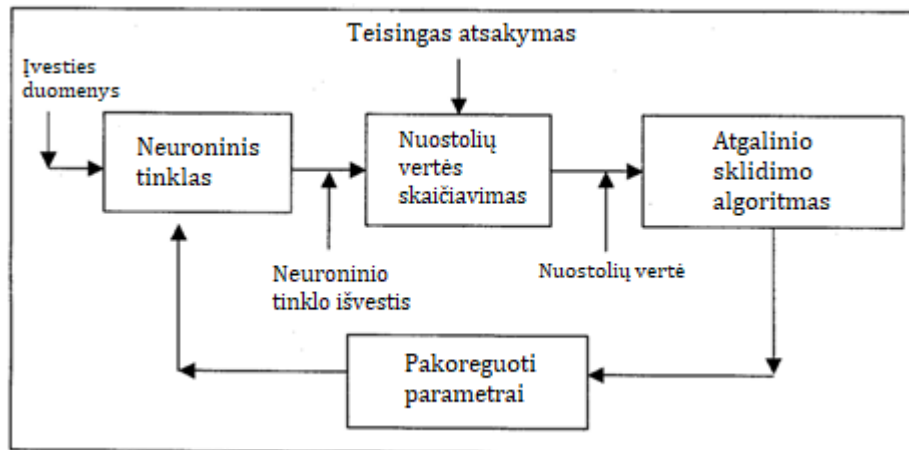
- Kryžminė kategorinė entropija (naudojama sprendžiant klasifikavimo užduotis):

$$\text{Nuostolių vertė} = - \sum_{i=1}^L y_i * \log \hat{y}_i$$

- Vidutinė kvadratinė paklaida (naudojama sprendžiant regresijos užduotis):

$$\text{Nuostolių vertė} = \frac{1}{L} \sum_{i=1}^L (y_i - \hat{y}_i)^2$$

čia L – neuronų skaičius išvesties sluoksnyje, \hat{y}_i – neurono vertė išvesties sluoksnyje, y_i – laukiama teisinga atitinkamo neurono vertė išvesties sluoksnyje. Kuo yra mažesnė nuostolių vertė, tuo tiksliau atliktas tinklo spėjimas. Įvertinus nuostolių vertę galima taikyti atgalinio sklidimo algoritmą, kuris suskaičiuoja kaip koeficientų w ir b (4 pav. b) vertės turi būti pakeistos, tam kad neuroninio tinklo išvestis būtų tikslesnė (sumažėtų nuostolių vertė). Galiausiai, minėtų koeficientų vertės yra keičiamos naudojant stochastinio gradientinio nusileidimo metodą^[20] (5 pav.). Taigi, tinkamiausi parametrai nėra skaičiuojami tiesiogiai, tai užtruktų be galo ilgai, bet jie pakeičiami vis tikslesnėmis vertėmis kiekvieno tinklo apmokymo ciklo metu.




5 pav. Schema parodanti kaip vyksta neuroninio tinklo mokymasis naudojant atgalinio sklidimo metodą.

Paimta iš [35]

Nėra universalių taisyklių, kurios tiksliai pasakytų kiek projektuojant neuroninį tinklą tam tikrai užduočiai atlikti reikia naudoti sluoksnių ar kiek kiekviename sluoksnyje turi būti neuronų, o taip pat yra didelė laisvė pasirenkant ir aktyvacijos funkcijas bei pačio neuroninio tinklo tipą. Dažniausiai praktikoje ta pati užduotis yra atliekama su keliais skirtingais neuroniniais tinklais ir sulyginami gauti rezultatai, o galiausiai pasirenkamas tas tinklas, kuris pateikia tiksliausią atsakymą. Tačiau dažnai norint sutaupyti laiko ar dėl ribotų skaičiavimo pajėgumų daromi tam tikri kompromisai tinklo spėjimo tikslumo sąskaita.

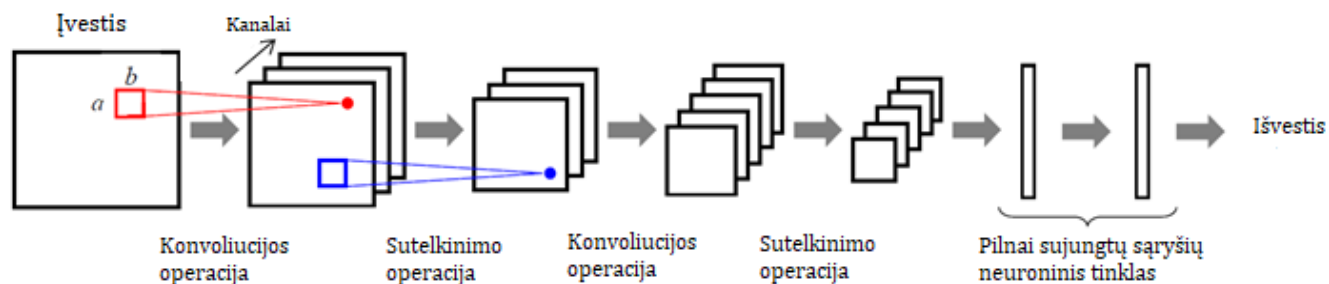
2.3.2. Konvoliucinis neuroninis tinklas

Konvoliuciniai neuroniniai tinklai dažniausiai naudojami nagrinėti dvimačius duomenis, kuriuose yra svarbi erdvinė informacija (nuotraukos, vaizdo įrašai, spektrogramos ir t.t.). Kiekvienos nuotraukos taškas yra susietas su tam tikru neuronu. Konvoliucinio neuroninio tinklo atveju yra atliekama konvoliucijos operacija su pasirinkto dydžio lokalia matymo sritimi (6 pav.). Įprastu atveju lokali matymo sritis būna 3x3 dydžio filtras, kuriame yra 9 neuronai.



6 pav. Konvoliucijos operacijos pavyzdys.
Paimta iš [36]

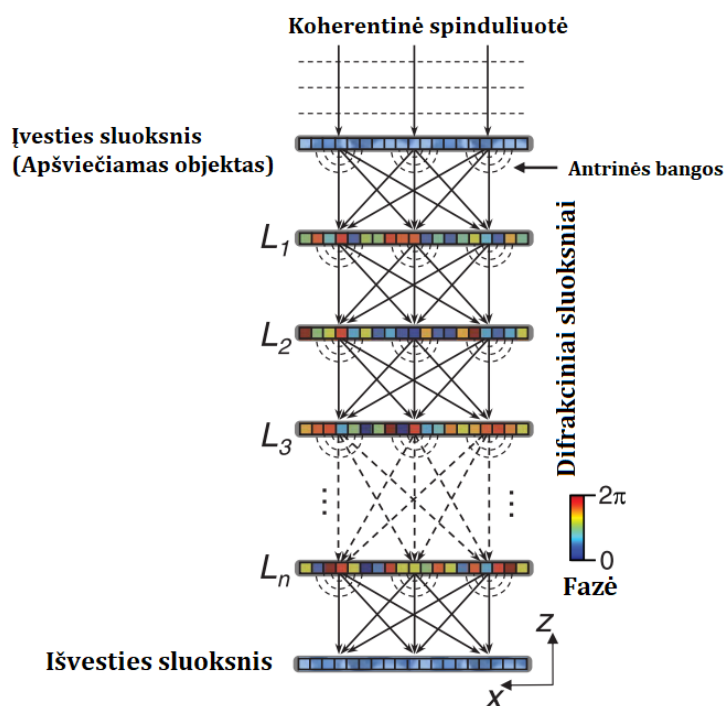
Atliekant konvoliucijas operacijas su skirtingais filtrais yra gaunamos nuotraukos su išryškintomis skirtingomis savybėmis (7 pav.). 7 paveiksluko atveju su spalvota RGB nuotrauka yra atliekamos konvoliucijos operacijos su kiekvienos spalvos kanalu atskirai ir gaunamos trys vienspalvės nuotraukos. Dažnai po konvoliucijos operacijos yra naudojamas sutelkinimo (pooling) operacija, leidžianti sumažinti nuotraukos rezoliuciją, tokiu būdu sumažinant reikalingų skaičiavimų apimtį ir sumažinant kitų sluoksnių jautrumą triukšmams^[27]. Paskutiniai sluoksniai įprastai būna jau aptarto pilnai sujungtų sąryšių tipo. Jie, išanalizavę konvoliucinių sluoksnių gautus rezultatus, pateikia galutinę neuroninio tinklo išvestį.



7 pav. Konvoliucinio neuroninio tinklo architektūra.
Paimta iš [16]

2.4. Difrakcinis neuroninis tinklas

Norint padidinti veikimo spartą bei mažinti įprastiniams skaitmeniniams neuroniniams tinklams reikalingos energijos sąnaudas, kuriami elektromagnetinių bangų sąveika su medžiaga ir jų tarpusavio sąveika grįsti optiniai neuroniniai tinklai. Bendras jų privalumas yra tas, kad jau apmokytame tinkle skaičiavimai vyksta šviesos greičiu, taip pat kai kurios tinklų architektūros skaičiavimus gali atlikti lygiagrečiai. Būtent vienas iš tokių optinių neuroninių tinklų yra difrakcinis neuroninis tinklas (D^2NN). Tai yra gilus neuroninis tinklas, kuris fiziškai yra pagaminamas naudojant kelias ar keliolika numatytam elektromagnetinės bangos ilgiui pralaidžių difrakcinių plokštelių išrikiuotų viena už kitos. Šios difrakcinės plokštelės atitinka neuroninius sluoksnius skaitmeniniame pilnai sujungtų sąryšių neuroniniame tinkle (9 pav.).




9 pav. Difrakcinis neuroninis tinklas pavaizduotas iš viršaus.
Paimta iš [9]

Difrakcinio neuroninio tinklo veikimas yra paremtas elektromagnetinių bangų sąveika su medžiaga bei interferencijos/difrakcijos reiškiniu. Dėl tos priežasties jo veikimui reikalingas tik pradinis optinis laukas, kurio sklidimas per optinį neuroninį tinklą ir turi būti išnagrinėtas. Atskiros difrakcinės plokštelės yra modeliuojamos atliekant simuliacijas kompiuteryje, pritaikant elektroninių neuroninių tinklų bendruosius principus – plokštelių storis tam tikrame taške, kuris atitinka neuroną, apskaičiuojamas naudojant atgalinio sklidimo bei stochastinio gradientinio nusileidimo metodus (9

pav.)^[9]. Simuliacijoje gautos atitinkamo reljefo D²NN plokštelės vėliau yra fiziškai pagaminamos naudojant 3D spausdinimą arba litografijos metodus^[10]. Kiekvienas D²NN veikia tik iš anksto pasirinktam elektromagnetinės bangos ilgiui, kuris yra palyginamas su vieno fizinio neurono dydžiu. Pavyzdžiui, terahercinės spinduliuotės (3 mm < λ < 0.03 mm) ilgabangėje srityje veikiančio D²NN elementų gamybai užtenka naudoti įprastinį 3D spausdinimą, kur standartinė skyra yra submilimetrų eilės. Tuo tarpu artimos infraraudonosios srities ar matomos spinduliuotės difrakciniams neuroniniams tinklams jau reikia naudoti didelės skyros sauso ėsdinimo ar elektronų pluoštelio litografijos metodus^[28].

Bangos intensyvumas bei fazė iškart už pirmosios D²NN plokštelės priklauso nuo tos plokštelės storio elektromagnetinės bangos kritimo vietoje. Krintančios bangos intensyvumas bei fazė ant tolimesnių D²NN plokštelių jau priklauso nuo praeitos plokštelės išvesties bei bangų interferencijos, kadangi kiekvienas praeitos plokštelės taškas pagal Hiugenso ir Frenelio principą yra antrinių bangų pasiekiančių sekantį neuroninio tinklo sluoksnį šaltinis (10 a pav.). Taip optiniu būdu yra suformuojamos jungtys tarp gretimuose sluoksniuose esančių neuronų, o pats optinis neuroninis tinklas primena pilnai sujungtų sąryšių skaitmeninį neuroninį tinklą^[9] (9 pav.).



