


Raspberry Pi
Foundation

Experience AI

Rječnik pojmova
umjetne inteligencije



Experience AI – Rječnik pojmova

Ovaj rječnik pojmova objašnjava ključne pojmove umjetne inteligencije (UI) i strojnog učenja (ML) korištene u [Lekcijama Experience AI](#) i više toga.

[Nastavi na rječnik pojmova](#)

Ova objašnjenja osmislili smo prvenstveno za učitelje, učiteljice i edukatore, imajući na umu mladu publiku. Ovim rječnikom pojmova želimo vam pomoći da poboljšate svoje razumijevanje ovih ključnih pojmova, kao i svoje tehničko znanje.

Vokabular je važan dio poučavanja i učenja. Ispravna upotreba vokabulara može pomoći učenicima da razviju svoje razumijevanje, dok njegova nedosljedna upotreba može dovesti do alternativnih koncepcija (pogrešnih shvaćanja) koje mogu ometati učenje učenika. Više o tome možete pročitati u [našoj Pedagogiji Kratkom štivu o alternativnim koncepcijama](#). Kao učiteljica ili učitelj, redovito i dosljedno korištenje točnog, tehničkog vokabulara može podržati konceptualno razumijevanje učenika.

U pisanju objašnjenja koristili smo teoriju 'semantičkih valova'. Svako objašnjenje slijedi istu trodijelnu strukturu: prvi je dio apstraktnije objašnjenje pojma, drugi dio analizira značenje pojma koristeći uobičajeni primjer, a treći dio ponovno objašnjava ono što je objašnjeno u primjeru na apstraktniji način kako bi se ponovno povezalo s vokabularom. Više možete saznati u [našoj Pedagogiji Kratkom štivu o semantičkim valovima](#).

Ovo je prva verzija rječnika pojmova. Ovaj će se rječnik pojmova dodavati, revidirati i ažurirati zajedno s razvojem lekcija Experience AI.

Sadržaj

[Čišćenje podataka](#)
[Čvor stabla odlučivanja ML-a](#)
[Društvena pristranost](#)
[Generativna UI](#)
[Kartica modela ML-a](#)
[Klasa strojnog učenja](#)
[Klasifikacija ML-a](#)
[Model ML-a](#)
[Nadzirano učenje](#)
[Nenadzirano učenje](#)
[Objašnjivost ML-a](#)
[Oznaka ML-a](#)
[Pismenost u području umjetne inteligencije](#)
[Podaci za treniranje strojnog učenja](#)
[Podaci](#)
[Podržano učenje](#)
[Pouzdanost ML-a](#)
[Prag pouzdanosti ML-a](#)
[Predviđanje strojnim učenjem](#)
[Pristranost podataka](#)
[Pristranost](#)
[Računalni vid](#)
[Stablo odlučivanja ML-a](#)
[Strojno učenje](#)
[Temeljeno na podacima](#)
[Temeljeno na pravilima](#)
[Testni podaci ML-a](#)
[Točnost strojnog učenja](#)
[Treniranje strojnog učenja](#)
[Umjetna inteligencija](#)
[Životni ciklus projekta umjetne inteligencije](#)
[Značajka ML-a](#)

Čišćenje podataka

Čišćenje podataka odnosi se na pripremu **podataka** koji se upotrebljavaju za **treniranje modela strojnog učenja (ML)**. Čišćenje podataka uključuje prepoznavanje i popravljavanje grešaka u podacima. Na primjer, ispravljanje tipfelera ili uklanjanje duplikata u tekstualnim podacima dva su primjera jednostavnih zadataka čišćenja podataka. Najčešće su podaci neuredni i zahtijevaju kompleksnije čišćenje prije nego ih se može upotrebljavati za treniranje modela ML-a. Ima mnogo načina za čišćenje podataka ovisno o problemu i vrsti podataka. Upotreba čistih podataka je temelj za izgradnju **točnih** modela ML-a.

