

Primena algoritama mašinskog učenja za klasifikaciju CTG signala u oblaku

Enis Osmani
Centar za radiologiju -
Odeljenje neuroradiologije
Odsek medicinske fizike - X nož
Univerzitetski Klinički centar Srbije
Beograd, Srbija
enisosmani.kcs@gmail.com
ORCID: 0009-0000-0626-3985

Milorad Paskas
Odsek Visoka škola za informacione i komunikacione tehnologije
Akademija tehničko-umetničkih strukovnih studija Beograd
Beograd, Srbija
milorad.paskas@ict.edu.rs
ORCID: 0000-0001-7273-0625

Abstract— Digitalizacija u zdravstvu, podržana primenom tehnologija veštačke inteligencije (AI) i Interneta stvari (IoT), nudi značajne mogućnosti za poboljšanje dijagnostike, praćenja pacijenata i optimizaciju medicinskih procesa. Microsoft Azure platforma pruža širok spektar rešenja koja omogućavaju zdravstvenim ustanovama da integrišu AI i IoT tehnologije kako bi se poboljšao kvalitet nege i povećala operativna efikasnost. U ovom radu ispituju se načini na koje se veštačka inteligencija i IoT tehnologije, podržane Microsoft Azure platformom, mogu primeniti u optimizaciji zdravstvenih usluga kroz analizu podataka kardiokardiografije. Posebna pažnja posvećena je primeni ovih tehnologija u praćenju vitalnih parametara pacijenata, prediktivnoj analitici i poboljšanju operativne efikasnosti zdravstvenih ustanova. Razmatraju se izazovi i ograničenja povezana sa implementacijom ovih tehnologija, kao i potencijalna rešenja za njihovo prevazilaženje. Prikazani su konkretni primeri primene, sumirani su ključni nalazi i razmatrane su buduće perspektive razvoja u ovoj oblasti.

Ključne reči— IoT, mašinsko učenje, veštačka inteligencija, Microsoft Azure, računarstvo u oblaku

I. UVOD

Platforma Microsoft Azure nudi širok spektar rešenja koja omogućavaju zdravstvenim institucijama da integrišu AI (*Artificial Intelligence*) i IoT (*Internet of Things*) tehnologije u cilju poboljšanja kvaliteta nege i efikasnosti rada. Rešenja *Azure Healthcare IoT* [1] omogućavaju prikupljanje, analizu i sigurnu obradu podataka sa medicinskih uređaja u realnom vremenu, čime se doprinosi bržem donošenju odluka i personalizovanoj nezi pacijenata. Korišćenjem naprednih analitičkih alata i AI modela na platformi Azure, moguće je predviđati zdravstvene ishode, automatizovati procese i smanjiti opterećenje medicinskog osoblja. U oblasti zdravstvene zaštite, Azure omogućava naprednu obradu podataka, implementaciju veštačke inteligencije i određenih IoT rešenja koja unapređuju kvalitet brige o pacijentima, poboljšavaju operativnu efikasnost i pojačavaju sigurnost podataka.

Primena Azure IoT rešenja u zdravstvu donosi višestruke prednosti. Jedna od ključnih prednosti je brže donošenje odluka zahvaljujući analizi podataka u realnom vremenu, što omogućava ranu detekciju zdravstvenih problema kod pacijenata. Druga prednost je smanjenje operativnih troškova, jer IoT rešenja omogućavaju efikasnije korišćenje resursa i smanjuju potrebu za nepotrebnim hospitalizacijama. Azure IoT

rešenja omogućavaju povećanje kvaliteta same nege, jer se lekarima i medicinskom osoblju pružaju precizni podaci o pacijentima u svakom trenutku. *Azure Healthcare IoT* rešenja omogućavaju povezivanje medicinskih uređaja i senzora sa platformom u oblaku, čime se prikupljaju podaci o pacijentima u realnom vremenu. Jedan od bitnih prednosti rešenja *Azure Healthcare IoT* jeste upotreba same platforme za udaljeno nadgledanje zdravstvenog stanja pacijenata (*Remote Patient Monitoring*), koje omogućava lekarima da prate vitalne znake pacijenata na daljinu, jer se na taj način smanjuje potreba za fizičkim posetama lekara sobama za negu pacijenata. Rezultati se uvek mogu u realnom vremenu iščitavati i direktno uticati na urgenciju, ukoliko je potrebna kod nekog pacijenta.

