



TALLINNA TEHNIKAÜLIKOOL
LOODUSTEADUSKOND
KÜBERNEETIKA INSTITUUT

**MASINÕPPE RAKENDAMINE TAU OSAKESTE HADRONILISTE
LAGUNEMISKANALITE KLASSIFITSEERIMISEL SIMULEERITUD
KIIRENDIEKSPERIMENDIS**

Bakalaureusetöö

Üliõpilane: Hardi Vanaveski
Juhendaja: Joosep Pata, PhD, vanemteadur, KBF
Õppekava: Rakendusfüüsika

Sisukord

Sissejuhatus	4
1 Kirjanduse ülevaade	5
1.1 Standardmudel	5
1.1.1 Tau lepton	6
1.1.2 Tau leptoni lagunemiskanaliid	6
1.2 Osakeste juga	7
1.2.1 Joa osakeste rekonstrueerimine.	8
2 Masinõpe	9
2.1 Juhendatud masinõpe	9
2.2 Pärilevivõrk	10
3 Metoodika	12
3.1 Andmete simuleerimine	12
3.1.1 Andmete struktuur	12
3.1.2 Testandmestik	14
3.2 Mudeli struktuur	15
3.3 Mudeli optimeerimine	15
3.4 Mudeli hindamine	16
4 Tulemused ja arutelu	17
4.1 Tulemused	17
4.2 Arutelu	19
5 Kokkuvõte	21
Annotatsioon	22
Abstract	23
Tänuavaldused	24
Kasutatud kirjandus	25
Lisad	27

Lühendid ja terminid

CMS	Kompaktne müüoni solenoid (ingl <i>Compact Muon Solenoid</i>)
ECAL	Elektromageetiline Kalorimeeter (ingl <i>Electromagnetic Calorimeter</i>)
FN	Vale negatiivne (ingl <i>False Negative</i>)
FP	Vale positiivne (ingl <i>False Positive</i>)
HCAL	Hadronite kalorimeeter (ingl <i>Hadron Calorimeter</i>)
NN	Närvivõrk (ingl <i>Neural Network</i>)
PDG	Osakeste Andme Grupp (ingl <i>Particle Data Group</i>)
PF	Osakeste vool (ingl <i>Particle Flow</i>)
SM	Standardmudel
TN	Õige negatiivne (ingl <i>True Negative</i>)
TP	Õige positiivne (ingl <i>True Positive</i>)

Sissejuhatus

Tehnoloogia areng on märkimisväärselt edendanud nii eksperimentaalset kui ka teoreetilist füüsikat, avades uusi võimalusi keerukate nähtuste uurimiseks. Masinõppe ja süvaõppe meetodid on eriti tähtsaks muutunud, võimaldades suuremahuliste andmehulkade analüüsimist ja keerukate füüsikaliste protsesside modelleerimist efektiivsemalt kui kunagi varem. Tehnoloogilise arengu mõju oli märgata näiteks Standardmudeli (SM) Higgsi bosoni otsingul, kus kasutati tiptasemel arvutussüsteeme ja klasterdamise algoritme [1].

Pärast Higgsi bosoni avastamist on kindlaks määratud tema lagunemiskanaliid, millest üks on $H \rightarrow \tau^- \tau^+$ [2]. Tau (τ) on leptonite hulka kuuluv elementaariosake, mille eripäraks on mitukümmend korda suurem mass võrreldes teiste leptonitega, nagu elektron ja müüon. Tänu tema võrdlemisi suurele massile on tau osakesel unikaalne võime laguneda nii leptoniliselt kui ka hadroniliselt. See omadus muudab ta füüsikas oluliseks uurimisobjektiks, kuna tau hadronilised lagunemised pakuvad teavet fundamentaalsete füüsikaliste protsesside kohta.

Tau hadroniliste lagunemiste tuvastamine on oluline ülesanne nii praegustes kui ka tulevastes kõrge energia füüsika eksperimentides. See panustab oluliselt Higgsi osakese ja elektro-nõrkade bosonite lagunemise analüüsimisse, ning aitab avastada uusi füüsikalisi nähtusi Standardmudelist väljaspool [3]. Samuti on tau hadroniliste lagunemiste uurimine oluline kvantkromodünaamika põhimõtete ja fundamentaalsete suuruste uurimiseks ja mõõtmiseks. Nende nähtuse analüüsimiseks on vaja puhast valimit, ehk kõrge täpsusega tuvastada taolisi tau lagunemisi gluuonite ja kvarkide taustast [4].

Käesoleva uurimistö eesmärk on klassifitseerida tau hadronilisi lagunemiskanaleid, ning mõista nende füüsikalist sisu. Selleks optimeeriti olemasolevat süvaõppe koodi [3], rakendades pärilevivõrku tau lagunemiste tuvastamiseks. Närvivõrgu treenimiseks kasutati simuleeritud $e^- e^+$ põrgete sündmusi. Mudeli efektiivsuse hindamiseks esitati segadusmaatriks koos ebavõrdse andmestiku hindamise jaoks loodud funktsioonidega ja tulemusi võrreldi teiste uuringute omadega.


Uurimistö järgnevates peatükkides tutvustatakse osakestefüüsika tausta, masinõppe algoritmide töötamise põhimõtteid ning kirjeldatakse kasutatud mudelit, andmestikku ja tulemusi. Seejärel analüüsitakse saadud tulemusi, nende füüsikalist sisu ja pakutakse välja võimalikke lahendusid mudelite edasiseks arendamiseks. Lõpetuseks tehakse uurimistöle kokkuvõte.

1. Kirjanduse ülevaade

Osakestefüüsika või kõrge energia füüsika on füüsika haru, mis uurib peamiselt kiirgust ja materiat moodustavaid alusosakesi, ning nendevahelisi vastasikmõjusid. Kuna paljud elementaarosakesed ei esine madalal energiatasemel, peab nende saamiseks osakesi kiirendama ja suure energiaga kokku põrgatama. Sealt tuleb haru viimane nimetus. Uuringud selles valdkonnas on tõestanud kvarkide, leptonite ja bosonite olemasolu, millega tegeleb tänapäevane osakestefüüsika [5].

1.1 Standardmudel

Alusosakeste käitumist selgitavate protsesside matemaatiliseks kirjeldamiseks loodi Standardmudel (vt joonis 1), mis pakub täpset seletust paljude osakeste kiirendi ja kiirendita katsete tulemustele. Standardmudeli keskmes on kvargid, leptonid, jõukandja osakesed ning nendevahelised interaktsioonid läbi alusjõudude. Alusjõudusid on Standardmudelis kolme erinevat tüüpi ja neid vahendavad erinevad jõudude kandjad. Elektromagnetilisi jõudusid vahendavad fotonid, nõrkasid jõudusid vahendavad W ja Z bosonid, ning tugevaid jõudusid vahendavad gluonid [6].



Joonis 1. Standardmudel koosneb alusosakestest: kvarkidest (lillad), leptonitest (rohelistest) ja jõukandja osakestest bosonitest (punased). Higgs on skalaarboson, ehk spinniga 0 (kollane) [7].

1.1.1 Tau lepton


Tau osake on üks alusosakestest, mis kuulub leptonite perekonda koos müüonite ja elektronidega. Tal on sama laeng ja spinn kui elektronil ja müüonil, kuid eristub nendest palju suuremat massi omades. Tau keskmine eluiga on $t_\tau = 290.15 \pm 0.5 \times 10^{-15}$ s [5] ja keskmine lagunemiskaugus 30 GeV energia juures on

$$\lambda_\tau = c \cdot \frac{p_\tau}{m_\tau} \cdot t_\tau \simeq 3.00 \times 10^{11} \text{ mm/s} \cdot \frac{30 \text{ GeV}}{1.78 \text{ GeV}} \cdot 290.15 \times 10^{-15} \text{ s} \simeq 1.5 \text{ mm}. \quad (1.1)$$

Kus c on valguse kiiruse konstant, p_τ on tau impulss ja m_τ on tau mass. Äärmiselt kiire eluea ja lühikese lagunemiskauguse tõttu ei ole võimalik taud detektoritega otseselt tuvastada. Tau lagunemisi saab tuvastata kaudselt tema lagunemisproduktide kaudu [1].

