



azvo

agencija za
znanost i visoko
obrazovanje

Radionica „Priznaj, oslobodi, olakšaj: mobilnost
i fleksibilno studiranje”

Zagreb, 25.9.2026.



azvok osiguravanje kvalitete
u visokom obrazovanju

azvo.hr

Fleksibilizacija i individualizacija visokog školstva u kontekstu odlazne mobilnosti studenata

Prof. dr. sc. Ljiljana Brkić

Sveučilište u Zagrebu

Fakultet elektrotehnike i računarstva

1. Trendovi i procesi mobilnosti na FER

- Kvantitativni pokazatelji mobilnosti (trendovi odlazne i dolazne mobilnosti)
- Povezanost programa, priznavanja i oslobođanja obveza

2. Fleksibilan i individualiziran program

- Obilježja programa pogodnog za mobilnost
- Učinak fleksibilizacije na broj odlazaka
- Studijske obveze umjesto popisa kolegija
- Izbornost kao prostor individualizacije

3. Kako priznajemo na FER-u

- Načela priznavanja
- Proces i podjela uloga
- Primjer iz prakse i izazovi



Fakultet elektrotehn
Sveučilište

3500 prijediplomskih & diplomskih studenata

134 prijediplomska & 244 diplomska kolegija

500 poslijediplomskih studenata



600 zaposlenika

300 nastavnika

osoblje



Mobilnost studenata FER-a kroz brojke



Studijski program, priznavanje, oslobađanje

- Odlazna mobilnost ne traži iznimku od pravila, nego program koji podnosi individualni put studenta.
- Student ne bi smio birati između mobilnosti i urednog napredovanja kroz studij.
- Studijski program je okvir, a priznavanje i oslobađanje povezuju razmjenu s nastavkom studija:
 - **studijski program** postavlja okvir – kroz ishode učenja te obvezne i izborne kolegije određuje **što student treba ostvariti**
 - **priznavanje** utvrđuje **što je student ostvario na razmjeni**
 - **oslobađanje** na temelju priznatih postignuća utvrđuje **od kojih je obveza matičnog studija student oslobođen.**
- Rezultat ovisi o najslabijoj karici: ako priznato ne dovede do oslobađanja od odgovarajuće obveze, student usporeno napreduje kroz studij, što može smanjiti interesa za mobilnost.

Fleksibilan i individualiziran
studijski program



Obilježja programa pogodnog za mobilnost

Jasni i usporedivi ishodi

- program opisan ishodima učenja, a ne samo sadržajem
- ishodi programa su mjerljivi i usporedivi
- usklađenost s EQF/HKO i ECTS metodologijom

Fleksibilna struktura

- manji udio krutih obveznih cjelina
- veći udio izbornih kolegija
- ograničeni i opravdani lanci preduvjeta
- višesemestralni kolegiji koče i mobilnost i priznavanje

Transparentna dokumentiranost

- izvedbeni planovi kolegija na engleskom jeziku
- online katalog kolegija
- realna procjena radnog opterećenja
- jasni uvjeti upisa i polaganja

Pogodan vs manje pogodan

Semestar	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	Napredni algoritmi i strukture podataka				Napredne baze podataka				Napredni razvoj programske potpore za web / Strojno učenje 1 / Statistička analiza podataka*				Izborni kolegij profila				Izborni kolegij				Diplomski projekt				Trans.					
2	Informacijski sustavi				Sustavi baza podataka / Analiza i pretraživanje teksta / Analiza velikih skupova podataka / Oblikovni obrasci u programiranju* / Paralelno programiranje				Sustavi baza podataka / Analiza i pretraživanje teksta / Analiza velikih skupova podataka / Oblikovni obrasci u programiranju* / Paralelno programiranje				Izborni kolegij profila				Izborni kolegij				Prezentacijski seminar				Trans.					
3	Izborni kolegij profila				Izborni kolegij profila				Izborni kolegij profila				Izborni kolegij				Izborni kolegij ili Istraživački seminar				Mentorski seminar				Trans.					
4	Diplomski rad																													

