

Turinys

Dirbtinio intelekto (DI) raidos istorija	2
DI taikymo pavyzdžiai šiandien	3
Dirbtinio intelekto ir mašininio mokymosi samprata: įvairūs mašininio mokymosi įrankiai	5
Dirbtinis neuroninis tinklas (DNT)	7
Dirbtinių neuroninių tinklų tipai	11
DNT taikymo sritys (apibendrinimas):	12
Sprendimų medis	12
Dirbtinio intelekto taikymas siekiant analizuoti, klasifikuoti, atpažinti ir prognozuoti duomenis	14
Pažangios naujovės	25
Sentimentų analizė	26
Dirbtinio intelekto (DI) naudojimo etika, teisiniai ir socialiniai principai	27
Naudojimo privalumai ir grėsmės	30
Sudėtingesni dirbtinio intelekto taikymo pavyzdžiai	32
Autentifikavimo ir identifikavimo sistemos	34
Suasmenintas turinys	35
Tiuringo testas	39
Asociacijų analizė	40
Klasterizacija, klasifikavimas, grupavimas	41

Dirbtinio intelekto (DI) raidos istorija

Dirbtinio intelekto (DI) raidos istorija apima kelis dešimtmečius, ir ši technologija nuolat tobulėja bei plečiasi įvairiose srityse. Nuo pirmųjų bandymų sukurti maštančias mašinas iki šiuolaikinių pažangių modelių, DI pasiekė didžiulę pažangą.

1. Ankstyvieji bandymai ir teorijos (1950-1960 m.)

Dirbtinio intelekto idėja atsirado kaip bandymas sukurti mašinas, kurios galėtų atlikti užduotis, reikalaujančias žmogaus intelekto. Šie pirmieji bandymai buvo daugiau teoriniai nei praktiniai.

- **1950 m. – Alan Turing ir Turingo testas:** Alan Turingas pasiūlė **Turingo testą**, kurio tikslas buvo nustatyti, ar mašina gali parodyti žmogaus intelekto elgseną. Tai tapo pagrindu būsimam dirbtinio intelekto vystymuisi.
- **1956 m. – Džonas Makartis ir DI gimimas:** Džonas Makartis, amerikiečių kompiuterių mokslininkas, 1956 m. organizavo **Dartmuto konferenciją**, kur buvo pirmą kartą oficialiai įvardintas „dirbtinis intelektas“ kaip mokslo šaka.
- **1956-1960 m. – Pirmieji bandymai sukurti mašinas, galinčias atlikti loginį mąstymą:** Pirmieji DI projektai buvo skirti logikai ir matematikai, pavyzdžiui, sukurtas pirmasis **Logic Theorist** programinis įrankis, kuris galėjo įrodyti teoremas.

2. Pirmoji DI žiema (1970-1980 m.)

Šiuo laikotarpiu, nepaisant pirmųjų pasiekimų, dirbtinio intelekto plėtra buvo sulėtinta dėl per didelių lūkesčių ir technologinių trūkumų. Šis laikotarpis žinomas kaip **DI žiema**, kai finansavimas ir susidomėjimas sumažėjo.

- **Per dideli lūkesčiai ir riboti rezultatai:** Daugelis projektų, ypač kurie buvo susiję su kalbos atpažinimu ir natūralios kalbos apdorojimu, nesugebėjo pasiekti realių rezultatų, o tai sukėlė nusivylimą ir sumažino investicijas.

3. Mašininio mokymosi atsiradimas (1980-1990 m.)

1980-aisiais metais įvyko svarbus perversmas DI srityje – pradėjo vystytis **mašininis mokymasis**, kuriame dėmesys buvo skiriamas algoritmams, kurie galėtų „mokytis“ iš duomenų.

- **Dirbtiniai neuroniniai tinklai (DNT):**
Nepaisant pirmo bandymo sukurti neuroninius tinklus 1940-aisiais, didesnę susidomėjimą jie pradėjo kelti 1980-aisiais, kai buvo įvykdyti pirmieji tikslūs praktiniai neuroninių tinklų taikymai.
- **Mašininio mokymosi metodai:**
Atsirado metodai kaip **sprendimų medžiai**, **k-naudojimo kaimynai (KNN)** ir **SVM (Support Vector Machines)**, kurie tapo populiarūs duomenų klasifikavimui ir analizei.

4. Antroji DI žiema (1990-2000 m.)

Tai buvo laikotarpis, kai vėl sumažėjo susidomėjimas ir finansavimas dirbtiniu intelektu dėl sunkumų sukurti veikiančias programas ir daugelio teorinių trūkumų.

- **Kritiškos problemos ir riboti pasiekimai:**
Nors atsirado naujų teorijų ir metodų, DI vis dar kovojo su praktinėmis problemomis, tokiais kaip žinių apdorojimas ir kalbos atpažinimas.

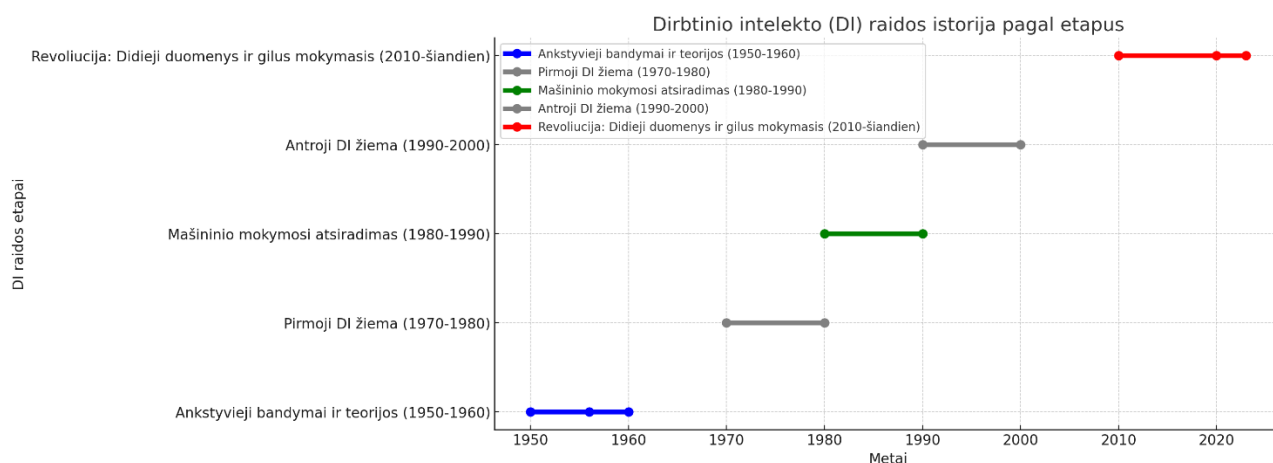

5. Revoliucija: Didieji duomenys ir gilus mokymasis (2010-iki šiol)

2010-aisiais metais prasidėjo tikrasis revoliucinis DI vystymasis, kur technologijų pažanga ir didžiuliai duomenų kiekiai leido pasiekti reikšmingų laimėjimų.

- **Giluminis mokymasis (Deep Learning):**
Pagrindinė pažanga buvo **gilus mokymasis**, kai naudojami dideli neuroniniai tinklai, ypač **konvoliuciniai neuroniniai tinklai (CNN)** ir **recurrent neuroniniai tinklai (RNN)**, kad būtų galima apdoroti didelius duomenų kiekius ir atlikti sudėtingas užduotis, tokias kaip vaizdų ir kalbos atpažinimas.
- **Sukūrimas pažangių modelių kaip BERT, GPT:**
BERT ir **GPT** modeliai pakeitė natūralios kalbos apdorojimą (NLP). Šie modeliai naudoja

transformatorių architektūrą, kuri leidžia atlikti sudėtingas užduotis su žymiai geresniais rezultatais nei ankstesni metodai.


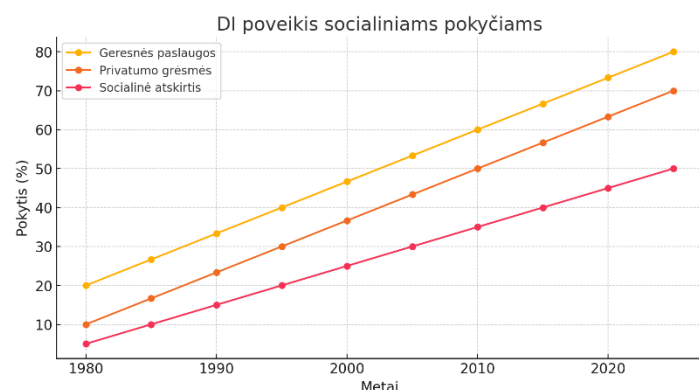


- **Dideli duomenys ir didelės skaičiavimo galios:**
Galingos kompiuterinės sistemos ir platus interneto duomenų pasiekiamumas leido kurti ir treniruoti galingus modelius, pvz., **OpenAI GPT**, kuris generuoja tekstą ir atlieka sudėtingus uždavinius.



DI taikymo pavyzdžiai šiandien

Sritis	Taikymo pavyzdžiai	Papildoma informacija
Sveikatos priežiūra	Medicininis vaizdo apdorojimas: ligų atpažinimas (pvz., vėžys)	DI modeliai gali analizuoti rentgeno ir MRT vaizdus ir padėti gydytojams nustatyti diagnozes.
	Diagnostika ir prognozavimas: ankstyva ligų diagnostika, genomo analizės	Didina gydymo efektyvumą ir individualizaciją, prisideda prie sklandesnio gydymo proceso.
Finansai	Prekybos algoritmai: automatinis sprendimų priėmimas remiantis rinkos duomenimis	Greiti sprendimai gali pagerinti prekybos rezultatus ir sumažinti riziką.

	Kredito rizikos vertinimas: mašininio mokymosi modeliai	Tikslesnis vartotojų kredito vertinimas leidžia sumažinti bankų nuostolius dėl nesumokėtų paskolų.
Automobiliai	Savarankiški automobiliai: objekto atpažinimas ir sprendimų priėmimas	Naudojamas gilusis mokymasis ir kompiuterinis regėjimas siekiant pagerinti eismo saugumą.
Pardavimai ir rinkodara	Personalizacija: prekių, filmų ir muzikos rekomendacijos	Naudojamas mašininis mokymasis, kad pagerintų vartotojų patirtį ir didintų pardavimus.
	Chatbot'ai ir virtualūs asistentai: sudėtingos užduotys naudojant NLP	Pagerina klientų aptarnavimą ir sumažina darbuotojų krūvį, leidžiant automatizuoti dažniausiai užduodamus klausimus.
Socialiniai tinklai	Turinys moderavimas: nepageidaujamo turinio identifikavimas	DI padeda sumažinti melagingų naujienų ir neapykantos kalbos paplitimą, užtikrinant saugesnę platformą.
Kalbos atpažinimas ir vertimas	Google Translate: tekstų vertimas tarp kalbų	DI pasiekė didelę tikslumą, palengvinant tarptautinį bendravimą ir mokymąsi.
Žaidimai ir pramogos	Kompiuteriniai žaidimai: protingi NPC ir sudėtingos strategijos	DI gali pagerinti žaidimų dinamiką ir sudėtingumą, suteikdamas žaidėjams unikalią patirtį.



Etinės dilemos ir kiti aspektai:

- Etika: užtikrinti, kad DI sprendimai būtų sąžiningi ir nešališki.
- Privatumo grėsmės: asmens duomenų analizė gali kelti pavojų privatumo saugumui.
- Socialinė atskirtis: nelygybė gali didėti dėl nevienodos prieigos prie DI technologijų.

Dirbtinis intelektas perėjo ilgą kelią nuo pirmųjų bandymų sukurti „mąstančias“ mašinas iki šiuolaikinių giluminių modelių, kurie išsprendžia sudėtingas problemas daugelyje sričių. DI technologijos tampa vis svarbesnės tiek kasdieniame gyvenime, tiek pramonėje, ir jų potencialas nuolat auga.

Dirbtinio intelekto ir mašininio mokymosi samprata: įvairūs mašininio mokymosi įrankiai

Dirbtinio intelekto (DI) samprata apima technologijas, sistemas ir algoritmus, kurie geba atlikti užduotis, paprastai reikalaujančias žmogaus intelekto. Tai tokios užduotys kaip mokymasis, sprendimų priėmimas, problemų sprendimas, kalbos atpažinimas, vaizdų analizė ar kūrybinė veikla.

Pagrindiniai dirbtinio intelekto bruožai:

- **Mokymasis** – gebėjimas analizuoti duomenis, pastebėti dėsningumus ir remiantis jais tobulinti savo veikimą.
- **Savarankiškumas** – sprendimų priėmimas be tiesioginio žmogaus įsikišimo.
- **Prisitaikymas** – gebėjimas keisti elgseną atsižvelgiant į naują informaciją ar aplinkybes.
- **Kūrybiškumas** – naujų idėjų generavimas, problemų sprendimo būdų ieškojimas.

DI skirstomas į:

- **Siaurąjį DI (ANI)** – specializuotas tam tikrai užduočiai (pvz., kalbos vertimas, veidų atpažinimas).
- **Bendrojo DI (AGI)** – teorinis intelektas, gebantis atlikti bet kokią užduotį, reikalaujančią žmogaus intelekto.
- **Superintelektas (ASI)** – hipotetinis DI, pranokstantis žmogaus intelektą visose srityse.

DI technologijos jau naudojamos įvairiose srityse: medicinoje, finansuose, transporto sektoriuje, švietime, kūryboje ir kasdieniame gyvenime.

Mašininio mokymosi metodai:

- **Neuroniniai tinklai ir gilusis mokymasis** – įkvėpti žmogaus smegenų veiklos, naudojami sudėtingoms užduotims, kaip vaizdų ar kalbos atpažinimas.
- **Sprendimų medžiai ir atsitiktiniai miškai** – populiarūs klasifikacijos ir prognozavimo įrankiai.
- **Regresijos modeliai** – naudojami prognozuojant skaitines reikšmes, kaip būsto kainas ar pardavimų apimtį.
- **K-grupių klasterizacija** – viena iš neprižiūrimo mokymosi technikų, skirstanti duomenis į grupes pagal panašumus.
- **Stiprinamasis mokymasis** – naudojamas kuriant sistemas, kurios mokosi iš patirties per bandymų ir klaidų metodą.

Mašininio mokymosi įrankių yra daugybė – nuo bibliotekų ir platformų iki specializuotų įrankių, skirtų modelių kūrimui, treniravimui ir vertinimui. Štai keletas populiariausių ir plačiai naudojamų:

Programavimo kalbos ir jų bibliotekos:

- **Python** – populiariausia kalba mašininiam mokymuisi dėl plačios bibliotekų ekosistemos ir paprastumo.
 - ✓ **TensorFlow** – Google sukurta gilaus mokymosi biblioteka, tinkanti tiek paprastiems, tiek sudėtingiems modeliams.
 - ✓ **PyTorch** – labai lanksti ir intuityvi biblioteka, ypač populiari moksliniuose tyrimuose.
 - ✓ **Scikit-learn** – klasikinio mašininio mokymosi biblioteka su daugybe algoritmų, tinkama regresijai, klasifikacijai, klasterizacijai ir kt.
 - ✓ **XGBoost, LightGBM, CatBoost** – efektyvios ir greitos bibliotekos gradientiniam stiprinimui (boosting).

- **R** – statistikos ir duomenų analizės kalba, taip pat turinti stiprias mašininio mokymosi bibliotekas (pvz., **caret**, **randomForest**).

Platformos ir debesų paslaugos:

- **Google Colab** – nemokama platforma darbui su Python, leidžianti treniruoti modelius naudojant Google GPU/TPU.
- **Amazon SageMaker** – AWS paslauga, leidžianti lengvai kurti, treniruoti ir diegti DI modelius.
- **Microsoft Azure Machine Learning** – įrankis, skirtas mašininio mokymosi projektams kurti ir valdyti debesyje.
- **Vertex AI** – Google Cloud platforma, skirta visam DI projektų gyvavimo ciklui.

Automatizuoto mašininio mokymosi (AutoML) įrankiai:

- **Google AutoML** – automatiškai kuria ir optimizuoja modelius pagal įkeltus duomenis.
- **H2O.ai** – galinga atviro kodo platforma AutoML modeliams.
- **TPOT** – Python biblioteka, automatizuojanti modelių parinkimą ir hiperparametrų optimizavimą.

Duomenų vizualizavimo ir analizės įrankiai:

- **Pandas** ir **NumPy** – Python bibliotekos duomenų manipuliacijai ir analizavimui.
- **Matplotlib**, **Seaborn** ir **Plotly** – duomenų vizualizavimo įrankiai, leidžiantys kurti grafikus ir diagramas.

Žemo kodo ir be kodo (Low-code/No-code) įrankiai:

- **Teachable Machine** – Google įrankis, leidžiantis treniruoti paprastus modelius be kodavimo.
- **DataRobot** – platforma, siūlanti automatizuotą modelių kūrimą ir analizę.
- **Azure ML Designer** – „drag-and-drop“ tipo aplinka, kurioje galima kurti modelius vizualiai.

Teachable Machine – tai „Google“ sukurtas paprastas ir intuityvus įrankis, leidžiantis greitai kurti ir treniruoti mašininio mokymosi modelius be programavimo žinių. Jis idealiai tinka pradedantiesiems, edukaciniams tikslams ir greitam prototipų kūrimui.

Pagrindinės Teachable Machine savybės:

- **Paprastas naudojimas:** Modelį galima sukurti vos keliais paspaudimais.
- **Trys mokymo tipai:**
 - ✓ **Vaizdų atpažinimas** (pvz., veidų, objektų, gestų atpažinimas).
 - ✓ **Garsų atpažinimas** (pvz., plojimų, balsų ar aplinkos garsų skyrimas).
 - ✓ **Pozų atpažinimas** (pvz., kūno judesių ar gestų analizė).
- **Realus laikas:** Modelius galima treniruoti ir iškart išbandyti naudojant kompiuterio kamerą ar mikrofoną.
- **Eksportavimas:** Sukurtus modelius galima eksportuoti į „TensorFlow.js“, „TensorFlow Lite“ arba „Coral“, kad juos būtų galima naudoti internetinėse svetainėse ar mobiliosiose aplikacijose.

Kaip veikia Teachable Machine:

1. **Pasirink modelio tipą:** Vaizdų, garsų ar pozų atpažinimas.
2. **Surink duomenis:** Įkelk vaizdus, įrašyk garsus arba tiesiogiai naudok kamerą/mikrofoną.
3. **Pažymėk kategorijas:** Sukurk klases (pvz., „Šypsena“ ir „Rimtas veidas“) ir priskirk duomenis.
4. **Treniruok modelį:** Vienu mygtuko paspaudimu Teachable Machine išmokys modelį atpažinti duomenų kategorijas.
5. **Testuok ir eksportuok:** Išbandyk modelio tikslumą realiu laiku ir eksportuok jį tolimesniam naudojimui.

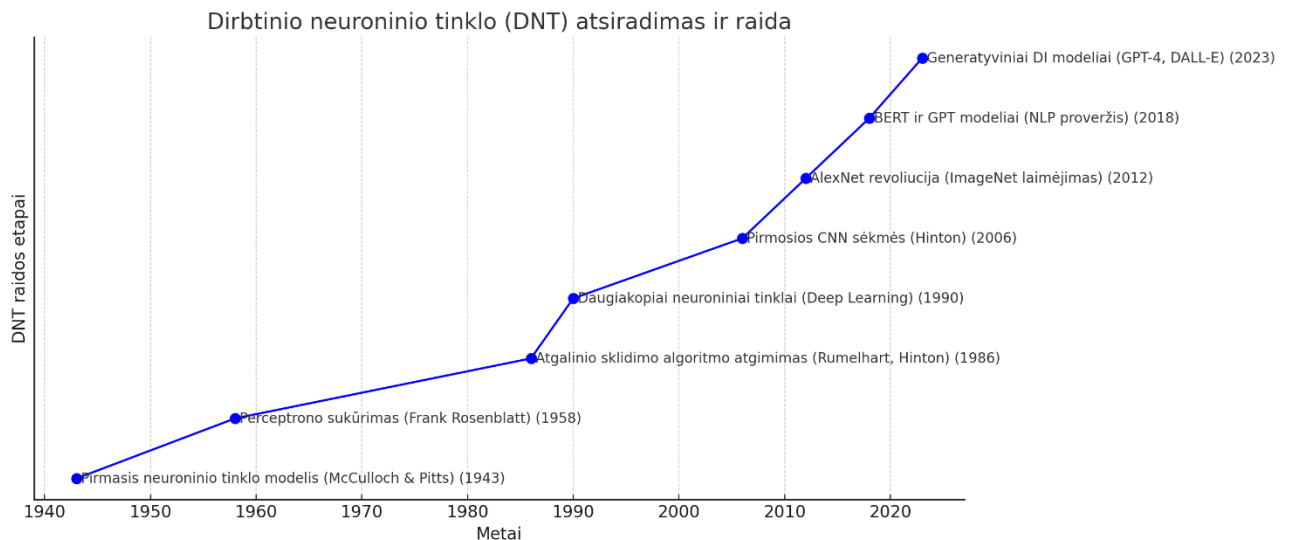
Praktinis pritaikymas:

- Kūrybiniai projektai (pvz., interaktyvūs menai).
- Edukacija (mokymasis apie DI ir duomenų klasifikavimą).

