

TARTU ÜLIKOOL
Arvutiteaduse instituut
Andmeteaduse õppekava

Reemet Ammer
Tööstusettevõtetele suunatud
praktiline tehisintellekti lühikursus
Magistritöö (15 EAP)

Juhendajad: Prof. Jaak Vilo
Elena Sügis, PhD

Tartu 2022

Tööstusettevõtetele suunatud praktiline tehisintellekti lühikursus

Lühikokkuvõte:

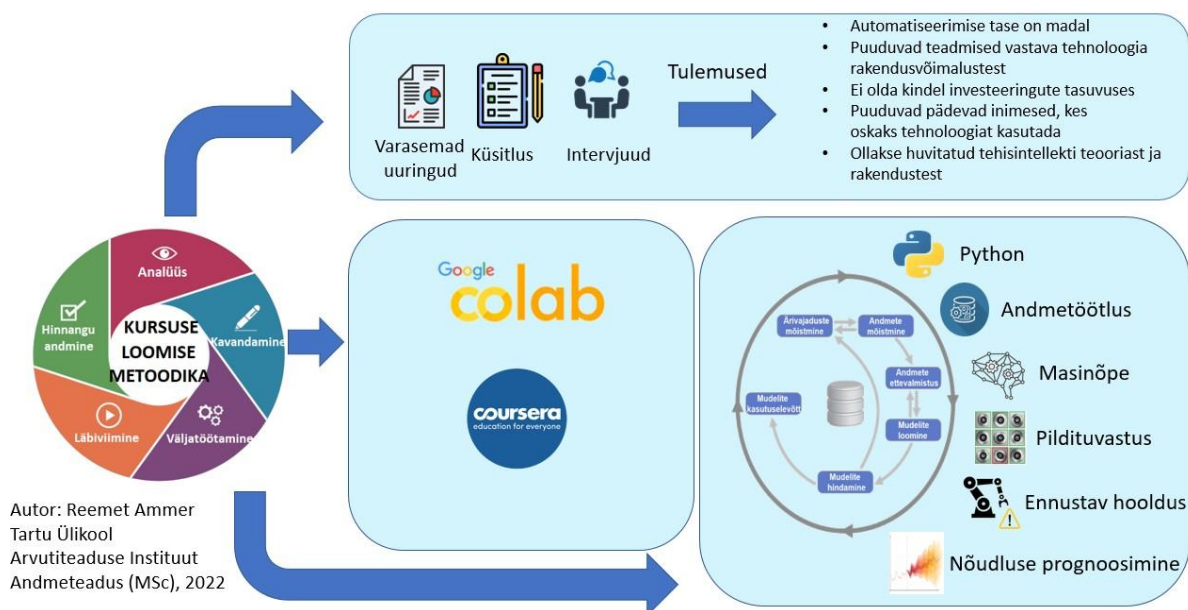
Käesoleva magistritöö eesmärgiks on koostöös Tehisintellekti- ja robotikakeskusega AIRE välja selgitada Eesti tööstusettevõtete võimekused ning vajadused tööstusprotsesside automatiseerimisel ning nende valmisoleku uute tehisintellekti põhiste tehnoloogiate õppimiseks ning juurutamiseks oma ettevõtte tööstusprotsessides. Pärast vajaduste välja selgitamist luuakse nende baasilt Coursera platvormil uus kursus tööstusettevõtetele. Töös esitatakse muuhulgas lühitutvustus erinevatest Tööstus 4.0 tehnoloogiatest ning nende rakendusvõimalustest.

CERCS teaduseriala: P176 Tehisintellekt

Märksõnad: tööstus, tehisintellekt, masinõpe, õppematerjal

Graafiline abstrakt:

Tööstusettevõtetele suunatud praktiline tehisintellekti lühikursus



Practical Artificial Intelligence Course For Industrial Enterprises

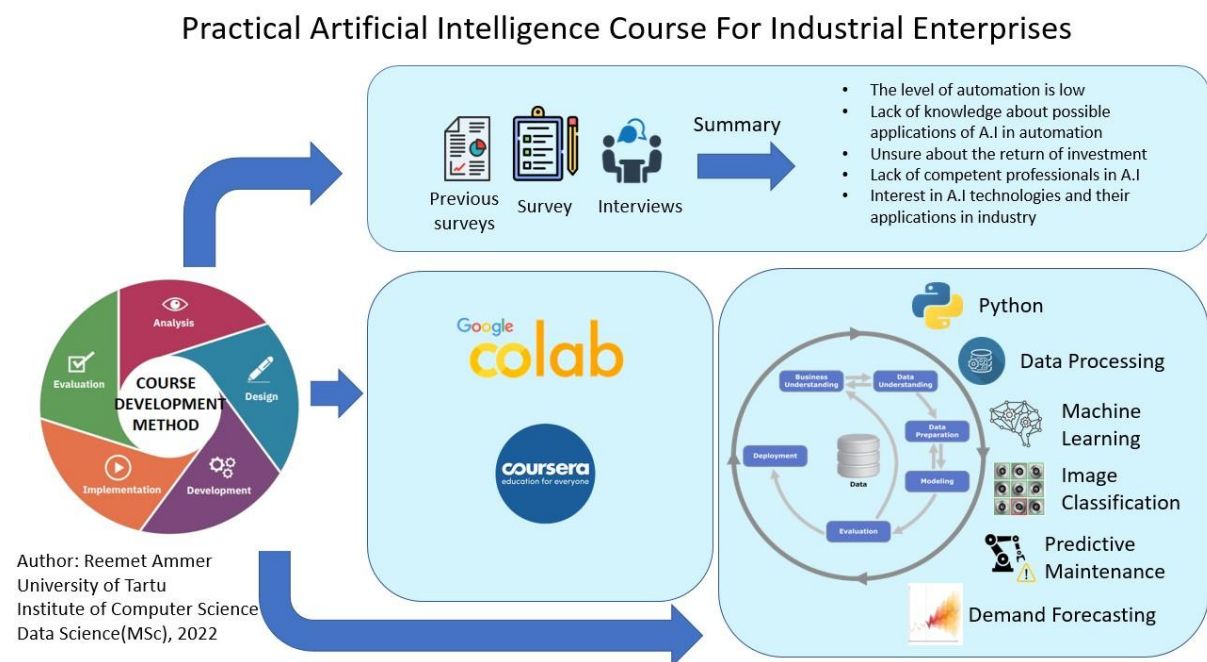
Abstract:

The goal of this thesis is to find out the needs and obstacles of Estonian industrial enterprises in automating business processes, and the readiness to learn new artificial intelligence technologies, and deploy them on their enterprises' business processes. After finding the needs and obstacles, the goal is to create a new practical course on a Coursera platform that takes those needs into account. A short introduction of different Industry 4.0 technologies and their applications is also given.

Keywords: manufacturing industry, artificial intelligence, machine learning, course

CERCS: P176 Artificial intelligence

Graphical abstract:



| | |
|---------------------------------------------------------------------------------|-----------|
| Sissejuhatus | 5 |
| 1. Mõisted ja terminid | 6 |
| 2. Taustainfo | 8 |
| 2.1 Tööstus 4.0 | 8 |
| 2.1.1 Asjade Internet | 9 |
| 2.1.2 Suurandmed | 9 |
| 2.1.3 Pilvetechnoloogia | 9 |
| 2.2 Tehisintellekt ja masinõpe | 10 |
| 2.2.1 Tehisintellekt | 10 |
| 2.2.2 Masinõpe | 10 |
| 2.2.3 Regressioon | 12 |
| 2.2.4 Klassifitseerimine | 12 |
| 2.2.5 Tehisnärvivõrgud | 13 |
| 2.2.6 Konvolutsioonilised närvivõrgud | 14 |
| 2.3 Näiteid tehisintellekti võimalikest rakendustest tööstuses | 15 |
| 2.3.1 Pildi- ja objektituvastus | 15 |
| Tootmisdetailide klassifitseerimine | 15 |
| Tootmisjääkide sorteerimine | 16 |
| Teksti ja numbrite tuvastamine | 16 |
| 2.3.2 Anomaaliate tuvastamine | 17 |
| 2.3.3 Ennustav hooldus | 18 |
| 2.3.4 Nõudluse prognoosimine | 19 |
| 2.4 Kursuse väljatöötamise meetodid | 20 |
| 2.4.1 ADDIE mudel | 20 |
| 2.4.2 LORI hindamismudel | 22 |
| 2.4.3 CRISP-DM | 23 |
| 2.5 AIRE - AI & Robotics Estonia | 24 |
| 3. Kursuse analüüs | 25 |
| 3.1 Kursuse loomise vajadus ning üldised eesmärgid | 25 |
| 3.2 Sihtrühma vajadused | 25 |
| 3.2.1 Eesti tööstussektori ülevaade | 25 |
| 3.2.2 Swedbanki 2021. aasta tööstusettevõtete uuring | 26 |
| 3.2.3 Tööstus 4.0 tehnoloogiate rakendamine Eesti tööstusettevõtete tarneahelas | 27 |
| 3.2.4 Küsitlusuuringu tulemused | 28 |
| 3.2.5 Vajaduste analüüsi tulemused intervjuude alusel | 31 |
| 3.2.6 Uuringute, küsitluse ja intervjuude kokkuvõte | 32 |
| 4. Kursuse kavandamine | 33 |
| 4.1 Kursuse sihtrühm | 33 |
| 4.2 Kursuse maht | 33 |
| 4.3 Õpiväljundid | 33 |

| | |
|-----------------------------------------------------------------------------|-----------|
| 4.4 Sisu kaardistamine | 34 |
| 4.5 Iseseisvad tööd ja hindamine | 34 |
| 4.6 Õppevahendid | 34 |
| 4.6.1 Google Colab | 34 |
| 4.6.2 Coursera lühitutvustus | 34 |
| 5. Kursuse väljatöötamine | 36 |
| 5.0 Google Colab lühitutvustus | 36 |
| 5.1 Pythoni lühitutvustus | 36 |
| 5.2 Andmete esmane vaatlus ja eeltöötlus | 37 |
| 5.3 Juhendatud masinõppe mudelite arendustsükkel | 38 |
| 5.4 Tootmisdefektide tuvastamine | 39 |
| 5.5 Ennustav hooldus: hüdraulilise pressi katki minemise prognoosimine | 40 |
| 5.6 Masinõppe aegridade mudeldamisel: energia nõudluse ja hinna ennustamine | 41 |
| 6. Kokkuvõte ja tuleviku töö | 42 |
| 7. Viidatud kirjandus | 43 |
| Lisad | 46 |
| I. Küsitlus | 46 |
| II. Githubi repositoorium | 49 |
| III. Litsents | 50 |

Sissejuhatus

Alates 18. sajandi keskpaigast hakkas tööstus kiiresti arenema. Tootmises hakati kasutama aurumasinaid, hiljem elektrimasinaid ning siis arvutijuhitavaid masinaid. Eelnimetatud etappe tööstuse arengus nimetatakse vastavalt esimeseks, teiseks ja kolmandaks tööstusrevolutsiooniks. Tänapäeval on tööstusprotsesside automatiseerituse tase veelgi suurenenud. Neljas tööstusrevolutsioon ehk Tööstus 4.0 on seotud asjade interneti-, küberfüüsiliste süsteemide-, suurte andmete- ja tehisintellektiga, mis muudavad kogu tootmistsüklit eesmärgiga vähendada rikkeid, jäätmeid ja tootmiskulusid, ning muuta tootmist tõhusamaks ja ohutumaks.

Erinevate tööstusharude kiire areng ning Tööstus 4.0 etapile üleminek eeldab uute kaasaegsete oskuste omandamist ja tehnoloogiate kasutuselevõttu, et tagada ettevõtetele konkurentsivõimet ja luua lisandväärtust. Üheks olulisemaks Tööstus 4.0 tehnoloogiaks on tehisintellekt. Tehisintellekti abil on võimalik automatiseerida paljusid keerulisemaid tööstusprotsesse nagu näiteks isejuhtivate robotite pildituvastust, tootmisanomaaliatuvastamist, sensorandmete põhjal automaatsete otsuste tegemist jne. Takistuseks tehisintellektil põhinevate tehnoloogiate kasutuselevõtul võivad olla nii kesised teadmised selle tehnoloogia rakendusvõimalustest kui ka oskused [1] neid tehnoloogiaid tööstusprotsessides rakendada. Tartu Ülikoolis on tehisintellekti [2,3,4] ja robotika teemalisi [5] kursusi õpetatud juba pikka aega, kuid tööstusettevõtetele suunatud kursuste arv on piiratud.

Käesoleva magistritöö eesmärgiks on uurida eesti tööstusettevõtete hetkeseisu automatiseerivate ja tehisintellekti hõlmavate tehnoloogiate rakendamise pädevustest ja vajadustest. Uuring viiakse läbi koostöös Tehisintellekti- ja robotikakeskusega AIRE (AI & Robotics Estonia) [6]. Uuringust saadud teadmiste põhjal loob magistritöö autor uue praktilise tehisintellekti teemalise kursuse.

Töö esimeses osas tutvume vajaminevate terminite ja mõistetega. Teises osas anname lühikese ülevaate kursuse õppematerjalide väljatöötamise metoodikast ning Tööstus 4.0 tehnoloogiatest nagu asjade internet, suurandmed ja pilvetehnoloogia. Kuna magistritöö temaatika põhineb tehisintellekti rakendustel tööstuses, siis anname lisaks põgusa ülevaate erinevatest masinõppe alamteemadest ning masinõppe rakendusvõimalustest tööstuses. Töö kolmandas osas anname ülevaate tööstusettevõtete pädevustest ning vajadustest automatiseerivate ning tehisintellekti tehnoloogiate kasutamisel. Ülevaate anname varasemate uuringute, intervjuude ning küsitluse põhjal, millele tööstusettevõtted vastasid. Töö neljandas osas anname ülevaate loodava kursuse sisust ning väljunditest. Loodav kursus on praktilise iseloomuga ning sisaldab teemasid nagu näiteks andmete integreerimine, andmete eeltöötlus ning masinõppepõhiste mudelite loomine tootmisdetailide ja defektide tuvastamiseks, ennustavaks hoolduseks ja nõudluse prognoosimiseks jne. Töö viimases osas anname lühikese ülevaate loodud praktiliste moodulite sisust ja nendes käsitletud ülesannetest.

1. Mõisted ja terminid

Tööstus - tootmise ja töötlemisega seotud ettevõtted, nt metallitööstus ja puidutööstus.

Tööstus 4.0 - esimese, teise ja kolmanda tööstusrevolutsiooni järel neljas tööstusrevolutsioon, mida iseloomustab kõiksuguste seadmete ja masinate omavaheline suhtlemine võrguühenduse kaudu, autonoomsed robotid, seadmetelt mitmesuguste andmete kogumine, analüüsimine ning prognoosivate mudelite loomine, tehisintellekt jne.