1. SEMESTAR	2. SEMESTAR	3. SEMESTAR	4. SEMESTAR
5. SEMESTAR	6. SEMESTAR		

Obavezni predmeti

6	Digitalna logika (183360)	60+0+15+15 ✱
ECTS	M. Mikuc, Z. Kalafatić, M. Čupić, T. Hrkać	
5	Linearna algebra (183355)	60+0+15+0 ✱
ECTS	A. Aglič Aljinović, I. Brnetić, A. Nakić, M. Pavčević, M. Puljiz, D. Vlah	
8	Matematička analiza 1 (183352)	90+0+30+0 ✱
ECTS	I. Brnetić, M. Bukal, T. Burić, J. Milišić, M. Pašić, A. Žgaljić Keko	
0	Tjelesna i zdravstvena kultura 1 (252321)	0+0+0+30 ✱
ECTS		
7	Uvod u programiranje (183357)	60+0+0+18 ✱
ECTS	G. Gledec, I. Mekterović, L. Brkić	
4	Vještine komuniciranja (229831)	30+3+0+5 ✱
ECTS	J. Petrović	

1. SEMESTAR	2. SEMESTAR	3. SEMESTAR	4. SEMESTAR
5. SEMESTAR	6. SEMESTAR		

Obavezni predmeti


6	Fizika (183368)	75+0+0+15 ✱
ECTS	S. Iljić, S. Pleslić, A. Babić, A. Sušac, Ž. Bošnjak, V. Gornzi	
7	Matematička analiza 2 (183361)	90+0+15+0 ✱
ECTS	T. Burić, D. Kovačević, M. Pašić, T. Šikić, I. Velčić, A. Žgaljić Keko, M. Puljiz	
8	Objektno orijentirano programiranje (183371)	60+0+15+18 ✱
ECTS	M. Kušek, K. Pripužić, B. Mlašinović, J. Babić, K. Križanović, T. Jagušć	
7	Osnove elektrotehnike (183374)	90+0+0+15 ✱
ECTS	B. Trkulja, M. Randić, M. Dadić, D. Pintar, M. Vranić	
0	Tjelesna i zdravstvena kultura 2 (252323)	0+0+0+30 ✱
ECTS		

Transverzalni kolegiji (16168)

❗ Broj ECTS bodova koje je potrebno odabrati: najmanje 2.0

2	Energija i društveno-gospodarski razvoj (240764)	30+5+0+0 ✱
ECTS	I. Rajšl, M. Delimar	
2	Menadžment u inženjerstvu (269089)	30+5+0+0 ✱
ECTS	V. Bilas, Ž. Car, H. Pandžić, B. Trkulja	
2	Osnovna načela dizajna (183378)	15+0+0+13 ✱
ECTS	F. Vukić	
Kolegij ima ograničenje na broj studenata za upis		

Učinak fleksibilnosti programa na mobilnost



Individualizacija kroz studijske obveze

- Studijske obveze promatramo kroz ishode učenja i minimalan broj ECTS bodova, a ne kao zadani popis kolegija.

- OBVEZA VEZANA UZ ODREĐENI KOLEGIJ – npr. obvezni kolegij
- SKUPNA STUDIJSKA OBVEZA – npr. skupina kolegija ukupno N ECTS
od kojih student treba ostvariti M ECTS, $N \geq M$

PRIMJER STUDIJSKIH OBVEZA

Studijska obveza	ECTS	Tip
Strojno učenje 1	5	Obvezni kolegij
Prezentacijski seminar	3	Obvezni kolegij
Izborni kolegiji profila	≥ 10	Skupna obveza
Slobodni izborni kolegij	≥ 10	Skupna obveza
Transverzalni kolegij	≥ 2	Skupna obveza

- Procjena podudarnosti se provodi na razini ishoda učenja – uspoređuju se ishodi studijskog programa/konkretne obveze s ishodima ostvarenima kroz inozemne kolegije.
- No, u konačnici studenta treba osloboditi studijskih obveza – mora biti jasno što nakon povratka više ne mora ostvariti.
- Student ne mora nužno ostvariti konkretan kolegij – treba ispuniti odgovarajuću studijsku obvezu.
- Inozemni kolegij ne mora imati „blizanca” u našem programu – treba se uklopiti u jednu ili više studijskih obveza.