10 pav. Elektroninio ir D²NN palyginimas. **Y** - optinis laukas tam tikrame sluoksnyje; **W** - parametų matrica; **B** – laisvųjų narių matrica; **X** – optinio lauko amplitudė; „o“ žymi Hadamardo daugybą. Paimta iš [9]

Nors iš pirmo žvilgsnio D²NN yra gana panašus į pilnai sujungtų sąryšių neuroninį tinklą, tačiau tarp jų yra ir esminių skirtumų. D²NN atveju įvesties duomenys yra kompleksiniai (optinis laukas aprašomas kompleksine bazine lygtimi, kur parametrai yra bangos amplitudė ir fazė), o laisvasis parametras B, kuris priklauso nuo plokštelės storio yra sudauginamas su optiniu lauku, kai skaitmeninio neuroninio tinklo atveju jis yra pridamas (10 pav.). Kitas esminis skirtumas yra tas, kad norint įgyvendinti netiesines aktyvacijos funkcijas D²NN reikia naudoti netiesinėmis optinėmis savybėmis pasižyminčias medžiagas (pvz. puslaidininkinius kvantinius darinius), o tai padaryti yra netriviali užduotis. Tad iki šiol pademonstruoti difrakciniai neuroniniai tinklai naudojo tik tiesines aktyvacijos funkcijas^[9, 10], tačiau nepaisant to naudojant D²NN pademonstruotas 96 % viršijantis objektų klasifikavimo tikslumas.

2.5. Kampinio spektro metodas

Norint apmokinti difrakcinį neuroninį tinklą, reikia sugebėti tiksliai kompiuteryje modeliuoti elektromagnetinės bangos sąveiką su difrakcine plokšte bei elektromagnetinės bangos sklidimą erdvėje įvertinant interferencijos/difrakcijos reiškinius. Būtent tam puikiai tinka plačiai paplitęs, kampinio spektro metodas (Angular Spectrum Method)^[43, 44]. Modeliuojant pastovios koherentinės elektromagnetinės bangos sklidimą yra atliekami keli etapai^[44] :

1. Iš pat pradžių reikia išmatuoti pasirinktą skaičių kompleksinio bangos lauko taškų vertes pradiniam z ašies taške (11 pav. Difrakcinė plokštelė). Tai yra aprašoma formule :

$$u(x', y', 0; t) = U(x', y', 0)e^{-\omega t i} \quad \text{Formulė 1}$$

Kur $U(x', y', 0)$ yra elektromagnetinės bangos laukas, kai $z = 0$, o $e^{-\omega t i}$ laikinė elektromagnetinės bangos sklidimo dalis. Kuo turima daugiau taškų tuo bus gaunami tikslesni rezultatai, tačiau reikalaus didesnių skaičiavimo pajėgumų.

2. Kai elektromagnetinės bangos laukas $U(x', y', 0)$ yra žinomas, tuomet reikia suskaičiuoti elektromagnetinio lauko krentančio ant difrakcinės plokštelės ($z = 0$) 2D Furjė transformaciją (Formulė 2).

$$A(k_x, k_y, 0) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} U(x', y', 0) e^{-(k_x x' + k_y y') i} dx' dy' \quad \text{Formulė 2}$$

Kur $A(k_x, k_y, 0)$ yra $U(x', y', 0)$ elektromagnetinio lauko kampinis spektras (angular spectrum)

3. Jeigu norima modeliuoti bangos sklidimą už pradinės plokštumos, kuri yra plyšys arba atspindintis/pralaidus objektas, tuomet reikia atsižvelgti ir į pradinės plokštumos laidumo funkciją ($t_A(x', y')$). Tai galima padaryti tiesiog sudauginus elektromagnetinio lauko vertes pradinėje plokštumoje su minėta pralaidumo funkcija :

$$U(x', y', 0) = U_0(x', y', 0)t_A(x', y') \quad \text{Formulė 3}$$

Jeigu pradinė sklidimo plokštuma nėra objektas, tokiu atveju $t_A(x', y') = 1$ ir bangos lauko funkcija lieka nepakitusi. Gautas naujas elektromagnetinio lauko pasiskirstymas $U(x', y', 0)$ ir yra naudojamas kitame žingsnyje.

4. Norint įvertinti kaip elektromagnetinis laukas kinta paraleliai pradinei plokštumai (11 pav. vaizdas ant ekrano, $U(x, y, z)$), reikia pasinaudoti Helmholtz'o lygtimi, kuri yra gaunama atskyrus banginės lygties laikinę dalį:

$$\nabla^2 U + k^2 U = 0, \text{ kur } k = \frac{2\pi}{\lambda} \quad \text{Formulė 4}$$

Pasinaudojus atvirkštine Furjė transformacija yra gaunama elektromagnetinio lauko funkcija :

$$U(x, y, z) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} A(k_x, k_y, z) e^{-(k_x x + k_y y) i} dk_x dk_y \quad \text{Formulė 5}$$

Kur $A(k_x, k_y, z)$ yra dažninis spektras atstume z nuo pradinės plokštumos (11 pav. Ekranas).


Įstačius formulę 5 į Helmholtz'o lygtį ir ją išsprendus yra gaunamas sąryšis tarp pradinio dažninio spektro ir atstumo nuo pradinės plokštumos :

$$A(k_x, k_y, z) = A(k_x, k_y, 0) e^{-k_z z i} \quad \text{Formulė 6}$$

Galiausiai yra skaičiuojama atvirkštinė Furjė transformacija į formulę 5 įstačius gauta dažninio spektro sąryšį (formulė 6) :

$$U(x, y, z) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} A(k_x, k_y, 0) e^{-k_z z i} e^{-(k_x x + k_y y) i} dk_x dk_y \quad \text{Formulė 7}$$

O tai ir yra ieškomas elektromagnetinio lauko pasiskirstymas leidžiantis modeliuoti sklaidimą paraleliai pradinei plokštumai.



11 pav. Koherentinės šviesos sklaidimas jai sąveikaujant su mažu plyšiu
Paimta iš [43]


2.6. Terahercinė spinduliuotė

Terahercinė spinduliuotė – elektromagnetinių bangų ruožas tarp mikrobangų ir infraraudonosios spinduliuotės, maždaug tarp 100 GHz ir 10 THz (bangos ilgiai tarp 3mm ir 0.03 mm). Pagrindiniai sunkumai nagrinėjant THz spinduliuotę yra susiję su tuo, jog klasikinė fizika, kuri gerai tinka mažesniems dažniams šiame ruože nustoja galioti, o kvantmechaninė fizika dėl dar per mažų dažnių netinka, tai reiškia, jog nėra vienareikšmių fizikos principų, kuriais remiantis būtų galima sukurti gerus šaltinius ir detektorius šiame elektromagnetinių bangų ruože. Dėl to terahercinė spinduliuotė dar yra žinoma kaip terahercų tarpas (terahertz gap). Nepaisant to, susidomėjimas THz spinduliuote yra didelis dėl jos galimų taikymų tokiose svarbiose srityse kaip neinvazinė medicininė diagnostika, pakuotėse ar drabužiuose paslėptų potencialiai pavojingų objektų paieška, medžiagų atpažinimas bei vaizdinimas, maisto kokybės kontrolė, plačiaujustė bevielė komunikacija ir daugybė kitų^[29, 30].

Vaizdinimui ir medžiagų atpažinimui terahercinė spinduliuotė tinka, nes nemaža dalis dielektrinių medžiagų molekulių vibraciniai šuoliai atitinka terahercinės spinduliuotės kvantų energiją (~ 0.4 – 40 meV), todėl galima fiksuoti būtent tai medžiagai būdingą spektrą. Taip pat terahercinės elektromagnetinės bangos gali prasiskverbti pro plonus dielektrinių medžiagų sluoksnius (popieriaus lapą, kartoną, plastiką, rūbus), o tai atveria pritaikymo galimybes saugumo srityje, pavyzdžiui, oro uoste tirti, ar žmogus neturi pasislėpęs kokių pavojingų daiktų, ar paštuose tirti vokų/siuntinių turinį jų neatidarius^[30]. Vaizdinimo sistemos prototipas, kuris galėtų būti pritaikytas oro uosto saugumo patikros punktuose yra pavaizduotas 12 paveiksle. Šis prietaisas pasitelkia 0.35 THz dažnio nejonizuojančią spinduliuotę ir sugeba vaizdinti net 25 kadru per sekundę greičiu. Žmonių nuotraukoje galima pastebėti ginklą primenantį įtartina objektą paslėptą po rūbais. O tai leidžia nustatyti ir sulaikyti pavojingus asmenis. Taip pat THz vaizdinimą galima pritaikyti ir medicinoje, kadangi tai yra nejonizuojanti ir žmogaus sveikatai nepavojinga spinduliuotė. Vanduo gan stipriai sugeria THz spinduliuotę, tad galimai nesunkiai tirti vandens koncentracijos skirtumus audiniuose, tokiu būdu nustatant pažeistas audinių bei piktybinių navikų vietas^[30].

Pagrindiniai sunkumai bandant naudoti terahercinę spinduliuotę komunikacijoje yra stipri sugertis dėl ore esančių vandens garų. Todėl sklisdama laisvoje erdvėje ji greitai slopsta ir negali nukeliauti didelių atstumų^[30]. Vis dėlto išnaudojant dažnių ruožus, kuriuose THz sugertis atmosferoje yra gerokai mažesnė, dauguma tokių dažnių yra tarp 0.1 – 0.4 THz, galima sukurti bevielio ryšio sistemas, kurias būtų galima naudoti trumpais atstumais (dešimtys metrų) arba pastato viduje. Pagrindinis THz komunikacijos sistemų pranašumas yra tas, jog galima pasiekti net kelias dešimtis kartu didesnius

duomenų perdavimo greičius nei naudojant įprastines radijo bangas. O tai darosi vis svarbiau, augant suvartojamų duomenų kiekiui kiekvienais metais^[30].



12 pav. Vaizdinimo sistema operuojanti naudojant 0.35 THz spinduliuotę. Galinti vaizdinti 25 kadrus per sekundę. Prototipas prietaiso, kuris galėtų veikti oro uosto patikros punktuose
Paimta iš [30]

Nors terahercų dažnių elektromagnetinės bangos turi daugybę potencialių panaudojimų, dauguma jų yra apriboti dabartinių THz spinduliuotės šaltinių bei detektorių galimybių. Per paskutinius kelis dešimtmečius terahercų ruože atsirado nemažai šaltinių, kurie puikiai tinka vykdyti moksliniams tyrimams laboratorinėmis sąlygomis, tačiau dažniausiai jie būna dideli ir reikalauja šaldymo^[30], o tai stipriai apriboja jų komercinį naudojimą. Vienas iš tokių šaltinių pavyzdžių yra kvantinis kaskadinis lazeris, kuris pasižymi didele galia (daugiau nei 1 W) 1-5 THz dažnių ruože, tačiau gali veikti tik apie 200 K temperatūroje, kas apsunkina jo naudojimą už tyrimų laboratorijos ribų. O kiti prietaisai, tokie kaip Gunn diodai (dešimtys μW) arba elektroniniai dažnių daugintuvai (mW eilės), galintys operuoti kambario temperatūroje, jau pasižymi gerokai mažesnėmis galiomis^[30].

Kita svarbi problema yra ta, jog taip pat trūksta aukštos raiškos greitai reaguojančių bei nebrangių detektorių THz dažnių ruože. Tokie jutikliai leistų išvengti lėto rastrinio skanavimo THz vaizdinimo sistemose, taip gerokai jas paspartindami ir supaprastindami^[30]. Būtent technologiniai iššūkiai kuriant THz dažnių jutiklių masyvus verčia ieškoti alternatyvių sprendimų kaip būtų galima paspartinti THz vaizdinimą naudojantis jau esama technologija (pvz. išnaudojant kompiuterių skaičiuojamąją galią). Vienas iš galimų variantų yra „ pridėti“ THz vaizdinimo sistemoms proto panaudojant dirbtinio intelekto, konkrečiai optinių neuroninių tinklų teikiamas galimybes. Būtent toks prietaisas ir yra tiriamas šiame darbe.