1.1.2 Tau leptoni lagunemiskanaliid

Kõik leptonid, sealhulgas tau, lagunevad leptoniliselt, kuid erinevalt teistest leptonitest on tau ainus, mis võib laguneda ka hadroniliselt (vt joonis 2). Seda tänu tema suurele massile $m_\tau = 1776.86 \pm 0.12$ MeV, mis võrreldes müüoni massiga on pea kakskümmend korda suurem [1], [8].



Joonis 2. Feynmani diagrammid τ^- leptonilisest lagunemisest (vasakul) ja τ^- hadronilisest lagunemisest (paremal). Leptoniline lagunemine tähendab, et osake (τ^-) laguneb läbi nõrga jõukandja osakese (W^-) leptoniks, näiteks müüoniks (μ^-) või elektroniks (e^-) ja vastavaks neutriinoks ($\nu_{e,\mu}$). Hadroniline lagunemine on sarnane, kuid lagunemisproduktideks on hadronid (h), nagu piionid (π) ja kaaonid (K), mis koosnevad kahest kvargist [8]. Näiteks $\pi^- : \bar{u}, d$ ja $K^- : \bar{u}, s$ [5].

Lagunemine kahe kanali vahel pole võrdväärne tänu lihtsale kombinatoorikale. Leptoniliselt lagunemise võimalusi on peamiselt kaks - elektroniks või müüoniks ja vastavaks neutriinoks. Hadroniliselt lagunemise teeb tõenäolisemaks kvarkide värvilaengud, mis võimaldavad rohkem erinevaid kombinatsioone, ehk erinevaid hadroneid. Eksperimentaalsed katsed näitavad, et leptoniliselt laguneb umbes 1/3 ja hadroniliselt ülejäänud 2/3 juhtudest [1].

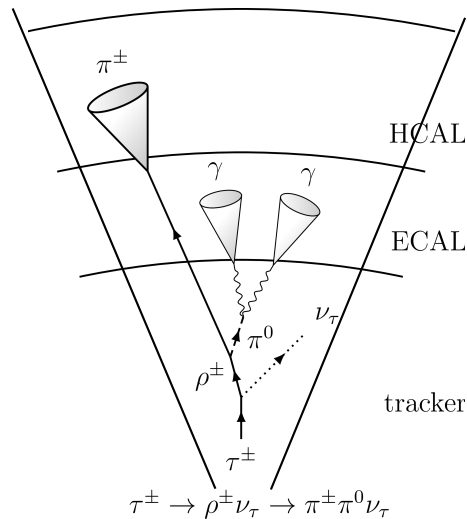
Peamised lagunemiskanalid on koos nende mõõdetud osakaaludega tabelis 1. Tabelist on näha, et kõige tõenäolisem tau lagunemine on üheks laetud hadroniks, neutraalseks piioniks ja tau neutriinoks [5]. Lisaks võib märgata hadronilise lagunemise puhul osakaalu ja osakeste arvu vahelist korrelatsiooni - mida rohkem osakesi, seda vähem tõenäolisem on kanali osakaal.

Lagunemise kanal	Kanali osakaal (%)
Hadroniline lagunemine	64.79
$\tau^- \rightarrow h^- \nu_\tau$	11.51
$\tau^- \rightarrow h^- \pi^0 \nu_\tau$	25.93
$\tau^- \rightarrow h^- \pi^0 \pi^0 \nu_\tau$	9.48
$\tau^- \rightarrow h^- \pi^0 \pi^0 \pi^0 \nu_\tau$	1.18
$\tau^- \rightarrow h^- h^- h^+ \nu_\tau$	9.80
$\tau^- \rightarrow h^- h^- h^+ \pi^0 \nu_\tau$	4.76
$\tau^- \rightarrow \text{muu}$	2.31
Leptoniline lagunemine	35.21
$\tau^- \rightarrow e^- \bar{\nu}_e \nu_\tau$	17.82
$\tau^- \rightarrow \mu^- \bar{\nu}_\mu \nu_\tau$	17.39

Tabel 1. Peamised tau lagunemise kanalid ja osakaalud. h^- alla kuuluvad π^- ja K^- lagunemised [5].

1.2 Osakeste juga

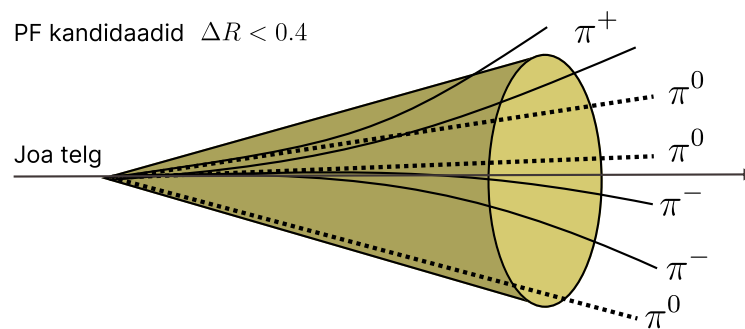
Osakeste kõrgeenergilistel kokkupõrgetel tekivad kvargid ja gluonid, mis fragmenteeruvad ja hadroniseeruvad, tulemuseks on värvineutraalsed hadronid. See nähtus tuleneb kvantkromodünaamikast, mis kehtestab, et kvarkide ja gluonite üksik olek pole võimalik ning need peavad ühinema, moodustades värvineutraalse kombinatsiooni. Näiteks antipunane ja punane annavad värvitu. Kvarke mõjutab tugev vastastikmõju, mistõttu osakeste kokkupõrkel tekkinud kvargid interakteeruvad koheselt teiste kvarkidega vastavalt värvilaengu reeglile. Tekkinud hadronitel on kokku sama impulss, kui osakestel, millest nad tekkisid, ehk lagunemise käigus liiguvad hadronid ühes kitsas koonuses. Seda hadronitest koosnevat kitsast koonust kutsutakse joaks (ingl *jet*) [9]. Joonis 3 kujutab, mida detektorid tuvastavad ja kuidas osakeste lagunemise protsessid toimuvad koonuse sees.



Joonis 3. Juga tau lagunemisel [10]. Joonise all on tau lagunemiskanal. Kõik protsessid toimuvad kitsa koonuse, ehk joonisel kahe sirge vahel, moodustades ühe joa. Hadronite kalorimeeter (HCAL) tuvastab ainult ühe laetud piioni ning elektromagneetiline kalorimeeter (ECAL) tuvastab kaks fotonit.

1.2.1 Joa osakeste rekonstrueerimine.

Selleks, et teada, mis osakesed kuuluvad jugsasse kasutatakse CMS-is joa rekonstrueerimisel, mitmeid algoritme. Individuaalsete osakeste tuvastamiseks ja rekonstrueerimiseks on Particle Flow (PF) algoritm, mis saab infot kõigilt detektoritelt. PF pakutud osakestest, ehk kandidaatidest rekonstrueeritakse klasterdamise algoritmi anti- k_T abil joad (vt joonis 4).



Joonis 4. PF kandidaatidest joa rekonstrueerimine anti- k_T algoritmiga [9].

2. Masinõpe

Masinõpe ehk ML (ingl Machine learning) on tehisintellekti alamvaldkond, mille peamine eesmärk on luua algoritme, mis automaatselt avastavad andmetes mustreid ja struktuure. Tohutute andmehulkade ja komplekssete andmete analüüsimisel leiavad automatiseeritud masinõppe algoritmid inimestele nähtamatuid seoseid. ML võib jagada kolme kategooriasse: juhendatud õpe, juhendamata õpe ja stiimulõpe. Juhendatud masinõpe on kui algoritmid sobitavad mingi objekti parameetrite järgi ette nähtud klassi, näiteks pildilt arvude tuvastamine. Juhendamata masinõpe on kui algoritm ei pea ennustama spetsiifilist klassi, vaid loob selle ise. Stiimulõpe kasutab ümbritsevaid andmeid, et kohandada ennast tehislikus keskkonnas, saades minimaalselt trahvi [11].