Ishodi određuju podudarnost, a odluka o oslobađanju određuje što student više ne mora raditi.

Obveze vezane uz određeni kolegij i skupne obveze – različita razina provjere pri oslobađanju

- Ishodi kolegija su **specifičniji i užeg opsega** od ishoda studijskog programa.

OBVEZNI kolegiji

- Za oslobađanje nije dovoljna podudarnost s ishodima programa – potrebno je provjeriti **pokrivenost ishoda konkretnog kolegija**.
- Ne mora biti ostvareno 100 % ishoda, ali **pokrivenost mora biti dovoljna za opravdano oslobađanje od obveze**.

IZBORNI kolegiji

- U pravilu je dovoljno provjeriti **doprinos li ostvareni/priznati ishodi ostvarivanju ishoda studijskog programa**.
- Nije potrebno pronaći podudarnost s konkretnim izbornim kolegijem.
- Razina provjere ovisi o **ulozi skupne obveze u studijskom programu** – od opće izbornosti do izbora unutar određenog profila.

Što je studijska obveza specifičnija, to se procjena podudarnosti mora spustiti na konkretniju razinu ishoda.

Obveza vezana uz određeni kolegij (obvezni kolegiji)

AI potpomognuta provjera ostvarenosti ishoda učenja

MATIČNI OBVEZAN KOLEGIJ

Opis • ishodi učenja • tjedni plan



STRANI KOLEGIJ / KOLEGIJI

Opis • ishodi učenja • tjedni plan



AI kao pomoć u usporedbi

→ prepoznaje sličnosti i razlike

→ povezuje ishode i sadržaje

→ ukazuje na moguće izostanke ishoda

→ ukazuje na djelomičnu podudarnost ishoda



AKADEMSKA PROCJENA

→ jesu li ishodi učenja doista ostvareni?

Ulaz:

domaći kolegij + 1 ili više stranih kolegija

Pitanje:

U kojoj su mjeri ishodi učenja domaćeg kolegija ostvareni kroz ove strane kolegije?
Koji su ishodi pokriveni, djelomično pokriveni ili nepokriveni?

+



Claude is AI and can make mistakes. Please double-check cited sources.

Sonnet 5 Medium

Strojno učenje 1 (5 ECTS)

<https://www.fer.unizg.hr/predmet/struce1>

Opis kolegija

Strojno učenje grana je umjetne inteligencije koja se bave oblikovanjem algoritama koji svoju učinkovitost poboljšavaju na temelju empirijskih podataka. Strojno učenje jedno je od danas najaktivnijih i najzujbujivijih područja računarke znanosti, ponajviše zbog brojnih mogućnosti primjene koje se protežu od raspoznavanja uzoraka i dubinske analize podataka do robotike, računalnog vida, bioinformatike i računalne lingvistike. Ovaj se kolegij bavi teorijom i načelima strojnog učenja te daje pregled njegovih primjena. Kolegij obuhvaća dva osnovna pristupa strojnom učenju: nadzirano učenje (klasifikacija i regresija) i nenadzirano učenje (grupiranje i smanjenje dimenzionalnosti).

Preduvjeti

Minimalna potrebna predznanja: ishodi učenja predmeta "Uvod u programiranje", "Algoritmi i strukture podataka", "Matematička analiza 1", "Matematička analiza 2", "Diskretna matematika", "Linearna algebra", "Vjerojatnost i statistika" i "Teorija informacija" ili njima sličnih predmeta. Dobro znanje programiranja u Pythonu.

Ishodi učenja

1. Definirati osnovne pojmove strojnog učenja
2. Razlikovati između generativnih i diskriminativnih, parametarskih i neparametarskih te probabilističkih i neprobabilističkih modela
3. Objasniti teorijske pretpostavke, prednosti i nedostatke temeljnih algoritama strojnog učenja
4. Primijeniti postupak odabira modela i statističkog vrednovanja uspješnosti naučenog modela
5. Primijeniti razne algoritme klasifikacije, uključivo generativne, diskriminativne i neparametarske
6. Primijeniti algoritme grupiranja podataka i postupke provjere grupiranja
7. Dizajnirati i implementirati postupak za klasifikaciju/grupiranje podataka te provesti njegovu evaluaciju
8. Procijeniti prikladnost nekog algoritma strojnog učenja za zadani zadatak

