

Факултет инжењерских наука Универзитета у Крагујевцу



Назив студијског програма: Машинско инжењерство

Ниво студија: Мастер академске студије

Модул: Машинске конструкције и механизација

Предмет: Примена рачунара у развоју производа

Број индекса: 429/2018

Наталија А. Пантелић

Машинско учење и машинско конструисање

Мастер рад

Комисија за преглед и одбрану:

1. Др Ненад Марјановић ред. проф. - ментор

2. _____

3. _____

Датум одбране: _____

Оцена: _____

У оквиру овог рада кандидат треба да представи дефиниције вештачке интелигенције и машинског учења и затим да прикаже могућности примене машинског учења у креативним активностима конструисања.

Препоручена литература:

- [1] Z. Nagy, *Основе вештачке интелигенције и машинског учења*, Компјутер библиотека, Београд, 2019.
- [2] B.J. Copeland, *Artificial intelligence*, University of Canterbury, Christchurch, New Zealand, 2020.
- [3] С. Бранковић, *Вештачка интелигенција и друштво*, Филозофски факултет, Ниш, 2017.

Крагујевац, 2020.

ментор:

Др Ненад Марјановић, ред. проф.

РЕЗИМЕ

У оквиру рада описане су основе вештачке интелигенције и машинског учења и објашњене неке основне дефиниције. Такође, дат је и преглед различитих метода вештачке интелигенције и алгоритама машинског учења. Затим, дати су и разни примери њихове примене. На крају рада, могућности примене машинског учења у активностима конструисања су илустроване конкретним примерима.

Кључне речи: интелигенција, конструисање, учење

ABSTRACT

The paper describes the basics of artificial intelligence and machine learning and explains some basic definitions. Also, an overview of different methods of artificial intelligence and machine learning algorithms is given. Then, various examples of their application are given. At the end of the paper, the possibilities of applying machine learning in construction activities are illustrated with concrete examples.

Key words: intelligence, construction, learning

Садржај

1. Увод	1
2. Вештачка интелигенција	2
2.1 Појам интелигенције	3
2.1.1 Компоненте интелигенције	3
2.1.1.1 Учење	4
2.1.1.2 Расуђивање	4
2.1.1.3 Решавање проблема	5
2.1.1.4 Перцепција	5
2.1.1.5 Језик	5
2.2 Историја вештачке интелигенције	6
2.3 Структура вештачке интелигенције	9
2.4 Разноврсност дисциплина	9
2.5 Примена вештачке интелигенције	10
2.5.1 Симулација људског понашања	10
2.5.1.1 Слушање и говор	10
2.5.1.2 Разумевање језика	11
2.5.1.3 Памћење	11
2.5.1.4 Размишљање	11
2.5.1.5 Вид	11
2.5.1.6 Покрет	11
2.5.2 Симулирање интелигенције - Турингов тест	12
2.6 Категоризација вештачке интелигенције	12
2.7 Методе вештачке интелигенције	12
2.7.1 Симболични и конекционистички приступи	12
2.7.2 Јака вештачка интелигенција, примењена вештачка интелигенција и когнитивна симулација	13
2.8 Циљеви вештачке интелигенције	14
2.9 Будућа разматрања	15
3. Машинско учење	17
3.1 Методе машинског учења	19
3.1.1 Надгледано учење	19

3.1.2 Ненадгледано учење.....	21
3.1.3 Класификација наспрам груписања.....	22
3.1.4 Полунадгледано учење.....	23
3.1.5 Учење са подршком	23
3.2 Примена машинског учења	24
3.2.1 Примери примене машинског учења.....	25
4. Разлика између вештачке интелигенције и машинског учења	27
5. Дубоко учење и неуронске мреже	28
5.1 Дубоко учење	28
5.1.1 Начин функционисања дубоког учења.....	28
5.1.2 Важност дубоког учења	30
5.1.3 Примери дубоког учења.....	31
5.1.4 Разлика између машинског учења и дубоког учења	31
5.1.5 Стварање и обучавање модела дубоког учења.....	32
5.2 Неуронска мрежа	33
5.2.1 Начин функционисања неуронских мрежа	33
5.2.2 Архитектура неуронске мреже	34
5.2.3 Примена неуронских мрежа.....	34
5.2.4 Периодичност	35
5.2.5 Технике коришћене са неуронским мрежама	35
5.2.5.1 Надгледано учење	36
5.2.5.2 Класификација	36
5.2.5.3 Регресија.....	36
5.2.5.4 Препознавање образаца	36
5.2.5.5 Ненадгледано учење	36
5.2.5.6 Груписање	36
6. Могућности примене машинског учења у креативним активностима конструисања	37
6.1 Аутономна обрада геометрије коришћењем машинског учења	37
6.1.1 Фаза 1: Дефиниција проблема	39
6.1.2 Фаза 2: Дефиниција проблема	40
6.1.3 Изазови у примени машинског учења на геометријске податке	40
6.1.3.1 Припрема скупа података	41

6.1.3.2 Скупови података.....	41
6.1.3.3 Генерисање карактеристика	42
6.1.3.4 Анализа и визуализација података	43
6.2 Помагање у конструисању кроз машинско учење.....	43
6.2.1 Конволуционе неуронске мреже.....	44
6.2.2 Преседани	44
6.2.2.1 Конволуционе неуронске мреже са више приказа за препознавање 3D облика	44
6.2.2.2 3D револуционарна неуронска мрежа за препознавање објекта у реалном времену	44
6.2.2.3 Волуметријске репрезентације и машинско учење у конструисању	45
6.2.3 Дефиниција модела	45
6.2.3.1 Извор података и генерисање.....	45
6.2.3.2 Класификација	46
6.2.4 Уклапање	47
6.2.5 Закључно разматрање.....	48
6.3 Методологија за класификацију делова уз надгледано машинско учење	48
6.3.1 Спецификација проблема и сродни радови.....	50
6.3.2 Приступ класификацији машинских делова	51
6.3.2.1 Прикупљање података	52
6.3.2.2 Издајање својстава	55
6.3.2.3 3D сферне хармонике	55
6.3.2.4 Геометријска статистика	56
6.3.2.5 Унутрашња растојања.....	57
6.3.2.6 Расподела облика	57
6.3.2.7 Дескриптор светлосног поља	57
6.3.2.8 Истраживачка анализа простора карактеристика	58
6.3.2.9 Претходна обрада простора карактеристика	58
6.3.2.10 Избор карактеристика.....	60
6.3.2.11 Смањење карактеристика	60
6.3.3 Моделирање класификатора	61
6.3.4 Анализа резултата	61
6.3.5 Закључна разматрања.....	64

7. Пример конструисања фелне за аутомобиле помоћу машинског учења	66
7.1 Маса фелне.....	67
7.2 Толеранције положаја отвора и храпавост	67
7.3 Облик фелне.....	68
7.4 Толеранција облика фелне	68
7.5 Димензије конструкције	68
7.6 Технологија израде	69
8. Закључак.....	70
Литература.....	72

1. Увод

Вештачка интелигенција је наука која се користи за стварање интелигенције помоћу хардверских и софтверских решења [1].

Инспирисана је обрнутим инжењерингом, на пример, како неурони делују у људском мозгу. Наш мозак се састоји од малих јединица које се називају неурони, а њихова мрежа се назива неуронска мрежа. Поред неуронских мрежа, у неуронауци постоји много других модела који се могу користити за решавање стварних проблема вештачке интелигенције.

Дакле, вештачка интелигенција је способност дигиталног рачунара или рачунарско контролисаног робота да обавља задатке који су обично повезани са интелигентним бићима. Овај израз се често примењује за пројекат развоја система који су обдарени интелектуалним процесима карактеристичним за људе, као што су способност расуђивања, откривања значења, генерализације или учења из претходног искуства. Од развоја дигиталног рачунара четрдесетих година прошлог века, показано је да рачунари могу бити програмирани да обављају веома сложене задатке, као што су, на пример, откривање доказа за математичке теореме или играње шаха. Ипак, упркос сталном напретку у брзини обраде рачунара и капацитету меморије, још увек нема програма који могу да се ускладе са људском флексибилношћу у ширим доменима или у задацима који захтевају пуно свакодневног знања. Са друге стране, неки програми су достигли ниво перформанси људских стручњака и професионалаца у обављању одређених специфичних задатака, тако да се вештачка интелигенција у овом ограниченом смислу може наћи у разним применама, као што су медицинска дијагноза, рачунарски претраживачи и препознавање гласа или рукописа [2].

Машинско учење је појам који се често меша са вештачком интелигенцијом. Први пут га је дефинисао *Arthur Lee Samuel* као област науке у којој рачунари могу да уче без експлицитног програмирања [1].

Tom Mitchell предложио је математички прецизнију дефиницију машинског учења. Каже се да рачунарски програм учи из искуства E у вези са задатком T и мером перформанси P , ако се његове перформансе у T , мерене метрикама P , побољшавају искуством E .

Из ове две дефиниције може се закључити да је машинско учење начин за постизање вештачке интелигенције. Међутим, вештачка интелигенција може постојати без машинског учења. На пример, ако се изричито наведу правила и стабла одлука или ако се користе технике претраживања, могуће је направити агента вештачке интелигенције, чак и ако приступ нема никакве везе са машинским учењем.

2. Вештачка интелигенција

Вештачка интелигенција је начин закључивања и поступања по закључцима, у потпуности ослањајући се на логику, где мишљење и дело не спроводе људи или било који други живи организам, већ машине у најширем смислу те речи. Под машином се не мисли на традиционално значење те речи, односно гломазан уређај направљен од осовина, челичних зупчаника и ланаца, већ на све оно што самостално испуњава неке сложене функције и није живо биће. У класичном смислу, то заиста могу бити машине опремљене софтвером који их води, или чисте виртуалне, нефизичке јединице: софтверске апликације које немају видљив физички изглед за обично људско биће. Оне се често физички не налазе на једном месту, али су активне на великом броју виртуелних адреса и истовремено могу обављати операције на милијардама различитих просторних тачака широм света, па чак и у својој орбити [3].

Дакле, вештачка интелигенција се односи на симулацију људске интелигенције у машинама које су програмиране да мисле попут људи и опонашају њихово деловање. Овај израз се такође може применити на било коју машину која показује својства повезана са људским умом, попут учења и решавања проблема [4].

Идеална карактеристика вештачке интелигенције је њена способност да рационализује и предузме радње које имају најбоље шансе за постизање одређеног циља.

Вештачка интелигенција заснива се на принципу да се људска интелигенција може дефинисати на такав начин да је машина лако опонаша и извршава задатке, од најједноставнијих до оних који су сложенији. Циљеви вештачке интелигенције укључују:

- учење,
- расуђивање и
- перцепцију.

Како технологија напредује, претходна мерила која су дефинисала вештачку интелигенцију постају застарела. На пример, машине које израчунавају основне функције или препознају текст оптималним препознавањем знакова више се не сматрају вештачком интелигенцијом, јер је ова функција сада узета здраво за готово као својствена функција рачунара.

Вештачка интелигенција се непрекидно развија у корист многих различитих индустрија. Маchine су повезане помоћу интердисциплинарног приступа заснованог на математици, рачунарској науци, лингвистици, психологији и још много тога.

Вештачка интелигенција дефинисана је као начин закључивања и реаговања на закључке који се у потпуности ослањају на логику, при чему то не раде људи, већ машине у најширем смислу.

Вештачка интелигенција је класификована:

- 1) према областима примене, почев од интелигентне телефоније, као вештачке метаинтелигенције, преко економије, комуникације, забаве, културе, државне управе и
- 2) према степену интелектуалности, прво као средство које рутински обавља одређене задатке, и друго као интелигентна машина која, слично људској интелигенцији, развија способност учења.

Вештачка интелигенција је епохална новост у историји људске цивилизације. Њени почеци јављају се са кибернетиком и аутоматизацијом, а њен развој се у почетку фокусирао на машине и роботе, посебно на свемирску и сличну технологију. Међутим, појава и масовна примена дигитализације довели су до снажног ширења вештачке интелигенције и проширили њено поље деловања на практично сва подручја људског живота. Придев „паметни“ почео је да краси све већи број именица: паметна машина, паметни телефон, аутомобил, град, паметна играчка, зграда, осветљење, учионица, табла, што најбоље илуструје брзо ширење вештачке интелигенције.

2.1 Појам интелигенције

Интелигенција је дефинисана из перспективе различитих научних дисциплина и може се различито одређивати у зависности од гледишта појединих дисциплина [3].

У најширем смислу, интелигенција се може описати као вештина и пракса:

- перцепције и сазнавања света око себе, укључујући самосазнавање,
- проналажења начина за сопствени опстанак и добробит,
- поштовања друштвених норми до те мере да одређена особа или група нађе своје место у друштву и оправдава своје право на постојање,
- налажења начина за постизање постављених циљева, барем у елементарној мери.

У овом основном облику интелигенције може се говорити и о интелигенцији животиња, па чак и биљака.

Друго поље интелигенције је на много вишем нивоу: то је посматрање и описивање дубљих законитости и односа у природном, друштвеном и духовном свету, посебно са циљем сталног унапређења квалитета живота. На истом нивоу је уметничка спознаја и изображавања света и живота, било вербално, визуелно, звучно, у облику скулптура или грађевина, затим позоришна, балетска, спортска или друга игра, као и све остало што се практикује у циљу да постигнете одређено задовољство и срећа.

Трећи и најапстрактнији ниво је област метафизике, односно спекулативна филозофија и „знање ради знања“, а не само ради остваривања мање или више практичних циљева, као и „уметност ради уметности“.

2.1.1 Компоненте интелигенције

Све осим најједноставнијег људског понашања приписује се интелигенцији [2].

Психолози генерално не карактеришу људску интелигенцију само једном особином, већ комбинацијом многих различитих способности.

Истраживања у вештачкој интелигенцији су се углавном фокусирала на следеће компоненте интелигенције:

- учење,
- расуђивање,
- решавање проблема,
- перцепцију и
- коришћење језика.

2.1.1.1 Учење

Постоји неколико различитих облика учења који се примењују на вештачку интелигенцију. Најједноставније је учење покушајима и грешкама. На пример, једноставан компјутерски програм за решавање шаховских проблема може покушати да се креће насумично док не нађе мат. Програм тада може да сачува решење са позицијом тако да ће следећи пут када се рачунар нађе у истој тој позицији повући то решење. Ово једноставно памћење појединачних предмета и поступака, познато као учење напамет, релативно је лако имплементирати на рачунар. Још је изазовнији проблем спровођења оног што се назива генерализацијом. Генерализација укључује примену претходног искуства на аналогне нове ситуације. На пример, програм који учи прошло време регуларних енглеских глагола учењем напамет неће моћи да произведе прошло време речи као што је „jump“, осим ако претходно није представљена са „jumped“, док програм који може да генералише може да научи правило „додај -ed“ и тако формира прошло време глагола „jump“ на основу искуства са сличним глаголима [2].

2.1.1.2 Расуђивање

Расуђивање је извлачење закључака који су одговарајући ситуацији. Закључци су класификовани као [2]:

- дедуктивни или
- индуктивни.

Најзначајнија разлика између ових облика расуђивања је та што у дедуктивном случају истина гарантује истинитост закључка, док у индуктивном случају истина даје потпору закључку без давања апсолутне сигурности.

Индуктивно закључивање је уобичајено у науци, где се прикупљају подаци и развијају оквирни модели за опис и предвиђање будућег понашања, све док појава аномалних података не натера модел да буде ревидиран.

Дедуктивно расуђивање је уобичајено у математици и логици, где су сложене структуре непобитних теорема изграђене из малог скупа основних аксиома и правила.

Дошло је до значајног успеха у програмирању рачунара за извођење закључака, нарочито дедуктивних. Међутим, истинско расуђивање укључује више него само извлачење закључака. Оно укључује извлачење закључака релевантних за решење одређеног задатка или ситуације. Ово је један од најтежих проблема са којим се суочава вештачка интелигенција.

2.1.1.3 Решавање проблема

Решавање проблема, посебно у вези са вештачком интелигенцијом, може се окарактерисати као систематска претрага низом могућих акција како би се постигао неки унапред дефинисани циљ или решење. Методе решавања проблема деле се на методе [2]:

- посебне и
- опште намене.

Метода посебне намене прилагођена је одређеном проблему и често користи веома специфичне карактеристике ситуације у којој је проблем уграђен.

Супротно томе, метода опште намене је применљива на широк распон проблема. Једна од техника опште намене која се користи у вештачкој интелигенцији је анализа крајњег циља, корак по корак или инкрементално, смањењем разлике између тренутног стања и крајњег циља.

Многи разнолики проблеми су решени програмима вештачке интелигенције. Неки примери су проналажење победничког потеза (или редоследа потеза) у друштвеној игри, осмишљавање математичких доказа и манипулација „виртуелним објектима“ у рачунарско-генерисаном свету.

2.1.1.4 Перцепција

У перцепцији се околина скенира помоћу различитих чулних органа, стварних или вештачких, а приказ се разлаже у посебне објекте у различитим просторним односима. Анализа је компликована чињеницом да се објекат може појавити различит у зависности од угла из којег се посматра, правца и интензитета осветљења у приказу и колико се објекат разликује од околног поља [2].

Тренутно је вештачка перцепција довољно добро развијена да би омогућила оптичким сензорима да идентификују појединце, аутономна возила која се возе умереном брзином по отвореном путу и сл.

2.1.1.5 Језик

Језик је систем знакова који имају значење по конвенцији. У том смислу, језик не треба да буде ограничен на изговорену реч. На пример, саобраћајни знакови формирају минијезик, а то је питање конвенције Δ која значи „опасност испред“ у неким земљама [2].