Tehisintellekt - masin, arvuti või arvutiprogramm, mis suudab jäljendada ja lahendada ülesandeid, mida harilikult on seostatud inimtegevusega, nagu nt visuaalne tajus, kõnetuvastus, keskkonnast saadud tagasiside põhjal õppimine, uutes olukordades kohanemine jne.

Masinõpe - tehisintellekti alamvaldkond, kus mudelite loomiseks kasutatakse suurel hulgal andmeid. Masinõppe mudelile loomiseks antakse algoritmidele ette suure hulga näiteid, kuidas mingit spetsiifilist probleemi on lahendatud, ning seejärel õpib algoritm ära talle antud näidetest võimalikud seosed, mis antud probleemi ja tema lahendamist kirjeldavad.

Juhendatud õpe - masinõppe alamvaldkond, kus mudelite loomiseks kasutatakse märgendatud andmeid. Märgendatud andmete puhul on valitud tunnus, mille väärtused on varasemast teada. Mudel õpib seoseid märgendatud andmetest ning tulevikus saab neid väärtusi automaatselt ennustada ja määrata uute märgendamata andmete jaoks.

Tunnus - tunnus on masinõppes andmeobjektide omadus, mille väärtused kirjeldavad nende andmeobjektide olekut (nt mõõtetulemus) mingis aspektis. Tunnuse väärtuse võivad olla nii arvulised (nt pikkus ja vanus) kui ka mittearvulised ehk kategoorilised (nt silmavärv ja sugu).

Tehisnärvivõrk - masinõppe kitsam tehnoloogia, kus mudelite struktuur on osaliselt inspireeritud inimese ajurakkude võrgustikest. Tehisnärvivõrgu põhiline arvutusüksus on tehisneuron, mille töö- ja ülesehituse printsiibid jäljendavad bioloogilist neuronit. Tehisnärvivõrgud sobivad hästi pildi- ja kõnetuvastuseks, kõnesünteesiks, masintõlkeks jne.

ADDIE mudel - õppekursuse disainimise, loomise ja läbiviimise raamistik, tuletatud lühenditena sõnadest *Analysis, Design, Development, Implementation, and Evaluation*. Raamistik koosneb viiest etapist: analüüs, kavandamine, väljatöötamine, läbiviimine, hinnangu andmine.

CRISP-DM - valdkondadeülene andmekaeve standardprotsess on ühtne metoodika andmekaeve, statistilise ning masinõppe-põhise andmeanalüüsi rakendamiseks ükskõik millises valdkonnas, tuletatud lühenditena sõnadest *Cross-Industry Standard Process for*

Data Mining. Andmete analüüsi ülesanne jaotatakse kuueks etapiks: ärivajaduste mõistmine, andmete mõistmine, andmete eeltöötlus, mudelite loomine, tulemuste hindamine, mudelite juurutamine.

Õppeplatvorm - e-õppe keskkond, mis pakub õpilasele ühes kohas kõike vajalikku: videoloenguid, õppematerjale, teadmiste kontrolli, võimalusi kohtuda ja vestelda teiste õpilastega ning palju muud.

Suurandmed - andmed, mille hulk on sedavõrd mahukas, et nende hoiustamine ja töötlemine ei mahu enam ära ühele arvutile. Suurandmete töötlemisel läheb enamjaolt vaja hajusarvutust, kus andmed on jaotatud üle võrgu mitme arvuti vahel, mis oma arvutustööd koordineerivad.

EAP - eriala ainepunkt, mis sisaldab endas 26 akadeemilist tundi tööd.

2. Taustainfo

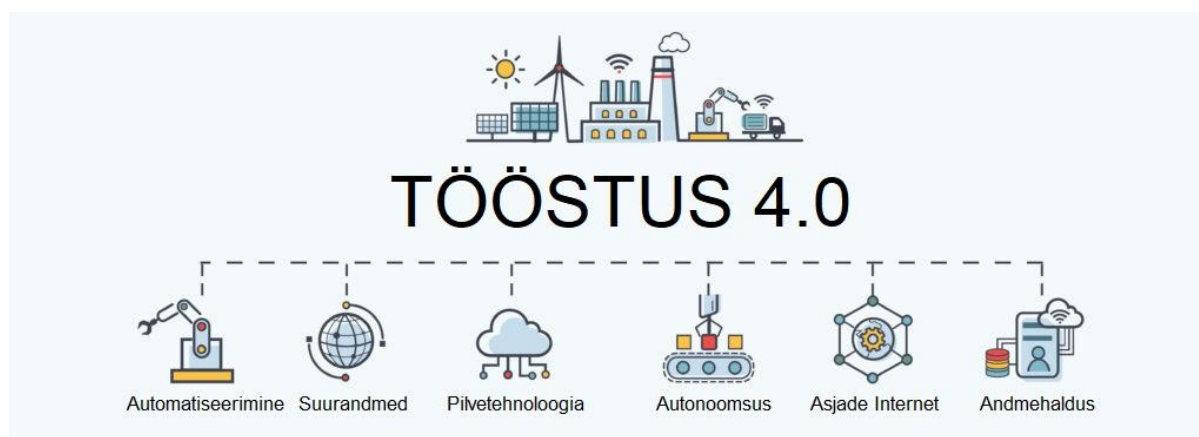
Selles peatükis anname ülevaate valdkonnaspetsiifilistest taustteadmistest, mis hõlbustab magistritöö edasiste peatükkide sisu mõistmist. Samuti tutvume lõputöös kasutatud kursuse väljatöötamise metoodikatega.

2.1 Tööstus 4.0

18. sajandi lõpus hakkas Euroopas, Suurbritannias ning USA-s toimuma suur muutus tootmisprotsessides, kus käsitsi toodete valmistamine hakkas asenduma masinatega, hakati rohkem töötlemata metalli, hakati kasutama aurumasinaid, transpordis hakati kasutama sise põlemismootoreid jne. Kõik need muutused parandasid oluliselt inimeste elukvaliteeti. Seda tööstuse arengu ajajärku on hakatud nimetama esimeseks tööstusrevolutsiooniks.

19. sajandi lõpus arenesid tootmistehnikad veelgi, ning lisaks paljudele uutele arengutele sai üheks olulisemaks tööstuse iseloomujooneks elektriliste seadmete ja masinate kasutus. Seda arengut tööstuses nimetatakse teiseks tööstusrevolutsiooniks. Kolmas tööstusrevolutsioon on seotud arvutite ja digitaliseerimisega. Arvutid võeti laialdasemalt kasutusele alates 20. sajandi keskpaigast. Sellel ajal hakati kasutama arvutijuhitavaid tootmis- ja töötlusmasinaid (CNC - *computer numerical control*).

Neljandat tööstusrevolutsiooni iseloomustavad autonoomsete masinate võrgustikud, nende omavaheline suhtlus, nende poolt tekitatud ja analüüsitud suurandmed (näiteks mitmesugustest sensoritest), tehisintellekt ja masinõppel põhinevad autonoomsed süsteemid jne.



Joonis 1. Peamised komponendid, mis kirjeldavad Tööstust 4.0 [7].

2.1.1 Asjade Internet

Asjade internet (ingl *Internet of Things - IoT*) [8] hõlmab endas kõiksuguste seadmete ja sensorite omavahelist ühendust ja suhtlust üle kohaliku võrgu või interneti. IoT sihib manussüsteemide (ingl *embedded system*) ja mikrokontrollerite integreerimist mitmesugustesse seadmetesse. Sellised seadmed genereerivad oma töö käigus erinevaid andmeid ning vahetavad teineteisega edasiste otsuste tegemiseks vajalikku informatsiooni autonoomselt. Eriti oluliseks võib masinate omavaheline reaalsajas infovahetus osutada koosteliinides, kus mingi toote valmistamiseks ja kokkupanemiseks läheb vaja mitme roboti või masina koostööd ja koordineerimist. Asjade interneti rakendamise tagajärjel on võimalik luua nii targa kodu, targa linna kui ka targa tehase ja tootmise kontseptsioonid.

2.1.2 Suurandmed

Suurandmete tehnoloogiad [9] hõlmavad endas suures mahus ja perioodiliselt või reaalsajas edastavate ning erineva iseloomuga andmete kogumist, hoiustamist ja töötlemist. Suurandmed ei mahu üldiselt ühele arvutile ära ning need andmed hajutatakse üle võrgu mitme arvuti vahel. Suurandmete töötlemiseks kasutatakse tihti algoritme, mis toetavad paralleelarvutusi. Suurandmed võivad olla struktureeritud, kuid enamjaolt on nad struktureerimata toorandmed nagu nt arvud, tekst, pildid, heli jne. Tööstuse kontekstis tekivad suurandmed eelkõige mitmesugustest sensoritest, kaamerateist, tootmise erinevatest etappidest ning nende läbimisest, logistikast jne. Taolised andmed tekivad reaalsajas. Selliste andmete kogumiseks ja töötlemiseks on vaja suure mahuga ning hajutatud andmebaase ning suure läbilaskevõimega tarkvaratehnoloogiaid.

2.1.3 Pilvetehnoloogia

Pilvetehnoloogia võimaldab hallata ja siduda arvutusressursse ning arvutusvõimsust vastavalt vajadusele kiiresti skaleerida. Pilvetehnoloogiat võimaldavaks alustehnoloogiaks on füüsiliste arvutite virtualiseerimine ehk riistvarakomponentide loogiline jaotamine teineteisest eraldatud üksusteks, millest igat üksust saab kasutada eraldi operatsioonisüsteemi installeerimiseks ja kasutamiseks. Lisaks virtuaalmasinate kasutamisele on olemas veel eraldi tehnoloogia, mis võimaldab igat virtuaalmasinat omakorda jaotada eraldiseisvateks konteineriteks, mis eraldavad teineteisest rakenduskeskkonnad, mille puhul saab vanaminevaid servereid ja rakendusi nii kiiresti üles sättida kui ka maha võtta. Pilvetehnoloogia võimaldab luua taristut, mille kaudu kõik seadmed saavad teineteisega efektiivselt ja turvaliselt informatsiooni vahetada. Lisaks saab pilvetehnoloogia abil kõikidest seadmetest tulevaid andmeid kokku koguda ühtsesse andmebaasi ning neid andmeid erinevate tehnoloogiate abil töödelda ja analüüsida.

2.2 Tehisintellekt ja masinõpe

2.2.1 Tehisintellekt

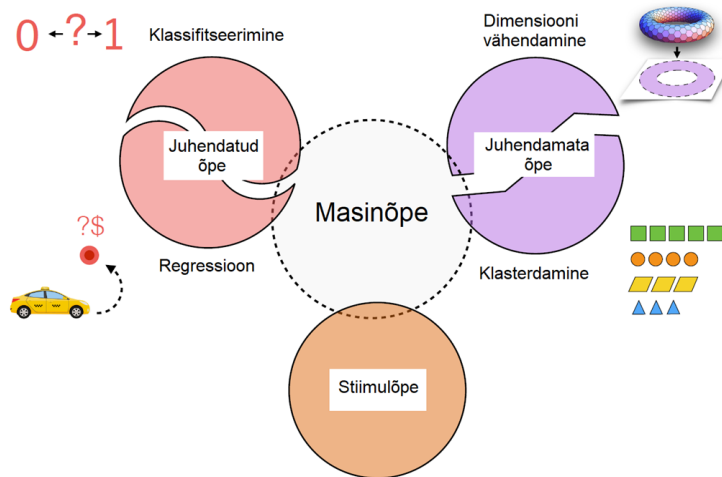
Tehisintellekt on valdkond, mille eesmärk on arvutisüsteemide arendamine, mis on võimelised täitma ülesandeid, mida harilikult on peetud omaseks inimestele. Näited sellistest toimingutest ja omadustest on pilditaju, vaateväljas olevate objektide tuvastamine, kõnetuvastus, probleemide lahendamise ja otsustamise võime, uutes olukordades kohanemine, loovus jne. Hetkel võivad tehisintellekti arvutiprogrammid või robotid inimeste intellekti omadusi mingil moel matkida, kuid on vara rääkida, et nende intellekt on võrdne inimese intellektiga.

Kõige lihtsam tehisintellekti süsteem on reeglipõhine. Reeglipõhistes süsteemides kasutatakse tegevuste elluviimiseks palju tingimuslauseid, mis annavad pealtvaadates näilise intelligentsi, kuigi tegelikult on kõikvõimalikud toimingud samm-sammu haaval ära määratud ja kirjeldatud.

Teine viis, kuidas koostada tehisintellekti programmi, on kasutades andmepõhist õppimist. Andmepõhine õppimine on protsess, kus arvutiprogrammile antakse ette ülesanne, mida ta peab lahendama ning hulgaliselt märgendatud andmeid ehk näiteid, kuidas antud ülesanne on varem lahendatud. Seejärel õpib programm, kuidas antud ülesande lahendamist on võimalik varasema info põhjal võimalikult hästi jäljendada. Eelpool kirjeldatud andmepõhist tehisintellekti valdkonda nimetatakse masinõppeks.

2.2.2 Masinõpe

Masinõpe on üks tehisintellekti alamvaldkond, mis võimaldab arvutitel õppida andmetest erinevaid seaduspärasusi, seosed, trende jne. Masinõppe rakenduste kiire kasv võimaldab tehisintellekti erinevates tööstusharudes laialdaselt kasutusele võtta. Masinõppes luuakse mudeleid ja programme suurte andmehulkade abil. Programmile antakse ette palju näiteid, kus uuritav ülesanne on juba ära lahendatud, ning seejärel õpib mudel ära vajalikud seosed, et pärast uute andmete puhul ise samat ülesannet automaatselt lahendada.



Joonis 2. Masinõppe alamvaldkondade skemaatiline esitus [3].

Masinõpet võib jaotada kolmeks alamrühmaks (Joonis 2): juhendatud-, juhendamata- ja stiimulõpe. Antud jaotamine põhineb viisil, kuidas mudel andmetest seoseid õpib. Antud töö raames keskendutakse juhendatud masinõppe meetodite rakendamisele tööstuses.


Masinõppe mudelite loomiseks on võimalik kasutada mitmesuguseid andmeid: teksti, heli, pilte, arvandmeid jne. Igat tüüpi andmete jaoks on olemas eraldi tehnikad, kuidas vastavaid masinõppe mudeleid luua. Lihtsamate masinõppe mudelite loomiseks kasutatakse struktureeritud andmeid, mis on harilikult tabelkujul. Andmetabel koosneb ridadest ja veergudest. Veergudeks on andmeobjekte kirjeldavad omadused ehk tunnused. Tunnused võivad olla nii arvilised (nt pikkus, kaal) kui ka mitteamrillised (nt silmavärv). Masinõppe mudeli loomisel võetakse aluseks üks tunnus (uuritava tunnus), mille väärtusi me teiste tunnuste kaudu tahame ennustama hakata. Seejärel valitakse välja kirjeldavad tunnused, mille abil me uuritava tunnuse väärtusi ennustada tahame.