2.1 Juhendatud masinõpe

Juhendatud masinõppe algoritmid otsivad andmetes seoseid, millega kirjeldada määratud väljundeid, näiteks kindlaid klasse. Andmeid on vaja enne töötlemist ette valmistada, et mudelil oleks võimalikult kvaliteetne valim, sest müra ja andmestruktuuride erinevused põhjustavad mudeli täpsuse langemist. Erinevused on näiteks, kui klasside arväärtused on erineva komakoha täpsusega või, kui osadel muutujatel puuduvad väärtused. Lisaks on vaja andmeid märgendada, ehk määrata andmeridadele märgendid (ingl *target*), et ML algoritmil oleks millelt õppida [12]. Juhendatud masinõpet kasutatakse osakestefüüsikas erinevate osakeste tuvastamiseks. Kiirendiekspereimendis simuleeritakse suuri andmehulki, mille peal treenitakse algoritme tuvastama spetsiifilist osakest või protsessi. Näiteks Higgsi osakese otsimisel loodi algoritm, mis eristas Z bosoni lagunemist taudeks Higgsi omadest [1].

Andmehulk, mille kogume mudeli jaoks on kui maatriks, mis koosneb ridadest ja veergudest. Ridu võime kujutada kui sildistatud objekte, mida kirjeldavad veeru väärtused ehk omadused. Näiteks, kui iga rida on mingi tau lagunemiskanali, siis veerg kirjeldab selle kanali omadusi, nagu osakeste arv, tau laeng, neliimpulss jms. Juhendatud masinõppe eesmärk on leida funktsioon, mis suudab uuele, märgistamata reale anda väljund, mis sarnaneb simulatsioonist teada oleva sildiga [12].

Andmed jagatakse tavaliselt kolmeks: treening-, test- ja valideerimisandmestikuks. Treeningandmestikku kasutatakse mudeli "õpetamiseks", aidates mudelil tuvastada sisendandmete ja märgendatud väljundite vahelisi seoseid. Testandmestik on eraldiseisev andmehulk, mida kasutatakse mudeli kvaliteedi hindamiseks pärast treenimist. Valideerimisandmestik on mudeli üldise jõudluse hindamiseks, aidates vältida ületreenimist ja tagades mudeli võime teha

täpseid ennustusi ka uute andmete põhjal [11].

2.2 Pärilevivõrk

Pärilevivõrgu tööpõhimõte seisneb selles, et informatsioon liigub ühes suunas - sisendkihist läbi ühe või mitme peidetud kihi kuni väljundkihini. Kõik kihid koosnevad sõlmedest (ingl *nodes*). Sõlmed on omavahel ühendatud servadega (ingl *edges*), mis kannavad informatsiooni ühest sõlmest teise (vt joonis 5). Iga serv on seotud kaaluga, mis määrab selle serva kaudu liikuva informatsiooni olulisuse. Iga sõlme sisendite summa arvutatakse kaalude ja sisendite korrutisena, millele lisatakse nihe (ingl *bias*). See summa on sõlme aktiveerimisfunktsiooni sisend. Aktiveerimisfunktsioon määrab sõlme väljundi, mis on sisendiks järgmise kihi sõlmedele [13].

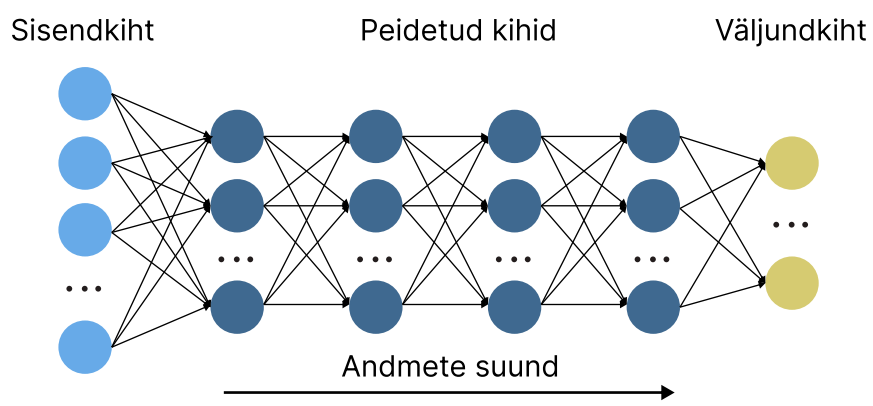
Aktiveerimisfunktsioonina kasutatakse sageli ReLU (ingl *Rectified Linear Unit*) funktsiooni, mis on lihtne, kuid tõhus. ReLU funktsioon on null, kui sisend on negatiivne ja võrdub sisendiga, kui see on positiivne. See võimaldab võrgul õppida mittelineaarseid seoseid, mis on olulised paljude andmestike puhul [14].

Närvivõrgu parameetrite optimeerimine toimub gradientlaskumise ja tagasilevi (ingl *back-propagation*) meetodite abil. Gradientlaskumine on optimeerimisalgoritm, mis püüab leida igal iteratsioonil võrgu kaaluparameetritele väärtused, mis minimeerivad kaotusfunktsiooni. Tagasilevi võimaldab arvutada kaotusfunktsiooni gradiendid võrgu kaalude suhtes, viies vea tagasi võrgu väljundkihist sisendkihti. Selle abil korrigeeritakse kaale, et parandada võrgu ennustusvõimet, muutes kaaluparameetreid suunas, mis vähendab kaotust. See kombinatsioon on vajalik võrgu tõhusaks treenimiseks ja optimeerimiseks [15].

Optimeerimisfunktsioonina kasutatakse sageli AdamW-d [16], mis on Adam [17] optimeerija modifikatsioon, mis võtab arvesse kaalude langust. See aitab vältida üleõppimist ja parandab närvivõrgu üldist kvaliteeti. AdamW optimeerija kohandab iga kaalu õppimiskiirust individuaalselt, mis võimaldab võrgul kiiremini ja tõhusamalt õppida.

Dropout-meetodit kasutatakse üleõppimise vältimiseks. See seisneb selles, et õppimise ajal "visatakse ära" juhuslikult valitud sõlmed, mis tähendab, et neid ei arvestata võrgu väljundi arvutamisel. See sunnib võrku olema robustsem ja vähem sõltuv üksikutest sõlmedest, mis aitab parandada võrgu üldist kvaliteeti valideerimisandmestikul [18].

Joonisel 5 on näha, et lisaks sisend- ja väljundkihtidele on ka neli peidetud kihti. Peidetud kihtide arv ja nende sõlmede arv võivad varieeruda sõltuvalt konkreetsest ülesandest ja andmestikust. Peidetud kihtides toimub suurem osa võrgu õppimisest, kuna need sisaldavad sõlmi, mis õpivad andmestiku keerukamaid omadusi. Näiteks võivad esimese peidetud kihi sõlmed õppida tuvastama lihtsaid omadusi, nagu jooned või värvid, samas kui sügavamate kihtide sõlmed õpivad tuvastama keerukamaid omadusi, nagu kujud või objektid [14].



Joonis 5. Kuuekihiline pärilevivõrk, millest neli on peidetud kihid.

