

# Ishodi učenja predmeta

Strojno učenje 1, UNIZG FER, ak. god. 2022./2023.

Objavljeno: 3. 10. 2022.

Ovaj dokument definira ishode učenja za predmet Strojno učenje 1, ak. god. 2022./2023. Ishodi učenja su izjave koje opisuju što biste trebali znati, razumjeti ili moći napraviti na kraju nastavnih aktivnosti iz ovog predmeta. Ishodi učenja služe povećanju svijesti o vlastitom učenju i lakšoj pripremi za provjere znanja i vještina. Ovdje navedeni ishodi učenja definirani su u skladu s [revidiranom Bloomovom taksonomijom](#).

## Ishodi učenja na razini predmeta

Nakon završetka ovog predmeta, moći ćete:

1. Definirati osnovne pojmove strojnog učenja.
2. Objasniti teorijske pretpostavke, matematičke osnove te prednosti i nedostatke temeljnih algoritama nadziranog i nenadziranog strojnog učenja.
3. Primijeniti temeljne algoritme klasifikacije, regresije i grupiranja na jednostavnije probleme.
4. Primijeniti postupak odabira modela i evaluacije točnosti naučenog modela.
5. Analizirati i usporediti temeljne algoritme strojnog učenja s obzirom na njihove komponente i računalnu složenost.
6. Razlikovati temeljne pristupe strojnom učenju (generativni/diskriminativni, parametarski/neparametarski, bayesovski/frekventistički) te objasniti poveznice.
7. Procijeniti prikladnost temeljnih algoritama strojnog učenja za zadani zadatak.
8. Oblikovati i implementirati jednostavnije algoritme za klasifikaciju, regresiju i grupiranje.

Nastavne aktivnosti na ovom predmetu (predavanja, domaće zadaće, auditorne vježbe i laboratorijske vježbe) oblikovane su tako da združeno doprinose gore navedenim ishodima učenja.

## Ishodi učenja na razini predavanja

U nastavku su navedeni specifični ishodi učenja za svako predavanje. Ishodi označeni zvjezdicom (\*) nisu obavezni i nisu uključeni u provjere znanja, ali mogu pomoći boljem razumijevanju gradiva.

## 1 Uvod u strojno učenje

- 1.1. Definirati strojno učenje.
- 1.2. Navesti tipične slučajeve primjene strojnog učenja.
- 1.3. Razlikovati između pristupa, zadataka i primjena strojnog učenja.
- 1.4. Razlikovati između nadziranog i nenadziranog strojnog učenja te dati primjere.
- 1.5. Razlikovati između klasifikacije i regresije te dati primjere.

## 2 Osnovni koncepti

- 2.1. Definirati hipotezu i model te dati primjere.
- 2.2. Definirati induktivnu pristranost, razlikovati vrste pristranosti te dati primjere.
- 2.3. Definirati funkciju gubitka i funkciju pogreške te dati primjere.
- 2.4. Objasniti komponente algoritma učenja i povezati ih s induktivnom pristranošću.
- 2.5. Odrediti predikciju dane hipoteze na skupu primjera.
- 2.6. Objasniti utjecaj šuma na složenost modela i navesti moguće uzroke šuma.
- 2.7. Objasniti odabir modela, prenaučenost i podnaučenost.
- 2.8. Razlikovati između parametara i hiperparametara modela.
- 2.9. Objasniti unakrsnu provjeru i graf pogrešaka u ovisnosti o složenosti modela.
- 2.10. Interpretirati i usporediti složenost modela na temelju pogreške učenja/ispitivanja.

## 3 Linearna regresija

- 3.1. Definirati model linearne regresije i jednostavne regresije.
- 3.2. Navesti vrste regresija i dati primjere.
- 3.3. Objasniti postupak najmanjih kvadrata i motivaciju za njegovu primjenu.
- 3.4. Izvesti rješenje najmanjih kvadrata u matričnom obliku.
- 3.5. Objasniti probabilističku interpretaciju linearne regresije i izvesti kvadratni gubitak.
- 3.6. Objasniti vezu između log-izglednosti podataka pod modelom i pogreške modela.
- 3.7. Analizirati komponente i induktivnu pristranost algoritma linearne regresije.