Важна карактеристика људских језика, за разлику од саобраћајних знакова, је њихова продуктивност. Продуктивни језик може формулисати неограничену количину реченица.

Релативно је лако написати рачунарске програме који су у стању да, у строго ограниченом контексту, течно одговоре људским језиком на питања и изјаве. Иако ниједан од ових програма заправо не разуме језик, они могу стићи до тачке у којој се њихово познавање језика не разликује од уобичајеног човека.

2.2 Историја вештачке интелигенције

Интелигентни роботи и вештачки живот први пут су се појавили у древним грчким митовима антике. Аристотелов развој силогизма и његова употреба дедуктивног расуђивања били су кључни тренутак у тежњи човечанства да разуме сопствену интелигенцију. Иако су корени дуги и дубоки, историја вештачке интелигенције о којој се данас размишља постоји мање од једног века [5].

Преглед најважнијих догађаја у историји вештачке интелигенције (слика 2.1) [5, 6]:



Слика 2.1. Историја вештачке интелигенције [6]

Сазревање вештачке интелигенције (1943-1952)

- Година 1943: *Warren McCullough* и *Walter Pitts* објављују „Логички рачун идеја које се налазе у нервним активностима“. У раду је предложен први математички модел за изградњу неуронске мреже.

- Година 1949: У својој књизи „Организација понашања: неуропсихолошка теорија“, *Donald Hebb* предлаже теорију да се неуронски путеви створе из искустава и да везе између неурона постају јаче што се чешће користе. *Hebb*-ово учење и даље је важан модел вештачке интелигенције.
- Година 1950: *Alan Turing* објављује рад „Рачунарске машине и интелигенција“, предлажући оно што је данас познато као Турингов тест, односно метод за утврђивање да ли је машина интелигентна.

Рођење вештачке интелигенције (1952-1956)

- Година 1952: *Arthur Samuel* развија програм само-учења за играње игре даме.
- Година 1954: Експеримент машинског превођења *Georgetown-IBM* аутоматски преводи 60 пажљиво изабраних руских реченица на енглески.
- Година 1955: *Allen Newell* и *Herbert A. Simon* креирали су „први програм вештачке интелигенције“ који је назван „Теоретичар логике“. Овај програм је доказао 38 од 52 математичке теореме и пронашао нове и елегантније доказе за неке теореме.
- Година 1956: Израз „Вештачка интелигенција“ први је усвојио амерички рачунарски научник *John McCarthy* на конференцији у *Dartmouth*-у.

Златне године - рани ентузијазам (1956-1974)

- Година 1958: *John McCarthy* развија програмски језик вештачке интелигенције *Lisp* и објављује рад „Програми са здравим разумом“. У раду је предложен хипотетички саветник, комплетан систем вештачке интелигенције са способношћу да учи из искуства једнако ефикасно као и људи.
- Година 1963: *John McCarthy* покреће лабораторију вештачке интелигенције на Станфорду.
- Година 1966: Истраживачи су истакли развој алгоритама који могу решити математичке проблеме. *Joseph Weizenbaum* је 1966. године створио први „chatbot“ који је назван *ELIZA*.
- Година 1972: У Јапану је направљен први интелигентни хуманоидни робот који је назван *WABOT-1*.

Прва зима вештачке интелигенције (1974-1980)

- Зима вештачке интелигенције односи се на временски период у којем су се рачунарски научници суочили са великим недостатком финансијских средстава од стране владе за истраживање вештачке интелигенције. Током овог периода интересовање јавности за вештачку интелигенцију је смањено.

Успон вештачке интелигенције (1980-1987)

- Година 1980: Након прве зиме, вештачка интелигенција се вратила са „*Expert System*“-ом. Програмирани су експертски системи који oponaшају способност одлучивања људског стручњака. Такође, ове године на Универзитету Станфорд

одржана је прва национална конференција „Америчког удружења за вештачку интелигенцију“.

- Година 1982: Јапанско министарство међународне трговине и индустрије покреће амбициозни пројекат „Рачунарски системи пете генерације“ (*Fifth Generation Computer Systems - FGCS*). Циљ *FGCS*-а је да развије перформансе сличне компјутеру и платформу за развој вештачке интелигенције.
- Година 1983: Као одговор на јапански *FGCS*, америчка влада покреће „Иницијативу за стратешко рачунање“ (*Strategic Computing Initiative*) ради пружања истраживања у напредном рачунару и вештачкој интелигенцији, које финансира *DARPA*.
- Година 1985: Компаније троше више од милијарду долара годишње на стручне системе, а читава индустрија, позната као тржиште машина *Lisp*, излази да их подржи. Компаније попут *Symbolics* и *Lisp Machines Inc.* граде специјализоване рачунаре како би радили на програмском језику вештачке интелигенције *Lisp*.

Друга зима вештачке интелигенције (1987-1993)

- Година 1987: Како се рачунарска технологија побољшавала, појавиле су се јефтиније алтернативе и тржиште *Lisp* машина је пропало, покренувши „другу зиму вештачке интелигенције“. Током овог периода, стручни системи су се показали прескупим за одржавање и ажурирање.
- Година 1992: Јапан прекида *FGCS* пројекат, наводећи неуспех у испуњавању амбициозних циљева зацртаних деценију раније.
- Година 1993: *DARPA* прекида „Иницијативу за стратешко рачунање“ након што је потрошила скоро милијарду долара и пала далеко изнад очекивања.

Појава интелигентних агената (1993-2011)

- Година 1997: *IBM*-ов *Deep Blue* победио је светског првака у шаху *Gary Kasparov*-а.
- Година 2002: Вештачка интелигенција је први пут ушла у домове у виду *Roomba*, усисивача.
- Година 2006: Вештачка интелигенција је стигла у пословни свет. Компаније попут *Facebook*-а, *Twitter*-а и *Netflix*-а такође су почеле да користе вештачку интелигенцију.

Дубоко учење, велики подаци и вештачка општа интелигенција (2011-данас)

- Година 2008: *Google* је направио напредак у препознавању говора и представио ову функцију у својој *iPhone* апликацији.
- Година 2011: *IBM*-ов *Watson* победио је у квизу *Jeopardy*, где је морао да реши сложена питања, као и загонетке. *Watson* је доказао да може разумети природни језик и може брзо решити трик питања.
- Година 2012: *Google* је представио функцију за андроид апликацију „*Google now*“ која је могла да пружи информације кориснику као предвиђање.

- Година 2014: „*Chatbot Eugene Goostman*“ победио је на такмичењу у злогласном „Туринговом тесту“.
- Година 2016: *Google DeepMind*-ов *AlphaGo* победио је светског првака *Go* играча *Lee Sedol*-а. Сложеност древне кинеске игре сматрана је главном препреком за уклањање у вештачкој интелигенцији.
- Година 2018: *IBM*-ов „*Project Debater*“ расправљао је о сложеним темама са два главна дебatera и такође је имао изузетно добре резултате. Такође, *Google* је демонстрирао програм вештачке интелигенције „*Duplex*“ који је био виртуелни асистент и који је заказао фризера на позив, а да даме са друге стране нису приметиле да разговарају са машином.

Сада се вештачка интелигенција развила до изузетног нивоа. Концепт дубоког учења, великих података и науке о подацима данас се креће попут процвата. Данас компаније попут *Google*-а, *Facebook*-а, *IBM*-а и *Amazon*-а сарађују са вештачком интелигенцијом и стварају невероватне уређаје. Будућност вештачке интелигенције инспиративна је и доћи ће са великом интелигенцијом.

2.3 Структура вештачке интелигенције

Вештачка интелигенција састоји се од најмање пет компоненти [3]:

- 1) *сазнавање* - усредсређивање на информације потребне за обављање задатака, систематско претраживање различитих популација, посматрање и евидентирање података и њихово прикупљање, класификовање и мерење,
- 2) друга компонента је *закључивање* које се заснива на сазнавању - било да је реч о примени формалних логичких правила закључивања, тј. дедуктивном извлачењу закључака или индуктивном опажању правилности у некој појави,
- 3) трећа је *практично поступање* по донесеним закључцима, уколико се то тражи од интелигентне машине,
- 4) четврта је *процена успешности закључивања и поступања*,
- 5) пета је *учење* (на основу процене успешности) и *корекција* елемената 1, 2 и 3 на основу добијених резултата или последица.

Ово није линеарни пут, али захваљујући петој тачки у овом моделу, пре би могао да се назове спиралом, где се спирала креће према горе.

2.4 Разноврсност дисциплина

На пример, аутомобил који се креће самостално и не може „осетити“ да се и други аутомобили крећу истим аутопутем био би врло опасан. Агент вештачке интелигенције мора процесуирати и „осетити“ шта се дешава око њега како би возио аутомобил. Међутим, то само по себи није довољно. Без разумевања физике објеката који се крећу, вожња аутомобила у нормалном окружењу била би готово немогућа [1].

У креирању употребљивог решења вештачке интелигенције укључене су различите дисциплине. На пример:

- роботика - за померање предмета у простору,
- теорија алгоритма - за конструисање ефикасних алгоритама,
- статистика - за добијање корисних резултата, предвиђање будућности и анализа прошлости,
- психологија - за моделирање начина функционисања људског мозга,
- софтверски инжењеринг - за креирање решења која се могу одржавати и издржати тест времена,
- рачунарска наука или рачунарско програмирање - за примену софтверских решења у пракси,
- математика - за извођење сложених математичких операција,
- теорија контроле - за креирање система за прослеђивање и поврат информација,
- теорија информације - за представљање, кодирање, декодирање и компресовање информација,
- теорија графика - за моделирање и оптимизацију различитих тачака у простору и за представљање хијерархија,
- физика - за моделирање стварног света,
- рачунарска графика и обрада слика - за приказивање и обраду слика и филмова.

2.5 Примена вештачке интелигенције

2.5.1 Симулација људског понашања

Људи имају пет основних чула: вид, слух, додир, мирис и укус. Међутим, у циљу бољег разумевања како настају интелигентне машине, потребно је раздвојити дисциплине на следећи начин [1]:

- слушање и говор,
- разумевање језика,
- памћење,
- размишљање,
- вид и
- покрет.

2.5.1.1 Слушање и говор

Вештачка интелигенција може да прикупља информације користећи систем за препознавање говора. Помоћу синтезе говора, интерни подаци се могу претворити у разумљиве звукове. Технике препознавања говора и синтезе говора препознају и конструишу звукове које људи емитују или које могу да разумеју [1].

Уколико нека особа путује у земљу у којој се говори језик који не разуме, она може да говори у микрофон свог телефона и да очекује да телефон „разуме“ оно што говори, а затим то преведе на други језик. Исто је и супротно, односно када локални становник говори, вештачка интелигенција преводи звукове на језик који та особа разуме. Препознавање говора и синтеза говора то омогућавају.

2.5.1.2 Разумевање језика

Природни језик се може разумети уколико се обради. Ово подручје је познато као обрада природног језика (*Natural Language Processinga - NLP*) [1].

Када је у питању обрада природног језика, језици се уче на основу статистичког учења.

2.5.1.3 Памћење

Уколико свету треба представити нешто познато, да би се то постигло, стварају се базе знања и хијерархијске репрезентације, које се називају онтологије. Онтологије категоризују елементе и идеје и садрже везе између тих категорија [1].

2.5.1.4 Размишљање

Систем вештачке интелигенције треба да буде експерт у одређеној области коришћењем експертског система, који може бити заснован на математичкој логици, на детерминистички начин, као и на нејасан, односно недетерминистички начин [1].

База знања експертског система представљена је коришћењем различитих техника. Како проблем с доменом расте, стварају се хијерархијске онтологије.

Могуће је поновити ову структуру моделирањем мреже на градивним блоковима мозга. Ови градивни блокови се називају неурони, а сама мрежа се назива неуронска мрежа.

Постоји још један кључни појам који треба повезати са неуронским мрежама, а то је дубоко учење. Ово учење је дубоко, јер надилази образац препознавања и категоризације. Утиснуто је на неуронску структуру мреже. На пример, посебан задатак дубоког учења је препознавање предмета уз помоћ рачунарског вида.

2.5.1.5 Вид

Уколико је потребно видети нешто, у том случају треба створити технике рачунарског вида, за учење о окружењу. Препознавање лица је корисно и углавном су људи експерти за то [1].

Рачунарски вид зависи од обраде слике. Иако обрада слике није директно дисциплина вештачке интелигенције, она је неопходна дисциплина за вештачку интелигенцију.

2.5.1.6 Покрет

Покрет и додир су природни за људе, али веома сложени задаци за рачунаре. Покрет се одвија уз помоћ роботике, која је математички захтевна тема [1].

Роботика се заснива на теорији контроле у којој се ствара повратна петља и контролише кретање објекта на основу прикупљених повратних информација. Занимљиво је да теорија контроле проналази примену и у другим областима које немају апсолутно никакве везе са кретањем објеката у простору. Разлог је чињеница да су потребне повратне петље сличне онима које су моделиране у економији.

2.5.2 Симулирање интелигенције - Турингов тест

Alan Turing, изумитељ Турингове машине, апстрактног концепта теорије алгоритама, предложио је начин за тестирање интелигенције. Овај тест се у литератури вештачке интелигенције назива Турингов тест [1].

Испитивач четује са особом и *chatbot*-ом преко текстуалног интерфејса. Задатак *chatbot*-а је да превари испитивача до те мере да не може да каже да ли је човек или не.

Да би се успешно завршио Турингов тест пре свега, треба да се разуме говорни језик да би се знало шта испитивач говори, што се постиже обрадом природног језика (*Natural Language Processing* - *NLP*). Такође, неопходно је одговорити испитивачу.

Затим, треба изградити експертски систем, укључујући таксономију предмета и апстрактно размишљање у нашем свету, као и историјске догађаје, па чак и емоције.

Успешно полагање Туринговог теста је веома тешко. Тренутно се предвиђа да се не може створити систем који може проћи Турингов тест до краја следеће деценије.

2.6 Категоризација вештачке интелигенције

Вештачка интелигенција се може поделити у две различите категорије [4]:

- слаба и
- јака.

Слаба вештачка интелигенција представља систем дизајниран за обављање једног одређеног посла. Слаби системи вештачке интелигенције укључују видео игре, попут шаха и личне помоћнике, попут *Amazon*-овог *Alexa* и *Apple*-ове *Siri*. Помоћнику се поставља питање, а он одговара.

Јаки системи вештачке интелигенције су системи који обављају задатке који се сматрају људским. Они су обично сложенији и компликованији системи. Програмирани су да управљају ситуацијама у којима ће се од њих можда тражити да реше проблем без интервенције особе. Овакви системи могу се наћи у применама попут аутомобила који сами возе или у болничким операционим салама.

2.7 Методе вештачке интелигенције

2.7.1 Симболични и конекционистички приступи

Истраживање вештачке интелигенције прати две различите, и донекле конкурентне, методе [2]:

- симболички („одозго на доле”) и
- конекционистички („одоздо на горе”) приступ.

Приступ „одозго на доле“ настоји да копира интелигенцију анализирајући когницију независно од биолошке структуре мозга, у погледу прераде симбола, одакле симболичка етикета.

Приступ „одоздо на горе“, с друге стране, укључује стварање вештачких неуронских мрежа у имитацији мождане структуре, одакле и конективистичка ознака.

Да би се илустровала разлика између ових приступа, разматра се задатак изградње система, опремљеног оптичким скенером, који препознаје слова абетеде. Приступ „одоздо на горе“ обично укључује обуку вештачке неуронске мреже представљањем слова једно по једно, постепено побољшавајући перформансе „подешавањем“ мреже. Подешавање прилагођава реакцију различитих неуронских путева на различите подстицаје. Супротно томе, приступ „одозго на доле“ укључује писање рачунарског програма који свако слово упоређује са геометријским описима. Једноставно речено, неуронске активности су основа приступа „одоздо на горе“, док су симболички описи основа приступа „одозго на доле“.

У часопису „*The Fundamentals of Learning*“, *Edward Thorndike*, психолог са Универзитета Колумбија, први је навео да се људско учење састоји од непознатог својства веза између неурона у мозгу. У „Организацији понашања“, *Donald Hebb*, психолог са Универзитета *McGill*, навео је да учење посебно укључује јачање одређених образаца неуронске активности повећањем вероватноће (тежине) индукованог пуцања неурона између удружених веза.

1957. године две снажне присталице симболичке вештачке интелигенције, *Allen Newell*, истраживач из корпорације *RAND*, и *Herbert Simon*, психолог и рачунарски научник са Универзитета *Carnegie Mellon*, сумирали су приступ „одозго на доле“ у хипотези физичког симболичког система. Ова хипотеза каже да је обрада структура симбола у принципу довољна за производњу вештачке интелигенције у дигиталном рачунару и да је, осим тога, људска интелигенција резултат исте врсте симболичких манипулација.

Током 50-их и 60-их година прошлог века истовремено су се вршили приступи „одозго на доле“ и „одоздо на горе“ и оба су постигла запажене, али ограничене, резултате. Током 70-их, међутим, вештачка интелигенција „одоздо на горе“ била је занемарена и тек је током 80-их тај приступ поново постао истакнут. Данас се користе оба приступа и оба су суочена са потешкоћама. Симболичке технике делују у поједностављеним областима, али се обично слома када се суочавају са стварним светом. У међувремену, истраживачи приступа „одоздо на горе“ нису били у стању да копирају нервни систем чак и најједноставнијих живих бића. *Caenorhabditis elegans*, много проучавани црв, има око 300 неурона чији је образац међусобних веза савршено познат. Ипак конекционистички модели нису успели да опонашају чак ни овог црва.