Čvor stabla odlučivanja ML-a

Stablo odlučivanja strojnog učenja (ML) sastoji se od čvorova. Čvorovi su povezani da bi stvorili strukturu na temelju koje se može generirati **predviđanje**. Postoje dvije vrste čvorova: čvorovi odluka i listni čvorovi. Na primjer, uzmete u obzir stablo odlučivanja izgrađeno za predviđanje vrsta zvijezda u našem solarnom sustavu. Čvorovi odluka predstavljaju **značajke podataka** kao što je temperatura, promjer, boja ili svjetlina zvijezda. Listovni čvorovi predstavljaju vrste zvijezda u obliku **oznaka** predviđanja, kao što je 'Crveni patuljak', 'Bijeli patuljak' ili 'Smeđi patuljak'. Čvorovi stabala odlučivanja tvore strukturu koja je potreban da bi **model** ML-a mogao generirati predviđanje.

Društvena pristranost

Društvena pristranost odnosi se na **pristranost** koju ima velika skupina ljudi ili društvo kao cjelina. Postoji mnoštvo različitih vrsta društvenih pristranosti, kao što je rasna pristranost, rodna pristranost ili etnička pristranost. Primjer društvene pristranosti jest ideja da su žene manje prikladne za karijere u području inženjerstva od muškaraca. **Podaci** prikupljeni od velikih skupina ljudi mogu zrcaliti društvenu pristranost, što će rezultirati u **pristranosti podataka**. Ako podaci koji zrcale društvenu pristranost se upotrebljava za **treniranje modela strojnog učenja (ML)**, to može dovesti do toga da će modeli generirati pristrana **predviđanja**. U ML-u, bitno je ublažiti društvene pristranosti koje se nalaze u **podacima za treniranje** da bi se izbjegli diskriminatorni ili nepravedni ishodi.

Generativna UI

Generativna UI je vrsta **umjetne inteligencije (UI)** koja je dizajnirana za generiranje sadržaja kao što je tekst, slike ili zvuk. Postoji mnoštvo aplikacija koje upotrebljavaju generativni UI, uključujući proizvodnju umjetnosti ili glazbe ili generiranje teksta za chatbotove. Na primjer aplikacije generativne UI umjetnosti mogu generirati sliku na temelju upita kao što je „napravi mi sliku zmaja koji čita knjigu”. Generativna UI umjetnost kreira se upotrebom **modela strojnog učenja** koje su **trenirane** na milijunima slika postojeće umjetnosti. Slike koje su rezultat toga mogu replicirati stil umjetnika, bez da originalni umjetnik to zna ili odobri. Aplikacije generativne UI postaju sve više i više uobičajene i često ne možete ni primijetiti da se upotrebljava generativna umjetna inteligencija.

Kartica modela ML-a

Kartica modela **strojnog učenja (ML)** je način dokumentiranja najbitnijih informacija o **modelima** ML-a strukturiran način. Kartice modela ML-a pišu razvojni programeri ML-a za stručnjake i nestručnjake. Na primjer, aplikacija ML-a razvija se za prevođenje različitih jezika, kao što je s arapskog na francuski i obrnuto. Kartica modela uključuje informaciju o **točnosti** prijevoda modela, kao i učinkovitost modela što se tiče žargona, slenga i narječja. Ostale informacije kartice modela mogu uključivati vrstu modela model ML-a, različiti indikatori učinkovitosti te čak poznate **pristranosti**. Kartice modela kreiraju se tijekom stupnja objašnjavanja **životnog ciklusa projekta UI** da bi se prikazale informacije o sposobnostima i ograničenjima modela na lako razumljiv način.

Klasa strojnog učenja

Za **treniranje klasifikacijskih modela, strojnog učenja (ML)** programeri organiziraju **podatke** u unaprijed definirane skupine koje se nazivaju klase. Klase se definiraju unaprijed na temelju onoga što ljudi smatraju korisnim za grupiranje stvari u. Zamislite aplikaciju strojnog učenja osmišljenu za identifikaciju voća u supermarketu. Podaci se mogu klasificirati u klase jabuka, banana, naranči, borovnica itd. Klasa jest skupina stvari koje upotrebljavaju klasifikacijski modeli za prepoznavanje sličnosti u podacima.