Mašinsko učenje (*Machine Learning*, ML) [2] na platformi Azure u kontekstu IoT-a predstavlja integrisani proces kroz koji se podaci prikupljeni sa povezanih uređaja (senzora, monitora, pametnih uređaja) analiziraju i koriste za kreiranje prediktivnih i adaptivnih modela ponašanja.

Ključna prednost rešenja mašinskog učenja u oblaku je mogućnost obuke modela na različitim računarskim resursima [3]. Korisnici mogu da treniraju modele lokalno na sopstvenim računarima, korišćenjem resursa u oblaku, ili skalirati trening na distribuirane klastere kako bi ubrzali obradu podataka i poboljšali performanse modela. Ova fleksibilnost omogućava optimizaciju procesa u zavisnosti od potreba projekta i raspoložive infrastrukture. Platforma Azure je usklađena sa vodećim regulativama kao što su HIPAA (*Health Insurance Portability and Accountability Act*) i GDPR (*General Data Protection Regulation*). Alatkice *Azure Security Center* i *Azure Policy* omogućavaju organizacijama da prate usklađenost sistema sa standardima i da brzo reaguju na potencijalne bezbednosne incidente.

U ovom radu korišćene su tehnike mašinskog učenja sa nadziranjem dostupne na platformi Azure kako bi se izvršila klasifikacija CTG signala. U obzir je uzeto više scenarija, pri čemu su testirani različiti klasifikatori i ispitane mogućnosti svakog od njih. Kroz komparativnu analizu korišćenih klasifikatora i više metrika za evaluaciju utvrđene su prednosti i mane svakog od njih.

Rad je organizovan na sledeći način. U sekciji II opisane su metode mašinskog učenja dostupne na platformi u oblaku, kao i


korišćena šema za klasifikaciju CTG signala. Numerički rezultati eksperimenata sprovedenih za različite klasifikatore prikazani su u sekciji III. Sekcija IV donosi zaključke i dalje ciljeve istraživanja na ovom planu.

II. METODOLOGIJA


Kardiotokografija (CTG) je neinvazivna dijagnostička metoda koja se koristi u savremenom akušerstvu za praćenje fetalnog srčanog ritma (FHR) i kontrakcija materice (UC), kako bi se procenilo stanje fetusa tokom trudnoće i u toku porođaja [4]. CTG se koristi za otkrivanje određenih bolesti srca deteta poput hipoksije (nedostatak kiseonika), fetoplacentarne insuficijencije i za praćenje odgovora ploda na kontrakcije materice. Takođe je neophodna metoda za procenu rizika od neželjenih ishoda i razumevanje gradacija fetalnog stresa i odgovora na stres bebe, što rezultira time da se donesu zaključci o stanju bebe i proceni potreba za intervencijom (carski rez, potpomognuti porođaj).

Korišćeni CTG signali dostupni su na repozitorijumu *UCI Machine Learning Repository* [5]. Svaki CTG signal predstavljen je nizom parametara koji se odnose na karakteristike fetalnog srčanog ritma i kontrakcija materice. Kao očekivani izlaz klasifikacije CTG signala koriste se tri kategorije zdravstvenog stanja fetusa: normalno, sumnjivo i patološko.

Eksperiment je izvršen na onlajn platformi Microsoft Azure [6], gde je korišćen servis *Azure Machine Learning* (Azure ML) [7]. Na servisu Azure ML je započet proces kreiranjem *Azure Machine Learning* radnog zadatka (*workspace*) pod nazivom ProjekatCTG, koji je smešten u grupu resursa MLprojekat, gde će takođe biti smešteni svi resursi koji će biti kreirani u toku izrade projekta. U okviru zadatka kreirana je računarska instanca pod nazivom CTG2 tipa *Compute Instance Standard_DS12_v2* sa 4 jezgra i 28 GB RAM, koja je podrazumevano konfigurisana tako da se automatski isključuje nakon 60 minuta neaktivnosti. Pored ove instance paralelno je kreiran klaster tipa *Compute Cluster* sa skalabilnošću 0 - 4 čvora, što omogućava efikasnu distribuciju računskih zadataka.