3. Metoodika

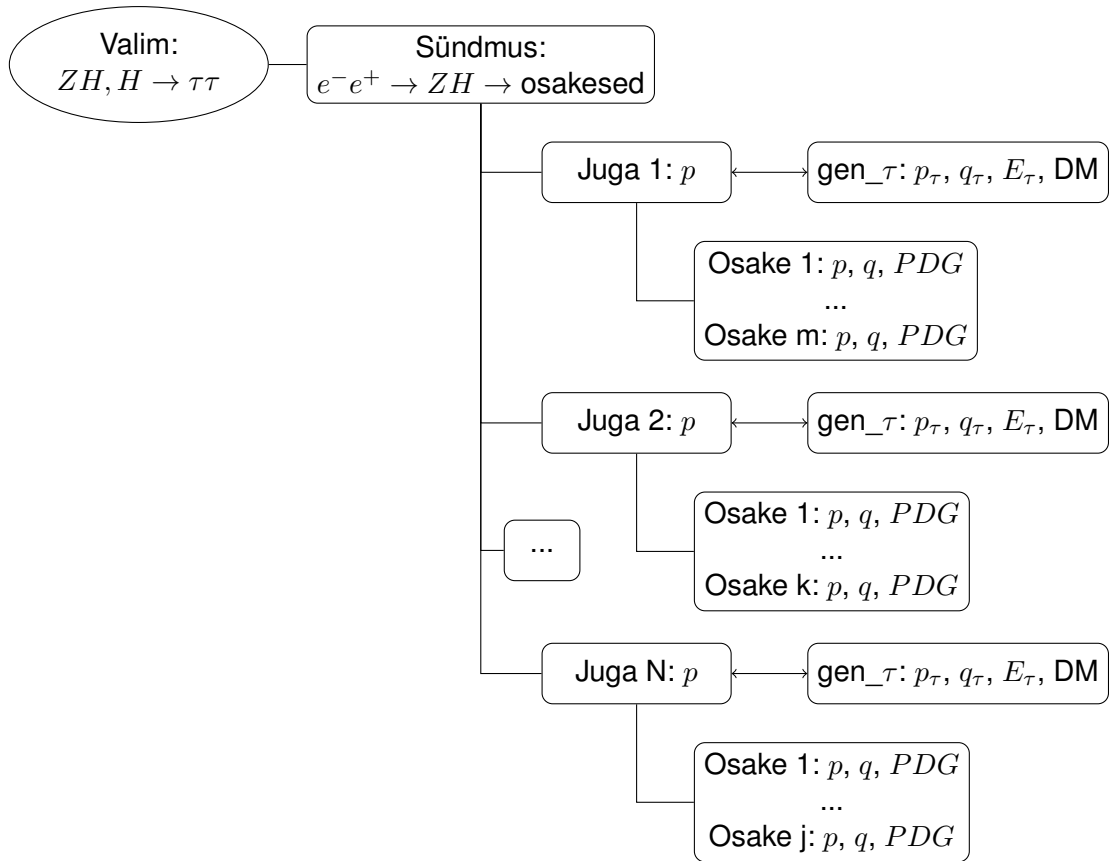
Uurimistöö eesmärk oli edasi arendada avaldatud tulemusi [3], mis tuvastasid tau hadronilisi lagunemisi, kuid ei klassifitseerinud lagunemiskanalite harusid. Autor modifitseeris koodi vastavalt uurimistöö eesmärgile.

3.1 Andmete simuleerimine

Kogu protsess oli simuleeritud, ehk simuleeriti osakesi ja nende interaktsioone detektoritega. Esialgu genereeriti sündmuste kogum PYTHIA8 [19] programmiga e^-e^+ põrgetest energiaga 380 GeV. Genereeritud sündmuste $Z, Z \rightarrow \tau\tau$ ja $ZH, H \rightarrow \tau\tau$ puhul oli teada, kas toimus tau lagunemine või mitte. Genereeritud andmeid kasutati sisendina detektori simulatsioonis, mille väljundiks olid kalorimeetrite ja laetud osakeste detektorite signaalid. Detektoritest registreeritud signaalide põhjal rekonstrueeriti osakesed. Tulemuseks saadi rekonstrueeritud osakesed, mis erinesid genereeritud osakestest simuleeritud müra ja mõõtevigade tõttu, olles geomeetriliselt piisavalt sarnased genereeritud osakestele ja säilitades tau lagunemise olemasolu [3].


3.1.1 Andmete struktuur

Üldine andmete struktuur on kujutatud joonisel 6. Valim näitas, kas taud tulid genereeritud Z või H bosoni lagunemisest. Valimi moodustasid vastavad sündmused $e^-e^+ \rightarrow Z, Z$ või $e^-e^+ \rightarrow ZH, H$, mis lagunesid madalama energiaga osakesteks. Sündmuse kogumi moodustasid joad, mis olid vastavusse seatud genereeritud tudega. Iga juga kirjeldas neliimpulss p ja joas olevate osakeste jada, ning genereeritud tau kohta teati neliimpulssi p_τ , laengut q_τ , energiat E_τ ja lagunemiskanalit DM. Iga osakest kirjeldasid järgmised suurused: neliimpluss p , laeng q , osakese tüüp (hadron, lepton, footon jms).



Joonis 6. Üldine andmete struktuur. Sündmustes oli varieeruv arv jugasid ja igas joas oli varieeruv arv osakesi.

Joonisel 7 on kujutatud osakeste jaotused $ZH, H \rightarrow \tau\tau$ jugades. Jugasid oli kokku umbes viissada tuhat ja osakeste arv joas varieerus. Vasakpoolsetel alamjoonistel on kahedimensionaalne histogramm, mis kujutab osakeste jaotust ümber joa telje, kus $\Delta\eta = \eta_{jet} - \eta_{osake}$ ja $\Delta\phi = \phi_{jet} - \phi_{osake}$. Väheste osakestega harude korral on suurem enamus osakesi väga lähedal joa teljele. Rohkemate osakeste korral on joa telje ümber suurem hajumine. Parempoolsetel alamjoonistel on kahe haru osakeste arvjaotuse histogramm. Lagunemiskanalis $\tau^- \rightarrow \pi^- \nu_\tau$ oli kõige rohkem ühe osakesega jugasid ja $\tau^- \rightarrow \pi^- \pi^0 \pi^0 \nu_\tau$ oli kõige rohkem viie osakesega jugasid. Mõlemad tulemused olid ootuspärased, arvestades, et tau lagunedes mitmeks osakeseks, suureneb ka rekonstrueeritud osakeste arv joas.



Joonis 7. Parempoolsed tulpdigrammid kujutavad jugade $\tau^- \rightarrow \pi^- \nu_\tau$ (1h_0pi0) ja $\tau^- \rightarrow \pi^- \pi^0 \pi^0 \nu_\tau$ (1h_2pi0) osakeste arvjaotusi. $\tau^- \rightarrow \pi^- \nu_\tau$ oli umbes seitsekümmend tuhat ja $\tau^- \rightarrow \pi^- \pi^0 \pi^0 \nu_\tau$ umbes kaheksakümmend viis tuhat. Vasakpoolsed 2D-histogrammid kujutavad jugade osakeste jaotusi ümber joa telged, kus η on nurk neliimpulsi vektori p ja neliimpulsi vektori ristsuunalise komponendi p_T vahel, ja ϕ on nurk CMS'i x-telje ja neliimpulsi vektori vahel [20]. Värviskeem on logaritmiline.

3.1.2 Testandmestik

Testandmestikus oli umbes sada tuhat juga, kust puudusid tausid mitte sisaldavad ja leptonilised tau joad, kuna eesmärk oli klassifitseerida ainult tau hadronilisi lagunemiskanaleid. Selleks, et mudeli tulemused oleks võrreldavad Particle Data Group'i (PDG) omadega tuli tabeli 1 väärtused ümber arvutada, et saada sobilikud osakaalu väärtused (tabel 2).

Lagunemiskanal	Algne osakaal (%)	Kohandatud osakaal (%)
Hadroniline lagunemine	64.79	100
$\tau^- \rightarrow h^- \nu_\tau$	11.51	17.77
$\tau^- \rightarrow h^- \pi^0 \nu_\tau$	25.93	40.02
$\tau^- \rightarrow h^- \pi^0 \pi^0 \nu_\tau$	9.48	14.63
$\tau^- \rightarrow h^- \pi^0 \pi^0 \pi^0 \nu_\tau$	1.18	1.82
$\tau^- \rightarrow h^- h^- h^+ \nu_\tau$	9.80	15.13
$\tau^- \rightarrow h^- h^- h^+ \pi^0 \nu_\tau$	4.76	7.35
$\tau^- \rightarrow muu$	2.13	3.29

Tabel 2. Tau hadronilise lagunemise algsed ja kohandatud osakaalud protsentides.