## 4 Linearna regresija II

- 4.1. Objasniti bazne funkcije i funkciju preslikavanja te motivaciju za njenu primjenu.
- 4.2. Povezati složenost modela s funkcijom preslikavanja.
- 4.3. Objasniti regularizaciju te objasniti prednosti i nedostatke L1- i L2-regularizacije.
- 4.4. Objasniti zašto L1-regularizacija rezultira rijetkim modelima, a L2-regularizacija ne.
- 4.5. Izvesti rješenje za parametre hrbatne regresije u matričnom obliku.
- 4.6. Povezati regularizaciju, pogrešku učenja/ispitivanja i složenost modela.
- 4.7. Povezati rang matrice dizajna, multikolinearnost značajki i L2-regularizaciju.
- 4.8. \*Objasniti kondiciju matrice dizajna i vezu s regularizacijom i multikolinearnošću.
- 4.9. Izračunati matricu dizajna za zadani skup primjera i zadanu funkciju preslikavanja.

## 5 Linearni diskriminativni modeli

- 5.1. Definirati pojam linearnog diskriminativnog modela.
- 5.2. Objasniti geometriju linearnog modela i izvesti udaljenost primjera od hiperravnine.
- 5.3. Objasniti sheme OVO/OVR, definirati pripadne modele i objasniti prednosti i nedostatke.
- 5.4. Objasniti klasifikaciju regresijom i objasniti nedostatke.
- 5.5. Definirati i skicirati funkciju gubitka perceptrona i usporediti je s gubitkom 0-1.
- 5.6. Definirati i skicirati funkciju pogreške perceptrona i usporediti je s udjelom netočne klasifikacije.
- 5.7. Izvesti algoritam perceptrona.
- 5.8. Navesti prednosti i nedostatke algoritma perceptrona.
- 5.9. Primijeniti algoritam perceptrona na zadane podatke.

## 6 Logistička regresija

- 6.1. Definirati i skicirati logističku funkciju te objasniti prednosti kada se koristi kao aktivacijska funkcija.
- 6.2. Definirati model logističke regresije i objasniti interpretaciju izlaza.
- 6.3. Definirati pojam poopćenog linearnog modela.
- 6.4. Izvesti pogrešku unakrsne entropije i objasniti korištene pretpostavke.
- 6.5. \*Izvesti logističku funkciju gubitka za oznake  $-1$  i  $+1$ .
- 6.6. Skicirati funkciju logističkog gubitka i usporediti ju s drugim funkcijama gubitka.
- 6.7. Objasniti konveksnost funkcije pogreške i vezu s konveksnošću funkcije gubitka.
- 6.8. Objasniti stopu učenja, globalnu kovergenciju i linijsko pretraživanje, te motivaciju za potonje.
- 6.9. Objasniti optimizaciju gradijentnim spustom i objasniti grupnu/stohastičku inačicu algoritma.
- 6.10. Izvesti algoritam grupnog/stohastičkog grad. spusta za L2/neregulariziranu logističku regresiju.
- 6.11. Objasniti prednosti regularizacije u kontekstu logističke regresije.
- 6.12. Skicirati i objasniti pogrešku logističke regresije kao funkciju parametara ili iteracija.
- 6.13. Analizirati komponente i induktivnu pristranost algoritma logističke regresije.

## 7 Logistička regresija II

- 7.1. Objasniti (kvazi-)Newtonov postupak i motivaciju za njegovu primjenu.
- 7.2. Definirati funkciju softmax i objasniti što se njome ostvaruje.
- 7.3. \*Demonstrirati da je funkcija softmax poopćenje logističke funkcije.
- 7.4. Definirati model multinomijalne logističke regresije i objasniti interpretaciju izlaza.
- 7.5. Izvesti poopćenu pogrešku unakrsne entropije.
- 7.6. Izvesti i objasniti algoritam LMS.

- 7.7. Izračunati predikciju modela multinomijalne regresije za zadane primjere.
- 7.8. \*Povezati poopćene linearne modele s distribucijama iz eksponencijalne familije.
- 7.9. Objasniti vezu između logističke regresije i umjetnih neuronskih mreža.

