


Raspberry Pi
Foundation

Experience AI

DI terminų žodynas



„Experience AI“. Terminų žodynas

Šiame žodyne paaiškinami pagrindiniai dirbtinio intelekto (DI) ir mašininio mokymosi (MM) terminai, vartojami [„Experience AI“](#) pamokose ir vėliau.

[Pereiti prie žodyno](#)

Šiuos paaiškinimus visų pirma sukūrėme mokytojams ir švietimo srities darbuotojams, atsižvelgdami į jauną auditoriją. Šiuo žodynu siekiame padėti jums geriau suprasti šiuos pagrindinius terminus ir įgyti techninių žinių.

Žodynelis yra svarbi mokymo ir mokymosi dalis. Tinkamai vartojant žodžių atsargas (žodynelį), besimokantiejiems gali būti lengviau gilinti žinias bei geriau suprasti dalyką, o žodynelį naudojant nenuosekliai, gali būti vartojamos klaidingos (neteisingai suprantamos) sąvokos, kas gali trukdyti mokiniams mokytis. Daugiau apie tai galite paskaityti [mūsų skirsnyje „Pedagogika. Glaustai apie klaidingas sąvokas“](#). Jei mokytojas taisyklingai ir nuosekliai vartoja kruopščiai parinktas techninių terminų žodžių atsargas (t. y., techninių terminų žodynelį), tai gali padėti plėtoti mokinių konceptualų supratimą.

Į pagalbą rengiant paaiškinimus mes pasitelkėme „semantinių bangų“ teoriją. Kiekvienas paaiškinimas parengtas pagal vieningą trijų dalių struktūrą: pirmoji dalis skirta abstraktesniam termino paaiškinimui, antrojoje dalyje išskleidžiama termino prasmė pateikiant įprastą pavyzdį, o trečiojoje dalyje abstraktesnėmis sąvokomis perteikiama tai, kas buvo paaiškinta pavyzdyje, kad terminus būtų galima vėl susieti su žodyneliu. Platesnį aprašymą galite rasti [mūsų skirsnyje „Pedagogika. Glaustai apie semantines bangas“](#).

Tai yra žodyno 1 redakcija. Šis žodynas bus papildomas, peržiūrimas ir atnaujinamas plėtojant „Experience AI“ pamokas.

Turinys

[DI projekto raidos ciklas \(AI project lifecycle\)](#)
[Dirbtinis intelektas \(Artificial intelligence\)](#)
[Duomenimis grindžiamas \(Data-driven\)](#)
[Duomenų šališkumas \(Data bias\)](#)
[Duomenų valymas \(Data cleaning\)](#)
[Duomenys \(Data\)](#)
[Gebėjimas naudotis DI \(AI Literacy\)](#)
[Generatyvinis DI \(Generative AI\)](#)
[Kompiuterinė rega \(Computer vision\)](#)
[Mašininis mokymasis \(Machine learning\)](#)
[MM klasė \(ML class\)](#)
[MM klasifikacija \(ML classification\)](#)
[MM modelio apmokymas \(ML training\)](#)
[MM modelio apmokymo duomenys \(ML training data\)](#)
[MM modelio kortelė \(ML model card\)](#)
[MM modelio prognozė \(ML model prediction\)](#)
[MM modelis \(ML model\)](#)
[MM paaiškinamumas \(ML explainability\)](#)
[MM patikimumas \(ML confidence\)](#)
[MM patikimumo riba \(ML confidence threshold\)](#)
[MM sprendimų medis \(ML decision tree\)](#)
[MM sprendimų medžio mazgas \(ML decision tree node\)](#)
[MM testavimo duomenys \(ML test data\)](#)
[MM tikslumas \(ML accuracy\)](#)
[MM ypatybė \(savybė, požymis\) - \(ML feature\)](#)
[MM žymeklis \(ML label\)](#)
[Neprižiūrimas mokymasis \(Unsupervised learning\)](#)
[Prižiūrimas mokymasis \(Supervised learning\)](#)
[Šališkumas \(Bias\)](#)
[Socialinis šališkumas \(Societal bias\)](#)
[Sustiprintas mokymasis \(Reinforcement learning\)](#)
[Taisyklėmis pagrįstas \(Rule-based\)](#)

DI projekto raidos ciklas (AI project lifecycle)