Klasifikacija ML-a

Klasifikacija se odnosi na zadatak dodjeljivanja stvari predefinirane grupe, koje se zovu **klase**. Klase se definiraju unaprijed na temelju onoga što ljudi smatraju korisnim grupi stvari. Primjer klasifikacijskog problema jest analiza sentimenta recenzija pjesama. **Model strojnog učenja (ML)** klasifikacije **jetreniran** pomoću recenzija **koje su ljudi označili** kao 'pozitivne' ili 'negativne'. Nakon treniranja, model ML-a može se upotrebljavati za **predviđanje** je li neka recenzija klasificirana kao 'pozitivna' ili 'negativna'. Klasifikacijski model predviđa jednu ili više oznaka klase. Klasifikacijski pristup je koristan za rješavanje problema kada se odgovor može uvrstiti u predefinirane grupe.

Model ML-a

Model **strojnog učenja (ML)** upotrebljava aplikacija ML-a za izvršavanje ili rješavanje nekog problema. Model ML-a je reprezentacija problema koji se rješava. Razvojni programeri ML-a upotrebljavaju ogromnu količinu **podataka** koji predstavlja određeni problem za **treniranje** modela za prepoznavanje uzoraka. Rezultat treniranja jest model koji se upotrebljava za **predviđanje** o novim podacima u istom kontekstu. Na primjer, autonomni automobili proizvedeni su upotrebom modela ML-a za predviđanje kada je potrebno zaustavljanje. Modeli se treniraju upotrebom milijuna primjera situacija u kojima je potrebno da se automobili zaustave. Postoji mnoštvo različitih vrsta modela, upotrebom različitih vrsta podataka i različitih vrsta treniranje modela. Svi modeli ML-a trenirani su za prepoznavanje uzoraka u **podacima za treniranje** za predviđanje o novim podacima.

Nadzirano učenje

Nadzirano učenje je pristup koji se upotrebljava za **treniranje modela strojnog učenja (ML)**. Pristupi nadziranog učenja upotrebljavaju velike količine **podataka koji su označili** ljudi relevantnim informacijama. Jedna vrsta nadziranog učenja je **klasifikacija**. Primjer klasifikacijskog problema jest identifikacija tigrova u divljini. Podaci se sastoje od mnoštva slika, s onima koji sadržavaju tigrove označenima.

Model ML-a treniran je označenim slikama i **predviđa** je li tigar na tim slikama. Točno označavanje slika omogućilo je razvojnom programeru da zna do koje su mjere predviđanja modela **točna** i prilagoditi treniranje modela. Nakon toga model ML-a može se upotrijebiti za predviđanje ima li tigre u potpuno novim slikama. Pristupi nadziranog učenja ovise o dovoljnoj količini ispravno označenih podataka za pravljenje točnih predviđanja.

Nenadzirano učenje

Nenadzirano učenje je jedan od pristupa za **treniranje modela strojnog učenja**. Razvojni programeri treniraju modele nenadziranog učenja za organizaciju **podataka** na temelju sličnosti. Tim se postupkom dobiva pronalaženje skrivenih uzoraka u podacima. Jedna vrsta nenadziranog učenja je grupiranje. Primjer grupiranja problema je **predviđanje** kako se zdravstveni podaci mogu grupirati za pomoć pri dijagnozi bolesti. Te se skupine nazivaju klasteri, koji nisu unaprijed poznati. Model ML-a može se upotrijebiti za predviđanja pripada li novi zdravstveni podatak jednom od klastera. Pristupi nenadziranog učenja mogu biti korisni pri rješavanju problema pri kojima ljudi možda ne znaju na što obratiti pozornost.

Objašnjivost ML-a

Objašnjivost se odnosi na opseg do kojeg se nešto može razumjeti. U **strojnom učenju (ML)**, objašnjivost pomaže ljudima razumjeti kako je proizvedeno neko **predviđanje**. Na primjer, **modeli stabla odlučivanja** ML-a mogu se objasniti jer se **čvorovi** mogu analizirati na način na koji ljudi to mogu razumjeti. Većina modela ML-a ne mogu se u potpunosti objasniti, a neki su više objašnjivi od drugih. Povećavanje objašnjivosti modela može pomoći u uklanjanju problema i u borbi protiv **pristranosti**.