## 8 Stroj potpornih vektora

- 8.1. Definirati maksimalnu marginu, objasniti motivaciju i dati primjere.
- 8.2. Objasniti maksimalnu marginu pomoću koncepta konveksnih ljusaka klasa.
- 8.3. Definirati model SVM-a i izvesti (primarni) optimizacijski problem maksimalne margine.
- 8.4. \*Objasniti Lagrangeovu funkciju i uvjete KKT.
- 8.5. Definirati Lagrangeovu funkciju i uvjete KKT za SVM s tvrdom marginom.
- 8.6. \*Objasniti načelo dualnosti i Lagrangeovu dualnu funkciju.
- 8.7. Izvesti dualni kvadratni problem maksimalne margine i dualni oblik SVM modela.
- 8.8. Usporediti primarnu i dualnu formulaciju SVM-a te navesti prednosti svake od njih.
- 8.9. Definirati pojam potpornog vektora i dati primjere.
- 8.10. Izračunati predikciju SVM-a te dualne/primarne parametre iz primarnih/dualnih parametara.
- 8.11. Analizirati komponente i induktivnu pristranost algoritma SVM.

## 9 Stroj potpornih vektora II

- 9.1. Definirati problem meke maksimalne margine i objasniti motivaciju za nju.
- 9.2. Izvesti dualni problem meke maksimalne margine.
- 9.3. Definirati Lagrangeovu funkciju i uvjete KKT za SVM s mekom marginom.
- 9.4. Definirati i skicirati funkciju gubitka zglobnice.
- 9.5. Skicirati funkciju gubitka SVM-a i usporediti ju s drugim funkcijama gubitka.
- 9.6. Definirati funkciju pogreške SVM-a i objasniti ulogu hiperparametra  $C$ .
- 9.7. Izračunati gubitak/pogrešku zadanog modela SVM-a na zadanom primjeru/skupu.
- 9.8. Objasniti potrebu za skaliranjem značajki kod SVM-a.
- 9.9. \*Objasniti Plattovu metodu probabilističke kalibracije SVM-a.

## 10 Jezgrene metode

- 10.1. Definirati jezgrene funkciju, objasniti motivaciju i navesti primjere uporabe.
- 10.2. Definirati tipične jezgrene funkcije za vektorske ulazne prostore.
- 10.3. Objasniti ulogu parametra  $\sigma^2$  odnosno  $\gamma$  Gaussove jezgrene funkcije.
- 10.4. Definirati i usporediti jezgreni stroj i rijetki jezgreni stroj.
- 10.5. Objasniti jezgreni trik i prednosti inverznog oblikovanja.
- 10.6. Objasniti Mercerovu jezgru i demonstrirati to svojstvo za linearnu i Gaussovu jezgru.
- 10.7. Objasniti svojstva Hilbertovog prostora induciranog Gaussovom jezgrom.

- 10.8. \*Dokazati da Gaussova jezgra inducira beskonačnodimenzijski prostor značajki.
- 10.9. Izračunati parametre/predikciju zadanog jezgrenog stroja za zadane primjere.
- 10.10. Izračunati parametre/predikciju SVM-a sa zadanim primjerima i jezgrom.
- 10.11. Objasniti optimizaciju hiperparametara  $C$  i  $\gamma$  kod SVM-a s Gaussovom jezgrom.

## 11 Neparametarske metode

- 11.1. Razlikovati parametarske i neparametarske metode.
- 11.2. Navesti prednosti i nedostatke parametarskih odnosno neparametarskih metoda.
- 11.3. Usporediti parametarsku i neparametarsku varijantu modela SVM-a.
- 11.4. Definirati modele  $k$ -NN i težinski  $k$ -NN te opisati odgovarajuće algoritme.
- 11.5. Objasniti ulogu hiperparametra  $k$  kod algoritma  $k$ -NN.
- 11.6. Navesti pristupe za nalaženje najbližih susjeda.
- 11.7. Objasniti problem prokletstva dimenzionalnosti.
- 11.8. Definirati model  $k$ -NN za regresiju i jezgreno zaglađivanje.
- 11.9. Izračunati predikciju (težinske)  $k$ -NN klasifikacije/regresije za zadane primjere.