Juhendatud õppe puhul antakse arvutile ette hulk andmeid ning iga andmeobjekti korral uuritava tunnuse väärtus ehk märgend. Antud andmete ja uuritava tunnuse väärtuste puhul õpib masin ära mudeli, mis väljendab seoseid kirjeldavate tunnuste ja uuritava tunnuse väärtuste vahel. Kui mudel on loodud, siis on selle abil võimalik mingi täpsusega ennustada varem nägemata ja puuduvat uuritava tunnuse väärtust. Laialt jaguneb juhendatud õpe kaheks valdkonnaks: regressioon ja klassifitseerimine(Joonis 2), millest räägime järgmises osas.

Mudeli treenimine on protsess, kus arvutiprogrammile antakse näidetena ette andmeobjekte ja neile vastavaid märgendeid, ning iga andmeobjekti puhul programm korrigeerib mudeli parameetreid selliselt, et erinevus mudeli ennustuste ja tegelike märgendite väärtuste vahel oleks võimalikult väike, s.t algoritmi eesmärgiks on võimalikult palju minimiseerida ehk vähendada mudeli ennustuste veamäära. Juhendatud masinõppe mudeleid võib tööstuses rakendada näiteks ennustavas hoolduses, et ennustada seadmete eluiga või seda, kas mõni seade läheb järgmise määratud ajaperioodi jooksul tõenäoliselt katki või mitte. Rohkem juhendatud masinõppe mudelite rakendamise näiteid tööstuses toome välja peatükis 2.3.

2.2.3 Regressioon


Regressiooni puhul on uuritavaks tunnuseks reaalarvu tüüpi märgenditega tunnus (nt auto hind või läbisõit, vt Joonise 2 esimest osa). Regressioonimudeleid on mitmeid, kuid mõned näited on lineaarne regressioon [10] ja regressiooni puu [11]. Kui me vaatleme ühte kirjeldavat ja ühte uuritavat tunnust, siis saab nende tunnuste vahelist seost kujutada punktisarvena koordinaattasandil (Joonis 3A). Regressioonimudel püüab sellisel juhul leida funktsiooni (joont graafikul 3B), mis oleks kõikidele andmepunktiledele korruga võimalikult ligidal.



Joonis 3. A) kahe arvulise tunnuse hajuvusdiagramm. B) Andmepunktidele sobitatud lineaarfunktsioon (sirge), mis on kõigile andmepunktidele korruga võimalikult ligidal. C) Andmepunktidele sobitatud mittelineaarne funktsioon (antud juhul regressioonipuu).

2.2.4 Klassifitseerimine


Klassifitseerimise puhul on uuritavaks tunnuseks kategoorilist tüüpi tunnus, nt silmavärv, loomatõug, auto silindrite arv, 0 või 1 jne. Kategoorilise tunnuse erinevaid väärtusi nimetatakse klassideks. Klassifitseerimisalgoritmidele antakse ette näiteandmed ning andmepunktide klassid (alloleval joonisel 4 on andmepunktide klassid märgitud värviga), ning mudeli algoritm õpib objektide ja klasside seoseid. Joonisel 4 püüab mudel graafikut jagada vastavate klasside piirkondadeks, kus iga piirkond sisaldaks võimalikult täpselt vastava klassi punkte. Neid piirkondi nimetatakse ka otsustuspiirkondadeks. Uute andmepunktide puhul ennustab selline treenitud algoritm klassi.



Joonis 4. Graafikul A on visualiseeritud andmepunkte, ning iga andmepunkti puhul on roheline, sinise või punase värviga ära märgitud, et millisesse klassi ta mingi valitud kategoorilise tunnuse järgi kuulub. Graafikul B on lineaarse klassifikatsiooni mudel, mis jaotab graafiku sirgjoonte abil kolme piirkonda, kus iga piirkond kataks võimalikult palju vastava klassi andmepunkte. Graafikul C on mittelineaarse klassifikatsiooni mudel, mis jaotab graafiku kõverjoonte abil kolme piirkonda, kus iga piirkond kataks võimalikult palju vastava klassi andmepunkte.

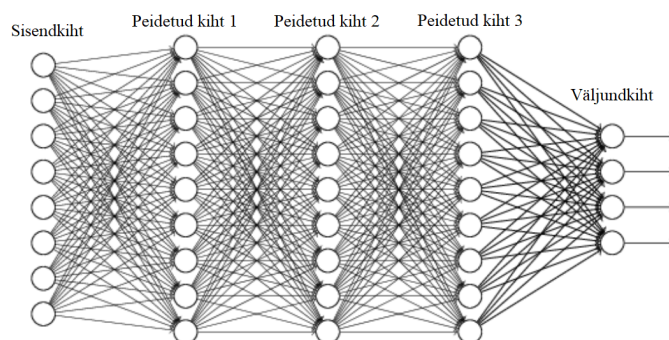
2.2.5 Tehisnärvivõrgud

Üks masinõppe olulisemaid alaliike on sügavõpe. Sügavõppes kasutatakse mudelitena tehisnärvivõrke. Tehisnärvivõrkudel põhinevatel mudelitel on palju rakendusi mitmesugustest tööstusharudes, robotikas jne. Tehisnärvivõrgud on inspireeritud bioloogiliste neuronite võrgustikest. Tehisnärvivõrgu kõige olulisemad komponendid on **tehisneuronid** (Joonis 5). Tehisneuron võtab sisendiks arvilisi väärtusi teistest tehisneuronitest ning korrutab need teatud arvude ehk kaaludega läbi. Seejärel liidetakse kaaludega läbi korrutatud sisendid kokku. Saadud summale rakendatakse **aktiivatsioonifunktsiooni**, ning saadud väljund (üks arv) on üheks sisendiks järgmistele tehisneuronitele.



Joonis 5. Bioloogilise ajuneuroni ja tehisneuroni skemaatiline ülesehitus [12]. Pildil A on kujutatud inimese ajuraku ehk neuroni üldist ehitust. Pildil B on kujutatud tehisnärvivõrkude ühe põhilise komponendi tehisneuroni üldist ehitust.

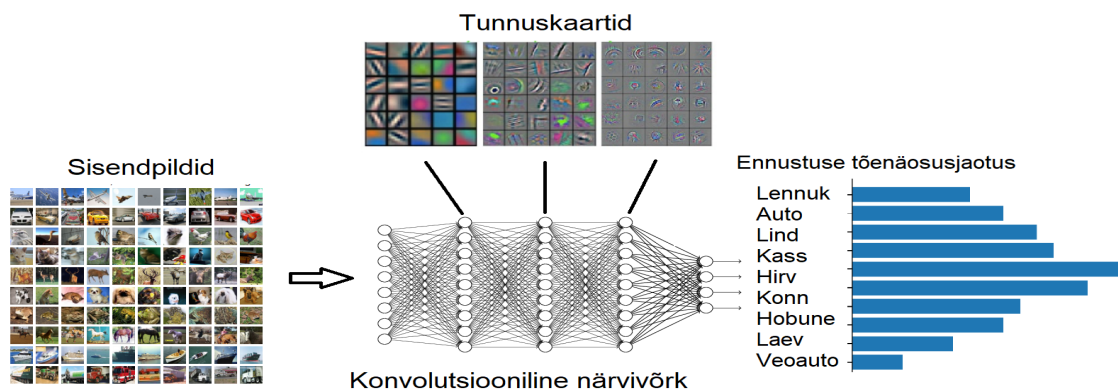
Tehisnärvivõrgus rühmitatakse tehisneuronid erinevatesse kihtidesse (Joonis 6), kus ühe kihi tehisneuronid on ühendatud nii eelneva kui ka järgneva kihi tehisneuronitega. Tehisnärvivõrgu esimene kiht on sisendkiht, kuhu sisestatakse andmeid, mille põhjal mudel luuakse. Viimane kiht on väljundkiht, mis on tehisnärvivõrgu töö tulemusel tekkinud ennustus või prognoos, mis sisendkihis olevatele andmetele vastab. Sisendkihi ja väljundkihi vahele jäävad peidetud kihid, mis sisendkihi väärtusi töötlevad ja arvutavad.



Joonis 6. Näide lihtsamast tehisnärvivõrgu struktuurist [13]. Tehisnärvivõrk koosneb kihtidesse jaotatud tehisneuronitest, mis on teineteisega ühendatud.

2.2.6 Konvolutsioonilised närvivõrgud

Konvolutsioonilised närvivõrgud on üks tüüp tehisnärvivõrke, mis sobivad hästi piltide analüüsimiseks, klassifitseerimiseks, segmenteerimiseks jne [14]. Konvolutsioonilised närvivõrgud võtavad arvesse sisendväärtuste omavahelist järjestust ja paigutust (Joonis 7). Selle närvivõrgu töö käigus rakendatakse sisenditele filtreid, mille tulemusel tekivad tunnuskaardid. Tunnuskaardid väljendavad erinevaid kujundeid, mis antud pilte võiks iseloomustada. Uue sisendi korral sõltub klassifitseerimise tulemus sellest, kuidas sisendpildi mingid piirkonnad “aktiveeruvad” antud tunnuskaartidega. Konvolutsioonilisi kihte on sellises närvivõrgus harilikult mitu ning sügavamates kihtides tekkivad tunnuskaardid sisaldavad üha terviklikumaid ja keerulisemaid kujundeid.



Joonis 7. Konvolutsioonilise närvivõrgu lihtsustatud tööpõhimõte [15]. Närvivõrgule antakse sisendiks pilte ning konvolutsioonilistes kihtides tekib filtrite rakendamisel pildiosadel tunnuskaardid. Närvivõrgu viimases kihis on klasside tõenäosusjaotus, mis väljendab, kuidas tõenäoliselt närvivõrk antud pilti erinevatesse klassidesse kuulumist peab. Tõenäosusjaotuse tõenäosuste summa peab võrduma ühega.

Järgmises peatükis 2.3 ja peatükis 5 näitame, kuidas rakendada masinõppe meetodeid praktiliste ülesannete lahendamisel tööstusettevõtetes.

2.3 Näiteid tehisintellekti võimalikest rakendustest tööstuses

Tehisintellekt võib aidata lahendada erinevaid praktilisi korduvaid ülesandeid tööstusettevõttes, muuta tootmist efektiivsemaks, ohutumaks ja säästa tootmiskulusid. Järgnevas osades kirjeldame tehisintellekti rakendamise juhtumeid, mida kursuse materjalides käsitletakse.

2.3.1 Pildi- ja objektituvastus

Objektituvastuse puhul antakse masinõppe algoritmile ette pilte erinevatest objektidest, ning iga objekti puhul märgendi, mis ütleb, millise objektiga on tegu (millisesse klassi ta kuulub). Kui algoritmile anda ette piisavalt palju selliseid pildinäiteid, siis algoritm õpib piltidelt eraldama tunnuseid, mille abil on tal võimalik otsustada, kas antud pildil olev objekt kuulub ühte klassi või mõnda teise klassi. Kui mudel on valmis, siis on edaspidi võimalik mudelile anda sisendiks pilte, mille puhul pole enam käsitsi märgendatud, mis objekt pildil on, ning seejärel ennustab mudel ise, millise objektiga on pildil tegu.

Eelnevas kirjeldatud “objektid” võivad olla ükskõik missugused esemed. Näiteks võime me eristada erinevaid tootmisdetailide, transpordivahendeid, liiklusmärke, inimeste nägusid, kuid lisaks veel ka katkisi või terveid esemeid, mädanenud või terveid puuvilju jne. Võimalusi on lõputult. Järgnevas toome mõned näited konkreetsetest klassifitseerimismudelitest tööstuses.

Tootmisdetailide klassifitseerimine


Tootmisliinil võib lindi peal joosta erinevaid detaile. Kaamera abil tootmisdetailide tuvastamise järel on võimalik erinevaid detaile loendada, sorteerida ja korrastada. Samuti saab koosterobot tuvastatud detaile haarata ja neid toodeteks kokku panna. Masinõppe abil on võimalik luua mudel, millele antakse näideteks pilte paljudest tootmisdetailidest ning nende nimedest, mille põhjal mudel õpib neid detaile eristama (Joonis 8). Kui valmis mudelile hiljem anda ilma nimeta tootmisdetaili pilt (nt kaamerapildilt), siis mudel suudab ise automaatselt tuvastada, millise tootmisdetailiga on tegu.



Joonis 8. Näiteid erinevatest tootmisdetailidest, mida masinõppe abil on võimalik eristada [16].

Tootmisjääkide sorteerimine

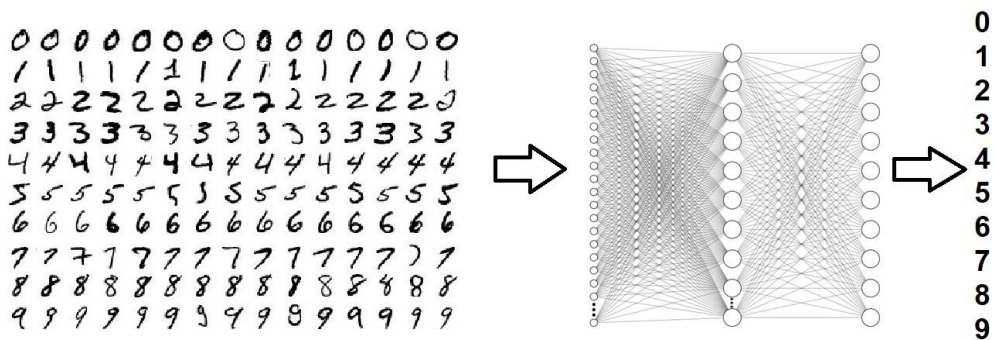
Tootmise käigus tekib jääke. Mõnikord on efektiivsuse suurendamiseks ja reostuse vähendamiseks otstarbekas tootmisjääke ning prügi sorteerida. On võimalik luua klassifitseerimise mudel, mis kaamerapildi põhjal erinevaid materjale automaatselt tuvastab. Antud juhul esindavad materjalid mudeli jaoks klasse nagu näiteks papp, klaas, metall, plastik (Joonis 9).



Joonis 9. Näiteid andmestiku piltidest, mis kuuluvad erinevatesse klassidesse (erinevad materjalid) [17].