2.7.2 Јака вештачка интелигенција, примењена вештачка интелигенција и когнитивна симулација

Користећи горе описане методе, истраживање вештачке интелигенције покушава постићи један од три циља [2]:

- јаку вештачку интелигенцију,
- примењену вештачку интелигенцију или
- когнитивну симулацију.

Јака вештачка интелигенција има за циљ да изгради машине које мисле. Израз јака вештачка интелигенција увео је за ову категорију истраживања 1980. године филозоф *John Searle* са Калифорнијског Универзитета у Берклију. Крајња амбиција јаке вештачке интелигенције је да произведе машину чија се укупна интелектуална способност не разликује од људске. Овај циљ је изазвао велико интересовање током 50-их и 60-их година прошлог века, али такав оптимизам уступио је место уважавању екстремних потешкоћа. До данас је напредак био незнатан.

Примењена вештачка интелигенција, такође позната као напредна обрада информација, има за циљ стварање комерцијално одрживих „паметних“ система, на пример, „стручних“ медицинских дијагностичких система и система трговања залихама. Примењена вештачка интелигенција је доживела значајан успех.

У когнитивној симулацији рачунари се користе за тестирање теорија о томе како функционише људски ум, на пример, теорије о томе како људи препознају лица или се сећају сећања. Когнитивна симулација је већ снажно средство и у неурознаности и у когнитивној психологији.

2.8 Циљеви вештачке интелигенције

Један од основних циљева вештачке интелигенције је елиминација људског мозга у свим функцијама које машине могу обављати, а те функције се обављају неупоредиво брже и тачније него што би то радио човек. Типичан пример такве употребе вештачке интелигенције је у разним прорачунима у распону од сада архаичног дигитрона до савремених софтверских апликација које тренутно изводе сложене статистичке и друге операције са великим бројем променљивих: рачунање корелација и примена виших образаца и модела за мерење односа великог броја променљивих, које се због своје сложености не могу директно посматрати, али су описане већим бројем једноставних променљивих. Да се ове и сличне операције изводе „ручно“ без вештачких помагала, статистика, математика и сличне гране напредовале би неупоредиво спорије него данас [3].

Други, много амбициознији циљ може се назвати усложњавањем и поједностављивањем. Непрекидне иновације у разним областима увек отварају нове могућности како у бизнису, тако и у култури, уметности, образовању, забави, комуникацији, што несумњиво усложњава живот. Према Глобалном институту *Mek Kinzi*, количина података који се генеришу широм света расте за 40% годишње [3].

Да не постоји одговор на овај тренд, појединци, друштвене заједнице, организације, институције, па чак и технолошка инфраструктура били би преоптерећени и свет би се претворио у неподношљив хаос.

Израз за то је у поједностављивању све сложенијег друштвеног света. То се може постићи тежњом за једноставнијом, тренутно доступном, квалитетнијом и све специфичнијом информацијом него што је постојала у доба пре интернета и у ранијој историји интернета. То поједностављује и олакшава управљање и надгледање сложених система као што су државна управа, финансије, здравство, транспорт, саобраћај и сл.

Велики напредак остварен је у поједностављивању економије, нарочито тржишта, а најбољи пример за то је е-трговина. Уместо лутања од једног продајног места до другог, разгледања, упоређивања карактеристика и цена производа, на претраживачима се доста брже добијају информације потребне за доношење одлуке о куповини, плаћање је тренутно, а роба се довози на кућу адресу, што представља огромну уштеду времена.

2.9 Будућа разматрања

Од свог почетка вештачка интелигенција је под будном контролом научника и јавности. Једна уобичајена тема је идеја да ће машине постати толико високо развијене да људи неће бити у стању да их држе и оне ће саме „полетети“, редизајнирајући се експоненцијалном брзином [3, 4].

Друго је да машине могу да харају у приватност људи, па чак и да буду наоружане. Други аргументи расправљају о етици вештачке интелигенције и о томе да ли са интелигентним системима, попут робота, треба поступати са истим правима као и са људима.

Аутомобили који сами возе прилично су контроверзни, јер су њихове машине дизајниране за најмањи могући ризик и најмање жртава. Ако им се представи сценарио судара са једном или другом особом у исто време, ови аутомобили би израчунали опцију која би проузроковала најмање штете.

Друго спорно питање које многи људи имају са вештачком интелигенцијом је како може утицати на запосленост људи. С обзиром да многе индустрије желе аутоматизовати одређене послове коришћењем интелигентних машина, постоји забринутост да би људи били гурнути ван радне снаге. Аутомобили који самостално возе могу да уклоне потребу за таксијима, док произвођачи могу лако заменити људски рад машинама, чинећи вештину људи застарелом.

Развој вештачке интелигенције, у делу који се односи на појединца, вероватно ће довести до стварања неке врсте „дигиталног ЈА“, тј. дигиталне личности. Сврха таквог алата прво ће бити одмењивање мозга из рутинских послова, који одузимају пуно времена и који се могу решити на овај начин готово тренутно и са много већом тачношћу него ако га обавља човек.

Међутим, дигитализација ће такође помоћи да се створи свеобухватна „историја догађаја“ у различитим областима. На пример, када је у питању здравље и опште добро човека, дигитално очитани здравствени параметри (крвна слика, биохемија, хормони, субјективни осећај) могу се пратити као зависне променљиве с једне стране и читав низ независних променљива, с друге стране, почевши од онога што се уноси (било да је то храна, дијетски додаци исхрани или лекови), преко низа вредности метеоролошких параметара, физичке активности и друштвеног живота у најширем смислу те речи (степен изложености тешким напорима, штетним утицајима, поступцима људи из ближе или даље околине, итд.). Израчунавање односа између ове две велике групе променљивих и представљање историје тих односа може резултирати значајно бољом дијагностиком и

потпуно персонализованим препорукама и терапијама. У неком сложенијем подухвату вероватно се могу развити алгоритми који објашњавају добра и лоша стања за сваку особу и на основу тога могу дати корисне препоруке.

Велико подручје примене вештачке интелигенције било би и у области личне и породичне економије. Могу се евидентирати приходи и расходи, извршити поуздане анализе и на основу тога тестирати планови, степен повољности одлука, доносити најбоље препоруке и предлагати нове могућности.

На нивоу фактографије о друштву, старинску статистику и њене записе о догађајима, стањима и пословним резултатима замениће свеобухватна слика живота појединаца и колективних ентитета, као и целог човечанства, другим речима, свеобухватни отисак стварности. Садашњи статистички заводи постаће архива појединачног и колективног живота једне нације и читавог човечанства.

На таквој платформи се развијају неупоредиво боља истраживања и анализе. Уместо досадашњих истраживања на узорцима, без проблема ће се моћи обухватити читаве популације, а таква опсежна и квалитетна фактографија, у поређењу са ситуацијом пре дигиталног друштва, омогућиће много ширу слику стварности када је у питању описни ниво сазнања. С друге стране, анализа заснована на вештачкој интелигенцији може узети у обзир милионе могућих комбинација односа великог броја променљивих, издвојити оне променљиве и њихове односе који највише доприносе решавању одређеног проблема и рангирати их према врсти и степену доприноса. У неком чистом експерименту могуће је симулирати све активне силе и комбиновати могућности које произилазе из њиховог укрштања, зависно од 1) да ли се, 2) како и 3) колико те силе а) уједињују, б) остају неутралне у међусобном односу или в) се сукобљавају. Избор свакако остаје на људском уму, а он ће на основу таквих квалитетних увида и резултата моћи да одабере оне опције које најбоље испуњавају циљеве које треба постићи.

3. Машинско учење

Машинско учење је грана вештачке интелигенције која је усмерена на изградњу апликација које уче из података и побољшавају њихову тачност током времена, а да притом нису програмирани за то [7].

То је техника аналитичке обраде података која учи рачунаре да раде оно што природно долази од људи и животиња, односно да уче из искуства. Алгоритми машинског учења користе рачунске методе да „науче“ информације директно из података без ослањања на унапред одређену једначину као модел. Алгоритми адаптивно побољшавају своје перформансе како се повећава број узорака доступних за учење. Што је алгоритам бољи, то ће одлуке и предвиђања постати тачнији док се обрађује више података [7, 8].

Постоји неколико дефиниција машинског учења, од којих се најчешће користе:

- општа - машинско учење су механизми учења машина на основу искустава којима се машине чине интелигентним и
- формална (*Tom Mitchell* 1998. година) - програм (машина) M учи из искуства E у односу на класу задатка T и меру перформанси P (мера је дефинисана над особином или скупом особина које такође морају бити дефинисане), ако се мера перформанси P програма (машине) побољшава у вези задатка T након искуства E .

Са порастом података, машинско учење је постало кључна техника за решавање проблема у областима, као што су [8]:

- рачунарске финансије, за бодовање кредита и алгоритамско трговање,
- обрада слике и рачунарски вид, за препознавање лица, детекцију покрета и откривање објеката,
- рачунарска биологија, за откривање тумора, откривање лекова и секвенцирање ДНК,
- производња енергије, за предвиђање цена и оптерећења,
- аутомобилска, ваздухопловна и производна индустрија, за предиктивно одржавање,
- обрада природног језика за апликације за препознавање гласа.

Алгоритми машинског учења проналазе природне обрасце у подацима који стварају увид и помажу у доношењу бољих одлука и предвиђања. Они се свакодневно користе за доношење критичних одлука у медицинској дијагнози, трговању залихама, предвиђању енергетског оптерећења и још много тога.

Данас су примери машинског учења свуда. Дигитални асистенти претражују веб странице и пуштају музику као одговор на гласовне команде. Веб странице препоручују производе, филмове или песме на основу онога што је раније куповано, гледано или слушано. Детектори нежељене поште заустављају нежељене поруке. Системи за

медицинску анализу слике помажу лекарима да уоче туморе који су им можда промакли. И први аутомобили који возе самостално [7].

Машинско учење треба користити када постоји сложен задатак или проблем који укључује велику количину података и пуно променљивих, али нема постојеће формуле или једначине [8].

Како велики подаци постају све већи, како рачунарство постаје снажније и приступачније, а како научници података развијају способније алгоритме, машинско учење ће довести до све веће ефикасности у личном и радном животу [7].

Предности машинског учења су [9]:

- врло је тешко тачно (алгоритамски) описати неке врсте задатака које људи могу лако да реше, на пример, препознавање лица, препознавање говора,
- алгоритми за решавање могу се дефинисати за неке врсте задатака, али ови алгоритми су веома сложени или захтевају велике базе знања, на пример, аутоматски превод,
- у многим областима се подаци континуирано прикупљају како би се из њих „нешто сазнало“, на пример:
 - у медицини - подаци о пацијентима и терапијама,
 - у маркетингу - подаци о корисницима / купцима и ономе што су купили, шта их је занимало, како су оценили производе,...

Оваква анализа података захтева приступе помоћу којих се могу утврдити правилности, регуларности података који нису ни познати ни очигледни, али могу бити корисни (*Data mining*).

На слици 3.1 приказан је процес машинског учења.




Слика 3.1. Процес машинског учења [9]

3.1 Методе машинског учења

Две методе машинског учења које се највише упоребљавају су (слика 3.2) [7, 8]:

- надгледано учење, које гради модел на познатим улазним и излазним подацима како би могао предвидети будуће резултате и
- ненадгледано учење, које у улазним подацима проналази скривене обрасце или унутрашње структуре.



Слика 3.2. Методе машинског учења [8]

Такође, поред ове две методе, користе се и:

- полунадгледано учење и
- учење са подршком.

3.1.1 Надгледано учење

Надгледано машинско учење гради модел који предвиђа на основу доказа у присуству несигурности. Алгоритам надгледаног учења (слика 3.3) узима познати скуп улазних података и познате одговоре на податке (излаз) и гради модел да би створио разумна предвиђања за одговор на нове податке. Ово учење користи се ако су познати подаци за излаз који се покушава предвидети [7, 8, 10, 11].

Сваки улазни податак (узорак) x прати излазну вредност y коју модел добијен учењем треба предвидети (y је у општем случају вектор с више излазних променљивих).

Циљ надгледаног учења је одређивање функције која пресликава улазне податке у жељене излазне вредности за те податке на основу познатих парова података (x, y) . Ова функција је непозната пре учења, па се назива хипотезом $h(x)$ (данас се она често назива и функција предикције).

Хипотеза се мења током обуке модела и оптимизује се тако да се улазни подаци што тачније пресликају у жељене излазне вредности.

Скуп познатих парова података (x, y) формира скуп података за обуку модела или тренинг скуп:

$$P = \{(x^{(p)}, y^{(p)})\}, p = 1, 2, \dots, P \quad (3.1)$$

где је P укупан број узорака у тренинг скупу.


Циљ учења је добити такав модел који не даје само добре резултате за податке коришћене у обуци модела (тренинг скуп), већ и за касније, до тада невидљиве податке, који нису коришћени током обуке. Ова способност модела назива се способност генерализације.

Способност генерализације модела тестира се довођењем скупа парова података (x, y) који нису коришћени током обуке модела. Овај скуп података назива се скуп података за тестирање модела или, укратко, тест скуп:

$$T = \{(x^{(t)}, y^{(t)})\}, t = 1, 2, \dots, T \quad (3.2)$$

где је T укупан број узорака у тест скупу.

Током процеса обуке модела испитује се у којој мери модел греша на излазима с обзиром на жељене вредности за све узорке који се доводе на улаз модела, те се на основу тога оцењује степен генерализације модела, тј. квалитет обуке модела.



Слика 3.3. Алгоритам надгледаног учења [11]

На основу врсте излазне вредности модела y , разликује се примена надгледаног учења у следећим проблемима:

- y је континуирана вредност:
 - проблем регресије,
- y је дискретна (категоријска) вредност:
 - проблем класификације,
 - ако постоје две класе, онда је то бинарна класификација, а уколико постоји више класа, то је вишекласна класификација,

- у је структурирана вредност:
 - проблем структуриране предикције,
 - структурирани подаци састоје се од неколико делова који садрже информације, а однос између њих важан је у проматраној структури података,
 - пример структурираних података: стабло, графикон, слике, низови.

Надгледано учење користи класификационе и регресионе технике за развој предиктивних модела.

Технике класификације предвиђају дискретне одговоре, на пример, да ли је адреса е-поште оригинална или нежељена или да ли је тумор канцерогени или бенигни. Модели класификације класифицикују улазне податке у категорије. Типичне примене укључују медицинско снимање, препознавање говора и кредитно оцењивање.

Класификација се користи ако се подаци могу означити, категорисати или раздвојити у одређене групе или класе. На пример, апликације за препознавање ручног писања користе класификацију за препознавање слова и бројева. У процесу обраде слике и рачунарског вида користе се ненадгледане технике препознавања узорака за детекцију објеката и сегментацију слике.

Регресионе технике предвиђају континуиране реакције, на пример, промене температуре или предвиђања у потражњи електричне енергије. Типичне примене укључују предвиђање оптерећења електричном енергијом и алгоритамско трговање.

Регресиона техника се користи ако се ради са распоном података или ако је природа одговора стварни број, као што су температура или време до отказа за неку опрему.

3.1.2 Ненадгледано учење

Ненадгледано учење проналази скривене обрасце или унутрашње структуре у подацима. Користи се за вађење закључака из скупова података који се састоје од улазних података без означених одговора [7, 8, 10, 11].

Код ненадгледаног учеља дати су само улазни подаци x , а не постоје жељене вредности y .

Проблем се огледа у томе што се у улазним подацима мора наћи одређена правилност.

Ненадгледано учење користи се за решавање следећих задатака:

- груписање (кластерисање) - подаци су подељени у групе које максимизирају неке изабране критеријуме сличности или минимизирају неке изабране критеријуме различитости,
- смањење димензионалности - проналажење мањег скупа променљивих који одржава исте главне обрасце и варијације у скупу почетних променљивих.

Груписање (кластерисање) је најчешћа техника ненадгледаног учења. Користи се за истраживачке анализе података за проналажење скривених образаца или груписања у подацима (слика 3.4). Апликације за кластер анализу укључују анализу генске секвенце, истраживање тржишта и препознавање објеката.



Слика 3.4. Груписање проналази скривене обрасце у подацима [8]


На пример, ако компанија за мобилне телефоне жели да оптимизује локације на којима гради торњеве за мобилне телефоне, могу да користе машинско учење да процене број кластера људи који се ослањају на њихове торњеве. Телефон може разговарати само с једним торњем одједном, тако да тим користи алгоритме груписања да би дизајнирао најбољи положај торњева како би оптимизовао пријем сигнала за групе или кластере својих купаца.

3.1.3 Класификација наспрам груписања

У табели 3.1 и на слици 3.5 приказане су разлике између класификације (надгледано учење) и груписања (ненадгледано учење) [11].

Табела 3.1. Класификација наспрам груписања [11]

Класификација	Груписање (кластерисање)
Укупан број класа је унапред познат	Укупан број класа није унапред познат
Постојећи подаци имају означену припадност класи	Постојећи подаци немају означену припадност класи
Модел се користи за класификовање нових података	Модел се користи за разумевање или истраживање постојећих података
Припада проблему који се решава надгледаним машинским учењем	Припада problemu који се решава ненадгледаним машинским учењем



Слика 3.5. Класификација наспрам груписања [11]

3.1.4 Полунадгледано учење

Полунадгледано учење нуди посредовање између надгледаног и ненадгледаног учења. Током обуке користи мањи скуп означених података да би водио класификацију и издвајање одлика из већег, неозначеног скупа података. Полунадгледано учење може да реши проблем недовољног броја означених података да би се научио алгоритам надгледаног учења [7, 10, 11].

За мањи део улазних података x_s постоје означене жељене излазне вредности y_s , док за већи део улазних података x_u нема означених жељених излазних вредности.

Циљ полунадгледаног учења је употреба неозначених података за боље усавршавање модела.