3.2 Mudeli struktuur

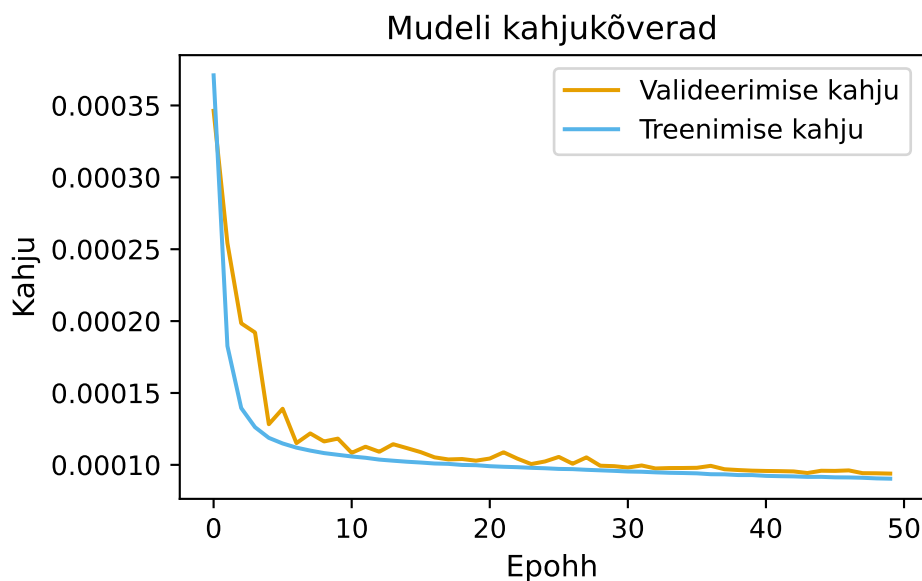
Mudel ennustas tau lagunemiskanalit ühe joa haaval, ehk mudeli sisendiks oli juga ja tema osakeste parameetrid (vt joonis 6) ja väljundiks oli lagunemiskanalile vastav arv. Mudel oli kuuekihiline pärilevivõrk, mille sisendkiht koosnes 3080 sõlmest, iga peidetud kiht 512 sõlmest ja väljundkiht 16 sõlmest. Sisend- ja peidetud kihtide sõlmede arvud valiti vastavalt arvutuskeskuse võimekusele ja parima tulemuse saavutamiseks tuleks neid optimeerida. Närvivõrgus kasutati aktiveerimisfunktsioonina mittelineaarset ReLU funktsiooni, sest see on mitmekihilisel närvivõrgul palju efektiivsem kui sigmoid funktsioon [13].

Mudeli optimeerimiseks kasutati AdamW optimeerimisalgoritmi ja dropout-meetodit. Dropout-meetod, nullis juhusliku sisendkihi sõlme tõenäosusega 0.1. AdamW kohandas õppimiskiirust vastavalt iga parameetri tähtsusele. Mõlemad meetodid vähendavad mudeli üleõppimise riski ja parandavad üldistusvõimet [14].

3.3 Mudeli optimeerimine

Mudel treeniti treeningandmestikul kuni 49 epohhi, ehk iteratsioonini. Iga epohhi jooksul minimeeriti treeningandmetel kahjufunktsiooni, muutes mudeli kaalusid. Samaaegselt jälgiti mudeli täpsust valideerimisandmestikul, et hinnata mudeli üldistamisvõimet ja vältida üleõppimist. Joonisel 8 on kujutatud mõlemad kahjukõverad.

Mudeli optimeerimisel kasutati ristentroopiakahjufunktsiooni (ingl *cross-entropy loss function*), mis sobib hästi mitmik-klassi ülesande jaoks. Ristentroopiakahju mõõdab erinevust mudeli ennustatud ja tegelike klasside vahel. Selle arvutamine algab mudeli väljundite tõenäosusjaotuse ja tegelike klasside tõenäosusjaotuse võrdlemisest. Tegelikud klassid kodeeritakse *one-hot encoding* meetodiga, kus iga klassi jaoks vastav element vektoris on väärtusega 1 ja kõik ülejäänud elemendid on väärtusega 0.



Joonis 8. Treening- ja valideerimisandmestike kahjuköverad. Need kõverad kujutavad kahjufunktsioonide väärtuste pidevat vähenemist iga epoohhi ajal, mis näitab, et mudel muutub ennustamises järjest paremaks.

3.4 Mudeli hindamine

Kuigi kahjufunktsiooni abil saab hinnata mudeli täpsust, ei anna see füüsiliselt mõistetavat informatsiooni mudeli või klasside täpsuse kohta. Mudeli üldise efektiivsuse hindamiseks kasutati tasakaalustatud täpsust (ingl *balanced accuracy*) ning F1-skoori, kuna need arvestavad ebavõrdsusega andmeklasside jaotuses [21]. Tasakaalustatud täpsus võtab arvesse nii tõeliselt positiivsete (TP) kui ka tõeliselt negatiivsete (TN) osakaalu. F1-skoor on täpsuse (ingl *precision*) ja saagise (ingl *recall*) harmooniline keskmine. Täpsus näitab, kui palju mudeli tehtud positiivseid ennustusi on tegelikult õiged. Saagis näitab, kui palju mudel suudab TP juhtumeid tuvastada. Klasside skooride arvutamiseks kasutati `scikit-learn` [21] paketi `classification_report` funktsiooni, mis arvutab peamised klassifitseerimise hinnangud (tabel 3).

$$\text{Tasakaalustatud täpsus} = \frac{1}{2} \left(\frac{TP}{TP + FN} + \frac{TN}{TN + FP} \right) \quad (3.1)$$

$$\text{F1 skoor} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (3.2)$$

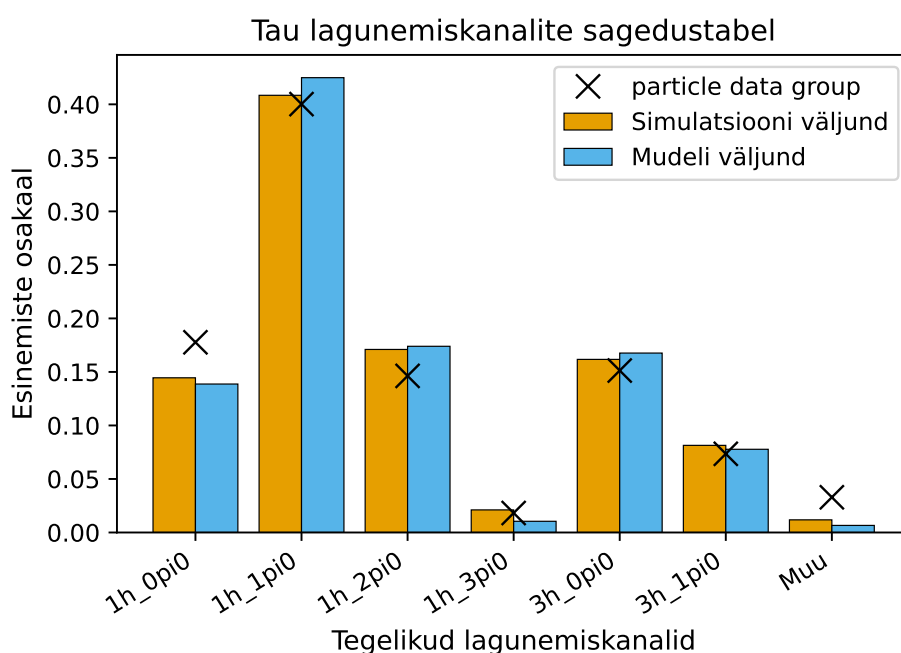
kus TP on õiged positiivsed, TN õiged negatiivsed, FP valed positiivsed, FN valed negatiivsed.

4. Tulemused ja arutelu

Peatükis hinnatakse antud tehisnärvivõrgu mudeli tulemusi ja võrreldakse neid teiste uurimistööde omadega. Lisaks arutleti väljundite füüsilise sisu üle.