- Greiti prototipai (pvz., paprastos programėlės su DI).\

Dirbtinis neuroninis tinklas (DNT)

Dirbtinis neuroninis tinklas (DNT) – tai viena pagrindinių dirbtinio intelekto (DI) ir mašininio mokymo technologijų, įkvėpta žmogaus smegenų veikimo principų. Jis sudarytas iš dirbtinių neuronų, kurie kartu sprendžia sudėtingas užduotis, tokias kaip vaizdų atpažinimas, natūralios kalbos apdorojimas ar prognozavimas.



DNT struktūra:



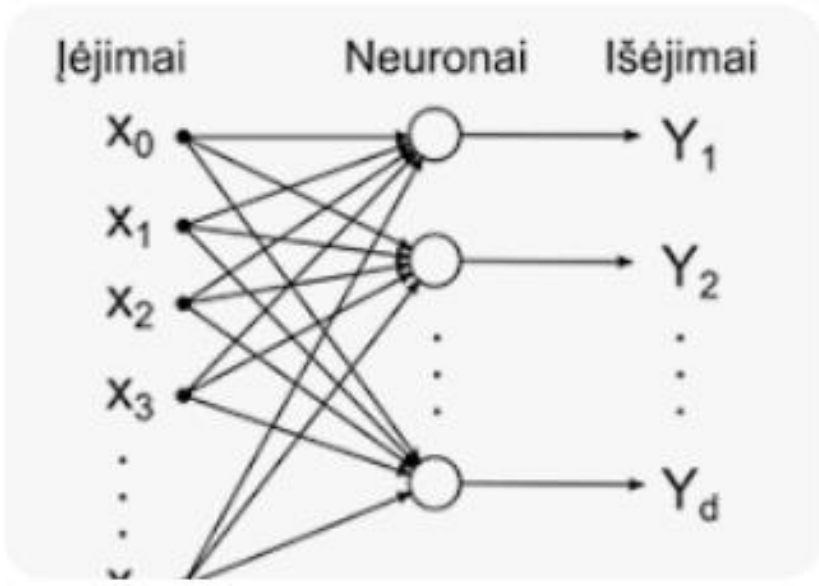
- **Įvesties sluoksnis (angl. Input layer):** Priima pradinį duomenį (pvz., skaitmeninė reikšmė, tekstas, paveikslėlis).
- **Paslėptieji sluoksniai (angl. Hidden layers):** Atliekami skaičiavimai ir duomenų transformacijos. Kuo daugiau sluoksnių, tuo tinklas tampa „gilesnis“ (gilus mokymas).
- **Išvesties sluoksnis (angl. Output layer):** Pateikia galutinį rezultatą (pvz., klasifikacija, skaitinė prognozė).

Kaip veikia DNT:

1. **Svertai ir poslinkiai:** Kiekvienas ryšys tarp neuronų turi svorį (weight), kuris rodo to signalo reikšmę. Poslinkis (bias) leidžia modelį labiau pritaikyti prie duomenų.
2. **Aktyvavimo funkcija:** Nustato, ar neuronas turi „suaktyvėti“ ir perduoti signalą toliau (pvz., ReLU, Sigmoid, Tanh).
3. **Išplitimas į priekį (angl. Forward propagation):** Įvesties duomenys keliauja per sluoksnius, atliekami skaičiavimai ir gaunamas rezultatas.
4. **Paklaidos skaičiavimas:** Lyginamas tinklo rezultatas su realiais duomenimis ir apskaičiuojama klaida (pvz., „Cross-Entropy“ arba MSE).
5. **Grįžtamasis sklaidimas (angl. Backpropagation):** Atnaujinami svoriai ir poslinkiai, kad sumažintų klaidą.
6. **Optimizavimas:** Naudojami algoritmai, kaip „Stochastic Gradient Descent“ arba „Adam“, kad modelis greičiau mokytųsi.

Kiekvienas dirbtinis neuronas gauna įvestį iš kitų neuronų ir ją sumuoja pagal svorius. Tada ši suma perduodama aktyvavimo funkcijai (pvz., sigmoido ar ReLU), kuri nustato neuronų aktyvumo lygį. Jei aktyvumas viršija tam tikrą slenkstį, neuronas siunčia signalą toliau per tinklą.

Toliau pateikiame keletą neuroninių tinklų grafinio vaizdavimo būdų:



Neuroninis tinklas sudaromas iš daugelio tarpusavyje sujungtų labai paprastų skaičiavimo elementų (dirbtinių neuronų). Šie elementai, sujungti įvairaus stiprumo jungtimis, yra apytikslis biologinių neuronų modelis. Dirbtiniu neuroniniu tinklu siekiama emuliuoti kai kurias biologinių sistemų savybes, pvz., biologinių sistemų gebėjimą mokytis, prisitaikyti ir adaptuotis. Mokymosi metu gyvųjų organizmų smegenyse keičiasi jungčių, siejančių neuronus, stiprumas. Toks jungčių stiprumo (vadinamojo neuronų svorių) kitimas būdingas ir dirbtiniams neuroniniams tinklams, kurių svarbiausias elementas yra dirbtiniai neuronai. Dirbtinio neuroninio tinklo neuronus apibūdina jų įėjimo (arba įvesties) signalas ($x_0, x_1, x_2, \dots, x_d$), neuronų svoriai ($w_0, w_1, w_2, \dots, w_d$), perdavimo funkcija (tiesinė, hiperbolinio tangento, logistinio sigmoido ar kitokia) ir neuronų išėjimo (arba išvesties) signalas (y). Bet kurios paskirties neuroninio tinklo kintamųjų vertės iš išorės gauna per įėjimus, o atsakas perduodamas per išėjimus. Dažnai būna ir tarpinių (paslėptųjų) neuronų, skaičiuojančių vidinių tinklo funkcijų vertes. Įėjimo, paslėptieji ir išėjimo neuronai jungiami vieni su kitais. Neuroninis tinklas būna tiesioginio sklidimo, jei signalai sklinda iš kiekvieno neurono įėjimo per visus paslėptuosius elementus ir pasiekia išėjimo neuronus. Šio tinklo neuronų signalai sudaro įėjimo vektorių x , o neuronų išėjimo signalai – vektorių y . Tokia struktūra yra stabili. Jei neuroninis tinklas yra rekurentinis su atgalinėmis jungtimis iš vėlesniųjų neuronų į ankstesnius, jis gali būti nestabilus ir dažniausiai turi sudėtingą dinamiką. Dirbtiniame neuroniniame tinkle neuronus įprasta grupuoti į atskirus sluoksnius. Neuronų įėjimo signalai sudaro įėjimo sluoksnį, kuris nėra skaičiavimo neuronų sluoksnis, o įveda įėjimo kintamųjų vertes į neuroninį tinklą, nes prieš duomenų apdorojimą neuroniniu tinklu dažnai atliekamas pirminis jų apdorojimas, pvz., normavimas, centravimas. Po to paeiliui apskaičiuojamos paslėptųjų sluoksnių neuronų išėjimo vertės, galiausiai – išėjimo sluoksnio neuronų išėjimo vertės, kurios laikomos neuroninio tinklo išėjimo vertėmis. Vieno sluoksnio neuronai turi tą pačią perdavimo funkciją. Konkrečiam uždaviniui spręsti reikalingas paslėptųjų neuronų skaičius randamas eksperimentiniu būdu. Praktikoje dažniausiai naudojamas vienas paslėptųjų neuronų sluoksnis. Paslėptųjų ir išėjimo sluoksnių neuronai dažniausiai sujungti su ankstesnio sluoksnio neuronais (kartais neuronai jungiami ne su visais gretimų sluoksnių neuronais). Dirbtinio neuroninio tinklo mokymas būna dvejopas: su mokytoju (prižiūrimas mokymas) ir be mokytojo (neprižiūrimas mokymas, arba savimoka). Mokant su mokytoju žinomos ne tik įėjimo, bet ir atitinkamos išėjimo vertės, dar vadinamos užduoties vertėmis, kurias pateikia mokytojas. Mokymo metu minimizuojama tam tikra klaidos funkcija. Labai dažnai tai būna neuroninio tinklo išėjimo y_j ir užduoties d_j tarpusavio skirtumo funkcija.

Mokymo metu neuronų svoriai keičiami taip, kad $E(w)$ vertė mažėtų – neuroninio tinklo išėjimo vertės artėtų prie norimų verčių. Mokoma naudojant pasirinktą duomenų rinkinį, vadinamą duomenų imtimi. Savimokos atveju pats neuroninis tinklas nustato savo būseną. Apmokyto neuroninio tinklo neuronų svoriai paprastai būna fiksuoti. Informacija, reikalinga konkrečiam uždaviniui spręsti, kaupiama neuronų svorių vertėse. Dirbtiniai neuroniniai tinklai yra viena naujausių informacijos apdorojimo priemonių, taikomų įvairiose žmogaus veiklos srityse. Naudojami įvairiems signalams atpažinti, duomenims klasifikuoti, analizuoti, įvairiems reiškiniams prognozuoti, kontroliuoti, techninėms sistemoms modeliuoti, optimizuoti ir kitur. Jie yra daugelio techninių įrenginių (modemų, vaizdų bei kalbos apdorojimo ir atpažinimo sistemų, signalinių procesorių, biomedicininės įrangos ir kitų) elementas.

Dirbtinio neuroninio tinklo matematinį modelį 1943 sukūrė Warrenas Sturgisas McCullochas ir Walteris Harry'is Pittsas (abu Jungtinės Amerikos Valstijos). 1949 sukurtas neuroninio tinklo mokymo metodas. 1958 išrastas perceptronas (dirbtinė apmokoma neuroninė sistema, modeliuojanti atpažinimo procesą). Dirbtinius neuroninius tinklus imta naudoti praktinėms reikmėms.

Privalumai:

- Didelis universalumas – tinka įvairioms užduotims.
- Geba išmokti sudėtingus, nežymius ryšius tarp duomenų.
- Naudojamas tiek klasifikacijai, tiek regresijai, tiek generatyviniams modeliams.

Trūkumai:

- Reikalingi dideli duomenų kiekiai mokymui.
- Dideli skaičiavimo resursai (ypač Gilesniems tinklams).
- Rizika permokyti (overfitting) arba nepakankamai išmokti (underfitting).

Dirbtinio neuroninio tinklo (DNT) apmokymas

Dirbtinio neuroninio tinklo (DNT) apmokymas yra procesas, kurio metu tinklas išmoksta atpažinti duomenų raštus ir numatyti teisingus rezultatus. Pagrindinė DNT apmokymo idėja – rasti optimalius kiekvieno neurono ryšius (svorius), kad būtų sumažintas prognozės klaidos laipsnis. Šis procesas apima du pagrindinius etapus: pirmyn sklidimą ir atgalinį sklidimą.

1. Pirmyn sklidimas (angl. Forward Propagation)

Pirmyn sklidimas – tai procesas, kurio metu įėjimo duomenys (pvz., vaizdų pikseliai ar teksto žodžiai) keliauja per visus tinklo sluoksnius, kol pasiekiamas išėjimo sluoksnis, kuriame generuojamas modelio rezultatas.

Pirmyn sklidimo žingsniai:

- Įėjimo duomenys yra siunčiami į pirmąjį sluoksnį, kuris paprastai vadinamas įėjimo sluoksniu.
- Kiekvienas neuronas apdoroja signalą, padaugindamas įvestis iš jų atitinkamų svorių ir sudėdamas reikšmes. Ši reikšmė siunčiama per aktyvavimo funkciją (pvz., „sigmoid“, „ReLU“), kuri padeda neuronui priimti sprendimą, ar siųsti signalą toliau.
- Signalas juda iš vieno sluoksnio į kitą, kol pasiekia išėjimo sluoksnį, kuris pateikia galutinę prognozę arba klasifikaciją.
- Tačiau pradžioje tinklas beveik visada generuoja netikslius atsakymus, nes svoriai yra atsitiktiniai. Todėl tinklui reikia koreguoti savo svorius, kad rezultatai taptų tikslesni.

2. Klaidos skaičiavimas

Kai tinklas generuoja išėjimo sluoksnio atsakymą, ši reikšmė palyginama su tikrąja verte (pvz., mokymo duomenų etike). Tada apskaičiuojama klaida, kuri parodo, kiek skiriasi prognozuotas ir tikras atsakymas. Klaidos skaičiavimui naudojama nuostolių funkcija (pvz., kvadratinės paklaidos funkcija regresijai arba kryžminė entropija klasifikacijai).

3. Atgalinis sklidimas (angl. Backpropagation)

Atgalinis sklidimas yra metodas, naudojamas klaidai sumažinti, koreguojant kiekvieno neurono svorius. Tai esminis DNT mokymosi etapas.

Atgalinio sklidimo žingsniai:

- Gradiento skaičiavimas: nustatoma, kaip kiekvieno svorio reikšmė prisideda prie bendros klaidos. Naudojant grandinės taisyklę, apskaičiuojama klaidos įtaka kiekvienam tinklo svoriui.
- Svorio atnaujinimas: naudojant gradientinį nusileidimą (Gradient Descent), svoriai koreguojami siekiant sumažinti klaidą. Gradientinis nusileidimas leidžia koreguoti svorius nedideliais žingsniais (pagal mokymosi tempą), kad klaida palaipsniui mažėtų.
- Šis procesas kartojamas tol, kol klaida tampa pakankamai maža arba pasiekiamas maksimalus mokymosi iteracijų (epochų) skaičius.

4. Modelio optimizavimas ir validacija

Mokymo metu tinklas gali susidurti su per didelio pritaikymo (overfitting) problema, kai modelis per daug prisitaiko prie mokymo duomenų ir praranda bendrumą. Todėl yra naudojamos tokios strategijos kaip:

Duomenų padalijimas į mokymo, validacijos ir testavimo aibę.

- Regularizacija: pridėtinės sąlygos, kurios neleidžia tinklui „per daug“ mokytis, pavyzdžiui, svorių „bauda“ arba „dropout“ technika.
- Ankstyvas sustabdymas (Early Stopping): sustabdomas mokymas, kai klaida testavimo duomenų atžvilgiu nustoja mažėti.

5. Baigtinis modelis

Po mokymo modelis gali būti naudojamas realių duomenų prognozėms ar klasifikacijoms atlikti. Jei modelis yra pakankamai tikslus, jis gali būti diegiamas, pvz., vaizdų atpažinimui, klientų elgesio prognozavimui arba automatiniam tekstų vertimui.

DNT apmokymas – tai iteracinis procesas, kurio metu tinklas, naudojant pirmyn ir atgal sklindančią informaciją, optimizuoja savo svorius, kad sumažintų klaidą ir užtikrintų tikslumą. Šis procesas yra galingas įrankis analizuoti didelius ir sudėtingus duomenų rinkinius, dėl ko neuroniniai tinklai plačiai naudojami įvairiose DI taikymo srityse.

Dirbtinių neuroninių tinklų tipai

Dirbtinių neuroninių tinklų yra keletas rūšių, kurie skiriasi savo struktūra ir pritaikymu:

DNT Rūšis	Struktūra	Pritaikymo sritys	Detalizavimas
1. Perceptronas	Paprasčiausias neuroninis tinklas.	Binarinė klasifikacija	Naudojamas paprastoms klasifikacijos užduotims, pavyzdžiui, taikant duomenų grupes.
2. Daugiasluoksnis perceptronas (MLP)	Kelios paslėptos sluoksnys.	Klasifikavimas ir regresija	Tinka sudėtingesnėms problemoms, gali atpažinti sprendimų ribas, naudojamas daugiausia inžinerijos srityse.
3. Konvoliuciniai neuroniniai tinklai (CNN)	Konvoliuciniai sluoksniai, maksimalių sujungimo sluoksniai.	Vaizdų atpažinimas ir analizė	Efektyviai atpažįsta objektus, veidus, naudojamas medicininių vaizdų analizėje ir autonominiame vairavime.
4. Pasikartojantys neuroniniai tinklai (RNN)	Cikliniai ryšiai tarp neuronų.	Sekų duomenų apdorojimas	Naudojami tekstų analizei, kalbos modeliavimui, muzikai generuoti.
5. Ilgos trukmės trumpalaikės atminties tinklai (LSTM)	Speciali RNN struktūra su atminties ląstelėmis.	Kalbos modeliavimas ir prognozavimas	Tinka ilgalaikiams duomenų ryšiams užtikrinti, pvz., analizuoja dainų tekstus ar pasakojimus.
6. Transformerių tinklai	Dėmesio mechanizmas ir sluoksnių sąveika.	Natūralios kalbos apdorojimas	Naudojami šiuolaikiniuose NLP modeliuose (pvz., „ChatGPT“), teksto suvokimui ir generavimui.
7. Generatyviniai priešiniai tinklai (GAN)	Dvi tinklo dalys: generatorius ir diskriminatorius.	Duomenų generavimas	Naudojami naujiems vaizdams, tekstams generuoti; puikiai tinka meno kūrimui ir imitacijai.
8. Autoenkoderiai	Kompresijos ir dekonstrukcijos sluoksniai.	Duomenų suspaudimas ir triukšmo šalinimas	Efektyvūs savybių išgavimui ir triukšmo šalinimui; naudojami rekomendacijų sistemose.

DNT taikymo sritys (apibendrinimas):

Taikymo sritis	DNT taikymo pavyzdžiai	Detalizavimas
Kompiuterinė rega	Objektų atpažinimas, veidų atpažinimas, autonominis vairavimas	DNT leidžia automatiškai atpažinti ir analizuoti vaizdus, kuriant efektyvias technologijas.
Natūralios kalbos apdorojimas	Kalbos vertimas, kalbos sintezė, pokalbių botai	Efektyviai apdorojant ir generuojant tekstą, leidžia sukurti interaktyvias naudotojų sąsajas.
Sveikatos priežiūra	Ligos diagnostika, medicininių vaizdų analizė	Padedą greitai ir tiksliai nustatyti ligas, optimizuojant gydymo procesus.
Finansai	Rinkos tendencijų prognozavimas, sukčiavimo aptikimas	Naudojami analizuoti duomenis ir prognozuoti finansinius sprendimus.

DNT tobulėjimas ir jų taikymo galimybės auga sparčiai, ypač dėl pažangių modelių, kaip kad giliųjų neuroninių tinklų (deep learning) ir kitų pažangių metodų, kurie vis labiau integruojami į kasdienį gyvenimą.

Sprendimų medis

Sprendimų medis yra vienas iš populiariausių ir aiškiausių mašininio mokymosi bei statistikos įrankių, naudojamų klasifikavimo ir regresijos užduotims spręsti. Ši technologija veikia hierarchinės struktūros principu, kuris leidžia lengvai ir vizualiai suprasti modelio sprendimų eigą. Sprendimų medis imituoja žmogaus priimamus sprendimus, todėl tampa intuityviu įrankiu analizuoti sudėtingus duomenų rinkinius.

Kaip veikia sprendimų medis?

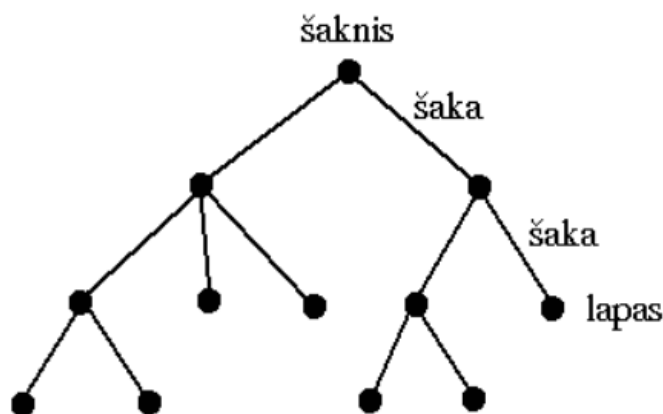
Sprendimų medis prasideda nuo vadinamojo šaknies mazgo (root node), kuriame apdorojamas visas duomenų rinkinys. Kiekviename medžio lygyje duomenys skirstomi į grupes pagal tam tikras savybes (atributus) ir atitinkamas jų vertes. Šis procesas vadinamas skirstymu arba šakomis (branches). Kiekvienas toks šakos taškas yra mazgas (node), o galutinis taškas – lapas (leaf), kuris atspindi klasifikacijos ar prognozės rezultatą. Taigi, sprendimų medis ieško „taip“ arba „ne“ tipo sprendimų sekos, vedančios į tikslinį rezultatą.

Pagrindiniai sprendimų medžio elementai

Mazgai (angl. nodes) – tai sprendimo taškai, kuriuose atliekamas kintamojo (atributo) pasirinkimas ir duomenų skaidymas.

Šakos (angl. branches) – tai kelių galimų pasirinkimų iš mazgų keliai, skaidantys duomenis toliau pagal pasirinktas taisykles.