Teksti ja numbrite tuvastamine

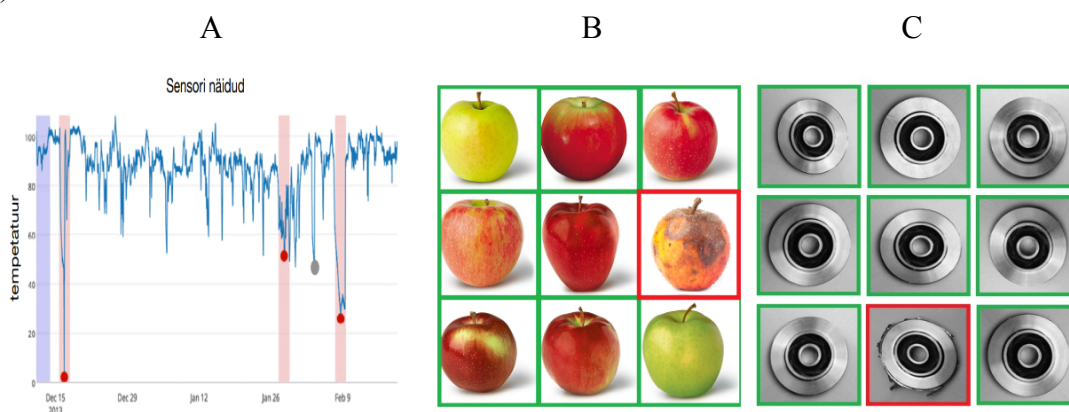
Tootmises on nii toodetel kui ka nende pakenditel tekstilist või numbrilist informatsiooni. Tihti pole selline tekst standardiseeritud, s.t tekstid ja numbrid on kirjutatud erinevas stiilis. Tehisnärvivõrke on võimalik õpetada kaamerapildist automaatselt ära tuvastama erinevaid tähti ning numbreid. Üks traditsioonilisi näiteid on kirjaümbrikutelt inimese käekirjas kirjutatud aadresside ja postiindeksite lugemine (Joonis 10).



Joonis 10. Näide närvivõrgust, mis võtab sisendiks mingi käsitsi kirjutatud numbrini ning püüab määrata, millist numbrit on käsitsi kirjutades kujutatud [18].

2.3.2 Anomaaliate tuvastamine

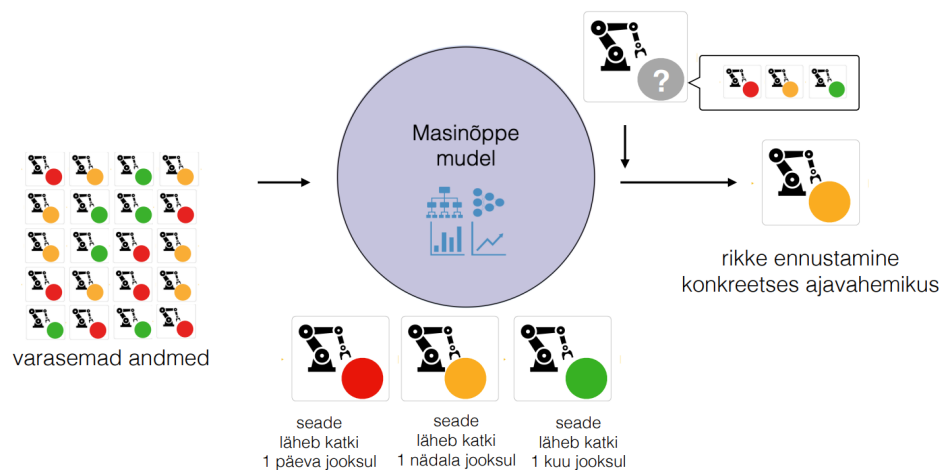
Tööstusprotsessides võib tekkida anomaaliaid ehk kõrvalekaldeid protsessi tavapärasest kulgemisest (Joonis 11A). Üheks näiteks on masinate rikki minemine ja tootmisproduktide defektid. Masinate katki minemisele võib eelneada anomaalseid signaale, heli jne. Anomaaliaid tuvastama treenitud masinõppemudelid suudavad aegsasti ja automaatselt tuvastada, kui masinate töö käigus on midagi tavapäratuks muutunud, ning seejärel sellest inimesi hoiatada. Samuti võib masinnägemise abil automaatselt tuvastada vigaseid, deformeerunud või muul viisil kahjustunud tootmisdetaile, produkte, tööriistu jne (Joonis 11 B, C).



Joonis 11. Pildil A on punaste punktidega kujutatud ekstreemselt kõrvalekalduvate temperatuuride väärtuseid ja vastavaid kuupäevi. Pildil B on kujutatud terveid õunu ning ühel pildil on kujutatud mädanenud (defektne) õun. Pildil C on kujutatud näiteid nii tervetest tootmisdetailidest kui ka ühest defektsest detailist [19, 20, 21].

2.3.3 Ennustav hooldus

Masina lähed oma töö käigus aeg-ajalt katki. Kui masina töökäigust koguda sensorite abil andmeid näiteks temperatuuri, rõhu, heli, vibratsiooni jms kohta ning pidada arvet, millal masin töötab nagu oodatud ning millal katki läheb, siis nende andmete põhjal on võimalik luua mudeleid, mille põhjal on hiljem võimalik ennustada, millal masin hakkab mingil viisil katki minema (Joonis 12). Ennustava hoolduse (ingl *predictive maintenance*) abil on võimalik kokku hoida nii raha kui ka töötajate aega, kuna vastavate mudelite abil on võimalik ennetavalt ära hoida masina komponentide täielikku purunemist, ning samuti pole vaja mehaanikute poolt teha tarbetuid masina seisukorra kontrolle.



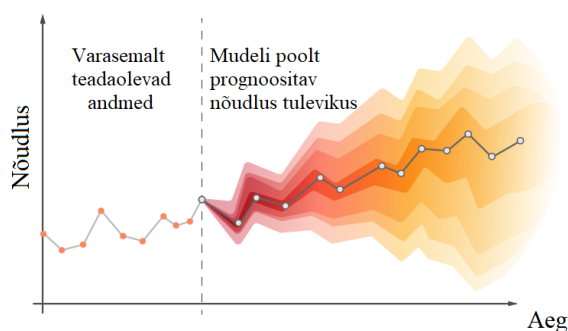
Joonis 12. Masina rikke ennustamise näide [20]. Mudeli treenimiseks on etteantud hulk varasemaid näiteid koos masina töötamise parameetritega ning seisukorra hinnangutega (punane, oranž, roheline). Pärast mudeli treenimist antakse mudelile ette uue masina tööparameetrid ja sensorandmed, mille tehniline seisukord pole veel teada, ning mudel ennustab, millise aja jooksul see masin tõenäoliselt katki läheb.

2.3.4 Nõudluse prognoosimine

Masinõppe mudeleid saab rakendada ka aegridadega seonduvate prognooside tegemiseks. Aegrida kirjeldab aja jooksul muutuvaid väärtuseid. Jooksvat arvet võidakse pidada näiteks tootmis- ja energiakulude ning läbimüügi üle. Prognoosimisel luuakse mudel, mis arvestab antud aegrea varasemaid väärtusi, ning püütakse aegrea varasema käitumise puhul ennustada võimalikke tuleviku väärtusi. Aegridade prognooside abil saab näiteks optimeerida, millal on mõistlik suuremas mahus toota (nt kui prognoositav nõudlus on suurem) ning millal vähem (Joonis 13).

Kuigi traditsiooniliselt on aegridade analüüsiks kasutatud statistilisi meetodeid nagu ARIMA (ingl *Autoregressive integrated moving average*) [22], siis arvutusvõimsuse kasvuga on hakatud aegridasid modelleerima ka masinõppel põhinevate mudelitega nagu nt LSTM (ingl *Long short-term memory*) tehisenärvivõrkudega [23]. LSTM tehisenärvivõrkude ehitus on selline, mis võimaldab mudeli loomisel arvesse võtta ennustatava tunnuse väärtuste järjendeid (nagu nt aegreas).

Näiteid aegridadest, mille väärtusi võib olla otstarbekas ennustada on tootmiskulude muutumine ajas, nõudluse muutumine ajas, elektri hindade muutumine ajas, energiakulu muutumine ajas jne.



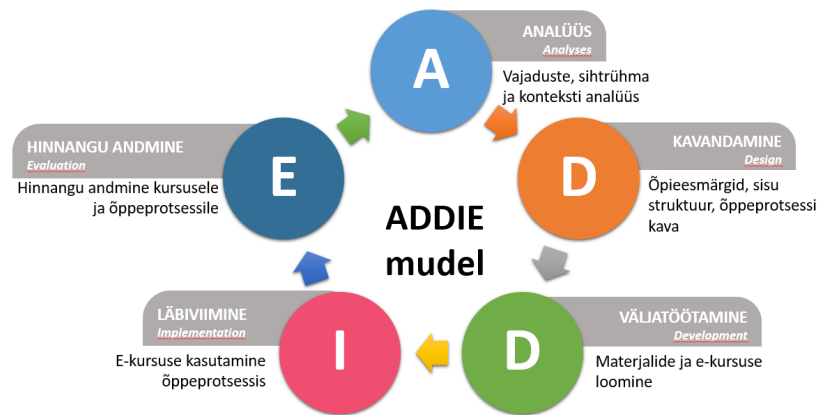
Joonis 13. Näide aegrea väärtuste prognoosimisest. Mudeli loomisel kasutatakse varasemaid andmeid, et ennustada aegrea väärtusi tulevikus, kusjuures ennustuse usalduspiirid muutuvad üha laiemaks (ebakindlamaks), mida kaugema tuleviku kohta ennustusi teeme [24].

2.4 Kursuse väljatöötamise meetodid

Käesoleva magistritöö eesmärgiks on luua eesti tööstusettevõtetele suunatud praktiline veebipõhine tehisintellekti lühikursus. Selles peatükis anname ülevaate loodava kursuse õppematerjalide kavandamiseks ja väljatöötamiseks kasutatavatest meetodikatest (osa 2.4.1 ja 2.4.2) ning tehisintellekti praktiliste ülesannete loomise meetodikast (osa 2.4.3).

2.4.1 ADDIE mudel

Autor kasutab õppematerjalide väljatöötamiseks ADDIE (ingl *analysis, design, development, implementation, evaluation*) mudelmeetodit (Joonis 14). ADDIE mudel on üks enim kasutatavaid raamistikke kursuste loomiseks. Antud raamistik pakub tõestatud meetodit tõhusate koolitusprogrammide ja kursuste koostamiseks. Kuigi ADDIE mudel koosneb viiest olulisest etapist, siis selle töö raames keskendub autor kolmele esimesele etapile.



Joonis 14. ADDIE mudel. Juhend kvaliteetse e-kursuse loomiseks [25]. ADDIE mudel on õppekursuse disainimise, loomise ja läbiviimise raamistik, tuletatud lühenditena inglisekeelsetest sõnadest Analysis, Design, Development, Implementation, and Evaluation. Raamistik koosneb viiest etapist: analüüs, kavandamine, väljatöötamine, läbiviimine, hinnangu andmine.

ADDIE mudeli põhietapid võib ära kirjeldada järgmiselt:

1. **Analüüs** - selgitatakse välja õppijate sihtrühma teadmised, oskused ning vajadused. Vajaduste väljaselgitamiseks võib kasutada nii varasemaid uuringuid, korraldada ise küsitlusi ning samuti võib läbi viia intervjuusid. Analüüsi etapis määratakse ära kursuse üldised õpiväljundid ning nende saavutamise viisid, kursuse temaatiline sisu ning maht.
2. **Kavandamine** - selles etapis planeeritakse kursuse jooksul tehtav töö, õppemeetodid- ja vahendid, teadmiste kontrollimise ja tagasiside viisid, seatakse kursuse hindamise kriteeriumid jne.
3. **Väljatöötamine** - selles etapis toimub kursuse sisu tegelik loomine. Luuakse teoreetilist/tekstilist materjali, ülesandeid, videosid, graafilisi ja interaktiivseid elemente, teste jne.
4. **Läbiviimine** - pärast kursuse loomist toimub kursuse läbiviimine õpilaste seas. Toimub õpilaste toetamine, vajadusel nõustamine ja muul viisil abistamine, mis aitab õpilastel kursusel olevaid õpiväljundeid saavutada.
5. **Hinnangu andmine** - pärast kursuse lõppemist on mõistlik läbitud kursuse sisu ja läbiviimise kohta koguda tagasisidet, mille põhjal saab ülevaate, mis on läbiviidud kursuses hea ning millega oleks vaja veel parandustööd teha.

Käesolevas magistritöös töötab autor vaid ADDIE mudeli kolme esimese etapiga. Kursuse läbiviimine ning pärast läbiviimist kursusele hinnangu andmine jääb tulevikku ning väljapoole magistritöö mahtu.

2.4.2 LORI hindamismudel

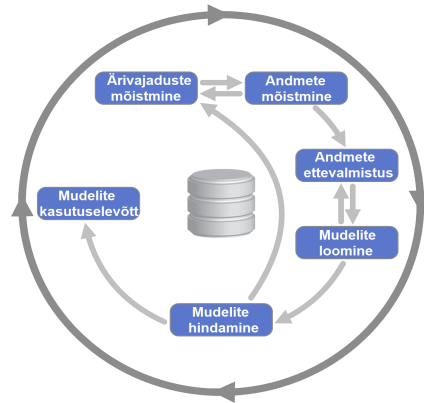
Loodav digitaalne õppematerjal toetub LORI hindamismudelile (ingl *Learning Object Review Instrument*) [26]. LORI hindamismudeli abil on võimalik hinnata loodud õppematerjali kvaliteeti. LORI keskendub kursuse õppematerjalide loomisel järgmistele omadustele:

- **Sisu on kvaliteetne** - õppematerjal on sisult ja keeleliselt korrektne, ei sisalda faktivigu, väited on põhjendatud ja loogilised.
- **Sisu vastab õpiväljunditele** - õpiväljundid on selgelt välja toodud ja vastavad sihtrühma vajadustele. Õppematerjalide sisu aitab saavutada kirjeldatud õpiväljundeid.
- **Tagasiside õpilastele** - õppematerjal on ehitatud selliselt, et võimaldab õppijal aegsasti saada tagasisidet teemade läbimise kohta, kasutades nt lühikesi enesekontrolli küsimusi, interaktiivseid komponente vms.
- **Õppimist motiveeriv** - õppematerjal ja selle sisu äratav õppijas huvi, on piisavalt mitmekesine, annab paraja väljakutse, vastab õppija huvidele ja eesmärkidele.
- **Visuaalne disain** - õppematerjal on sobival määral piltlikult illustreeritud ning toetavad ja mitmekesistavad õppesisu.
- **Kergesti kasutatav** - õppematerjal ja selle sisu on intuiitiivselt kasutatav ning lihtsasti navigeeritav.
- **Kättesaadav** - õppematerjal võiks olla kättesaadav erinevates seadmetes ja platvormidel.