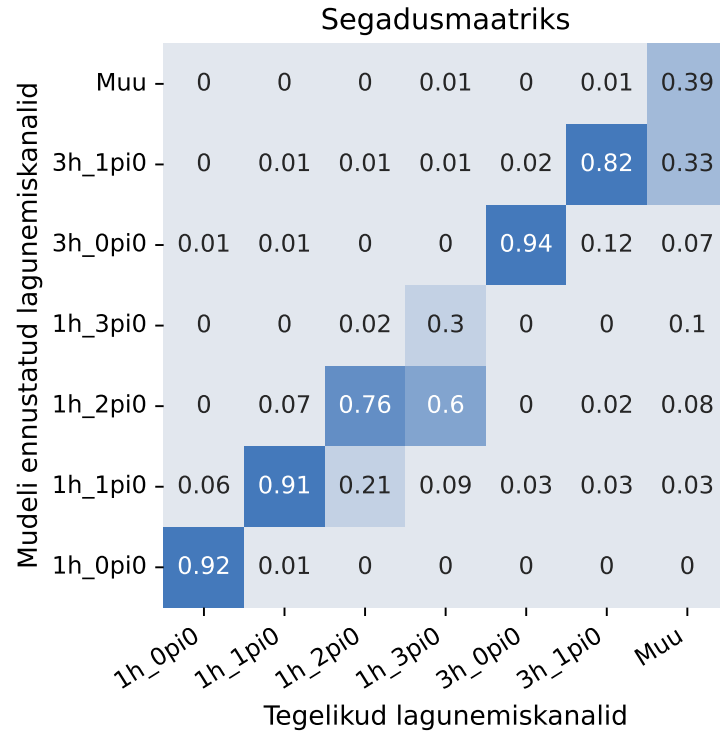
4.1 Tulemused

Joonisel 9 on kujutatud tau hadroniliste lagunemiskanalite osakaalud nii simuleeritud kui ka mudeli väljunditega. Joonise horisontaalsel teljel on simuleeritud andmetes esinenud lagunemiskanalid. Alla ühe protsendilise osakaaluga hadronilised lagunemiskanalid võeti kokku ja kategoriseeriti sildiga "muu". Vertikaalsel teljel on mudeli väljundite ja simuleeritud kanalite osakaalud kujutatud tulpadena.



Joonis 9. Tau lagunemiskanalite sagedustabel simulatsiooni ja mudeli väljunditega. Võrdluseks lisati x-iga tähistatud PDG osakaalud tabelist 2.

Uurimistöö oluline tulemus on joonisel 10, kus on kujutatud mudeli väljundite ja simuleeritud andmete vaheline segadusmaatriks. Y-teljel on mudeli ennustatud, x-teljel tegelikud lagunemiskanalid ja z-teljel on ennustuste normaliseeritud väärtused. Maatriksi kõrvaldiagonaalil on mudeli õigesti ennustatud väärtused ja ülejäänud väärtused on valesti ennustatud.



Joonis 10. Mudeli ennustuste ja tegelike lagunemiskanalite segadusmaatriks. Tasakaalustatud täpsuseks tuli 71.9% ja F1-skooriks 86.3%.

Classification_report funktsiooniga saadud tulemused on tabelis 3. Funktsioon arvutas igale kanalile eraldi peamised hinnangud nagu täpsus, saagis, F1-skoor. Lisaks arvutas see nendele hinnangutele keskmise ja kaalutud keskmise. Tugi (ingl *support*) näitab palju jugasid oli kokku.

Lagunemiskanal	Täpsus	Saagis	F1-skoor	Tugi
$\tau^- \rightarrow h^- \nu_\tau$	0.961	0.923	0.942	14913
$\tau^- \rightarrow h^- \pi^0 \nu_\tau$	0.871	0.906	0.888	42146
$\tau^- \rightarrow h^- \pi^0 \pi^0 \nu_\tau$	0.745	0.758	0.751	17646
$\tau^- \rightarrow h^- \pi^0 \pi^0 \pi^0 \nu_\tau$	0.596	0.296	0.395	2178
$\tau^- \rightarrow h^- h^- h^+ \nu_\tau$	0.909	0.942	0.925	16687
$\tau^- \rightarrow h^- h^- h^+ \pi^0 \nu_\tau$	0.855	0.817	0.835	8399
$\tau^- \rightarrow muu$	0.699	0.391	0.502	1219
Õigsus			0.863	103188
Keskmine	0.805	0.719	0.748	103188
Kaalutud keskmine	0.860	0.863	0.859	103188

Tabel 3. Klassifikatsiooni tulemused.

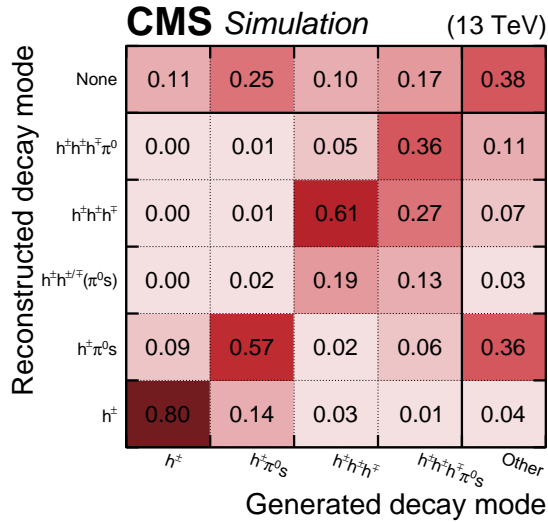
4.2 Arutelu

Jooniselt 9 on näha, et kõige rohkem esines ühe laetud osakesega lagunemisi, moodustades pea 70% hadronilistest lagunemistest. Suur osakaal tulenes $\tau^- \rightarrow h^- h^0 \nu_\tau$ kanalist, mis esines andmestikus pea pooltel juhtudel. Ülejäänud osa moodustasid kolme laetud osakesega ja muud kanalid. PDG katse osakaalud sarnanevad simulatsiooni andmetega, mis omakorda sarnanevad mudeli tulemustega. Näha on ka, kuidas kanalites, kus osaleb järjest rohkem osakesi on vähem tõenäolisemad. Sama trend esineb ka uurimistöö tulemustes, näidates mudeli usaldusväarsust ja täpsust.

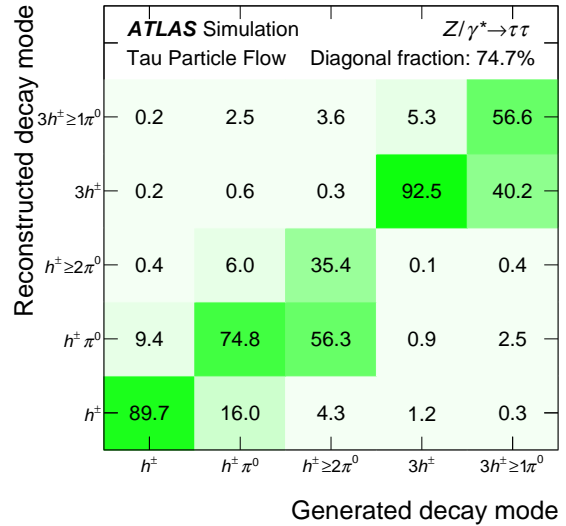
Mudeli hea efektiivsuse visuaalseks indikaatoriks on segadusmaatriksile tekkiv nähtavalt eristuv diagonaal. Joonis 10 maatriksi kõrvaldiagonaal pole perfektne, mis tuleneb teatud klasside arvulist vähesust ja/või nende valesti määramist. Antud juhul on tegu mõlema probleemiga. Parema tulemuse saamiseks oleks mõistlik võtta alla 5% osakaaluga kanalid kokku ühe märgise alla.

Mudel oli väga edukas $\tau^- \rightarrow h^- \nu_\tau$ ja $\tau^- \rightarrow h^- h^- h^+ \nu_\tau$ lagunemiste määramisel, kus kõik skoorid ületasid 0.92 piiri. Kõrge tulemuse põhjuseks tundub olevat laenguta piionite puudumine ja piisav valimi suurus. Hästi läks mudelil $\tau^- \rightarrow h^- \pi^0 \nu_\tau$ määramisel, kus skoorid püsisid 0.88 ümbruses. Võib öelda, et mudeli põhirõhk oligi selle klassi ennustamisel, kuna klassi osakaal oli valimis suurim. Kõige rohkem vigu tehti $\tau^- \rightarrow h^- \pi^0 \nu_\tau$ ja $\tau^- \rightarrow h^- \pi^0 \pi^0 \nu_\tau$ vahel, mõjutades negatiivselt viimase tulemusi. $\tau^- \rightarrow h^- \pi^0 \pi^0 \pi^0 \nu_\tau$ halbade skooride põhjuseks võib olla väike valim ja neutraalsete piionite eristamise keerulisus. Sagedusmaatriksist (vt joonis 10) paistab, et seda kanalit ennustati rohkem valesti, kui õigesti. Üldiselt mudeli vead korreleeruvad klassi neutraalsete piionite arvuga ja valimi suurusega.