Lapų mazgai (angl. leaves) – tai galutiniai taškai, kuriuose pateikiama klasifikacija arba prognozė.



Sprendimų medžio algoritmai

Sprendimų medis dirbtiniame intelekto (DI) – tai vienas iš priežiūrimo mokymo (angl. supervised learning) algoritmų, naudojamas klasifikacijai ir regresijai. Tai hierarchinė struktūra, kuri priima sprendimus pagal duomenų savybes, padalindama duomenis į mažesnes grupes remiantis tam tikrais kriterijais.

Sprendimų medžio pagrindinės dalys:

- **Šaknis (angl. Root node):** Pradinis taškas, kuriame atliekamas pirmasis padalijimas.
- **Šakos (angl. Branches):** Ryšiai tarp skirtingų mazgų, rodantys sprendimų kryptį.
- **Vidiniai mazgai (angl. Internal nodes):** Taškai, kuriuose priimami sprendimai pagal tam tikrą savybę ar kriterijų.
- **Lapai (angl. Leaf nodes):** Galutiniai mazgai, kurie pateikia klasifikaciją ar reikšmę.

Kaip veikia sprendimų medis:

1. Pasirenka geriausią savybę, pagal kurią duomenys skirstomi (pvz., naudojant informacijos prieaugį arba Gini koeficientą).
2. Padalina duomenis į poskyrius pagal pasirinktą savybę.
3. Kiekvienas poskyris gali būti toliau skaidomas, kol pasiekiamas stabdymo sąlyga (pvz., maksimalus gylis, minimalus pavyzdžių skaičius mazge).
4. Kai skaidymai baigti, galutiniai lapai pateikia sprendimą.

Yra keletas populiariausių algoritmų, naudojamų sprendimų medžių formavimui:

- **CART (angl. Classification and Regression Trees):** šis algoritmas naudojamas tiek klasifikavimo, tiek regresijos problemoms spręsti. Jis skirsto duomenis, naudodamas „Gini impurity“ arba vidutinius kvadratų klaidų kriterijus.
- **ID3 (angl. Iterative Dichotomiser 3):** tai paprastas klasifikavimo metodas, kuris naudoja informacijos pelno (information gain) matą duomenų skaidymui.
- **C4.5 ir C5.0:** tai patobulinti ID3 algoritmai, kuriuose įdiegtos papildomos funkcijos, tokios kaip supaprastintas medžio genėjimas ir kintamųjų tvarkymas.

Privalumai:

- **Aiškumas:** sprendimų medis lengvai suprantamas ir gali būti atvaizduojamas grafinėje formoje.
- **Mažai reikalavimų duomenų paruošimui:** duomenys neturi būti normalizuoti ar standartizuoti.
- **Universalumas:** gali būti naudojamas tiek klasifikavimo, tiek regresijos užduotims.

Trūkumai:

- **Pernelyg didelis tinkamumas (overfitting):** sprendimų medžiai dažnai linkę pernelyg prisitaikyti prie mokymo duomenų, ypač kai medis tampa per gilus.
- **Jautrus triukšmui duomenyse.**

- Jautrumas duomenų variacijai: nedidelis duomenų pokytis gali reikšmingai pakeisti medžio struktūrą.

Taikymas

Sprendimų medžiai plačiai naudojami įvairiose srityse:

- Medicinoje: diagnozės ir prognozių nustatymui, pavyzdžiui, ligos rizikos vertinimui.
- Finansų srityje: rizikos vertinimui ir kreditų vertinimo sistemoms kurti.
- Marketinge: klientų segmentacijai ir pirkimo modelių prognozėms.

Sprendimų medžiai dažnai naudojami su kitais modeliais (pavyzdžiui, atsitiktiniais miškais ar XGBoost algoritmais), kurie padeda sprendimų medžiams tapti tikslesniais ir mažiau linkusiais į per didelį tinkamumą.

Dirbtinio intelekto taikymas siekiant analizuoti, klasifikuoti, atpažinti ir prognozuoti duomenis

Dirbtinis intelektas (DI) yra plačiai taikomas įvairiose srityse, **siekiant analizuoti, klasifikuoti, atpažinti ir prognozuoti duomenis**. Pateikiu pagrindinius DI taikymo būdus duomenims klasifikuoti, atpažinti ir prognozuoti.

- **Duomenų klasifikacija** – tai DI metodo, tokio kaip mašininis mokymasis, panaudojimas objektams ar duomenims priskirti prie tam tikrų iš anksto apibrėžtų klasių. Taikymo pavyzdžiai:
 - ✓ El. laiškų filtravimas: Naudojamas spam'o atpažinimui, kur DI klasifikuoja el. laiškus į šlamštą arba norimus laiškus.
 - ✓ Medicininė diagnostika: DI modeliai gali klasifikuoti medicininius vaizdus (pvz., rentgeno nuotraukas) ir nustatyti, ar yra tam tikra liga, pavyzdžiui, vėžys.
 - ✓ Finansinių sandorių stebėjimas: Klasifikuoja sandorius kaip įprastus arba galimai apgaulingus.
 - ✓ Teksto analizė: Nustato teigiamus ar neigiamus komentarus socialinėje žiniasklaidoje arba peržiūrų svetainėse.
- **Atpažinimas (angl. recognition)**: Atpažinimas – tai DI gebėjimas identifikuoti specifinius objektus ar šablonus duomenyse, naudojant metodus, tokius kaip gilusis mokymasis ar kompiuterinė rega. Taikymo pavyzdžiai:
 - ✓ Veidų atpažinimas: Naudojamas saugumo sistemose, socialinių tinklų nuotraukų žymėjime ar biometriniuose įrenginiuose.
 - ✓ Kalbos atpažinimas: Programos, tokios kaip "Google Assistant" ar "Siri", naudoja DI, kad suprastų ir interpretuotų vartotojų balsą.
 - ✓ Objektų atpažinimas nuotraukose ir vaizdo įrašuose: Naudojamas autonominėse transporto priemonėse, kurios atpažįsta kelio ženklus, kliūtis, žmones ir kitas transporto priemones.
 - ✓ Rašysenos atpažinimas: DI gali atpažinti ranka rašytus tekstus, pavyzdžiui, skenuojant dokumentus ar parašus.
- **Prognozavimas** – tai DI gebėjimas analizuoti istorinę informaciją ir numatyti būsimus rezultatus ar tendencijas. Tai gali būti pasiekta naudojant metodus, tokius kaip regresinė analizė, laiko eilučių modeliai, gilusis mokymasis ar neuroniniai tinklai. Taikymo pavyzdžiai:
 - ✓ Finansinės rinkos prognozės: Modeliai gali analizuoti praeities duomenis ir prognozuoti akcijų ar valiutų kainų svyravimus.
 - ✓ Orų prognozavimas: DI modeliai, naudojantys milžiniškus meteorologinių duomenų rinkinius, gali tiksliai prognozuoti orus, audras ir klimato pokyčius.
 - ✓ Verslo analitika: Pardavimų, vartotojų elgesio ar paklausos prognozavimas, padedantis įmonėms priimti strateginius sprendimus.

- ✓ Medicinos prognozės: DI gali numatyti ligos progresavimą arba prognozuoti pacientų reakcijas į tam tikrus gydymo metodus.
- ✓ Techninės priežiūros prognozavimas: Pramonėje DI naudojamas numatyti įrangos gedimus, kad būtų galima atlikti prevencinę priežiūrą prieš gedimus.

Technologijos ir metodai: Norint įgyvendinti minėtus DI taikymus, dažniausiai naudojami šie metodai:

- **Neuroniniai tinklai**: Ypač gilusis mokymasis, naudojamas atpažinimui ir prognozavimui, pavyzdžiui, vaizdų ir kalbos apdorojime.
- **Mašininio mokymosi algoritmai**: Naudojami klasifikacijai ir prognozavimui (pvz., SVM, sprendimų medžiai, atsitiktinių miškų modeliai).
- **Natūralios kalbos apdorojimas (NLP)**: Naudojamas tekstų ir kalbos atpažinimui, klasifikacijai bei supratimui.
- **Kompiuterinė rega**: Naudojama vaizdų ir objektų atpažinimui.

Dirbtinio intelekto taikymai duomenų klasifikavimui, atpažinimui ir prognozavimui leidžia spręsti realaus pasaulio problemas tokiose srityse kaip medicina, finansai, pramonė, saugumas ir socialinė žiniasklaida. DI metodai nuolat tobulėja ir padeda analizuoti didelius duomenų rinkinius, numatyti ateities įvykius ir pagerinti kasdienio gyvenimo kokybę.

Duomenų klasifikacija yra viena iš svarbiausių dirbtinio intelekto (DI) ir mašininio mokymosi sričių. Jos tikslas yra priskirti duomenų pavyzdžius iš anksto apibrėžtomis kategorijoms arba klasėms. Klasifikavimo algoritmai mokosi iš jau paženklintų duomenų (vadinamų treniravimo rinkiniais), o po to naudoja išmoktą modelį, kad prognozuotų naujų, nežinomų duomenų kategorijas. Tai plačiai naudojama įvairiose srityse, pavyzdžiui, medicinoje, finansuose, rinkodaroje ir dirbtinio intelekto sistemose.

- **Kas yra klasifikacija?** Klasifikacija yra prižiūrimas mokymasis (angl. supervised learning), kai algoritmas mokosi iš treniravimo duomenų rinkinio, kuriame kiekvienas pavyzdys turi etiketę (klasę). Šiuo būdu, algoritmas bando išmokti, kaip kiekvienas duomenų pavyzdys susijęs su atitinkama klase, kad galėtų klasifikuoti naujus duomenų pavyzdžius į tas pačias arba kitas klases.
Pavyzdys: El. pašto klasifikavimas kaip „spam“ arba „ne spam“ (dvejtainė klasifikacija). Ligos diagnozavimas iš medicininių duomenų (daugialypė klasifikacija).
- **Duomenų klasifikavimo problemos tipai: Klasifikavimo užduotys gali būti skirstomos į kelias pagrindines kategorijas:**
 - ✓ Dvejtainė klasifikacija (angl. binary classification): Tai klasifikavimo užduotis, kai turime tik dvi galimas klases. Pavyzdžiui, el. laiško klasifikavimas kaip „spam“ arba „ne spam“.
 - ✓ Daugialypė klasifikacija (angl. multiclass classification): Šiuo atveju duomenys gali priklausyti vienai iš daugiau nei dviejų klasių. Pavyzdžiui, vaizdų klasifikavimas į „katė“, „šuo“ ir „paukštis“ klases.
 - ✓ Daugianarė klasifikacija (angl. multilabel classification): Kiekvienam duomenų pavyzdžiui gali būti priskirtos kelios etiketės ar klasės. Pavyzdžiui, vienas el. laiškas gali būti priskirtas tiek „skubus“, tiek „darbinis“.
- **Pagrindiniai klasifikavimo algoritmai**
 - ✓ Logistinė regresija: Tai vienas iš populiariausių klasifikavimo algoritmų dvejtainėje klasifikacijoje. Logistinė regresija apskaičiuoja tikimybę, kad pavyzdys priklauso tam tikrai klasei, ir priskiria pavyzdį pagal tą tikimybę.
Pavyzdys: Logistinė regresija gali būti naudojama finansiniuose modeliuose prognozuoti, ar klientas bus mokus (mokės paskolą) arba nemokus.

- ✓ K-naive kaimynai (K-Nearest Neighbors, KNN): Tai paprastas, bet efektyvus klasifikavimo algoritmas, kuris priskiria duomenų pavyzdžius pagal jų artumą prie kitų pavyzdžių. Naujiems duomenims klasė priskiriama pagal K artimiausių kaimynų klasės daugumą.
Pavyzdys: KNN gali būti naudojamas rekomendacijų sistemose, pavyzdžiui, siūlant produktus vartotojui, kuris elgiasi panašiai kaip kiti vartotojai.
- ✓ Sprendimų medžiai (angl. Decision Trees): Sprendimų medis – tai hierarchinė struktūra, kurioje kiekvienas mazgas atspindi sprendimą ar testą pagal tam tikrą atributą, o šakos – rezultatus. Galutiniuose lapuose pateikiama klasifikacija.
Pavyzdys: Sprendimų medis gali būti naudojamas medicininėse diagnostikose, kur gydytojas, remdamasis simptomais, priima sprendimą dėl diagnozės.
- ✓ Atsitiktinių miškų algoritmas (angl. Random Forest): Tai ansamblinis metodas, kuriame naudojama daug sprendimų medžių. Kiekvienas medis pateikia savo klasifikaciją, o galutinė klasifikacija nustatoma balsavimo būdu.
Pavyzdys: Atsitiktiniai miškai yra dažnai naudojami finansų sektoriuje prognozuoti kredito riziką arba akcijų rinkos tendencijas.
- ✓ Naivusis Bayeso klasifikatorius (angl. Naive Bayes): Šis algoritmas grindžiamas Bayeso teorema ir prielaida, kad visi požymiai yra nepriklausomi. Tai paprastas, tačiau labai veiksmingas klasifikavimo metodas, ypač tekstų klasifikavimui.
Pavyzdys: Naudojamas el. laiškų filtravimui į „spam“ arba „ne spam“ kategorijas pagal turinį ir struktūrą.
- ✓ Palaiškymo vektorių mašina (angl. Support Vector Machine, SVM): SVM ieško hiperlokio (linijos dvejetainės klasifikacijos atveju), kuris optimaliai atskiria klases duomenų erdvėje, siekdamas maksimaliai atskirti duomenis.
Pavyzdys: SVM naudojama vaizdo apdorojimo srityje, pavyzdžiui, veidų atpažinimo užduotims, kad atskirtų veidus nuo kitų objektų.
- ✓ Neuroniniai tinklai ir gilusis mokymasis: Neuroniniai tinklai (ypač gilusis mokymasis) yra labai efektyvūs sprendžiant sudėtingas klasifikavimo problemas, kur yra daug duomenų ir kompleksiški ryšiai tarp požymių. Jie sudaro gilių sluoksnių struktūras, kurios išmoksta sudėtingus modelius.
Pavyzdys: Giliai neuroniniai tinklai naudojami vaizdų ir kalbos atpažinime, pavyzdžiui, klasifikuojant vaizdus (katės, šunys) arba atpažįstant balsus.

- **Klasifikavimo procesas**
 - ✓ Duomenų rinkimas: Klasifikavimo procesas prasideda nuo duomenų rinkimo ir pasirengimo. Duomenys gali būti įvairios formos – skaičiai, tekstai, vaizdai ir pan. Svarbu, kad šie duomenys būtų žymėti (kiekvienam pavyzdžiui turi būti priskirta klasė).
 - ✓ Duomenų išankstinis apdorojimas: Dažnai duomenis reikia apdoroti prieš juos naudojant mokymuisi. Tai apima:
 - Trūkstančių duomenų tvarkymą,
 - Duomenų normalizavimą arba standartizavimą,
 - Kategorizuotų duomenų kodavimą (pvz., „vieno karšto kodavimo“ metodas),
 - Duomenų skaidymą į treniravimo ir testavimo rinkinius.
 - ✓ Modelio treniravimas: Šiame etape naudojamas klasifikavimo algoritmas, kuris išmoksta ryšius tarp duomenų požymių ir jų atitinkamų klasių. Mokymasis vyksta treniravimo duomenų rinkinyje.
 - ✓ Modelio vertinimas: Modelis yra testuojamas naudojant testavimo duomenų rinkinį, siekiant įvertinti jo tikslumą. Naudojami įvairūs vertinimo rodikliai:
 - Tikslumas (angl. accuracy) – teisingai klasifikuotų pavyzdžių dalis,
 - Tikslumas ir atšaukimas (angl. precision ir recall) – rodikliai, vertinantys kaip tiksliai ir pilnai modelis atpažįsta teigiamus pavyzdžius,
 - F1 rodiklis – subalansuotas tikslumo ir atšaukimo vidurkis.
 - ✓ Modelio optimizavimas: Modelio parametrų (hiperparametrų) optimizavimas ir, jei reikia, kitų algoritmų pritaikymas siekiant pagerinti tikslumą ir našumą.
- **Realių problemų sprendimas naudojant klasifikavimą**
 - ✓ Finansų sektorius: Klasifikavimas naudojamas vertinant kredito riziką, nustatant potencialius sukčiavimo atvejus.
 - ✓ Medicina: DI modeliai padeda diagnozuoti ligas, klasifikuojant medicininius duomenis (pvz., MRT vaizdus ar pacientų istorijas).
 - ✓ Rinkodara: Vartotojų segmentavimas pagal pirkimo elgseną arba interesus, siekiant pateikti personalizuotus pasiūlymus.
 - ✓ Socialiniai tinklai: Komentarų arba naujienų klasifikavimas į teigiamus, neigiamus ar neutralus.
- **Klasifikacijos proceso detalizavimas**
 - ✓ Požymių inžinerija: Požymių inžinerija yra esminė klasifikavimo dalis. Ji apima duomenų transformavimą, kad iš jų būtų galima išgauti reikšmingus požymius, kurie pagerina modelio veikimą. Tinkamai parinkti požymiai gali labai pagerinti modelio tikslumą.
Pavyzdys: Finansiniuose duomenyse gali būti naudojami toki požymiai kaip „vidutinė mėnesio išlaidų suma“ arba „pirkimo dažnumas“, kurie gali padėti klasifikuoti vartotojų elgseną.
 - ✓ Modelio hiperparametrų optimizavimas: Kiekvienas klasifikavimo algoritmas turi tam tikrus hiperparametrus, kuriuos reikia tinkamai nustatyti. Tai gali apimti sprendimų medžių gylį, neuroninio tinklo sluoksnių skaičių arba SVM branduolio funkcijas. Hiperparametrų optimizavimas leidžia pagerinti modelio veikimą.
Pavyzdys: Palaikymo vektorių mašinose reikia pasirinkti tinkamą branduolio funkciją (pvz., linijinį, polinominį ar radialinį).
- **Klasifikavimo iššūkiai**
Pagrindiniai iššūkiai klasifikavimo užduotyse yra:
 - ✓ Duomenų disbalansas;
 - ✓ Perteklinis pritaikymas;
 - ✓ Trūkstami duomenys;

- ✓ Triukšmingi ar nereikšmingi požymiai.
- Šių iššūkių valdymas yra esminis norint sukurti veiksmingą ir tikslią klasifikavimo modelį.

Klasifikacija yra labai universali ir plačiai naudojama technika duomenų mokslui ir dirbtiniam intelektui. Svarbu pasirinkti tinkamą klasifikavimo algoritmą pagal duomenų struktūrą, įvertinti iššūkius ir nuolat optimizuoti modelį, kad jis galėtų sėkmingai atlikti priskirtą užduotį. Klasifikavimo užduotys gali būti sudėtingos, ypač kai susiduriama su įvairiais iššūkiais, kurie gali neigiamai paveikti modelio tikslumą ir patikimumą. Toliau pateikiami pagrindiniai iššūkiai, su kuriais susiduriama kuriant ir naudojant klasifikavimo algoritmus.

- **Perteklinis pritaikymas (angl. Overfitting)**

Perteklinis pritaikymas įvyksta, kai modelis per gerai prisitaiko prie treniravimo duomenų, tačiau nepajėgia generalizuoti ir tinkamai pritaikyti naujiems, nematytiems duomenims. Tai atsitinka, kai modelis išmoksta ne tik naudingus duomenų šablonus, bet ir triukšmą ar atsitiktinius nuokrypius, kurie neturi bendrų tendencijų.

Pavyzdys: Per sudėtingas modelis, kaip gilusis neuroninis tinklas su per daug sluoksnių, gali pradėti atpažinti atsitiktinius treniravimo duomenų šablonus, kurie nėra reikšmingi testavimo duomenims.

Sprendimo būdai:

- ✓ Naudoti paprastesnius modelius (pvz., mažiau sluoksnių neuroniniuose tinkluose).
- ✓ Naudoti reguliarizacijos metodus, kaip L1 ar L2 reguliarizacija, kad būtų sumažintas modelio sudėtingumas.
- ✓ Naudoti daugiau treniravimo duomenų, kad modelis turėtų daugiau įvairovės mokymuisi.

- **Neužtektini duomenys**

Klasifikavimo modeliams reikia pakankamai duomenų, kad jie galėtų išmokti reikšmingų šablonų. Jei duomenų rinkinys yra per mažas, modelis gali neturėti pakankamai informacijos, kad tinkamai generalizuotų, arba išvis nepavyks mokyti modelio.

Pavyzdys: Medicininėse diagnozėse, kai tam tikros retos ligos duomenys yra itin riboti, DI modelis gali nesugebėti tiksliai numatyti ligos buvimo.

Sprendimo būdai:

- ✓ Naudoti duomenų papildymą (data augmentation), siekiant sukurti naujus duomenų pavyzdžius iš esamų.
- ✓ Naudoti perdavinimo mokymą (transfer learning), kai modelis yra iš anksto išmokytas su dideliu panašių duomenų rinkiniu ir pritaikomas mažesniai konkrečiai uždaviniui.
- ✓ Naudoti k-vidurkio kryžminę validaciją (angl. k-fold cross-validation), siekiant maksimaliai panaudoti esamus duomenis.