Käesolevas töös loodava kursuse õppematerjalide puhul võetakse LORI kriteeriume arvesse, kuid kursuse lõplikku hinnangut, mis tehakse ADDIE mudeli viimases etapis, käesolevas töös läbi ei viida.

2.4.3 CRISP-DM

Praktilised näited luuakse ja viiakse läbi CRISP-DM [27] (ingl *Cross-industry standard process for data mining*) raamistiku etappe järgides.



Joonis 15. CRISP-DM tsükli skemaatiline esitus [27]. Kogu meetodika elutsükkel ei pruugi olla sirgjooneline, vaid võib tekkida vajadus pöörduda tagasi eelnevate etappide juurde.

1. **Ärivajaduste mõistmine:** sisaldab endas äriprobleemide mõistmist ning andmeanalüüsi ülesande ja edukuse kriteeriumite püstitust sõltuvalt ärilistest probleemidest, eesmärkide püstitusest ning oodatavatest tulemustest. Äriprobleem tõlgitakse selles etapis andmeanalüüsi probleemiks ja teostatakse projekti esialgne planeerimine.
2. **Andmete mõistmine:** sisaldab endas andmete kogumist, andmete esmast kirjeldamist, lihtsamat statistikat, lihtsamate seoste visualiseerimist ja andmete kvaliteedi hindamist.
3. **Andmete eeltöötlus:** sisaldab endast andmete korrastamist, puhastamist, sobivate tunnuste valikut ning vastava mudeli jaoks ette valmistust.
4. **Mudelite loomine:** sisaldab endas sisendandmetele ja ülesandele vastava mudeli valikut, esialgsete mudeli parameetrite valikut ning mudeli loomist ja mudeli headuse hindamist. Sobiva mudeli loomine nõuab kogemust, intuitsiooni ning tihti tuleb katsetada mitme erineva mudeliga ja siis valida neist sobivaim.
5. **Tulemuste hindamine:** selles etapis hinnatakse, kui võrd mudel ja selle mudeli kasutamisest tulenev kasu vastab esimeses etapis püstitatud ärilistele ja andmeanalüütilistele eesmärkidele.
6. **Juurutamine:** mudel võetakse kasutusele uutel andmetel ennustuste tegemiseks. Selle saavutamiseks võib vaja olla mudelit integreerida muude süsteemidega, mis antud mudelit võivad kasutada. Lisaks jälgitakse jooksvalt mudeli tööd ning vajadusel antakse edasiseid hinnanguid mudeli kasutuskõlblikkusele.

2.5 AIRE - AI & Robotics Estonia

Tehisintellekti ja robotika keskus (ingl AI & Robotics Estonia) AIRE [6] on osa European Digital Innovation Hubs (EDIH) võrgustikust. AIRE toob kokku tööstusettevõtteid, lahenduste pakkujad, ülikoolid ja teaduspargid, kes kõik töötavad pühendunult ühe eesmärgi nimel. AIRE keskuse eesmärgiks on Eesti tööstusettevõtete konkurentsivõime tõstmine. Keskuse eesmärgid hõlmavad muuhulgas erinevate tehisintellekti lahenduste tutvustamist ning eestikeelsete koolituste korraldamist tööstusettevõtetele. Tartu Ülikooli õppejõud on teinud tihedat koostööd AIRE keskusega ja loonud mitmeid kursusi [28, 29]. Kursuse sihtrühma ehk tööstusettevõtete töötajate vajaduste mõistmiseks on käesoleva töö autor koostöös AIRE-ga läbi viinud uuringu, mille üksikasjalik kirjeldus on peatükis 3.

3. Kursuse analüüs

Selles peatükis anname ülevaate loodava kursuse sihtrühma vajadustest. Vajaduste väljaselgitamiseks kasutame varasemaid uuringuid, viime läbi küsitluse ning intervjuerime tööstusega seotud eksperte.

3.1 Kursuse loomise vajadus ning üldised eesmärgid

Tartu Ülikooli Arvutiteaduse Instituudi poolt pakutakse mitmeid tehisintellekti ja andmeanalüüsi teemalisi kursuseid [2, 3, 4, 30, 31, 32, 33], kuid tööstusettevõtetele on neist suunatud vaid kursus “Tehisintellekti projekti planeerimine ja läbiviimine tööstusettevõttes (LTAT.TK.024)” [20]. Eelnimetatud kursuse fookus on teoreetiline sissejuhatus tehisintellekti valdkonda ning tehisintellekti rakendamisele tööstuses ilma tehisintellekti ning programmeerimise taustata inimestele. Kursusel aga ei õpita kuidas andmeanalüüsi programmeerimiselt läbi viia ja kuidas luua sobivaid matemaatilisi mudeleid. Käesoleva magistritöö käigus loodav kursus on osalt praktiline jätk eelmainitud kursusele. Tehisintellekti rakenduste vajaduste väljaselgitamiseks tööstusettevõtetes teeb töö autor koostööd Tehisintellekti ja robotika keskusega AIRE.

3.2 Sihtrühma vajadused

Sihtrühma vajaduste väljaselgitamine viidi läbi kasutades erinevaid meetodeid, et saada terviklik pilt. Esimesena analüüsiti kahte varasemalt läbiviidud uuringut [34, 35]. Seejärel koostas magistritöö autor küsimustiku (vt lisa 1), mille vastuste analüüsi tulemused on kirjeldatud alapeatükis 3.2.4. Viimase etapina viis magistritöö autor läbi kaks intervjuud tööstusvaldkondade ekspertidega, et vajadusi täpsustada (osa 3.2.5). Järgnevates alapeatükkides kirjeldame uuringute analüüsi tulemusi ning viimase sammuna teeme kokkuvõtlikud järeldused sihtrühma vajaduste kohta.

3.2.1 Eesti tööstussektori ülevaade

2021. aasta seisuga on töötlev tööstus Eesti suurim majandussektor [36], kus töötab ligi 120000 inimest ning mis moodustab 14.4% Eesti SKP-st.

Tööstus hõlmab endas:


- loodusvarade kaevandamist ja töötlemist;
- energia, seadmete, masinate ja kaupade tootmist;
- põllumajandussaaduste töötlemist;
- tööstuses valmistatud toodete töötlemist.

Suurimad tööstusharud Eestis on puidutööstus, metallitööstus ning toiduainetööstus. Järgnevalt toome välja mõned tähelepanekud juba olemasolevatest uuringutest Eesti tööstusettevõtete pädevuste ja vajaduste kohta Tööstus 4.0 tehnoloogiate aspektist.

3.2.2 Swedbanki 2021. aasta tööstusettevõtete uuring


Swedbanki 2021. aasta uuringus uuriti Eesti tööstusettevõtete olukorda, arvestades nende ettevõtete eksporti, investeeringuid ja fookust, tööjõudu ning automatiseerimist. Siin peatükis anname uuringu ülevaate just automatiseerimisega seotud tulemustest lähtuvalt [34].

2021. aastal küsitletud tööstusettevõtetel olid järgmise kahe aasta jaoks kolmeks peamiseks fookuseks efektiivsuse kasv, mahtude kasv ja tootearendus. Ettevõtetes on küsitluse vastuste põhjal 2021. aasta seisuga kõige enam kasutatavad tehnoloogiad automatiseeritud tehnoloogiad, sensorid ning ERP (ettevõtte ressursside haldamise süsteem) süsteemid (Joonis 16A). Tulevikus plaanitakse samuti keskenduda automatiseeritud tehnoloogiatele, robotikale, anduritele ja sensoritele ning ERP süsteemidele (Joonis 16B).



Joonis 16. A) Tööstus 4.0 tehnoloogiate kasutus tööstusettevõtetes aastal 2021. B) Tööstus 4.0 tehnoloogiate planeeritav kasutuselevõtt tulevikus.

Kõige olulisemad kasutegurid, mida küsitlusele vastanud ettevõtted soovivad automatiseerimisega ja digitaliseerimisega saavutada on tootlikkuse ning efektiivsuse suurendamine (Joonis 17A). Põhjuseid, miks küsimustele vastanud ettevõtted automatiseerimist või digitaliseerimist ei rakenda, on mitu: eelkõige ei olda kindel, milliseid protsesse saab digitaliseerida, lisaks ei olda kindel investeeringute tasuvusajas, ning samuti puudub ettevõtetes tihti kompetents, et vastavad tehnoloogiat rakendada (Joonis 17B).




Joonis 17. Kõige olulisemad põhjused automatiseerimiseks ja/või digitaliseerimiseks. A) Automatiseerimise ja digitaliseerimise motivaatorid tööstusettevõtetes. B) Põhilised takistused automatiseerimisel ja digitaliseerimisel.

3.2.3 Tööstus 4.0 tehnoloogiate rakendamine Eesti tööstusettevõtete tarneahelas


Antud peatükk põhineb Seido Kaur-i magistritööl “Tööstus 4.0 eesti masinatööstuse ettevõtete tarneahelas” (2019) [35]. Tööstus 4.0 keskendub peamiselt tööstuse tehnoloogilistele aspektidele koos tööstuse protsesside digitaliseerimise ja automatiseerimisega. Oma magistritöös tõi Seido Kaur välja, et Eestit teatakse digitaliseerimise teemade valdkonnas kui üht arenenumat riiki, kuid tööstuse digitaliseerimises Eesti nii eesrindlik ei ole.

Kõige kasulikumateks digitaalseteks tehnoloogiateks ettevõtte tarneahelale hindasid vastajad automatiseerimist, robotikat, suurandmeid, masinõpet ja tehisintellekti (Joonis 18A). Suurimateks kasuteguriteks, mida Tööstus 4.0 tehnoloogiad võimaldavad, hindasid küsitlusele vastajad automatiseerimist, tootmise paindlikkust ning ressursside efektiivsust (Joonis 18B).



Joonis 18. Kõige kasulikumad Tööstus 4.0 tehnoloogiad ettevõtte tarneahelale. A) Digitaalsete tehnoloogiate kasu. B) Tööstus 4.0 tehnoloogiate rakendamise kasu tööstusettevõtetele.

Peamiste takistustena Tööstus 4.0 tehnoloogiate rakendamisel on küsimustikule vastanud ettevõtete seas tugevalt esiplaanis puudulikud teadmised nii tehnoloogiast endast kui ka selle rakendamise võimalustest, lisaks kompetentse tööjõu puudus. Samuti on takistavaks asjaoluks ettevõtete rahaline võimekus (Joonis 19).



Joonis 19. Tööstus 4.0 juurutamise peamised takistused.

3.2.4 Küsitlusuuringu tulemused


Lisaks varasemate uuringute ülevaatele koostas magistritöö autor ka ise küsitluse (vt lisa 1), kus uuris täiendavaid ning täpsemaid küsimusi seoses tööstusprotsesside automatiseerimisega tööstusettevõtetes. Küsimustiku koostas autor Google Forms keskkonnas ning jagas seda Facebooki grupis “Eesti Masinatööstuse Liit ja tema sõbrad”. Lisaks otsis autor cv-online [37] ja cv-keskus [38] portaalidest välja 160 tööstusega seotud ettevõtet ning nende ettevõtete e-mailid e-krediiinfo.ee portaalist [39] ning saatis sama küsitluse ettevõtete avalikele e-mailidele.

Läbi viidud küsitluses küsis autor järgmiste teemade kohta:

- ettevõtete suurust ja vastaja ametikohta;
- hinnanguid ettevõtte erinevate protsesside automatiseerituse taseme kohta;
- põhilisi tehnoloogiaid, mida ettevõtte oma tootmisprotsessides kasutab;
- peamisi põhjusi, mis takistavad automatiseerivaid tehnoloogiaid kasutusele võtmast;
- võimalikke pildituvastuse rakendusi, mida vastajad oma ettevõttes sooviks kasutada;
- võimalikke prognoosmodelite rakendusi, mida vastajad oma ettevõttes sooviks kasutada;
- milliste tehnoloogiate kohta vastajad sooviksid õppida ning millisel viisil.


Enamike küsimuste puhul said vastajad valida mitu varianti, mistõttu pole valikute summa alati võrdne vastajate koguarvuga. Allpool kirjeldame vastuste analüüsi tulemusi. Nendel tulemustel on aga piiranguid, mis on seotud vähese vastajate arvuga. Küsitlusele vastas 7 ettevõtet, mistõttu on järgnevate vastuste korral raske teha statistilisi üldistusi, mis ütleks midagi eesti tööstusettevõtete kui terviku kohta.

Küsimustele vastasid enamjaolt kontoritöötajad ja tootmisjuhid (Joonis 20A). Vastajad töötasid enamjaolt metallitööstusega seotud ettevõtetes (Joonis 20B). Vastanute ettevõtetes töötas üldiselt 10 kuni 250 inimest (Joonis 20C).




Joonis 20. A) Vastajate ametite jaotus. B) Vastajate ettevõtete tegevusvaldkondade jaotus. C) Vastajate ettevõtete suurused.

Ettevõtete automatiseerituse taseme hinnangud olid kõrgemad põhiliselt prognoosimisega seotud tegevustes (Joonis 21A). Võimalik, et kasutatakse erinevaid digitaalseid rakendusi, mis prognoosimist hõlbustab. Teisalt võib see olla seotud sellega, et kolm küsitlusele vastanud inimest olid kontoritöötajad, kes on rohkem kursis kontoritarkvaraga. Üldiselt kasutatakse vastanute ettevõtetes käsitsi juhutavaid masinaid, ning vähemal määral arvutijuhitavaid masinaid (Joonis 21B).




Joonis 21. A) Tööstusprotsesside automatiseerituse tase. B) Ülevaade tööstusettevõtetes kasutatavatest tehnoloogiast.

Vastanute seas ei olda kindlad, kuid võrd mingid investeeringud end ära tasuvad ning samuti ei teata erinevate tehnoloogiate rakendusvõimalusi (Joonis 22). Käesolevas magistritöös loodava kursuse käigus on üheks eesmärgiks tutvustada erinevaid tehisintellekti rakendusi tööstusprotsessides.




Joonis 22. Takistused automatiseerivate tehnoloogiate kasutuselevõtul vastajate ettevõtetes.

Kaamerapildi abil on küsitlusele vastajate põhjal kõige otstarbekam tuvastada erinevaid tootmisdetaile, katkiseid vs terveid tootmisdetaile, inimeste tööruumis viibimist ning samuti töötajate nägusid (Joonis 23A). Prognoosida soovitakse enim tootmise ressursikulu, ajakulu või materiaalset kulu (Joonis 23B).



Joonis 23. A) Automaatse pildituvastuse soovitud rakendused. B) Prognoosivate mudelite soovitud rakendused.