2.7. 3D spausdinimo technologija

3D spausdinimo technologija buvo sukurta kaip metodas greitai gauti fizinius prototipų variantus. Tai buvo pasiekta dedant skirtingos formos pasirinktos medžiagos sluoksnius vieną ant kito, kol gaunamas norimas objektas. Pastaruoju metu 3D spausdinimo tikslumas bei galimų naudoti medžiagų pasirinkimas gerokai išaugo, kas suteikė galimybę gaminti net ir labai kompleksiškos formos, mažus objektus. Toks šios technologijos galimybių tobulėjimas leidžia jį pritaikyti įvairiose srityse: medicinoje (širdies palaikymo prietaisai, dirbtinės akies ragenos it t.t.), statybų srityje, robotikoje, aviacijoje ir daugybėje kitų^[48].


Tam kad būtų patenkinti tikslumo ir gamybos iš skirtingų medžiagų poreikiai įvairiose srityse, buvo sukurta daugybė 3D spausdinimo technologijų. Jos visos gali būti suskirstytos į tris kategorijas: kepinimu (sintering), lydymu ir stereolitografija paremtos technologijos^[49]. Pastaruoju metu vienas iš populiariausių 3D spausdintuvų yra paremtas lydinio nusodinimo modeliavimo metodu (Fused deposition modelling; FDM). FDM metodo metu termoplastinė medžiaga yra kaitinama iki lydymosi temperatūros (180 °C - 280 °C). Tuomet stumiant medžiagą pro išėjimo galvutę yra gaunamas medžiagos siūlas iš kurio po vieną sluoksnį yra formuojamas objektas. FDM spausdintuvai turi padėklą ant kurio ir yra auginamas objektas. Priklausomai nuo komplektacijos gali judėti tiek pačio spausdintuvo išėjimo galvutė, tiek pats padėklas auginimo metu^[49]. Maksimali pasiekama rezoliucija tiek vertikalioje, tiek horizontalioje ašyje įprastai siekia apie 0.2 milimetro.

Kitas populiarus metodas yra fotopolimerizacijos metodas (Photopolymerization), kuris priklauso stereolitografijos kategorijai. Ši technologija paremta tuo, jog kai kurie suskystinti polimerai apšviesti šviesa arba ultravioletine spinduliuote sukietėja. Fotopolimerizacijos metodas įprastai yra naudojamas gaminant objektus, kurie reikalauja aukštos kokybės bei didelio tikslumo. Šio metodo įprasta rezoliucija vertikalioje ašyje siekia 25 – 100 μm , o horizontalioje ašyje apie 50 μm.

3D spausdinimo technologijos pasižymi tuo, jog galima per kelias valandas sukurti kompleksiškos formos, lengvus objektus. Gamybos metu beveik nėra išvaistoma medžiagų, kas dažnu atveju atsitinka gaminant kitais metodais, ypač pjaustant objektus iš neperdirbamų medžiagų. Taip pat jie yra nesunkiai prieinami ir kompaktiški, tad gali būti įdiegti daugumoje patalpų. Tačiau reiktų pabrėžti, jog 3D spausdintuvai vis dėlto turi ribotą medžiagų pasirinkimą kuriomis gali operuoti. Labiausiai tai apriboja aukšta temperatūra, kuri yra reikalinga, tam kad medžiaga būtų galima manipuliuoti. Taip pat norint atspausdinti didesnius objektus (dešimčių centimetrų eilės) procesas gali gerokai prailgti ir trukti net kelias dienas. Tad dažniausiai yra apsiribojama gaminant mažesnius objektus.

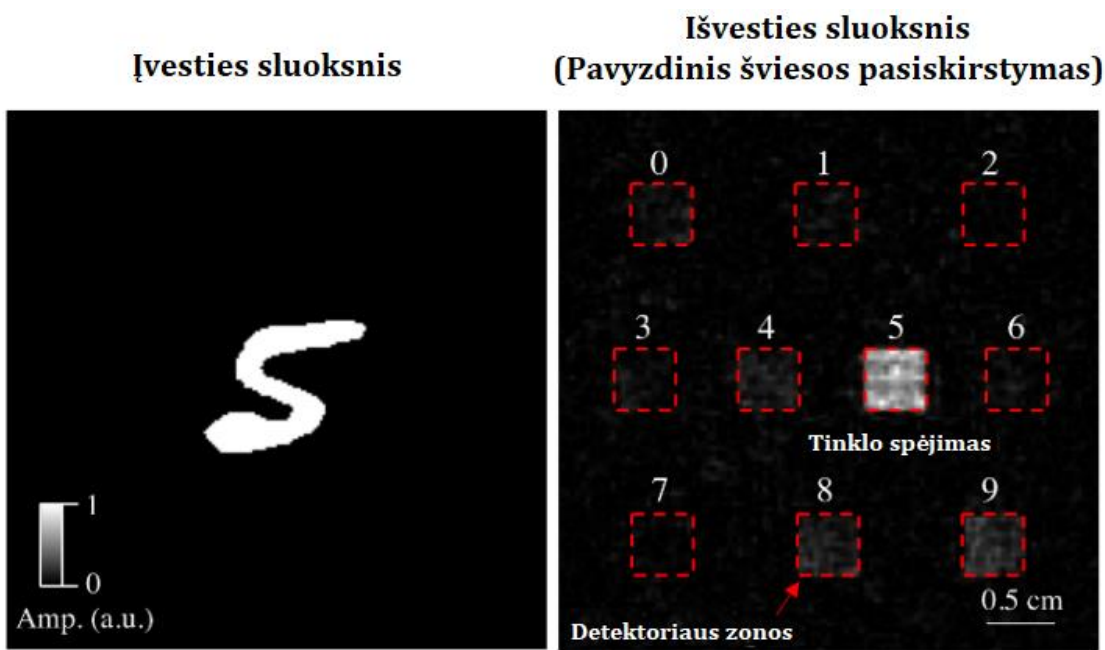
3. Tyrimo metodika

Difrakciniai neuroniniai tinklai buvo sukurti ir apmokyti naudojant TensorFlow 2.7 aplinką ir Python 3.7 programavimo kalbą. Buvo tiriamos optinio difrakcinio neuroninio tinklo galimybės atskirti koks objektas yra nuotraukoje: vienu atveju buvo klasifikuojami skaičiai nuo 0 iki 9, o kitu peilis, pistoletas ir išmanusis telefonas. Abiem atvejais paskutinis neuroninio tinklo sluoksnis arba detektorių plokštuma buvo suskirstytas į klasių kiekį atitinkantį zonų skaičių. Neuroninis tinklas buvo apmokytas taip, kad tam tikrą objektą apšvietusi ir per tinklą praėjusi monochromatinė šviesa būtų fokusuojama į būtent to objekto klasei priskirtą detektorių plokštumos zoną (13 pav. ir 14 pav.).



13 pav. Difrakcinio neuroninio tinklo vizualizacija. Įvesties sluoksnyje yra apšviečiamas objektas (skaičius 5). Toliau sklindanti spinduliuotė krenta ant difrakcinio sluoksnio, kurio kiekvienas taškas atitinka neuroną, turintį kompleksinį pralaidumo koeficientą. Šis koeficientas ir yra optimizuojamas apmokymo metu, jog spinduliuotė būtų nukreipta į teisingą detektoriaus zoną (mėlynai nuspalvina detektoriaus sritis).

Paimta iš [9]



14 pav. Ant difrakcinio neuroninio tinklo įvesties ir išvesties sluoksnių krentančios spinduliuotės amplitudės pasiskirstymo pavyzdys. Įvesties sluoksnyje turimas objektą atvaizduojantis pasiskirstymas. Išvesties sluoksnyje yra stebima į teisingą detektoriaus zoną sukonzentruota spinduliuotė.

Paimta iš [9]

Nustatinėjant optimalų paslėptųjų sluoksnių skaičių bei optimalų atstumą tarp jų buvo nuspręsta naudoti 300 GHz ($\lambda = 1$ mm) dažnio spinduliuotę. Norint, jog vyktų difrakcijos reiškiniai, sąveikaujantys objektai turi būti panašaus dydžio, tad atitinkamai buvo pasirinktas ir 1 milimetro neurono kraštinės ilgis. Tokie parametrai buvo pasirinkti iš anksto atsižvelgus į laboratorijoje prieinamo terahercinės spinduliuotės šaltinio bangos ilgį, bei įvertinus trimačio spausdintuvo skyros parametrus. Čia reikia pabrėžti kad jau sukūrus difrakcinio neuroninio tinklo modelį jį galima palyginus nesunkiai apmokyti ir kitiems neuronų dydžiams (bangos ilgiams).

Modeliuojant D^2NN tinklą ranka rašytiems skaičiams atpažinti apmokymo duomenys buvo sudaryti iš 510 nuotraukų, validavimo duomenys sudaryti iš 90, o testavimo iš 300 nuotraukų. Skaičių nuotraukos buvo paimtos iš MNIST (Modified National Institute of Standards and Technology) duombazės^[46]. Klasifikuojant pavojingus objektus (peilį, pistoletą, išmanųjį telefoną) apmokymo duomenys buvo sudaryti iš 472, validavimo iš 83, o testavimo iš 90 nuotraukų. Abiem atvejais nuotraukų skaičius priklausantis atitinkamai klasei buvo beveik toks pat. Ieškant optimalių neuroninio tinklo parametrų (sluoksnių skaičius bei atstumas tarp sluoksnių) buvo naudojamos 34 x 34 rezoliucijos nespaltvotos nuotraukos. Taip apdoroti nuotraukas buvo nuspręsta norint išsaugoti kuo daugiau objekto detalių nuotraukoje, tačiau taip pat bandant kuo labiau sutrumpinti apmokymo proceso trukmę.

Sumažinus nuotraukų rezoliuciją iki 34 x 34 pikselių apmokymo procesas vienam parametru rinkiniui truko netoli 20 minučių. Didinant naudojamų pikselių skaičių nuotraukose tiesiogiai didėja ir apmokymo proceso trukmė. Apmokymo proceso trukmė išauga net beveik iki 2,5 valandų nuotraukoms su 100 x 100 rezoliucija. Neuroninio tinklo apmokymui buvo naudojami atgalinio sklaidimo ir stochastinio gradientinio nusileidimo algoritmai (Adam). Neuroninio tinklo mokymosi iteracijų (epochs) skaičius buvo nustatytas ties 20 iteracijų. Modeliavimas buvo atliktas naudojantis nemokamomis Google Colab paslaugomis. Visi skaičiavimai buvo atlikti nenaudojant GPU, o pasitelkiant tik CPU galimybes (Intel(R) Xeon(R) CPU @ 2.20GHz, 13 GB RAM, Linux operacinė sistema).

Reikia pabrėžti, jog realiai atspausdintų ir naudotų neuroninio tinklų plokštelių matmenys buvo parinkti atsižvelgus į laboratorijoje naudojamos kvazioptinės sistemos geometrinius apribojimus. Optinio neuroninio tinklo elementai gali būti apšviesti 2 cm diametro kolimuotos THz spinduliuotės spinduliu, o pasirinktas bangos ilgis, taigi ir vieno neurono kraštinės ilgis yra 1 mm atsižvelgus į turimą terahercinių bangų šaltinio generuojamą dažnį. Į 2 cm skersmens optinį pluoštą telpa 1,4 cm x 1,4 cm kvadratinė plokštelė, o jau minėtas neurono kraštinės ilgis yra apie 1 mm, todėl viename modeliuojamo neuroninio tinklo sluoksnyje telpa $14^2 = 196$ neuronai.