Sąvoka „**dirbtinio intelekto (DI)** projekto raidos ciklas“ apibrėžiami įvairūs veiksmai, kuriuos gali prireikti atlikti norint sukurti ir suformuoti **mašininio mokymosi (MM) modelį**. Veiksmai apima problemos (uždavinio) apibrėžimą, **duomenų** paruošimą, modelio **apmokymą**, testavimą, įvertinimą ir išaiškinimą. Pavyzdžiui, MM modelis skirtas naujiems dainų grojaraščiams kurti. MM kūrėjas pirmiausiai gali apgalvoti, kokio tipo grojaraštį nori sukurti. Tada jie gali rinkti ir paruošti dainų duomenis. MM modelis apmokomas ir ištestuojamas pasitelkiant dainų duomenis. MM modelis įvertinamas nustatant, ar jis veikia taip, kaip tikėtasi. Galiausiai MM modelis išaiškinamas, kad juo galėtų naudotis kiti. Paprastai DI projekto raidos ciklo veiksmai atliekami kartotinai, o ne vienas po kito. DI projekto raidos ciklas yra serija pasikartojančių veiksmų, atliekamų kuriant ir tobulinant MM modelį.

Dirbtinis intelektas (Artificial intelligence)

Dirbtinis intelektas (DI) yra sistemų, kurios, panašu, imituoja protingą elgesį, kūrimas ir tyrimas. Kai kurios DI taikomosios programos yra grindžiamos taisyklėmis. Dabartinais laikais DI taikomosios programos dažniau kuriamos pasitelkiant **mašininį mokymąsi**, kuris suteikia galimybę „mokyti“ iš pavyzdžių, pateikiamų **duomenų** pavidalu. Pavyzdžiui, kai kurios DI taikomosios programos sukurtos atsakyti į klausimus arba padėti diagnozuoti ligas. Kitos DI taikomosios programos gali būti sukurtos kenkėjiškais tikslais, pavyzdžiui, netikroms naujienoms (melagienoms) platinti. DI taikomosios programos negalvoja ir nemąsto. DI taikomosios programos sukurtos užduotims atlikti taip (tokiu būdu), kaip tai atrodo esą protinga.

Duomenimis grindžiamas (Data-driven)

Duomenimis grindžiamas metodas – tai sistemų kūrimo būdas, kuomet naudojami duomenys, užuot nuosekliai, papunkčiui pateikiant instrukcijas ar nurodymus. Pavyzdžiui, sunku žinoti, kas sukelia tam tikras ligas, tačiau yra daug pavyzdinių duomenų. Todėl atitinkamo modelio kūrėjai ligai diagnozuoti naudoja tokia liga sergančių žmonių medicininius duomenis. Duomenimis grindžiamos sistemos skiriasi nuo **taisyklėmis pagrįstų** sistemų. Duomenimis grindžiamos sistemos yra tinkamos spręsti problemoms (uždaviniams), kuomet sunku sukurti taisykles, taikytinas kiekvienai situacijai. Vietoj to, galima surinkti pakankamai pavyzdžių duomenimis grįstam sprendimui rasti.

Duomenų šališkumas (Data bias)

Sąvoka „duomenų šališkumas“ apibrėžiamas **šališkumas**, atsispindintis **duomenyse**, naudojamuose **apmokant mašininio mokymosi (MM) modelius**. Dėl duomenų šališkumo MM modeliai gali būti apmokomi šališkoms **prognozėms** generuoti. Pavyzdžiui, kai kurie veido atpažinimo modeliai yra šališki tam tikro odos atspalvio veidų atžvilgiu, nes MM modeliai buvo apmokomi naudojant daugiausia vieno odos atspalvio veidų atvaizdus. Yra kelios galimos priežastys ar veiksniai, dėl kurių atsiranda duomenų šališkumas. Taip gali nutikti dėl neišsamių duomenų ir duomenų, atspindinčių **socialinį šališkumą**. Svarbu aptikti duomenų šališkumą, kad MM modeliai negeneruotų šališkų prognozių.

Duomenų valymas (Data cleaning)

Duomenų valymas – tai veiksmas, atliekamas paruošiant **duomenis**, naudojamus **mašininio mokymosi (MM) modeliui apmokyti**. Duomenų valymas apima duomenų klaidų nustatymą ir taisymą. Pavyzdžiui, spausdinimo klaidų taisymas arba dublikatų pašalinimas iš tekstinių duomenų yra dvi paprastos duomenų valymo užduotys. Dažniausiai duomenys yra netvarkingi ir prieš juos naudojant MM modeliams apmokyti, būtina atlikti sudėtingesnį jų valymą. Yra daug būdų, kaip išvalyti duomenis, atsižvelgiant į problemą (uždavinį) ir duomenų tipą. Norint sukurti **tikslus** MM modelius, būtina naudoti švairius duomenis.