- **Nepusiausvyros duomenys (angl. Imbalanced Data)**

Klasifikavimo užduotys gali būti sunkiai sprendžiamos, kai klasių pasiskirstymas yra labai nevienodas. Kai kurios klasės gali turėti daug daugiau pavyzdžių nei kitos, todėl modelis gali išmokti teisingai prognozuoti tik dažniausias klases, ignoruodamas retesnes.

Pavyzdys: Sukčiavimo aptikimo sistemos dažnai turi daug daugiau teisėtų sandorių nei apgaulingų, o tai gali lemti, kad modelis labiau linkęs klasifikuoti sandorius kaip „teisėtus“, net jei jie yra sukčiavimo atvejai.

Sprendimo būdai:

- ✓ Naudoti duomenų balanso metodus, pavyzdžiui, perėmimą (oversampling) retoms klasėms arba subėmimą (undersampling) dažniausiai klasei.
- ✓ Naudoti algoritmus, kurie gali spręsti disbalansą, pavyzdžiui, kostiumizuotus praradimo funkcijas (cost-sensitive learning), kai klaidingos klasifikacijos sunkesnėms klasėms yra labiau baudžiamos.

- ✓ Naudoti SMOTE (angl. Synthetic Minority Over-sampling Technique), kuris sukuria naujus sintetiniai pavyzdžius iš mažumos klasių.
- **Trūkstami duomenys**
Trūkstami arba neišsamūs duomenys gali rimtai pakenkti modelio tikslumui, nes klasifikavimo modeliai reikalauja visos informacijos norint išmokyti tikslius šablonus. Trūkstami duomenys dažniausiai atsiranda dėl klaidų rinkimo procese arba techninių priežasčių.
Pavyzdys: Pacientų medicininiuose įrašuose gali trūkti tam tikrų laboratorinių tyrimų rezultatų, o tai gali klaidinti diagnostikos modelius.
Sprendimo būdai:
 - ✓ Naudoti duomenų imputaciją, kad būtų užpildyti trūkstami duomenys (pvz., pakeičiant trūkstamas reikšmes vidurkiais, medianomis arba naudoti pažangesnius metodus, kaip KNN imputacija).
 - ✓ Pašalinti pavyzdžius arba atributus, kuriuose trūksta reikšmingo duomenų kiekio, jei jų trūksta per daug.
 - ✓ Naudoti algoritmus, kurie yra atsparesni trūkstamiems duomenims, pavyzdžiui, sprendimų medžiai.
- **Pernelyg didelis duomenų kiekis arba nereikšmingi požymiai**
Kai duomenų rinkinys turi daug požymių (features), iš kurių kai kurie gali būti nereikšmingi arba net triukšmingi, modelis gali išmokyti netinkamus šablonus. Tai vadinama matmenų prakeiksmu (curse of dimensionality), kai duomenų erdvė tampa pernelyg sudėtinga ir daugialypė, o mokymosi procesas tampa neveiksmingas.
Pavyzdys: Duomenų rinkinys, kuriame yra tūkstančiai nereikšmingų požymių, gali trukdyti modeliui išmokyti tikrus klasifikavimo šablonus.
Sprendimo būdai:
 - ✓ Naudoti požymių atranką (angl. feature selection), pavyzdžiui, ANOVA F-test arba laukų svarbos matavimus (angl. feature importance scores), siekiant pašalinti nereikšmingus požymius.
 - ✓ Naudoti požymių sumažinimo (angl. dimensionality reduction) metodus, kaip PCA (angl. Principal Component Analysis) arba t-SNE, siekiant sumažinti požymių erdvę iki svarbiausių komponentų.
- **Požymių inžinerija**
Kartais esami požymiai (features) nėra tinkamai reprezentuojami ir nesugeba apibūdinti reikšmingų šablonų, todėl būtina kurti naujus požymius. Požymių inžinerija – tai procesas, kai sukurti papildomi požymiai, siekiant geriau apibrėžti duomenis ir pagerinti modelio našumą.
Pavyzdys: Finansinių duomenų rinkinyje galima sukurti naujus požymius, apskaičiuojant kiekvieno kliento vidutines išlaidas per mėnesį ar pirkimo dažnumą, kad būtų lengviau klasifikuoti jų rizikos lygį.
Sprendimo būdai:
 - ✓ Gilinti žinias apie duomenų sritį, kad būtų sukurti reikšmingi nauji požymiai.
 - ✓ Naudoti automatizuotus požymių inžinerijos įrankius arba metodus, tokius kaip FeatureTools.
- **Per mažas duomenų įvairovės lygis**
Jei treniravimo duomenys nėra pakankamai įvairūs arba neatspindi visos duomenų įvairovės, klasifikavimo modelis gali veikti gerai tik su panašiais duomenimis, bet prastai su neįprastais ar naujais pavyzdžiais.
Pavyzdys: Veidų atpažinimo modelis, išmokytas tik su tam tikros amžiaus grupės ar etninės grupės pavyzdžiais, gali nesugebėti teisingai atpažinti kitų grupių atstovų.

Sprendimo būdai:

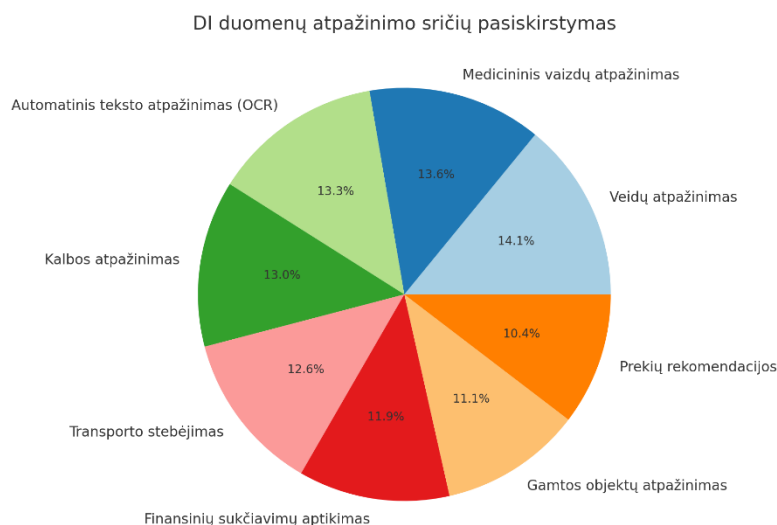
- ✓ Naudoti įvairesnius ir labiau atstovaujančius treniravimo duomenis.
 - ✓ Taikyti duomenų papildymą, kad būtų galima sukurti įvairių pavyzdžių iš esamų duomenų, ypač kai yra disbalansas.
 - **Duomenų pasikeitimas laike (angl. Concept Drift)**

Kai duomenys laikui bėgant keičiasi, DI modeliai gali tapti netikslūs. Tai ypač aktualu srityse, kur duomenys sparčiai evoliucionuoja, kaip finansai, socialiniai tinklai ar rinkodara. Kai šablonai, pagal kuriuos mokėsi modelis, tampa neaktualūs, būtina atnaujinti modelį.

Pavyzdys: Finansų srityje, klientų pirkimo įpročiai gali keistis dėl ekonominių pokyčių, o tai gali priversti modelį, mokyta prieš keletą metų, tapti netikslų.
- #### Sprendimo būdai:
- ✓ Nuolat atnaujinti modelį naujausiais duomenimis.
 - ✓ Naudoti adaptuojamus modelius, kurie geba koreguotis prie duomenų pokyčių realiu laiku.

Visi šie klasifikavimo iššūkiai reikalauja nuoseklaus problemų identifikavimo ir tinkamų sprendimų taikymo.

Dirbtinio intelekto (DI) taikymas duomenų atpažinimui apima gebėjimą analizuoti ir interpretuoti duomenis, kad būtų atpažinti tam tikri modeliai, objektai ar kiti elementai. Tai itin svarbi sritis, naudojama įvairiuose praktiniuose kontekstuose, pradedant vaizdų ir kalbos atpažinimu, baigiant tekstų analizavimu ir biometrinėmis technologijomis.



1. Kas yra duomenų atpažinimas?

Duomenų atpažinimas – tai procesas, kai DI modeliai geba analizuoti didelius duomenų kiekius ir automatiškai identifikuoti tam tikras ypatybes, šablonus ar struktūras. Šis procesas dažniausiai vyksta be žmogaus įsikišimo ir naudojant pažangius algoritmus, kaip neuroninius tinklus, gilųjį mokymąsi ir kompiuterinę regą.

Pavyzdžiai:

Veido atpažinimas: Atpažinti žmonių veidus iš vaizdų ar vaizdo įrašų.

Kalbos atpažinimas: Atpažinti žmogaus kalbą ir ją konvertuoti į tekstą.

Rankraščio atpažinimas: Nustatyti rašytinį tekstą ir jį skaitmenizuoti.

2. DI taikymo sritys duomenims atpažinti

a) Vaizdų atpažinimas

Vaizdų atpažinimas – tai procesas, kai DI modeliai analizuoja vizualinę informaciją, siekiant identifikuoti objektus, žmones ar kitus elementus vaizduose. Šis procesas dažniausiai grindžiamas konvoliuciniais neuroniniais tinklais (CNN), kurie sugeba išmokti kompleksiškus vaizdų požymius. Pavyzdys: Naudojamas autonominėse transporto priemonėse, kur DI modeliai atpažįsta eismo ženklus, kitus automobilius ir pėsčiuosius. Medicina: Vaizdų atpažinimas naudojamas radiologijoje, siekiant atpažinti navikus ar kitas anomalijas medicininiuose vaizduose.

b) Kalbos atpažinimas

Kalbos atpažinimas (speech recognition) yra procesas, kai DI sistema garsu pagrįstą informaciją paverčia tekstu. Tam naudojami rekurentiniai neuroniniai tinklai (RNN) arba transformatorių modeliai, tokie kaip BERT ir GPT.

Pavyzdys: Naudojamas asistentuose, kaip „Siri“ ar „Google Assistant“, kur vartotojo komandos yra suprantamos natūralia kalba ir automatiškai apdorojamos.

c) Veido atpažinimas

Veido atpažinimas – tai ypatinga vaizdų atpažinimo rūšis, kai sistema sugeba atpažinti arba identifikuoti asmenį pagal veido bruožus. Veido atpažinimo sistemose taip pat naudojami konvoliuciniai neuroniniai tinklai (CNN).

Pavyzdys: Naudojamas saugumo sistemose, pavyzdžiui, veido atpažinimas mobiliajame telefone, arba stebėjimo kameroje, kuriose atpažįstami ieškomi asmenys.

d) Optinio simbolių atpažinimas (OCR)

OCR technologija naudojama skaitmenizuoti rašytinius tekstus ir konvertuoti juos į skaitmeninius dokumentus. Naudojant pažangius DI metodus, OCR gali atpažinti įvairių kalbų simbolius bei netgi interpretuoti ranka rašytą tekstą.

Pavyzdys: Naudojama skenuotų dokumentų automatiniam vertimui į redaguojamą tekstą, pavyzdžiui, skaitmeninant archyvus.

e) Tekstų atpažinimas ir analizė

Natūraliosios kalbos apdorojimas (NLP) leidžia DI sistemoms suprasti, analizuoti ir interpretuoti tekstinę informaciją. Naudojant pažangius NLP algoritmus, DI gali atlikti sentimentų analizę, klasifikuoti tekstus ir net generuoti naujus tekstus.

Pavyzdys: Automatinė el. laiškų analizė, siekiant klasifikuoti juos kaip „spam“ ar „ne spam“.

3. Technologijos ir algoritmai duomenų atpažinimui

a) Konvoliuciniai neuroniniai tinklai (CNN)

CNN yra giliųjų neuroninių tinklų architektūra, kuri dažniausiai naudojama vaizdų apdorojimui ir atpažinimui. CNN sugeba efektyviai atpažinti kompleksinius vaizdų šablonus, suskaidant juos į mažesnius vaizdo fragmentus ir analizuoja hierarchinius vaizdo požymius.

Pavyzdys: CNN naudojami objektų atpažinimui autonominėse transporto priemonėse arba medicininiuose vaizduose (pvz., MRT ar rentgeno nuotraukose).

b) Rekurentiniai neuroniniai tinklai (RNN)

RNN algoritmai puikiai tinka sekos duomenų apdorojimui, ypač kalbos atpažinimui ar natūralios kalbos apdorojimui (NLP). Jie gali analizuoti duomenų sekas ir išlaikyti atmintį apie ankstesnius žingsnius, kas yra svarbu tvarkant laiko sekos duomenis.

Pavyzdys: Kalbos atpažinimas arba vertimo sistemos, kur kiekvienas žodis priklauso nuo ankstesnių konteksto.

c) Transformeriai

Transformeriai yra pažangesnė sekos apdorojimo architektūra, plačiai naudojama natūraliosios kalbos apdorojimo užduotims. Modeliai kaip BERT, GPT arba T5 sugeba suprasti tekstą, atlikti semantinę analizę ir net generuoti natūraliai skambančius tekstus.

Pavyzdys: Tekstų generavimas, vertimas, automatizuotas dialogų vedimas arba teksto suvestinės kūrimas.

d) Optinio srauto metodai

Šie metodai naudojami atpažinimui vaizdo įrašuose, stebint judesį ir sekant objektus. Tai padeda analizuoti ne tik statinius vaizdus, bet ir dinامينius pokyčius vaizduose, pavyzdžiui, judėjimo kryptį.

Pavyzdys: Sporto vaizdo įrašuose žaidėjų judesių sekimas arba transporto priemonių judėjimo stebėjimas.

4. Praktiniai DI duomenų atpažinimo taikymai

a) Autonominės transporto priemonės

Autonominės transporto priemonės remiasi DI algoritmais, kurie atpažįsta objektus (kitus automobilius, eismo ženklus, pėsčiuosius) ir realiu laiku priima sprendimus. Vaizdo atpažinimas yra viena iš svarbiausių technologijų autonominiuose automobiliuose.

Pavyzdys: „Tesla“ autonominės transporto priemonės, kurios naudoja kameras ir DI modelius eismo ženklams ir kliūtims atpažinti.

b) Medicinos diagnostika

Dirbtinis intelektas tapo nepakeičiamas įrankis medicinoje, ypač diagnozuojant ligas iš vaizdinių duomenų, kaip rentgeno nuotraukos, MRT ar ultragarsas. Naudojami vaizdų atpažinimo algoritmai leidžia automatizuotai aptikti anomalijas, pvz., navikus.

Pavyzdys: Diabetinės retinopatijos aptikimas analizuojant akies dugno nuotraukas.

c) Finansinės sistemos

DI naudojamas atpažinti anomalijas finansinėse operacijose, identifikuojant galimus sukčiavimo atvejus realiu laiku. Šios sistemos sugeba analizuoti milijonus operacijų ir greitai atpažinti nesąžiningą veiklą.

Pavyzdys: Kreditinių kortelių transakcijų stebėjimas ir įtartinų operacijų atpažinimas.

d) Veidų atpažinimas saugumo srityje

Veido atpažinimas plačiai taikomas saugumo srityje: nuo oro uostų patikrinimų iki viešų renginių stebėjimo. Sistemų tikslumas nuolat gerėja, leidžiant jas naudoti dideliuose duomenų rinkiniuose ir realaus laiko stebėjimuose.

Pavyzdys: Veido atpažinimo sistemos, naudojamos viešosiose vietose, siekiant užtikrinti saugumą arba identifikuoti nusikaltėlius.

e) E. komercija ir rekomendacijų sistemos

Rekomendacijų sistemos, naudojamos elektroninės prekybos svetainėse, remiasi DI, kuris sugeba atpažinti vartotojų pirkimo modelius ir rekomenduoti produktus. Šie algoritmai nuolat mokosi iš vartotojų veiklos ir tobulina rekomendacijas.

Pavyzdys: „Amazon“ arba „Netflix“ rekomendacijų sistemos, kurios naudoja ankstesnes paieškas ir veiklą siekiant pasiūlyti vartotojui tinkamus produktus arba filmus.


5. Iššūkiai duomenų atpažinime naudojant DI

Dideli duomenų kiekiai: Duomenų atpažinimui reikalingi dideli ir kokybiški duomenų rinkiniai. Dideli vaizdų arba kalbos duomenų rinkiniai gali kelti iššūkių dėl laikymo ir apdorojimo pajėgumų.

Duomenų privatumas ir saugumas: Ypač kalbant apie veido atpažinimą ir biometrinius duomenis, iškyla dideli privatumo ir duomenų apsaugos iššūkiai.

Modelių tikslumas: Atpažinimo tikslumas priklauso nuo naudojamų algoritmų ir treniravimo duomenų kokybės. Netiksliai apmokyti modeliai gali pateikti klaidingus rezultatus.

Dirbtinis intelektas atvėrė daugybę galimybių duomenų atpažinimo srityje. Nuo medicininės diagnostikos iki autonominių transporto priemonių, DI geba analizuoti ir interpretuoti duomenis taip, kaip anksčiau buvo neįmanoma. Nepaisant iššūkių, DI atpažinimo technologijos nuolat tobulėja ir tampa vis svarbesnės kasdiniame gyvenime.



Dirbtinio intelekto (DI) taikymas duomenims prognozuoti apima metodus ir algoritmus, leidžiančius analizuoti praeities duomenis ir numatyti būsimus įvykius arba tendencijas. DI prognozavimo modeliai naudoja didelius duomenų rinkinius ir iš jų mokosi identifikuoti pasikartojančius modelius, kurie gali būti naudojami prognozėms daryti. Tai itin svarbi sritis, plačiai taikoma finansuose, rinkodaroje, sveikatos priežiūroje, klimato tyrimuose ir kitose srityse.

1. Kas yra duomenų prognozavimas?

Duomenų prognozavimas – tai procesas, kai DI modeliai analizuoja istorinius duomenis ir sukuria modelius, leidžiančius numatyti būsimus duomenų taškus. Pagrindinis tikslas – suprasti esamus duomenis ir rasti ryšius, kurie galėtų padėti tiksliai nuspėti ateitį.

Pavyzdžiai:

Pardavimų prognozavimas: Nuspėti būsimą pardavimų augimą, atsižvelgiant į ankstesnių metų duomenis.

Finansinių rinkų prognozavimas: Prognozuoti akcijų kainų pokyčius arba valiutos kursų svyravimus.

Sveikatos prognozavimas: Numatyti paciento sveikatos būklės pablogėjimą remiantis mediciniais įrašais.

2. DI taikymo sritys duomenims prognozuoti

a) Finansų prognozavimas

Finansų sektoriuje prognozavimas yra būtinas, siekiant tiksliai numatyti akcijų rinkų tendencijas, valiutų kursų pokyčius ar investicijų grąžą. DI modeliai analizuoja istorinę finansų informaciją ir ieško šablonų, kurie gali padėti priimti investicinius sprendimus.

Pavyzdys: DI modeliai, kurie naudoja laiko eilučių duomenis (pvz., akcijų kainų pokyčius per tam tikrą laiką) ir prognozuoja būsimus pokyčius.

b) Sveikatos priežiūra

Sveikatos sektoriuje prognozavimo modeliai padeda numatyti pacientų sveikatos būklės pokyčius, ligos progresavimą ir netgi numatyti epidemijų protrūkius. DI gali analizuoti medicininius duomenis ir suteikti įžvalgas apie galimą ligos riziką.

Pavyzdys: Naudojant DI analizuoti paciento ligos istoriją ir prognozuoti galimą širdies smūgį ar kitą sveikatos būklės pablogėjimą.

c) Rinkodaros prognozės

DI taikomas rinkodaroje, siekiant prognozuoti vartotojų elgseną, pirkimo tendencijas ir rinkos pokyčius. DI modeliai analizuoja klientų elgseną, jų pirkimo istoriją ir socialinių tinklų duomenis, kad nuspėtų būsimus veiksmus.

Pavyzdys: E. komercijos platformos, naudojančios DI, kad numatytų, kurie produktai bus populiariausi artimiausiomis savaitėmis arba mėnesiais.

d) Klimato prognozės

Klimato prognozavimo srityje DI modeliai naudojami analizuoti orų duomenis, jūros temperatūros pokyčius, vėjo greitį ir kitas aplinkos sąlygas, kad būtų galima nuspėti ilgalaikius klimato pokyčius arba artimiausią orų prognozę.

Pavyzdys: Klimato modeliai, kurie numato globalinio atšilimo poveikį ar sezoninių klimato pokyčių tendencijas.

e) Pramonės priežiūros prognozavimas

Pramonės srityje DI naudojamas prognozuoti įrangos gedimus arba remonto poreikius. Remiantis surinktais duomenimis apie mašinos naudojimą ir veikimo sąlygas, galima numatyti, kada įranga gali sugesti ir išvengti netikėtų prastovų.

Pavyzdys: DI modeliai, naudojami gamyklose arba energetikos sektoriuje, siekiant prognozuoti įrangos gedimus, remiantis istorine veikimo informacija.