Oznaka ML-a

U **nadziranom učenju**, **model strojnog učenja (ML)** se **trenira** upotrebom označenih **podataka**. Svakom podatku se dodjeljuje jedna ili više oznaka koje pružaju informacije o tom podatku. Na primjer, model ML-a dizajniran je za identifikaciju pjeva ptica. Svaki se zvuk označuje imenom ptice koja pravi taj zvuk. Model ML-a trenira se pomoću označenih zvukova i može **predvidjeti** oznaku (ime ptice) novih zvukova. Podatke najčešće označuju ljudi da bi se pružilo najtočniji primjeri za treniranje modela ML-a.

Pismenost u području umjetne inteligencije

Pismenost u području umjetne inteligencije je skup kompetencija i načina razmišljanja koji ljudima omogućuju smisleno korištenje aplikacija **umjetne inteligencije (UI)**, kao i u situacijama u kojima se oko njih koriste aplikacije UI. Takve kompetencije uključuju razumijevanje umjetne inteligencije, sudjelovanje u razvoju sustava UI i posjedovanje informiranih mišljenja o načinima na koje se sustavi UI koriste u svijetu. Na primjer, osoba koristi pismenost u području umjetne inteligencije kada procjenjuje točnost informacija koje pruža chatbot aplikacija UI. Osim različitih načina korištenja aplikacija UI, pismenost u području umjetne inteligencije uključuje i potencijal ljudi da aktivno sudjeluju u odlučivanju o tome kako bi se sustavi UI mogli koristiti oko njih

Podaci za treniranje strojnog učenja

U **strojnom učenju (ML)**, podaci za treniranje odnosi se na primjere u obliku **podataka** koji se upotrebljavaju za **treniranje ML modela**. Razvojni programeri grade modele za prepoznavanje uzoraka u podacima za treniranje, koji se mogu upotrijebiti za generiranje **predviđanja** o novim podacima. Na primjer, razvojni programer ML-a razvije aplikaciju za prepoznavanje govora. Podaci za treniranje može uključivati mnoštvo primjera ljudi koji govore različitim narječjima ili tonovima. Što više podaci za treniranje predstavljaju stvarnost, to bolje će model vjerojatno raditi.

Podaci

Podaci su vrijednosti, mjerenja, činjenice ili opažanja u obliku koji je primjeren za obradu računalnim programom. Postoji mnoštvo vrsta podataka, kao što je tekst, slika ili zvuk. Primjer tekstualnog podatka su poruke koje ljudi dijele s prijateljima na digitalnim uređajima. U **strojnom učenju (ML)**, podaci predstavljaju primjere ML-a kojim **sumodelitrenirani**. Prikupljanje, **čišćenje** i strukturiranje ogromne količine podataka predstavlja temeljni dio dizajniranja modela ML-a.

Podržano učenje

Podržano učenje je jedan pristup za **treniranje modela strojnog učenja**. Taj se pristup upotrebljava za rješavanje problema s jasnim ciljem, pri čemu se upotrebljavaju nagrade i kazne za postizanje tog cilja. Pristupi podržanog učenja upotrebljavaju se pri dizajnu autonomnih automobila ili za igranje kompliciranih igrica. Na primjer, model podržanog učenja može se upotrebljavati za dizajniranje aplikacije za igranje šaha. Model je treniran da **predviđa** pokrete koji maksimiziraju nagrade i minimiziraju kazne za pobjedu. Pristupi podržanog učenja upotrebljavaju nagrade i kazne za identificiranje strategija ispunjavanja cilja.

Pouzdanost ML-a

Pouzdanost se odnosi na to koliko je nešto pouzdano. U **strojnom učenju (ML)**, pouzdanost je način mjerenja sigurnosti nekog **predviđanja**. Na primjer, **klasifikacija modela** je dizajniran za predviđanje hoće li sutra pasti kiša. Model predviđa s 90 % pouzdanosti da će sutra biti kiše. Drugim riječima,

postoji sigurnost od 90 % da će sutra pasti kiša. Upotrebom pouzdanosti za mjerenje sigurnosti nekog predviđanja pomaže procijeniti kvalitetu nekog modela ML-a.