Duomenys (Data)

Sąvoka „duomenys“ apibrėžiamos vertės, matavimai, faktai ar pastebėjimai tokia forma, kuri yra tinkama apdoroti kompiuterinėmis programomis. Yra daugybė duomenų tipų, pavyzdžiui, tekstiniai, vaizdiniai ar garsiniai duomenys. Tekstinių duomenų pavyzdys yra pranešimai, kuriais žmonės keičiasi su draugais naudodami skaitmeninius įrenginius. **Mašininio mokymosi (MM)** srityje duomenys atspindi pavyzdžius, pasitelkiamus **apmokant MM modelius**. Didelio duomenų kiekio rinkimas, **valymas** ir struktūrizavimas yra esminė MM modelių kūrimo dalis.

Gebėjimas naudotis DI (AI Literacy)

Gebėjimas naudotis DI – tai kompetencijų ir mąstymo būdų, kurie žmonėms suteikia galimybę prasmingai bendradarbiauti (sąveikauti) su **dirbtinio intelekto (DI)** taikomosiomis programomis bei veikti situacijose, kuriose tokių žmonių aplinkoje naudojamos DI taikomosios programos, rinkinys. Tokios kompetencijos apima nusimanymą apie DI, dalyvavimą kuriant DI sistemas ir informacija paremtos nuomonės apie DI sistemų naudojimo būdus pasaulyje turėjimą. Pavyzdžiui, žmogus pasitelkia gebėjimą naudotis DI, kai vertina DI pokalbių roboto taikomosios programos pateiktos informacijos tikslumą. Be įvairių būdų, kaip dirbti su DI taikomosiomis programomis, gebėjimas naudotis DI apima žmonių galimybę aktyviai dalyvauti sprendžiant, kaip DI sistemos galėtų būti pasitelkiamos jų aplinkoje.

Generatyvinis DI (Generative AI)

Generatyvinis DI yra **dirbtinio intelekto (DI)**, skirto turiniui, pvz., tekstiniam, vaizdiniam ar garsiniam, kurti (generuoti), tipas. Yra daugybė taikomųjų programų, naudojančių generatyvinį DI, įskaitant meno ar muzikos kūrimą arba teksto generavimą pokalbių robotams. Pavyzdžiui, generatyvinio DI meno taikomosios programos gali generuoti vaizdą pagal raginimą, pvz., „sukurk man knygą skaitančio drakono paveikslą“. Generatyviniu DI menas kuriamas naudojant **mašininio mokymosi modelius, apmokytus** pasitelkiant milijonus realiai egzistuojančių meno kūrinių vaizdų. Gautuose vaizduose gali būti atkartotas menininko stilius tikrajam menininkui to nežinant ir jam nepatvirtinus. Generatyvinio DI taikomosios programos tampa vis įprastesnės ir dažnai neįmanoma atspėti, jog naudojamas generatyvinis DI.

Kompiuterinė rega (Computer vision)

Kompiuterinė rega yra sistemų, skirtų informacijai iš skaitmeninių vaizdų ar vaizdo įrašų apdoroti, tyrimas. Kompiuterinės regos taikymo pavyzdžiai apima veido atpažinimą, medicininį vizualizavimą ir stebėjimą vaizdo kameromis. Pavyzdžiui, kompiuterinė rega naudojama projektuojant savivaldžius automobilius, kad būtų galima aptikti objektus ir išvengti su jais susidūrimo. Dažniausiai kompiuterinės regos sistemos naudoja **mašininio mokymosi modelius**, kad nustatytų vaizdų ir vaizdo įrašų duomenų šablonus. Kompiuterinės regos sistemos praverčia, kai informaciją iš skaitmeninių vaizdų ar vaizdo įrašų galima naudoti problemai (uždaviniui) išspręsti.

Mašininis mokymasis (Machine learning)

Mašininis mokymasis (MM) – tai metodas, taikomas **dirbtinio intelekto (DI)** sistemoms kurti. Teigiama, kad MM „mokosi“ naudodamas pavyzdžius **duomenų** pavidalu, o ne vykdydamas nuosekliai, papunkčiui pateikiamas instrukcijas ar nurodymus. Kitaip tariant, MM taikomosios programos yra **grindžiamos duomenimis**. Pavyzdžiui, kalbėsenai atpažinti naudojama MM taikomoji programa. Ji paremta daugybe pavyzdžių, kai žmonės kalba skirtingais akcentais ir balsu tonais. Kitos MM taikomosios programos apima objektų identifikavimą vaizduose arba žaidžiant sudėtingus žaidimus. Kiekviena MM taikomoji programa skirta konkrečiai problemai (uždaviniui) spręsti.