Apmokius difrakcinį neuroninį tinklą ir žinant galutinį paslėptųjų sluoksnių poveikį krentančios bangos fazei, reikia suskaičiuoti kokio storio (H) turima medžiaga atitiktų sumodeliuotą fazės pokytį ($\Delta\Phi$). Tai yra pasiekama atsižvelgus į krentančios spinduliuotės bangos ilgį (λ) bei naudojamos medžiagos lūžio rodiklį (n):


$$H = \frac{\lambda \cdot \Delta\Phi}{2 \cdot \pi \cdot (n - n_{oro})} \quad 8 \text{ formulė}$$

Reiktų paminėti, jog neuroninio modeliavimo metu taip pat buvo atsižvelgta ir į intensyvumo pokyčius dėl spinduliuotės sąveikos su plokštelėmis. Turint plokštelės storį (H) atitinkamame taške bei medžiagos slopinimo koeficientą (μ) galima paskaičiuoti ir praėjusios bangos nuslopimą pasinaudojant Beer-Lambert'o dėsnium:

$$I = I_0 e^{-\mu H} \quad 9 \text{ formulė}$$

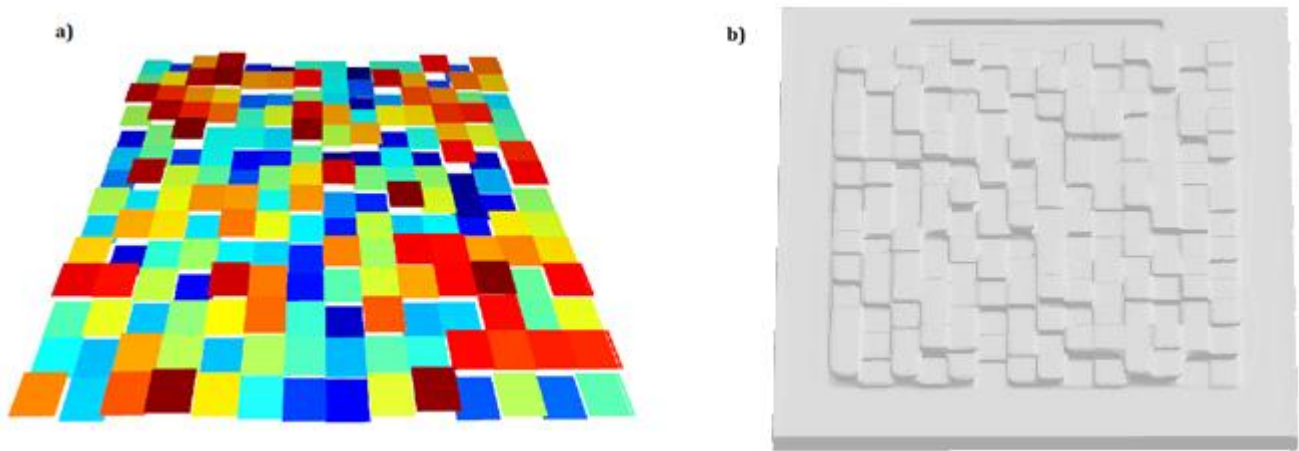
Tad prieš pradėdant modeliavimą reikia nustatyti 3D spausdinimo metu naudojamos medžiagos (Anycubic Grey UV Resin) lūžio rodiklį (n) ir slopinimo koeficientą (μ). Slopinimo koeficientas buvo paskaičiuotas išmatavus pralaidumo bei sugerties spektrus (15 pav.). Tokiu būdu nustatytas slopinimo koeficientas 300 GHz spinduliuotei yra $\mu = 507.47 \text{ m}^{-1}$. O iš lūžio rodiklio spektro nustatytas $n = 1.5056$

esant 300 GHz dažniui. Matavimai buvo atlikti naudojant THz spektroskopiją su laikine skyra (THz-TDS)



15 pav. Naudotos polimerinės medžiagos išmatuoti sugerties, slopinimo ir lūžio rodiklio spektrai išmatuoti naudojant THz-TDS

Tad difrakcinis neuroninis tinklas buvo apmokytas pasitelkus būtent šiuos nustatytus parametrus. Sumodeliuotos plokštelės taškų debesies (point cloud) pavyzdys yra pateiktas 16 paveiksle a dalyje. Apdorojus paslėptojo sluoksnio taškų debesį Poisson paviršiaus rekonstrukcijos^[50] metodu buvo sugeneruota plokštelė (16 pav. (b) dalis), kurią jau galima pateikti naudotam fotopolimerizacijos 3D spausdintuvui.




16 pav. Apmokytos difrakcinio neuroninio tinklo vieno paslėptojo sluoksnio taškų debesis (a) ir Poisson paviršiaus rekonstrukcijos metodu apdorota bei paruošta spausdinimui plokštelė (b)

Buvo atspausdinti 5 difrakcinio neuroninio paslėptieji sluoksniai. Vieno atspausdinto sluoksnio pavyzdys yra pateikiamas 17 paveiksluke. Plokštelė buvo papildomai apvyniota nepralaidžia terahercinei spinduliuotei medžiaga, tam kad eksperimento metu būtų sumažinta pro neuroninio tinklo plokštelės kraštus sklindančios THz spinduliuotės įtaka.




17 pav. 3D spausdintuvu paruoštas difrakcinio neuroninio tinklo paslėptasis sluoksnis

Atspausdinto difrakcinio neuroninio tinklo tyrimas buvo atliekamas pasitelkiant schemą pavaizduotą 18 paveiksliuke.




18 pav. Difrakcinio neuroninio tinklo tyrimo schema

Buvo naudojamas ~ 10 mW galios, 1 kHz moduliacijos dažnio ir 300 GHz dažnio terahercinės spinduliuotės šaltinis veikiantis harmoninės dažnio generacijos metodu (VDI MC 156). Sugeneruota spinduliuotė praėjusi pro intensyvumo reguliavimui skirtą filtrą, pasiekia taikinių (pistoletą, peilį, telefoną imituojančią plokštelę 19 pav.). Taikiniai buvo pagaminti pasitelkiant FDM tipo 3D spausdintuvą, bei apklijuoti aliuminio folija tam kad kolimuota THz spinduliuotė praeitų tik pro objekto formos plyšį.



19 pav. Plokštelės (taikiniai) imituojančios (a) peilius, (b) pistoletus ir (c) telefonus

Tad difrakcinį neuroninį tinklą jau pasiekia spinduliuotė, praėjusi pro tiriamo objekto kaukę. Visos difrakcinio neuroninio tinklo plokštelės yra išdėstytos 2 centimetru atstumu viena nuo kitos (20 pav.). Galiausiai, difrakcinis neuroninis tinklas priklausomai nuo kritusios spinduliuotės šešėlio formos, ją sufokusuoja į atitinkamą zoną (14 pav.) esančią 2 centimetrų atstumu nuo paskutinio paslėptojo sluoksnio. Sufokusuota spinduliuotė yra detektuojama pasitelkiant titano mikrobolometrinių detektorių (32 pikselių). Norint išmatuoti difrakcinio neuroninio tinklo apdorotą terahercinę spinduliuotę buvo pasitelktas rastrinis skanavimas. Tai leidžia užfiksuoti terahercinę spinduliuotę pakankama raiška naudojant mažo skaičiaus aktyvių pikselių detektorius (20 pav.). Tačiau, kadangi reikia keisti detektoriaus poziciją erdvėje daugybę kartų, tai gerokai sulėtina eksperimentą. Idealiu atveju, difrakcinis neuroninis tinklas galėtų leisti išvengti šio lėto rastrinio skanavimo, kadangi spinduliuotė būtų fokusuojama į mažą erdvės sritį atitinkamai nuo kritusios spinduliuotės šešėlio. Ir į kiekvieną objekto klasę atitinkantį fokuso tašką pastačius po nedidelį mažos raiškos detektorių būtų galima nesunkiai nustatyti, koks objektas buvo apšviestas.



20 pav. Iš arti pavaizduotas difrakcinis neuroninis tinklas su taikiniu bei detektoriumi

4. Tyrimų rezultatai bei jų aptarimas

4.1. Difrakcinio neuroninio tinklo modeliavimas bei optimalių parametrų nustatymas

Difrakcinis neuroninis tinklas (D^2NN) įprastai yra įgyvendinamas naudojant pilnai sujungtų sąryšių sluoksnius arba dalinai sujungtų sąryšių sluoksnius, priklausomai nuo atstumo tarp realių D^2NN sluoksnių. Norint įgyvendinti pilnai sujungtų sąryšių sluoksnius turi būti pasirinktas pakankamas atstumas tarp sluoksnių, kadangi šviesa po difrakcijos reiškinio turi apšviesti visą sekantį sluoksnį. Šiai sąlygai užtikrinti buvo pasirinktas 2 centimetrų atstumas tarp sluoksnių.


Naudota nuostolių funkcija rėmėsi tuo, jog buvo skaičiuojamas santykis tarp viso normalizuoto kritusios šviesos intensyvumo ir kritusio spinduliuotės intensyvumo ant teisingo pikselio, atsakingo už tam tikrą klasę. Taigi, toks nuostolių funkcijos pasirinkimas reiškia, jog D^2NN apmokymo metu nebuvo stengiamasi maksimizuoti krentančio ant detektoriaus spinduliuotės intensyvumo, o bandyta gauti kuo didesnę tikslumą.

4.1.1. Objektų sutinkamų kasdienėje aplinkoje klasifikavimas

Iki šiol atlikti optinių difrakcinių tinklų galimybių tyrimai įprastai apsiribojo tokiais užduotimis kaip : MNIST ranka rašytų nuotraukų rinkinio klasifikacija^[9], krentančios polichromatinės terahercinės spinduliuotės dažnių atskyrimas erdvėje^[10], kitokių paprastų simbolių klasifikacija^[11]. Tačiau nebuvo bandoma sukurti optinio difrakcinio neuroninio tinklo realių, kasdienėje aplinkoje sutinkamų, objektų klasifikacijai atlikti. Taigi, šiame skyriuje yra tiriami objektai, kurių klasifikavimas būtų naudingas bandant atskirti pavojingus (peilis, pistoletas) nuo nepavojingų (išmanusis telefonas) daiktų. Tokią užduotį aukštu tikslumu atliekantis optinis difrakcinis neuroninis tinklas būtų pageidaujamas užtikrinant saugumą oro uostuose, valstybinėse institucijose, sporto renginiuose ar kitose masinio susibūrimo vietose.

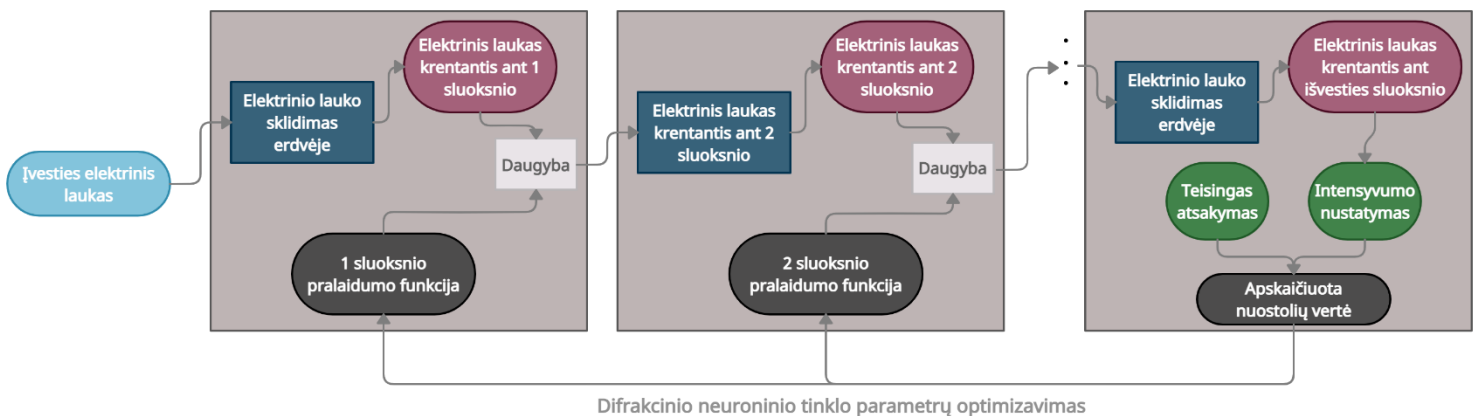
Difrakcinis neuroninis tinklas buvo modeliuojamas remiantis 21 paveikslu. Iš pradžių buvo modeliuojamas įvesties plokštelės su objekto formos plyšiu (įvesties nuotrauka 23 pav. b dalis) apšvietimas terahercine spinduliuote (21 pav. įvesties sluoksnis). Tuomet naudojant kampinio spektro metodą apskaičiuotas krentantis vaizdas ant pirmos difrakcinės plokštelės susidaręs dėl difrakcijos reiškinio. Difrakcinę plokštelę pasiekusi spinduliuotė yra paveikiama kiekviename taške (neurone) priklausomai nuo plokštelės pralaidumo koeficiento tame taške, kurį galima keisti manipuliuojant plokštelės storiu. Pralaidumo funkcija kiekviename plokštelės taške būtent ir yra tas parametras, kurį

neuroninis tinklas optimizuoja mokymosi metu. Žinant medžiagos, iš kurios pagaminta plokštelė, lūžio rodiklį ir sugerties koeficientą galima tiksliai paskaičiuoti koks turi būti plokštelės storis kiekviename taške norint įgyvendinti sumodeliuotą pralaidumo funkciją. Vėl pritaikius kampinio spektro metodą elektriniam laukui gautam iš karto už pirmosios plokštelės buvo suskaidytas ant antros difrakcinės plokštelės krentantis spinduliuotės vaizdas. Ji priklausomai nuo jos reljefo (pralaidumo funkcijos) vėl modifikuoja kritusios spinduliuotės pasiskirstymą. Toks procesas tęsiasi tol, kol yra pasiekiamas išvesties sluoksnis, kuriame yra nustatomas spinduliuotės intensyvumo pasiskirstymas ant detektoriaus zonų atsakingų už tam tikrą klasę (21 pav. išvesties sluoksnis). Nustačius detektorių plokštumos zoną, turinčią didžiausią dalį kritusios spinduliuotės yra nustatomas tinklo spėjimas.