Prag pouzdanosti ML-a

Prag pouzdanosti odnosi se na skup vrijednosti kao razina prihvatljivosti za **predviđanje modela strojnog učenja**. Prag pouzdanosti odabire razvojni programer ML-a pri dizajniranju modela ML-a. Na primjer, predviđanje generira model ML-a s 50 % **pouzdanosti** da će sutra biti snježna oluja. No ako je prag pouzdanosti postavljen na 60 % da će se to predviđanje smatrati netočnim. Drugim riječima, osim ako je pouzdanost predviđanja 60 % ili veća, neće se prihvatiti kao **točno**. Vrijednost se postavlja u skladu s prirodom problema koji se treba riješiti, s medicinskom dijagnozom koja predviđa zahtijevanje većeg praga pouzdanosti od preporuka pjesama. Odabir praga određuje što je prihvatljiva razina pouzdanosti predviđanja.

Predviđanje strojnim učenjem

Modeli strojnog učenja (ML) se **treniraju** za predviđanja. Predviđanje koju proizvede model ML-a predlaže što **podaci** predstavljaju ili što bi bilo korisno kao zadatak. Na primjer, razvojni programer ML-a može trenirati model za predviđanje o tome koji film bi netko možda htio sljedeće gledati, na temelju njihovih navika gledanja. Model će generirati predviđanje nakon što se trenira na odabiru filma mnoštva ljudi. Glavni zadatak model ML-a jest praviti predviđanja. Svi modeli ML-a prave predviđanja, iako u nekim slučajevima ta predviđanja nisu očita korisniku.

Pri stranost podataka

Pri stranost podataka odnosi se na **pri stranost** koja se preslikava na **podatke** koji se upotrebljavaju za **treniranje modela strojnog učenja (ML)**. Pri stranost podataka može dovesti do toga da se modeli ML-a treniraju za generiranje pristranih **predviđanja**. Na primjer, neki modeli prepoznavanja lica pristrani su odnosu na lica određenih boja kože, jer su modeli ML-a trenirani uglavnom upotrebom slika lica jedne boje kože. Postoji nekoliko potencijalnih izvora pristranosti podataka. To uključuje nepotpune podatke i podatke koji zrcale **društvenu pristranost**. Pronalaženje pristranosti podataka je bitno za izbjegavanje da modeli ML-a generiraju pristrana predviđanja.

Pri stranost

Pri stranost se odnosi na sklonost prema nečemu ili protiv nečega. Na primjer, učenik bi mogao preferirati satove hrvatskog jezika u odnosu na satove matematike i provoditi više vremena na domaćoj zadaći iz hrvatskog jezika. Drugim riječima, pristrani su prema hrvatskom jeziku. Postoje mnoge vrste pristranosti, uključujući **društvenu pristranost** i **pri stranost podataka**. Razvojni programeri **strojnog učenja (ML)** moraju pažljivo razmisliti o tome jesu li **podaci** koje koriste za **treniranje modela** strojnog učenja pristrani ili ne. Pri stranost može rezultirati davanjem prednosti osobi, skupini ili skupu ideja ili uvjerenja u usporedbi s drugima.

Računalni vid

Računalni vid je istraživanje sustava koji su dizajnirani za obradu informacija s digitalnih slika ili videozapisa. Primjeri primjene računalnog vida uključuje prepoznavanje lica, medicinsko snimanje i videonadzor. Na primjer, računalni vid se upotrebljava pri dizajniranju autonomnih automobila za prepoznavanje i izbjegavanje sudare s predmetima. Najčešće, sustavi računalnog vida upotrebljavaju modele **strojnog učenja** za prepoznavanje uzoraka u podacima slika i videozapisa. Sustavi računalnog vida su korisni kada se informacije s digitalnih slika ili videa mogu upotrebljavati za rješavanje nekog problema.

Stablo odlučivanja ML-a

Stablo odlučivanja **strojnog učenja (ML)** jedna je vrsta **modela** ML-a. Razvojni programeri ML-a upotrebljavaju stabla odlučivanja za skup uvjeta na temelju kojih se mogu raditi **predviđanja**. Uvjeti proizlaze iz **značajki** u **podacima**. Na primjer, stablo odlučivanja može se upotrijebiti za izgradnju sustava za preporučivanje filmova. Model stabla odlučivanja se **trenira** upotrebom preferenci za filmove mnoštva ljudi. Tijekom treniranja, uvjeti se generiraju na temelju značajki kao što je vrsta filma, duljina ili glavni glumac. Model ML-a generira predviđanje o tome koji bi film netko htio gledati sljedeće na temelju toga kako njihove preference prate uvjete u modelu. Struktura stabla odlučivanja ML-a generira se na temelju ogromne količine podataka i može se promijeniti ako se trenira s drugačijim podacima.

