

Primena federativnog učenja u predikciji aktivnosti studenata na e-learning kursevima

Marko Živanović, saradnik van radnog odnosa
 Fakultet informacionih tehnologija,
 Univerzitet Metropolitan
 Beograd, Republika Srbija
marko.zivanovic@metropolitan.ac.rs
 ORCID: 0009-0005-9264-3314

Danijela Milošević, redovni profesor
 Fakultet Tehničkih nauka u Čačku,
 Univerzitet u Kragujevcu
 Čačak, Republika Srbija
danijela.milosevic@ftn.kg.ac.rs
 ORCID: 0000-0002-4763-7012

Abstract—Ovaj rad istražuje primenu federativnog učenja (Federated Learning, FL) u predikciji poseta kursevima na osnovu log zapisa interakcija studenata. Federativno učenje omogućava treniranje modela na distribuiranim podacima bez potrebe za njihovim centralizovanjem, čime se poboljšava privatnost i sigurnost podataka. Istraživanje uključuje tri klijenta koji predstavljaju različite kurseve (Veštacka inteligencija, Operativni sistemi i Računarski hardver) i koristi LSTM neuronske mreže za vremensku predikciju broja poseta. Modeli se treniraju lokalno na svakom klijentu, dok se agregacija modela vrši na centralnom serveru koristeći Federated Averaging (FedAvg) algoritam. Performanse FL modela uporedene su sa centralizovanim modelima koristeći metriku modela R² Score. Rezultati pokazuju da FL pristup može postići konkurentne rezultate u poređenju sa centralizovanim modelima, uz značajne prednosti u zaštiti privatnosti podataka. Ovaj rad pruža doprinos u oblasti analitike učenja i otvara mogućnosti za dalja istraživanja primene FL u obrazovnim sistemima.

Ključne reči—federativno učenje, predikcija poseta kursevima, LSTM, analitika učenja, zaštita privatnosti.

I. UVOD

U današnje vreme, digitalno učenje postaje sve zastupljenije, a platforme poput Moodle DLS (Distance Learning System) generišu ogromne količine podataka o aktivnostima studenata. Ovi podaci, koji uključuju log zapise interakcija studenata sa sistemom, mogu se koristiti za analizu obrazovnih trendova i predikciju obrazovnih ishoda. Posebno je važno istaći da je Moodle DLS sistem najviše opterećen u periodima pred ispite i rokove za predaju zadataka, kada studenti intenzivno koriste platformu za učenje i konsultacije sa nastavnicima[1]. Jedan od ključnih problema u digitalnom učenju jeste predikcija poseta kursu, što omogućava unapređenje nastavnih metoda, optimizaciju resursa i prepoznavanje rizičnih studenata koji bi mogli odustati od kursa. Tradicionalne metode mašinskog učenja koje se oslanjaju na centralizovane podatke suočavaju se sa problemima privatnosti i sigurnosti podataka, posebno kada je reč o obrazovnim podacima. Federativno učenje (eng. Federated Learning, FL) predstavlja inovativan pristup koji omogućava treniranje modela mašinskog učenja na distribuiranim podacima, bez potrebe za njihovim centralizovanjem. U ovom radu primenjujemo FL za predikciju poseta kursu koristeći log zapise sa Moodle DLS sistema. Konkretno, koristimo tri klijenta koji predstavljaju tri različita kursa: Veštacka inteligencija, Operativni sistemi i Računarski hardver. Svaki klijent lokalno trenira model na svojim podacima, a agregacija modela se vrši na serveru koristeći Federated Averaging (FedAvg) strategiju. Cilj ovog istraživanja je analiza log zapisa sa Moodle DLS sistema kako bi se identifikovali ključni faktori koji utiču na posete kursevima, kao i primena LSTM modela u federativnom

okruženju za vremensku predikciju broja poseta. Takođe, rad se bavi evaluacijom performansi FL modela u poređenju sa centralizovanim modelima, pri čemu se tačnost predikcije procenjuje pomoću metrika kao što je **R2 Score**. Na osnovu dobijenih rezultata, biće moguće proceniti efikasnost federativnog učenja u predikciji obrazovnih trendova i potencijalne koristi koje ovaj pristup donosi u domenu digitalnog obrazovanja. Postavljena hipoteza ovog istraživanja jeste da će primena horizontalnog federativnog učenja poboljšati performanse predikcije poseta u određenim vremenskim intervalima, pri čemu će agregirani model na serveru nadmašiti pojedinačne lokalne modele u tačnosti predikcije.