21 pav. Difrakcinio neuroninio tinklo schema
Paimta iš [9]

Difrakciniame neuroniniame tinkle vykstantys procesai yra apibendrinti 22 paveiksle. Reiktų pabrėžti, jog juodame fone yra pavaizduotos pralaidumo funkcijos, kurios būtent ir yra optimizuojamos apmokymo metu (22 pav.).



22 pav. Difrakciniame neuroniniame tinkle vykstančių procesų schema. Juodame fone pavaizduoti procesai vyksta tik neuroninio tinklo mokymosi metu

Viena iš pistoleto nuotraukų, paimta iš testavimo duomenų rinkinio, yra pavaizduota 23 paveiksle (a dalis). Nuotraukos buvo apdorojamos taip, kad norint eksperimentiškai patikrinti rezultatus, būtų įmanoma jos kopiją fiziškai atvaizduoti ant plokštelės sukuriant plyšį (23 pav. b). Dėl spinduliuotės sąveikos su įvesties plokšte ir dėl spinduliuotės sklaidimo iki difrakcinės plokštelės, nuotraukos vaizdas gerokai išsikreipia ir tikrasis objektas tampa jau gana sunkiai atpažįstamas (23 pav. c). Taigi, difrakcinis neuroninis tinklas pirmą kartą pamato tik jau stipriai iškraipytą objekto atvaizdą (23 pav. c), tačiau vis tiek turi sugebėti iš jo išskirti atitinkamai klasei būdingus bruožus.

a)




a) – Originali nuotrauka

b)



b) – Apdorota nuotrauka pateikiama įvesties sluoksniui

c)



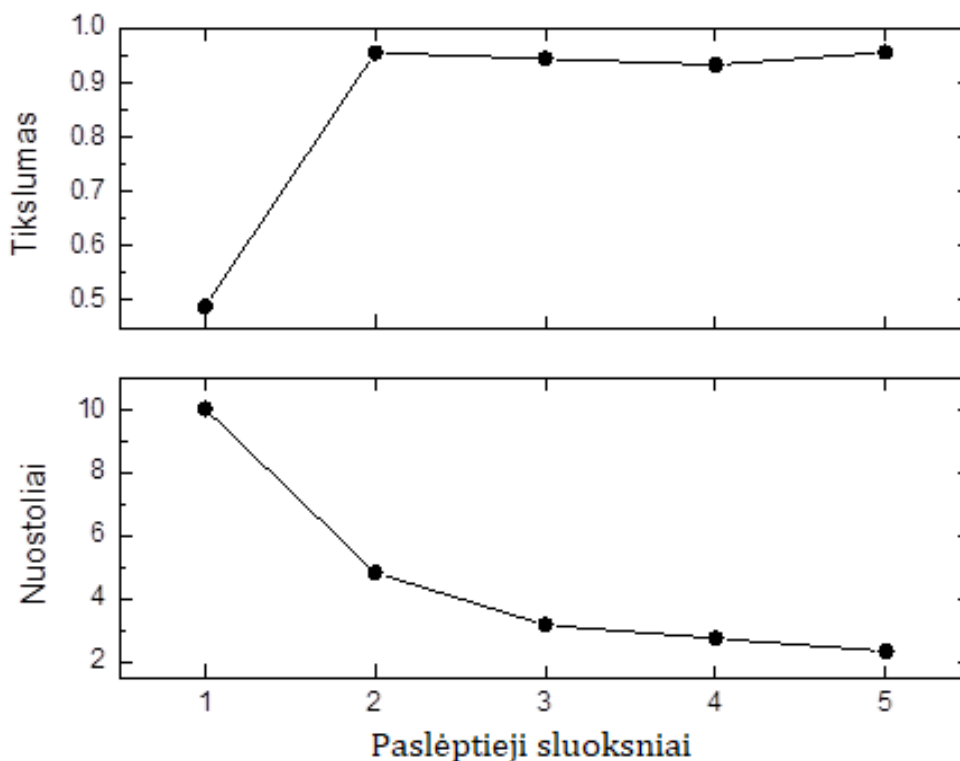
c) – Spinduliuotės intensyvumas krentantis ant pirmos difrakcinės plokštelės

23 pav. Difrakcinio neuroninio tinklo apmokymo procese naudojamos nuotraukos evoliucija. a) Originali, nė kiek neapdorota nuotrauka; b) apdorota nuotrauka, jog būtų ją įmanoma pateikti neuroniniam tinklui; c) spinduliuotės intensyvumo pasiskirstymas ant pirmos difrakcinės plokštelės

4.1.2. Difrakcinio neuroninio tinklo objektų klasifikavimo rezultatų priklausomybė nuo difrakcinių plokštelių skaičiaus

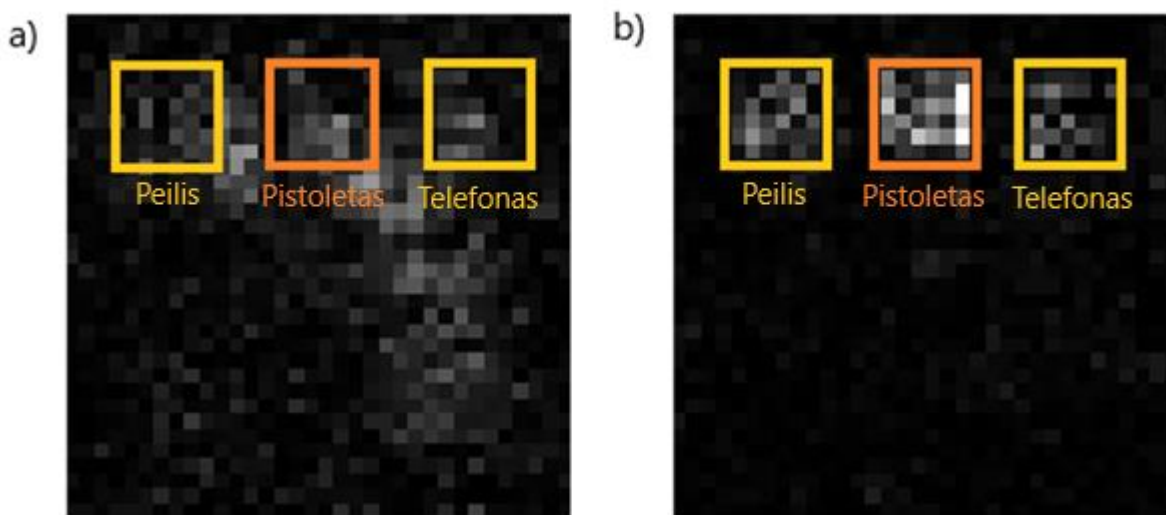
Difrakcinis neuroninis tinklas yra sudarytas iš taikinio (įvesties sluoksnio), difrakcinių plokštelių (paslėptųjų sluoksnių) bei detektoriaus (išvesties sluoksnio). Nenaudojant nei vieno paslėptojo sluoksnio, optinis neuroninis tinklas neturi galimybės pakeisti krintančios spinduliuotės krypties ir išnaudoti difrakcijos reiškinio. Todėl tokiu atveju visi teisingai klasifikuoti atvejai būtų tik dėl atsitiktinumo, o tikslumas būtų lygus $\frac{1}{3}$ (atsitiktinai renkantis iš 3 galimų klasių). Tad, tyrimas buvo pradėtas turint 1 paslėptąjį sluoksnį ir didinant jų skaičių iki 5 difrakcinių plokštelių.

Pažvelgus į 24 paveikslėlį yra matoma, jog esant bent vienam paslėptajam sluoksniui yra pasiekiamas apie 49 % tikslumas (24 pav.). Tai rodo, jog neuroninis tinklas geba išmokti manipuluoti šviesa, tačiau neturi pakankamai galimybių išmokti svarbiausius objektų bruožus ir atitinkamai pakeisti kritusios spinduliuotės pasiskirstymą.



24 pav. Tikslumo ir nuostolių priklausomybė nuo difrakcinių plokštelių (paslėptųjų sluoksnių) skaičiaus

Įdėjus papildomą difrakcinę plokštelę neuroninio tinklo tikslumas staiga išauga net iki 95.56 % (24 pav.), o nuostolių vertė gan stipriai nukrinta nuo 10 iki 4.8. Tai rodo, jog difrakciniam neuroniniam tinklui išmokti klasifikuoti objektus yra reikalingi bent 2 paslėptieji sluoksniai. Pateikus pistoleto nuotrauką (23 pav.) neuroniniam tinklui su 2 difrakcinėmis plokštelėmis yra matoma, jog neuroninis tinklas teisingai spėja objekto klasę (25 pav. b). Lyginant su difrakciniu neuroniniu tinklu turinčiu vieną paslėptąjį sluoksnį (25 pav. a), spinduliuotės intensyvumas yra santykinai labiau fokusuotas į išvesties plokštelės (detektoriaus) pikselį, atsakingą už pistoleto klasės atpažinimą, o tai reiškia, jog tinklas yra labiau įsitikinęs, kad pateiktas daiktas yra pistoletas.



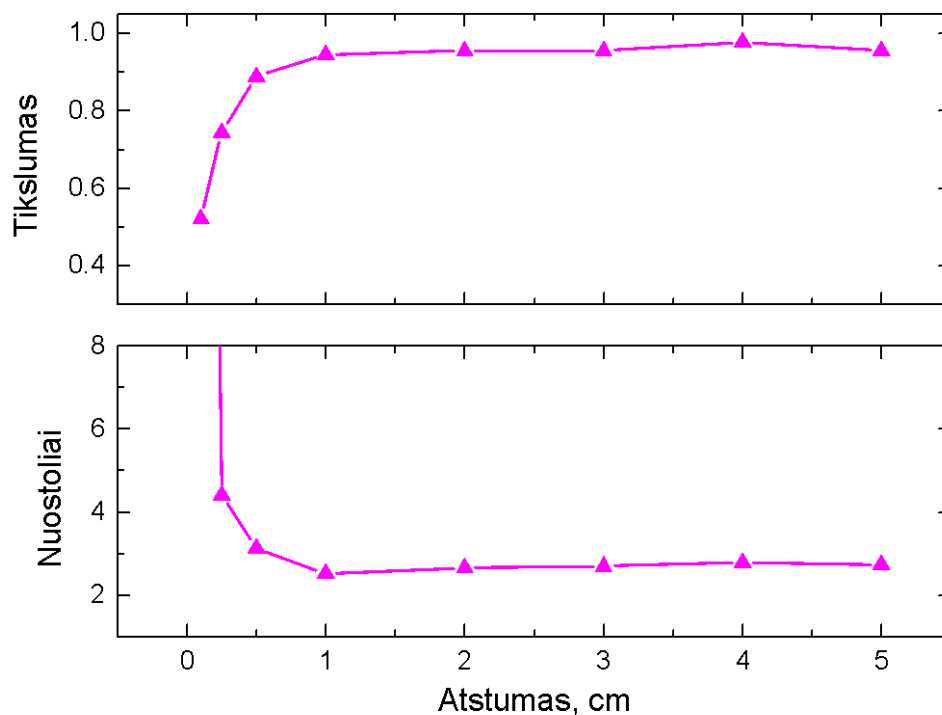
25 pav. Spinduliuotės intensyvumo pasiskirstymas ant detektoriaus. Kiekvienas iš pavaizduotų pikselių yra atsakingas už atskirą klasę (peilį, pistoletą ir išmanųjį telefoną atitinkamai). Oranžinės spalvos kvadratu yra pažymėtas pikselis atsakingas už pistoleto klasę. a) D^2NN su vienu paslėptuoju sluoksniu; b) D^2NN su dviem paslėptaisiais sluoksniais

Toliau didinant sluoksnių skaičių, o taip pat ir neuronų skaičių, modelio tikslumas nebeauga. Tačiau nuostolių vertė pastebimai krenta ir pasiekia mažiausią vertę naudojant 5 difrakcines plokšteles. Tai rodo, kad darant neuroninį tinklą kompleksiškesnį, jis sugeba išmokti daugiau skiriamųjų savybių ir atlieka spėjimus su didesniu pasitikėjimu, nors spėjimų tikslumas ir nebeauga. Taigi, remiantis atliktu modeliavimo eksperimentu, difrakcinis neuroninis tinklas su 5 difrakcinėmis plokštelėmis yra tinkamiausias nagrinėjamai užduočiai atlikti, nes pasižymi vienu iš didžiausių tikslumu (~ 96 %) su pačia mažiausia nuostolių verte (~ 2.3).