Полунадгледано учење у пракси има велику вредност јер је за многе проблеме тешко добити велику количину података са означеним жељеним излазним вредностима.

3.1.5 Учење са подршком

Начин за разумевање учења са подршком је размишљање о томе како неко може да научи играти стару рачунарску игру први пут, кад није упознат са правилима или како да контролоше игру. Иако су можда потпуни почетници, на крају, гледањем односа између дугмади које притискају, онога што се дешава на екрану и њиховог резултата у игри, њихов учинак постаје све бољи и бољи [7, 10, 11].

Учење са подршком углавном се користи за оспособљавање агената за деловање у простору акција. Учење се одвија на основу датих улазних података, који представљају акције агената и сигнале подршке. Агент добија сигнал подршке на крају акција које је предузео. Сигнал подршке може бити позитиван или негативан у зависности од тога да ли је понашање агента било пожељно или непожељно током извођења низа акција.

Алгоритам учења агента користи сигнал подршке како би одредио који скуп или редослед акција на крају резултира позитивним или негативним сигналом подршке и на основу тога кориговао понашање агента.

Пример учења са подршком је *Google DeepMind's Deep Q-network* која је победила људе у широком спектру видео игара. Систем уноси пикселе из сваке игре и одређује различите информације о стању у игри, као што је удаљеност између објеката на екрану. Затим, разматра како се стање игре и акције које она обавља у игри односе на резултат који постиже.

Током процеса много циклуса играња игре, систем на крају гради модел радњи које ће максимизирати резултат, у којој околности, на пример, у случају *Breakout* видео игре, где треба померити рекет, како би се пресрела лопта.

Примена учења са подршком су: роботика, шах, Go игра, видео игре.

3.2 Примена машинског учења

Примене машинског учења су [11]:

- примена код проблема који се веома тешко решавају алгоритамски, па класично програмирање није могуће:
 - обрада природних језика (српски, енглески, немачки,...) - детекција нежељене поште, машински превод текста,
 - рачунарски вид - препознавање текста (*Optical Character Recognition - OCR*), препознавање облика, препознавање лица, препознавање покрета,
 - роботика - проблем кретања робота који се креће кроз простор, предузимање акције од стране руке робота,
 - препознавање образаца у узорцима - помоћ у медицинској дијагностици, откривање тумора на медицинским сликама,
 - играње компјутерских игара - играње *AlphaGo* игре,
- примена у истраживању података (*Data mining*), које укључује:
 - процес откривања правилности, законитости или образаца у великим количинама података који могу бити корисни за трансформацију тих података у структуре које се могу даље обрађивати,
 - процес трансформације података и
 - процес управљања подацима,
- машинско учење се најчешће користи у првом кораку истраживања података (које се често назива анализом података), које укључује издвајање корисних информација из велике количине необрађених података (често се назива извлачење скривених знања из необрађених података).
- поред анализе података, истраживање података укључује следеће кораке:
 - препроцесирање података,
 - разматрање статистичких модела и метрике модела,
 - разматрање сложености података,
 - постпроцесирање откривених структура,
 - складиштење података и
 - визуализацију података.

Примери примене истраживања података су:

- анализа понашања корисника производа / услуга на тржишту,
- предвиђање кретања цена акција,
- примена у системима подршке у одлучивању,
- употреба у медицинским и генетским истраживањима,
- анализа велике количине података добијених приликом читавања сензора,
- примена у модерним пословним системима за доношење одлука за унапређење пословања.

3.2.1 Примери примене машинског учења

Као што је напоменуто на почетку, машинско учење је свуда. Неки од примера машинског учења који се сусрећу сваког дана су [7]:

- дигитални асистенти - *Apple Siri, Amazon Alexa, Google Assistant* и други дигитални асистенти покрећу обраду природних језика, машинску апликацију за учење која омогућава рачунарима да обрађују текст и гласовне податке и „разумеју“ људски језик као што то раде људи. Обрада природног језика такође покреће апликације које се заснивају на гласу, као што су *GPS* и софтвер за препознавање говора;
- препоруке - модели дубоког учења користе „људи такође воле“ и „само за вас“ препоруке које нуде *Amazon, Netflix, Spotify* и друге малопродаје, забаве, путовања, тражење посла и вести;
- контекстуално мрежно оглашавање - модели машинског учења и дубоког учења могу да процене садржај веб странице, не само тему, већ и нијансе попут мишљења или става аутора, и послужују рекламе прилагођене интересовањима посетиоца;
- *chatbots* - они могу користити комбинацију препознавања образаца, обраду природног језика и дубоке неуронске мреже за тумачење улазног текста и пружање одговарајућих одговора;
- откривање преваре - регресиони и класификациони модели машинског учења заменили су системе откривања превара заснованих на правилима, који имају велики број лажних позитивних резултата приликом означавања коришћења украдених кредитних картица и ретко су успешни у откривању криминалне употребе украдених или угрожених финансијских података;
- *cybersecurity* - машинско учење може извући интелигенцију из извештаја о инцидентима, упозорења, постова на блогу, за препознавање потенцијалних претњи, саветовања безбедносних аналитичара и убрзавања реакције;
- анализа медицинске слике - врсте и количина података о дигиталном медицинском снимку су експлодирале, што је довело до расположивих информација за подупирање дијагноза, али и више могућности за људске грешке у читању података. Конволуционарне неуронске мреже, понављајуће неуронске мреже и други модели дубоког учења показали су се све успешнијим у вађењу

карактеристика и информација из медицинских слика како би се подржала тачна дијагноза;

- аутомобили који возе самостално - ауто-аутомобили морају непрекидно идентификовати предмете у околини око аутомобила, предвидети како ће се мењати или кретати и усмерити аутомобил око предмета као и према возачевом одредишту. Готово сваки горе наведени алгоритам машинског учења и дубоког учења игра одређену улогу у омогућавању аутоматског управљања аутомобилом.

4. Разлика између вештачке интелигенције и машинског учења

Машинско учење је у последње време можда уживало огроман успех, али то је само једна метода за постизање вештачке интелигенције [10].

Рођењем поља вештачке интелигенције 1950-их, вештачка интелигенција је дефинисана као било која машина способна да обавља задатак који обично захтева људску интелигенцију.

Ове две области су нераскидиво повезане, иако су различите. Вештачка интелигенција је свуда око нас. Она има моћ да мења свет, али то је постепен процес. Машинско учење се често користи као синоним за вештачку интелигенцију, мада је машинско учење потпуно другачија, али повезана дисциплина. Док се термин вештачке интелигенције односи на рачунарски програм који је у стању да „размишља“ за себе, без додатних програмираних упутстава, машинско учење је само процес којим рачунар може да научи шта је потребно.

Процес машинског учења сличан је људском учењу кроз искуство. Разликују се по томе што су, бар за сада, машине специјализоване за учење једне ствари или две истовремено.

На пример, уколико постоји апликација за фотографије, која се може користити за претраживање њеног садржаја, када се откуца реч „мачка“, апликација ће прикати слике мачака. Апликација зна како изгледа мачка јер је то научила машинским учењем, односно на хиљаде фотографија мачака убачено је у рачунарски програм, због чега је могла да схвати како мачка изгледа. Програм је приметио сличности (реп, бркови, уши) баш као и људи. Ако се, затим, тој апликацији покаже било која фотографија са интернета, она може да каже да ли на тој слици постоји мачка.

Ова врста машинског учења дешава се свуда око нас јер компанијама пружа податке које користе за свакодневно учење. На тај начин *Google* претраживач може предвидети шта ће особа унети у оквир за претрагу. Све је то несумњиво корисно, али моћ машинског учења да промени свет лежи у способности вештачке интелигенције да опажа оно што људи не могу. Поред њене иновативне употребе у авиокомпанијама и у банкарском сектору, занимљив је пример њене примене у здравству. Снабдевајући вештачку интелигенцију ехокардиограмима пацијената са рестриктивном кардиомиопатијом и констриктивним перикардитисом, вештачка интелигенција је у два месеца успела да утврди разлику између ове две болести у 96% случајева. Људско око је приметило разлику у 50% до 75% случајева.

У овом случају је вештачка интелигенција на крају поставила дијагнозу, али то не би било могуће без претходног учења. Машинско учење је само један од начина на који научници могу да учине вештачку интелигенцију интелигентнијом.

5. Дубоко учење и неуронске мреже

5.1 Дубоко учење

Дубоко учење је ново подручје машинског учења, чији је циљ да приближи машинско учење свом првобитном циљу, вештачкој интелигенцији [11].

Дубоко учење је део шире породице машинског учења које се заснива на учењу репрезентације података (слика 5.1).



Слика 5.1. Место дубоког учења у машинском учењу [11]

Дубоко учење је скуп алгоритама машинског учења за обучавање слојевитих структура, углавном вишеслојних или понављајућих неуронских мрежа. Слојеви у овим моделима одговарају различитим нивоима концепата података, тако да исти концепти на нижим нивоима учествују у формирању различитих концепата на вишим нивоима.

Алгоритми дубоког учења дефинишу вештачку неуронску мрежу која је осмишљена да учи на начин на који људски мозак учи. Модели дубоког учења захтевају велике количине података који пролазе кроз више слојева израчунавања, примењујући значаје и склоности у сваком узастопном слоју како би се континуирано прилагођавали и побољшавали резултати.

Модели дубоког учења обично су ненадгледано или полунадгледао учење. Модели учења са подршком такође могу бити модели дубоког учења. Одређени типови модела дубоког учења, укључујући конволуционарне неуронске мреже и понављајуће неуронске мреже, воде ка напретку у областима као што су рачунарски вид, природна обрада језика (укључујући препознавање говора) и аутомобили који возе самостално.

У дубоком учењу модел може сам пронаћи одговарајуће атрибуте, али за сваки проблем је потребно пронаћи одговарајућу структуру модела.

5.1.1 Начин функционисања дубоког учења

Дубоко учење еволуирало је руку под руку са дигиталном ером, која је довела до експлозије података у свим облицима и из свих региона света. Ови подаци, познати само као велики подаци, црпе се, између осталог, из друштвених медија, интернет претраживача,

платформи за е-трговину и онлајн биоскопа. Ова огромна количина података је лако доступна [12].

Међутим, подаци, који су обично неструктурисани, толико су огромни да би људима требале деценије да их схвате и извуку релевантне информације. Компаније схватају невероватан потенцијал који може проистећи из разоткривања овог богатства информација и све се више прилагођавају системима вештачке интелигенције за аутоматизовану подршку.

Већина метода дубоког учења користи архитектуре неуронских мрежа, због чега се модели дубоког учења често називају дубоким неуронским мрежама [13].

Термин „дубоко“ обично се односи на број скривених слојева у неуронској мрежи. Традиционалне неуронске мреже садрже само 2-3 скривена слоја, док дубоке мреже могу имати чак 150.


Модели дубоког учења се обучавају коришћењем великих скупова означених података и архитектура неуронске мреже који својства уче директно из података без потребе за ручним издвајањем карактеристика.

Један од најпопуларнијих типова дубоких неуронских мрежа познат је под називом конволуционе неуронске мреже (*CNN*). *CNN* спаја научене карактеристике са улазним подацима и користи 2D конволуционе слојеве, што ову архитектуру чини врло погодном за обраду 2D података, попут слика.

CNN-ови елиминишу потребу за ручним извлачењем карактеристика, тако да се не морају идентификовати карактеристике које се користе за класификацију слика. *CNN* ради извлачењем карактеристика директно са слика. Релевантне карактеристике нису претходно обучене, већ се уче док мрежа тренира на колекцији слика. Ово аутоматизовано издвајање карактеристика чини моделе дубоког учења изузетно прецизним за задатке рачунарског вида као што је класификација предмета.

CNN-ови науче да откривају различите карактеристике слике користећи десетине или стотине скривених слојева. Сваки скривени слој повећава сложеност научених карактеристика слике. На пример, први скривени слој могао би да научи како да детектује ивице, а последњи како да открије сложеније облике посебно прилагођене облику предмета који се покушава препознати.

На слици 5.2 приказан је пример мреже са много конволуционих слојева.



Слика 5.2. Пример мреже са много конволуционих слојева. Филтери се примењују на сваку слику обуке у различитим резолуцијама, а излаз сваке слике служи као улаз на следећи слој [13]

5.1.2 Важност дубоког учења

Дубоким учењем постиже се тачност препознавања на вишим нивоима него икад раније. Ово помаже потрошачкој електроници да испуни очекивања корисника и пресудно је за безбедносно критичне примене попут аутомобила без возача. Недавни напредак у дубоком учењу побољшао се до те мере да дубоко учење надмашује људе у неким задацима попут класификовања предмета на сликама [13].

Иако се о дубоком учењу први пут говорило 1980-их, два су главна разлога што је тек недавно постало корисно:

- 1) дубоко учење захтева велике количине означених података. На пример, развој аутомобила без возача захтева милионе слика и хиљаде сати видео записа;
- 2) дубоко учење захтева значајну рачунарску снагу. Јединице за обраду графике високих перформанси имају паралелну архитектуру која је ефикасна за дубоко учење. У комбинацији са кластерима или рачунарством у облаку, ово омогућава развојним тимовима да смање време обуке за мрежу дубоког учења са недеља на сате или мање.

5.1.3 Примери дубоког учења

Апликације за дубоко учење користе се у индустријама, од аутоматизоване вожње до медицинских уређаја [13]:

- аутоматизована вожња - истраживачи аутомобила користе дубоко учење како би аутоматски открили предмете као што су знакови за заустављање и семафори. Поред тога, дубоко учење се користи за откривање пешака, што помаже у смањењу незгода;
- ваздухопловство и одбрана - дубоко учење се користи за идентификацију објеката са сателита који лоцирају подручја од интереса и идентификовање сигурних или небезбедних зона за трупе;
- медицинска истраживања - истраживачи рака користе дубоко учење како би аутоматски открили ћелије рака. Тимови у *UCLA* направили су напредни микроскоп који даје високодимензионални скуп података који се користи за обуку апликације за дубоко учење како би се тачно идентификовале ћелије карцинома;
- индустријска аутоматизација - дубоко учење помаже у побољшању безбедности радника око тешких машина аутоматским откривањем када су људи или предмети на небезбедној удаљености од машина;
- електроника - дубоко учење се користи у аутоматизованом превођењу слуха и говора. На пример, уређаји за помоћ у кући који реагују на глас и знају преференције корисника покрећу се апликацијама за дубоко учење.


5.1.4 Разлика између машинског учења и дубоког учења

Дубоко учење је специјализовани облик машинског учења. Ток рада машинског учења започиње релевантним функцијама које се ручно издвајају са слика. Функције се затим користе за стварање модела који категоризује објекте на слици. Процесом дубоког учења, релевантне функције се аутоматски издвајају са слика. Поред тога, дубоко учење изводи „учење од краја до краја“, где мрежа добија сирове податке и задатак који треба да изврши, попут класификације, и она научи како то да уради аутоматски [13].

Друга кључна разлика су алгоритми дубоког учења који се скалирају подацима, док се „плитко“ учење конвергира. „Плитко“ учење односи се на методе машинског учења које заузимају одређени ниво перформанси када се мрежи дода више примера и података о обуци.

Кључна предност мрежа дубоког учења је та што се оне често настављају побољшавати како се величина података повећава.

На слици 5.3 приказано је поређење машинског учења са дубоким учењем.



Слика 5.3. Поређење приступа машинском учењу са категоризацијом возила (лево) са дубоким учењем (десно) [13]

У машинском учењу се ручно бирају функције и класификатор за сортирање слика. У дубоком учењу кораци за издвајање и моделирање функција су аутоматски.

5.1.5 Стварање и обучавање модела дубоког учења

Три најчешћа начина на која људи користе дубоко учење за извршавање класификације предмета су [13]:

- обука од нуле,

Да би се истренирала дубока мрежа од нуле, потребно је сакупити врло велики означени скуп података и дизајнирати мрежну архитектуру која ће научити функције и модел. Ово је добро за нове апликације или апликације које ће имати велики број излазних категорија. Ово је мање уобичајен приступ, јер уз велику количину података и брзину учења, овим мрежама обично требају дани или недеље да би се обучиле.

- учење трансфера,

Већина апликација за дубоко учење користи приступ учења трансфера, процес који укључује прецизно подешавање претходно обученог модела. Почиње се са постојећом мрежом, као што је *AlexNet* или *GoogLeNet*, и убацују се нови подаци који садрже претходно непознате класе. Након неколико подешавања мреже, сада се може извршити нови задатак, као што је категоризација само паса или мачака, уместо 1000 различитих предмета. Овај приступ такође има предност што му је потребно много мање података (обрада на хиљаде слика, а не милиона), па време израчунавања пада на минуте или сате.

За учење трансфера потребан је интерфејс за унутрашњост постојеће мреже, тако да се може хируршки модификовати и побољшати за нови задатак. *MATLAB*® има алате и функције дизајниране да помогну да се научи трансфер.

- издвајање карактеристика.

Нешто ређи, специјализованији приступ дубоком учењу је употреба мреже као издвајање карактеристика. Будући да су сви слојеви задужени за учење одређених карактеристика са слика, могу се извући из мреже у било ком тренутку током процеса обуке. Ове карактеристике се затим могу користити као улаз у модел машинског учења као што су методе подржавајућих вектора.

5.2 Неуронска мрежа

У протеклих 10 година, системи вештачке интелигенције са најбољим перформансама, попут препознавача говора на паметним телефонима или најновијег *Google*-овог аутоматског преводиоца, настали су из технике која се назива „дубоко учење“ [14].

Дубоко учење је заправо ново име за приступ вештачкој интелигенцији названој неуронске мреже, који улази и излази из моде више од 70 година. Неуронске мреже први пут су 1944. године предложили *McCullough* и *Walter Pitts*, два истраживача са Универзитета у Чикагу који су се преселили на *MIT* 1952. године као оснивачи онога што се понекад назива првим одсеком за когнитивне науке.