II. PREGLED SRODNIH ISTRAŽIVANJA

Federativno učenje (FL) postaje sve zastupljenije u obrazovnoj analitici zbog svoje sposobnosti da omogući treniranje modela mašinskog učenja na distribuiranim podacima bez potrebe za njihovim centralizovanjem, što doprinosi zaštiti privatnosti. Više istraživanja se fokusira na primenu FL u obrazovnim sistemima, naročito u predikciji obrazovnih trendova i personalizovanom učenju. Fachola i saradnici istraživali su primenu FL za predikciju odustajanja studenata sa kurseva, koristeći distribuirane podatke iz različitih obrazovnih centara. Njihovi rezultati pokazuju da FL može postići performanse uporedive sa centralizovanim modelima, ali uz dodatne prednosti u pogledu privatnosti i sigurnosti podataka[2]. Takođe, u radu Prabha Hridi i saradnika istaknuti su tehnički i logistički izazovi implementacije FL u obrazovanju, uključujući prenos podataka, heterogenost sistema i balansiranje opterećenja između učesnika u FL mreži[3]. Pregledna studija Banabilaha i saradnika daje sveobuhvatan pregled FL tehnologija, arhitektura i primena, uključujući domene kao što su obrazovanje, zdravstvo, IoT i industrijski sistemi. Ovaj rad ističe ključne izazove FL-a, poput poboljšanja efikasnosti komunikacije, prilagođavanja heterogenim sistemima i optimizacije modela u distribuiranim okruženjima[4]. Yu i saradnici dodatno razmatraju specifične aspekte primene FL u rudarenju podataka, klasifikujući istraživanja prema oblastima primene, među kojima je i obrazovanje[5]. U radu Wen i saradnika analiziraju se ključni izazovi FL-a, kao što su mehanizmi zaštite privatnosti, problemi u heterogenim sistemima i optimizacija komunikacionih troškova. Ovaj rad takođe ističe buduće pravce istraživanja, među kojima su personalizacija modela, pravednost FL sistema i uloga FL-a u javnim sektorima. Osim toga, istraživanje Federativnog učenja za predikciju obrazovnih ishoda, koje koristi model FecMap sa višeslojnim mehanizmima zaštite privatnosti, pokazuje da FL može poboljšati personalizovano



učenje dok istovremeno štiti osetljive podatke studenata[6]. Rezultati ovog rada upoređeni su sa nalazima prethodnih srodnih istraživanja.

III. OPIS MOODLE SISTEMA I LOG ZAPISA KOJI SE KORISTE

A. Arhitektura i inženjerski aspekti Moodle DLS sistema

Moodle (eng. Modular Object-Oriented Dynamic Learning Environment) je sistem za upravljanje učenjem (eng. Learning management system) otvorenog koda koji omogućava kreiranje i upravljanje obrazovnim sadržajem, evaluaciju studenata i analizu podataka o učenju. Moodle DLS (eng. Distance Learning System) je varijanta Moodle platforme optimizovana za udaljeno učenje i kolaborativni rad[7].

Moodle DLS sistem koristi višeslojnu arhitekturu sa **prezentacionim slojem** (PHP, JavaScript), **aplikacionim slojem** (PHP, poslovna logika), **slojem baze podataka** (MySQL, PostgreSQL), **sistemom keširanja** (Redis, Memcached) i **API slojem** (REST, SOAP), dok modularni dizajn omogućava proširenje putem dodataka, uključujući: **Module kurseva** (kvizovi, forumi), **autentifikaciju** (LDAP, OAuth2, SAML) i **analitiku** (pranje korisničkih interakcija).

B. Analiza log fajlova Moodle DLS sistema

Moodle DLS generiše log zapise koji beleže sve korisničke interakcije. Primer zapisa dat je na slici (sl.1).

```

Bpexe,Puno ime korisnika","Pogodeni
korisnik","Kontekst dogadaja","Komponenta,"Naziv
dogadaja","Opis,Poreklo","IP adresa"
31/12/2020 11:09,"Marko Živanović",
,Ostali,Direktorijum,"Modul kursa prikazan","The user with id
'5170' viewed the 'Folder' activity with course module id
'12241',",web, 188.120.118.138
31/12/2020 11:09,"Marko Živanović",,"Kurs: Veštačka
inteligencija",Sistem,"Kurs prikazan","The user with id '5170'
viewed the course with id '220',web,188.120.118.138

```

sl.1 Prikaz sadržaja CSV datoteke sa log zapisima za kurs Veštačka inteligencija

Svaki zapis sadrži sledeće informacije:

- **Vreme dogadaja** – Tačan trenutak aktivnosti.
- **Korisnički identitet** – Puno ime korisnika.
- **Pogodeni korisnik** – Ako je primenljivo, korisnik na koga se odnosi događaj.
- **Kontekst dogadaja** – Kurs ili sistemska komponenta u kojoj se događaj desio.
- **Naziv dogadaja** – Tip akcije (npr. prikaz modula kursa).
- **Opis dogadaja** – Dodatne informacije o akciji.
- **Poreklo** – Izvor aktivnosti (npr. web, mobilna aplikacija).
- **IP adresa** – Identifikacija korisničke mreže.

C. Matematički model analize log fajlova

Matematički, analiza log podataka može se vršiti putem vremenskih serija:

$$X_t = f(X_{t-1}, X_{t-2}, \dots, X_{t-n}) + \epsilon_t, \quad (1)$$

gde je:

X_t – broj poseta u trenutku t ,

f – funkcija predikcije,

ϵ_t – šum (nasumične varijacije)[8].