4.1.3. Difrakcinio neuroninio tinklo galimybės klasifikuoti objektus keičiant atstumą tarp plokštelių

Taikant difrakcinį neuroninį tinklą patogiausia būtų turėti kuo mažesnę atstumą tarp kiekvienos iš plokštelių, tam kad fizinė tinklo realizacija būtų kuo kompaktiškesnė. Tačiau norint realizuoti pilnai sujungtų sąryšių neuroninį tinklą, minimalus atstumas tarp plokštelių tampa apribotas. Taip atsitinka dėl to, jog šviesa lūžusi tam tikru kampu pradinėje difrakcinėje plokštelėje, sugebės pilnai apšviesti kitą plokštelę tik už tam tikro atstumo.


Tiriant difrakcinio neuroninio tinklo priklausomybę nuo atstumo tarp plokštelių buvo tiriamas difrakcinis neuroninis tinklas turintis 5 difrakcines plokšteles, nes jis pasižymėjo didžiausiu tikslumu bei mažiausia nuostolių verte praeitame eksperimente. Gauti rezultatai yra pateikti 26 paveiksle.



26 pav. Tikslumo ir nuostolių priklausomybė nuo atstumo tarp difrakcinių plokštelių

Esant 0.1 centimetro atstumui tarp plokštelių yra stebimas apie 52 % tikslumas. Toks mažas tikslumas gali būti paaiškinamas tuo, jog iš kiekvieno neurono išeinanti spinduliuotė turi fiksuotą skėsties kampą ir neapima viso gretimos plokštelės ploto. Taigi, sąryšiai tarp gretimų sluoksnių neuronų yra

stipriai apriboti. Tokiu atveju realizuojamas dalinai sujungtų sąryšių, o ne norimas pilnai sujungtų sąryšių neuroninis tinklas. Šį efektą galima stebėti 27 paveiksle, kai neuroniniam tinklui buvo pateikta anksčiau aptarta pistoleto nuotrauka (23 pav.).



27 pav. Spinduliuotės intensyvumo pasiskirstymas ant detektoriaus pateikus pistoleto nuotrauką (16 pav.). a) Atstumas tarp difrakcinių plokštelių lygus 0.1 cm; b) atstumas tarp plokštelių lygus 2 cm. Oranžinės spalvos kvadratu yra pažymėtas pikselis atsakingas už pistoleto klasę.

Atstumą padidinus iki 0.5 centimetro D^2NN tikslumas išauga iki 89 %. Toks tikslumo pagerėjimas yra stebimas dėl to, jog gerokai išauga galimų jungčių skaičius tarp gretimų paslėptųjų sluoksnių (10 pav.), kas pagerina neuroninio tinklo galimybes išskirti charakteringus objektų bruožus. Toliau padidinus atstumą iki 1 centimetro jau yra stebimas net 94% tikslumas. Toks rezultatų pagerėjimas yra pasiekiamas tik tada, kai visi gretimų paslėptųjų sluoksnių neuronai gali sąveikauti vieni su kitais ir neuroninis tinklas tampa pilnai sujungtų sąryšių neuroniniu tinklu. Dar labiau tolinant difrakcines plokšteles vieną nuo kitos nebėra stebimas reikšmingas tikslumo didėjimas ar nuostolių vertės kritimas. O užfiksuotas didžiausia užfiksuota tikslumo vertė 98% esant 4 centimetrų atstumui gali būti paaiškinama vertės neapibrėžtumu atsirandančiu dėl naudotų stochastinio mokymosi algoritmo ypatumų.

Taigi, norint pilnai išnaudoti difrakcinio neuroninio tinklo (naudojančio 1.4 x 1.4 cm difrakcines plokšteles) galimybes reiktų pasirinkti nemažesnę nei 1 centimetro atstumą. O norint turėti gero tikslumo, tačiau kuo kompaktiškesnį neuroninį tinklą, būtų galima difrakcines plokšteles išdėlioti kas pusę centimetro. Taip pat verta paminėti, jog norint padaryti neuroninį tinklą kompaktiškesnį neprarandant tikslumo galima mažinti naudojamos spinduliuotės bangos ilgį, kadangi remiantis Bragg'o difrakcija

($m\lambda = 2d \sin \alpha$; λ – bangos ilgis, d – atstumas tarp gardelės plokštumų, α – difragavusios bangos kampas, m – difragavusio spindulio eilė) apšvietus mažesniu bangos ilgiu difrakcijos kampas padidėja. Tačiau mažinant spinduliuotės bangos ilgį, būtų privaloma mažinti ir pačių neuronų dydį tam, kad būtų išpildoma difrakcijos sąlyga (bangos ilgis turi būti panašus į objekto matmenis). Pastaruoju atveju reiktų pasitelkti gerokai tikslesnius, sudėtingesnius ir brangesnius plokštelės gamybos metodus negu šiuo metu populiarus 3D spausdinimas.

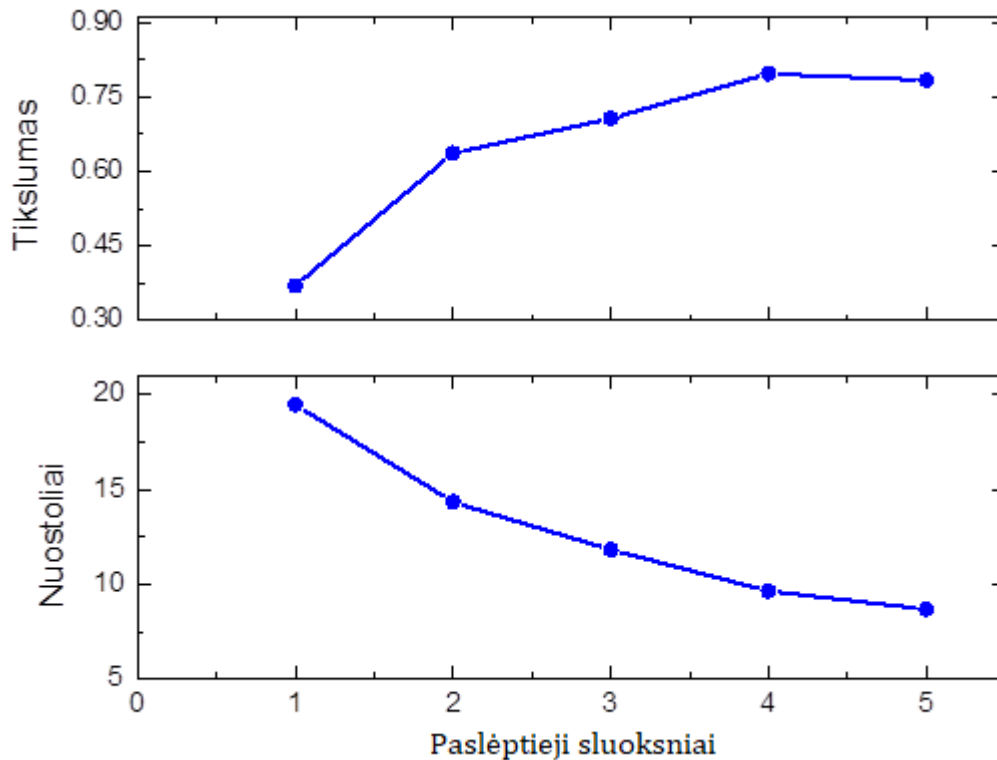
4.1.4. MNIST duomenų rinkinio klasifikavimas

Norint išsiaiškinti difrakcinio neuroninio tinklo galimybes atliekant užduotis reikalaujančias klasifikuoti daugiau skirtingų klasių, buvo pasirinktas MNIST duomenų rinkinys^[46], kuris yra gana dažnai naudojamas klasifikavimo algoritmų galimybės testuoti. MNIST duomenų rinkinyje yra 28x28 raiškos, jokių triukšmų ar pašalinių objektų neturinčių ranka rašytų skaitmenų nuotraukos. Duomenys sudaryti iš 10 skirtingų simbolių (nuo 0 iki 9). Visi difrakcinio neuroninio tinklo parametrai buvo palikti tokie patys kaip ir anksčiau aptarto difrakcinio neuroninio tinklo skirto peilio, pistoleto ir išmaniojo telefono objektų klasifikavimo užduočiai atlikti.

Pažvelgus į 28 paveikslą matome, kad yra stebima beveik tokia pati priklausomybė nuo difrakcinių plokštelių skaičiaus kaip ir kasdienių objektų klasifikavimo uždavinyje. Didžiausias tikslumas buvo stebimas naudojant difrakcinį neuroninį tinklą su 4 paslėptaisiais sluoksniais (~80 %), o nuostolių vertė buvo mažiausia naudojant 5 paslėptuosius sluoksnius ir siekė ~ 8.7. Taip pat MNIST duomenų rinkinio klasifikavimas patvirtina, jog naudojant tik vieną paslėptąjį sluoksnį difrakcinis neuroninis tinklas nesugeba gerai išmokti svarbiausių objektų bruožų ir pasižymi mažesniu tikslumu.

Įdomu tai, jog klasifikuojant 3 skirtingas klases buvo pasiektas maksimalus apie 96 % procentų tikslumas, o 10 skirtingų klasių atveju buvo pasiektas gerokai mažesnis tikslumas, netgi kai patys objektai buvo gerokai paprastesni, o nuotraukos gerokai aukštesnės kokybės. Naudojant įprastus skaitmeninius neuroninius tinklus buvo pasiektas apie 99.7 % tikslumas klasifikuojant MNIST duomenų rinkinį^[45]. Panašus tikslumas buvo pademonstruotas ir naudojant difrakcinį neuroninį tinklą, kuriuo buvo pasiektas netgi 93.39 % tikslumas^[9], kai bangos ilgis buvo trumpesnis (0.75 mm) ir buvo naudojami 5 paslėptieji sluoksniai. Šiame eksperimente pasiektas gerokai mažesnis tikslumas gali būti paaiškinamas tuo, jog difrakcinio tinklo parametrai nebuvo optimizuoti MNIST duomenų rinkinio klasifikacijai atlikti.

Taip pat buvo naudojama gerokai mažesnis skaičius nuotraukų negu kituose tyrimuose (60 nuotraukų vienai klasei).