Sl. 1 Prikaz modula: *Train Model*, *Score Model*, *Convert to CSV* sa klasifikatorom (linearna regresija)



Sl. 2 Prikaz modula za evaluaciju (nastavak dijagrama sa Sl. 1)

Na Sl. 1 i 2 prikazan je kreirani dijagram za klasifikaciju. Nakon modula *Clean Missing Data*, gde se vrši odbacivanje onih signala koji nemaju dostupne sve vrednosti, signali ulaze u moduo *Split Data*, gde se vrši podela signala na skup za

treniranje i skup za testiranje. U radu je za sve klasifikatore izabrano 70% signala za treniranje, dok 30% njih odlazi na testiranje (od ukupno 2126 signala). Opcijom *randomized split* redosled redova se nasumično izmeni pre podele, dok opcija *random seed* može dovesti do različitih rezultata pri ponovnim pokretanjima treninga. Važno je napomenuti da je upravo ovaj korak presudan za kasniju evaluaciju modela, jer osigurava da model ne vidi podatke za test, tokom procesa učenja.

Trening podaci ulaze u blok *Train Model* gde se inicira proces učenja. U našem slučaju, neki od algoritama (klasifikatora) koje smo koristili analiziraju vezu između brojnih parametara fetalnog pomeranja i ciljane promenljive na izlazu. Ovim procesom inicira se modul *Train Model* koji predstavlja skup parametara i težina koje će kasnije biti korišćene za predikciju. Paralelno sa podacima za trening, test podaci čuvaju se za kasniju evaluaciju, što predstavlja moćan alat u objektivnoj oceni modela. Nakon završetka treninga, dolazi do interakcije modela i test podataka u komponenti *Score Model*. Ova faza predstavlja proveru kvaliteta rešenja, gde sam model primenjuje naučene obrasce na do tada neviđene podatke. Dobijaju se konkretne numeričke predikcije koje se mogu uporediti sa stvarnim vrednostima i generišu se metrike koje kvantifikuju performanse modela. Nakon završene obrade podataka, može se izvršiti pregled svih rezultata i vrednosti svih procena grešaka u pregledima preko komponenti *Evaluate Model* kao i *Convert to CSV* omogućavajući vizuelnu analizu u aplikaciji Excel.

Za potrebe ispitivanja korišćena su četiri regresiona modela na platformi Azure sa svojim podmodelima koje smo implementirali za obradu i treniranje podataka prema određenim kriterijumima koja smo im zadali pre samog pokretanja zaduženja:

1) OLS (*Ordinary Least Squares*) [8] kao temeljni pristup podacima. Konfigurisan je sa L2 regularizacijom (težina 0,001), sa algoritmom uz čiju pomoć minimizuje sumu kvadrata odstupanja između realnih i predviđenih vrednosti. OLS model je interoperabilan - svaki koeficijent jasno ukazuje na intenzitet i smer uticaja pojedinačnih parametara fetalnog monitoringa. Međutim, često je nemoguće na adekvatan način obuhvatiti kompleksne, nelinearne interakcije koje su uglavnom prisutne u biološkim sistemima.

2. OGD (*Online Gradient Descent*) [8] konfigurisan sa stopom učenja od 0,1 (korak pri ažuriranju težinskog faktora), kao i broj učenja od 10 sesija (koliko puta model prolazi kroz ceo skup podataka). Za razliku od metoda OLS, koji u celovitosti minimizira funkciju gubitka, ovaj model iterativnog pristupa omogućava inkrementalno učenje, što ga čini posebno pogodnim za velike skupove podataka. Normalizacija koja je omogućena u realizovanoj konfiguraciji dodatno stabilizuje proces približavanja cilju, odnosno konvergenciji. Iako ova varijanta deli osnovna ograničenja linearne regresije, njena adaptivna priroda pruža veću fleksibilnost u realnim uslovima gde podaci mogu biti nestacionarni ili nepotpuni.

3. DFR (*Decision Forest Regression*) [9] konfigurisan je putem broja stabala kroz koje se može izvršiti odlučivanje, odnosno zadato je 8 stabala koje imaju maksimalnu dubinu od 32 čvora (nastavak granjanja stabala) što predstavlja prvi korak ka nelinearnom modelovanju. Kroz metod *bagging resampling*, svako pojedinačno stablo u šumi trenira se na različitom podskupu podataka, čime se postiže smanjivanje varijacije (šuma) u podacima ili modelima, kako bi se dobile tačnije,

stabilnije i pouzdanije procene, a smanjila potencijalna greška zbog pojednostavljivanja. Klasifikator DFR postavlja ograničenje svakom stablu, tako da list na njemu može ostati bez uzorka, dok forsira pristup da svako stablo mora imati bar jedan uzorak čime se sprečava *overfitting* (prekomerno obučavanje). Kod CTG signala, struktura stabala pomaže u razumevanju složenih veza između različitih medicinskih parametara.