MM klasė (ML class)

Siekdami **apmokyti klasifikacijos modelius, mašininio mokymosi (MM)** modelių kūrėjai susistemina **duomenis** suskirstydami juos į iš anksto apibrėžtas grupes, vadinamas klasėmis. Klasės apibrėžiamos iš anksto, atsižvelgiant į tai, kas žmonėms atrodo naudinga sugrupuojant dalykus į. Įsivaizduokite MM taikomąją programą, skirtą vaisiams identifikuoti prekybos centre. Duomenys gali būti susisteminti juos suskirstant į obuolių, bananų, apelsinų, mėlynų ir kt. klases. Klasė yra dalykų grupė, kurią klasifikavimo modeliai naudoja duomenų panašumui nustatyti.

MM klasifikacija (ML classification)

Sąvoka „klasifikacija“ („klasifikavimas“) apibrėžiama užduotis priskirti dalykus į iš anksto nustatytas grupes, vadinamas **klasėmis**. Klasės apibrėžiamos iš anksto, atsižvelgiant į tai, kas žmonėms atrodo naudinga, norint sugrupuoti dalykus. Klasifikavimo uždavinio pavyzdys yra dainų apžvalgų sentimentų analizė. **Mašininio mokymosi (MM)** klasifikacijos **modelis apmokomas** pasitelkiant apžvalgas (atsiliepimus, recenzijas), kurias žmonės **pažymi** kaip „teigiamas“ arba „neigiamas“. Apmokius, MM modelis gali būti pasitelkiamas **prognozuoti**, ar nauja apžvalga (atsiliepimas, recenzija) turėtų būti klasifikuojama kaip „teigiama“, ar kaip „neigiama“. Klasifikacijos modelis prognozuoja vienos ar kelių klasių žymeklius. Klasifikacijos metodas yra naudingas sprendžiant problemas (uždavinius), kai atsakymas patenka į iš anksto nustatytas grupes.

MM modelio apmokymas (ML training)

Mašininio mokymosi (MM) modeliai apmokomi rasti šablonus ir generuoti **prognozes**, apmokymui pasitelkiant pavyzdžius **duomenų** pavidalu. Apmokymo metu šablonai ypač kruopščiai koreguojami, kad prognozės būtų kuo tikslesnės. Pavyzdžiui, MM kūrėjas gali sukurti modelį dainoms rekomenduoti. MM modelis bus apmokomas rasti panašumų tarp tų kūrinių, kuriuos skirtingi žmonės mėgsta klausytis, remiantis daugelio žmonių pasirenkamomis dainomis. Kuo įvairesnis dainų rinkinys pasitelkiamas modeliui apmokyti, tuo geresnė, tikėtina, bus rekomenduojamos dainos prognozė. Yra daug skirtingų MM modelių apmokymo būdų naudojant skirtingų tipų duomenis. Kūrėjas iš galimų apmokymo tipų išsirinks tinkamiausią atsižvelgdamas į problemą (uždavinį), kurią (kurį) bando išspręsti, ir į turimus duomenis jai (jam) išspręsti. Apmokymo kokybė labai priklauso nuo naudojamų duomenų kokybės.

MM modelio apmokymo duomenys (ML training data)

Mašininio mokymosi (MM) srityje sąvoka „apmokymo duomenys“ apibrėžiami pavyzdžiai **duomenų** pavidalu, naudojami MM **modeliams apmokyti**. MM kūrėjai kuria modelius apmokymo duomenų šablonams, kuriuos galima naudoti generuojant **prognozes** apie naujus duomenis, sudaryti. Pavyzdžiui, MM modelio kūrėjas sukuria kalbėsenos atpažinimo taikomąją programą. Apmokymo duomenys gali apimti daugybę žmonių kalbėsenos pavyzdžių, kuomet kalbama skirtingais akcentais ar balso tonais. Kuo labiau apmokymo duomenys atspindi tikrovę, tuo našiau modelis turėtų veikti.