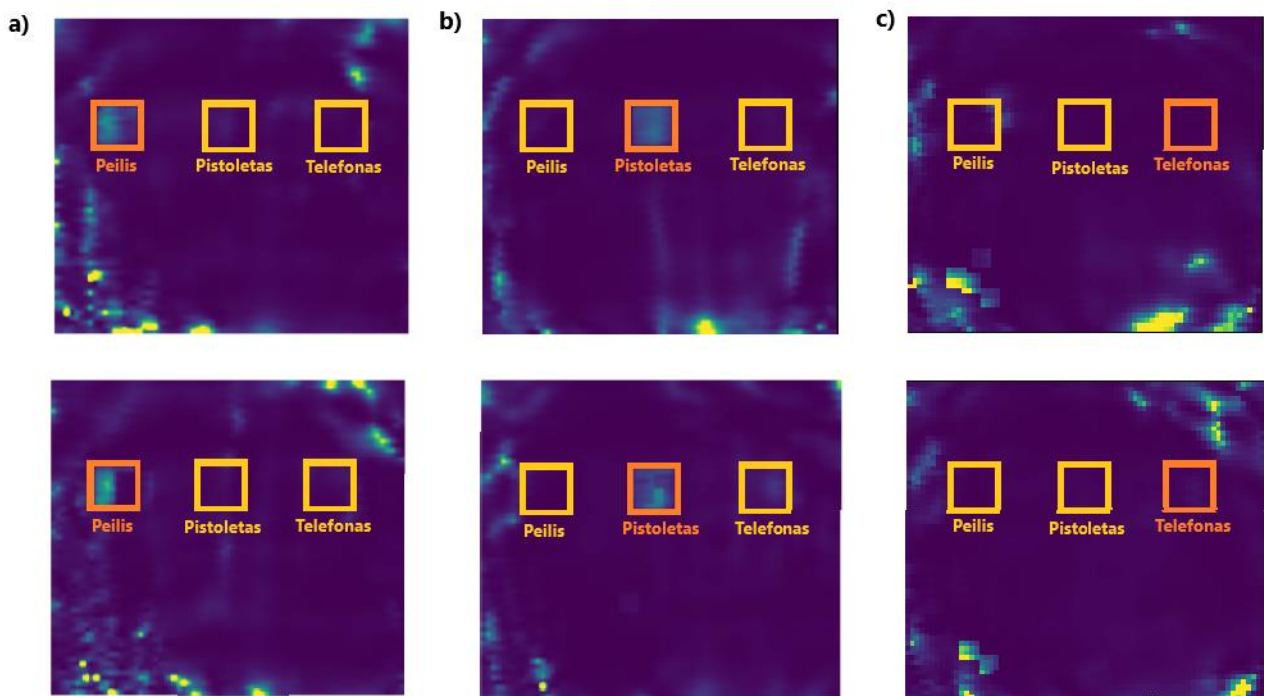
28 pav. Tikslumo ir nuostolių priklausomybė nuo difrakcinių plokštelių (paslėptųjų sluoksnių) skaičiaus klasifikuojant MNIST duomenų rinkinį

4.2. Fiziškai realizuoto difrakcinio neuroninio tinklo testavimas

Remiantis praeitame skyrelyje modeliavimo būdu atliktais tyrimais, eksperimente (18 pav.) yra testuojamas difrakcinis neuroninis tinklas turintis 5 difrakcines plokšteles (17 ir 20 pav.), nes toks neuroninis tinklas pasižymi didžiausiu tikslumu bei mažiausia nuostolių verte (24 pav.). Taip pat buvo pastebėta, jog norint pilnai išnaudoti difrakcinio neuroninio tinklo galimybes atstumas tarp gretimų difrakcinių plokštelių turi būti nemažesnis negu 1 centimetras, tačiau pasirinkus didesnę atstumą tikslumas nesuprastėtų (26 pav.). Tad, dėl techniškai patogesnio įgyvendinimo pasirinktas 2 centimetrų atstumas.

Difrakcinio neuroninio tinklo testavimo metu yra naudojami 24 objektus imituojantys taikiniai (19 pav.). Peilį ir pistoletą imitavo po 10 taikinių, o išmanųjį telefoną 4-ios plokštelės. Mažesnis telefoną imituojančių plokštelių skaičius pasirinktas dėl sunkumų atkuriant išmanųjį telefoną primenantį plyšį.

Rezultatai yra gaunami išmatavus spinduliuotės intensyvumo pasiskirstymą už 2 centimetrų nuo paskutinės difrakcinės plokštelės. Siekiant sumažinti triukšmus atsirandančius eksperimento metu, taip pat buvo atsižvelgta į signalą gaunamą pašalinus difrakcinį neuroninį tinklą, tačiau palikus kelyje taikinį. Tokiu būdu gauti taikinių klasifikavimo rezultatai yra pateikti 29 paveiksliuke. Pateikiant peilį imituojančią plokštelę yra matoma gana stipriai sufokusuota terahercinė spinduliuotė zonoje atsakingoje už peilio klasifikavimą, o kitose zonose spinduliuotės intensyvumas yra labai mažas (29 pav. a). Tai reiškia, jog neuroninis tinklas atpažįsta ir teisingai klasifikuoja peilį. Dar tiksliau sufokusuojama spinduliuotė į teisingą zoną yra pateikus pistoletą primenantį taikinį (29 pav. b). Tačiau pateikus taikinį su telefono formos plyšiu, nėra stebimas spinduliuotės fokusavimas nei į viena iš zonų (29 pav. c). Panašus vaizdas yra stebimas ir kitų telefoną imituojančių taikinių atveju. Taip gali būti dėl to, jog telefoną primenantys taikiniai yra sudaryti iš didelio, beveik visą plokštelę užimančio plyšio ir nepasižymi jokiais aiškiai skiriamaisiais bruožais. Taip pat, buvo pastebėta, jog THz spinduliuotė atsispindi nuo vidinių laikiklio sienelių, kas irgi gali pabloginti gaunamus rezultatus. Galiausiai, nemažą įtaką gali daryti ir tai, jog šaltinio generuojamos spinduliuotės pjūvis statmenas sklidimo kryptčiai nėra visiškai Gauso pluošto formos. Tai galimai sukelia papildomus triukšmus bei apsunkina neuroninio tinklo veikimą. Toks efektas yra ypač pastebimas tais atvejais, kai taikinyje turi didelį plyšį, kuris neapriboja kritusios spinduliuotės ir nesumažina nehomogeniškumo sukeltų triukšmų.



29 pav. Terahercinės spinduliuotės pasiskirstymas plokštumoje už 2 cm nuo paskutinės difrakcinės plokštelės pateikus šešis skirtingus taikinius. Pateikiami (a) peilio; (b) pistoleto; (c) telefono taikiniai.

Išmatavus visų sukurtų taikinių rezultatus buvo gautas 87.5% tikslumas. Tai yra šiek tiek mažesnis negu modeliavimo metu gautas maksimalus ~98% tikslumas. Pažvelgus į klasifikavimo lentelėje pateiktus apibendrintus rezultatus (30 pav.), nesunku pastebėti, jog pagrindinė mažesnio tikslumo priežastis yra visiškai atsitiktinis telefono taikinių klasifikavimas. Tinklo spėjimas yra teisingas tik 1 iš 4 kartų klasifikuojant telefoną primenančius taikinius. Tai reiškia, jog telefono taikiniai yra klasifikuojami visiškai atsitiktinai (tikimybė atspėti teisingą objektą yra 1 iš 3). Tačiau neuroninis tinklas puikiai atpažįsta peilius ir pistoletus ir be jokių klaidų juos priskiria teisingai klasei. Tad norint pasiekti simuliacijos metu gautą tikslumą, reiktų sukurti panašesnius į telefoną bandinius ir naudoti idealų Gauso pluoštą atitinkančią THz bangą.

Tinklo spėjimas	Taikiny		
	Peilis	Pistoletas	Telefonas
Peilis	10	0	2
Pistoletas	0	10	1
Telefonas	0	0	1

30 pav. Terahercinės spinduliuotės pasiskirstymas plokštumoje už 2 cm nuo paskutinės difrakcinės plokštelės. (a) dalyje pateikiamas peilio; (b) dalyje pateikiamas pistoleto; (c) dalyje pateikiamas telefono taikiny.

5. Išvados

1. Šiame darbe buvo skaitmeniškai sumodeliuotas, o vėliau ir trimačio spausdinimo būdu fiziškai pagamintas difrakcinis neuroninis tinklas, skirtas trijų objektų klasių atpažinimui taikinius apšvietus 300 GHz dažnio elektromagnetine spinduliuote. Iš modeliavimo rezultatų matyti, kad neuroninis tinklas tiksliausiai spėjimus atlieka pasitelkus 5 paslėptuosius sluoksnius ir išdėsčius juos nemažesniu negu 1 centimetro atstumu vieną nuo kito.

2. Stebimas atvirkštinis sąryšis tarp difrakcinio neuroninio tinklo tikslumo klasifikuojant objektus ir ribinio atstumo tarp difrakcinių plokštelių. Viršijus ribinį atstumą tikslumas nustoja augti ir išlieka pastovus. Norint sukurti kompaktiškesnę neuroninį tinklą ir išlaikyti užduoties atlikimo tikslumą, reikia mažinti naudojamos spinduliuotės bangos ilgį, o tuo pačiu ir neuronų dydį. Tačiau tai reikalauja technologiškai sudėtingesnės optinio neuroninio tinklo elementų gamybos.

3. Sumodeliuotas difrakcinis neuroninis tinklas pasižymėjo net 98 % maksimaliu tikslumu klasifikuojant kasdienėje aplinkoje sutinkamus objektus (peilį, pistoletą, išmanųjį telefoną). O pagaminus fizinį difrakcinį neuroninį tinklą tikslumas sumažėjo iki 87.5 %.

4. Fiziškai realizuotas difrakcinis neuroninis tinklas puikiai atpažįsta peilius ir pistoletus. Tačiau mažesnis fizinio neuroninio tinklo tikslumas lyginant su modeliavimo rezultatais gali būti paaiškinamas tuo, jog nepavyko sukurti gerai telefoną imituojančių bandinių. Dėl šios priežasties testavimo metu telefono taikiniai buvo priskirti visiškai atsitiktinei klasei.

6. Šaltiniai

- [1] Daniel Zhang, Saurabh Mishra, Erik Brynjolfsson, John Etchemendy, Deep Ganguli, Barbara Grosz, Terah Lyons, James Manyika, Juan Carlos Niebles, Michael Sellitto, Yoav Shoham, Jack Clark, and Raymond Perrault, “The AI Index 2021 Annual Report,” AI Index Steering Committee, Human-Centered AI Institute, Stanford University, Stanford, CA, March 2021.
- [2] Litjens, Geert, Thijs Kooi, Babak Ehteshami Bejnordi, Arnaud Arindra Setio, Francesco Ciompi, Mohsen Ghafoorian, Jeroen A.W.M. van der Laak, Bram van Ginneken, and Clara I. Sánchez. “A Survey on Deep Learning in Medical Image Analysis.” *Medical Image Analysis* 42 (2017): 60–88. <https://doi.org/10.1016/j.media.2017.07.005>.
- [3] Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. “ImageNet Classification with Deep Convolutional Neural Networks.” *Communications of the ACM* 60, no. 6 (2017): 84–90. <https://doi.org/10.1145/3065386>.
- [4] Cho, Kyunghyun, Bart van Merriënboer, Caglar Gulcehre, Dzmitry Bahdanau, Fethi Bougares, Holger Schwenk, and Yoshua Bengio. “Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation.” arXiv.org, September 3, 2014. <https://arxiv.org/abs/1406.1078>.
- [5] Jumper, John, Alexander Pritzel, Tim Green, Michael Figurnov, Kathryn Tunyasuvunakool, Olaf Ronneberger, Russ Bates, et al. “High Accuracy Protein Structure Prediction Using Deep Learning.” Essay. In *CRITICAL ASSESSMENT OF TECHNIQUES FOR PROTEIN STRUCTURE PREDICTION*, edited by Richard Evans, 23–24. May–September, 2020.
- [6] Raccuglia, Paul, Katherine C. Elbert, Philip D. Adler, Casey Falk, Malia B. Wenny, Aurelio Mollo, Matthias Zeller, Sorelle A. Friedler, Joshua Schrier, and Alexander J. Norquist. “Machine-Learning-Assisted Materials Discovery Using Failed Experiments.” *Nature* 533, no. 7601 (2016): 73–76. <https://doi.org/10.1038/nature17439>.
- [7] Leshno, Moshe, Vladimir Ya. Lin, Allan Pinkus, and Shimon Schocken. “Multilayer Feedforward Networks with a Nonpolynomial Activation Function Can Approximate Any Function.” *Neural Networks* 6, no. 6 (1993): 861–67. [https://doi.org/10.1016/s0893-6080\(05\)80131-5](https://doi.org/10.1016/s0893-6080(05)80131-5).
- [8] Hu, Zheng, Jiaojiao Zhang, and Yun Ge. “Handling Vanishing Gradient Problem Using Artificial Derivative.” *IEEE Access* 9 (2021): 22371–77. <https://doi.org/10.1109/access.2021.3054915>.
- [9] Lin, Xing, Yair Rivenson, Nezih T. Yardimci, Muhammed Veli, Yi Luo, Mona Jarrahi, and Aydogan Ozcan. “All-Optical Machine Learning Using Diffractive Deep Neural Networks.” *Science* 361, no. 6406 (2018): 1004–8. <https://doi.org/10.1126/science.aat8084>.
- [10] Luo, Yi, Deniz Mengu, Nezih T. Yardimci, Yair Rivenson, Muhammed Veli, Mona Jarrahi, and Aydogan Ozcan. “Design of Task-Specific Optical Systems Using Broadband Diffractive Neural Networks.” *Light: Science & Applications* 8, no. 1 (2019). <https://doi.org/10.1038/s41377-019-0223-1>.
- [11] B. Limbacher, S. Schoenhuber, M. Wenclawiak, M. A. Kainz, G. Strasser, J. Darmo, A. M. Andrews and K. Unterrainer, „Terahertz optical machine learning for object recognition“, APL Photon. 5, 126103 (2020).
- [12] Copeland, B. (2020, August 11). Artificial intelligence. Encyclopedia Britannica. <https://www.britannica.com/technology/artificial-intelligence>.
- [13] Goodfellow, Ian, Yoshua Bengio, and Aaron Courville. *Deep Learning*. MIT Press, 2016.
- [14] “Minimax Principle.” Minimax principle - Encyclopedia of Mathematics. Accessed June 9, 2021. https://encyclopediaofmath.org/index.php?title=Minimax_principle.
- [15] Korf, R.E. “Does Deep Blue Use Artificial Intelligence?1.” *ICGA Journal* 20, no. 4 (1997): 243–45. <https://doi.org/10.3233/icg-1997-20404>.