IV. PREDSTAVLJANJE ARHITEKTURE FEDERATED LEARNING MODELA (KLJENTI I SERVER)

Federativno učenje (eng. Federated Learning - FL) predstavlja napredni pristup distribuiranom mašinskom učenju

koji omogućava treniranje modela direktno na uređajima korisnika, bez potrebe za centralizovanim prenosom i skladištenjem podataka. Ova tehnologija omogućava očuvanje privatnosti korisnika, smanjuje prenos podataka preko mreže i omogućava personalizaciju modela mašinskog učenja prema specifičnim potrebama korisnika. Ključne komponente federativnog učenja su: Klijenti i serveri.

A. Klijenti

Klijenti u federativnom učenju predstavljaju pojedinačne uređaje ili entitete koji poseduju sopstvene podatke i vrše lokalnu obuku modela. Ovi klijenti mogu biti mobilni telefoni, IoT uređaji, računari ili serveri u distribuiranim sistemima (slika sl.2). Svaki klijent trenira lokalnu kopiju modela koristeći samo svoje podatke, bez deljenja sirovih podataka sa drugim entitetima, čime se čuva privatnost i sigurnost podataka. Iako svi klijenti koriste istu arhitekturu modela, podaci na svakom uređaju mogu biti različiti, što može dovesti do nebalansiranih i heterogenih skupova podataka. Proces lokalne obuke obuhvata više epoha treniranja na lokalnim podacima, nakon čega se ažurirani parametri modela (težine i pristrasnosti) šalju ka **centralnom serveru**. Klijenti mogu koristiti različite optimizacione algoritme, ali se najčešće koristi **Stochastic Gradient Descent (SGD)** ili njegove varijante kako bi se minimizovala funkcija greške modela[9]. U zavisnosti od okruženja i raspoloživih resursa, klijenti mogu imati ograničenu **procesorsku snagu, memoriju i mrežne kapacitete**, što može uticati na efikasnost i pouzdanost federativnog učenja.



sl.2 Klijentski računarski sistemi

B. Centralni server

Centralni server je ključna komponenta federativne arhitekture koja upravlja procesom obuke modela i omogućava koordinaciju između više klijenata (sl.3). Njegova glavna funkcija je agregacija ažuriranih modela koje šalju klijenti nakon lokalne obuke. Ova agregacija se obično vrši pomoću algoritma **Federated Averaging (FedAvg)**, koji kombinuje težine modela iz svih klijenata i izračunava novi globalni model. Nakon agregacije, novi globalni model se distribuira nazad klijentima, omogućavajući im da nastave sa sledećim ciklusom lokalne obuke. Ovaj proces se ponavlja kroz više iteracija dok se ne postigne **konvergencija modela**. Centralni server može primeniti različite tehnike za optimizaciju modela, kao što su težinsko prilagođavanje učešća klijenata, filtriranje modela niskog kvaliteta i prilagođavanje učestalosti ažuriranja. U nekim slučajevima, federativno učenje može koristiti hijerarhijsku arhitekturu sa više posredničkih servera kako bi se poboljšala skalabilnost i smanjila opterećenost centralnog servera. Sigurnosni izazovi, kao što su zaštita od napada trovanjem modela (eng. model poisoning) i osiguravanje integriteta podataka, predstavljaju ključne aspekte u dizajnu centralnog servera[9].



sl.3 Centralni server

V. STOHASTIČKI GRADIJENTNI SPUST

Stohastički gradijentni spust (eng. Stochastic Gradient Descent, SGD) je optimizaciona metoda koja se široko koristi u oblastima mašinskog učenja i dubokog učenja. Reč je o varijanti **standardnog gradijentnog spusta** (eng. Gradient Descent, GD) koja umesto da koristi celu trenažnu skupinu podataka (eng. batch gradient descent), oslanja se na slučajno odabранe podskupove podataka (eng. mini-batches) za ažuriranje težina modela. Ova tehnika omogućava značajno ubrzanje konvergencije i poboljšanje sposobnosti generalizacije modela, što je posebno važno kod velikih i distribuiranih skupova podataka, kao što su log zapisi sa Moodle Distance Learning System (DLS) platforme[10]. Neka je $f(\theta)$ funkcija troška koju želimo minimizirati optimizacijom njenih parametara θ . Standardni batch gradient descent računa gradijent funkcije gubitka L u odnosu na parametre θ koristeći sve dostupne podatke:

$$\theta_{t+1} = \theta_t - \eta \nabla L(\theta) \quad (2)$$

gde je:

η (*learning rate*) – stopa učenja, koja određuje korak prilagodavanja težina,

$\nabla L(\theta)$ – gradijent funkcije gubitka L u odnosu na θ ;

Stohastički gradijentni spust (SGD) rešava ovaj problem tako što aproksimira gradijent koristeći samo jedan slučajno odabran uzorak x_i u svakoj iteraciji:

$$\theta_{t+1} = \theta_t - \eta \nabla L(\theta_t, x_i) \quad (3)$$

Međutim, u velikim podacima, računanje gradijenta na celom skupu podataka može biti skupo[11].

Ova aproksimacija omogućava bržu konvergenciju i poboljšava efikasnost algoritma.