Strojno učenje

Strojno učenje (ML) je pristup koji se upotrebljava za dizajniranje i izgradnju sustava **umjetne inteligencije (UI)**. ML 'uči' upotrebom primjera u obliku **podataka**, umjesto izvršavanja uputa korak po korak. Drugim riječima, aplikacije ML-a **temelje se na podacima**. Na primjer, aplikacija ML-a upotrebljava se za prepoznavanje govora. Temelji se na mnoštvu primjera govora ljudi u različitim narječjima i tonovima. Druge aplikacije ML-a uključuju identifikaciju objekata u slikama ili igranju složenih igrica. Svaka aplikacija ML-a dizajnirana je za rješavanje određenog problema.

Temeljeno na podacima

Temeljeno na podacima jest način dizajniranja sustava upotrebom **podataka** umjesto pisanja uputa korak po korak. Na primjer, teško je saznati što prouzrokuje određene bolesti, ali postoji puno primjera podataka. Zbog toga, dizajneri upotrebljavaju zdravstvene podatke ljudi koji su oboljeli od neke bolesti za dijagnozu. Sustavi koji su temeljeni na podacima u suprotnosti su u odnosu na sustave **temeljene na podacima**. Sustavi koji su temeljeni na podacima primjereni su za rješavanje problema gdje je teško napraviti pravila koja pokrivaju svaku situaciju. Umjesto toga, dovoljan se broj primjera može prikupiti za oblikovanje rješenja.

Temeljeno na pravilima

Temeljeno na pravilima je način dizajniranja sustava upotrebom skupa predefiniраниh pravila. Na primjer, križić i kružić (iks-oks) program dizajniran je da upotrebljava pravila koji potez napravi kako bi pobijedio igru. Pravila su definirali ljudi koji su obično stručnjaci u domeni rješavanja problema. Sustavi **umjetne inteligencije (UI)** koji se grade pomoću pristupa temeljenog na pravilima, poznato i kao 'stari AI'. Sustavi temeljeni na pravilima u suprotnosti su naspram sustava **temeljenih na podacima** gdje se **podaci** upotrebljavaju za rješavanje problema. Sustavi temeljeni na pravilima korisni su za rješavanje problema gdje je moguće stvoriti i slijediti pravila koja pokrivaju većinu situacija.

Testni podaci ML-a

U **strojnom učenju (ML)**, testni podaci odnosi se na **podatke** koji se upotrebljavaju za testiranje i procjenutreniranih modela ML-a. Na primjer, model ML-a treniran je za **predviđanje** dijagnoze za neko zdravstveno stanje. Prije upotrebe u stvarnim situacijama, model se testira i evaluira upotrebom testnih podataka. Testni podaci razlikuju se od **podataka za treniranje** kojim se model ML-a trenira. Testni podaci se upotrebljavaju za mjerenje performance modela ML-a s primjerima koji nadilaze podatke za treniranje.

Točnost strojnog učenja

Točnost se odnosi na to koliko je nešto točno. U **strojnom učenju (ML)**, točnost je način mjerenja koliko često **model** strojnog učenja daje ispravno **predviđanje**. Na primjer, model **klasifikacije** osmišljen je za klasifikaciju jabuka. Od 100 slika jabuka, 90 je ispravno klasificirano. Točnost klasifikacije modela je 90 %. Točnost je jedan od načina procjene modela strojnog učenja. Najčešće se točnost koristi zajedno s drugim mjerama za procjenu kvalitete modela.