3. Technologijos ir algoritmai prognozavimui

a) Laiko eilučių analizė

Laiko eilučių analizė – tai metodas, naudojamas duomenims analizuoti, kurie kinta laike. Šie algoritmai analizuoja ankstesnių įvykių seką ir numato, kaip ji gali pasikeisti ateityje. Tai dažnai naudojama finansinėse prognozėse, pardavimų prognozavime ir orų prognozėse.

Pavyzdys: Laiko eilučių modeliai, kaip ARIMA ar Exponential Smoothing, naudojami prognozuoti akcijų kainas.

b) Dirbtiniai neuroniniai tinklai (DNT)

Neuroniniai tinklai, ypač rekurentiniai neuroniniai tinklai (RNN) ir ilgalaikės trumposios atminties (LSTM) modeliai, plačiai naudojami prognozavimui. Jie puikiai tinka sekos duomenų apdorojimui, nes gali apdoroti ilgalaikes priklausomybes ir atsiminti ankstesnius duomenis, svarbius prognozuojant ateitį.

Pavyzdys: LSTM naudojamas laiko sekos duomenų prognozavimui, pavyzdžiui, numatant elektros energijos paklausą arba vartotojų elgesį.

c) Giluminis mokymasis

Giluminis mokymasis naudojamas kompleksinių prognozavimo modelių kūrimui, kurie sugeba įsisavinti didžiulius duomenų kiekius ir nustatyti sudėtingas priklausomybes tarp duomenų. Šie modeliai gali būti naudojami įvairiose srityse, pradedant finansų prognozėmis ir baigiant medicininėmis prognozėmis.

Pavyzdys: Naudojant giluminius neuroninius tinklus siekiant prognozuoti pardavimų augimą didelėse kompanijose, remiantis ekonominiais rodikliais ir rinkos duomenimis.

d) Statistiniai modeliai

Be giliųjų mokymosi metodų, statistiniai metodai, tokie kaip regresijos analizė, taip pat yra plačiai naudojami prognozavimo modeliuose. Regresijos modeliai padeda nustatyti priklausomybes tarp kintamųjų ir numatyti ateities tendencijas remiantis šiais ryšiais.

Pavyzdys: Regresijos modeliai, naudojami prognozuoti nekilnojamojo turto kainas, remiantis ekonomikos rodikliais, vietos sąlygomis ir kitais veiksniais.

e) Mašininis mokymasis

Klasikiniai mašininio mokymosi algoritmai, tokie kaip XGBoost, Random Forests, taip pat naudojami prognozavimo užduotims spręsti. Šie algoritmai gerai veikia su struktūrizuotais duomenimis, kai reikia prognozuoti diskrečius ar tęstinius duomenis.

Pavyzdys: Mašininio mokymosi modeliai naudojami draudimo sektoriuje, siekiant numatyti draudžiamų įvykių tikimybę ir nustatyti draudimo įmokas.

4. **Praktiniai DI prognozavimo taikymai**

a) Prekybos prognozės (Sales forecasting)

Prekybos sektoriuje prognozavimas padeda numatyti būsimus pardavimus ir optimizuoti atsargas. DI analizuoja istorinius pardavimų duomenis, sezoniškumą ir rinkos sąlygas, kad prognozuotų paklausą.

Pavyzdys: E. prekybos įmonės, kurios naudoja DI prognozavimui, siekdamos tiksliau valdyti atsargas ir užtikrinti, kad reikalingi produktai būtų pasiekiami, kai yra didžiausias poreikis.

b) Energetikos prognozavimas

Energetikos sektoriuje prognozavimo modeliai padeda numatyti energijos paklausą, remiantis istorine

Pažangios naujovės

Dirbtinio intelekto (DI) srityje pastaruoju metu pasirodė daugybė pažangių naujovių, kurios apima tiek techninius algoritmus, tiek naujas pritaikymo galimybes. Štai keletas naujausių DI technologijų tendencijų ir išradimų:

1. **Generatyvūs DI modeliai (angl. Generative AI)**

GPT-4 ir multimodaliniai modeliai: Šiuolaikiniai DI modeliai, tokie kaip GPT-4, apdoroja ir kuria turinį keliuose formatuose – tekstą, vaizdus ir net garsą. Tokie modeliai darosi vis populiareni dėl gebėjimo vienu metu naudoti skirtingų tipų duomenis.

Stabilios difuzijos ir DALL-E vaizdų generavimo modeliai: Šie modeliai sugeba generuoti itin aukštos kokybės vaizdus pagal pateiktą tekstą, todėl sparčiai naudojami reklamos, meno kūrybinių, dizaino bei kūrybinių industrijų srityse.

2. **Pažangūs natūralios kalbos apdorojimo (NLP) modeliai**

DialGPT ir pažangios chatbot sistemos: Šiuolaikiniai pokalbių botai, sukurti naudojant GPT ar kitus pažangius NLP modelius, geba atlikti sudėtingus pokalbius bei pritaikyti informaciją pagal vartotojo poreikius. Šie botai dabar naudojami klientų aptarnavimui, švietimui ir kitose srityse.

Automatinis vertimas ir kalbos atpažinimas: Pažangūs kalbos atpažinimo modeliai, tokie kaip Whisper ir kitų didelių kompanijų vertimo sistemos, siūlo itin tiksliai realaus laiko vertimo paslaugas.

3. Sustiprinta realybė (AR) ir virtuali realybė (VR) su DI integracija

XR (Extended Reality): Šios sistemos pritaiko DI, kad būtų galima sukurti pažangias AR ir VR patirtis. Pavyzdžiui, „Meta“ naudoja DI įrankius, kurie leidžia patirti virtualius susitikimus su itin realistiškais personažais.

3D objektų generavimas ir manipuliacija: DI modeliai, tokie kaip NeRF (Neural Radiance Fields), sukuria itin realistiškus 3D objektus ir scenas, kuriuos galima naudoti animacijoje, filme ir VR aplinkose.

4. Mašininis mokymasis su minimaliu duomenų kiekiu (angl. Few-shot ir zero-shot learning)

Naujosios „Few-shot“ ir „Zero-shot“ mokymosi technologijos leidžia DI sistemoms suprasti ir mokytis iš minimalaus duomenų kiekio. Tai itin svarbu verslams, kurie turi ribotus duomenų kiekius ar nori kurti modelius specializuotoms užduotims.

5. Savarankiškai mokančios mašinos ir sustiprintas mokymasis (angl. Reinforcement Learning)

AlphaFold ir AlphaZero algoritmai: Šie DI modeliai pritaikomi tiek medicinoje, tiek žaidimuose.

AlphaFold, pavyzdžiui, padeda modeliuoti baltymų struktūras ir numatyti jų elgesį, kas yra itin svarbu medicinos tyrimams.

Autonominės sistemos ir robotika: Sustiprintas mokymasis naudojamas autonominiuose robotuose ir transporto priemonėse, kurie geba priimti sprendimus be žmogaus įsikišimo.

6. Etinis DI ir skaidrumo užtikrinimas

Atsakingas DI ir „Explainable AI“ (XAI): Kadangi DI sprendimai darosi vis labiau integruoti į kasdienį gyvenimą, svarbu suprasti jų veikimą ir užtikrinti, kad jie būtų etiški. Atsiranda vis daugiau įrankių, kurie padeda paaiškinti DI sprendimus, padidinti skaidrumą ir atitikti etikos reikalavimus.

DI technologijos sparčiai evoliucionuoja ir tampa nepakeičiama įvairiose srityse, todėl galima tikėtis, kad artimiausiu metu atsiras dar daugiau inovacijų ir naujų pritaikymų.

Sentimentų analizė

Sentimentų analizė – tai natūralios kalbos apdorojimo (NLP) užduotis, kurios tikslas yra nustatyti tekstinio turinio emocinį toną. Ji dažniausiai naudojama siekiant automatiškai atpažinti, ar tekstas išreiškia teigiamą, neigiamą ar neutralią nuomonę.

Kaip veikia sentimentų analizė:

1. **Duomenų surinkimas:** Tai gali būti socialinių tinklų įrašai, atsiliepimai, komentarai, naujienų straipsniai ir kt.
2. **Teksto apdorojimas:** Apima žodžių normalizavimą (mažosios raidės, skyrybos ženklų šalinimas), lematizavimą, stemmingą ir dažnai žodžių vektorizavimą (pvz., naudojant „Bag of Words“, „TF-IDF“ ar „Word Embeddings“).
3. **Modelio kūrimas:** Naudojami klasifikavimo algoritmai ar neuroniniai tinklai:
 - ✓ **Paprasti metodai:** Logistinė regresija, Naivusis Bajesas.
 - ✓ **Sudėtingesni metodai:** LSTM, GRU, CNN.
4. **Sentimentų priskyrimas:** Modelis prognozuoja, ar tekstas yra teigiamas, neigiamas ar neutralus.

Praktinis pritaikymas:

- **Klientų atsiliepimų analizė:** Suprasti, kaip vartotojai vertina produktus ar paslaugas.
- **Socialinių tinklų stebėseną:** Nustatyti viešąją nuomonę apie prekių ženklą ar aktualijas.
- **Nuotaikų analizė:** Vertinti naujienų ar straipsnių emocinį toną.
- **Filmų, knygų ar prekių apžvalgų klasifikavimas.**

Lematizavimas – tai natūralios kalbos apdorojimo (NLP) technika, kurios tikslas – transformuoti žodį į jo **žodyninę (pirminę) formą**, vadinamą **lema**. Skirtingai nuo „stemmingo“ (kamienavimo), kuris tiesiog pašalina žodžio galūnes, lematizavimas atsižvelgia į **žodžio reikšmę ir gramatiką**, todėl

grąžina **gramatiškai taisyklingą formą**. **Žodžių vektorizavimas** – tai procesas, kai žodžiai paverčiami į **skaitmenines reikšmes**, kurios atspindi jų semantinę prasmę ir kontekstą. Šis procesas yra esminė dalis natūralios kalbos apdorojimo (NLP) užduočių, nes kompiuteriai negali tiesiogiai apdoroti tekstų, tačiau jie gali efektyviai apdoroti skaitmenines reikšmes.

Dirbtinio intelekto (DI) naudojimo etika, teisiniai ir socialiniai principai

Dirbtinio intelekto (DI) naudojimo etika, teisiniai ir socialiniai principai yra svarbūs klausimai, kylantys kartu su technologijų plėtra. DI gali turėti tiek teigiamą, tiek neigiamą poveikį visuomenei, todėl būtina užtikrinti, kad jo naudojimas būtų atsakingas, saugus ir naudingas visiems. Pateikiu pagrindinius **etikos, teisinės ir socialinės atsakomybės principus**, kurie turi būti atsižvelgiami kuriant ir diegiant DI sistemas.

1. Etikos principai dirbtinio intelekto srityje

a) Skaidrumas (Transparency):

- **Kiekvienas DI sprendimas turi būti aiškiai suprantamas.** Tai reiškia, kad DI sistemų veikimo principai turi būti skaidrūs ir paaiškinami tiek vartotojams, tiek suinteresuotoms šalims.
- **Algoritmų ir modelių interpretavimas:** Pavyzdžiui, svarbu, kad būtų galima paaiškinti, kaip DI pasiekė tam tikrą sprendimą ar prognozę (ypač kai sprendimai gali turėti didelį poveikį, pvz., kredito skyrimas ar darbo vietos suteikimas).

b) Teisingumas (Fairness):

- **DI turi būti be šališkumo (bias).** Algoritmai turi užtikrinti, kad jie neveiktų diskriminuojančiai pagal rasę, lytį, amžių, seksualinę orientaciją, religiją ar kitus asmeninius bruožus.
- **Socialinė įtaka:** DI sistemų turėtų būti naudojama taip, kad jos nepadidintų socialinės nelygybės ar neteisybės, ypač darbo rinkoje, sveikatos priežiūros srityje, švietime ir kitose jautriose srityse.

c) Atsakomybė (Accountability):

- **Kas turi atsakyti už DI sprendimus?** Jei DI sistema priima klaidingą ar žalingą sprendimą (pavyzdžiui, klaidingai diagnozuoja ligą), turėtų būti aišku, kas yra atsakingas už šį sprendimą – ar tai kūrėjai, įmonės, ar patys vartotojai.
- **Paskirstymas:** DI kūrėjai ir organizacijos turėtų užtikrinti, kad jie prisiima atsakomybę už tai, kaip jų sukurti algoritmai elgiasi praktikoje.

d) Privatumas (Privacy):

- **Duomenų apsauga ir vartotojo privatumas:** DI sistemos dažnai apdoroja didelius duomenų kiekius, todėl svarbu užtikrinti, kad būtų laikomasi **duomenų apsaugos teisės akto ir privatumo taisyklių**, pvz., Europos **GDPR**.
- **Anonimiškumas ir duomenų saugumas:** Svarbu užtikrinti, kad vartotojų asmens duomenys būtų saugomi ir tvarkomi atsakingai, taip pat kad vartotojai turėtų teisę kontroliuoti, kokius duomenis jie dalijasi.

e) Žmogaus kontrolė (Human Control):

- **Pagrindinis principas – žmogus turi galimybę kontroliuoti DI sistemos veikimą.** DI neturi pakeisti žmogaus sprendimų galios, ypač jautriuose kontekstuose, pvz., teisinėje sistemoje, medicinoje ar karinėse operacijose.

2. Teisiniai principai ir reguliavimas

a) Teisinis atsakomybės klausimas:

- **Teisinė atsakomybė už DI sistemas** yra sudėtinga, nes klausimai apie tai, kas atsako už klaidingus ar žalingus sprendimus (programuotojai, įmonės, DI sistemos kūrėjai), vis dar nėra visiškai išspręsti.

- **Atitiktis įstatymams:** DI turi atitikti nacionalinius ir tarptautinius teisės aktus, kurie reglamentuoja asmens duomenų apsaugą, lygybę, žmogaus teises ir saugumą.

b) Patikimumas ir saugumas:

- DI sistemos turi būti patikimos ir saugios. Kiekviena technologija, naudojama svarbioms užduotims (pvz., automobilių vairavimui, medicininėms diagnozėms), turi būti sukurta laikantis aukščiausių saugumo standartų.
- **Sistemos turi būti atsparios manipuliacijoms ir kibernetinėms atakoms,** užtikrinant, kad jos nebus pažeistos ir negalės priimti žalingų sprendimų.

c) Tarptautystiniai reguliavimai:

- **Tarptautinis bendradarbiavimas:** Kadangi DI technologijos yra globalios, reikalingas tarptautinis bendradarbiavimas kuriant bendras taisykles ir standartus. Pavyzdžiui, Europos Sąjunga ir JAV pradėjo kurti skirtingus teisės aktus, kad reglamentuotų DI technologijų naudojimą ir užtikrintų teisinę atsakomybę.

3. Socialiniai principai

a) Darbo vietos ir užimtumas:

- **Automatizacija ir darbo rinkos pokyčiai:** DI gali automatiškai atlikti daugelį užduočių, tačiau tai gali sukelti darbo vietų praradimą kai kuriuose sektoriuose (pvz., gamyboje, logistikos sektoriuje). Svarbu užtikrinti, kad per šiuos pokyčius neatsirasų pernelyg didelė socialinė nelygybė.
- **Darbo vietų kūrimas ir persikvalifikavimas:** Svarbu skatinti švietimą ir persikvalifikavimą, kad žmonės galėtų prisitaikyti prie naujų darbo rinkos reikalavimų.

b) Skaitmeninė nelygybė:

- **Skaitmeninė atskirtis:** Ne visi žmonės turi vienodą prieigą prie DI technologijų. Tai gali padidinti nelygybę tarp regionų, šalių ir socialinių grupių. Svarbu, kad DI plėtra nebūtų tik turtingųjų šalių naudai, ir kad mažiau išsivysčiusios šalys galėtų pasinaudoti šiais pokyčiais.

c) Žmogaus teisės ir demokratija:

- **DI ir žmogaus teisės:** DI turėtų būti naudojamas taip, kad nepakenktų žmogaus teisėms, įskaitant laisvę, privatų gyvenimą ir teisę į informaciją.
- **Demokratijos išlaikymas:** DI neturėtų būti naudojamas manipuliuoti viešąja nuomone ar įtakoti politinių procesų (pvz., per manipuliavimą rinkimais ar dezinformacijos platinimą).

d) Kognityviniai ir psichologiniai padariniai:

- **Įtakos žmogaus elgsenai:** DI gali turėti įtakos žmogaus elgsenai ir socialiniams santykiams, todėl reikia įvertinti, kaip technologijos gali formuoti žmonių elgesį ir socialinius ryšius. Pavyzdžiui, per daug priklausomybė nuo automatizuotų sistemų gali sumažinti žmonių savarankiškumą ir sprendimų priėmimo gebėjimus.

4. DI etiką ir teisinį reguliavimą įgyvendinant

- **Kūrybinės ir edukacinės iniciatyvos:** Svarbu skatinti mokslininkus, inžinierius ir politikus bendradarbiauti kuriant etikos ir teisės aktų gaires. Tai apima ir skirtingų DI kūrimo sričių, tokių kaip kalbos modeliai, kompiuterinis regėjimas, autonominės sistemos ir kt., standartizavimą.
- **Iniciatyvos ir organizacijos:** Tokios organizacijos kaip **AI Now Institute**, **OpenAI**, **Partnership on AI** ir kt. atlieka svarbų vaidmenį kuriant etikos ir socialinės atsakomybės gaires, kad DI technologijos būtų naudojamos atsakingai.

Išvados:

Dirbtinio intelekto etika, teisė ir socialinė atsakomybė yra esminiai klausimai, kurie turi būti svarstomi kuriant ir taikant šias technologijas. Atsakingas ir etiškas DI naudojimas užtikrins, kad šios technologijos būtų naudingos visuomenei, skatinant teisingumą, skaidrumą ir žmogaus teisių apsaugą.

Europos Sąjunga (ES) ir Lietuva įsipareigojo kurti ir įgyvendinti teisės aktus, kurie reglamentuoja **dirbtinio intelekto (DI) naudojimą** įvairiose srityse, įskaitant **švietimą** ir **meną**. Šie teisės aktai siekia užtikrinti technologijų naudojimą atsakingai ir etiškai, taip pat apsaugoti asmens teises ir skatinti inovacijas. Štai pagrindiniai teisės aktai, reglamentuojantys DI naudojimą šiose srityse:

1. Europos Sąjunga (ES)

a) *Europos Komisijos Baltoji Knyga dėl Dirbtinio Intelektu (2020)*

- **Pagrindinė nuostata:** Baltasis Knyga, paskelbta 2020 m., išdėsto ES strategiją ir teisinius pagrindus, kaip reglamentuoti **dirbtinį intelektą**. Tai apima **etinius principus, saugumo standartus** ir **reguliavimo priemones**, taikomas DI technologijų vystymui ir naudojimui.
- **Taikymas švietime ir mene:** DI naudojimas švietime ir mene yra iš esmės susijęs su šios strategijos principais – užtikrinti, kad DI būtų naudojamas etiškai ir skaidriai, ypač kai kalbama apie **privatumo apsaugą ir naudotojo teisę į informaciją**. Tai ypač svarbu švietimo priemonėse, kur asmens duomenų apsauga ir jų panaudojimas turi būti griežtai reglamentuojami.

b) *Dirbtinio Intelektu reguliavimo pasiūlymas (2021)*

- **Pagrindinė nuostata:** Tai pirmasis pasaulyje teisės aktas, skirtas reglamentuoti DI technologijas, ir jis siūlo **teisinę struktūrą**, kaip užtikrinti **saugų ir atsakingą DI naudojimą**. Šis pasiūlymas įveda **skirtingas DI rizikos kategorijas** ir reglamentuoja, kokios sritys, įskaitant švietimą ir kūrybą, reikalauja aukštesnių saugumo ir skaidrumo standartų.
- **Taikymas švietime ir mene:** DI naudojimas šiose srityse turėtų būti reglamentuojamas atsižvelgiant į **aukštą riziką**, pavyzdžiui, kuriant personalizuotas švietimo priemones, rekomendacijas ar įrankius, skirtus meno kūrinį kūrimui. Tai užtikrins, kad asmens duomenys būtų naudojami atsakingai, ir kad DI sprendimai būtų paaiškinami bei kontroliuojami.

c) *ES Bendrasis Duomenų Apsaugos Reglamentas (GDPR)*

- **Pagrindinė nuostata:** **GDPR** (2018 m.) reglamentuoja, kaip gali būti renkami, saugomi ir naudojami asmens duomenys, įskaitant duomenis, naudojamus mokymosi ir kūrybos procese.
- **Taikymas švietime ir mene:** Naudojant DI švietimo srityje (pvz., personalizuotą mokymąsi) ir mene (pvz., generuojant meno kūrinius), svarbu, kad būtų laikomasi asmens duomenų apsaugos nuostatų. Tai apima **sutikimą** dėl duomenų naudojimo, **duomenų subjekto teises**, kaip teisę būti pamirštam, ir duomenų apsaugos priemones.

d) *Europos Parlamentas ir Taryba: Diapazonas ir Dėmesys Etikai (2021)*

- **Pagrindinė nuostata:** 2021 m. ES taip pat pristatė naujas rekomendacijas dėl DI etikos ir žmogaus teisių apsaugos, ypatingą dėmesį skiriant **nuoširdumui, teisingumui** ir **žmogaus kontrolės išlaikymui**. Šie principai yra svarbūs tiek švietimo technologijose, tiek meno kūrybos srityje, kur DI gali keisti kūrybos procesą ir sąveiką su kūrėjais.