VI. TIP NEURONSKE MREŽE LONG SHORT-TERM MEMORY

Long Short-Term Memory (LSTM) je poseban tip rekurentne neuronske mreže (RNN) koji je dizajniran da reši problem dugoročnog pamćenja u sekvencijalnim podacima. Klasične RNN mreže pate od problema gubitka informacija zbog **eksponencijalnog slabljenja gradijenata** (problem dugih zavisnosti), dok LSTM koristi poseban mehanizam čelijskih stanja i vrata da zadrži bitne informacije kroz duže periode.

A. Arhitektura LSTM

LSTM neuronska mreža se sastoji od osnovnih blokova koji uključuju tri glavne kapije:

- Ulagana vrata (eng. input gate, i_t) koja odlučuju koje nove informacije treba dodati u stanje čelije.
- Zaboravna vrata (eng. forget gate, f_t) koja odlučuju koje informacije treba odbaciti iz prethodnog stanja.
- Izlazna vrata (eng. output gate, o_t) koja kontrolišu šta će biti izlaz iz trenutnog čvora mreže.

LSTM blok funkcioniše na sledeći način:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \sigma_c(W_c x_t + b_c) \quad (7)$$

$$h_t = o_t \odot \sigma_h(C_t) \quad (8)$$

gde su W i b parametri tretiranja, σ je sigmoidna funkcija aktivacije neuronske mreže [13].

VII. HORIZONTALNI I VERTIKALNI TIP FEDERATIVNOG UČENJA

Federated Learning (FL) može se klasifikovati na **horizontalni** i **vertikalni** model učenja, u zavisnosti od toga kako su podaci raspoređeni među klijentima. U ovom istraživanju korišćen je horizontalni tip federativnog učenja.

A. Horizontalni tip federativnog učenja

Horizontalni federativni model, poznat i kao (eng. sample-partitioned FL) koristi se kada različiti klijenti imaju slične atribute (eng. feature space), ali različite korisnike (primerke podataka). Drugim rečima, svi klijenti imaju istu strukturu podataka, ali različite instance.

Neka svaka institucija (klijent) k poseduje skup podataka:

$$D_k = \{(x_i, y_i)\}_{i=1}^{n_k}, \quad (9)$$

Gde su x_i ulazne karakteristike, a y_i izlazne vrednosti.

Glavna optimizacija funkcije gubitaka data je u jednačini:

$$F(w) = \sum_{k=1}^K \frac{n_k}{N} F_k(w) \quad (10)$$

gde je N ukupan broj podataka, a $F_k(w)$ funkcija gubitaka za klijenta k . Često se koristi **FedAvg** algoritam u ovom modelu[14]. Česti su primeri upotrebe u bankarskom sektoru gde više banaka u različitim gradovima imaju slične podatke o korisnicima kao što su ime, prihod, kreditni skor. Svaka banka poseduje informacije o svojim klijentima. U zdravstvenom sektoru kada bolnice imaju atribute pacijenata kao što su visina, težina, krvni pritisak, ali različite pacijetne.

B. Vertikalni tip federativnog učenja

Vertikalni federativni model (eng. feature-partitioned FL) se koristi kada različiti klijenti imaju različite atribute (eng. feature space) za iste korisnike. To znači da svaka institucija ima delimične informacije o istim entitetima. U koliko postoje dve institucije institucija A i B, gde institucija A ima skup podataka $D_A = \{x_A\}$, a institucija B ima skup podataka $D_B = \{x_B\}$ za iste korisnike[15]. Zajednička funkcija gubitaka se predstavlja na sledeći način:

$$F(w_A, w_B) = \sum_{i=1}^N \ell(w_A, w_B, x_{A,i}, x_{B,i}, y_i) \quad (11)$$

Gde je w_A model za instituciju A, w_B model za instituciju B, a ℓ funkciju gubitaka. Za obuku se koriste sigurnosni protokoli kao što su: **Secure Multi-Party Computation (SMPC)** i **Homomorfne enkripcije** da bi se osigurala privatnost podataka. Najznačajniji primjeri primene u bankarstvu se ogledaju u tome što se postiče finansijska stabilnost klijenta, dok platforme elektronske trgovine imaju podatke o njihovom ponašaju pri kupovini. Takođe, tipičan primer su osiguravajuće kompanije koje imaju podatke o polisama i predthosnim odštetnim zahtevima. Česte su primene u reklama za oglašavanje kao što su demografski podaci, dok društvena mreža ima podatke o interesovanjima korisnika.

VIII. OPŠTI PROCES FEDERATIVNOG UČENJA

Federated Averaging (FedAvg) je osnovni algoritam za federativno učenje koji omogućava distribuirano treniranje modela bez deljenja sirovih podataka između uređaja (klijenata). Cilj je optimizacija globalnog modela kroz

iterativnu agregaciju ažuriranja modela koje dolazi od više klijenata. Globalni model w^0 se inicijalizuje i distribuiru svim klijentima. U svakoj komunikacionoj rundi t , podskup klijenata S_t (nasumično odabranih) prima trenutni globalni model w^t . Svaki klijent k ažurira model na svojim podacima koristeći **mini-batch SGD** ili drugu optimizaciju[12].

Ako označimo lokalne podatke klijenta k kao D_k , tada minimizujemo njegovu lokalnu funkciju gubitka:

$$F_k(w) = \frac{1}{|D_k|} \sum_{i \in D_k} \ell(w, x_i, y_i), \quad (12)$$

gde je:

$\ell(w, x_i, y_i)$ funkcija gubitaka za podatak (x_i, y_i) .