Tjedni plan nastave

1. Zadatci i primjene strojnog učenja. Prisutpi i paradigme strojnog učenja, hipoteze, model prostor parametra, prostor inačica, induktivno učenje i induktivna pristranost. Pristranost jezika i pristranost preferencije. Funkcija gubitka i funkcija pogreške. Prenaučenost i odabir morela. Minimizacija empirijskog i strukturnog rizika
2. Regresija najmanjih kvadrata. procjena najveće izglednosti za regresiju, Regularizirana regresija, Model maksimalne entropije, Funkcije za preslikavanje značajki
3. Hipoteze, model. prostor parametra. prostor inačica. Perceptron (paradigme učenja, hebbovsko učenje, natjecateljsko učenje, Boltzmannovo učenje)
4. Logistička regresija, poopceni linerani modeli (eksponencijalna familija, procjenitelji ML i MAP)
5. Metoda potpornih vektora za klasifikaciju.
6. Lijeni klasifikatori (k-NN). Jezgrene funkcije (RBF, Mercerova jezgrene funkcija, linearna jezgrene funkcija). Jezgrena trik.
7. Zajednice klasifikatora.
8. Međuispit
9. Procjenitelj najveće izglednosti, Procjenitelj najveće aposteriorne vjerojatnosti. Laplaceov procjenitelj, Beta-binomni model, Dirichlet-multinomni model
10. Bajesovo pravilo za klasifikaciju, Naivan Bayesov klasifikator, Multivarijantni gausovski Bayesov model
11. Bayesove mreže. Monte Carlo zaključivanje.
12. Gaussov mješavinski model za grupiranje, Algoritam k-srednjih vrijednosti
13. Mjere vrednovanja zasnovane na matrici zabune (točnost, preciznost, odaziv, osjetljivost, F-mjera).
14. Odabir značajki (metode filtra, odabir podskupa značajki, metode omotača)
15. Završni ispit



Objectives

Background:

After a season in which different companies/institutions very invested in data collection by computerizing its operations (e.g. sensors, GPS systems), and in which many and varied new data sources have emerged (e.g. social networks), there is now the need to place such data at the service of those companies. The goal is to be able to extract knowledge from these data in order to improve efficiency and gain competitive advantage. From this need arises the Curricular Unit (UC) of Introduction to Machine Learning and Knowledge Extraction.

Objectives:

The student should be able to: (1) Use adequately descriptive statistics for data description; (2) To describe the different stages of the process of knowledge discovery CRISP; (3) to use and analyze the results of some of the main methods of classification and regression; (4) to use and interpret cluster analysis methods; (5) to use and interpret methods of association rules; (6) To be able to develop a project on Machine Learning or Knowledge Discovery using the CRISP-DM methodology.

Learning outcomes and competences

As a learning result, it is intended that students:

- Understand the different types of machine learning & data mining (ML&DM) tasks.
- Identify decision support problems that can be represented as ML&DM tasks.
- Understand the phases of a ML&DM project.
- Know the main methods / algorithms for each ML&DM task type and understand the basics of their behavior.
- Apply these methods to decision support problems.
- Evaluate the results of a ML&DM project.

Program

Descriptive ML&DM

- Descriptive data analysis techniques
- Quality of data and preprocessing techniques: normalization, reduction and discretization.
- Clustering: Partitioning, hierarchical, and densities algorithms. Evaluation measures.
- Association rules: APRIORI algorithm. Other algorithms. Evaluation measures.
- Data Mining Methodologies: CRISP-DM methodology. Project management.