2. Lietuvos teisės aktai

a) *Lietuvos Respublikos asmens duomenų apsaugos įstatymas*

- **Pagrindinė nuostata:** Šis įstatymas, kuris yra suderintas su **GDPR**, reglamentuoja asmens duomenų tvarkymą Lietuvoje. Tai apima ir švietimo sektorių, kur **mokinių duomenys** gali būti naudojami dirbtinio intelekto sistemose, kaip ir meno kūrinių kūrimo procesas, kai kuriuos duomenis reikia rinkti ir analizuoti.
- **Taikymas švietime ir mene:** Reikalingas specialus dėmesys **duomenų apsaugai**, kai DI naudojamas asmens ar kūrybos duomenims, pavyzdžiui, generuojant personalizuotas švietimo programas ar kuriančius meno kūrinius, pagrįstus asmens stiliumi.

b) *Nacionalinė švietimo informacinių technologijų plėtros strategija*

- **Pagrindinė nuostata:** Lietuvoje 2014–2020 m. buvo įgyvendinama **Nacionalinė švietimo informacinių technologijų plėtros strategija**, kuri skatino **informacinių ir komunikacinių technologijų (IKT) integraciją** į švietimo procesą. Nors ši strategija tiesiogiai nereglamentuoja

DI, ji siekia įgalinti **skaitmeninius mokymosi įrankius** ir technologijas, įskaitant **dirbtinį intelektą**, siekiant padėti mokytojams ir mokiniams pasiekti geresnių rezultatų.

c) Lietuvos autorių teisių ir gretutinių teisių įstatymas

- **Pagrindinė nuostata:** Šis įstatymas reglamentuoja **autorių teises**, įskaitant kūrybos procesą, kai DI naudojamas kurti menui. Tai apima ir klausimus, susijusius su **kūrybos autorystės, nuosavybės ir teisių į kūrinius** apsauga, kai meno kūriniai generuojami naudojant DI.
- **Taikymas mene:** DI naudojimas mene gali kelti klausimų dėl to, kam priklauso DI sukurtas kūrinys – ar žmogui, kuris sukūrė algoritmą, ar dirbtiniam intelektui, kuris sukūrė meno kūrinį.

d) Lietuvos Respublikos švietimo įstatymas

- **Pagrindinė nuostata:** Švietimo įstatymas apibrėžia **švietimo procesus** Lietuvoje, tačiau DI čia dar nėra tiesiogiai reglamentuotas. Visgi, švietimo srityje naudojami **inovatyvūs technologiniai sprendimai** gali būti pritaikomi remiantis šio įstatymo principais, pavyzdžiui, skatinti **mokymosi individualizavimą**, naudojant **DI sistemas**.
- **Taikymas švietime:** Švietimo įstatymas turi būti papildytas specifiniais teisės aktais, kurie reglamentuoja DI technologijų naudojimą švietimo procese, užtikrinant, kad būtų išlaikytas teisingumas, privatumas ir lygios galimybės visiems mokiniams.

Išvados

Europos Sąjungoje ir Lietuvoje pagrindiniai teisės aktai, reglamentuojantys dirbtinio intelekto naudojimą švietime ir mene, yra susiję su **asmenų duomenų apsauga, etika, saugumu ir autorių teisėmis**. ES iniciatyvos, tokios kaip Baltoji Knyga, GDPR ir DI reguliavimo pasiūlymas, nustato aukštus standartus dėl šių technologijų naudojimo atsakingai. Lietuva, remdamasi ES teisės aktais, taip pat stiprina šių technologijų naudojimą švietime ir mene, tačiau dar reikia daugiau aiškių teisės aktų, kurie reglamentuotų DI pritaikymą šiose srityse.

Naudojimo privalumai ir grėsmės

Dirbtinio intelekto (DI) naudojimo privalumai ir grėsmės yra svarbūs klausimai, kuriuos reikia atidžiai apsvaistinti, kad DI technologijos būtų naudojamos atsakingai ir naudingai visuomenei. Nors DI turi didelį potencialą pagerinti daugelį gyvenimo sričių, jis taip pat gali sukelti rimtų iššūkių, jei jis bus netinkamai valdomas.

Privalumai

1. **Efektyvumo didinimas:**
 - DI gali žymiai pagerinti darbo našumą ir sumažinti laiką, reikalingą užduotims atlikti. Pavyzdžiui, **automatizuotos sistemos** gali atlikti pasikartojančias ir sudėtingas užduotis daug greičiau ir tiksliau nei žmonės.
 - Pavyzdys: **pramonės robotai** arba **automatizuotos gamybos linijos** padeda užtikrinti spartesnę ir kokybiškesnę gamybos procesą.
2. **Asmeniniai sprendimai ir paslaugos:**
 - DI gali sukurti **personalizuotas paslaugas ir produktus**, kurie atitinka individualius vartotojų poreikius, tokius kaip rekomendacijos vaizdo įrašų platformose (pvz., **YouTube, Netflix**) arba **personalizuotas mokymosi platformas**.
 - Pavyzdys: **e-komercija** naudoja DI algoritmus, kad pasiūlytų produktus pagal vartotojo ankstesnę elgesį ir pirkinio įpročius.
3. **Tikslesnė analizė ir prognozės:**
 - DI technologijos, ypač **mašininis mokymasis**, leidžia atlikti galias duomenų analizes ir daryti tiksliausias prognozes. Tai gali būti naudinga tiek versle, tiek mokslo srityse, pavyzdžiui, prognozuojant rinkos tendencijas, optimizuojant tiekimo grandines, diagnostikuojant ligas ar net įspėjant apie gamtos stichijas.

- Pavyzdys: **medicinos DI sistemos** gali padėti gydytojams tiksliai diagnozuoti ligas, analizuojant paciento istoriją ir tyrimų duomenis.
4. **Saugumas ir prevencija:**
 - DI naudojimas gali pagerinti saugumą tiek viešajame, tiek privačiame sektoriuje. Pavyzdžiui, **autonominės transporto priemonės** gali sumažinti eismo įvykių skaičių, nes DI gali greičiau reaguoti į pavojų nei žmogus.
 - Pavyzdys: **stebėjimo sistemos** naudoja DI, kad atpažintų įtartinus veiksmus ir įspėtų apie galimas grėsmes, tokiu būdu gerinant saugumą.
 5. **Inovacijos ir naujos galimybės:**
 - DI gali atverti naujas galimybes inovacijoms, kuriant naujus produktus ir paslaugas. **Automatizuota kūryba**, pavyzdžiui, meno, muzikos ar rašymo srityse, atveria naujas kūrybinio proceso galimybes ir leidžia žmonėms atlikti užduotis, kurios anksčiau buvo neįsivaizduojamos.
 - Pavyzdys: **DI generuoti menai**, tokie kaip muzika ar vaizdai, gali padėti menininkams sukurti unikalius kūrinius ir eksperimentuoti su naujomis formomis.

Grėsmės

1. **Priklausomybė ir darbo vietų praradimas:**
 - DI technologijų plėtra gali lemti didelį darbo vietų praradimą, ypač pramonės ir paslaugų sektoriuose, kur automatizacija pakeičia žmogaus darbą. Tai gali padidinti socialinę nelygybę ir sukurti ekonominių sunkumų tiems, kurie praranda darbo vietas.
 - Pavyzdys: **automobilių gamyba**, kur daug darbo vietų buvo pakeistos robotais, arba **logistikos sektorius**, kuriame DI naudojama prekių pervežimui be žmogaus įsikišimo.
2. **Šališkumas ir diskriminacija:**
 - DI sistemos, ypač **mašininio mokymosi algoritmai**, gali būti šališki, jei jos apdoroja šališkus arba neteisingus duomenis. Tai gali lemti **diskriminaciją** pagal rasę, lytį, amžių, religiją ir kitus veiksnius.
 - Pavyzdys: **kreditų skyrimo algoritmai**, kurie remiasi istoriniais duomenimis, gali atsirasti diskriminuojantys, jei praeityje buvo šališkos praktikos, pvz., kai nebuvo teikiama pakankamai paskolų tam tikroms socialinėms grupėms.
3. **Privatumo pažeidimai ir duomenų apsauga:**
 - DI sistemos dažnai naudoja didelius duomenų kiekius, kurie gali apimti jautrią asmeninę informaciją. Jei šie duomenys nėra tinkamai apsaugoti, gali įvykti **duomenų pažeidimai** arba **netinkamas duomenų naudojimas**.
 - Pavyzdys: **socialinių tinklų platformos** gali rinkti ir analizuoti vartotojų elgesį, nesant visiškam vartotojų sutikimui, kas kelia rimtų privatumo klausimų.
4. **Neetiškas naudojimas ir manipuliacija:**
 - DI gali būti naudojamas **neetiškoms** ar **manipuliacijoms** praktikos, tokioms kaip **deepfake technologijos** arba **automatizuota propaganda**, kurios gali sukelti socialinių, politinių ar ekonominių problemų.
 - Pavyzdys: **politinių kampanijų** metu naudojama DI manipuliuoti rinkėjų nuomonėmis ar skleisti melagingą informaciją.
5. **Kontrolės praradimas ir autonomija:**
 - Aukštesnio lygio **autonominės sistemos**, tokios kaip **savišalės ginkluotės**, gali sukelti rimtų grėsmių, jei žmogaus kontrolė bus prarasta. Pavyzdžiui, **karinėse srityse**, kur DI gali valdyti ginkluotę ar robotus, nesant žmogaus priežiūros, gali kilti pavojus dėl klaidingų sprendimų ar nekontroliuojamų veiksmų.
 - Pavyzdys: **autonominės karo mašinos**, kurios gali priimti sprendimus be žmogaus įsikišimo, gali kelti rimtų etinių ir saugumo problemų.

6. Kognityvinis ir socialinis poveikis:

- Ilgalaikis DI naudojimas gali turėti **neigiamą poveikį žmogaus gebėjimams**, sumažinant žmonių sprendimų priėmimo įgūdžius ir kūrybiškumą. Be to, per didelis priklausomumas nuo DI gali paveikti **socialinius santykius** ir bendravimą, nes žmonės pradeda labiau bendrauti su technologijomis nei su kitais žmonėmis.
- Pavyzdys: **skaitmeninės asistentės** ir **robotai**, kurie padeda atlikti kasdienes darbus, gali sumažinti žmogaus įsitraukimą į socialinius procesus.

Dirbtinis intelektas turi tiek didžiulį potencialą, tiek ir grėsmes, todėl jo naudojimas turi būti labai atsargus ir atidžiai stebimas. **Privalumai**, tokie kaip efektyvumas, personalizacija ir inovacijos, gali žymiai pagerinti gyvenimo kokybę, tačiau **grėsmės**, tokios kaip darbo vietų praradimas, šališkumas, privatumo pažeidimai ir manipuliacijos, kelia didelius etinius, socialinius ir teisės iššūkius. Norint pasiekti maksimalią naudą ir sumažinti riziką, būtina sukurti aiškius reglamentus, skatinti skaidrumą ir užtikrinti, kad DI technologijos būtų naudojamos etiškai ir atsakingai.

Sudėtingesni dirbtinio intelekto taikymo pavyzdžiai

Daiktų internetas (IoT – Internet of Things) – tai technologinė sistema, kurioje įvairūs įrenginiai (daiktai), tokie kaip **jutikliai, prietaisai ir aparatai**, yra prijungti prie interneto ir gali keistis duomenimis tarpusavyje. Šie įrenginiai turi gebėjimą **surinkti, apdoroti ir perduoti informaciją** į kitus įrenginius ar sistemas be tiesioginio žmogaus įsikišimo.

Pagrindinės savybės ir komponentai:

1. **Jutikliai ir įrenginiai** – pagrindinis IoT komponentas yra įrenginiai, kurie gali matuoti fizines savybes, pavyzdžiui, temperatūrą, drėgmę, judėjimą ar garso lygį. Tai gali būti **šilumos ir slėgio jutikliai, išmanieji laikrodžiai, namų automatikos įrenginiai** (pvz., termostatai) ir kt.
2. **Duomenų perdavimas** – IoT įrenginiai naudoja įvairias **ryšių technologijas** (Wi-Fi, Bluetooth, Zigbee, LoRa, 5G ir kt.) norėdami perduoti surinktus duomenis į centrinę sistemą arba kitus įrenginius.
3. **Duomenų apdorojimas** – surinkti duomenys dažnai yra apdorojami vietoje (per **edge computing**) arba siunčiami į **debesiją** (cloud computing), kur jie analizuojami ir naudojami priimančioms sprendimams.
4. **Veiksmų vykdymas** – remiantis apdorotais duomenimis, IoT įrenginiai gali atlikti tam tikras veiklas, pvz., **pradėti šildytuvą, sumažinti apšvietimą** arba **siųsti įspėjimą vartotojui** apie problemą.

IoT privalumai:

1. **Efektyvumas ir patogumas:**
 - **Automatizavimas** leidžia sumažinti žmogaus įsikišimo poreikį kasdienėse užduotyse, pavyzdžiui, **išmanieji namai** automatiškai reguliuoja apšvietimą, temperatūrą ir saugumą.
 - **Įmonėms** tai leidžia optimizuoti **procesus**, pvz., sekti atsargų kiekį, stebėti gamybos procesus ir užtikrinti produktų kokybę be nuolatinio darbuotojų įsikišimo.
2. **Nuolatinis stebėjimas ir analizė:**
 - IoT leidžia **realiojo laiko stebėjimą**. Pavyzdžiui, **išmanūs miestai** gali stebėti oro kokybę, eismo srautą ir kitas miesto funkcijas, optimizuodami išteklių naudojimą ir sprendimų priėmimą.
3. **Naudojimo pritaikymas sveikatos apsaugai:**
 - **Išmanieji medicinos prietaisai**, kaip **širdies ritmo monitoriai** ar **cukraus kiekio kraujyje matuokliai**, leidžia nuolat sekti paciento būklę ir iš karto perduoti informaciją gydytojui arba šeimos nariams.

4. Aplinkosaugos sprendimai:

- IoT įrenginiai gali padėti stebėti ir mažinti **energijos suvartojimą** (pvz., išmaniosios elektros skaitikliai) ir **vandenį**, taip prisidedant prie aplinkosaugos tikslų.

Grėsmės ir iššūkiai:

1. Privatumo ir saugumo problemos:

- IoT įrenginiai renka daug jautrios asmeninės informacijos (pvz., sveikatos duomenys, kasdieniai įpročiai), todėl labai svarbu užtikrinti, kad duomenys būtų apsaugoti nuo **įsilaužimų ir neteisėto naudojimo**.
- **Kibernetinis saugumas** yra vienas didžiausių iššūkių IoT pasaulyje, nes daugelis prietaisų nėra tinkamai apsaugoti.

2. Didelės duomenų apimtys ir jų apdorojimas:

- IoT įrenginiai generuoja **milžinišką duomenų kiekį**, o tai kelia iššūkių dėl jų **analizės ir saugojimo**. Nors **debesų kompiuterija** leidžia efektyviai saugoti ir apdoroti duomenis, didelis duomenų kiekis gali užtrukti apdorojimui ir reikalauti didelių išteklių.

3. Kompatibilumo ir standartų stoka:

- Skirtingi gamintojai kuria savo IoT įrenginius, kurie gali nesuderinti su kitų gamintojų produktais. Tai sukelia problemų dėl **kompatibilumo ir integracijos** tarp skirtingų sistemų.

4. Poveikis darbo rinkai:

- Automatizacija, kurią sukuria IoT technologijos, gali paveikti darbo rinką, nes įrenginiai gali atlikti užduotis, kurias anksčiau atlikdavo žmonės, todėl gali sumažėti tam tikrų profesijų paklausa.

5. Etiniai klausimai:

- **Nuolatinis stebėjimas** ir duomenų rinkimas gali kelti **etikos** klausimų, susijusių su žmonių kontrolės praradimu ir asmens laisvių apribojimu.

Pavyzdžiai IoT taikymo srityse:

1. Išmanieji namai:

- **Išmanūs termostatai** (pvz., **Nest**) gali automatiškai reguliuoti temperatūrą pagal gyventojų gyvenimo būdą, todėl taupoma energija ir užtikrinamas komfortas.
- **Išmanieji užraktai ir kamera stebėjimo sistemos** užtikrina namų saugumą.

2. Sveikatos apsauga:

- **Išmanieji laikrodžiai** (pvz., **Apple Watch**) stebi širdies ritmą, fizinį aktyvumą ir siunčia perspėjimus apie galimas sveikatos problemas.
- **Išmanieji gydymo prietaisai** gali stebėti pacientų būklę ir siųsti duomenis gydytojui.

3. Pramonė ir gamyba:

- **Pramoniniai IoT jutikliai** padeda stebėti įrangos būklę ir užtikrina, kad gamyba vyktų efektyviai, mažinant gedimų ir prastovų riziką.
- **Intelligentiškos gamybos linijos** gali reaguoti į realaus laiko duomenis ir optimizuoti gamybos procesą.

4. Žemės ūkis:

- **Išmanieji drėkinimo sistemos** gali sekti dirvožemio drėgmės lygį ir automatizuotai reguliuoti vandens tiekimą, taip padidinant derlių ir taupant išteklius.

Išvados

Daiktų internetas (IoT) yra technologija, kuri turi didžiulį potencialą pagerinti kasdienį gyvenimą, įmonių veiklą ir net visuomenės veiklą. Nuo **išmaniųjų namų iki sveikatos apsaugos ir pramonės automatizavimo**, IoT gali ženkliai padidinti efektyvumą ir patogumą. Tačiau šios technologijos plėtra kelia rimtų iššūkių, tokių kaip **privatumo užtikrinimas, kibernetinis saugumas, kompatibilumas** ir

duomenų apdorojimo problemas. Svarbu, kad ateityje būtų kuriami aiškūs reglamentai ir standartai, užtikrinantys atsakingą ir saugų IoT naudojimą.

Autentifikavimo ir identifikavimo sistemos

Autentifikavimo ir identifikavimo sistemos yra svarbios technologijos, kurios užtikrina saugumą, patikrinant asmens tapatybę prieš leidžiant jam prieiti prie tam tikrų resursų arba paslaugų. Šios sistemos naudojamos tiek fiziniame pasaulyje (pvz., patikrinant asmens tapatybę dokumentuose), tiek ir skaitmeninėse sistemose, pvz., prisijungiant prie internetinių paslaugų ar naudojant išmaniuosius įrenginius.

1. Identifikavimas:

Identifikavimas – tai procesas, kurio metu sistema nustato, **kas** yra asmuo, dažniausiai pagal unikalius duomenis ar savybes. Tai pirmas žingsnis prieš autentifikavimą.

Pavyzdžiai:

- **Naudotojo vardas** (username) – dažniausiai naudojamas pirmas žingsnis, kad sistema galėtų „atpažinti“ vartotoją.
- **Biometriniai duomenys** – pvz., veido atpažinimas ar pirštų atspaudai gali būti naudojami, kad būtų identifikuojama asmens fizinė savybė.
- **QR kodai** – kai naudojamas skaitmeninis identifikavimas per specialius kodus, kurie atpažįsta vartotoją.

2. Autentifikavimas:

Autentifikavimas – tai procesas, kurio metu patikrinama, ar asmuo, kuris bandė prisijungti (arba buvo identifikkuotas), tikrai yra tas, už kurį save laiko. Tai gali būti atlikta įvairiais būdais.

Autentifikavimo metodai:

1. **Kas žino? (Žinojimo pagrindu)** – šis metodas remiasi informacija, kurią tik tikras vartotojas turėtų žinoti.
 - **Slaptažodis** (password): Tai dažniausiai naudojamas autentifikavimo metodas, kai vartotojas turi įvesti slaptažodį, kad prisijungtų prie sistemos.
 - **Pin kodas**: Panašiai kaip slaptažodis, tačiau dažniausiai trumpesnis (pvz., 4–6 skaitmenys).
2. **Kas turi? (Turėjimo pagrindu)** – remiasi fizinių įrenginių ar kortelių, kuriuos asmuo turi, naudojimu.
 - **Išmanieji įrenginiai** (pvz., mobilūs telefonai arba išmanieji laikrodžiai): naudodami šiuos įrenginius galima patvirtinti asmens tapatybę per **Bluetooth** ar kitą technologiją.
 - **Saugumo žetonai** (token): Tai specialūs prietaisai arba kortelės, generuojantys atsitiktinius autentifikavimo kodus, kurie yra laikomi paslapyje.
3. **Kas tu esi? (Būdų pagrindu)** – autentifikavimas remiasi unikaliais asmens bruožais.
 - **Biometriniai duomenys**:
 - **Veido atpažinimas** – sistema gali nuskenuoti žmogaus veidą ir palyginti su duomenų baze.
 - **Pirštų atspaudai** – naudojami ypač populiariuose išmaniuosiuose telefonuose.
 - **Retina atpažinimas** – kai autentifikavimui naudojama žmogaus akies tinklainė.
 - **Balsų atpažinimas** – autentifikavimas pagal asmens balsą, ypač naudojamas telefonu arba balso komandų sistemose.
4. **Kelių faktorių autentifikavimas (MFA)** – tai metodas, kuriuo naudojama daugiau nei viena autentifikavimo rūšis. Tai labai sustiprina saugumą, nes net jei viena sistema pažeidžiama, kitos vis tiek užtikrina asmens tapatybę.
 - **Pavyzdys**: Vartotojas gali prisijungti naudojant slaptažodį (pirmas faktorius), o vėliau gauti unikalų kodą savo išmaniajame telefone (antras faktorius).