Klijent ažurira model primenom E koraka SGD:

$$w_k^{t+1} = w_k^t - \eta \nabla F_k(w_k^t) \quad (13)$$

gde je:

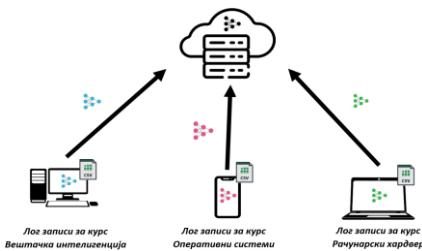
η (*learning rate*) – stopa učenja, koja određuje korak prilagođavanja težina.

Na centralnom serveru se nakon lokalnog treniranja sa svakog klijenta vraća svoj ažurirani model w_k^{t+1} .

Server izračunava **ponderisanu prosečnu vrednost** svih ažuriranih modела, gde je ponderisanje proporcionalno broju podataka na svakom klijenta, a dato je na sledećoj formuli:

$$w^{t+1} = \sum_{k \in S_t} \frac{|D_k|}{\sum_{j \in S_t} |D_j|} w_k^{t+1} \quad (14)$$

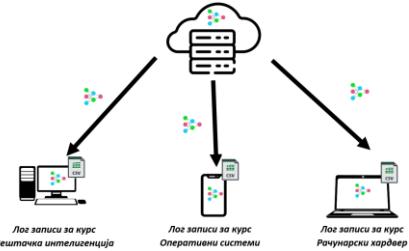
Ako posmatramo udruženi krug kao jednu cikličnu fazu u procesu sticanja znanja proes federalivnog učenja prvo započinje ciklus inicijalizacijom, pri čemu centralni server na osnovu ulaznih parametara određuje odgovarajući model mašinskog učenja, poput linearne regresije, neuronskih mreža ili metoda pojačanja, koji će biti treniran na distribuiranim lokalnim čvorovima. Nakon inicijalizacije, čvorovi se aktiviraju i ostaju u stanju pripravnosti dok ne dobiju instrukcije od servera (sl.3).



sl.3 Klijenti šalju trenirane modele serveru

U sledećem koraku, centralni server bira deo lokalnih čvorova koji će učestvovati u treniranju modela na svojim lokalnim podacima, dok preostali čvorovi čekaju naredni ciklus. Odabrani čvorovi preuzimaju aktuelnu verziju modela, a zatim server određuje precizan način treniranja, uključujući parametre poput mini-batch ažuriranja pomoću metode gradijentnog spuštanja. Kada lokalni čvorovi završe proces obuke, oni šalju ažurirane verzije modela nazad serveru, koji ih agregira, ažurira globalni model i ponovo distribuiru ažuriranu verziju čvorovima. Istovremeno, centralni server upravlja potencijalnim problemima, poput nedostupnih čvorova ili izgubljenih ažuriranja. Ovaj proces se ponavlja kroz više iteracija sve dok se ne ispunи neki od unapred definisanih kriterijuma završetka, poput dostizanja maksimalnog broja iteracija ili zadovoljavajuće tačnosti

modela, nakon čega centralni server vrši završnu agregaciju i finalizuje globalni model[16].



sl.4 Server vraća odgovor klijentima

IX. METODE ISTRAŽIVANJA

Istraživanje se temelji na implementaciji horizontalnog federalivnog učenja, gde tri klijentske jedinice lokalno treniraju model koristeći sopstvene podatke to su log zapisi sa tri kursa (veštačka inteligencija, operativni sistemi, računarski hardver) dok centralni server upravlja procesom agregacije i evaluacije modela. Ovaj metod omogućava distribuirano učenje bez potrebe za deljenjem sirovih podataka između klijenata i servera, čime se unapređuje privatnost i sigurnost podataka. Podaci koji su korišćeni za trening obuhvataju 2020, 2021, 2022, 2023 i 20204 godinu. Koja je uključivala brojne izazove u savremenom obrazovnom procesu.

A. Hipoteza istraživanja

Postavljena hipoteza ovog istraživanja jeste da će primena horizontalnog federalivnog učenja poboljšati performanse predikcije poseta u određenim vremenskim intervalima, pri čemu će agregirani model na serveru nadmašiti pojedinačne lokalne modele u tačnosti predikcije.