Küsitluses osalenute seas on rohkem huvi õppida tehisintellektiga seotud teooriat ja rakendusi (Joonis 24A). Vastuste põhjal eelistatakse pigem kaugõppega seotud õppe formaate, nagu nt videod ja veebiloengud (Joonis 24B). Suurem osa vastanutest hindab mõistlikuks kursuse pikkuseks 25 tundi, mis on ca 1 EAP ja mis ongi magistritöö käigus loodava kursuse mahu eesmärgiks (Joonis 24C).



Joonis 24. A) Huvi uute tehnoloogiate õppimise vastu. B) Sobivamad õppimisviisid. C) Sobiv kursuse maht.

3.2.5 Vajaduste analüüsi tulemused intervjuude alusel

Lisaks küsitlusele viis magistritöö autor läbi intervjuud kahe eksperdiga, kes on mõlemad tööstusettevõtetega tugevalt seotud ning kes suhtlevad tööstusettevõtetega tööalaselt. Intervjuude eesmärgiks oli välja selgitada, millised on intervjuueeritud ekspertide hinnangud tööstusettevõtete pädevustele ning takistustele seoses tööstusprotsesside automatiseerimisega. Intervjuud põhinesid samadel küsimustel, mis saadeti tööstusettevõtetele küsimustiku kaudu (vt lisa 1).

Esimese intervjuueeritava eksperdi hinnangul on eesti masinatööstuse ettevõtete teadmised robotikast oluliselt suuremad kui tehisintellektist. Lühikeste ajavahemike järel tulevad tööstusesse täiesti uued teemad, mille puhul ettevõtetel teadmisi pole. Digitaliseerimise tase on järk-järgult tõusnud, aga muutuste toomine tööstusesse võtab aega. Eesti seadmeпарк on kirju ning täiendatakse samm-sammuliselt. Eestis on palju keskmisi ja väikeseid ettevõtteid, kes on paindlikud uusi tehnoloogiaid vastu võtma. Samas uutesse tehnoloogiasse investeerimise puhul ollakse pigem ettevaatlik.

Teise intervjuueeritava eksperdi hinnangul on eesti tööstuse digitaliseerituse ning automatiseerituse tase madal. Tööstus 4.0 tehnoloogiatest inimesed väga teadlikud pole, pigem on segadus. Palju kasutatakse nõ vanakooli käsitsi juhitavaid või poolautomaatseid masinaid. Liinitootmist Eestis eriti pole, pigem on masinad teineteisest eraldatud eraldi aladesse või saartesse. Enamjaolt on komponendid sorteeritud juba masinate juures, mistõttu automaatset sorteerimist pole väga vaja. Lisaks puudub eksperdi hinnangul tööstusettevõtetes ülevaade, mis reaajas tootmises toimub. Teatakse ainult tootmisprotsessi sisendeid ja oodatavaid väljundeid, kuid ei teata, kui kaugel etapp on jne. Olulisel kohal on materjali optimeerimine, s.t tootmismaterjali maksimaalselt efektiivne kasutamine. Kontorite poole pealt kasutatakse palju Exceli tabeleid, kuigi populaarsust on hakanud koguma ka ERP süsteemide kasutamine. Kvaliteedi kontrolli tehakse enamjaolt inimeste poolt käsitsi. Samuti ei oska tööstusettevõtetes töötavad inimesed tihtipeale ise oma probleeme sõnastada.

Kuna ei ole suurt masstoodangut, siis ei tasu investeringud uutesse tehnoloogiasse ära. Ettevõtted on hädas pigem olemasoleva masinate tööshoidmise ja parandamisega, mistõttu ei jõuta uutele tehnoloogiatele mõelda. Ettevõtted tahavad pigem võtmed kätte lahendust, mitte ise midagi looma hakata. Samas kinnitas ekspert, et väikese ja keskmise suurusega ettevõtted on uutele tehnoloogiatele rohkem kohanduvad ning neid on ka arvuliselt rohkem.

Võimaliku lähenemisviisina protsesside automatiseerimiseks tõi ekspert välja, et enne mingisuguste andmete kogumist ja veel enam analüüsimist on vaja kõigepealt masinaid varustada sensoritega ja kontrollritega ning alles siis andmeid koguda. Ei pea ostma uusi masinaid, vaid olemasolevaid masinaid on võimalik lisakomponentidega täiendada.

3.2.6 Uuringute, küsitluse ja intervjuude kokkuvõte

Nii Swedbanki 2021. aasta uuringus kui ka Seido Kauri magistritöös korraldatud uuringus tuli mõlemast välja, et tööstusettevõtted soovivad rohkem kasutusele võtta automatiseerivaid tehnoloogiaid ning robotikat. Samuti tuli mõlemast uuringust välja, et põhilised takistused uute digitaliseerivate tehnoloogiate kasutuselevõtul on puudulikud teadmised vastavatest tehnoloogiatest ja nende kasutusvõimalustest ning samuti investeeringute tasuvuses. Investeeringute tasuvuse probleemi kinnitavad ka läbiviidud intervjuud ja küsitluse analüüsi tulemus.

Intervjuude põhjal soovitakse enim automatiseerida ning muuta tootmist efektiivsemaks. Hetkel on palju käsitsi juhitavaid masinaid ning poolautomaatseid CNC (ingl *computer numerical control*) masinaid. Detailid toodetakse otse masina juures ning nõ liinitootmist enamjaolt ei ole. Kuigi tööstuses on teadmisi tehisintellekti ja masinõppe rakendustest vähe, on huvi nende tehnoloogiate vastu olemas. Üldiselt ollakse valmis uute tehnoloogiate õppimise tarbeks panustama ca 26 tundi ehk 1 EAP jagu aega. Intervjueeritavate hinnangul soovitakse enamjaolt ikkagi nõ “võtmed kätte” lahendust, s.t juba töötavaid programme ja masinaid, et ise ei peaks oluliselt ressursse millegi uue õppimisele kulutama. Samas olid küsitlusele vastanud inimesed huvitatud tehisintellekti teooriast ja rakendustest tööstuses.

4. Kursuse kavandamine

Selles peatükis kavandab autor loodava lühikursuse põhikirjelduse ning sisu. Kursuse kavandamine on ADDIE metoodikas kolmas etapp. Kavandamise käigus täpsustatakse kursuse sihtrühm, kursuse maht, õpiväljundid, õppesisu, teemad, iseseisvad tööd ning hindamiskriteeriumid. Kursuse kavandamisel võetakse arvesse varasema sihtrühma vajaduste analüüsi tulemusi ning peetakse silmas, et loodav kursus vastaks LORI kriteeriumitele.

4.1 Kursuse sihtrühm

Kursuse sihtrühmaks on väikestes ja keskmise suurusega tööstusettevõtetes töötavad inimesed, soovitatavalt tootmisprotsessidega lähemalt seotud olevad inimesed nagu nt kvaliteedijuhid, tootmisjuhid, masinaoperaatorid ja insenerid. Kursusel osalejatelt ei eeldata programmeerimise teadmisi, kuid kursuse edukaks läbimiseks on vajalikud tehisintellekti ja masinõppe algteadmised, näiteks kursuste “Tehisintellekti projekti planeerimine ja läbiviimine tööstusettevõttes” [20] ja “Tehisintellekti algkursus” tasemel [12].

4.2 Kursuse maht

Kursuse maht on 1 EAP ehk 26 tundi akadeemilist tööd. Töö hulka kuulub nii praktikumi materjalide läbitöötamine kui ka iseseisvate tööde sooritamine. 26 tundi vastab ka töö autori poolt koostatud küsitluse vastustest, kus enamik vastanutest hindas soovitavaks töö mahuks ca 26 tundi.

4.3 Õpiväljundid

Kursuse õpiväljundid vastavad varasemalt läbiviidud tööstusettevõtete vajaduste uuringutele ning keskendub tehisintellekti ja sellega seonduvate vajalike eelteadmiste ning oskuste praktilisele arendamisele ja seejärel konkreetsete tehisintellekti rakenduste läbitöötamisele.

Kursuse läbinud õppija:

- oskab sõnastada enda ettevõttes automatiseerimise ja optimeerimisega seotud konkreetseid probleeme;
- teab põhilisi andmete kogumise ja korrastamise viise;
- omab ülevaadet põhilistest masinõppe meetoditest ja nende kasutusviisidest;
- omab ülevaadet mõnedest olulisematest tehisintellekti rakendustest tööstuses;
- oskab Python-i abil rakendada lihtsamaid masinõppe mudeleid erinevate tööstuses esinevate probleemide uurimisel/lahendamisel.

4.4 Sisu kaardistamine

Kursuse sisu ning teemad on valitud vastavalt sihtrühma vajaduste ning huvide uuringutele (varasemad uuringud, intervjuud, küsitlus). Kuna praktilisest vaatepunktist on prognoosivad ja automatiseerivad mudelid arvutiprogrammid, siis on ka nende mudelite praktiliseks mõistmiseks ja loomiseks eelnevalt vaja omada ülevaadet programmeerimisest endast. Kuna programmide poolt loodavad mudelid on andmepõhised, on mõistlik tutvuda ka põhiliste andmete töötlemise meetoditega. Esmalt tutvustatakse õpilastele Pythonit, andmetöötlust ja põhilisi masinõppe meetodeid, et anda alus ülejäänud juba konkreetsetele rakendustele.

Kursuse praktiline osa koosneb kuuest moodulist:

1. Pythoni lühitutvustus;
2. Andmete ülevaade ja nende esmane töötlus;
3. Ülevaade masinõppest;
4. Pilditutvustus: defektsete tootmisdetailide tuvastamine;
5. Hüdraulilise pressmasina ennustav hooldus;
6. Energia nõudluse ennustamine.

Iga moodul on üles ehitatud CRISP-DM (peatükk 2.4.3) põhimõtteid silmas pidades, kus esialgu luuakse stsenaarium, mis vajab probleemi püstitust ja mõistmist, tasuvuse uurimist, vajalike andmete kogumist ning mõistmist, mudeli valimist ja loomist ning lõpuks kasutamist.

4.5 Iseseisvad tööd ja hindamine

Iga mooduli lõpus on juhend õpilastele sarnase ülesande lahendamiseks, nagu vastava mooduli esimeses osas oli näitena toodud. Esialgse plaani kohaselt tuleb tehtud ülesanded käsitsi läbi vaadata kursuse läbiviijal või juhendajal, kuna nende ülesannete lahendamisel ei rakendata automaatset kontrolli.

4.6 Õppevahendid

4.6.1 Google Colab

Kursuse praktiline osa viiakse läbi Google Colab programmeerimiskeskonnas [40], kasutades Pythoni programmeerimiskeelt. Colab-i eelis on, et õpilane ei pea midagi enda arvutisse installeerima ega seadistama, vaid saab hakata koheselt veebilehitsejas tegutsema.

4.6.2 Coursera lühitutvustus

Kursuse läbiviimine on planeeritud coursera õppeplatvormi kaudu [41].

Coursera on populaarne veebikursuste platvorm, mis teeb koostööd ülikoolidega loomaks lühikursuseid ja mikrokraade õpivõimelistele üle maailma. Courseras on ligikaudu 4000

kursust ning 92 miljonit kasutajat. Enamjaolt kestavad Coursera kursused 4-12 nädalat ja keskmiselt on nädalas 1-2 tundi loenguid.

Courseras on võimalik luua küsimustikke, teste ning saada vastuste statistikat. Samuti on õpilastel Courseras võimalik luua õpieesmärke. Õppejõud saavad oma kursuste jaoks infot analüütikast, anda hinnanguid ja tagasisidet.

Tartu Ülikoolil on samuti Courseraga sõlminud koostööleppe, tänu millele seatakse sihiks suurendada kursuste kättesaadavust ja kasutamise mugavust õppijatele. Lisaks plaanitakse laiendada TÜ õpet osaliselt materjalidega, mis on saadaval Coursera platvormil, kasutada Coursera platvormi Tartu Ülikooli kontakt- ning e-ainete läbiviimise tugiplatvormina ning luua täiendavaid ehk "taset tõstvaid" tasandusmooduleid või erikursuseid (nt ained edasijõudnutele).

5. Kursuse väljatöötamine

Selles peatükis kirjeldame 6 praktilist moodulit ning seda, kuidas iga mooduli sisu ning ülesanded koostati. Iga mooduli töö sisu ja ülesanded on üles ehitatud CRISP-DM raamistikus. Esmalt tutvustatakse kursusel osalejatele probleemi, mida tuleb lahendada, ning seejärel võimalikke lahendusi ning nende tasuvust. Seejärel tutvuvad õpilased vajalike andmetega ning tehakse andmete esmast töötlust. Seejärel valitakse ning treenitakse andmetel masinõppe mudel ning hinnatakse selle mudeli headust, ning lõpuks rakendatakse loodud mudelit uutel andmetel ning hinnatakse antud projekti tulemusi. Lisaks sisaldab kursus iseseisvaid praktilisi ülesandeid eesmärgiga proovida õpitud materjali rakendada. Saadaval on ka näidislahendused. Moodulite loomise käigus peab töö autor silmas LORI õppematerjalide kriteeriume.

Kursuse materjalidele on võimalik ligi pääseda Tartu Ülikooli Coursera platvormi kaudu, GitHubi repositooriumist või Google Colabi keskkonnast. Juurdepääsuringid on esitatud Lisa II-s. Järgnevalt anname ülevaate kursuse põhilistest moodulitest.

5.0 Google Colab lühitutvustus

Enne praktiliste näidete juurde asumist tutvuvad õpilased Google Colab programmeerimiskeskonnaga. Google Colab võimaldab lihtsalt jooksutada ja jagada Pythoni koodi ilma, et õpilased peaks enda arvutisse midagi installeerima.

5.1 Pythoni lühitutvustus

Kuna kursuse kõik edasised näited põhinevad programmeerimiskeelel Python, siis on mõistlik esmalt õpilastele tutvustada Pythoni süntaksit ning põhilisi programmeerimise kontseptsioone nagu muutujad, tingimuslause, tsükliid, funktsioonid jne (vt Lisa II 2.1). Python on välja kujunenud üheks olulisemaks programmeerimiskeeleks andmete töötlemisel ja masinõppe mudelite loomisel. Python-i keel on võrreldes mõnede teiste programmeerimiskeeltega paindlik, platvormist sõltumatu ning lihtsamini loetav, mistõttu kasutatakse seda palju erinevate rakenduslike tehisintellekti mudelite loomiseks ja treenimiseks. Python-is jaoks erinevate vabatahtlike inimeste ning entusiastide poolt loodud hulganisti põhjalikke avatud lähtekoodiga kooditeeke andmeanalüüsiks ja masinõppeks, mida teised programmeerijad saavad mugavalt kasutada. Seetõttu õpitakse ka loodavas lühikursuses esmalt just Pythonit, kuna see on algajatele lihtsalt õpitav ning sisaldab populaarseid ja palju kasutatavaid andmetöötlus- ja masinõppe teeke ning raamistikke.