Joonisel 11 on võrdluseks toodud CMS-i [22] ja ATLAS-e [23] teadustööde segadusmaatriksid. Nende tööde eesmärgid olid sarnased käesoleva uurimistöö omaga, kuid nende lähenemised erinesid oluliselt. CMS kasutas tau hadroniliste lagunemiste klassifitseerimiseks süvaõpet, samas kui ATLAS piirdus ainult algoritmidega. Andmekogumid genereeriti PYTHIA8 programiga pp põrgetest ja joa kandidaadid rekonstrueeriti $Z \rightarrow \tau\tau$ sündmustest. pp põrge ei ole nii puhas kui e^-e^+ põrge, seetõttu oli osakesi ka keerulisem rekonstrueerida. Lisaks piirduti tau lagunemiskanalite klassifitseerimisel viie peamise kanaliga jättes välja üle 2 neutraalse piioniga ja muud haruldased kanalid. Nende töödega võrdlemine on oluline, sest see aitab mõista, kuidas erinevad meetodid ja andmestikud mõjutavad tulemuste täpsust ja mudelite üldist efektiivsust.



(a) CMS segadusmaatriks. Tasakaalustatud täpsus oli 54.4% [22].



(b) ATLAS segadusmaatriks. Tasakaalustatud täpsus oli 74.7%.

Joonis 11. CMS ja ATLAS tulemused pp põrgete ja $Z \rightarrow \tau\tau$ sündmusega [23]. Y-teljel on rekonstrueeritud lagunemiskanalid ja x-teljel tegelikud lagunemiskanalid.

Võrreldes käesoleva töö tulemusi jooniselt 10 joonise 11 omadega on näha palju sarnasusi. Kanalid, mida kõik tööd ennustasid suure täpsusega olid neutraalsete piioniteta, ehk ainult ühe ja kolme hadroniga. Neutraalsete piionite arvu suurenemisel langesid kanalite täpsused. CMS valis neli peamist kanalit ja muud klassifitseeriti "muu" alla, mis võis oluliselt langetada tasakaalustatud keskmist. ATLAS jättis ära rohkem kui kahe neutraalse piioniga ja "muud" kanalid, mis võis oluliselt tõsta tasakaalustatud täpsust.

Käesolevat tööd analüüsid, võiks mudeli täpsuse tõstmiseks kaaluda alla 5% osakaaluga kanalite üheks märgendamist, või hoopis nende ära jätmist. Kindlasti peaks ka optimeerima pärilevivõrgu parameetreid, nagu sõlmede arvu kihis.

5. Kokkuvõte

Uurimistöö eesmärk oli juhendatud masinõppe abil klassifitseerida tau hadronili lagunemiskanaaleid simuleeritud kiirendi eksperimendis ja mõista tulemuste füüsikalist sisu. Tau hadroniliste lagunemiskanalite klassifitseerimine on oluline, et saada puhas valim, mis võimaldaks edasi uurida Standardmudeli välist füüsikat.

Tau lagunemised genereeriti PYTHIA8 programmiga, simuleerides e^-e^+ põrkeid ja sellele järgnevaid sündmusi $Z, Z \rightarrow \tau\tau$ ja $ZH, H \rightarrow \tau\tau$. Genereeritud osakesed läbisid detektori simulatsiooni, mille väljundiks olid rekonstrueeritud osakesed ja joad, mis moodustasid treening-, test- ja valideerimisandmestiku.

Klassifitseerimiseks kasutati kuuekihilist pärilevivõrgu mudelit, millest neli olid peidetud kihid. Mudeli sisendkihis oli 3080 sõlme, igas peidetud kihis 512 sõlme ja väljundkihis 16 sõlme. Mudeli sisenditeks olid rekonstrueeritud joa ja joa osakeste muutujad, nagu neliimpulss, laeng ja osakeste tüüp. Mudelit trenniti treeningandmestikul, samal ajal hinnati selle kvaliteeti valideerimisandmestikul ja tulemusi hinnati testandmestikul.

Pärilevivõrk suutis kõrge täpsusega ennustada $\tau^- \rightarrow h^- \nu_\tau$, $\tau^- \rightarrow h^- \pi^0 \nu_\tau$, $\tau^- \rightarrow h^- h^- h^+ \nu_\tau$ ja $\tau^- \rightarrow h^- h^- h^+ \pi^0 \nu_\tau$ lagunemisi, kusjuures tulemused sarnanesid CMS, ATLAS, Particle Data Group omadega. Siiski esines raskusi haruldaste ja mitme neutraalse hadroniga lagunemiskanalite klassifitseerimisel. Probleem võib tuleneda juba rekonstrueerimise tasandil, kuna neutraalsed hadronid asuvad joas väga lähedal üksteisele ja nende eristamine detektoritega on keeruline.

Uurimistöö tulemuste põhjal võib järeldada, et mudel oli efektiivne, sest oluliste klasside täpsused olid ennustamisel suuremad kui 80%. Mudeli täpsuse tõstmiseks võiks kaaluda alla 5% osakaaluga kanalite üheks märgendamist või nende ära jätmist. Lisaks tuleks optimeerida pärilevivõrgu parameetreid, näiteks sõlmede arvu kihtides.

Annotatsioon

Uurimistöö eesmärgiks oli juhendatud masinõppe meetodite abil klassifitseerida tau hadronilisi lagunemiskanaleid simuleeritud kiirendi eksperimendis ja mõista tulemuste füüsikalist sisu. Tau hadroniliste lagunemiskanalite klassifitseerimine on oluline puhta valimi saamiseks, mis võimaldaks põhjalikult uurida Standardmudeli välist füüsikat. Uurimistöös kasutati süvaõppe meetodina mitmekihilist pärilevivõrku. Mudeli treening-, valideerimis- ja testandmestik genereeriti PYTHIA8 programmiga e^-e^+ põrgetest. Närvivõrku treeniti rekonstrueeritud joa ja joa osakeste muutujatel ennustama 16 võimaliku klassi vahel. Mudel suutis võrdlemisi kõrge täpsusega ennustada $\tau^- \rightarrow h^- \nu_\tau$, $\tau^- \rightarrow h^- \pi^0 \nu_\tau$, $\tau^- \rightarrow h^- h^- h^+ \nu_\tau$, $\tau^- \rightarrow h^- h^- h^+ \pi^0 \nu_\tau$ lagunemisi ja sagedused sarnanesid Particle Data Group'i omadega.

Uurimistöö tulemuste põhjal võib järeldada, et masinõppe algoritmil oli raskusi haruldaste ja mitme neutraalse hadroniga lagunemiskanalite klassifitseerimisel. Probleemid võivad esineda juba rekonstrueerimise tasandil, sest neutraalsed hadronid on joas väga lähedal üksteisele ja nende eristamine detektoritega on samuti keeruline. Siiski oluliste klasside täpsused olid ennustamisel suuremad kui 80%.

Abstract

The aim of this study was to classify tau hadronic decay channels in a simulated accelerator experiment using supervised machine learning methods and to understand the physical content of the results. The classification of tau hadronic decay channels is important for obtaining a clean sample, which would allow for a thorough investigation of physics beyond the Standard Model. The study used a multilayer feedforward network as a deep learning method. The model's training, validation, and test datasets were generated from e^-e^+ collisions using the PYTHIA8 program. The neural network was trained on reconstructed jet and jet particle variables to predict between 16 possible classes. The model was able to predict $\tau^- \rightarrow h^- \nu_\tau$, $\tau^- \rightarrow h^- \pi^0 \nu_\tau$, $\tau^- \rightarrow h^- h^- h^+ \nu_\tau$, $\tau^- \rightarrow h^- h^- h^+ \pi^0 \nu_\tau$ decays with relatively high accuracy, and the frequencies resembled those of the Particle Data Group.

Based on the results of the study, it can be concluded that the deep learning algorithm was successful in classifying rare decay channels with multiple neutral hadrons. Problems may occur already at the reconstruction level, as neutral hadrons are very close to each other in the jet and their differentiation with detectors is also complicated. However, the accuracies of important classes were greater than 80%.