MM modelio kortelė (ML model card)

Mašininio mokymosi (MM) modelio kortelė yra būdas struktūriškai pagrįsti dokumentais esminę informaciją apie MM **modelius**. MM modelių korteles MM kūrėjai rengia ir ekspertams, ir neekspertams. Pavyzdžiui, MM taikomoji programa sukurta įvairioms kalboms versti, kaip antai, iš arabų į prancūzų ir atvirkščiai. Modelio kortelėje pateikiama informacija apie modelio vertimo **tikslumą** bei apie modelio veikimo našumą vartojant žargoną, slengą, tarmes ir dialektus. Kita modelio kortelės informacija gali apimti MM modelio tipą, skirtingus veikimo našumo rodiklius ir net žinomą **šališkumą**. Modelių kortelės sukuriamos per **DI projekto raidos ciklo** paaiškinimo etapą, siekiant kuo suprantamiau pateikti informaciją apie modelio galimybes ir apribojimus.

MM modelio prognozė (ML model prediction)

Mašininio mokymosi (MM) modeliai yra **apmokomi** prognozėms generuoti. MM modelio sugeneruota prognozė daro užuominą apie tai, ką atspindi **duomenys** arba kas gali būti naudinga atliekant užduotį. Pavyzdžiui, MM kūrėjas gali apmokyti modelį pagal žmogaus filmų žiūrėjimo įpročius prognozuoti, kurį kitą kino filmą žmogus galimai norėtų žiūrėti toliau. Modelis sugeneruos prognozę po to, kai bus apmokytas prognozuoti pagal daugelio žmonių kino filmų pasirinkimo

„skonį“. Pagrindinė MM modelio užduotis – generuoti prognozes. Visi MM modeliai generuoja prognozes, net jei kai kuriais atvejais šios prognozės naudotojui nėra akivaizdžios.

MM modelis (ML model)

Mašininio mokymosi (MM) modelis naudojamas MM taikomojoje programoje užduočiai atlikti arba problemai (uždaviniui) išspręsti. MM modelis yra sprendžiamos problemos (uždavinio) atvaizdavimo priemonė. MM kūrėjai naudoja didelius konkrečiai problemai būdingų **duomenų** kiekius, kad **apmokytų** modelį aptikti tam tikras tendencijas. Apmokymo rezultatas – modelis, kuris yra naudojamas **prognozėms** apie naujus duomenis tame pačiame kontekste generuoti. Pavyzdžiui, savivaldžiai automobiliai kuriami naudojant MM modelius, skirtus prognozuoti, kada automobiliui sustoti. Tokiu atveju modeliai apmokomi pasitelkiant milijonus situacijų, kai automobiliai turi sustoti, pavyzdžių. Yra daug įvairių modelių tipų, naudojami įvairūs duomenys ir pasitelkiami įvairūs modelių apmokymo būdai. Visi MM modeliai apmokomi **apmokymo duomenyse** aptikti šablonus (angl. „patterns“) prognozėms apie naujus duomenis generuoti.

MM paaiškinamumas (ML explainability)

Sąvoka „paaiškinamumas“ apibrėžiamas mastas, kiek kažką galima suprasti. **Mašininio mokymosi (MM)** srityje paaiškinamumas padeda žmonėms suprasti, kaip buvo sugeneruota **prognozė**. Pavyzdžiui, MM **sprendimų medžio modeliai** yra paaiškinami, nes **mazgai** gali būti analizuojami žmonėms suprantamu būdu. Dauguma MM modelių nėra visiškai paaiškinami, o kai kurie yra labiau paaiškinami nei kiti. Padidinant modelio paaiškinamumą, tai gali padėti išspręsti problemas (uždavinius) ir kovoti su **šališkumu**.

MM patikimumas (ML confidence)

Sąvoka „patikimumas“ apibrėžiama tai, kiek kažkas yra tikra. **Mašininio mokymosi (MM)** srityje patikimumas yra būdas **prognozės** tikrumui, neabejotinumui įvertinti. Pavyzdžiui, **klasifikacijos modelis** yra sukurtas prognozuoti, ar rytoj lis. Modelis su 90 proc. patikimumu prognozuoja, kad rytoj bus lietaus. Kitaip tariant, yra 90 proc. tikrumo, kad rytoj lis. Pasitikėjimo naudojimas prognozių tikrumui įvertinti padeda įvertinti MM modelio kokybę.