## 12 \*Ansampli

*Ova je tema ove godine opcionalna. Niže navedeni ishodi učenje služe za orijentaciju onima koji žele samostalno savladati ovu temu. Te ishode učenje nećemo ispitivati u provjerama znanja.*

- 12.1. Objasniti motivaciju za kombiniranje klasifikatora.
- 12.2. Definirati modele glasanja i *stackinga*.
- 12.3. Objasniti postupak *bagginga*.
- 12.4. \*Objasniti naziv "0.632 bootstrap".
- 12.5. Napisati pseudokôd i objasniti prednosti algoritma slučajne šume.
- 12.6. Napisati pseudokôd i objasniti prednosti algoritma AdaBoost.
- 12.7. \*Primijeniti algoritam AdaBoost na zadane primjere.

## 13 Procjena parametara

- 13.1. Navesti prednosti i nedostatke probablističkih modela.
- 13.2. Objasniti vezu između učenja probablističkog modela i procjene parametara.
- 13.3. Definirati i izračunati očekivanje, (ko)varijancu i kovarijacijsku matricu.
- 13.4. Definirati Pearsonov koeficijent korelacije i vezu s nezavisnošću slučajnih varijabli.
- 13.5. Povezati vrste varijabli/značajki s teorijskim vjerojatnosnim distribucijama.
- 13.6. Definirati Bernoullijevu, kategoričku i uni/multivarijatnu Gaussovu distribuciju.
- 13.7. Objasniti inačice Gaussove distribucije s ograničenjima na kovarijacijsku matricu.
- 13.8. Definirati statistiku, procjenitelj i pristranost procjenitelja.
- 13.9. \*Dokazati (ne)pristranost procjenitelja srednje vrijednosti i procjenitelja varijance.
- 13.10. Navesti metode za izvođenje procjenitelja.

## 14 Procjena parametara II

- 14.1. Definirati i objasniti funkciju izglednosti te vezu sa vjerojatnošću uzorka.
- 14.2. Definirati i skicirati funkciju izglednosti Bernoullijeve distribucije.
- 14.3. Definirati procjenitelj MLE te navesti njegove prednosti i mane.
- 14.4. Izvesti procjenitelj MLE za Bernoullijevu i univarijatnu Gaussovu razdiobu.
- 14.5. Definirati procjenitelj MAP te navesti njegove prednosti i mane.
- 14.6. Objasniti ideju konjugatnih distribucija i njihovu ulogu u procjeni parametara.
- 14.7. Izvesti Beta-Bernoullijev model i definirati Laplaceovo zaglađivanje.
- 14.8. Objasniti Dirichlet-kategorički model i definirati procjenitelj MAP za kategoričku varijablu.
- 14.9. Izračunati MLE/MAP procjenu parametara Bernoullijeve/kategoričke distribucije za zadani uzorak.

## 15 Bayesov klasifikator

- 15.1. Napisati pravilo zbroja i umnoška te izvesti Bayesovo pravilo i pravilo lanca.
- 15.2. Definirati model Bayesovog klasifikatora i navesti nazive pojedinih distribucija.
- 15.3. Razlikovati generativne i diskriminativne modele te navesti njihove prednosti i nedostatke.
- 15.4. Napisati generativnu priču za Bayesov klasifikator.
- 15.5. Definirati uni/multivarijatni Gaussov Bayesov klasifikator.
- 15.6. Skicirati gustoće vjerojatnosti univarijatnog Gaussovog Bayesovog klasifikatora.
- 15.7. Izvesti i skicirati tri pojednostavljene inačice Gaussovog Bayesovog klasifikatora.
- 15.8. \*Dokazati (ne)linearnost granice za danu inačicu Gaussovog Bayesovog klasifikatora.
- 15.9. Izračunati broj parametara za danu inačicu Gaussovog Bayesovog klasifikatora.
- 15.10. Procijeniti parametre Gaussovog Bayesovog klasifikatora na skupu podataka.