Неуронске мреже биле су главно подручје истраживања како у неурознаности, тако и у рачунарству све до 1969. године, када су их, према науци о рачунарским наукама, убили математичари са *MIT*-а *Marvin Minsky* и *Seymour Papert*, који ће годину дана касније постати ко-директори нове лабораторије за вештачку интелигенцију *MIT*.

Техника је тада поново оживела 1980-их, поново је пала у заборав у првој деценији новог века, а у другој се вратила подстакнута углавном повећаном процесорском снагом графичких чипова.

Неуронска мрежа је низ алгоритама који настоје да препознају основне односе у скупу података кроз процес који имитира начин на који људски мозак делује. У том смислу, неуронске мреже се односе на системе неурона, било органске или вештачке природе. Неуронске мреже се могу прилагодити промени уноса, тако да мрежа генерише најбољи могући резултат без потребе за редизајнирањем излазних критеријума. Концепт неуронских мрежа, који има своје корене у вештачкој интелигенцији, брзо стиче популарност у развоју трговинских система [15].

5.2.1 Начин функционсања неуронских мрежа

Неуронске мреже су средство за машинско учење, у којем рачунар учи да извршава неки задатак анализирајући примере обуке. Обично су примери ручно означени унапред. На пример, систем препознавања предмета могао би да садржи хиљаде означених слика аутомобила, кућа, шоља кафе и тако даље, а на сликама би пронашао визуелне обрасце који доследно корелирају са одређеним ознакама [14].

По узору на људски мозак, неуронска мрежа састоји се од хиљада или чак милиона једноставних чворова за обраду који су густо међусобно повезани. Већина данашњих неуронских мрежа су организоване у слојеве чворова и оне су „унапред прослеђене“, што значи да се подаци крећу кроз њих у само једном смеру. Појединачни чвор може бити повезан са неколико чворова у слоју испод себе, одакле прима податке, и неколико чворова у слоју изнад, којима шаље податке.


Свакој од својих долазних веза чвор ће доделити број познат као „тежина“. Када је мрежа активна, чвор прима другу ставку података, различит број, преко сваке од својих веза

и множи је са придруженом тежином. Затим сабира резултујуће производе, дајући један број. Ако је тај број испод граничне вредности, чвор не прослеђује податке следећем слоју. Ако број премаши граничну вредност, чвор се „активира“, што у данашњим неуронским мрежама обично значи слање броја, збира пондерисаних улаза, дуж свих његових одлазних веза.

Када се неуронска мрежа обучава, све њене тежине и граничне вредности се у почетку постављају на случајне вредности. Подаци о обуци се доводе у доњи слој, улазни слој, и они пролазе кроз наредне слојеве, множе се и сабирају на сложени начин, док коначно не стигну, радикално трансформисани, на излазни слој. Током обуке, тежине и граничне вредности се непрестано прилагођавају све док подаци о обуци са истим ознакама не дају стално сличне резултате.

5.2.2 Архитектура неуронске мреже

Неуронска мрежа комбинује неколико слојева обраде, користећи једноставне елементе који раде паралелно и инспирисани биолошким нервним системом. Састоји се од улазног слоја, једног или више скривених слојева и излазног слоја (слика 5.4). У сваком слоју постоји неколико чворова или неурона, при чему сваки слој користи излаз претходног слоја као свој улаз, тако да неурони међусобно повезују различите слојеве. Сваки неурон обично има тежине које се прилагођавају током процеса учења, а како се тежина смањује или повећава, мења јачину сигнала тог неурона [16].



Слика 5.4. Типична архитектура неуронске мреже [16]

5.2.3 Примена неуронских мрежа

Неуронске мреже се широко користе, са апликацијама за финансијско пословање, планирање предузећа, трговину, пословну аналитику и одржавање производа. Неуронске мреже такође су широко прихваћене у пословним апликацијама као што су предвиђања и решења за маркетиншка истраживања, откривање превара и процена ризика [15].

Неуронска мрежа процењује податке о ценама и открива могућности за доношење трговинских одлука на основу анализе података. Мреже могу разликовати суптилне нелинеарне међузависности и обрасце које друге методе техничке анализе не могу. Према истраживању, тачност неуронских мрежа у предвиђању цена за акције се разликује. Неки модели предвиђају тачне цене акција 50 до 60 % времена, док су други тачни у 70 % свих случајева. Неки сматрају да је побољшање ефикасности од 10 % све што инвеститор може тражити од неуронске мреже.

Увек ће постојати скупови података и класе задатака које је боље анализирати помоћу претходно развијених алгоритама. Међутим, није толико важан алгоритам. Добро припремљени улазни подаци о циљаном индикатору на крају одређују ниво успешности неуронске мреже.

5.2.4 Периодичност

До 1980-их истраживачи су развили алгоритме за модификовање тежина и граничних вредности неуронских мрежа који су били довољно ефикасни за мреже са више слојева, уклањајући многа ограничења која су идентификовали *Minsky* и *Papert* [14].

Али, интелектуално постоји нешто незадовољавајуће у вези са неуронским мрежама. Довољно обуке може ревидирати поставке мреже до те мере да може корисно класификовати податке.

Последњих година рачунарски научници почели су да смишљају генијалне методе за утврђивање аналитичких стратегија које су усвојиле неуронске мреже. Али 1980-их, стратегије мрежа нису се могле одгонетнути. Дакле, око почетка века, неуронске мреже су потиснуте методама подржавајућих вектора, алтернативним приступом машинском учењу који се заснива на врло чистој и елегантној математици.

Недавни препород неуронских мрежа, револуција дубоког учења, дошао је захваљујући индустрији рачунарских игара. Сложене слике и брзи темпо данашњих видео игара захтевају хардвер који може да иде у корак, а резултат је била јединица за обраду графике, која спакује хиљаде релативно једноставних процесорских језгара на једном чипу. Није требало дуго да истраживачи схвате да је архитектура јединица за обраду графике изузетно слична архитектури неуронске мреже.

Савремене јединице за обраду графике омогућиле су да једнослојне мреже 1960-их и дво- до трослојне мреже 1980-их процветају у данашње 10-, 15-, чак 50-слојне мреже. На то се односи „дубоко“ у „дубоком учењу“ - дубина слојева мреже. Тренутно је дубоко учење одговорно за системе са најбољим учинком у скоро свим областима истраживања вештачке интелигенције.

5.2.5 Технике коришћене са неуронским мрежама

Уобичајене технике машинског учења за дизајнирање апликација вештачких неуронских мрежа укључују надгледано и ненадгледано учење, класификацију, регресију, препознавање образаца и груписање [16].

5.2.5.1 Надгледано учење

Надгледане неуронске мреже су обучене да производе жељене излазе као одговор на узорке уноса, што их чини посебно погодним за моделирање и контролу динамичких система, класификацију података и предвиђање будућих догађаја [16].

5.2.5.2 Класификација

Класификација је врста надгледаног машинског учења у којем алгоритам „учи“ да класификује нова запажања из примера обележених података [16].

5.2.5.3 Регресија

Регресиони модели описују однос између променљиве одговора (излаза) и једне или више променљивих предиктора (улаза) [16].

5.2.5.4 Препознавање образаца

Препознавање образаца је важна компонента вештачких апликација неуронске мреже у рачунарском виду, радарској обради, препознавању говора и класификацији текста. Ради тако што класификује улазне податке у објекте или класе на основу кључних карактеристика, користећи или надгледану или ненадгледану класификацију [16].

На пример, у рачунарском виду, надгледане технике препознавања узорака користе се за оптичко препознавање знакова, откривање лица, препознавање лица, откривање предмета и класификацију објеката. У обради слика и рачунарском виду користе се ненадгледане технике препознавања узорака за откривање објеката и сегментацију слика.

5.2.5.5 Ненадгледано учење

Ненадгледане неуронске мреже се обучавају пуштањем да се неуронска мрежа непрекидно прилагођава новим улазима. Користе се за закључивање из скупова података који се састоје од улазних података без означених одговора. Помоћу њих се могу открити природне расподеле, категорије и односи категорија у подацима [16].

5.2.5.6 Груписање

Груписање је приступ ненадгледаног учења, у којем се вештачке неуронске мреже могу користити за истраживачку анализу података како би се пронашли скривени обрасци или груписања у подацима. Овај процес укључује груписање података по сличности. Апликације за кластер анализу укључују анализу секвенце гена, истраживање тржишта и препознавање објеката [16].

6. Могућности примене машинског учења у креативним активностима конструисања

6.1 Аутономна обрада геометрије коришћењем машинског учења

У овом делу рада описана је аутономна апликација за обраду геометрије, која користи алгоритме машинског учења за дешифровање интелигентних информација из STL мрежа. Ови циљеви се постижу у четири корака [17]:

- сегментирање STL мреже на шест основних типова површина:
 - цилиндричну,
 - сферну,
 - раванску,
 - конусну,
 - Б-завојну и
 - торусну,
- груписање детектованих површина и идентификовање карактеристика високог нивоа као што су рупе, конусне рупе, оборене ивице, заобљења.
- коришћење информација на нивоу карактеристика да би се разумели делови и склопови,
- механизам вештачке интелигенције идентификује различите врсте делова и означава их према индустрији.

Створена је микро веб услуга која узима STL датотеке као улаз и даје потпуно сегментирану мрежу као излаз. Друга веб апликација олакшава функцију откривања објеката из 3D CAD датотека.

Већина конструкционих техника као инжењерских датирају хиљадама година уназад. Цртеж перспективе изумљен је 1300-их, описна геометрија 1765-е, ортографска пројекција 1770-их, 2D CAD 1970-их и 3D CAD 1980-их. 3D CAD софтвер се појавио на тржишту само неколико деценија раније, али главна производња и архитектонска индустрија користе друге старије облике инжењерских цртежа, старијих од једног века.

Произведени производи и конструкције рађене пре широке адаптације 3D CAD-а данас се широко користе. Дизајн већине ових креација био је рађен или на правом папиру, или је можда дигитализован у 2D CAD датотеке цртежа. У данашњем свету 3D CAD датотеке су од највеће важности. Оне помажу у извођењу радова на обнови, симулацијама и импровизацији дизајна. Због тога постаје изузетно важно претварање ових дизајна у 3D CAD формате.

На свету постоје милиони таквих дизајна које треба претворити у 3D CAD датотеке. Међутим, организације не могу приуштити постављање CAD конструктора за ручно извршавање овог мамутског задатка. Ако се то уради, можда ће требати више година да се заврши. Потребна је нека врста софтверске аутоматизације или вештачке интелигенције да би се брзо обавио овај посао.

Решења за преношење не-дигиталних података у конструисању у дигиталне формате су:

- дизајни који су на папиру могу се примарно скенирати, а затим софтверски алгоритми или вештачка интелигенција могу се применити за генерисање њихових 3D CAD модела;
- 3D скенери се могу користити за скенирање и стварање датотека података облака тачака из произведених производа или архитектонских зграда које уопште немају податке о дизајну у било ком формату.

Када се добију подаци о дизајну у било ком дигиталном формату, може се радити на решењима за разумевање података и креирање 3D CAD модела који садрже све информације на нивоу карактеристика унутар њих. Богате информације о карактеристикама и повезаности између карактеристика које су присутне у 3D CAD датотекама чине их толико важним, док сирове датотеке у којима се чувају подаци о дизајну могу имати много мање информација.

На пример, у STL датотекама, облик 3D геометрије се ствара помоћу много троуглова. Датотека у правом смислу садржи 3D координатне вредности сваког темеа ових троуглова. Решење за аутоматизацију за генерисање CAD модела богатог карактеристикама из сваког необрађеног формата података дизајна ће увелико варирати.

Међутим, у овој ери аутоматизације и вештачке интелигенције не би се требало зауставити са генерисањем 3D CAD модела на основу ових информација о ниском нивоу дизајна. Уместо тога, требало би унети аспект интелигенције у 3D CAD моделе, попут откривања контекстуалних имена сваког дела присутног у 3D CAD датотеци. На пример, требало би да постоји механизам вештачке интелигенције који може читати 3D CAD датотеку и идентификовати имена свих објеката присутних у том CAD моделу.

Рецимо, уколико се постави CAD модел куће са свим намештајем у себи, мотор вештачке интелигенције би требао моћи да идентификује предмете попут зидова, софе, стола, столица, телевизора, фрижидера, итд. Ако постоје 3D CAD модели и ове врсте контекстуалних и интелигентних информација о сваком појединачном дизајну икад направљеном на овом свету, отвара се пуно могућности које се могу учинити са овим интелигентним подацима о дизајну. Дакле, потребно је учинити информације о дизајну паметнијим.

На основу разумевања тржишта, уочено је да је једна од главних потреба обрада података 3D скенера из стварне геометрије и генерисање 3D модела из њега. Такође, већина података о дизајну доступних у дигиталном формату је у STL-у или у неколико других сличних формата. Чак и излаз 3D скенера се може лако трансформисати у формате попут STL-а. Постоји неколико фаза конверзије STL датотеке у 3D CAD моделе богате карактеристикама, а то су:

- фаза 1.1 - Откривање и груписање троуглова који припадају примитивном типу површине попут цилиндричне површине, сферне површине, равне површине, итд.;
- фаза 1.2 - Откривање и груписање колекције примитивних типова површина (откривених у фази 1) у карактеристике. На пример, примитивне карактеристике попут оборених ивица, заобљења или инжењерске карактеристике попут рупе, конусне рупе, навоја за завртањ, прирубнице у цеви, итд.;
- фаза 1.3 - Коришћење свих информација прикупљених из претходних фаза за генерисање 3D CAD модела богатог карактеристикама дате STL геометрије;
- фаза 2 - Стварање решења заснованог на вештачкој интелигенцији које може идентификовати имена 3D објеката из CAD датотека, попут откривања објеката са слика.

Како би се идентификовали примитивни типови површина из датотеке геометрије STL и откривање објеката из 3D CAD модела, потребно је ограничити опсег само на фазе 1.1 и 2.

Потребно је створити хеуристички алгоритам са пуно правила која могу класификовати сваки троугао дате STL датотеке у следеће типове површина:


- цилиндричну површину,
- сферну површину,
- торус површину,
- конусну површину,
- равну површину или
- било коју другу генеричку Б завојну површину.

Варијације у триангулацијама од случаја до случаја могу бити огромне и писање правила за сваку такву варијацију једноставно може бити ван домета хеуристичког приступа решавања овог проблема. Због тога је овде потребно пронаћи решење коришћењем вештачке интелигенције и машинског учења.

6.1.1 Фаза 1: Дефиниција проблема

Прва фаза је откривање и груписање троуглова из STL датотеке који припадају примитивном површинском типу [17].

Потребно је креирати аутономну веб апликацију на технологији вештачке интелигенције која ће прихватити STL датотеку 3D геометрије (лево) и генерисати нову OBJ датотеку (десно) у којој су сви троуглови класификовани у своје примитивне типове површина (слика 6.1).




Слика 6.1. Фаза 1 [17]

6.1.2 Фаза 2: Дефиниција проблема

Друга фаза подразумева препознавање имена 3D објеката из CAD датотека [17].

Потребно је креирати аутономну веб апликацију на технологији вештачке интелигенције која ће прихватити 3D CAD датотеку и идентификовати сваки објекат у њој (слика 6.2).



Слика 6.2. Фаза 2 [17]

6.1.3 Изазови у примени машинског учења на геометријске податке

Већина машинског учења се врши на структурисаном скупу података. Скуп података се може назвати структурисаним када све тачке података у скупу података могу увек бити представљене са истим бројем карактеристика [17].

Данас је на пољу машинског учења постигнут огроман успех у скуповима података који се састоје од слика, текста, звука и бројева. Све су то структурисани подаци. Међутим, ниједан проблем из стварног света није инхерентно структурисан по природи. Научници о подацима раде на претварању ових неструктурисаних података прикупљених из стварних проблема у структурисани образац, тако да се алгоритми машинског учења могу применити на њих.

6.1.3.1 Припрема скупа података

Машинско учење у великој мери зависи од података. Ако човек не може да схвати записе података, машина ће бити готово бескорисна или можда чак и штетна. Због тога је припрема скупа података тако важан корак у процесу машинског учења. Укратко, припрема података је скуп поступака који помажу да скуп података буде погоднији за машинско учење [17].


Процес припреме података за алгоритам машинског учења може се сажети у наредне кораке.

6.1.3.2 Скупови података

Скупови података су саставни део поља машинског учења. Поседовање богатих података помаже алгоритмима за учење да прецизније уче и учине модел машинског учења поузданијим. Високо квалитетни означени скупови података за обуку за надгледане и полунадгледане алгоритме учења обично су тешки и скупи за производњу [17].

На слици 6.3 је приказан пример базе података 3D CAD модела. Постоји укупно 1.500 модела који припадају неколико генеричких категорија: мотор, вентили, зупчаници, завртњеве, навртке, точкови, кључеви, кућишта лежајева, прирубнице, подлошке, итд.

Ових 1.500 модела садржи 37 милиона бројева троуглова који су подељени у три дела: обука, валидација и тест. Сет за обуку и сет за валидацију користе се за извођење модела и одабир хиперпараметара, док се тест сет користи за процену коначне грешке генерализације и непристрасан начин упоређивања различитих класификатора. На слици је приказан само део 3D модела из скупа података.



Слика 6.3. Скуп података [17]

Ознаке троуглова у комплетном скупу података категорисане су на начин приказан у табели 6.1.