B. Eksperimentalni okvir

Sistem se sastoji od tri klijentske aplikacije i jednog servera. Svaki klijent preuzima podatke iz lokalne baze podataka i vrši njihovu obradu, gde se podaci transformišu u relevantne karakteristike, poput meseca, godine, prisustva vikenda i trigonometrijskih vrednosti koje reprezentuju sezonske fluktuacije. Nakon preprocesiranja, podaci se skaliraju pomoću StandardScaler metode kako bi se obezbedila konzistentnost modela. Postupak treniranja federalivnog modela mašinskog učenja dat je na slici sl.5. Za modeliranje vremenskih serija koristi se unapređena LSTM (eng. Long Short-Term Memory) neuronska mreža sa tri ili više slojeva i 128–256 skrivenih jedinica. Finalna implementacija koristi unapređenu LSTM neuronsku mrežu (klasa EnhancedLSTM), koja se sastoji od tri rekurentna sloja sa 256 skrivenih jedinica i jednim potpuno povezanim (fully connected) izlaznim slojem. Ulagani vektor sadrži 5 karakteristika koje reprezentuju vremenske osobine meseca i godine (uključujući sin i kosinus komponente sezonskih fluktuacija). Model koristi nn.LSTM sloj PyTorch biblioteke sa batch_first=True, što omogućava unos podataka u formatu [batch_size, sequence_length, features], i predikcija se vrši na osnovu poslednjeg vremenskog koraka. Izlaz modela je jedna numerička vrednost po instanci, koja predstavlja procenjeni broj poseta. Ova arhitektura omogućava modelu da efikasno uči sezonske obrasce i dugoročne zavisnosti u vremenskim serijama. Modeli se treniraju lokalno na svakoj klijentskoj jedinici, a potom ažurirani parametri modela šalju centralnom serveru koji vrši agregaciju pomoću algoritma

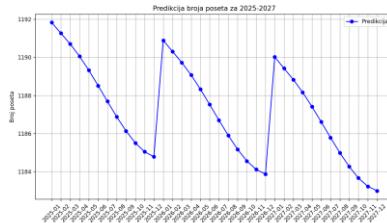
FedAvg (eng. Federated Averaging). Ovaj pristup omogućava poboljšanu tačnost predikcije dok istovremeno smanjuje potrebu za direktnim deljenjem podataka između klijenata i servera.

```
[ 92mINFO [ 90m: [ROUND 1]
[ 92mINFO [ 90m: configure_fit: strategy sampled 2 clients (out of 3)
[ 92mINFO [ 90m: aggregate_fit: received 3 results and 0 failures
[ 92mINFO [ 90m: No fit_metrics_aggregation_n provided
[ 92mINFO [ 90m: configure_evaluate: strategy sampled 3 clients (out of 3)
[ 92mINFO [ 90m: aggregate_evaluate: received 3 results and 0 failures
[ 92mINFO [ 90m: [ROUND 2]
[ 92mINFO [ 90m: configure_fit: strategy sampled 3 clients (out of 3)
[ 92mINFO [ 90m: aggregate_fit: received 3 results and 0 failures
[ 92mINFO [ 90m: configure_evaluate: strategy sampled 3 clients (out of 3)
[ 92mINFO [ 90m: aggregate_evaluate: received 3 results and 0 failures
[ 92mINFO [ 90m: [ROUND 3]
[ 92mINFO [ 90m: configure_fit: strategy sampled 3 clients (out of 3)
[ 92mINFO [ 90m: aggregate_fit: received 3 results and 0 failures
[ 92mINFO [ 90m: configure_evaluate: strategy sampled 3 clients (out of 3)
[ 92mINFO [ 90m: aggregate_evaluate: received 3 results and 0 failures
[ 92mINFO [ 90m: [ROUND 4]
[ 92mINFO [ 90m: configure_fit: strategy sampled 3 clients (out of 3)
```

sl.5 Postupak treniranja modela mašinskog učenja

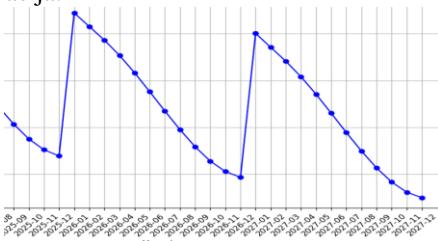
C. Postupak treniranja i evaluacije

Tokom svakog ciklusa federativnog učenja, centralni server bira podskup klijenata koji učestvuju u treningu modela. Klijenti preuzimaju trenutnu verziju globalnog modela i obučavaju ga na lokalnim podacima koristeći mini-batch gradient descent optimizaciju sa Adam optimizatorom. Nakon završetka lokalnog treniranja, ažurirani parametri se šalju serveru, koji vrši agregaciju svih modela kako bi se dobio poboljšani globalni model. Evaluacija modela se vrši na serveru kroz metriku koeficijent determinacije (R^2), čime se meri preciznost predikcija. U tabeli 1 dati su rezultati predikcije po iteracijama. Vredno je primetiti da R^2 skor tokom prvih iteracija opada, a zatim postepeno raste, što nije tipičan obrazac stabilne konvergencije. Ovakvo ponašanje može ukazivati na početnu nestabilnost modela, neadekvatnu inicijalizaciju težina ili varijabilnost među podacima klijenata. Takođe, ovo može biti posledica inherentne neujednačenosti u federativnom učenju, gde klijenti koriste različite skupove podataka. Može se zaključiti da model konvergira efikasno u stabilno u svim uslovima. Nakon završetka obuke, globalni model se koristi za predikciju budućih vrednosti za period od 2025. do 2027. godine data je na slici (sl.6). Predikcije se vraćaju na originalnu skalu pomoću inverzne Min-Max normalizacije kako bi se rezultati mogli adekvatno interpretirati. Vizualizacija predikcija omogućava analizu sezonskih trendova i varijacija u broju poseta.



sl.6 Predikcija broja poseta za period 2025-2027 godine

Posebno je značajan deo koda koji se odnosi na buduće dogadjaje na slici 7 možemo videti kako izgledaju buduće vrednosti. Sam sistem je treniran i na dogadjajima iz budućnosti kroz 20 iteracija.



sl.7 Predikcija broja poseta za period druge polovine 2025 pa do 2027 godine

U tabeli 1 ponašanje R^2 skora u ovoj tabeli sugerira da model prelazi kroz fazu prilagođavanja, gde počinje sa lošim performansama zbog učestalog istraživanja podataka, a zatim uči stabilne obrasce i konačno se stabilizuje u visokom učinku. Ovo je tipično za modele koji zahtevaju višestruke iteracije da bi u potpunosti naučili obrasce u podacima.