## 16 Bayesov klasifikator II

- 16.1. Objasniti i izvesti vezu između modela logističke regresije i Bayesovog klasifikatora.
- 16.2. Izvesti model naivnog Bayesovog klasifikatora i objasniti korištene pretpostavke.
- 16.3. Definirati uvjetnu nezavisnost slučajnih varijabli i objasniti ju na primjeru.
- 16.4. Objasniti potrebu za uvođenjem pretpostavke o uvjetnoj nezavisnosti značajki.
- 16.5. Objasniti polunaivan Bayesov klasifikator i objasniti potrebu za takvim modelom.
- 16.6. Definirati KL-divergenciju i uzajamnu informaciju.
- 16.7. Navesti moguće kriterije za odabir modela kod polunaivnog Bayesovog klasifikatora.
- 16.8. Izračunati broj parametara za danu inačicu diskretnog Bayesovog klasifikatora.
- 16.9. Procijeniti parametre diskretnog Bayesovog klasifikatora na danom skupu podataka.

## 17 Probabilistički grafički modeli

- 17.1. Navesti tri aspekta probabilističkih grafičkih modela.
- 17.2. Definirati Bayesovu mrežu.
- 17.3. Napisati faktorizaciju zajedničke distribucije na temelju Bayesove mreže i obratno.
- 17.4. Definirati uređajno Markovljevo svojstvo i objasniti vezu s bridovima Bayesove mreže.
- 17.5. Izvesti uvjetne nezavisnosti iz dane faktorizacije zajedničke distribucije.
- 17.6. Nacrtati Bayesovu mrežu polu/naivnog Bayesovog klasifikatora.
- 17.7. Objasniti, definirati i skicirati skriveni Markovljev model (HMM).
- 17.8. Izvesti tri pravila d-odvojivosti za stazu od tri čvora.
- 17.9. Odrediti uvjetne nezavisnosti varijabli u Bayesovoj mreži korištenjem d-odvojivosti.
- 17.10. Objasniti efekt “objašnjavanja” te ga ilustrirati primjerom.

## 18 Probabilistički grafički modeli II

- 18.1. Razlikovati opažene i skrivene varijable te varijable upita i varijable smetnje.
- 18.2. Razlikovati posteriorne i MAP-upite.
- 18.3. Izračunati posteriorni/MAP-upit egzaktnim zaključivanjem na danoj Bayesovoj mreži.
- 18.4. \*Objasniti ideju postupka eliminacije varijabli.
- 18.5. Objasniti i na primjeru ilustrirati zaključivanje unaprijednim uzorkovanjem i uzorkovanjem s odbijanjem.
- 18.6. Objasniti i na primjeru ilustrirati Gibbsovo uzorkovanje.
- 18.7. Izvesti log-izglednost Bayesove mreže te MLE/MAP procjenitelje.
- 18.8. Procijeniti parametre Bayesove mreže na danom skupu podataka.
- 18.9. Razlikovati između učenja iz potpunih i nepotpunih podataka.
- 18.10. Skicirati Bayesovu mrežu za nepotpune podatke i definirati pripadnu log-izglednost.

## 19 Grupiranje

- 19.1. Definirati problem grupiranja.
- 19.2. Razlikovati partijsko i hijerarhijsko grupiranje te čvrsto i meko grupiranje.
- 19.3. Definirati kriterijsku funkciju algoritma k-sredina i izvesti iterativnu optimizaciju.
- 19.4. Napisati pseudokôd algoritma k-sredina i primijeniti ga na dane podatke.
- 19.5. Objasniti konvergenciju i neoptimalnost algoritma k-sredina.
- 19.6. Objasniti najvažnije načine odabira početnih središta grupa.
- 19.7. Napisati pseudokôd algoritma k-medoida i primijeniti ga na dane podatke.
- 19.8. Navesti glavne razlike algoritma k-sredina i algoritma k-medoida.
- 19.9. Objasniti osnovne pristupe određivanju broja grupa.
- 19.10. Definirati Randov indeks i izračunati ga na danom primjeru.