Табела 6.1. *Ознаке троуглова* [17]

Торус	Цилиндар	Раван	Б завојни	Сфера	Купа
28.47 %	23.16 %	16.30 %	14.5 %	10.9 %	6.67 %

6.1.3.3 Генерисање карактеристика

Генерисање карактеристика је такође познато као конструкција карактеристика, екстракција или инжењеринг карактеристика. Постоје различита тумачења појмова генерисање, конструкција, екстракција и инжењеринг. Неке готово еквивалентне, а различите дефиниције ових појмова су [17]:

- конструкција карактеристика из сирових података,
- стварање мапирања за претварање оригиналних карактеристика у нове,
- стварање нових карактеристика од једне или више функција.

То је процес коришћења знања о домену о подацима за стварање карактеристика које алгоритми машинског учења раде. Карактеристични инжењеринг је од пресудног значаја за примену машинског учења и истовремено је тежак и скуп.

Карактеристика је атрибут или својство које деле све независне јединице на којима треба извршити анализу или предвиђање. Било који атрибут може бити карактеристика, све док је користан моделу.

Према специфичној природи домена проблема, одабир карактеристика које имају очигледно препознатљиво значење је пресудан корак у припреми овог приступа. Карактеристике би требале бити непроменљиве до небитне деформације, неосетљиве на буку и врло ефикасне за разликовање различитих категорија CAD модела.

Повећањем података постало је јасно да унос алгоритма учења може имати значајан утицај на перформансе алгоритама учења. Стога претходна обрада података постаје све важнија. Претходна обрада података је збирни назив за све методе којима је циљ осигурати квалитет података. Дакле, у претходној обради података фокусира се на две методе које се називају генерисање и избор карактеристика.

У случају са слике постоје само координате тачака у тродимензионалном простору. Из ових координата постоје одређена својства троугла која се могу извести попут површине, односа ширине и висине, дужине ивица, опсега, удаљености тежишта од сва три темена, унутрашњих углова, нормале троугла, валенције троугла, врсте троугла и многих других.

Такође, изведене су карактеристике из наведених својстава, јер изведена својства представљају начин за убацивање стручног знања у процес обуке и тако га убрзавају. Неке од изведених карактеристика су однос угла између нормале, однос дужине ивица, удаљеност тежишта од другог троугла, осветљеност троугла, итд.

Потребно је алгоритму вештачке интелигенције дати знање о визуелним информацијама свих троуглова које ће покушати да категорише, а то је чврст угао. Чврст угао је мера величине видног поља са неке одређене тачке коју дати објекат покрива, односно то је мера колико се велики објекат чини посматрачу који гледа од те тачке.

6.1.3.4 Анализа и визуализација података

Након добијања скупа података, следећи корак у току израде модела је увек анализа података. Анализа података се врши коришћењем општих статистичких алата, при чему се добијају нумеричке вредности које се састоје од броја, максималне вредности, минималне вредности, средње вредности, стандардне девијације и опсега квантила. Ове нумеричке вредности пружају униваријантну анализу података које је понекад тешко прочитати кроз вредности. Анализа података је лакша помоћу алата за визуелизацију података, јер неки алати помажу у повезивању различитих карактеристика података [17].

Разумевање увида у коришћење датотека постаје све теже како се величина скупа података повећава. За визуализацију података користе се различити графикони и графикони за визуализацију података како би се олакшало откривање образаца података. То помаже у идентификацији области којима је потребна пажња и разумевању фактора који имају већи утицај на резултат. Сви подаци се преносе у неки облик парцела и даље анализирају.

6.2 Помагање у конструисању кроз машинско учење

Коришћење машинских препорука искоришћено је у небројеним индустријама. У основи, механизам за препоруке може да тражи релевантне информације (текст, слике итд.) међу огромним базама података и да их прикаже кориснику док он комуницира са датим интерфејсом. Како се велика 3D складишта података данас обједињују, конструисање би могло имати користи од сличних пракси [18].

У ствари, процес конструисања се углавном одвија путем 3D софтвера. Углавном путем CAD софтвера (*Computer-Aided Design*) или данас BIM мотора (*Building Information Modeling*) конструктори непрестано преводе своју намеру у линије и површине у 3D простору. Предлагање релевантних 3D објеката, преузетих из спољних извора података, могао би бити начин за побољшање њиховог процеса конструисања.

Примена машинског учења у конструисању може омогућити помоћ конструкторима кроз „сугестивно моделирање“. Док конструктори цртају у 3D простору, низ класификатора заснованих на машинском учењу могао би да тражи релевантне сугестије и предложи алтернативне, сличне или комплементарне опције дизајна.

У том циљу, узимајући инспирацију из преседана на пољу 3D препознавања и класификације облика, потребно је користити методологију и скуп алата који могу предложити моделе конструкторима док цртају. Циљ ове методологије је:

- убрзати процес 3D моделирања унапред моделираним сугестијама и
- инспирисати конструкторе кроз алтернативне или комплементарне опције конструисања.

6.2.1 Конволуционе неуронске мреже

Могућност постављања упита 3D објектима који се подударају са карактеристикама дизајна који је нацртао корисник ослања се на упоређивање карактеристика. Далеко од стандардне геометријске дескриптивне метрике, конволуционе неуронске мреже нуде поједностављену и свеобухватнију опцију за упоређивање облика [18].

Уместо да се подударају са једноставним метрикама, које се такође називају екстракција карактеристика, конволуционе неуронске мреже узимају слике као улаз, прослеђујући приказ пиксела у низу слојева „неурона“. Модел конволуционе неуронске мреже подешава пондере у сваком неурону док даје предвиђање на његовом последњем слоју. Кроз узастопне фазе обуке и валидације, конструктор је у могућности да процени тачност модела и даље подешава тежине како би се максимизирала тачност. Једном када се потпуно обучи, модел конволуционе неуронске мреже предвиђа „класу“ или категорију датог представљања слике објекта.

Ова врста мреже је стандардна пракса у машинском учењу и сама по себи не представља сложену архитектуру. Међутим, њена способност да изгради одређену количину интуиције искључиво на основу просторних карактеристика више је него релевантна за њену примену. Способност да се објекти узму у обзир само на основу њихових тополошких карактеристика, користећи слике, нуди робустан обједињујући оквир за упоређивање и проналажење 3D облика.

6.2.2 Преседани

Три главна истраживачка пројекта, која су недавно структурисала поље препознавања и класификације 3D објеката, откривају важност конволуција као идеалног алата за разумевање и описивање 3D облика [18].

6.2.2.1 Конволуционе неуронске мреже са више приказа за препознавање 3D облика

Овај пример представља стандардну архитектуру конволуционе неуронске мреже обучену за идентификацију приказаних приказа облика независно једни од других и показује да се 3D облик може препознати чак и из једног приказа са тачношћу далеко већом од коришћења најсавременијих дескриптора 3D облика. Стопе препознавања се даље повећавају када се пружају вишеструки прикази облика [18].

Поред тога, представљена је нова архитектура конволуционе неуронске мреже која комбинује информације из више погледа 3D облика у један компактан дескриптор облика који нуди још боље перформансе препознавања.

6.2.2.2 3D револуционарна неуронска мрежа за препознавање објеката у реалном времену

Да би се повећала количина база података облака тачака предлаже се „VoxNet“. Архитектура овог модела има за циљ да се позабави питањем велике обраде облака тачака и означавања, интегришући волуметријску репрезентацију мреже заузећа са надгледаном 3D конволуционом неуронском мрежом [18].

6.2.2.3 Волуметријске репрезентације и машинско учење у конструисању

Овај пример истражује могућности моделирања воксела уз машинско учење [18].

Појам моделирања воксела је први пут представљен и упоређен са традиционалном техником моделирања. Објашњени су концепти као што су мапа пиксела и графикони, да би се коначно испитале прототипичне примене предложених дизајнерских система или токова рада заснованих на процесу од растеризације простора и геометрије уз машинско учење.


6.2.3 Дефиниција модела

Циљ овог приступа је да препозна објекат који корисник скицира и понуди сличне објекте једноставним коришћењем облика објекта као заступника [18].

Укратко, модел који се дизајнира бави се са два главна задатка:

- 1) класификација - идентификовање врсте предмета који корисник скицира, тј. проналажење одговарајуће ознаке („столица“, „клуба“, „кревет“, итд.) за било који дати унос слике, повезан са оценом поузданости предвиђања и
- 2) подударање - испитивање, у бази података о 3D објектима, неких облика који се најбоље подударају са аспектом корисниковог моделираног уноса, тј. враћање листе објеката пронађених у бази података, поређаних од најсличнијих до најмање сличних.

Као што је приказано на слици 6.4, спајањем два различита нивоа модела (класификација и подударање), овај поступак се може извести у два корака. Сваки модел ће бити обучен на сликама 3D објеката, а затим ће бити тестиран на сликама објеката које је корисник моделирао.




Слика 6.4. Спајање класификације и подударања [18]

6.2.3.1 Извор података и генерисање

Први корак је стварање базе података за обуку модела. Будући да је ова методологија намењена дељењу, потребно је прво издвојити информације из постојећих јавних складишта 3D објеката [18].

Користећи *Rhinceros* и *Grasshopper*, скриптира се алат за стварање скупова за обуку и валидацију. У овој скрипти, ротирајући око сваког узастопног објекта камера снима објекат под одређеним углом и снима JPG слике у дати директоријум.

Слика 6.5 приказује типичан пут камере (лево) и резултујуће слике (десно).



Слика 6.5. Пут снимања слика и резултирајуће слике [18]

За сваки објекат се узима 30 слика за обуку и 10 за валидацију, задржавајући белу / неутралну позадину.

Напокон, добија се библиотека означених слика, за 10 предмета по класи, који имају укупно 14 различитих класа.

6.2.3.2 Класификација


Када је скуп података спреман, циљ је да се обучи први модел, класификатор, на великим количинама слика 3D објеката, истовремено проверавајући његове перформансе на скуповима слика других објеката, који припадају сличним класама [18].

Неколико параметара снажно утиче на тачност обученог класификатора, а то су:

- величина сета за обуку и валидацију,
- број часова,
- број објеката по класама,
- број слика по објекту,
- величина слика у оба сета и
- пут снимања камере око објекта.

Након тога, врши се понављање између различитих опција и тежи повећању укупне тачности модела на сету за валидацију. Због ограничених ресурса, коришћење неког трансфер учења добро дође, јер нуди могућност повећања тачности модела заобилазећи дане обуке.

Кључни недостатак овог процеса обуке је тај што пут камере заправо значајно утиче на резултирајућу тачност. На слици 6.6, илустроване су упоредне перформансе две различите путање камере, кружне и сферне.



Слика 6.6. Перформансе тренинга под различитим техникама снимања слика [18]

На крају, бира се класификатор са сферном путањом камере, 30 слика по објекту за обуку и 10 за валидацију. После 30 епоха, коначно се добија тачност на скупу за валидацију од 93%. Сада се чини јасно да следећи параметри у великој мери утичу на перформансе целокупног модела:

- повећавање величине слике повећава тачност;
- пут снимања камере такође директно утиче на тачност. Коришћењем сферне путање снимања, уместо кружне, значајно се побољшавају перформансе модела, односно тачност је много већа, након мање епоха. Чини се да је употреба сферне путање холистичкији начин за снимање аспекта датог облика;
- како се предмет моделира, толико мало површина ће бити довољно да гурне класификатор у правом смеру. Као резултат, на самом почетку процеса моделирања, постоји могућност да се идентификује класа моделираног објекта. Заузврат се могу кориснику предложити модели из базе података, потенцијално смањујући време 3D моделирања, уколико корисник пронађе подударане међу предлозима.

6.2.4 Уклапање

У другом кораку, модел покушава пронаћи идеална подударања у опсежној бази података 3D модела. Ако модел класификације помаже у сужавању претраге, одговарајући модел рангира све 3D моделе из дате класе од најсличнијих до најмање сличних [18].

Модел подударања је још једна конволуциона неуронска мрежа, обучена на сликама објеката дате класе и потврђена на истим објектима, са погледима снимљеним из различитих углова. Приликом тестирања, као улаз се користи једна слика 3D модела који је креирао корисник, а излаз је листа свих објеката у бази података идентификоване класе, ранжираних по редоследу сличности.

Обучавањем одговарајућег модела за сваку појединачну класу, настаје могућност да се класификациони модел и одговарајући модели групишу као један. Након тога се може обрадити улазна слика која ће прво бити класификована и коначно подударана са сличним

објектима присутним у бази података. У исто време, модел даје извесно поверење у предвиђање да би помогао да се процени колико је заправо слична сличност између оригиналног и уклопљеног модела.

6.2.5 Закључно разматрање

Много је урађено у овој области и донело је решења за суседна поља. Груписање модела конволуционе неуронске мреже само је једна могућа верзија већег концепта - препознавање и сугестија 3D облика. Могли би се применити и други приступи и модели како би ширина и богатство јавно доступних података били на дохват руке архитектама и конструкторима [18].

Као што је овде показано, како би се пронашао заједнички језик, омогућавајуће поређење различитих и сложених облика, може се у одређеној мери ослонити на машинско учење.

На темељнијем нивоу, овај приступ једноставно показује потенцијал сугестивног конструисања. Доносећи релевантне алтернативе конструкторима током креативних активности конструисања, има прилику да прошири опсег њиховог рада.

6.3 Методологија за класификацију делова уз надгледано машинско учење

Истраживање у овом примеру примењује препознавање узорака, односно класификацију кроз надгледане технике машинског учења за идентификацију облика и производње у CAD базама података. Циљ је побољшати управљање инжењерским подацима користећи апроксимативну геометрију ниског нивоа CAD модела. Техника олакшава проналажење и архивирање предмета за инжењере, подстиче поновну употребу делова и дизајна ради побољшања управљања животним циклусом производа и убрзава конструисање и производне процесе производа [19].

Аутоматска CAD класификација може се моделирати у оквиру препознавања узорака / класификације, тако да се различите карактеристике модела и класификатора могу међусобно заменити како би се произвеле различите шеме класификације. Истраживање подудараности облика представило је разне дескрипторе који бележе облике модела.

У машинској индустрији, широка употреба алата за рачунарски потпомогнути дизајн (*Computer-Aided Design - CAD*) произвела је велике скупове података о моделима производа. У том контексту, могућност једноставног проналажења, а затим поновне употребе / модификације постојећих CAD модела била би од највеће важности за убрзавање развоја нових производа. У том циљу су последњих деценија у компаније уведени PDM (*Product Data Management*) системи за организацију и документовање њихових старих података о производима. Стога се модели могу преузимати у складу са усвојеном организацијом и метаподацима наведеним за описивање делова и склопова. Дакле, могућности проналажења елемената снажно зависе од информација које су доделили конструктори, а не од стварног садржаја модела. Ово може бити велико ограничење, такође узимајући у обзир да не усвајају све компаније PDM системе и да се често PDM могућности

користе само делимично. Поред тога, наслеђени модели произведени пре увођења PDM система често се архивирају у систему датотека, а да нису правилно документовани, тако да је тешко доћи до њих. Да би се превазишле ове границе, истраживачке заједнице су истраживале методе проналажења засноване на облику, а сада се појављују и неки комерцијални алати. Ови системи обично омогућавају претрагу 3D модела сличних датом објекту упита формираном једним делом. Чак и ако се машински производи углавном састоје од неколико компоненти, само неколико метода се бави проналажењем склопова. Суочавање са склоповима уводи додатне проблеме у вези са организацијом компонената, који обично нису експлицитно кодирани у моделу, као и поједностављењем компоненти, које се често дешава када се компоненте набављају од треће стране. Иако се већина истраживања која се предлажу у литератури углавном фокусира на процесно оријентисану класификацију (нпр. сличне методе израде) или на геометријску сличност делова и склопова, значајне би биле могућности проналажења које су више оријентисане на сврху дела или примењених механизма у моделу. Потпуно аутоматизована функционална класификација делова заснована само на њиховом облику готово је немогућа, јер делови који су наизглед идентични могу имати различиту употребу, а исте функције могу обављати делови различитог облика [20].

Разумевање функционалности дела или компоненте у склопу захтева расуђивање не само о облику његових елемената већ и о његовој употреби у производу. У ствари, с једне стране, поједностављени делови сличних облика могу одговарати за извођење различитих функционалности, што се може приметити из њиховог контекста употребе, односно како су делови уграђени у модел склопа. С друге стране, чак и ако се функционални скуп може добити са различитим допунским деловима организованим на различите начине, неке компоненте и аранжмани се стално понављају. Стога, инжењерско знање о функционалним скуповима може пружити корисне индикације за класификацију компонената, а тиме и за идентификацију специфичних механизма. На пример, функционални скупови чији је задатак трансформација улазног кретања углавном укључују осе на које су уметнути зупчаници, одстојници и лежајеви. Појаве овог скупа делова добар су показатељ присуства тог типа механизма. Заиста, идентификација компонената склопа које потенцијално припадају овим класама (тј. оса, зупчаници, одстојници и лежајеви) може у великој мери поједноставити препознавање механизма у великим моделима склопа. На основу ових разматрања, овај приступ класификације делова примењује се у више корака у систему за проналажење модела склопа. Развијена су два специфична модула:

- 1) први додељује категорију сваком делу само у складу са карактеристикама његовог облика и
- 2) затим искоришћавајући инжењерско знање, други модул процењује и, ако је потребно, исправља почетну класификацију засновану на облику анализом контекста употребе дела у склопу са крајњим циљем идентификовања компоненти које представљају специфичне функционалне скупове.

Постојећа истраживања за класификацију машинских делова укључују алгоритме који раде са различитим дескрипторима облика на основу пројектованих профила,

екстракцијом карактеристика и функцијама повезаним са обликом. У сваком случају, препознаје се да не постоји ниједан дескриптор који има добар учинак у свим разним врстама облика.