- [16] Park, Hochong, and Joo-Hiuk Son. "Machine Learning Techniques for THz Imaging and Time-Domain Spectroscopy." *Sensors* 21, no. 4 (2021): 1186. <https://doi.org/10.3390/s21041186>.
- [17] Mnih, Volodymyr, Koray Kavukcuoglu, David Silver, Alex Graves, Ioannis Antonoglou, Daan Wierstra, and Martin Riedmiller. "Playing Atari with Deep Reinforcement Learning." [1312.5602] *Playing Atari with Deep Reinforcement Learning*, December 19, 2013. <http://export.arxiv.org/abs/1312.5602>.
- [18] Nitish Srivastava Department of Computer Science, Nitish Srivastava, Department of Computer Science, Geoffrey Hinton Department of Computer Science, Geoffrey Hinton, Alex Krizhevsky Department of Computer Science, Alex Krizhevsky, et al. "Dropout: a Simple Way to Prevent Neural Networks from Overfitting." *The Journal of Machine Learning Research*, January 1, 2014. <https://dl.acm.org/doi/10.5555/2627435.2670313>.
- [19] Rokach, Lior. "Ensemble-Based Classifiers." *Artificial Intelligence Review* 33, no. 1-2 (2009): 1–39. <https://doi.org/10.1007/s10462-009-9124-7>.
- [20] Kinsley, Harrison, and Daniel Kukiela. *Neural Networks from Scratch in Python*. Harrison Kinsley, 2020.
- [21] Deep Learning Wins Brain Segmentation Contest. <https://people.idsia.ch/~juergen/deeplearningwinsbraincontest.html>.
- [22] "History of Computer Vision Contests Won by Deep CNNs on GPUs." [people.idsia.ch https://people.idsia.ch/~juergen/computer-vision-contests-won-by-gpu-cnns.html](https://people.idsia.ch/~juergen/computer-vision-contests-won-by-gpu-cnns.html).
- [23] Feng, Xiaoyue, Hao Zhang, Yijie Ren, Penghui Shang, Yi Zhu, Yanchun Liang, Renchu Guan, and Dong Xu. "The Deep Learning-Based Recommender System 'Pubmender' for Choosing a Biomedical Publication Venue: Development and Validation Study." *Journal of Medical Internet Research* 21, no. 5 (2019). <https://doi.org/10.2196/12957>.
- [24] Aäron van den Oord, Sander Dieleman, and Benjamin Schrauwen. Deep content-based music recommendation, December 1, 2013. <https://dl.acm.org/doi/10.5555/2999792.2999907>.
- [25] Rosenblatt, F. "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain." *Psychological Review* 65, no. 6 (1958): 386–408. <https://doi.org/10.1037/h0042519>.
- [26] Sonoda, Sho, and Noboru Murata. "Neural Network with Unbounded Activation Functions Is Universal Approximator." *Applied and Computational Harmonic Analysis* 43, no. 2 (2017): 233–68. <https://doi.org/10.1016/j.acha.2015.12.005>.
- [27] Boureau, Y-Lan & Ponce, J. & Lecun, Yann. (2010). A Theoretical Analysis of Feature Pooling in Visual Recognition. *ICML 2010 - Proceedings, 27th International Conference on Machine Learning*. 111-118.
- [28] Chen, Hang, Jianan Feng, Minwei Jiang, Yiqun Wang, Jie Lin, Jiubin Tan, and Peng Jin. "Diffraction Deep Neural Networks at Visible Wavelengths." *Engineering*, 2021. <https://doi.org/10.1016/j.eng.2020.07.032>.
- [29] Hafez, H A, X Chai, A Ibrahim, S Mondal, D Férachou, X Ropagnol, and T Ozaki. "Intense Terahertz Radiation and Their Applications." *Journal of Optics* 18, no. 9 (2016): 093004. <https://doi.org/10.1088/2040-8978/18/9/093004>.
- [30] Dhillon, S S, M S Vitiello, E H Linfield, A G Davies, Matthias C Hoffmann, John Booske, Claudio Paoloni, et al. "The 2017 Terahertz Science and Technology Roadmap." *Journal of Physics D: Applied Physics* 50, no. 4 (2017): 043001. <https://doi.org/10.1088/1361-6463/50/4/043001>.
- [31] Sharma, Neha, Vibhor Jain, and Anju Mishra. "An Analysis Of Convolutional Neural Networks For Image Classification." *Procedia Computer Science* 132 (2018): 377–84. <https://doi.org/10.1016/j.procs.2018.05.198>.
- [32] He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. "Deep Residual Learning for Image Recognition." [1512.03385v1] *Deep Residual Learning for Image Recognition*, December 10, 2015. <https://export.arxiv.org/abs/1512.03385v1>.
- [33] "Deep Learning." Wikipedia. Wikimedia Foundation. https://en.wikipedia.org/wiki/Deep_learning#/media/File:AI-ML-DL.svg.

- [34] Heidenreich, Hunter. “What Are the Types of Machine Learning?” Medium. Towards Data Science, December 4, 2018. <https://towardsdatascience.com/what-are-the-types-of-machine-learning-e2b9e5d1756f>.
- [35] Sharma, Niraj & Chaudhry, Kauser & Chalapati Rao, C V. (2005). Vehicular pollution modeling using artificial neural network technique: A review. *Journal of Scientific and Industrial Research*. 64.
- [36] Qiu, Ying, Yang Liu, Juan Arteaga-Falconi, Haiwei Dong, and Abdulmotaleb El Saddik. “EVM-CNN: Real-Time Contactless Heart Rate Estimation From Facial Video.” *IEEE Transactions on Multimedia* 21, no. 7 (2019): 1778–87. <https://doi.org/10.1109/tmm.2018.2883866>.
- [37] T Nitta. On the critical points of the complex-valued neural network. In *Neural Information Processing, 2002. ICONIP'02. Proceedings of the 9th International Conference on*, volume 3, pages 1099–1103. IEEE, 2002.
- [38] Akira Hirose and Shotaro Yoshida. Generalization characteristics of complex-valued feedforward neural networks in relation to signal coherence. *IEEE Transactions on Neural Networks and learning systems*, 23(4): 541–551, 2012
- [39] Martin Arjovsky, Amar Shah, and Yoshua Bengio. Unitary evolution recurrent neural networks. arXiv preprint arXiv:1511.06464, 2015
- [40] Trabelsi, C., Bilaniuk, O., Zhang, Y., Serdyuk, D., Subramanian, S., Santos, J. F., Mehri, S., Rostamzadeh, N., Bengio, Y., & Pal, C. J. (2018, February 25). Deep Complex Networks. arXiv.org. <https://arxiv.org/abs/1705.09792>
- [41] Bassey, J., Qian, L., & Li, X. (2021, January 28). A survey of complex-valued neural networks. arXiv.org. <https://arxiv.org/abs/2101.12249>
- [42] Suresh, S., Sundararajan, N., & Savitha, R. (2013). Fully complex-valued multi layer perceptron networks. *Supervised Learning with Complex-Valued Neural Networks*, 31–47. https://doi.org/10.1007/978-3-642-29491-4_2
- [43] Fuente, R. de la. (n.d.). Simulating diffraction patterns with the angular spectrum method and python. *Simulating Physics*. <https://rafael-fuente.github.io/simulating-diffraction-patterns-with-the-angular-spectrum-method-and-python.html>
- [44] Goodman, J. W. (1996). *Introduction to fourier optics*. McGraw-Hill.
- [45] Ciresan, D., Meier, U., & Schmidhuber, J. (2012). Multi-column deep neural networks for Image Classification. 2012 IEEE Conference on Computer Vision and Pattern Recognition. <https://doi.org/10.1109/cvpr.2012.6248110>
- [46] *The MNIST Database*. MNIST handwritten digit database, Yann LeCun, Corinna Cortes and Chris Burges. (n.d.). <http://yann.lecun.com/exdb/mnist/>
- [47] Culurciello, E. (2018, December 24). *Neuromorphic and deep neural networks*. Medium. <https://towardsdatascience.com/neuromorphic-and-spiking-or-not-894a836dc3b3>
- [48] An Overview on 3D Printing Technology: Technological, Materials, and Applications. 10.1016/j.promfg.2019.06.089
- [49] Jandyal, A., Chaturvedi, I., Wazir, I., Raina, A., & Ul Haq, M. I. (2022). 3D printing – a review of processes, materials and applications in industry 4.0. *Sustainable Operations and Computers*, 3, 33–42. <https://doi.org/10.1016/j.susoc.2021.09.004>
- [50] University, M. K. J. H., Kazhdan, M., University, J. H., University, M. B. J. H., Bolitho, M., Research, H. H. M., Hoppe, H., Research, M., Columbia, U. of B., Berlin, F. U., & Metrics, O. M. V. A. (2006, June 1). Poisson surface reconstruction: Proceedings of the Fourth eurographics symposium on geometry processing. *ACM Conferences*. Retrieved from <https://dl.acm.org/doi/10.5555/1281957.1281965>

Nuoroda į difrakcinio neuroninio tinklo modeliavimo kodą:

<https://github.com/Laurynasend/Diffractive-Neural-Network>

7. Summary

Development and testing of diffractive neural network operating in terahertz frequency range

Deep learning has recently made various breakthroughs in solving complicated inference tasks. Despite digital neural networks becoming more and more popular, they still have some intrinsic detrimental properties. The need for vast energy and computational resources of a digital neural network during inference can be eliminated using optical diffractive neural network (D²NN) design, since only incident photon energy is being used and all computations are done in parallel at the speed of light. While the use of THz waves enables D²NN to be utilized in security, medicine and many other fields. The main task of this work was to design and test the capabilities of physically printed D²NN to classify objects. It was found that diffractive neural network design with 5 hidden layers, distanced no less than 1 centimeter apart showcased the best results. Such D²NN reached an accuracy of 98% when classifying between three chosen objects (a pistol, a knife and a smartphone). While physically printed D²NN performed slightly worse and reached an accuracy of 87.5%. Main factor influencing the drop of accuracy was the hardship in creating high quality smartphone objects, leading to many of them being misclassified.