5. **El. pašto ar SMS kodai** – autentifikavimas naudojant **laikinas kodo žinutes**, kurias sistema siunčia į el. paštą ar mobilųjį telefoną, kad patvirtintų tapatybę.
- 6.

Pagrindinės autentifikavimo ir identifikavimo sistemų rūšys:

1. **Slaptažodžių pagrindu veikiantis autentifikavimas:**
 - **Slaptažodžiai** – tai paprasčiausias autentifikavimo būdas, kai vartotojas įveda slaptažodį, kurį žino tik jis.
 - Trūkumas: nesaugūs slaptažodžiai, per dažnas jų naudojimas, lengvai pamirštami arba gali būti peržengti, naudojant kibernetines atakas (pavyzdžiui, **brute-force** atakas).
2. **Biometrinis autentifikavimas:**
 - **Pirštų atspaudai, veido atpažinimas, akis** – biometriniai metodai naudojami, kai reikalingas aukštas saugumo lygis. Jie paprastai greitesni ir patikimesni, nes jie reikalauja fiziškai esamo asmens buvimo.
 - Privalumai: paprasta ir patogiu vartotojui, sunku suklastoti.
 - Trūkumai: brangūs įrenginiai, gali kilti privatumo problemų.
3. **Vienkartinių slaptažodžių (OTP) autentifikavimas:**
 - Naudojant vienkartinius slaptažodžius, kurie yra sugeneruojami ir galioja tik vieną kartą, labai padidėja saugumas, nes net jei slaptažodis yra pavogtas, jis nebebus naudingas.
 - Pavyzdys: Bankai ir kitos organizacijos dažnai naudoja OTP per SMS žinutes arba specialius autentifikavimo įrenginius.
4. **Kelių faktorių autentifikavimas (MFA):**
 - Naudojant daugiau nei vieną autentifikavimo metodą, MFA stiprina apsaugą, nes bet koks pažeidimas viename faktoriuje nesukels sistemos pažeidimo.
 - Pavyzdys: Vartotojas turi įvesti slaptažodį, o tada gauti kodo žinutę į savo mobilųjį telefoną.

Autentifikavimo ir identifikavimo sistemos taikymo pavyzdžiai:

1. **Bankininkystė** – daugelis bankų naudoja kelių faktorių autentifikavimą (slaptažodis ir OTP per telefoną) apsaugoti klientų sąskaitas.
2. **Išmanieji įrenginiai** – **iPhone** ir kiti įrenginiai naudoja **pirštų atspaudų** ar **veido atpažinimo** technologijas, kad užtikrintų įrenginio saugumą ir apsaugotų naudotojo informaciją.
3. **Biometriniai įėjimai** – oro uostuose ar saugių patalpų prieigose naudojamos **pirštų atspaudų** ir **akis skenavimo** sistemos identifikacijai ir autentifikavimui.
4. **Socialinės paslaugos** – kai kurios paslaugos (pvz., **Google** ir **Facebook**) leidžia prisijungti per **socialinį autentifikavimą**, naudodamos paskyras iš kitų paslaugų, taip supaprastinant prisijungimo procesą.

Išvados:

Autentifikavimo ir identifikavimo sistemos yra esminės siekiant užtikrinti saugumą ir apsaugoti vartotojo duomenis tiek fiziniame pasaulyje, tiek internete. Pasirinkus teisingą autentifikavimo metodą, galima ne tik apsaugoti informaciją, bet ir užtikrinti, kad tik teisėti vartotojai galėtų pasiekti tam tikras sistemas ar paslaugas.

Suasmenintas turinys

Suasmenintas turinys – tai turinys, kuris pritaikytas pagal individualius vartotojo poreikius, pomėgius, elgesį ar kitus asmeninius duomenis. Suasmeninimas siekia suteikti vartotojui labiau pritaikytą, aktualų ir įdomų turinį, taip pagerinant vartotojo patirtį ir padidinant įsitraukimą.

Suasmeninto turinio principai:

Suasmenintas turinys remiasi duomenimis, surinktais apie vartotoją, ir naudojamas norint pritaikyti informaciją pagal jo prioritetus ir elgesį. Tai apima:

1. **Vartotojo elgseną:** Pavyzdžiui, internete naršantys vartotojai palieka „skaitmenines pėdsakus“, kurie leidžia nustatyti jų interesus (pvz., peržiūrėtus puslapius, paspaustus skelbimus ar atliktas paieškas).
2. **Istoriniai duomenys:** Pagal ankstesnį vartotojo veikimą galima prognozuoti, koks turinys jam gali būti naudingas (pvz., užsakytos prekės, naršytos kategorijos ar įsigytos paslaugos).
3. **Demografiniai duomenys:** Suasmeninimas gali vykti remiantis amžiumi, lytimi, geografinėmis vietovėmis, kalbos pasirinkimais ir kitais duomenimis.

Suasmeninto turinio naudojimo pavyzdžiai:

1. **Socialinės žiniasklaidos platformos:**
 - **Facebook, Instagram, Twitter** ir kitos socialinės žiniasklaidos platformos renkasi turinį, kurį vartotojas mato savo naujienų sraute, remiantis jo elgsena (pvz., ką jis patiko, komentuodavo, sekė).
 - Šios platformos naudoja **algoritmus**, kurie nuspėja, kokie įrašai gali būti įdomūs vartotojui, ir atitinkamai pritaiko turinį.
2. **E-komercijos svetainės:**
 - **Amazon, eBay** ir kitos elektroninės parduotuvės rodo vartotojams prekes, kurios atitinka jų ankstesnius pirkimus ar naršymo istoriją. Taip pat naudojamos rekomendacijos pagal kitų vartotojų pirkimo elgseną.
 - Pavyzdžiui, po to, kai žmogus perka ar žiūri konkrečią prekę, svetainė gali rekomenduoti panašius produktus arba su jais susijusias prekes.
3. **Muzikos ir video transliacijos paslaugos:**
 - **Spotify, YouTube** ir **Netflix** pritaiko savo turinį pagal vartotojo klausymo istoriją, žiūrėtus vaizdo įrašus ar žiūrėtus filmus. Pavyzdžiui, YouTube rekomenduoja kitus vaizdo įrašus, kurie atitinka vartotojo žiūrėjimo įpročius.
 - **Spotify** rodo muzikos albumus ir atlikėjus, kurie atitinka vartotojo klausymo istoriją, taip pat sukuria suasmenintas grojaraščius.
4. **Paieškos sistemos:**
 - **Google** ir kitos paieškos sistemos rodo individualiai suasmenintas paieškos rezultatus remiantis vartotojo ankstesnėmis paieškomis, geografinės vietos duomenimis ir net naudojamomis kalbomis.
 - Pavyzdžiui, jeigu žmogus dažnai ieško kelionių pasiūlymų, paieškos sistema gali rodyti su kelionėmis susijusius rezultatus aukščiau už kitus.
5. **Reklamos ir skelbimai:**
 - **Google Ads** ir **Facebook Ads** leidžia pritaikyti reklamas pagal vartotojo interesus, elgesį ir demografinius duomenis. Pavyzdžiui, jeigu vartotojas neseniai domėjosi naujais išmaniaisiais telefonais, jis gali pradėti matyti reklamas apie naujausias telefonų nuolaidas ar pasiūlymus.
 - Skelbimai taip pat gali būti suasmeninti pagal elgseną kitose svetainėse, naudojant **trečiųjų šalių sekimo technologijas**.

Suasmeninto turinio privalumai:

1. **Geresnė vartotojo patirtis:** Suasmenintas turinys padeda vartotojui lengviau rasti tai, kas jam tikrai įdomu, ir sumažina nereikalingos informacijos perteklių.
2. **Padidintas įsitraukimas:** Kai turinys yra pritaikytas pagal asmeninius poreikius ir interesus, vartotojai labiau linkę juo domėtis, užsiimti sąveika ir atlikti veiksmus (pvz., paspausti nuorodą, pirkti prekę).
3. **Tikslesnės rekomendacijos:** Įmonės gali teikti rekomendacijas, kurios padeda vartotojams atrasti produktus ar paslaugas, apie kurias jie galbūt net nebuvo pagalvoję.

Suasmeninto turinio iššūkiai ir pavojai:

1. Privatumo klausimai:

- Suasmenintas turinys dažnai reikalauja surinkti ir analizuoti asmens duomenis, kurie gali būti jautrūs. Netinkamas duomenų valdymas gali sukelti privatumo pažeidimus ir nepageidaujamą stebėjimą.
- Vartotojams gali būti nepatogu, kai jie jaučiasi nuolat sekami ar įrašomi jų asmeniniai duomenys be jų sutikimo.

2. Algoritminis šališkumas:

- Suasmeninimas dažnai pasikliauja **algoritmais**, kurie gali būti šališki arba remiasi klaidingais duomenimis. Tai gali sukelti nesąžiningą turinio pateikimą ar diskriminaciją.
- Pavyzdžiui, jei sistema klaidingai interpretuoja vartotojo pomėgius, gali atsirasti nereikalingos arba nepageidaujamos rekomendacijos.

3. „Informacijos burbulas“:

- Suasmenintas turinys gali sukurti **informacijos burbulą**, kai vartotojas nuolat mato tik turinį, kuris patvirtina jo esamas nuostatas ar įsitikinimus, tačiau negauna įvairių nuomonių ar alternatyvių požiūrių.
- Tai gali apsunkinti objektyvią nuomonę ir sukelti vartotojui ribotą informacijos suvokimą.

Išvados:

Suasmenintas turinys yra galinga priemonė tiek vartotojo patirties gerinimui, tiek verslui didinti įsitraukimą ir konversijas. Tačiau, norint išvengti galimų etinių ir privatumą pažeidžiančių problemų, svarbu laikytis atsakingos duomenų rinkimo ir naudojimo praktikos, taip pat užtikrinti vartotojų sutikimą ir kontrolę, kaip jų duomenys naudojami.

Autonominis vairavimas – tai technologija, leidžianti transporto priemonėms valdyti ir vairuoti save be žmogaus įsikišimo. Tokios transporto priemonės geba aptikti savo aplinką, priimti sprendimus ir atlikti vairavimo manevrus naudodamos įvairias jutiklių sistemas, dirbtinį intelektą (DI) ir mašininį mokymąsi.

Autonominiai automobiliai remiasi įvairiomis technologijomis, kurios leidžia jiems veikti savarankiškai:

Pagrindinės technologijos, naudojamos autonominiame vairavime:

1. Jutikliai ir sensoriai:

- **LiDAR (Light Detection and Ranging):** Tai lazeriniai jutikliai, kurie matuoja atstumą iki objektų ir kuria 3D žemėlapius, padedančius automobiliui „pamatyti“ aplinką.
- **Radarai:** Naudojami matuoti atstumus ir greitį iki kitų objektų, ypač naudingi blogomis oro sąlygomis (pvz., rūkas, lietus).
- **Kameros:** Padeda atpažinti objektus, kelio ženklus, pėsčiuosius, kitus automobilius ir aplinkos detales.
- **Ultragarsiniai jutikliai:** Naudojami artimų atstumų matavimams ir manevrų atlikimui, pavyzdžiui, parkavimosi metu.

2. Dirbtinis intelektas ir mašininis mokymasis:

- **Objektų atpažinimas ir analizė:** Diagramos, atvaizdai ir kitos technologijos, kurios leidžia automobiliui atpažinti ir reaguoti į aplinką. Tai leidžia identifikuoti pėsčiuosius, kitus automobilius, kelio ženklus ir net kelių sąlygas.
- **Autonominė navigacija:** Dirbtinis intelektas apdoroja duomenis iš jutiklių, kad galėtų priimti sprendimus, tokius kaip greičio reguliavimas, sustojimas prie stop ženklų, kairiojo posūkio atlikimas ir pan.

- **Išmokstamosios sistemos:** Mašininio mokymosi algoritmai leidžia automobiliui tobulėti ir gerinti savo gebėjimus remiantis ankstesnėmis patirtimis bei aplinkos sąlygomis.
3. **Vairavimo ir navigacijos sistemos:**
 - **GPS ir žemėlapių duomenys:** Su jų pagalba automobiliai žino savo tikslią vietą ir galintys optimizuoti maršrutą.
 - **Vairavimo algoritmai:** Tai priemonės, kurios padeda automobiliui atlikti įvairius manevrus: įjungti posūkio signalus, keisti juostas, stebėti kitas transporto priemones ir reaguoti į staigius įvykius.
 4. **Ryšio technologijos:**
 - **V2X (Vehicle-to-Everything):** Tai komunikacijos sistema, leidžianti automobiliams keistis informacija su kitais automobiliais, infrastruktūra, pėsčiaisiais ir kitomis sistemomis. Tai padeda geriau reaguoti į artėjančius įvykius ir optimizuoti judėjimą.

Autonominio vairavimo lygiai:

Autonominis vairavimas yra vertinamas pagal lygį, kur kiekvienas lygis atitinka automobilių gebėjimo valdyti įvairias užduotis be žmogaus įsikišimo mastą. Pagal **SAE International** (Society of Automotive Engineers) standartus, autonominio vairavimo lygiai yra nuo 0 iki 5:

- **Lygis 0 (Be autonomijos):** Žmogus visiškai kontroliuoja automobilį. Nėra jokių autonominių funkcijų.
- **Lygis 1 (Vairuotojo pagalba):** Pavyzdžiui, automobilis gali turėti vieną autonominę funkciją, pvz., adaptacinę kruizo kontrolę arba automatizuotą vairavimo pagalbą.
- **Lygis 2 (Išplėstinė vairuotojo pagalba):** Automobilis gali atlikti kelias funkcijas, pavyzdžiui, keisti juostą arba pritaikyti greitį pagal kitus automobilius. Tačiau vairuotojas turi likti budrus ir pasiruošęs perimti kontrolę.
- **Lygis 3 (Įrenginio valdymas esant tam tikroms sąlygoms):** Automobilis gali savarankiškai atlikti vairavimą ir kai kurias užduotis, tačiau vairuotojas turi būti pasiruošęs perimti kontrolę, jei reikia.
- **Lygis 4 (Aukštas autonomijos lygis):** Automobilis gali vairuoti save visiškai tam tikrose vietose (pvz., miesto gatvėse ar specifinėse aplinkose), tačiau tam tikrose situacijose žmogus gali būti reikalingas.
- **Lygis 5 (Pilna autonomija):** Automobilis visiškai valdo save visose situacijose, nebereikia žmogaus įsikišimo, jokių vairuotojo pagalbos funkcijų nereikia.

Autonominio vairavimo privalumai:

1. **Sauga:** Tikimasi, kad autonominiai automobiliai gali sumažinti eismo įvykių skaičių, nes jie pašalina žmogaus klaidas, kurios dažnai būna pagrindinė avarijų priežastis.
2. **Patogumas:** Automobiliai galėtų sumažinti vairavimo stresą ir laiką, nes vairuotojai galėtų atlikti kitas užduotis, pavyzdžiui, dirbti ar ilsėtis, kol automobilis važiuoja.
3. **Eismo srautų gerinimas:** Autonominiai automobiliai galėtų geriau koordinuoti judėjimą, optimizuodami maršrutus ir sumažindami kamščius.
4. **Prieinamumas:** Tai gali padėti žmonėms, turintiems negalią, vyresnio amžiaus asmenims arba kitiems, kuriems sunku vairuoti, nepriklausomai keliauti.

Grėsmės ir iššūkiai:

1. **Techniniai iššūkiai:** Nors technologijos tobulėja, autonominiai automobiliai vis dar susiduria su iššūkiais dėl sudėtingų eismo situacijų, ekstremalių oro sąlygų ir neįprastų situacijų, kurioms jie dar gali nesugebėti greitai reaguoti.
2. **Etiniai klausimai:** Ką daryti, kai atsiranda avarija, ir automobiliui reikia pasirinkti, kokį sprendimą priimti? Tai yra etinis klausimas, kurį reikia išspręsti, kad galėtume pasitikėti autonominėmis sistemomis.

3. **Privatumo ir saugumo problemos:** Autonominiai automobiliai renka daugybę duomenų, tokių kaip kelionės maršrutai, vairavimo įpročiai ir vietos. Tai kelia susirūpinimą dėl duomenų saugumo ir privatumo.
4. **Teisiniai ir reguliavimo klausimai:** Reikia sukurti naujus įstatymus ir reguliavimus, kad būtų galima užtikrinti autonominių automobilių saugumą ir suderinti juos su esamomis eismo taisyklėmis.

Autonominio vairavimo ateitis:

Nors autonominių automobilių technologijos yra sparčiai vystomos, šiuo metu daugelyje šalių jie vis dar nėra plačiai prieinami. Tačiau tikėtina, kad artimiausioje ateityje matysime vis daugiau bandymų ir pilotinių projektų, leidžiančių tobulinti šias sistemas, kad jos taptų saugesnės ir patikimesnės. Tai gali sukurti naujas transporto paslaugas ir iš esmės pakeisti mūsų kasdienį gyvenimą.

Tiuringo testas

Tiuringo testas (angl. **Turing Test**) – tai dirbtinio intelekto gebėjimo imituoti žmogaus mąstymą vertinimo metodas, kurį 1950 metais pasiūlė britų matematikas ir kompiuterių mokslininkas **Alanas Turingas**. Šis testas buvo sukurtas siekiant atsakyti į klausimą, ar mašina gali turėti „protingą“ elgesį, panašų į žmogaus.

Testo principas:

Tiuringo testas remiasi **komunikacija** tarp žmogaus ir kompiuterio, kuriuo bandoma nustatyti, ar kompiuteris susugeba imituoti žmogaus atsakymus tiek tiksliai, kad žmogus nebegali atskirti, kuris dalyvis yra žmogus, o kuris – mašina.

Testo eiga:

1. **Žmogaus vertintojas** (bent vienas, bet gali būti ir daugiau) dalyvauja pokalbyje su dviem subjektais: žmogumi ir kompiuteriu.
2. **Pokalbis vyksta raštu**, todėl vertintojas negali matyti dalyvių ar girdėti jų balsų, tai leidžia išvengti įtakos dėl išvaizdos, balso ar kitų neverbalių požymių.
3. **Kompiuteris** stengiasi įtikinti vertintoją, kad jis yra žmogus, atsakydamas į klausimus, rašydamas atsakymus, kurie būtų natūralūs ir „žmogiški“.
4. **Žmogus** taip pat bendrauja su vertintoju ir stengiasi suteikti autentiškus atsakymus.
5. **Jei vertintojas negali patikimai atskirti**, kuris atsakymas priklauso žmogui, o kuris – kompiuteriui, tada teigiama, kad kompiuteris **praėjo Tiuringo testą**.

Pagrindiniai tikslai ir idėjos:

- Tiuringo testas buvo sukurtas ne tam, kad įrodytų kompiuterio intelektą kaip „tą patį“ kaip žmogaus, bet tam, kad **nustatytų, ar mašina gali imituoti žmogaus elgesį taip gerai**, kad žmogus nesugebėtų atskirti, kas yra kas.
- Turingas teigė, kad jei kompiuteris sugeba įtikinti žmogų, jog jis yra žmogus, tai galima sakyti, kad kompiuteris turi tam tikrą formą „intelektą“, nes sugeba imituoti žmogišką mąstymą.

Tiuringo testo privalumai:

- **Objektyvumas** – testas nesiklauso į tai, kokių būdu kompiuteris pasiekia savo rezultatus, o tik į tai, ar jo elgesys atitinka žmogišką.
- Tai paprasta idėja, lengvai suprantama ir pritaikoma įvairiuose kontekstuose, kad būtų galima įvertinti kompiuterinių sistemų elgesį.

Kritiškas požiūris:

- **Klaudingas aiškinimas:** Tiuringo testas nesistengia įrodyti, kad kompiuteris tikrai „mąsto“ taip, kaip žmogus, o tik tai, kad jis gali **simuliuoti elgesį**.
- **Žmogiškumo problema:** Kritikai teigia, kad testas gali būti pernelyg susijęs su paviršutiniškais elgesio aspektais, o ne su tikru mąstymu, suvokimu ir sąmoningumu. Tai reiškia, kad kompiuteris gali **„pasirodyti protingas“** be tikro supratimo apie tai, ką jis daro.

- **Kiti intelekto aspektai:** Testas nesprendžia klausimų, kaip kompiuteris supranta pasaulį, ką jis gali jausti ar kaip jis priima sprendimus.