6.3.1 Спецификација проблема и сродни радови

Циљ је обезбедити аутоматизовани класификатор који може да повеже одређену категорију са 3D моделима машинских компонената [20].

На проблем класификације може се гледати као на подударање и проналажење 3D CAD података. У литератури су представљени различити поступци за проналажење 3D објеката који могу да укључују више функционалних или апликативних аспеката.

Marini и сарадници предлажу технику за дефинисање прототипа 3D облика за класификацију 3D садржаја. Дефинисани прототип облика резимира најрелевантније особине чланова класе. У овој методи, сваки члан класе представљен је структурним дескриптором кодираним као атрибутни графикон. Прототип се добија применом техника трансформације графикона међу дескрипторима облика који су повезани са члановима класе. Метода се боље примењује на уочене макро категорије објеката и не одговара машинским деловима са малим разликама.


У машинском пољу, *Jayanti* и сарадници пружају поређење примене метода кластеровања на 3D моделе. Додатни радови се баве категоризацијом делова према одређеним процесима конструисања. Међу њима, *Pernot* и сарадници баве се проблемом категоризације производа у смислу карактеристика које би могле утицати на поједностављење делова за Анализу коначних елемената (*Finite Element Analysis - FEA*). У ту сврху, користећи комбинацију дескриптора облика, делови су класификовани у три категорије: танки делови, делови са танким деловима и нормални делови. Нажалост, ова класификација је сувише груба да би се могао разабрати ефикасан облик делова. Ипак, у контексту припреме модела FEA, *Shalwan* и сарадници идентификују функционалне компоненте у склоповима, као што су завртањи, цевасте закивци и зупчаници. Овај приступ претпоставља да су сви делови у потпуности детаљни и снажно се ослања на геометријске интерференције између компонената и на способности закључивања на структурисаном формализованом инжењерском знању (у облику онтологије). Према томе, није у могућности да пружи назнаке било које категорије, било за појединачне делове који нису у склопу, нити за делове у склопу поједностављеног облика. Производне карактеристике су коришћене за процену и класификацију сличности од стране *Cicirello* и *Regli*. Главни недостаци коришћења карактеристика леже у потреби за поступком препознавања карактеристика, који даје резултате врло осетљиве на интеракције између карактеристика и не узима у обзир целокупан облик предмета.

Ip и сарадници дефинишу нови простор карактеристика на основу метричких карактеристика (унутрашње, спољашње и мешовите удаљености) преко којих приступају класификацији чврстих модела користећи технике учења (стабло одлучивања и учење са подршком), које омогућавају аутоматизовану категоризацију модела точкова, утичница, кућишта и сл. *Yiu Ip* и *Regli* представљају још један приступ аутоматизацији класификације

CAD модела помоћу техника машинског учења. У новије време, Qin и сарадници представљају аутоматизовани приступ класификацији 3D CAD модела заснован на техници дубоког учења. Класификатор је у стању да опонаша главне фазе процеса ручног класификовања у којима инжењер обично отвара 3D модел са CAD софтвером, ротира га на екрану, посматра га из пожељних углова посматрања, а затим синтетише слике да би се добила семантичка категорија. Wang и сарадници предлажу ново решење за проналажење 3D CAD објеката коришћењем конволуционе неуронске мреже која обрађује информације добијене методама заснованим на скицама и облику.

6.3.2 Приступ класификацији машинских делова

Као што је претходно речено, потребно је машинске делове повезати са одговарајућом категоријом. Иако се зна да је облик препознатљиви аспект делова, класификација заснована само на карактеристикама везаним за облик је немогућа. Слични облици могу задовољити различите функционалне циљеве, а штавише делови могу бити поједностављени када се убаце у склопове. Због тога се предлаже двофазни приступ приказан на слици 6.7 [20].



Слика 6.7. Предложени поступак класификације дела [20]

Прва фаза се примењује на појединачне делове како би се повезала најприкладнија категорија на основу карактеристика облика. Друга фаза се може применити само на делове уметнуте у склоп. У овој фази анализирају се делови према њиховој категорији како би се проценила исправност класификације. Евалуација користи инжењерско знање о генерално присутним интеракцијама између компонената у одређеним механизмима. Образложење је да одређена машинска компонента може да обавља своју функцију у оквиру функционалног скупа ако је постављена у складу са одређеним условима у односу на одређене класе компонената. Стога, да би се утврдило да ли компонента ефикасно припада додељеној класи, проверавају се њени односи са осталим компоненатама склопа, на пример, са којим врстама компонената / делова део који се испитује комуницира. Делови се анализирају класа по класа према датом редоследу. Ако део не поштује очекивано стање, он ће бити преквалификован у категорију која још увек није анализирана и која највише обећава.

Општи поступак анализе података заснива се на следећим корацима:


- прикупљање података:
 - добијање података,
 - визуелно истраживање простора података,
 - чишћење података,
- издвајање и анализа карактеристика:
 - издвајање особина,
 - истраживачка анализа простора карактеристика,
 - претходна обрада простора карактеристика,
 - избор карактеристика,
 - смањење карактеристика,
- моделирање класификатора:
 - моделирање система класификатора,
 - валидација модела,
 - визуелизација модела,
 - визуелизација и интерпретација резултата,
- анализа резултата:
 - примена модела,
 - визуализација резултата.

6.3.2.1 Прикупљање података

Примена техника учења за откривање најважнијих параметара и вредности за класификацију снажно се ослања на сет обуке. На исти објекат могу се применити различите класификације у зависности од сврхе. *Jayanti* и сарадници су предложили референтну базу података за процену метода претраживања заснованих на облику, релевантних за домен машинства. У том циљу, организација скупа података у класама изводи се у складу са главним карактеристикама облика делова како би се верификовале могућности различитих дескриптора облика да сними одређене квалитете облика. Слично томе, скупови података *Drexel CAD* модела пружају различите скупове података где су елементи класификовани према различитим критеријумима, на пример, производни процеси, функционалност, резолуција модела. Ови класификовани скупови података делимично су прикладни. Неки од њих не нуде функционалну класификацију, док други укључују само делове који су потпуно детаљни. Поред тога, њихов број елемената није довољан за правилно оспособљавање система учења. Због тога је потребно креирати сопствени скуп података који проширује категорије како би омогућио класификацију делова који нису у потпуности дизајнирани и додати примере у сваку категорију у циљу појачавања алгоритма обуке [20].

Скуп података добија се прикупљањем модела из различитих извора, као што су два позната онлајн бесплатна каталога (*GrabCAD* и *TraceParts*) и пројекти студената инжењерства. Ова класна организација је углавном функционално оријентисана. Међутим, уколико је потребно да се у поједностављеној верзији класификују и делови уметнути у склоп, укључују се примитивне класе запремине, попут сфере, које би требало да се

реклаификују у фази ревизије класификације засноване на контексту. На пример, тороидни део на слици 6.8 (а) и сфере на слици 6.8 (б) не могу се тумачити као елементи котрљања носеће компоненте без разматрања околних делова. Заправо, део у облику торуса такође се може користити за дизајн заптивке чија је функција обезбеђивање непропусности за течност.



Слика 6.8. Објекти чија се функција не може утврдити без узимања у обзир контекста употребе [20]

У овом примеру размотрено је 15 класа назначених у табели 6.2.

Табела 6.2. Категорије у скупу података [20]

Број категорије	Категорија	Број елемената
1	Осе	92
2	Лежај	26
3	Ускочник	202
4	Налик цилиндру	162
5	Налик коцки	111
6	Зупчаник	124
7	Кључ	25
8	Везни елементи	14
9	Матица	251
10	Остало	420
11	Део лежаја	274
12	Завртњев	454
13	Одстојник	123
14	Налик сфери	30
15	Налик торусу	46

Организација класа је креирана тако што је прво додељена објектима према њиховој расподели у оригиналним складиштима. Из расположивих пројеката изабрани су додатни делови. Затим су елементи који се могу користити у склопу са различитим значењима премештени у класу која ће се лакше препознати када се узме у обзир њен контекст


употребе. Дакле, скуп података се састоји од 15 категорија и садржи 2354 елемента. Слика 6.9 приказује слике елемената у категоријама. Категорије и број објеката по категорији приказани су у табели 6.2. Неке категорије имају мало елемената, јер нема много варијација њиховог облика.



Слика 6.9. Репрезентативни објекти у категоријама скупова података [20]

Одстојни елементи класе разликују се од елемената у облику цилиндра, јер имају најмање рупу дуж главне осе.

Одлучено је да се уведу класе „Лежај“ и „Део лежаја“, јер се лежај може моделирати и као склоп саставних делова и као један део који одговара споју саставних елемената. У првом случају, делови могу имати неколико облика. У једноставнијој примени лежај се може моделирати као три прстена (цилиндри са средишњом пролазном рупом), али понекад је унутрашњи део представљен као торус или образац примитивних облика попут сфера или цилиндара, можда укључујући кавез, који поправља положај ваљаних елемената чији је облик променљив. Примери различитих приказа лежајева приказани су на слици 6.10.



Слика 6.10. Пример лежајева: лево - лежај по моделу од три цилиндрична прстена и десно - лежај по моделу од два омотача и обрасцем од сфера [20]

Чини се да су неки делови лежајева слични одстојницима, али дужина одстојника дуж осе је већа од пречника, док делови лежајева који изгледају као одстојници имају пречник већи од дужине.

6.3.2.2 Издавање својстава

Алгоритми машинског учења захтевају скуп карактеристика које дискриминишу објекте који припадају различитим предложеним класама користећи неке мерљиве карактеристике. Будући да је потребно делове класификовати према њиховом облику, описи облика се користе као одлике приступа машинском учењу. У овом примеру нису дефинисани нови дескриптори, већ су у паметном окружењу комбиноване већ развијене геометријске и статистичке карактеристике. Међутим, посвећен је велики напор у проналажењу одговарајућег скупа карактеристика за класификацију облика. Литература садржи десетине дефиниција дескриптора за анализу облика и нема ниједног дескриптора који се понаша боље од других. У сваком случају, постоје дескриптори који имају бољи учинак за категорије облика са специфичним карактеристикама. Стога су, коришћењем претходних резултата истраживања и узимајући у обзир ефикасност израчунавања и поређења, одабрани они дескриптори који су погоднији за класе делова приказане на слици 6.9. Тачније, објекти који треба да се класификују су обртна чврста тела (нпр. оса, одстојник и завртањ), призматични делови (нпр. коцка и навртка) и танкозидни делови (нпр. ускочник). Дескриптори који најбоље представљају ове класе су 3D сферне хармонике, геометријска статистика, унутрашња растојања и расподела облика. Одабрани дескриптори израчунавају се помоћу слободно доступних алата на моделима у облику мозаика, који се могу произвести из било којег CAD система и из обрнутог инжењерског процеса [20].

Да би се извршила класификација, потребно је пројектовати објекте у нови простор карактеристика. Простор карактеристика формира колекција дескриптора облика и геометријске статистике, који су инваријантни код крутих трансформација, односно њихова вредност се не мења за трансформације као што су транслације и ротације. Нови простор има 875 карактеристика и садржи целе, бинарне и реалне бројеве.

За сваки објект израчунавају се следеће карактеристике:

- 1) 3D сферне хармонике - # 544 карактеристике,
- 2) геометријска статистика - бр. 11 карактеристика,
- 3) унутрашња растојања - # 256 карактеристика,
- 4) расподела облика - # 64 карактеристике.

6.3.2.3 3D сферне хармонике


3D сферне хармонике укључене су у предложени простор карактеристика због њихове способности да разликују обртна чврста тела. Поред тога, овај дескриптор има добре перформансе и у случају призматичних делова [20].

3D сферне хармонике делују слично *Fourier*-овој анализи сигнала, али на сферне функције. У проучавању *Fourier*-ових серија, компликоване, али периодичне функције записују се као пондерисани збир једноставних тригонометријских функција.

Kazhdan и сарадници су предложили нови дескриптор сферне функције инваријантне ротације ради задовољавања задатка упоређивања облика. Алгоритам примењује следећи поступак:

- разлагање функције на њене хармонике,
- збир хармоника унутар сваке фреквенције,
- израчунавање норме сваке компоненте фреквенције.

Резултат ове методологије је нормализовани хистограм, у овом случају од 544 карактеристике, који извештава о вредности збира хармоника за дату фреквенцију. Ова метода представља окосницу неколико алгоритама за упоређивање облика, али у овој студији случаја не успева у класификацији врло сличних објеката који припадају двеју различитих категорија, на пример, осе и завртањ на слици 6.11. Да би се превазишло ово ограничење, у простор карактеристика се додају друге карактеристике.



Слика 6.11. Пример два објекта (лева оса, десно апстрактни завртањ) који се не разликују правилно сферним хармоникама, али их класификатор правилно препознаје [20]

6.3.2.4 Геометријска статистика

Танкозидне компоненте одликују се већом површином и мањом запремином. Једноставне геометријске статистике имају бољу перформансу од осталих сложенијих дескриптора у њиховој карактеризацији. Стога, са овом врстом карактеристика, прикупљају се информације које су у стању да узму у обзир величине и пропорције међу странама [20].

Конкретно, вредности које се сматрају под називом геометријске статистике су:

- величина минималне граничне кутије,
- пропорција између дужине и висине минималне граничне кутије,
- пропорција између дужине и ширине минималне граничне кутије,
- пропорција између висине и ширине минималне граничне кутије,
- дужина дијагонале минималне граничне кутије,
- површина и
- танка љуска барицентра.

Почиње се са израчунавањем димензија минималне граничне кутије, која представља кутију са најмањом мером унутар које леже све тачке дела. Из граничног оквира се изводе друге статистике, које пружају индикације о глобалној дебљини предмета.

6.3.2.5 Унутрашња растојања

Унутрашња растојања се користе за изградњу дескриптора који може добро да окарактерише призматичне делове [20].

Унутрашње растојање је дефинисано као дужина најкраћег пута између оријентисаних тачака унутар облика и добро одражава структуру и деформације без експлицитног распадања. Унутрашња растојања чувају се као хистограм који даје расподелу вероватноће унутрашњих растојања између свих парова тачака узорка на површини.

6.3.2.6 Расподела облика

Да би се побољшала карактеризација чврстог обртног дела и делова са танким зидовима, с обзиром на преглед који су предложили *Jayanti* и сарадници, расподела облика је укључена у простор карактеристика [20].

Овај дескриптор је представљен у раду *Osada* и сарадници, где су се аутори позабавили проблемом мерења сличности између 3D облика помоћу функције облика која бележи глобална геометријска својства објекта. Аутори су истакли следеће функције облика:

- A3 - мери угао између три случајне тачке на површини 3D модела,
- D1 - мери растојање између фиксне тачке (нпр. тежишта границе) и једне случајне тачке на површини,
- D2 - мери растојање између две случајне тачке на површини,
- D3 - мери квадратни корен површине троугла између три случајне тачке на површини,
- D4 – мери кубни корен запремине тетраедра између четири случајне тачке на површини.

Експериментални резултати овог приступа и потврђени од стране *Jayanti* и сарадника сугеришу да је овај дескриптор добар избор за упоређивање облика, јер представља добар компромис с обзиром на ефикасност и добијене резултате.

6.3.2.7 Дескриптор светлосног поља


Дескриптор светлосног поља је самоконсистентна класа карактеристика чији је циљ да ухвати визуелну сличност 3D објеката. Дескриптор светлосног поља су увели *Chen* и сарадници, а добија се рачунањем *Zernike*-ових момената и *Fourier*-ових дескриптора на 100 ортогоналних пројекција објекта. Аутори су такође развили систем за 3D проналажење заснован на дескриптору светлосног поља који надмашује остале системе за проналажење заснованих на сферним хармоникама. Због тога, да би се процениле могућности комбиновања различитих дескриптора као карактеристика, овај систем класификације

делова се упоређује са оним добијеним коришћењем само простора карактеристика дескриптора светлосног поља. Алат узима као улаз ОБЈ датотеку и ствара 5 бинарних датотека [20].

6.3.2.8 Истраживачка анализа простора карактеристика

Овај задатак пружа прелиминарни опис скупа података у новом простору карактеристика, а затим помаже у смањењу простора карактеристика, уз очување његових главних карактеристика [20].

Мапа топлоте је графички приказ података матрице где су елементи матрице представљени у боји. Пример мапе топлоте је мозаична карта. Мозаична карта је плочаста мапа топлоте која представља двострану или вишестрану табелу података. Правоугаоне регије у мозаичној карти представљају податке који су хијерархијски организовани или који су прилично слични. Анализа мозаичне карте на слици 6.12 открива модуларну структуру, али растојања међу објектима имају тенденцију да буду прилично близу нуле. Ово указује на неопходност повећања удаљености (раздвајања) између предмета који припадају различитим класама. У супротном, метрички систем груписања могао би бити довољан и могао би се користити за класификацију машинских делова.




Слика 6.12. Мапа топлоте стандардизованих еуклидских растојања међу деловима у карактеристикама простора [20]

6.3.2.9 Претходна обрада простора карактеристика

Уколико претходна анализа сугерише да се скуп података мора побољшати, односно уколико објекти у простору карактеристика нису снажно одвојени, пре обуке алгоритама за класификацију потребно је проверити исправност скупа података. Овај корак се често означава као прочишћавање података. То је поступак исправљања или уклањања података у скупу података који су нетачни, непотпуни, неправилно форматирани или дуплирани. Бескорисни или оштећени подаци могу се открити применом неке једноставне валидације статистичких података, руковањем подацима који недостају и евентуалним брисањем дуплираних вредности. Недостајући или ретки подаци могу довести до веома обмањујућих резултата. Рачунају се следеће статистике [20]:

- бесконачне вредности или број вредности без броја,
- број дуплираних вредности по карактеристикама,
- број дуплираних карактеристика,
- број вредности које недостају и
- тест хетеросцедастичности.