Selle õppematerjali lõpus pakutakse õppijatele iseseisvalt kirjutada funktsioon Pythoni keeles. Ülesande ülesehitus eeldab, et õppija kasutab õppematerjalist saadud teadmisi.

5.2 Andmete esmane vaatlus ja eeltöötlus

Pärast esmast harjutamist Pythoniga tutvustame andmete korrastamise ning töötlemise viise (vt Lisa II 2.2) Pythoni teegis Pandas [42]. Selle praktikumi eesmärk on tutvustada masinõppe mudeli loomisele eelnevat etappi ehk andmete esmast ülevaatus ja eeltöötlust. Pandas on üks põhilisi teeke Python-is, mille abil saab hõlpsasti analüüsida andmetabeleid, teha andmetöötlust ning andmete puhastamist. Selles praktikumis õpetatakse Pandas-e abil sisse lugema CSV faile. Pärast faili sisselugemist tehakse saadud andmetabelist esmane ülevaade, mis sisaldab ridade ja veergude arvu, veergude andmetüüpe, puuduvaid väärtusi ning lihtsamaid statistikuid. Lisaks õpetatakse andmeridade filtreerimist mingi tingimuse põhjal. Seejärel õpetatakse andmetabeli muutmist, sh uue rea lisamist, uue veeru lisamist, ridade ja veergude kustutamist ning ümbernimetamist. Lisaks näidatakse, kuidas puuduvaid väärtusi asendada. Masinõppe seisukoha pealt selgitatakse tunnuste väärtuste normaliseerimise ja standardiseerimise vajalikkust ning tehakse need teisendused läbi. Seejärel selgitatakse tunnuste arvuliseks kodeerimise vajadust ning viiakse praktiliselt läbi “label-encoder” ja “one-hot-encoder” näited.

Praktikumi iseseisva osana tuleb õpilastel ise valida mingisuguse andmestiku CSV fail, see sisse lugeda ning läbi viia sarnane töötlus ja esmane andmetabeli uurimine nagu eelnevas näites oli läbi tehtud.

5.3 Juhendatud masinõppe mudelite arendustsükkel

Masinõppest ja tehisintellektist andsime esmase ülevaate peatükis 2.2. Selles praktikumis saavad osalejad praktilise ülevaate masinõppe mudelitest ning nende loomise tsüklist (vt Lisa II 2.3). Osalejad tutvuvad tunnuste ning nende liikidega. Õpitakse, kuidas CSV faile sisse lugeda ja esmast ülevaadet kuvada. Tutvutakse andmete visualisatsioonidega nagu tulpdiagramm, histogrammid, hajuvusdiagrammid jne. Seejärel tutvustatakse andmete eeltöötlust ja selgitatakse nende vajalikkust masinõppes. Eeltöötlus sisaldab andmete puhastamist, standardiseerimist ja normaliseerimist, üks-mitmele kodeerimist jne.


Potentsiaalsete õppijate vajaduste välja selgitamisest oleme jõudnud järeldusele, et enamiku ülesannetest, mida nad soovivad lahendada, saab sõnastada juhendatud masinõppe ülesannetena. Seega selles praktikumis piirduakse ainult juhendatud masinõppe mudelite tutvustamisega, kuhu kuuluvad regressiooni- ja klassifitseerimismudelid. Ühe uuritava ja ühe kirjeldava tunnuse jaoks tuuakse välja hulk regressioonimudeleid ning nende mudelite poolt määratud graafikuid, et osalejatel tekiks esmane intuitsioon, kuidas mingi mudeli ennustusjoon välja näeb. Klassifitseerimismudelite puhul tehakse sama ning kuvatakse klassifitseerimise otsustuspiirid.

Seejärel selgitatakse mudeli treenimise olemust, treenimis- ja testandmete erinevust, ning pärast mudeli loomist tutvustatakse erinevaid mudeli headuse hindamise võimalusi nii regressiooni- kui ka klassifitseerimismudelite jaoks. Lõpuks rakendatakse loodud mudelit uutele andmete ennustuste tegemiseks.

5.4 Tootmisdefektide tuvastamine

Pildituvastusega tutvusime esmalt peatükis 2.3.1. Pildituvastuse rakendusvaldkondade spekter on väga lai ning objektituvastus on keeletöötuse kõrval üks tehisnärvivõrkude teine lai rakendusala.


Selles praktikumis õpivad osalejad kasutama tehisnärvivõrkudel põhinevaid mudeleid pildidel olevate objektide tuvastamiseks. Täpsemalt luuakse mudel, mis õpib eristama pilte tervetest ning katkistest metallvormidest (vt Lisa II 2.4). Tootmisdefektide automaatne tuvastamine aitab kokku hoida kvaliteedikontrollijate käsitsi tööd ja aega. Enne pildituvastuse näite juurde asumist antakse õpilastele lühike ülevaade tehisnärvivõrkudest. Seejärel tutvustatakse täpsemalt konvolutsioonilisi närvivõrke, mis sobivad pildituvastuseks paremini. Näide põhineb andmestikul, mis sisaldab 7348 pilti nii korras kui ka katkistest metallvormidest [43].



Joonis 25. A) Näiteid tervetest metallvormidest. B) Näiteid defektsetest metallvormidest.

Töö käigus õpitakse, kuidas pilte Pythonisse sisse lugeda ning millisel arvulisel kujul pildid Python-is salvestatud on. Seejärel viiakse läbi piltide märgendamine kas katkisteks või terveteks objektideks. Praktika käigus on õpilastel võimalik luua tehisnärvivõrkudel põhinev mudel, mis õpib eristama terveid ning katkiseid metallvorme.

Antud õppematerjali lõpus pakutakse õppijatele iseseisvalt lahendada praktilist ülesannet. Pärast õppematerjali põhiosa näite läbi tegemist tuleb kursusel osalejatel iseseisvalt koostada sarnane mudel, mis õpib eristama terveid ning mädanenud õunu. Piltide andmestik õuntest on osalejatele ette antud. Lisaks on iseseisev ülesanne varustatud samm-sammuliste juhistega ja tugineb järk-järgult õpitud teadmistele ja oskustele.



Joonis 26. Näiteid tervetest õuntest ja ühest mädanenud õunast (punases kastis).

5.5 Ennustav hooldus: hüdraulilise pressi seisukorra hindamine

Ennustava hoolduse kohta on esmane ülevaade antud peatükis 2.3.3. Ennustav hooldus võimaldab masina töö käigus saadavate sensorandmete põhjal automaatselt hinnata masina tehnilist seisukorda ning seda, kas masin hakkab saadud andmete põhjal katki minema. Ennustav hooldus aitab ennetada masinate katki minemist ning annab masinaoperaatorile või remontijale aegsasti teada, millal oleks mõistlik aeg masin ning tema komponendid üle vaadata.

Selle praktikumi eesmärk on õppida valima ja treenima masinõppe mudelit ennustava hoolduse jaoks. Praktikumis õpivad osalejad käsitlema sensorandmeid ning nende andmete põhjal masina seisukorda ennustavate või teisisõnu prognoosivate mudelite loomist (vt Lisa II 2.5). Andmestik koosneb eksperimentaalselt hüdraulilise pressi töö käigus saadud sensorandmetest. Iga sensori andmed on viidud eraldi tekstifaili. Õpilased koguvad kõikide sensorite andmed eraldi failidest ühtsesse andmetabelisse, mis edasist analüüsi hõlbustab.

Kasutatavad andmed pärinevad kaheksast erinevast sensorist ning need sensorid mõõdavad rõhku, mootori võimsust, mahuvoolu, temperatuuri, vibratsiooni, efektiivsustegurit, jahutusefektiivsust ning jahutusvõimsust. Lisaks on hüdraulilise pressi töösükli järel ära märgitud selle pressi erinevate komponentide tehniline seisukord: jahuti seisukord, kraani seisukord, sisemise pumba lekked ning hüdraulilise akumulaatori seisukord.

Kursusel osalejad loovad seejärel erinevaid mudeleid, mis leiavad seosed hüdraulilise pressi töö käigus tekkivate sensorite näitude ning selle pressi tehnilise seisukorra vahel, et ennustada hüdraulilise pressi katki minemist. Iga uuritava tunnuse jaoks tuleb luua oma mudel, ning proovida võiks erinevaid mudeleid. See annab õpilasele ettekujutuse, et sobiva mudeli leidmine on omaette protsess.

Iseseisva tööna valivad kursusel osalejad praktikumi käigus veel kasutamata masina komponendi ehk masinõppe terminoloogias tunnuse, mille seisukorda prognoosida. Pärast tunnuste valikut katsetavad osalejad seejärel iseseisvalt erinevaid masinõppe mudeleid ning valivad loodud mudelist parima.

5.6 Masinõpe aegridade mudeldamisel: energia nõudluse ja hinna ennustamine

Aegridade ning nõudluse prognoosimise kohta andsime esmase ülevaate peatükis 2.3.4.

Aegridade analüüsil põhinevate mudelite abil on võimalik prognoosida ajas muutuvaid suuruseid nagu energiakulu, nõudlus, hind jne. Aegridade analüüsil põhinevad mudelid kasutavad aegrea minevikus esinenud väärtusi ning leiavad sealt teatud seaduspärasused nagu üleüldise trendi ning perioodilised muutused. Seejärel ennustab mudel, kuidas aegrea väärtused tulevikus muutuvad.

Selles praktikumis õpivad osalejad uurima ning modelleerima aegridasid (vt Lisa II 2.6).

Nõudluse ja kulude ennustamist tehakse tihti aegridade analüüsi abil. Näiteks võib meil olla andmeid selle kohta, kui palju mingit toodet mingil perioodil müüdi, ning me tahame ennustada, kuidas selle toote nõudlus lähitulevikus võiks välja näha, ning aidata tööstusettevõttel tootmismahu planeerida. Aegridade modelleerimisel on traditsiooniliselt loodud statistilisi mudeleid nagu ARIMA, aga antud praktikumi käigus näidatakse õpilastele, kuidas aegridade prognoosimist saab teha ka masinõppe abil.

Näide viiakse läbi andmestikul, mis kirjeldab nelja aasta jooksul kogutud Hispaania ilmastiku andmeid, energia genereerimist, tarbimist jne [44]. Andmestik koosneb kahest failist. Praktikumis laeme esmalt mõlemad andmefailid sisse, seejärel tuvastame kuupäeva ja aega kirjeldava veeru ning viime selle sobivale formaadile. Seejärel visualiseerime parema intuitsiooni saamiseks mõningaid aegridasid. Aegridade esmaste seoste leidmiseks tutvustame õppijale ka auto- ja ristkorrelatsiooni (ingl *cross-correlation*) mõisteid. Lisaks lahutame aegridasid trendiks, sesoonseks ja juhuslikuks komponendiks.

Esmase mudeli loome kasutades traditsioonilist ARIMA mudelit ning visualiseerimine saadud mudeli ennustustäpsust graafiliselt. Pärast seda loome ka teise mudeli, mis põhineb sügavõppe meetodil LSTM (ingl *long-short term memory*). LSTM tehisnärvivõrk sobib aegridade väärtuste prognoosimiseks hästi, kuna suudab kasutada järjestatud andmeid (nagu kuupäevad ja neile vastavad väärtused). Pärast LSTM mudeli loomist visualiseerime ka selle mudeli ennustustäpsust uutel andmetel. Lõpuks võrdleme ARIMA ning LSTM mudelite täpsust.

6. Kokkuvõte ja tuleviku töö

Käesolevas magistritöös selgitas autor välja Eesti tööstusettevõtete põhilised vajadused ning takistused seoses tööstusprotsesside automatiseerimisega. Vajaduste, takistuste ning huvide väljaselgitamiseks kasutas autor varasemad uuringuid, ekspertintervjuusid ning enda loodud küsitlust.

Uuringute tulemustest tuli välja, et tööstusettevõtete automatiseerimise tase on üldiselt madal. Tööstus 4.0 tehnoloogiate ning tehisintellekti mõistega ning rakendustega üldiselt kursis ei olda, kuid huvi tehisintellekti valdkonna ning selle rakenduste kohta on olemas. Peamised põhjused, mis takistavad automatiseerivaid ja tehisintellekti hõlmavaid tehnoloogiaid kasutusele võtmast, on ebakindlus vastavate investeeringute tasuvuse suhtes, ning samuti teadmatus erinevate tehnoloogiate rakendusvõimalustest. Samuti näitasid uuringu tulemused, et ettevõtted sooviksid lahendada ärilisi ülesandeid, mida saaks kõige paremini tõlkida andmeanalüüsi ülesanneteks juhendatud masinõppe ülesandena. Küsitluse järgi olid vastajad enamjaolt tehisintellekti kohta õppimise jaoks valmis panustama 26 tundi ehk 1 EAP jagu aega. Saadud tulemuste põhjal koostas töö autor loodava kursuse kavandi. Pärast kavandi loomist koostas töö autor kursuse õppematerjalid.

Õppematerjalid on oma põhisisult Google Colab failid (Pyhoni vihikud), mis sisaldavad iga teema kohta praktilisi näiteid ning iseseisvaid ülesandeid. Praktilised näited on kirjutatud Pythoni programmeerimiskeeles. Kursuse moodulites 1-3 antakse sissejuhatus Pythoni programmeerimiskeelde, andmetöötlusesse ning masinõppe rakendamise metoodikasse. Kui vajaminevad teoreetilised eelteadmised ja esmane praktiline kogemus masinõppe mudelitega on omandatud, keskenduvad järgnevad õppemoodulid 3-6 juba konkreetsete rakenduslike mudelite loomisele tööstuse erinevates protsessides. Praktiliste näidete tutvustamisel keskendutakse CRISP-DM struktuurile. Kuna magistritöös viidi läbi ADDIE mudeli kursuse arenduse kolm esimest etappi viiest, siis kaks viimast etappi (kursuse läbiviimine ja hinnangu andmine) jääb väljapoole käesoleva magistritöö mahtu. Kursuse edasiarendus ja läbiviimine on planeeritud tuleviku töö osana.