TABELA I. R² SCORE PO ITERACIJA

ITERACIJA	R ² SCORE
1.	0.8609
2.	0.7779
3.	0.7343
4.	0.6971
5.	0.6662
6.	0.6416
7.	0.6234
8.	0.6115
9.	0.6059
10.	0.6066
11.	0.6135
12.	0.6268
13.	0.6463
14.	0.6720
15.	0.7037
16.	0.7414
17.	0.7830
18.	0.8233
19.	0.8621
20.	0.8983

Tabela 2 prikazuje predikcije za server i tri klijenta u periodu od 2025. do 2027. godine, gde se vrednosti servera i klijenata smanjuju postepeno tokom vremena. Vrednost servera počinje od 1192 u januaru 2025. godine i opada do 1183 u decembru 2027. godine, što ukazuje na smanjenje resursa servera ili opterećenja na serveru tokom vremena. Slično tome, vrednosti klijenata (Klijent 1, Klijent 2, Klijent 3) opadaju proporcionalno padanju vrednosti servera. Ovaj obrazac ukazuje na to da su klijenti u međusobnom zavisnom odnosu sa serverom, pa kako server gubi kapacitet, smanjuje se i opterećenje na svakog od klijenata. Što pokazuje da smanjenje opterećenja servera dovodi do smanjenja resursa ili potrebe za klijentima. Iako server i klijenti opadaju, opadanje nije potpuno isto u svim mesecima. Ovaj obrazac se ne poklapa sa objašnjenjem poseta kursevima. Vrednosti klijenata opadaju za 1 mesecno, dok server opada za 1 ili 2, što pokazuje da smanjeno opterećenje servera dovodi do smanjenja resursa ili potreba za klijentima. Iako server i klijenti opadaju, opadanje nije potpuno jednak u svim mesecima, pri čemu se server povremeno smanjuje za 2, a klijenti ostaju dosledni u opadanju za 1 mesecno. Nakon stabilizacije servera na nižim vrednostima, uočava se stabilnost vrednosti klijenata, koji ostaju konstanti od oktobra 2025. godine do kraja 2027. godine, sa minimalnim promenama. Rezultati ukazuju na vrlo slične vrednosti, što je posledica ograničene mogućnosti pristupa drugim kursevima. Zbog ovog ograničenja, podaci o korisnicima su redukovani na samo nekoliko kurseva, što smanjuje varijaciju u rezultatima i otežava identifikaciju specifičnih obrazaca u ponašanju studenata.

TABELA II. PREDIKCIJE POSETA KLIJENATA

Datum predikcije	Server	Klijent 1	Klijent 2	Klijent 3
2025-01-01	1192	369	368	367
2025-02-01	1191	368	367	366
2025-03-01	1191	368	367	366
2025-04-01	1190	367	366	365
2025-05-01	1189	366	365	364
2025-06-01	1189	366	365	364
2025-07-01	1188	365	364	363
2025-08-01	1187	364	363	362
2025-09-01	1186	363	362	361
2025-10-01	1186	363	362	361
2025-11-01	1185	362	361	360
2025-12-01	1185	362	361	360
2026-01-01	1191	368	367	366
2026-02-01	1190	367	366	365
2026-03-01	1190	367	366	365
2026-04-01	1189	366	365	364
2026-05-01	1188	365	364	363
2026-06-01	1188	365	364	363
2026-07-01	1187	364	363	362
2026-08-01	1186	363	362	361
2026-09-01	1185	362	361	360
2026-10-01	1185	362	361	360
2026-11-01	1184	361	360	359
2026-12-01	1184	361	360	359
2027-01-01	1190	368	367	366
2027-02-01	1189	367	366	365
2027-03-01	1189	367	366	365
2027-04-01	1188	366	365	364
2027-05-01	1187	365	364	363
2027-06-01	1187	365	364	363
2027-07-01	1186	364	363	362
2027-08-01	1185	363	362	361
2027-09-01	1184	362	361	360
2027-10-01	1184	362	361	360
2027-11-01	1183	361	360	359
2027-12-01	1183	361	360	359

ZAKLJUČAK

Ovaj rad pokazuje da federativno učenje omogućava efikasnu i sigurnosnu predikciju poseta kursevima na Moodle DLS platformi. Korišćenjem LSTM modela u FL okruženju, postigli su se tačne prognoze bez centralizacije podataka. Rezultati pokazuju da FL može biti dobra alternativa centralizovanom učenju, posebno u zaštiti privatnosti. Buduća istraživanja mogu se usmeriti ka optimizaciji FL metodologije kroz naprednije tehnike agregacije modela, kao i ka primeni različitih arhitektura neuronskih mreža za poboljšanje tačnosti predikcije. Takođe, moguća je ekstenzija istraživanja na veći broj kurseva i različite tipove obrazovnih platformi kako bi se steklo šire razumevanje obrazovnih obrazaca u digitalnom okruženju.