## 20 Grupiranje II

- 20.1. Definirati model miješane gustoće te model Gaussove mješavine (MoG).
- 20.2. Objasniti što su latentne varijable i koja je njihova uloga u modelu MoG.
- 20.3. Definirati potpunu i nepotpunu log-izglednost parametara modela MoG.
- 20.4. Objasniti kako radi algoritam maksimizacije očekivanja.
- 20.5. Napisati izraze za E-korak i M-korak algoritma maksimizacije očekivanja za MoG.
- 20.6. Razlikovati aglomerativno i divizivno hijerarhijsko grupiranje.
- 20.7. Objasniti i definirati jednostruku, potpunu i prosječnu povezanost grupa.
- 20.8. Primijeniti algoritam HAC na dan skup primjera te skicirati pripadni dendrogram.

## 21 Vrednovanje modela

- 21.1. Izračunati matricu zabune za dani primjer.
- 21.2. Izračunati točnost, preciznost, odziv i  $F_1$ -mjeru za danu matricu zabune.
- 21.3. Objasniti motivaciju za uvođenjem  $F_1$ -mjere.
- 21.4. Izračunati mikro- i makro-mjere za danu višeklasnu matricu zabune.
- 21.5. Skicirati krivulju preciznost-odziv i definirati prosječnu preciznost.
- 21.6. Definirati i skicirati ROC-krivulju te definirati mjeru AUC.
- 21.7. Definirati metodu (ponovljenog) izdvajanja i navesti njene nedostatke.
- 21.8. Definirati metodu unakrsne provjere “izdvoji jednog” i navesti njene nedostatke.
- 21.9. Napisati pseudokôd ugniježdene  $k$ -struke unakrsne provjere i objasniti prednosti.
- 21.10. Objasniti i primjerom ilustrirati stratificiranu unakrsnu provjeru.

## 22 \*Vrednovanje modela II

*Ova je tema ove godine opcionalna. Niže navedeni ishodi učenje služe za orijentaciju onima koji žele samostalno savladati ovu temu. Te ishode učenje nećemo provjeravati u ispitima niti kvizovima.*

- 22.1. Objasniti distribuciju uzorkovanja i njenu ulogu u statističkom zaključivanju.
- 22.2. Definirati distribuciju uzorkovanja procjenitelja srednje vrijednosti.
- 22.3. \*Definirati z-statistiku i t-statistiku i navesti pripadne distribucije uzorkovanja.
- 22.4. Objasniti potrebu za t-statistikom.
- 22.5. Objasniti što su populacija, uzorak i statistika kod vrednovanja modela.
- 22.6. \*Izračunati interval pouzdanosti točnosti modela za zadanu matricu zabune.
- 22.7. Objasniti kritičnu vrijednost i p-vrijednost te njihovu ulogu u statističkom zaključivanju.
- 22.8. Napisati korake t-testa za srednju vrijednost i navesti pretpostavke testa.
- 22.9. Objasniti primjenu t-testa i unakrsne provjere za usporedbu točnosti dvaju modela.
- 22.10. Primijeniti jedno/dvostrani t-test za usporedbu točnosti dvaju modela na danom uzorku.



## 23 \*Odabir značajki

*Ova je tema ove godine opcionalna. Niže navedeni ishodi učenje služe za orijentaciju onima koji žele samostalno savladati ovu temu. Te ishode učenje nećemo provjeravati u ispitima niti kvizovima.*

- 23.1. Objasniti motivaciju za odabir značajki.
- 23.2. Razlikovati odabir i transformaciju značajki te navesti njihove prednosti i nedostatke.
- 23.3. Objasniti metodu univarijatnog filtra te njezine prednosti i nedostatke.
- 23.4. Objasniti odabir t-testom i izračunati relevantnost značajke za dani primjer.
- 23.5. Objasniti odabir  $\chi^2$ -testom i izračunati relevantnost značajke za dani primjer.
- 23.6. \*Objasniti postupak RELIEF i napisati pseudokôd algoritma.
- 23.7. Objasniti metodu multivarijatnog filtra te njezine prednosti i nedostatke.
- 23.8. \*Objasniti postupak VIF za uklanjanje redundantnih značajki.
- 23.9. Definirati relevantnost skupa značajki mjerom CFS.
- 23.10. Objasniti metodu omotača te njezine prednosti i nedostatke.