Treniranje strojnog učenja

Modeli strojnog učenja (ML) treniraju se upotrebom primjera u obliku **podataka** za pronalazak uzoraka i **predviđanje**. Tijekom treniranja, uzorci se fino podešavaju za poboljšavanje predviđanja. Na primjer, razvojni programer ML-a može izgraditi model za pravljenje preporuka pjesama. Model ML-a trenirat će se na odabirima pjesama mnoštva ljudi kako bi se pronašle sličnosti među onim što različiti ljudi vole slušati. Što je različiti odabir pjesama kojim se model trenira, to bolje će biti predviđanje preporučene pjesme. Postoji mnoštvo različitih načina treniranje modela ML-a upotrebom različitih vrsta podataka. Razvojni programer će odabrati među vrstama treniranja koji su dostupni ovisno o problemu koji trebaju riješiti i podaci koji su dostupni za njegovo rješavanje. Kvaliteta najviše ovisi o kvaliteti podataka koji se upotrebljavaju.

Umjetna inteligencija

Umjetna inteligencija (UI) je dizajn i proučavanje sustava koji naizgled oponašaju inteligentno ponašanje. Neke aplikacije UI temelje se na pravilima. Sve češće se aplikacije UI grade korištenjem **strojnog učenja** za koje se kaže da 'uči' iz primjera u obliku **podataka**. Na primjer, neke aplikacije UI izrađene su za odgovaranje na pitanja ili pomoć u dijagnosticiranju bolesti. Druge aplikacije UI mogle bi se izraditi u štetne svrhe, poput širenja lažnih vijesti. Aplikacije UI ne razmišljaju. Aplikacije UI izrađene su za izvršavanje zadataka na način koji se čini inteligentnim.

Životni ciklus projekta umjetne inteligencije

Životni ciklus projekta **umjetne inteligencije (UI)** odnosi se na različite korake koje bi moglo provesti u dizajniranju i izgradnji **modela strojnog učenja (ML)**. Koraci uključuju definiranje problema, pripremu **podataka**, **treniranje** modela, testiranje modela, evaluaciju modela i objašnjenje modela. Na primjer, model strojnog učenja dizajniran je za generiranje novih popisa za reprodukciju pjesama. Razvojni programer strojnog učenja prvo bi mogao razmotriti koju vrstu popisa za reprodukciju želi stvoriti. Zatim bi mogli prikupljati i pripremati podatke o pjesmama. Model strojnog učenja je treniran i testiran s podacima pjesme. Model strojnog učenja se procjenjuje kako bi se utvrdilo radi li kako se očekuje. Konačno, model strojnog učenja objašnjen je kako bi ga i drugi mogli koristiti. Obično se koraci životnog ciklusa projekta UI koriste iterativno, a ne jedan za drugim. Životni ciklus projekta umjetne inteligencije niz je iterativnih koraka koji se koriste za izgradnju i poboljšanje modela strojnog učenja.


Značajka ML-a

U **strojnom učenju (ML)**, značajke predstavljaju karakteristike koje su povezane s **podacima**. Na primjer, skup glazbenih podataka može imati značajke kao što su tempo, visina glasa, energija ili žanr. Neki **modeli ML-a treniraju** se upotrebom značajki za pronalazak sličnosti u podacima. Drugi **predviđaju** nove značajke u podacima koje ljudi ne mogu lako promatrati. Odabir koje značajke upotrijebiti pri treniranju modela ML-a može učiniti razliku u tome hoće li neki model dobro raditi ili ne.




Ovaj materijal licencirao je [Raspberry Pi Foundation](#) pod međunarodnom javnom licencijom Creative Commons Autorstvo-Nekomercijalno-Bez prerada 4.0 Međunarodna (CC BY-NC-ND 4.0). Za više informacija o toj licenciji, pogledajte creativecommons.org/licenses/by-nc-nd/4.0/deed.hr.

Experience AI



Ovaj rječnik pojmova kreirao je Raspberry Pi Foundation kao dio našeg obrazovnog programa Experience AI. Saznajte više na www.experience-ai.org

Ovaj materijal licencirao je Raspberry Pi Foundation pod međunarodnom javnom licencijom Creative Commons Autorstvo-Nekomercijalno-Bez prerada 4.0 Međunarodna (CC BY-NC-ND 4.0). Za više informacija o toj licenciji, pogledajte creativecommons.org/licenses/by-nc-nd/4.0/deed.hr.



Raspberry Pi
Foundation