На слици 6.13 је приказан проценат дупликата за сваку карактеристику (сферне хармонике, геометријске статистике, унутрашња растојања и расподелу дескриптора облика), а одговарајуће вредности су приказане у табели 6.3.



Слика 6.13. Проценат дупликата за сваку карактеристику [20]


Табела 6.3. Учесталост карактеристика са дуплираним вредностима [20]

Број карактеристика	Опсег фреквенције (%)
561	0-9.8
82	9.8-19.6
62	19.6-29.4
30	29.4-39.2
17	39.2-49
17	49-58.8
18	58.8-68.6
15	68.6-78.4
30	78.4-88.2
43	88.2-100

Откривено је да само једна карактеристика садржи 98% дупликата, са вредношћу једнаком нули.

Након нормализације, процењен је ефекат дупликата на растојање међу карактеристикама итеративним уклањањем карактеристика са дупликатама. Прво се уклањају функције са већим бројем дупликата, а затим у свакој итерацији остале. Овај корак побољшава раздвајање класа, али неке класе се и даље преклапају и из тог разлога за класификацију делова не могу се користити системи груписања засновани на метрици и потребан је нелинеарни интерполатор.

На слици 6.14 приказана је мапа топлоте након чишћења података.



Слика 6.15. Мапа топлоте стандардизоване еуклидске матрице растојања након чишћења података [20]

6.3.2.10 Избор карактеристика

Да би се побољшао квалитет и смањило рачунско време и употреба меморије класификатора, изводи се смањење простора карактеристика. Технике одабира карактеристика могу се класификовати у три сета: омотач, уграђене и филтер. У приступу омотач, алгоритам за класификацију је директно укључен и користи се за бодовање датог подскупа карактеристика. Уграђене методе су у основи итеративни алгоритми који додају процес одабира у шему учења класификатора. Методе филтрирања користе статистику за анализу својствених карактеристика података и оне раде без обзира на алгоритам класификације. Генерално, излаз избора функције је ранг или одабир подскупа. У првом се процењује важност сваке појединачне карактеристике, док је у другом дат коначни подскуп карактеристика које треба изабрати [20].

6.3.2.11 Смањење карактеристика

Ради потпуности, комбиновањем подскупова улазних карактеристика добија се још један приступ смањењу димензија простора карактеристика. Комбинација може бити линеарна или не. Анализа главних компонената, линеарна дискриминаторска анализа и независна анализа компонената, анализа фактора и пројекциона претрага главне су технике које се користе за смањење карактеристика [20].

6.3.3 Моделирање класификатора

У овом примеру примењује се корак „моделирања“ користећи приступ машинском учењу. Користе се надгледана вештачка неуронска мрежа као класификатор и шема класификације један наспрам остатка [20].

Надгледана вештачка неуронска мрежа је рачунарска мрежа инспирисана биолошким неуронским системима, која се састоји од чворова (неурона) и веза за повезивање чворова. Да би се надгледана вештачка неуронска мрежа користила за вишекласни проблем, потребна је шема обуке један наспрам осталих. Ова стратегија се састоји у уклапању једног класификатора по класи. За сваку класу одговара један класификатор. Будући да је свака класа представљена једним одређеним класификатором, могуће је стећи знање о класи прегледом њеног одговарајућег класификатора.

Користи се алгоритам повратног ширења унапред као алгоритам учења, а излаз је колекција матрица пондера, по једна за сваку класу. Функција логистичких губитака користи се за оптимизацију. Оптимизује се рачунско време укључивањем параметра топлог старта.

Да би се пронашла најбоља топологија, у смислу одређеног броја неурона у скривеном слоју, гради се и обучава неколико надгледаних вештачких неуронских мрежа, како за пројектовани простор карактеристика, тако и за простор дескриптора светлосног поља. С обзиром на репрезентацију скупа података коју чине функције одабране од стране међусобних инфорација или међусобних информација + анализа главних компонената, граде се n - надгледаних вештачких неуронских мрежа где је $n = 3 * 2 * \#$ карактеристика. Свака надгледана вештачка неуронска мрежа карактерише број неурона унутар интервала $[3 * 2 * \# \text{ карактеристика}]$. У статистичке сврхе, за сваки дати број неурона граде се 3 исте надгледане вештачке неуронске мреже. За сваку конфигурацију надгледана вештачка неуронска мрежа се обучава и тестирају се њене могућности класификације усвајањем приступа k унакрсне валидације, са $k = 10$. За сваку серију мери се тачност класификације за сваку категорију, просечна тачност и стандардна девијација. Као конфигурација победника бира се она која максимизира просечну површину испод криве. Ради јасноће, изводи се следећи експеримент са подацима:

- 1) дељење скупа података у два подскупа: обука и тест. Сет за обуку садржи 70% предмета из улазног скупа података,
- 2) обучавање класификатора тако што се итеративно промени број неурона и број скривених слојева,
- 3) за сваку категорију израчунава се пријемна карактеристична крива и њена површина испод криве.


6.3.4 Анализа резултата

Концепт примене у предиктивном истраживању података односи се на примену модела за предвиђање нових података. Да би се потврдио класификатор описан у претходном одељку, примењен је на скупу података који садржи 606 непознатих 3D објеката. Табела 6.4 приказује детаље о саставу скупа података [20].


Табела 6.4. Скуп непознатих 3D објеката класификованих према надгледаним вештачким неуронским мрежама [20]

Категорија	Број елемената
Осе	27
Лежај	8
Ускочник	52
Налик цилиндру	40
Налик коцки	24
Зупчаник	32
Кључ	6
Везни елементи	4
Матица	62
Остало	112
Део лежаја	73
Завртњиви	115
Одстојник	31
Налик сфери	8
Налик торусу	12


Такође, систем класификатора је примењен и за класификацију делова који припадају стварним моделима машинских склопова. Сlike 6.15–6.18 показују неке примере.




Слика 6.15. Пример класификације стварног модела механичког склопа [20]



Слика 6.16. Исти модел на слици 11 са уклоњеним делом [20]




Слика 6.17. Детаљи модела механичког склопа на слици 12. Лежај (направљен од два дела лежаја и низа сферних делова) и Ц-копче [20]



Слика 6.18. *Прави модел механичког склопа. Десно два објекта која су правилно класификована у погледу облика, али нису правилно класификована са функционалне тачке гледишта [20]*

Примери погрешних класификација приказани су лево на слици 6.18. Прстен је класификован као део лежаја јер је његов пречник већи од дужине, што је једно од правила које се користи за креирање скупа категорија дела лежаја, док је други елемент класификован као завртањ. Разлог је тај што у категорији завртњеви скупа података постоје неки апстрактни завртњеви слични објекту обојеном у плавој боји (слика 6.19). У оба случаја, ревизија класификације облика је у стању да исправи погрешну класификацију узимајући у обзир контакте са осталим деловима у склопу.



Слика 6.19. *Леви завртањ. Исправљени објекат са слике 14 погрешно класификован као завртањ [20]*

6.3.5 Закључна разматрања

Класификација делова у стварним моделима машинских склопова истакла је да се, чак и ако су облици правилно класификовани, тачна функционална интерпретација може постићи само узимајући у обзир њихов контекст употребе. Из тог разлога, представљени класификатор представља први корак модула описаног у *Lupinetti* и сарадници, који класификује функционалну компоненту у моделима склопова расуђујући како на облику њених елемената, тако и на њихову организацију унутар модела [20].

Да би се проценила могућност побољшања стопе класификације, разматрају се разна могућа проширења представљеног рада. Прва се односи на укључивање у вектор карактеристика додатних информација о облику које су директно доступне у САД моделима, као што су, за било који одређени тип површине, број страна и проценат површине у односу на укупну површину објекта. Још једно потенцијално побољшање могло би се постићи коришћењем техника ограниченог машинског учења као механизма класификације. Ограничено машинско учење проширује класичне технике машинског учења додавањем декларативних ограничења, на пример, обавезних карактеристика или начина на који два машинска елемента могу бити у контакту. Ограничења се могу користити као начин за укључивање домена и знања инжењера који морају увек бити задовољени током задатка класификације.

7. Пример конструисања фелне за аутомобиле помоћу машинског учења

Машинско учење омогућава програму да аутоматски креира бројне CAD моделе. Да би се то постигло потребно је прикупити велику количину 3D CAD података у циљаном подручју производа.

Сврха овог примера је да предложи поступак аутоматизације конструисања заснован на машинском учењу.

Овај пример је приказан кроз процес конструисања алуминијумских фелни за аутомобиле (слика 7.1).



Слика 7.1. 3D модел луминијумске фелне

Помоћу машинског учења могуће је креирати програм који ће на основу задатих параметера које конструкција треба да поседује, аутоматски одредити:

- масу фелне,
- толеранције положаја отвора који служе за повезивање фелни и главчина,
- храпавост контактих површина,
- облик фелне,
- толеранцију облика фелне,
- потребне димензије и
- технологију израде.

Такође, претходно је потребно омогућити програму учење, кроз аутоматско генерисање великог броја 3D CAD модела фелни који имају високе перформансе, на основу чега ће програм предвидети потребне перформансе засноване на 2D дизајну фелни без поступка 3D моделирања.

Тренутни процес конструисања није у потпуности ефикасан јер индустријски дизајнер креира само мали део дизајна, док конструктор креира CAD модел и пружа повратне информације индустријском дизајнеру, па је тиме потребно понављати поступак модификације дизајна. Међутим, у предложеном примеру, машинско учење прво генерише велику количину CAD модела, на основу којих индустријски дизајнери и конструктори могу аутоматски конструисати фелну која ће задовољавати претходно задате параметре.

7.1 Маса фелне

Један од циљева приликом дизајнирања производа је осигуравање што нижих трошкова. У том случају потребно је креирати програм који би редукцијом масе производа омогућио смањење трошкова израде дела, истовремено осигуравајући жељени облик, функцију и перформансе.

Сам програм који би се бавио анализирањем и унапређењем масе фелне мора да прати неколико битних параметара. Пре свега ту је оптерећење које фелна трпи приликом коришћења. Анализом масе на основу оптерећења и услова рада и средине у којој се ради, програм може да одреди да ли се приликом израде фелне у процесу ливења могу увести и олакшања која смањују масу.

7.2 Толеранције положаја отвора и храпавост

Овај програм би могао да анализом толеранција и положаја отвора на главчини и рукавцу возила, као и храпавости контактних површина, одреди и прилагоди толеранције и храпавост на фелни и тако обезбедити идеално налегање између површина. Места на којима је потребно поставити одговарајуће толеранције и храпавост означена су црвеном бојом на слици 7.2.



Слика 7.2. Толеранције положаја отвора и храпавост контактних површина

7.3 Облик фелне

Програм би користио смернице за дизајн како би помогао инжењерима да створе најбољи облик за задати задатак.

Проблем је потребно формулисати инжењерским терминима, након чега се на основу постављених ограничења и оптерећења аутоматски ствара геометрија фелне (слика 7.3). Такође, потребно је изразити и неколико параметара, као што су обим главчине, број завртњева, величина пнеуматика, и материјал, а систем ће имати препоручени облик.

Такође, овај програм би могао да се користи и за редизајн постојећих делова или пружање повратних информација о томе где ће можда бити потребно додати или одузети материјал.



Слика 7.3. Аутоматско креирање облика фелне

7.4 Толеранција облика фелне

Кружност фелне мора бити велика, јер је потребно остварити дихтовање између пнеуматика и фелне.

На основу оптерећења, услова рада и средине могуће је креирати идеалну толеранцију кружности и на тај начин смањити могућност пуцања пнеуматика.

7.5 Димензије конструкције

Програм ће на основу свих ових предходно наведених параметара моћи да анализира све толеранције, технологију израде и масу дела и да на тај начин прикаже идеалану геометрију фелне са идеалним димензијама.

7.6 Технологија израде

На основу конструкције дела програм може да научи како да оптимизује облик алата, уливне канале (како би били што боље распоређени), брзину хлађења дела, обраду рупа и унутрашњих ивица, као и дела на који се поставља гума, итд.

Програм на основу задатих толеранција може предвидети да ли је потребно додатно машинирање контактних површина ради остваривања толеранција и храпавости и у колико је потребно да одреди на основу параметара машине, на којој се машинира фелна, CNC начин стезања фелне и креира програм за машинирање.

8. Закључак

На основу разумевања тржишта, уочено је да је једна од главних потреба при конструисању обрада података 3D скенера из стварне геометрије и генерисање 3D модела из њега.

Предлагање релевантних 3D објеката, преузетих из спољних извора података, могао би бити још један начин за побољшање процеса конструисања. Примена машинског учења у конструисању може омогућити помоћ конструкторима кроз „сугестивно моделирање“. Док конструктори цртају у 3D простору, низ класификатора заснованих на машинском учењу могао би да тражи релевантне сугестије и предложи алтернативне, сличне или комплементарне опције дизајна.

Овај приступ показује потенцијал сугестивног конструисања и доносећи релевантне алтернативе конструкторима током креативних активности конструисања, има прилику да прошири опсег њиховог рада.

У машинској индустрији, широка употреба алата за рачунарски потпомогнути дизајн произвела је велике скупове података о моделима производа. У том контексту, могућност једноставног проналажења, а затим поновне употребе или модификације постојећих CAD модела била би од највеће важности за убрзавање развоја нових производа.

Препознавање узорака, односно класификација кроз надгледане технике машинског учења за идентификацију облика и производње у CAD базама података побољшава управљање инжењерским подацима. Техника олакшава проналажење и архивирање предмета за инжењере, подстиче поновну употребу делова и дизајна ради побољшања управљања животним циклусом производа и убрзава конструисање и производне процесе производа.

У будућности, помоћу адекватног програма који се бави машинским учењем, на основу захтева корисника, као што су маса, радни век, максимално оптерећење, услови рада и сл., могла би се аутоматски креирати конструкција која испуњава све постављене захтеве.

У основи, програм би могао користити информације које је конструктор унео како би сам креирао модел.

Такође, програм би на основу жеље корисника (на пример, употреба најадекватнијих материјала) и на основу прикупљених информација о томе како корисник конципира конструкцију кроз дужи временски период могао научити шта корисник воли (на пример, да ли у питању уштеда материјала или функционалност конструкције) и сам креирати дизајн.

Односно, програм би могао да препозна инжењерске проблеме који су се раније користили и утврди да ли их има у систему и на тај начин понуди модел заснован на објектима које је корисник конструисао у прошлости.

На пример, уколико корисник жели да направи носач за одређену количину тежине, а већ их је дизајнирао 10 који могу да издрже различите тежине, програм ће знати како би уколико је потребно да носач издржи задату количину тежине, он требао би бити дизајниран.

Тако би на пример, у авио индустрији, програм који се бави машинским учењем учио на основу искуства да ради у изради делова конкретно у авио индустрији и сам доноси закључак, на пример, какви треба да буду материјали (ултра лаки). Такође, програм би могао да анализира окружење у којем конструкција ради и сам донесе закључак о оптерећењима да би могао самостално да креира конструкцију.

У ствари, аутоматизација је будућност конструисања и она ће довести до најбољих могућих дизајна и производа.

Литература

- [1] Z. Nagy, *Основе вештачке интелигенције и машинског учења*, Компјутер библиотека, Београд, 2019.
- [2] B.J. Copeland, *Artificial intelligence*, University of Canterbury, Christchurch, New Zealand, 2020.
- [3] С. Бранковић, *Вештачка интелигенција и друштво*, Филозофски факултет, Ниш, 2017.
- [4] <https://www.investopedia.com/terms/a/artificial-intelligence-ai.asp>, приступљено: 28.06.2020.
- [5] <https://builtin.com/artificial-intelligence>, приступљено: 28.06.2020.
- [6] <https://www.javatpoint.com/history-of-artificial-intelligence>, приступљено: 28.06.2020.
- [7] <https://www.ibm.com/cloud/learn/machine-learning>, приступљено: 05.07.2020.
- [8] <https://www.mathworks.com/discovery/machine-learning.html>, приступљено: 05.07.2020.
- [9] http://ri4es.etf.rs/materijali/predavanja/IS_P11_MasinskoUcenje.pdf, приступљено: 05.07.2020.
- [10] <https://www.zdnet.com/article/what-is-machine-learning-everything-you-need-to-know/>, приступљено: 05.07.2020.
- [11] <https://www.project-benefit.eu/>, приступљено: 05.07.2020.
- [12] <https://www.investopedia.com/terms/d/deep-learning.asp>, приступљено: 05.08.2020.
- [13] <https://www.mathworks.com/discovery/deep-learning.html>, приступљено: 05.08.2020.
- [14] <https://news.mit.edu/2017/explained-neural-networks-deep-learning-0414>, приступљено: 05.08.2020.
- [15] <https://www.investopedia.com/terms/n/neuralnetwork.asp>, приступљено: 05.08.2020.
- [16] https://www.mathworks.com/discovery/neural-network.html?s_tid=srchtitle, приступљено: 05.08.2020.
- [17] <https://www.autodesk.com/autodesk-university/article/Autonomous-Geometry-Processing-Using-Machine-Learning-and-Forge-2020>, приступљено: 15.09.2020.
- [18] <https://towardsdatascience.com/suggestive-computer-aided-design-a9c7698c1cc9>, приступљено: 15.09.2020.
- [19] <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.83.7650&rep=rep1&type=pdf>, приступљено: 20.09.2020.

[20] <https://www.cambridge.org/core/journals/ai-edam/article/methodology-for-part-classification-with-supervised-machine-learning/69D95B66344317AE778C1058993BC2B9/core-reader>, приступљено: 20.09.2020.