4. BDTR (*Boosted Decision Tree Regression*) [10] kombinuje više jednostavnih stabala odlučivanja u jedan snažan model, tako što svako novo stablo pokušava da ispravi greške koje su prethodna stabla napravila. Kod metode BDTR stabla se treniraju jedno za drugim (sekvencijalno). Ovaj pristup omogućava modelu da bude veoma precizan, jer se uči na greškama i stalno se poboljšava. Posebno je koristan kada se u podacima nalaze retki, ali klinički važni parametri - na primer, specifična patologija koja se retko javlja, ali ima veliki značaj za zdravlje pacijenta. Modeli sa pojačanjem (*boosting*) bolje uočavaju takve parametre, jer se fokusiraju upravo na ono što prethodna stabla nisu uspela da prepoznaju. Međutim, visoka tačnost dolazi uz nedostatke poput povećanja računarskog vremena, mnogo više vremena i resursa za treniranje modela, zbog težeg objašnjavanja kako je model došao do određene odluke, jer se odluka donosi na osnovu velikog broja uzastopnih ispravki. Zbog toga se *boosted* stabla često koriste kada je tačnost ključna, a model ne mora nužno biti potpuno objašnjiv krajnjem korisniku.

III. EKSPERIMENTALNI REZULTATI

Svaki od navedenih modela procenjen je pomoću pet standardnih evaluacionih metrika koji proizilaze i koji opisuju rezultate klasifikacije signala CTG u okruženju Azure ML [11]:

1) srednja apsolutna greška (*Mean Absolute Error*, MAE). Meri prosečnu apsolutnu razliku između realnih i prediktovanih vrednosti, pružajući direktan uvid u veličinu greške modela. MAE predstavlja prosek apsolutnih vrednosti grešaka, odnosno ne daje veću težinu velikim greškama (manje je osetljiv). To znači da, ako je MAE vrednost manja ($MAE \approx 0$), trebalo bi da regresioni model bude bolji. Računa se tako što se saberu sve razlike između stvarnih i predviđenih vrednosti, pa se rezultat podeli sa brojem ukupnih vrednosti;

2) srednjekvadratna greška (*Root Mean Squared Error*, RMSE) pokazuje koliko su predikcije udaljene od stvarnih vrednosti u srednjekvadratnom smislu, odnosno koliko odstupaju greške u odnosu na osnovnu referentnu predviđenu vrednost. Ako je $RMSE \approx 0$ model je precizniji, odnosno teži ka idealnom. Osetljiv na velike greške (više „kažnjava“ veće greške), jer kvadrira razlike;

3) relativna kvadratna greška (*Relative Squared Error*, RSE) je parametar koji poredi grešku korišćenog modela sa greškom koja bi nastala korišćenjem srednje vrednosti, ali koristeći kvadrate greške umesto apsolutnih vrednosti. Ako je $RSE < 1$, to znači da je model bolji od predviđanja pomoću srednje vrednosti, odnosno što je RSE bliži vrednosti 0, to je model precizniji;

4) relativna apsolutna greška (*Relative Absolute Error*, RAE) predstavlja odnos između ukupne greške modela i greške koja bi nastala ako bi se umesto modela koristila jednostavna srednja vrednost. Drugim rečima, RAE pokazuje da li model

donosi neku dodatnu vrednost u odnosu na osnovno statističko predviđanje. Ako je $RAE < 1$, to znači da je model bolji od prosečnog pokazatelja;

5) koeficijent determinacije (*Coefficient of Determination*, R^2) – predstavlja procenat varijabilnosti zavisne promenljive koji je objašnjen nezavisnim promenljivama u modelu. Drugim rečima, pokazuje koliko dobro model reprodukuje stvarne podatke. Opseg R^2 kreće se od 0 do 1, gde veća vrednost ($R^2 \approx 1$) označava bolju prilagođenost modela podacima.