Predictive ML&DM

- Overfitting and resampling techniques.
- Regression: Multivariate linear regression and extensions. Evaluation measures.
- Selection criteria for techniques and models.
- Binary classification: evaluation measures.
- Predictive techniques based on distances, probabilities, search and optimization.
- Ensemble learning
- Algorithm Bias
- Non-binary classification tasks
- Classification with unbalanced data
- Semi-supervised classification and active learning

Brief introduction to: Text mining, recommendation systems and analysis of social networks

Što kaŽe AI

Podatke o domaćem kolegiju nađi ovdje: <https://www.fer.unizg.hr/predmet/struce1>
Podatke o stranom kolegiju nađi ovdje: https://sigarra.up.pt/feup/en/ucurr_geral.ficha_uc_view?pv_ocorrendia_id=559547
U kojoj su mjeri ishodi učenja domaćeg kolegija ostvareni kroz ove strane kolegije?
Koji su ishodi pokriveni, djelomično pokriveni ili nepokriveni?

Ishod FER-a (Strojno učenje 1)	Status	Obrazloženje
1. Definirati osnovne pojmove strojnog učenja	Pokriveno	FEUP: "Understand the different types of ML&DM tasks", "Know the main methods for each task type" — temeljna terminologija je dio kolegija.
2. Razlikovati generativne/diskriminativne, parametarske/neparametarske, probablističke/neprobablističke modele	Nepokriveno	Ova konceptualna taksonomija modela nigdje se eksplicitno ne spominje u opisu FEUP kolegija. Program navodi tehnike "based on distances, probabilities, search and optimization", ali to je opis obitelji algoritama, ne eksplicitna konceptualna usporedba pristupa koju traži FER-ov ishod.
3. Objasniti teorijske pretpostavke, prednosti i nedostatke temeljnih algoritama	Djelomično pokriveno	FEUP: "Know the main methods/algorithms... and understand the basics of their behavior" — sugerira poznavanje na razini primjene, ne nužno duboku teorijsku analizu pretpostavki kakva se traži kod FER-a (npr. MLE/MAP izvodi, regularizacija, jezgri trik). Kolegij je izraženije aplikativan (alati: Python, RapidMiner, RStudio) nego teorijski.
4. Primijeniti postupak odabira modela i statističkog vrednovanja uspješnosti	Pokriveno	FEUP: "Selection criteria for techniques and models", "Overfitting and resampling techniques", evaluacijske mjere za regresiju i klasifikaciju — izravno se poklapa.

5. Primijeniti razne algoritme klasifikacije, uključivo generativne, diskriminativne, neparametarske	Djelomično pokriveno	FEUP pokriva binarnu i nebinarnu klasifikaciju, klasifikaciju s neuravnoteženim podacima, semi-nadzirano učenje, te tehnike temeljene na udaljenostima/vjerojatnostima/optimizaciji — vjerojatno uključuje k-NN, naivni Bayes, možda SVM/logističku regresiju, ali nijedan algoritam nije poimence naveden (za razliku od FER-a koji eksplicitno uči SVM, logističku regresiju, Bayesove mreže, perceptron). Širina pristupa je slična, dubina i konkretni algoritmi nisu potvrđeni.
6. Primijeniti algoritme grupiranja podataka i postupke provjere grupiranja	Pokriveno	FEUP: "Clustering: Partitioning, hierarchical, and densities algorithms. Evaluation measures." — vrlo dobro se poklapa s FER-ovim k-means/GMM pristupom i evaluacijom grupiranja.
7. Dizajnirati i implementirati postupak za klasifikaciju/grupiranje te provesti evaluaciju	Pokriveno	FEUP ima obavezan skupni projekt (40% ocjene) koji zahtijeva "razviti projekt na ML/Data Mining koristeći CRISP-DM metodologiju" — ovo je čak i eksplicitnije strukturiran praktični zahtjev nego FER-ov laboratorij.
8. Procijeniti prikladnost nekog algoritma strojnog učenja za zadani zadatak	Pokriveno	FEUP: "Identify decision support problems that can be represented as ML&DM tasks", "Selection criteria for techniques and models", "Evaluate the results of a ML&DM project" — izravno pokriva ovaj ishod.

Sažetak

- **Pokriveno: 5 od 8** ishoda (1, 4, 6, 7, 8)
- **Djelomično pokriveno: 2 od 8** (3, 5)
- **Nepokriveno: 1 od 8** (2)

Ono što FEUP kolegij dobro nadoknađuje, a FER eksplicitno ne traži: association rules (APRIORI), CRISP-DM metodologija projektnog upravljanja, algorithm bias, tekstno rudarenje i preporučiteljski sustavi (kratko), rad s realnijim skupom alata (Python, RapidMiner, RStudio umjesto isključivo teorijskog pristupa).