MM patikimumo riba (ML confidence threshold)

Sąvoka „patikimumo riba“ apibrėžiama verčių aibė, kaip **mašininio mokymosi (MM) modelio prognozių** priimtimumo lygmuo. Patikimumo ribą pasirenka MM kūrėjas, kurdamas MM modelį. Pavyzdžiui, MM modelis sugeneruoja prognozę su 50 proc. **patikimumu**, kad rytoj bus pūga. Tačiau jei patikimumo riba nustatyta 60 proc., ši prognozė bus laikoma netiksli. Kitaip tariant, jei prognozės patikimumas nėra 60 proc. ar didesnis, jis nebus priimtas kaip **tikslus**. Vertė nustatoma atsižvelgiant į sprendžiamos problemos (uždavinio) pobūdį, o medicininių diagnozių prognozėms reikalinga didesnė patikimumo riba nei rekomendacijų dėl dainų atveju. Ribinės vertės pasirinkimas lemia, koks yra priimtinas prognozės patikimumo lygis.

MM sprendimų medis (ML decision tree)

Mašininio mokymosi (MM) sprendimų medis yra vienas iš MM modelių tipų. MM kūrėjai naudoja sprendimų medžius, kad sukurtų sąlygų rinkinį, kuriuo remiantis galima sugeneruoti **prognozę**. Sąlygos gaunamos iš **duomenyse** pateiktų **savybių, požymių ar ypatybių**. Pavyzdžiui, sprendimų medis gali būti naudojamas kuriant kino filmų rekomendacijų sistemą. Sprendimų medžio modelis yra **apmokomas** pasitelkiant daugelio žmonių teikiamą pirmenybę tam tikriems kino filmams. Apmokymo metu sąlygos sukuriamos atsižvelgiant į tokias savybes kaip filmo tipas, trukmė arba pagrindinis aktorius. MM modelis generuoja prognozę apie tai, kurį filmą kažkas norėtų žiūrėti toliau, remiantis tuo, kaip žmogaus teikiama pirmenybė atitinka modelyje nustatytas sąlygas. MM sprendimų medžių struktūra kuriama remiantis didžiuliais duomenų kiekiais ir gali pasikeisti, MM pakartotinai apmokyti naudojant skirtingus duomenis.

MM sprendimų medžio mazgas (ML decision tree node)

Mašininio mokymosi (MM) sprendimų medis sudarytas iš mazgų. Mazgai yra susieti, kad sudarytų struktūrą, kurios pagrindu galima sugeneruoti **prognozę**. Yra dviejų tipų mazgai: sprendimų ir lapų mazgai. Pavyzdžiui, įsivaizduokite sprendimų medį, sukurtą žvaigždžių tipams mūsų Saulės sistemoje nuspėti (prognozuoti). Sprendimų mazgai atspindi **duomenų** savybes, požymius ar ypatybes, kaip antai, temperatūra, spindulys, spalva arba žvaigždžių ryškumas. Lapų mazgai atspindi žvaigždžių tipus prognozės **žymeklių** pavidalu, pvz., „raudonoji nykštukė“, „baltoji nykštukė“ arba „rudoji nykštukė“. Sprendimų medžio mazgai sudaro struktūrą, reikalingą MM modeliui, kad šis sugeneruotų prognozę.

MM testavimo duomenys (ML test data)

Mašininio mokymosi (MM) srityje sąvoka „testavimo duomenys“ apibrėžiami **duomenys**, naudojami **apmokytiems** MM modeliams ištestuoti ir įvertinti. Pavyzdžiui, MM modelis yra apmokomas sveikatos sutrikimo diagnozei **prognozuoti**. Prieš pradėdant naudoti realiose situacijose, modelis yra ištestuojamas ir įvertinamas pasitelkiant testavimo duomenis. Testavimo duomenys yra atskirti nuo **apmokymo duomenų**, naudojamų MM modeliui apmokyti. Testavimo duomenys naudojami MM modelio veikimui įvertinti, be apmokymo duomenų papildomai pasitelkiant ir pavyzdžius.

MM tikslumas (ML accuracy)

Sąvoka „tikslumas“ apibrėžiama tai, kiek kažkas yra teisinga. **Mašininio mokymosi (MM)** srityje tikslumas – tai būdas įvertinti, kaip dažnai MM modelis teisingai **prognozuoja**. Pavyzdžiui, **klasifikacijos** modelis yra skirtas obuoliams klasifikuoti. Iš 100 obuolių vaizdų 90 klasifikuojami teisingai. Modelio klasifikavimo tikslumas yra 90 proc. Tikslumas yra vienas iš būdų MM modeliams įvertinti. Dažniausiai modelio kokybei įvertinti tikslumas naudojamas kartu su kitomis priemonėmis.