REFERENCE/LITERATURA

- [1] Kopylova, N., & Hockicko, P., "Methodological Basics of Digital Technologies in the Innovative Education System," in 2024 ELEKTRO (ELEKTRO), 2024, pp. 1-7. IEEE.
- [2] Fachola, C., Tornaria, A., Bermolen, P., Capdehourat, G., Etcheverry, L., & Fariello, M. I., "Federated learning for data analytics in education," *Data*, vol. 8, no. 2, p. 43, 2023.
- [3] Hridi, A. P., Sahay, R., Hosseinalipour, S., & Akram, B., "Revolutionizing AI-Assisted Education with Federated Learning: A Pathway to Distributed, Privacy-Preserving, and Debiased Learning Ecosystems," in Proceedings of the AAAI Symposium Series, vol. 3, no. 1, pp. 297-303, May 2024.
- [4] Banabilah, S., Aloqaily, M., Alsayed, E., Malik, N., & Jararweh, Y., "Federated learning review: Fundamentals, enabling technologies, and

future applications," *Information Processing & Management*, vol. 59, no. 6, p. 103061, 2022.

- [5] Yu, B., Mao, W., Lv, Y., Zhang, C., & Xie, Y., "A survey on federated learning in data mining," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 12, no. 1, p. e1443, 2022.
- [6] Wen, J., Zhang, Z., Lan, Y., Cui, Z., Cai, J., & Zhang, W., "A survey on federated learning: challenges and applications," *International Journal of Machine Learning and Cybernetics*, vol. 14, no. 2, pp. 513-535, 2023.
- [7] Jovanovic, M., Vukicevic, M., Milovanovic, M., & Minovic, M., "Using data mining on student behavior and cognitive style data for improving e-learning systems: a case study," *International Journal of Computational Intelligence Systems*, vol. 5, no. 3, pp. 597-610, 2012.
- [8] Bottou, L., "Stochastic gradient descent tricks," in *Neural Networks: Tricks of the Trade: Second Edition*, pp. 421-436, Berlin, Heidelberg: Springer, 2012.
- [9] Sun, T., Li, D., & Wang, B., "Decentralized federated averaging," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 45, no. 4, pp. 4289-4301, 2022.
- [10] Tian, Y., Zhang, Y., & Zhang, H., "Recent advances in stochastic gradient descent in deep learning," *Mathematics*, vol. 11, no. 3, p. 682, 2023.
- [11] Kamal, S., & Jalal, A., "A novel human interaction recognition via composite features and Max entropy classifier," in *Proceedings of the 2024 19th International Conference on Emerging Technologies (ICET)*, November 2024.
- [12] Gower, R. M., Loizou, N., Qian, X., Sailanbayev, A., Shulgin, E., & Richtárik, P., "SGD: General analysis and improved rates," in *International Conference on Machine Learning*, pp. 5200-5209, PMLR, May 2019.
- [13] Gers, F. A., Schraudolph, N. N., & Schmidhuber, J., "Learning precise timing with LSTM recurrent networks," *Journal of Machine Learning Research*, vol. 3, Aug 2002, pp. 115-143.
- [14] Stergiou, C. L., Psannis, K. E., & Gupta, B. B., "InFeMo: Flexible big data management through a federated cloud system," *ACM Transactions on Internet Technology (TOIT)*, vol. 22, no. 2, pp. 1-22, 2021.
- [15] Valdeira, P., Wang, S., & Chi, Y., "Vertical Federated Learning with Missing Features During Training and Inference," *arXiv preprint arXiv:2410.22564*, 2024.
- [16] Sørby, S., *Security and Privacy Concerns in Federated Learning when Applied to Precision Medicine Data Standards*, Master's thesis, NTNU, 2024.

ABSTRACT

Abstract—This paper explores the application of Federated Learning (FL) in predicting course visits based on student interaction log records. Federated Learning enables model training on distributed data without requiring centralization, thereby enhancing data privacy and security. The study involves three clients representing different courses (Artificial Intelligence, Operating Systems, and Computer Hardware) and utilizes LSTM neural networks for time-series prediction of visit counts. Models are trained locally on each client, while model aggregation is performed on a central server using the Federated Averaging (FedAvg) algorithm. The performance of the FL models is compared to centralized models using metrics such as Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and R² Score. The results show that the FL approach can achieve competitive performance compared to centralized models while providing significant advantages in data privacy protection. This paper contributes to the field of learning analytics and opens opportunities for further research on FL applications in educational systems.

PRIMENA FEDERATIVNOG UČENJA U PREDIKCIJI AKTIVNOSTI STUDENATA NA E-LEARNING KURSEVIMA

Marko Živanović, Danijela Milošević