Tiuringo testo reikšmė dirbtiniam intelektui:

Tiuringo testas buvo ir lieka svarbus orientyras **dirbtinio intelekto (DI) tyrimuose**. Nors jis buvo sukurtas dar 1950 m., jis vis dar naudojamas kaip svarbus etalonas vertinant kompiuterių gebėjimą imituoti žmogaus elgesį. Tuo pačiu, jis paskatino gilesnes diskusijas apie **sąmonę, intelektą ir mašininį mąstymą**, taip pat išryškino būtinybę atskirti **simuliaciją nuo tikro supratimo**.

Pavyzdžiai ir taikymas:

- **Chatbot'ai ir virtualūs asistentai** (pvz., **Siri, Alexa, Google Assistant**) kartais bando praeiti Tiuringo testą, siekdami suteikti žmonėms pojūtį, kad jie bendrauja su tikru žmogumi.
- **AI kūrimo etapai:** Nors daugelis šiuolaikinių DI sistemų, kaip **GPT-3** (kuris naudoja natūralaus kalbėjimo generavimą), yra labai pažangios ir gali sukurti įtikinamus atsakymus, jie vis dar dažnai neatitinka visų reikalavimų, kad būtų laikomi pilnai „sąmoningais“ ar protingais pagal Tiuringo testą.

Išvados:

Tiuringo testas buvo ir yra vienas iš svarbiausių **dirbtinio intelekto filosofinių** ir praktinių klausimų vertinimo metodų, tačiau jis nėra galutinis sprendimas ar įrodymas apie tikrą DI sąmoningumą. Jis tiesiog pabrėžia, kad intelektas gali būti **simuliuojamas** per elgesį, tačiau nesako nieko apie tai, kas iš tikrųjų vyksta viduje (mąstymas, suvokimas).

sugeba imituoti žmogaus atsakymus tiek tiksliai, kad žmogus nebegali atskirti, kuris dalyvis yra žmogus, o kuris – mašina.

Asociacijų analizė

Asociacijų analizė dirbtinio intelekto (DI) kontekste dažnai taikoma tam, kad būtų galima nustatyti ryšius tarp įvairių duomenų elementų, ypač dideliuose duomenų rinkiniuose. Tai padeda suprasti, kaip skirtingos savybės ar įvykiai yra tarpusavyje susiję. DI naudojant asociacijų analizę galima automatizuoti ryšių atradimą ir paspartinti sprendimų priėmimo procesus.

Asociacijų analizė ir jos pritaikymas dirbtiniame intelekto:

1. Rekomendacijų sistemos:

- **Pavyzdys:** Elektroninė prekyba, kur rekomenduojama prekė, atsižvelgiant į ankstesnius vartotojo pirkimus arba kitų vartotojų elgseną. DI naudojant asociacijų analizę, galima sukurti automatines rekomendacijas, kurios patinka vartotojui (pvz., "Pirkėjai, kurie pirko šią prekę, taip pat pirko...").
- **Algoritmai:** Apriori, Eclat, FP-growth.

2. Klientų elgsenos analizė:

- DI gali analizuoti pirkimo elgseną, kad nustatytų, kurie produktai dažnai perkami kartu, ir tada kurti suasmenintas pasiūlymus. Pavyzdžiui, jei pirkėjas pirko "laptopą", sistema gali pasiūlyti "pele" arba "krepšį".

3. Sukčiavimo aptikimas:

- Asociacijų analizė gali padėti identifikuoti neįprastus elgesio modelius ir įtartinas asociacijas. Pavyzdžiui, jei tam tikros elgsenos ar pirkimo modeliai dažnai būna susiję su sukčiavimo atvejais, DI sistema gali automatiškai įspėti apie galimą riziką.

4. Medicinos diagnozės ir gydymo nustatymas:

- Asocijuodama ligas ir simptomus, DI gali padėti sveikatos priežiūros specialistams nustatyti potencialias diagnozes ir siūlyti efektyviausius gydymo metodus. Pavyzdžiui, jeigu tam tikri simptomai dažnai būna susiję su tam tikra liga, tai gali būti naudojama kaip pagrindas greitai diagnozuoti.

5. Socialinių tinklų analizė:

- Asociacijų analizė naudojama nustatant ryšius tarp vartotojų, jų interesų ir veiksmų, taip padedant sukurti personalizuotas reklamines kampanijas arba gerinti turinio rekomendacijas.

Asociacijų analizės metodai DI:

1. **Apriori algoritmas:**

Šis algoritmas identifikuoja dažnai pasikartojančius elementus ir sąsajas tarp jų. Jis veikia iš skirtingų „kandidatinčių“ elementų rinkinių ir nustato dažnai pasikartojančius rinkiniai, kurie vėliau naudojami prognozavimams ir rekomendacijoms.

2. **FP-growth algoritmas:**

Tai greitesnė alternatyva Apriori metodui. Jis veikia taip, kad sukuria dažniausiai pasikartojančių elementų „medį“, kuris leidžia greičiau rasti asociacijas.

3. **Eclat algoritmas:**

Šis metodas taip pat naudojamas dažnai pasikartojančių elementų identifikavimui ir yra ypač efektyvus dideliuose duomenų rinkiniuose, nes jis remiasi „TID“ (Transaction ID) lista, siekiant padidinti greitį.

4. **Rekomendacijų sistemų algoritmai (Matrix Factorization, Collaborative Filtering):**

DI naudojant rekomendacijų sistemas, galima analizuoti vartotojų elgseną ir rasti ryšius tarp vartotojų ir produktų. Matrix Factorization ir Collaborative Filtering yra populiarūs metodai, kurie naudojami asociacijų analizėje, siekiant prognozuoti, kokius produktus vartotojai gali norėti įsigyti, remiantis kitų vartotojų elgesiu.

Asociacijų analizė ir DI – praktinis pritaikymas:

- **Automatiniai sprendimai:** DI gali ne tik nustatyti asociacijas, bet ir automatiškai priimti sprendimus ar pateikti rekomendacijas vartotojams ar verslo procesams.
- **Mokymasis iš duomenų:** DI sistemos gali nuolat mokytis iš naujų duomenų ir atnaujinti savo asociacijas, kad būtų geriau pritaikytos prie kintančių sąlygų, pavyzdžiui, rinkos pokyčių.

Asociacijų analizė DI srityje leidžia automatizuoti ir pagerinti įvairias verslo ir analizės užduotis, ypač kur svarbus greitas, tikslingas ir suasmenintas sprendimų priėmimas. Šis metodas padeda ne tik optimizuoti procesus, bet ir kurti dinamiškas ir asmenines paslaugas.

Klasterizacija, klasifikavimas, grupavimas

Klasterizacija ir grupavimas dažnai vartojami panašiam kontekste, tačiau jie gali turėti šiek tiek skirtingas reikšmes priklausomai nuo analizuojamos srities. Pateikiu pagrindinius skirtumus:

1. Apibrėžimas:

- **Klasterizacija** – tai neprižiūrimo mokymosi metodas, kurio tikslas yra suskirstyti duomenis į grupes (klasterius), kad tie duomenų taškai, kurie yra panašūs, būtų susiję su tais pačiais klasteriais, o skirtingi – su skirtingais. Šiuo procesu siekiama atrasti paslėptas struktūras duomenyse.
- **Grupavimas** – bendras terminas, apibūdinantis objektų ar duomenų suskirstymą į grupes, tačiau jis gali būti ir prižiūrimas (supervised) ar nesupervizuojamas (unsupervised). Grupavimas kartais gali reikšti tiesiog duomenų dalijimą pagal kokį nors kriterijų, nesvarbu, ar tai yra klasterizacija, ar kitas metodas.

2. Metodai:

- **Klasterizacija** dažniausiai siejama su tam tikrais neprižiūrimo (nesupervizuojamo) mokymosi metodais, tokiais kaip:
 - K-means
 - DBSCAN
 - Hierarchinė klasterizacija
 - GMM (Gaussian Mixture Models)

- **Grupavimas** gali būti platesnė sąvoka ir apimti įvairias strategijas, kaip:
 - Hierarchiniai metodai
 - Klasifikacijos metodai (jei grupavimas yra prižiūrimas)
 - Paprasti kriterijai, kaip, pavyzdžiui, suskirstymas pagal geografinius, demografinius ar kitus atributus.

3. Naudojimo tikslas:

- **Klasterizacija** dažniausiai naudojama tada, kai nėra aiškių žinių apie tai, kaip turėtų būti suskirstyti duomenys, ir tikslas – atrasti paslėptas struktūras duomenyse. Pavyzdžiui, analizuojant klientų pirkimo įpročius ar grupuojant dokumentus pagal panašumą.
- **Grupavimas** gali būti naudojamas tiek analizuojant duomenis, tiek juos suskirstant pagal iš anksto nustatytus kriterijus. Grupavimas gali būti ir paprastas, pvz., suskirstymas į grupes pagal amžiaus intervalus ar regionus.

4. Prižiūrimas ar neprižiūrimas mokymasis:

- **Klasterizacija** visada yra **nesupervizuojamas** metodas, nes ji siekia rasti natūralias struktūras duomenyse be išankstinių žinių apie grupių etiketes.
- **Grupavimas** gali būti tiek **supervizuojamas**, tiek **nesupervizuojamas**. Grupavimas su etiketėmis paprastai yra prižiūrimas, kai duomenys jau turi klasifikacijas, kurias norima išlaikyti.

5. Pavyzdžiai:

- **Klasterizacija:**
 - Klientų segmentavimas pagal pirkimo įpročius.
 - Panašių produktų grupavimas, remiantis jų savybėmis.
- **Grupavimas:**
 - Duomenų skirstymas pagal amžių (pvz., 18-24, 25-34 metai).
 - Geografiniai regionai, į kuriuos galima suskirstyti duomenis.
 - Grupavimas pagal klasifikacijas (pvz., priskyrimas įvairioms socialinėms grupėms pagal elgseną).

Santrauka:

- **Klasterizacija** – tai nesupervizuojamas duomenų grupavimas, kai tikslas yra atrasti natūralias grupes (klasterius) duomenyse pagal panašumą.
- **Grupavimas** – tai platesnis terminas, apimantis įvairius metodus ir gali būti tiek prižiūrimas, tiek neprižiūrimas, ir dažniausiai susijęs su tam tikrais iš anksto nustatytais kriterijais arba klasifikacijomis.

Svarbiausias skirtumas yra tas, kad **klasterizacija** yra konkretus metodas duomenų grupavimui, dažniausiai naudojamas be išankstinių žinių apie duomenis, o **grupavimas** gali apimti įvairius būdus ir būti plačiau taikomas.

Grupavimas ir **klasifikacija** nėra tas pats, nors jie turi panašumų. Abu metodai priklauso prie **duomenų analizės** technikų, tačiau jų tikslas, metodai ir naudojimo kontekstas skiriasi.

1. Apibrėžimas:

- **Grupavimas** (angl. **Clustering**): Tai **nesupervizuojamas mokymasis** (unsupervised learning) metodas, kai duomenys yra suskirstomi į grupes (klasterius), tačiau grupių etiketės nėra žinomos iš anksto. Tikslas – atrasti natūralias struktūras duomenyse. Grupės yra formuojamos remiantis duomenų taškų panašumu.
- **Klasifikacija** (angl. **Classification**): Tai **supervizuojamas mokymasis** (supervised learning) metodas, kai duomenys yra suskirstyti į iš anksto apibrėžtas kategorijas arba klases, naudojant anotuotus (su etiketėmis) duomenis. Tikslas – priskirti naujus duomenų taškus jau žinomoms klasėms.

2. Metodai:

- **Grupavimas:**

- **K-means,**
- **Hierarchinė klasterizacija,**
- **DBSCAN,**
- **Gaussian Mixture Models (GMM).**
- **Klasifikacija:**
 - **Logistinė regresija,**
 - **Neurono tinklai,**
 - **K-nearest neighbors (KNN),**
 - **Sprendimų medžiai (Decision Trees),**
 - **Random Forest,**
 - **Naivusis Bayeso klasifikatorius.**

3. Prižiūrimas vs. Neprižiūrimas:

- **Grupavimas – Neprižiūrimas mokymasis:** Jūs neturite išankstinių žinių apie tai, kaip duomenys turėtų būti suskirstyti, ir tikslas – atrasti paslėptas struktūras ar grupes.
- **Klasifikacija – Prižiūrimas mokymasis:** Jūs turite anotuotus duomenis, tai yra, žinote, kokios yra teisingos etiketės, ir tikslas – išmokyti modelį, kad jis galėtų priskirti naujus duomenis teisingoms etiketėms.

4. Tikslas:

- **Grupavimas:** Tikslas yra rasti **natūralias grupes** arba **klasterius** duomenyse, kai nėra aiškių žinių apie tai, kaip duomenys turėtų būti suskirstyti. Pavyzdžiui, segmentuoti klientus pagal jų elgseną.
- **Klasifikacija:** Tikslas yra priskirti objektus jau žinomoms **kategorijoms** arba **klasėms**. Pavyzdžiui, klasifikuoti laiškus kaip „šlamštą“ arba „ne šlamštą“ pagal jau iš anksto nustatytas kategorijas.

5. Pavyzdžiai:

- **Grupavimas:**
 - **Klientų segmentavimas:** Duomenų rinkinyje segmentuojami klientai pagal jų pirkimo įpročius, tačiau nesate iš anksto nustatę, kiek segmentų (grupių) bus.
 - **Dokumentų grupavimas:** Grupavimas pagal panašumą (pvz., žurnalų straipsniai pagal temą).
- **Klasifikacija:**
 - **Laiškų klasifikacija:** El. paštas priskiriamas kategorijai „šlamštas“ arba „ne šlamštas“, naudodamasis jau apmokytu modeliu su žinomais pavyzdžiais.
 - **Sukčiavimo aptikimas:** Atpažinti sandorius, kurie gali būti sukčiavimo atvejai, remiantis istoriniu duomenų rinkiniu, kuriame sandoriai yra pažymėti kaip „sukčiavimas“ arba „ne“.

Išvada:

- **Grupavimas** yra **nesupervizuojamas** metodas, kur tikslas yra rasti paslėptas grupes duomenyse be išankstinių žinių apie etiketes.
- **Klasifikacija** yra **supervizuojamas** metodas, kur tikslas yra priskirti objektus žinomoms etiketėms, remiantis anotuotais duomenimis.

Taigi, **grupavimas** dažniausiai naudojamas, kai norite atrasti naujas struktūras arba grupes duomenyse, o **klasifikacija** – kai turite iš anksto nustatytas kategorijas ir norite priskirti naujus duomenis šioms kategorijoms.

Klasterizacija – tai duomenų grupavimo metodas, kai objektai skirstomi į grupes (**klasterius**) taip, kad tos pačios grupės objektai būtų kuo panašesni tarpusavyje, o skirtingų grupių – kuo labiau skirtingi. Tai yra viena iš nesupervizuojamo mokymosi technikų, plačiai naudojama duomenų analitikoje ir mašininio mokymosi srityse.

Klasterizacijos paskirtis

1. **Duomenų segmentacija** – naudojama rinkodaroje, norint identifikuoti klientų grupes pagal pirkimo įpročius ar elgseną.
2. **Anomalijų aptikimas** – padeda nustatyti išskirtinius arba netipinius duomenų taškus, pavyzdžiui, sukčiavimo atvejus bankininkystėje.
3. **Vaizdų segmentacija** – pritaikoma kompiuterinėje regoje, siekiant suskirstyti vaizdą į prasmingas dalis.
4. **Biologinių duomenų analizė** – naudojama genetikoje ir bioinformatikoje, siekiant grupuoti genus ar ligų tipus pagal tam tikras savybes.
5. **Rekomendacijų sistemos** – padeda grupuoti vartotojus pagal jų elgseną ir pasiūlyti personalizuotus produktus ar paslaugas.

Pagrindiniai klasterizacijos metodai

1. **Particionavimo metodai**
 - **K-means** – populiariausias metodas, kuris dalina duomenis į iš anksto nustatytą klasterių skaičių.
 - **K-medoids** – panašus į K-means, bet mažiau jautrus išskirtiniams taškams.
2. **Hierarchiniai metodai**
 - **Aglomeratyvi klasterizacija** – pradeda nuo kiekvieno objekto kaip atskiro klasterio ir palaipsniui jungia juos į grupes.
 - **Dendrogramos** – vizualizuoja hierarchinį klasterizavimą ir padeda nustatyti optimalų klasterių skaičių.
3. **Tankio pagrindo metodai**
 - **DBSCAN (Density-Based Spatial Clustering of Applications with Noise)** – nustato tankius duomenų regionus ir automatiškai aptinka išskirtinius taškus.
 - **OPTICS** – išplėstas DBSCAN variantas, kuris geriau veikia su skirtingo tankumo klasteriais.
4. **Tinklelio pagrindo metodai**
 - Duomenų erdvė yra padalijama į mažus tinklelius, o tada vykdoma klasterizacija pagal jų tankį.
5. **Modelio pagrindo metodai**
 - **GMM (Gaussian Mixture Model)** – kiekvieną klasterį modeliuoja kaip kelių Gauso pasiskirstymų kombinaciją.

Kaip pasirinkti tinkamą klasterizacijos metodą?

- Jei klasterių forma yra aiškiai apibrėžta ir iš anksto žinomas skaičius → **K-means**
- Jei reikia vizualiai analizuoti duomenis → **Hierarchinė klasterizacija (dendrogramos)**
- Jei duomenys turi netolygius klasterius su triukšmu → **DBSCAN**
- Jei klasteriai gali turėti sudėtingą formą → **GMM**

Tinkamas metodo pasirinkimas priklauso nuo duomenų struktūros, klasterių formos ir tikslų, kuriuos siekiama pasiekti.

Klasifikacija vs. Klasterizacija: Pagrindiniai skirtumai

Kriterijus	Klasifikacija	Klasterizacija
Mokymosi tipas	Prižiūrimas (supervised learning)	Neprižiūrimas (unsupervised learning)
Duomenų struktūra	Turimi duomenys su etiketėmis (pvz., „katė“ arba „šuo“)	Duomenys be iš anksto nustatytų etikečių
Tikslas	Priskirti objektą vienai iš iš anksto žinomų kategorijų	Rasti natūralias duomenų grupes pagal panašumą
Pagrindiniai metodai	- Logistinė regresija - Besprendžiujų medžiai (Decision Trees) - Random Forest - Neuronų tinklai	-K-means - Hierarchinė klasterizacija - DBSCAN - Gaussian Mixture Model (GMM)
Rezultatas	Konkretus objekto priskyrimas klasei	Skirtingų duomenų grupių (klasterių) išskyrimas
Pavyzdys	El. pašto filtro sistema: laišakai klasifikuojami kaip „šlamštas“ arba „ne šlamštas“	Klientų segmentavimas pagal pirkimo įpročius be iš anksto nustatytų grupių
Tinkamumas	Kai žinome kategorijas ir turime anotuotus duomenis	Kai norime atrasti paslėptas struktūras duomenyse

Išvada:

- **Klasifikacija** yra kaip „mokytojas“, kuris žino atsakymus ir mokina modelį priskirti objektus teisingai.
- **Klasterizacija** yra kaip „tyrinėtojas“, kuris atranda natūralias duomenų grupes be iš anksto nustatytų taisyklių.

Trumpai: Jei turime etiketes – klasifikacija. Jei ne – klasterizacija!

Dendrograma yra hierarchinės klasterizacijos vizualizavimo būdas, vaizduojantis, kaip duomenų taškai grupuojami į klasterius. Ji dažniausiai naudojama **hierarchiniame klasterizavime**, kai objektai yra sujungiami pagal jų panašumą.

Dendrogramų naudojimo paskirtis

1. **Klasterių skaičiaus nustatymas** – dendrograma padeda identifikuoti optimalią klasterių struktūrą, pasirenkant tinkamą pjūvį.
2. **Duomenų struktūros analizė** – leidžia suprasti, kaip duomenys natūraliai grupuojasi.
3. **Genetiniai tyrimai** – naudojama evoliuciniams medžiams ir genų giminingumui analizuoti.
4. **Rinkodaros segmentacija** – padeda nustatyti vartotojų grupes pagal jų elgseną ar demografinius rodiklius.
5. **Dokumentų arba tekstų klasifikacija** – grupuoja panašius tekstus pagal jų semantinį turinį.

Kaip skaityti dendrogramą?

- **Lapų mazgai** – atitinka atskirus duomenų taškus.
- **Šakos** – jungia susijusius elementus į klasterius.
- **Aukštis** – rodo atstumą arba skirtumus tarp grupių (kuo aukščiau šakos jungiasi, tuo objektai mažiau panašūs).
- **Pjūvio taškas** – galima nustatyti klasterių skaičių nubrėžiant horizontalią liniją ir skaičiuojant, kiek atskirų šakų gaunama.

Dendrogramos dažniausiai generuojamos naudojant **Ward's, single linkage, complete linkage** ar **average linkage** metodus, priklausomai nuo to, kaip skaičiuojami atstumai tarp klasterių.