7. Viidatud kirjandus

- [1] Kutsekoda. OSKA 2022. aasta ülevaade valdkonnaspetsiifiliste IKT-oskuste vajadustest. <https://oska.kutsekoda.ee/uuring/info-ja-kommunikatsioonitehnoloogia> (05.08.2022)
- [2] Mark Fišel. Tehisintellekt (LTAT.01.003). 2021: <https://ois2.ut.ee/#/courses/LTAT.01.003/details> (05.08.2022)
- [3] Dmytro Fishman. Masinõpe (MTAT.03.227). 2021. <https://ois2.ut.ee/#/courses/MTAT.03.227/details> (05.08.2022)
- [4] Raul Vincenta Zafra. Tehisnärvivõrgud (LTAT.02.001). 2021. <https://ois2.ut.ee/#/courses/LTAT.02.001/details> (05.08.2022)
- [5] Janno Jõgeva. Robootika (LOTI.05.010). 2021. <https://ois2.ut.ee/#/courses/LOTI.05.010/details> (05.08.2022)
- [6] AIRE - AI & Robotics Estonia. <https://aire-edih.eu/> (05.08.2022)
- [7] Dat4.zero. What is Industry 4.0? Kohandatud. <https://dat4zero.eu/what-is-industry-4-0/> (05.08.2022)
- [8] Ramesh Cooke. The Internet of Things in Manufacturing. 2019. <https://www.linkedin.com/pulse/internet-things-manufacturing-ramesh-cooke/> (05.08.2022)
- [9] Wikipedia. Big Data. 2022. https://en.wikipedia.org/wiki/Big_data (05.08.2022)
- [10] Wikipedia. Linear Regression. 2022. https://en.wikipedia.org/wiki/Linear_regression (05.08.2022)
- [11] Wikipedia. Decision Tree Learning. 2022. https://en.wikipedia.org/wiki/Decision_tree_learning (05.08.2022)
- [12] Tartu Ülikool. Tehisintellekti algkursus (LTAT.TK.013). 2020. https://courses.cs.ut.ee/2020/Tehisintellekti_algkursus/Main/PARTIII/Vorgud (05.08.2022)
- [13] Esko Kilpi. Neural networks as the architecture of human work. <https://medium.com/@EskoKilpi/neural-networks-as-the-architecture-of-human-work-3f9d20f019a3> (08.08.2022)
- [14] Keiron O'Shea, Ryan Nash. An Introduction to Convolutional Neural Networks. 2015. <https://arxiv.org/abs/1511.08458> (05.08.2022)
- [15] Chris Kevin. Feature Maps. Kohandatud. https://medium.com/@chriskevin_80184/feature-maps-ee8e11a71f9e (05.08.2022)
- [16] DAKSH Tools & Appliances. Metal Parts Supplier. 2022. <https://www.dakshtools.com/products/metal-parts-supplier/98> (05.08.2022)
- [17] Cchangcs. Garbage Classification. Kohandatud. <https://www.kaggle.com/datasets/asdasdasdasdas/garbage-classification> (05.08.2022)
- [18] Yann Lecun. Corinna Cortes. Cristopher J.C. Burges. MNIST andmestik. Kohandatud. <http://yann.lecun.com/exdb/mnist/> (05.08.2022)
- [19] Pamela Doan. Where's the Fruit? Kohandatud. <https://highlandscurrent.org/2016/09/12/wheres-the-fruit> (05.08.2022)
- [20] Elena Sügis. Tartu Ülikooli kursus "Tehisintellekti projekti planeerimine ja läbiviimine tööstusettevõttes" (LTAT.TK.024). 2022. <https://moodle.ut.ee/course/view.php?id=11824> (05.08.2022)

- [21] Ravirajsinh Dabhi. Casting product image data for quality inspection. Kohandatud. <https://www.kaggle.com/datasets/ravirajsinh45/real-life-industrial-dataset-of-casting-product> (05.08.2022)
- [22] Wikipedia. Autoregressive integrated moving average (ARIMA). 2022. https://en.wikipedia.org/wiki/Autoregressive_integrated_moving_average (05.08.2022)
- [23] Joseph Mushailov. LSTM Framework For Univariate Time-Series Prediction. 2011. <https://towardsdatascience.com/lstm-framework-for-univariate-time-series-prediction-d9e7252699e> (05.08.2022)
- [24] Ajay Pratap Singh Pundhir. Time Series Forecasting. Kohandatud. <https://medium.com/analytics-vidhya/time-series-forecasting-c73dec0b7533> (05.08.2022)
- [25] HITSA (Hariduse Infotehnoloogia Sihtasutus). Juhend kvaliteetse e-kursuse loomiseks. 2021. <https://oppevara.edu.ee/ekursus/#sissejuhatus> (05.08.2022)
- [26] John Nesbit, Karen Belfer, Tracey Leacock. Learning Objective Review Instrument (LORI). 2009. https://www.academia.edu/7927907/Learning_Object_Review_Instrument_LORI_Autor (05.08.2022)
- [27] Nick Hotz. What is CRISP DM? <https://www.datascience-pm.com/crisp-dm-2/> (05.08.2022)
- [28] Elena Sügis. Tehisintellekti projekti planeerimine ja läbiviimine tööstusettevõttes. <https://aire-edih.eu/yritus/?30531> (05.08.2022)
- [29] AIRE - AI & Robotics Estonia. Koolitus: ROS - Robot Operating System. <https://aire-edih.eu/en/event/?35061> (05.08.2022)
- [30] Tartu Ülikool. Kursus “Sissejuhatus andmeteadusesse” (LTAT.02.002). 2021. <https://courses.cs.ut.ee/2022/ids/spring> (08.08.2022)
- [31] Tartu Ülikool. MOOC “Andmeteaduse võimalused äriettevõttes”. 2021. <https://courses.cs.ut.ee/2021/atva/fall> (08.08.2022)
- [32] Mare Vähi. Tartu Ülikooli kursus Andmeanalüüs 2 (MTMS.01.007). 2021. <https://ois2.ut.ee/#/courses/MTMS.01.007/details> (07.08.2022)
- [33] Sven Laur. Tartu Ülikooli kursus Masinõpe 2 (LTAT.02.004). 2021. <https://courses.cs.ut.ee/2022/ml-ii/spring> (07.08.2022)
- [34] Liisi Himma, Raul Kirsimäe (Swedbank). Tööstusettevõtete uuring. 2021. <https://www.tartu.ee/sites/default/files/uploads/Ettevotlus/swedbankitoostusettevoteteuuring2021-210726110347.pdf> (05.08.2022)
- [35] Seido Kaur. Magistritöö “Tööstus 4.0 eesti masinatööstuse ettevõtete tarneahelas”. 2019. <https://digikogu.taltech.ee/et/Download/558607c9-bb8b-4747-99a8-6bc9e1846636> (05.08.2022)
- [36] Statistikaamet. Tööstus. 2022. <https://www.stat.ee/et/avasta-statistikat/valdkonnad/majandus/toostus> (05.08.2022)
- [37] CV Online. 2022. <https://cv.ee> (12.05.2022)
- [38] CV Keskus. 2022. <https://www.cvkeskus.ee> (12.05.2022)
- [39] E-krediidiinfo. 2022. <https://www.e-krediidiinfo.ee> (12.05.2022)

- [40] Google Colab. 2022. <https://research.google.com/colaboratory> (05.08.2022)
- [41] Coursera. 2022. <https://www.coursera.org> (05.08.2022)
- [42] Pandas. <https://pandas.pydata.org/> (08.08.2022)
- [43] Ravirajsinh Dabhi. Casting product image data for quality inspection. Kohandatud. <https://www.kaggle.com/datasets/ravirajsinh45/real-life-industrial-dataset-of-casting-product> (05.08.2022)
- [44] Nicholas Jhana. Hourly energy demand generation and weather. <https://www.kaggle.com/datasets/nicholasjhana/energy-consumption-generation-prices-and-weather> (08.08.2022)

Lisad

I. Küsitlus

Lõputöö raames koostatud vajaduste väljaselgitamise küsitlus, millele pääseb ligi lingil:
<https://forms.gle/KAg7f3NiKyN9qz6b9>

1. Mis on teie amet?

- Masinaoperaator,
- Kvaliteedijuht/kvaliteedikontrollija,
- Tootmisjuht,
- Laotöoline,
- Abitöoline,
- Kontoritöötaja,
- Seadistaja,
- Elektrik,
- Insener

2. Millises tööstusettevõttes teie ettevõtte tegutseb?

- Metallitööstus,
- Masinatööstus,
- Seadmetetootmine,
- Puidutööstus,
- Tekstiilitööstus,
- Toidutööstus,
- Elektroonika,
- Mööblitööstus,
- Muu töötlev tööstus

3. Kui mitu inimest teie ettevõttes töötab?

- 1 kuni 10 inimest,
- 10 kuni 50 inimest,
- 50 kuni 250 inimest,
- Rohkem kui 250 inimest

4. Hinda oma ettevõtte automatiseerituse taset järgnevates tööstusprotsessides.

- Tootmiskahtude prognoosimine,
- Tootmiskulude prognoosimine,
- Nõudluse prognoosimine,
- Tootmisliini etappide ajakulude arvestamine,

- Tootmismasinade hooldus,
- Toormaterjali töötlemine,
- Kvaliteedikontroll, sh defektsete toodete tuvastamine,
- Logistika ja laondus,
- Tootmisproduktide sorteerimine,
- Tootmisjääkide sorteerimine

5. Milliseid tehnoloogiaid teie ettevõtte oma tootmisprotsessides kasutab?

- Käsitsi juhitud masinad,
- Programmeeritud arvutijuhitud masinad (CNC),
- Äri/tootmisprotsesside kaardistamine ja analüüs,
- Internetivõrgu abil ühendatud seadmed,
- Autonoomsed ja dünaamiliselt kohanduvad masinad (nt robotkäsi),
- Sensorandmete kogumine, nende analüüs, jälgimine,
- Andmeanalüütika (nt PowerBI),
- Kaugjuhitavad seadmed,
- Digikaksikuid

6. Millised on teie ettevõttes uute automatiseerivate tehnoloogiate kasutamisele võtmise peamised takistused?

- Ei tea, kui võrd investeeringud vastavasse tehnoloogiasse ära tasuvad,
- Ei tea, millised on vastava tehnoloogia rakendusvõimalused,
- Pole aega või raha uutesse tehnoloogiatesse investeerida,
- Uus tehnoloogia nõuab liiga palju muudatusi olemasolevates protsessides,
- Puuduvad pädevad inimesed, kes oskaks vastavat tehnoloogiat kasutada ja/või juhtida,
- Ei tea vastavate tehnoloogiate pakkujaid,
- Ettevõtte sisepoliitika, standardid või kvaliteedinõuded

7. Milliseid objekte oleks teie ettevõttes kõige kasulikum kaamerapildi abil automaatselt tuvastada?

- Erinevaid tootmisdetaile,
- Katkiseid vs terveid esemeid/tootmisdetaile,
- Inimeste tööruumis viibimise automaatne tuvastamine,
- Inimeste nägusid (nt tööruumidele ligipääsu tarbeks või masina opereerimiseks),
- Tootmisjääkide/prügi liiki (nt jäätmete sorteerimise jaoks),

- Teksti pakenditel ja toodetel,
- Erinevaid tootmismaterjale,
- Erinevaid tööriistu

8. Mida sooviksite oma ettevõttes prognoosida?

- Tootmisprotsesside ajakulu prognoosimine,
- Tootmiskulude prognoosimine,
- Tootmismahude prognoosimine,
- Logistiliste kulude prognoosimine,
- Tootmisjääkide mahu prognoosimine,
- Optimaalsete tootmisparameetrite hindamine,
- Masinate tööea prognoosimine,
- Nõudluse/müüginumbrite prognoosimine

9. Milliste tehnoloogiate kohta sooviksite kõige enam omandada teadmisi?

- Tehisintellekti rakendused tööstuses,
- Tehisintellekti ja masinõppe teooria,
- Robotika,
- Pildituvastus- ja töötlus,
- Äri- ja tööstusprotsesside modelleerimine,
- Sensorid,
- Sensorandmete töötlus ja analüüs

10. Millisel kujul sobiks teile kõige rohkem uute tehnoloogiate kohta õppida?

- Videod,
- Veebiloengud,
- Seminarid,
- Projektitööd,
- Kontaktõpe,
- Kaugõpe,
- E-õpik

11. Kui suure ajalise mahuga kursus oleks teie jaoks realistlik?

- 3 Tundi,
- 10 Tundi,
- 25 Tundi,
- 50+ Tundi

II. Githubi repositoorium

1. Lõputöös koostatud õppematerjalid Pythoni keeles asuvad Github repositooriumis, millele pääseb ligi lingilt: <https://github.com/Reemet1/industry>

2. Samuti pääseb õppematerjalidele ligi Google Colaboratory keskkonnast:

2.1. Sissejuhatus Pythonisse

https://colab.research.google.com/drive/1CzAkKHli_AkQCHVlsoo95ANTWeK8u27L?usp=sharing

2.2. Andmete eeltöötlus:

<https://colab.research.google.com/drive/1tK0g-0IB69A4XNdwU1Y6HEn-VnyhUGWq?usp=sharing>

2.3. Sissejuhatus masinõppesse

https://colab.research.google.com/drive/1_pTbfOx7YcldP9bUoJaHYo9dYvq_eltF?usp=sharing

2.4. Tootmisdefektide tuvastamine:

<https://colab.research.google.com/drive/1295AUxXTjOZfOOVSfSnu5PcWqqRSclbT?usp=sharing>

2.5. Ennustav hooldus:

<https://colab.research.google.com/drive/1Tlx1DjbvO-29MC9vTMy-2sPR7p2bXy9X?usp=sharing>

2.6. Aegridade analüüs:

<https://colab.research.google.com/drive/1XkIz9uvpHtKv0bH5ixEQFNGDhONLbpWt?usp=sharing>

3. Väljatöötatud õppematerjalide baasil toimuv kursus on planeeritud teha õpilastele kättesaadavaks Tartu Ülikooli Coursera õppeplatvormi kaudu: <https://www.coursera.org/learn/tehisintellekt>

III. Litsents

Lihtlitsents magistriprojekti reprodutseerimiseks ja üldsusele kättesaadavaks tegemiseks.

Mina, Reemet Ammer,

1. Annan Tartu Ülikoolile tasuta loa (lihtlitsentsi) minu loodud teose "Tööstusettevõtetele suunatud praktiline tehisintellekti lühikursus", mille juhendajad on Jaak Vilo ja Elena Sügis, reprodutseerimiseks eesmärgiga seda säilitada, sealhulgas lisada digitaalarhiivi DSpace kuni autoriõiguse kehtivuse lõppemiseni.
2. Annan Tartu Ülikoolile loa teha punktis 1 nimetatud teos üldsusele kättesaadavaks Tartu Ülikooli veebikeskkonna, sealhulgas digitaalarhiivi DSpace kaudu Creative Commons'i litsentsiga CC BY NC ND 3.0, mis lubab autorile viidates teost reprodutseerida, levitada ja üldsusele suunata ning keelab luua tuletatud teost ja kasutada teost ärieesmärgil, kuni autoriõiguse kehtivuse lõppemiseni.
3. Olen teadlik, et punktides 1 ja 2 nimetatud õigused jäävad alles ka autorile.
4. Kinnitan, et lihtlitsentsi andmisega ei riku ma teiste isikute intellektuaalomandi ega isikuandmete kaitse õigusaktidest tulenevaid õigusi.

Reemet Ammer 08.08.2022