MM ypatybė (savybė, požymis) - (ML feature)

Mašininio mokymosi (MM) srityje ypatybės (požymiai, savybės) atspindi charakteristikas, susijusias su **duomenimis**. Pavyzdžiui, muzikos duomenų rinkinyje gali būti pateiktos tokios ypatybės kaip tempas, aukštis, energija arba žanras. Kai kurie MM **modeliai** yra **apmokomi** pasitelkiant ypatybes (požymius, savybes) duomenų panašumams rasti. Kiti **numato** (prognozuoja) naujas duomenų ypatybes (požymius, savybes), kurių žmonės lengvai nepastebi. Atitinkamų ypatybių (požymių, savybių), pasitelkiamų apmokant MM modelį, pasirinkimas gali lemti modelio veikimo kokybę.

MM žymeklis (ML label)

Prižiūrimo mokymosi atveju **mašininio mokymosi (MM) modelis apmokomas** pasitelkiant pažymėtus **duomenis**. Kiekvienas duomenų elementas yra pažymėtas viena ar keliomis etiketėmis, kuriose pateikiama informacija apie tuos duomenis. Pavyzdžiui, egzistuoja MM modelis, skirtas paukščių garsams atpažinti. Kiekvienas garsas pažymėtas šį garsą skleidžiančio paukščio pavadinimu. MM modelis apmokomas pasitelkiant pažymėtus garsus ir gali **prognozuoti** naujų garsų žymeklį (paukščio pavadinimą). Duomenis paprastai pažymi žmonės, kad pateiktų tikslius pavyzdžius, kuriais remiantis apmokomi MM modeliai.

Neprižiūrimas mokymasis (Unsupervised learning)

Neprižiūrimas mokymasis – tai vienas iš metodų, taikomų **mašininio mokymosi (MM) modeliams apmokyti**. MM kūrėjai apmoko neprižiūrimo mokymosi modelius sisteminti **duomenis** pagal panašumus. Šis procesas skirtas paslėptiems šablonams duomenyse aptikti. Vienas iš neprižiūrimo mokymosi tipų yra grupavimas blokais (klasteriais). Grupavimo blokais (klasteriais) uždavinio pavyzdys yra **prognozavimas**, kaip galima sugrupuoti sveikatos duomenis, kad būtų lengviau diagnozuoti ligas. Šios grupės vadinamos blokais (klasteriais), kurie nėra žinomi iš anksto. MM modelis gali būti naudojamas prognozuoti, ar nauji sveikatos duomenys patenka į vieną iš blokinių (klasterių). Neprižiūrimo mokymosi metodai gali būti pravartūs sprendžiant problemas (uždavinius), kuomet žmonės gali nežinoti, ko ieškoti.

Prižiūrimas mokymasis (Supervised learning)

Prižiūrimas mokymasis – tai vienas iš metodų, taikomų **mašininio mokymosi (MM) modeliams apmokyti**. Prižiūrimo mokymosi metodams būdinga tai, jog naudojamas didelis kiekis **duomenų**, žmonių **pažymėtų** atitinkama informacija. Vienas iš prižiūrimo mokymosi tipų yra **klasifikacija**. Klasifikacijos uždavinio pavyzdys – tigrų atpažinimas natūralioje aplinkoje. Duomenys susideda iš daugelio vaizdų, kuriuose yra pažymėti tigrai.

MM modelis apmokomas naudojant pažymėtus vaizdus ir jis **prognozuoja**, ar tuose vaizduose yra tigras. Teisingai pažymėti vaizdai suteikia galimybę kūrėjui žinoti, kiek modelio prognozės yra **tikslios** ir atitinkamai pritaikyti modelio apmokymą. Po to MM modelis gali būti naudojamas

prognozuoti, ar visiškai naujuose vaizduose yra tigras. Prižiūrimo mokymosi metodai priklauso nuo to, ar yra pakankamai teisingai pažymėtų duomenų, kad būtų galima generuoti tikslias prognozes.

Šališkumas (Bias)

Sąvoka „šališkumas“ apibrėžiama pirmenybė, teikiama kažkam arba prieš ką nors. Pavyzdžiui, mokinys gali teikti pirmenybę anglų kalbos pamokoms, o ne matematikos pamokoms, ir skirti daugiau laiko anglų kalbos namų darbams. Kitaip tariant, mokinys yra linkęs mokytis anglų kalbos dalyką (t. y. yra šališkas šiam dalykui). Yra daug šališkumo tipų, įskaitant **socialinį šališkumą** ir **duomenų šališkumą**. **Mašininio mokymosi (MM)** kūrėjai turi kruopščiai apgalvoti, ar **duomenys**, kuriuos jie pasitelkia **MM modeliams apmokyti**, yra šališki, ar ne. Šališkumo atveju, asmeniui, grupei arba tam tikroms idėjoms ar įsitikinimams gali būti suteiktas pranašumas, palyginti su kitu.