Tänuavaldused

Töö autor soovib siiralt tänada oma *top-tier* juhendajat, Josep Patat, kelle juhendamine ja toetus on olnud hindamatud. Samuti avaldab autor sügavat tänu Keemilise ja Bioloogilise Füüsika Instituudile sujuva koostöö ja toetuse eest. Erilised tänud kuuluvad ka Laurits Tanile ja Norman Seebale nende väärtuslike nõuannete ja abivalmiduse eest.

Kasutatud kirjandus

- [1] Serguei Chatrchyan *et al.* „Observation of a New Boson at a Mass of 125 GeV with the CMS Experiment at the LHC“. *Phys. Lett. B* 716 (2012), lk. 30–61. DOI: 10.1016/j.physletb.2012.08.021. arXiv: 1207.7235 [hep-ex].
- [2] Albert M Sirunyan *et al.* „Observation of the Higgs boson decay to a pair of τ leptons with the CMS detector“. *Phys. Lett. B* 779 (2018), lk. 283–316. DOI: 10.1016/j.physletb.2018.02.004. arXiv: 1708.00373 [hep-ex].
- [3] Torben Lange *et al.* „Tau lepton identification and reconstruction: A new frontier for jet-tagging ML algorithms“. *Comput. Phys. Commun.* 298 (2024), lk. 109095. DOI: 10.1016/j.cpc.2024.109095. arXiv: 2307.07747 [hep-ex].
- [4] Felix Friedrich. „Tau Lepton Reconstruction and Identification at ATLAS“. *EPJ Web of Conferences* 28 (2012), lk. 12007. ISSN: 2100-014X. DOI: 10.1051/epjconf/20122812007. URL: <http://dx.doi.org/10.1051/epjconf/20122812007>.
- [5] K. A. Olive *et al.* „Review of Particle Physics“. *Chin. Phys. C* 38 (2014), lk. 090001. DOI: 10.1088/1674-1137/38/9/090001.
- [6] Mark Thomson. *Modern Particle Physics*. Cambridge University Press, 2013.
- [7] Wikimedia Commons. *File:Standard Model of Elementary Particles modified version.svg* — *Wikimedia Commons, the free media repository*. [Online; accessed 23-March-2024]. 2020. URL: https://commons.wikimedia.org/w/index.php?title=File:Standard_Model_of_Elementary_Particles_modified_version.svg&oldid=454788240.
- [8] Ze Chen. „Tau reconstruction in CMS exploiting machine learning techniques“. Masterarbeit. Hamburg: Universität Hamburg, 2022, lk. 55. DOI: 10.3204/PUBDB-2022-05177. URL: <https://bib-pubdb1.desy.de/record/483206>.
- [9] Gavin P. Salam. „Towards Jetography“. *Eur. Phys. J. C* 67 (2010), lk. 637–686. DOI: 10.1140/epjc/s10052-010-1314-6. arXiv: 0906.1833 [hep-ph].
- [10] Izaak Neutelings. *Hadronic tau decay*. Accessed: 2024-03-21. 2017. URL: https://tikz.net/tau_decay/.
- [11] Pankaj Mehta *et al.* „A high-bias, low-variance introduction to Machine Learning for physicists“. *Physics Reports* 810 (mai 2019), lk. 1–124. ISSN: 0370-1573. DOI: 10.1016/j.physrep.2019.03.001. URL: <http://dx.doi.org/10.1016/j.physrep.2019.03.001>.

- [12] Giuseppe Carleo *et al.* „Machine learning and the physical sciences“. *Reviews of Modern Physics* 91.4 (detsember 2019). ISSN: 1539-0756. DOI: 10.1103/revmodphys.91.045002. URL: <http://dx.doi.org/10.1103/RevModPhys.91.045002>.
- [13] Michael A. Nielsen. *Neural Networks and Deep Learning*. Determination Press, 2015.
- [14] Ian Goodfellow, Yoshua Bengio ja Aaron Courville. *Deep Learning*. <http://www.deeplearningbook.org>. MIT Press, 2016.
- [15] Jürgen Schmidhuber. „Deep learning in neural networks: An overview“. *Neural Networks* 61 (jaanuar 2015), lk. 85–117. ISSN: 0893-6080. DOI: 10.1016/j.neunet.2014.09.003. URL: <http://dx.doi.org/10.1016/j.neunet.2014.09.003>.
- [16] Ilya Loshchilov ja Frank Hutter. *Decoupled Weight Decay Regularization*. 2019. arXiv: 1711.05101 [cs.LG].
- [17] Diederik P. Kingma ja Jimmy Ba. *Adam: A Method for Stochastic Optimization*. 2017. arXiv: 1412.6980 [cs.LG].
- [18] Nitish Srivastava *et al.* „Dropout: A Simple Way to Prevent Neural Networks from Overfitting“. *Journal of Machine Learning Research* 15.56 (2014), lk. 1929–1958. URL: <http://jmlr.org/papers/v15/srivastava14a.html>.
- [19] Christian Bierlich *et al.* *A comprehensive guide to the physics and usage of PYTHIA 8.3*. 2022. arXiv: 2203.11601 [hep-ph].
- [20] Izaak Neutelings. *CMS coordinate system*. Accessed: 2024-05-20. 2017. URL: https://tikz.net/axis3d_cms/.
- [21] F. Pedregosa *et al.* „Scikit-learn: Machine Learning in Python“. *Journal of Machine Learning Research* 12 (2011), lk. 2825–2830.
- [22] Armen Tumasyan *et al.* „Identification of hadronic tau lepton decays using a deep neural network“. *JINST* 17 (2022), P07023. DOI: 10.1088/1748-0221/17/07/P07023. arXiv: 2201.08458 [hep-ex].
- [23] Georges Aad *et al.* „Reconstruction of hadronic decay products of tau leptons with the ATLAS experiment“. *Eur. Phys. J. C* 76.5 (2016), lk. 295. DOI: 10.1140/epjc/s10052-016-4110-0. arXiv: 1512.05955 [hep-ex].

Lisad

Lisa rektori 07.04.2020 käskkirjale nr 1-8/17

Lihtlitsents lõputöö reprodutseerimiseks ja lõputöö üldsusele kättesaadavaks tegemiseks¹

Mina, Hardi Vanaveski

1. Annan Tallinna Tehnikaülikoolile tasuta loa (lihtlitsentsi) enda loodud teose
MASINÕPPE RAKENDAMINE TAU OSAKESTE HADRONILISTE LAGUNEMISKANALITE
KLASSIFITSEERIMISEL SIMULEERITUD KIIRENDIEKSPERIMENDIS,
mille juhendaja on Joosep Pata,
 - (a) reprodutseerimiseks lõputöö säilitamise ja elektroonse avaldamise eesmärgil, sh Tallinna Tehnikaülikooli raamatukogu digikogusse lisamise eesmärgil kuni autoriõiguse kehtivuse tähtaja lõppemiseni;
 - (b) üldsusele kättesaadavaks tegemiseks Tallinna Tehnikaülikooli veebikeskkonna kaudu, sealhulgas Tallinna Tehnikaülikooli raamatukogu digikogu kaudu kuni autoriõiguse kehtivuse tähtaja lõppemiseni.
2. Olen teadlik, et käesoleva lihtlitsentsi punktis 1 nimetatud õigused jäävad alles ka autorile.
3. Kinnitan, et lihtlitsentsi andmisega ei rikuta teiste isikute intellektuaalomandi ega isikuandmete kaitse seadusest ning muudest õigusaktidest tulenevaid õigusi.

_____ (kuupäev)

¹Lihtlitsents ei kehti juurdepääsupiirangu kehtivuse ajal vastavalt üliõpilase taotlusele lõputööle juurdepääsupiirangu kehtestamiseks, mis on allkirjastatud teaduskonna dekaani poolt, välja arvatud ülikooli õigus lõputööd reprodutseerida üksnes säilitamise eesmärgil. Kui lõputöö on loonud kaks või enam isikut oma ühise loomingulise tegevusega ning lõputöö kaas- või ühisautor(id) ei ole andnud lõputööd kaitsvale üliõpilasele kindlaksmääratud tähtajaks nõusolekut lõputöö reprodutseerimiseks ja avalikustamiseks vastavalt lihtlitsentsi punktidele 1.a. ja 1.b, siis lihtlitsents nimetatud tähtaja jooksul ei kehti.