Ono što nedostaje ili je nesigurno: FEUP je vidljivo izraženije primijenjen i projektno orijentiran kolegij (60% pisani test, 40% skupni CRISP-DM projekt), dok je FER-ov kolegij izraženije teorijski utemeljen — traži izvode i konceptualnu taksonomiju modela (generativni/diskriminativni, parametarski/neparametarski) koju FEUP program nigdje ne spominje. To je najozbiljnija rupa i vjerojatno bi bila osnova za djelomično, a ne potpuno priznavanje — konkretno, ishod 2 gotovo sigurno zahtijeva dopunsku provjeru ili dodatnu zadaću ako se ide prema punom priznavanju.

Kako priznajemo na FER-u 

Načela priznavanja i oslobađanja - FER

- Studentu se priznaje sve što je uspješno obavio na stranoj instituciji
- Kolegiji se priznaju s **izvornim nazivima i brojem ECTS bodova** – ostvareno opterećenje ne umanjujemo niti uvećavamo.
- **Oslobađanje se temelji na fleksibilnom pristupu** koji **ne zahtijeva** potpunu podudarnost sadržaja ili ishoda učenja između kolegija matične i strane institucije.
- Od **jedne studijske obveze** (konkretne ili skupne) može se osloboditi temeljem **više stranih kolegija** – i obratno.
- Oslobađanje se može primijeniti na obveze iz bilo kojeg semestra.
- Višak ECTS bodova u pojedinoj studijskoj obvezi nije problem; problem je manjak.
- O kompatibilnosti ishoda učenja stranih i domaćih odlučuje se akademskom procjenom – ECTS koordinator usuglašava procjenu s nastavnicima, a student ne pregovara o kompatibilnosti svojih kolegija.

Čega se klonimo

- ❓ **NE:** „kolegij za kolegij” kao jedinog mjerila priznavanja.
- ❓ **NE:** umanjivanje ili uvećavanje ostvarenih ECTS bodova.
- ❓ **NE:** uvjetovanje priznavanja semestrom izvođenja kolegija na matičnom studiju.
- ❓ **NE:** prebacivanje procjene kompatibilnosti sadržaja i ishoda na studenta.
- ❓ **NE:** naknadno mijenjanje dogovorenog plana oslobađanja nakon povratka s mobilnosti.

Dva puta do iste fleksibilnosti

Preko programskih ishoda

- stečeni ishodi uspoređuju se s ishodima programa
- matrica poveznica i konstruktivno poravnanje
- rezultat je oslobođanje dijela programa

Preko studijskih obveza

- mjerilo je studijska obveza s minimalnim brojem ECTS bodova
- izbornost programa kao prostor priznavanja
- rezultat je ispunjena studijska obveza

Zajedničko obama pristupima

- odmak od uparivanja kolegij na kolegij
- mjerilo je program, a ne pojedini kolegij
- cilj je priznavanje cjelokupnog ostvarenog opterećenja i oslobođanje u istom obujmu

Izazovi koji ostaju

Institucionalni

- administrativna složenost postupka
- različiti IT sustavi i nepotpuna digitalizacija
- ovisnost prakse o pojedincima i njihovoj motivaciji

Akademski

- krutost pojedinih dijelova studijskog programa
- fleksibilnost u tumačenju podudarnosti ishoda
- lanci preuvjeta

Studentski

- strah od produljenja studija
- nejednaka informiranost i motiviranost
- ležeran odnos prema rokovima i dokumentaciji
- financijske prepreke sudjelovanju

- **Mobilnost treba biti sastavni dio studiranja, a ne iznimka.**
- Priznavanje i oslobađanje mora biti pravovremeno i potpuno – student ne smije biti „kažnjen” zbog mobilnosti.
- Fleksibilan studijski program je preduvjet, a dosljedno priznavanje i oslobađanje uvjet uspjeha.
- Institucionalna podrška i motivirano osoblje jednako su važni kao i jasna pravila.

Hvala 
na pozornosti!