Socialinis šališkumas (Societal bias)

Socialinis šališkumas reiškia **šališkumą**, būdingą didelei žmonių grupei arba visai visuomenei plačiąja prasme. Egzistuoja daug įvairių socialinio šališkumo tipų, tokių kaip rasinis, lyties ar etnis šališkumas. Lyčių šališkumo pavyzdys yra mintis, kad moterys yra mažiau tinkamos inžinerijos profesijoms nei vyrai. **Duomenys**, surinkti iš didelių žmonių grupių, gali atspindėti socialinio šališkumo apraiškas, lemiančias **duomenų šališkumą**. Jei duomenys, atspindintys socialinį šališkumą, naudojami **mašininio mokymosi (MM) modeliams apmokyti**, modeliai gali pradėti generuoti šališkas **prognozes**. Siekiant išvengti diskriminacinių ar neteisingų rezultatų, MM srityje svarbu sušvelninti socialinio šališkumo apraiškas, atsispindinčias **apmokymo duomenyse**.

Sustiprintas mokymasis (Reinforcement learning)

Sustiprintas mokymasis yra vienas iš metodų, taikomų **mašininio mokymosi (MM) modeliams** apmokyti. Šis metodas pasitelkiamas problemoms (uždaviniams) spręsti turint aiškų tikslą, kai tam tikslui pasiekti taikoma atpildo ir nuobaudų skyrimo sistema. Sustiprinto mokymosi metodai taikomi kuriant bei projektuojant savivaldžius automobilius arba programas sudėtingiems žaidimams žaisti. Pavyzdžiui, sustiprinto mokymosi modelis gali būti naudojamas kuriant taikomąją programą, skirtą žaisti šachmatais. Modelis yra apmokomas **prognozuoti** ėjimus, taip padidinant atpildo atvejus ir sumažinant nubaudų skyrimo atvejus, lemiančius partijos laimėjimą. Sustiprinto mokymosi metoduose pasitelkiama atpildo ir nuobaudų skyrimo sistema, kad būtų galima nustatyti strategijas užsibrėžtam tikslui pasiekti.

Taisyklėmis pagrįstas (Rule-based)


Taisyklėmis pagrįstas – tai būdas kurti sistemas pasitelkiant iš anksto apibrėžtų taisyklių rinkinį. Pavyzdžiui, programa „kryžiukai – nuliukai“ (tic-tac-toe) sukurta taikant taisykles, nustatančias, kokius ėjimus reikia atlikti norint pamėginti laimėti žaidimą. Taisykles nustato žmonės, kurie paprastai yra sprendžiamos problemos (uždavinio) srities ekspertai. **Dirbtinio intelekto (DI)** sistemos, sukurtos taikant taisyklėmis grindžiamą metodą, taip pat žinomos kaip „geras

senamadiškas DI“. Taisyklėmis pagrįstos sistemos skiriasi nuo **duomenimis grindžiamų** sistemų, kai **duomenys** naudojami kaip problemos (uždavinio) sprendimo pavyzdžiai. Taisyklėmis pagrįstos sistemos yra naudingos sprendžiant problemas (uždavinius), kai galima sukurti ir laikytis daugumai situacijų taikomų taisyklių.




Šiai mokomajai priemonei licenciją suteikė [„Raspberry Pi Foundation“](#) pagal „Creative Commons Attribution-NonCommercial-NoDerivatives 4.0“ tarptautinę viešąją licenciją (CC BY-NC-ND 4.0). Daugiau informacijos apie šią licenciją žr. creativecommons.org/licenses/by-nc-nd/4.0.

Experience AI



Šį žodyną sukūrė „Raspberry Pi Foundation“ kaip mūsų edukacinės programos „Experience AI“ dalį. Išsamesnės informacijos rasite adresu www.experience-ai.org

Šiam šaltiniui licenciją suteikė „Raspberry Pi Foundation“ pagal „Creative Commons Attribution-NonCommercial-NoDerivatives 4.0“ tarptautinę viešąją licenciją (CC BY-NC-ND 4.0). Daugiau informacijos apie šią licenciją žr. creativecommons.org/licenses/by-nc-nd/4.0.



Raspberry Pi
Foundation