U Tabelama I - IV prikazani su rezultati, odnosno vrednosti evaluacionih parametara za korišćene klasifikatore u eksperimentu. Posmatrajući i upoređujući analizu parametara iz ovih tabela, mogu se doneti sledeći zaključci.

Linearna regresija sa metodom OLS i linearna regresija sa metodom OGD, pokazali su nešto slabije rezultate u poređenju sa ostalim modelima. Oba modela imaju slične vrednosti grešaka MAE i RMSE, ali metoda OGD ima nešto niži RMSE i viši R^2 od klasične metode OLS, što znači da je nešto precizniji u odnosu na OLS regresionu metodu. Mora se uzeti u obzir i da je koeficijent determinacije kod oba modela ispod 0,8 što pokazuje da linearni modeli ne mogu potpuno da objasne kompleksnije strukture podataka.

Znatno bolje rezultate daje model *Boosted Decision Tree Regression* u svim metrikama u poređenju sa linearnim modelima. Njegove vrednosti grešaka su dosta niže, što sugerise da je tačniji od linearne regresije. Vrlo visok R^2 (0,966) pokazuje da ovaj model može da objasni čak 96,6% varijacija (odstupanja) u podacima.

Upoređujući rezultate sa prethodnim modelima, najbolji rezultat daje model *Decision Forest Regression* poput dosta niskih vrednosti svih grešaka kao što su MAE, RMSE, RAE i RSE, što znači da su greške u ovom modelu minimalne, dok koeficijent R^2 koji iznosi 0,975 i predstavlja najvišu vrednost parametra u poređenju sa svim prethodnim modelima. Model *Decision Forest Regression* je veoma precizan i stabilan, što ga čini najboljim izborom za analizu CTG podataka u posmatranom slučaju, te skoro u potpunosti objašnjava varijabilnost izlazne promenljive.

Na osnovu rezultata koji su prikazani u Tabelama I - IV i upoređivanja različitih modela regresije, može se zaključiti da se modeli zasnovani na stablima poput algoritma *Decision Forest Regression*, znatno bolje snalaze u predikciji CTG podataka nego linearni modeli, što ukazuje da su podaci koji su uzeti za analizu prilično nelinearni i dosta kompleksniji, pa su samim tim napredniji modeli uspešniji u učenju, kao i boljoj predikciji.

IV. ZAKLJUČAK

Organizacija toka podataka u Azure ML dijagramu predstavlja sistematski pristup koji omogućava praćenje transformacija podataka od sirovih podataka do konačnih predikcija. Svaka komponenta u ovom lancu ima svoju specifičnu ulogu, a njihov pravilan raspored i konfiguracija su presudni za kvalitet konačnog rešenja. Ova metodologija ne samo što olakšava razumevanje procesa mašinskog učenja, već i omogućava iterativno poboljšanje modela kroz sistematsku evaluaciju i analizu grešaka. Evaluacija modela pokazuje zadovoljavajuće rezultate u pogledu preciznosti predikcije, što potvrđuje potencijal primene veštačke inteligencije i mašinskog

učenja u analizi medicinskih podataka, konkretno u kontekstu procene fetalnog zdravlja (rada srca) pomoću CTG zapisa. Na osnovu rezultata prikazanih tabelama i upoređivanja različitih modela regresije, može se zaključiti da su modeli zasnovani na stablima poput algoritma *Decision Forest Regression*, znatno bolji u predikciji CTG podataka nego linearni modeli. Ovo se objašnjava time da je struktura analiziranih podataka verovatno nelinearna i kompleksna, pa su napredniji modeli uspešniji u učenju, kao i boljoj predikciji.

TABELA I. REZULTATI KLASIFIKACIJE KORIŠĆENJEM LINEARNE REGRESIJE (METODA NAJMANJIH KVADRATA, OLS)

<i>Evaluacioni parametar</i>	<i>Vrednost</i>
Srednja apsolutna greška (MAE)	0,205289
Srednjekvadratna greška (RMSE)	0,311853
Relativna kvadratna greška (RSE)	0,244858
Relativna apsolutna greška (RAE)	0,426814
Koeficijent determinacije (R^2)	0,755142

TABELA II. REZULTATI KLASIFIKACIJE KORIŠĆENJEM LINEARNE REGRESIJE (METODA NAJMANJEG GRADIJENTA, OGD)

<i>Evaluacioni parametar</i>	<i>Vrednost</i>
Srednja apsolutna greška (MAE)	0,213724
Srednjekvadratna greška (RMSE)	0,300414
Relativna kvadratna greška (RSE)	0,227224
Relativna apsolutna greška (RAE)	0,444352
Koeficijent determinacije (R^2)	0,772776

TABELA III. REZULTATI KLASIFIKACIJE KORIŠĆENJEM STABLA POJAČANOG ODLUČIVANJA (*BOOSTED DECISION TREE REGRESSION*)

<i>Evaluacioni parametar</i>	<i>Vrednost</i>
Srednja apsolutna greška (MAE)	0,053435
Srednjekvadratna greška (RMSE)	0,116265
Relativna kvadratna greška (RSE)	0,034034
Relativna apsolutna greška (RAE)	0,111095
Koeficijent determinacije (R^2)	0,965966

TABELA IV. REZULTATI KLASIFIKACIJE KORIŠĆENJEM ŠUME ODLUČIVANJA (*DECISION FOREST REGRESSION*)

<i>Evaluacioni parametar</i>	<i>Vrednost</i>
Srednja apsolutna greška (MAE)	0,020572
Srednjekvadratna greška (RMSE)	0,100328
Relativna kvadratna greška (RSE)	0,025343
Relativna apsolutna greška (RAE)	0,042771
Koeficijent determinacije (R^2)	0,974657

LITERATURA

[1] <https://azure.microsoft.com/en-us/products/health-data-services>

[2] <https://learn.microsoft.com/en-us/azure/machine-learning/?view=azureml-api-2>

[3] T. Khan, W. Tian, G. Zhou, S. Ilager, M. Gong, R. Buyya, "Machine learning (ML)-centric resource management in cloud computing: A review and future directions," *Journal of Network and Computer Applications* 204, 2022.

[4] E. Chandrarana, S. Pereirab, T. Ghic, A. G. Perez-Bonfilsd, S. Fienie, Y.-J. Jiaf, K. Griffithsg, S. Sukumaranh, C. Ingrami, K. Reevesj, M. Boltenk, K. Loserl, E. Carreras. A. Suym, I. Garcia-Ruizm, L. Gallio, A. Zaima, "International expert consensus statement on physiological interpretation of cardiotocograph (CTG)," *European Journal of Obstetrics & Gynecology and Reproductive Biology* 302 (2024) 346–355.

[5] CTG dataset, <https://archive.ics.uci.edu/dataset/193/cardiotocography>

[6] E. Osmani, „Klasifikacija CTG signala korišćenjem algoritama mašinskog učenja u oblaku“, Master rad, Odsek Visoka škola za informacione i komunikacione tehnologije, Akademija tehničko-umetničkih strukovnih studija Beograd, 2025.

[7] <https://ml.azure.com/>

[8] <https://learn.microsoft.com/en-us/azure/machine-learning/component-reference/linear-regression?view=azureml-api-2>

[9] <https://learn.microsoft.com/en-us/azure/machine-learning/component-reference/decision-forest-regression?view=azureml-api-2>

[10] <https://learn.microsoft.com/en-us/azure/machine-learning/component-reference/boosted-decision-tree-regression?view=azureml-api-2>

[11] <https://learn.microsoft.com/en-us/azure/machine-learning/component-reference/evaluate-model?view=azureml-api-2>

ABSTRACT

Digitalization in healthcare, supported by the application of Artificial Intelligence (AI) and Internet of Things (IoT) technologies, offers significant opportunities for improving diagnostics, patient monitoring, and the optimization of medical processes. Microsoft Azure platform provides a wide range of solutions that enable healthcare institutions to integrate AI and IoT technologies in order to enhance the quality of care and increase operational efficiency. This paper examines the ways in which Artificial Intelligence and IoT technologies, supported by the Microsoft Azure platform, can be applied to optimize healthcare services through the analysis of cardiotocography data. Special attention is given to the application of these technologies in monitoring patients' vital parameters, predictive analytics, and improving the operational efficiency of healthcare institutions. The challenges and limitations associated with the implementation of these technologies, as well as potential solutions for overcoming them, are discussed. Furthermore, specific application examples are presented, key findings are summarized, and future development perspectives in this field are discussed.

APPLICATION OF MACHINE LEARNING ALGORITHMS FOR THE CLASSIFICATION OF CTG SIGNALS IN A CLOUD

Enis Osmani, Milorad Paskaš