

Broj rada: I-5.03

DOI broj: [10.46793/CIRED24.I-5.03SK](https://doi.org/10.46793/CIRED24.I-5.03SK)

DEFINISANJE INDIKATORA PERFORMANSI ZASNOVANIH NA MODELIMA PREDIKCIJE POTROŠNJE KORIŠĆENJEM METODA MAŠINSKOG UČENJA ZA DISTRIBUTIVNA PREDUZEĆA

DEFINING KPIs BASED ON MACHINE LEARNING CONSUMPTION PREDICTION MODELS FOR DISTRIBUTION COMPANIES

Sofija KRSTEV, Dwelt d.o.o Banja Luka, Bosna i Hercegovina
Dragoljub KRNETA, Dwelt d.o.o Banja Luka, Bosna i Hercegovina

KRATAK SADRŽAJ

Povećana složenost modernih energetskih sistema zahteva napredne metode za efikasnu kontrolu i menadžment distribucije. Ovaj rad istražuje definisanje ključnih indikatora performansi (KPI-ova) koristeći modele mašinskog učenja za predikciju potrošnje energije, s ciljem poboljšanja kontrole distribucije i ukupne performanse sistema za održivi energetski menadžment.

Ključne reči: predviđanje, KPI, mašinsko učenje, energija, distribucija

ABSTRACT

Increased complexity in modern energy systems demands advanced methods for efficient distribution control and management. This paper explores defining key performance indicators (KPIs) using machine learning models to predict energy consumption, aiming to enhance distribution control and overall system performance for sustainable energy management.

Key words: prediction, KPI, machine learning, energy, distribution

Sofija Krstev. sofija@dwelt.net
Dragoljub Krneta, dragoljub@dwelt.net

1. UVOD

Razdvajanjem snabdevanja i distribucije na segmentiranom energetskom tržištu dovelo je do specijalizacije energetskih kompanija i preusmeravanje resursa na povećanje efikasnosti i smanjenje gubitaka distributivne mreže. Povećanje efikasnosti energetskih sistema zahteva napredne metode za efikasnu kontrolu proizvodnje, distribucije i potrošnje. Ovaj rad istražuje definisanje ključnih indikatora performansi (KPI-ova) koristeći modele mašinskog učenja za predikciju potrošnje energije, sa ciljem unapređenja kontrole potrošnje, planiranje proizvodnje uvođenjem novih varijabli i povećanjem efikasnosti sistema. Korišćenjem informacija o ponašanju sistema u budućnosti, menadžment distributivnih kompanija može lakše doneti odluku o proizvodnji, održavanju mreže i planirati resurse u skladu sa održivim energetskim menadžmentom [1].

Primarni ciljevi ovog rada su:

- Identifikovati i definisati relevantne KPI-ove koji su kritični za efikasno praćenje i upravljanje distribucijom energije.
- Implementirati modele mašinskog učenja za tačnu predikciju potrošnje energije.
- Evaluirati uticaj ovih prediktivnih KPI-ova na kontrolu distribucije energije i celokupnu performansu sistema.

U ovom radu će biti predstavljen proces definisana indikatora performansi baziranog na prikupljenim podacima o potrošnji u ODS "Elektrodistribucija" a.d. Pale i podacima o vremenskim uslovima u Republici Srpskoj. Modeli i indikatori performansi definisani u ovom procesu mogu poslužiti kao primer definisanja sopstvenih indikatora za

svako distributivno preduzeće, s tim da se indikatori mogu prilagoditi specifičnim uslovima tržišta i istorijskim podacima.

U drugom poglavlju će biti urađen kratak pregled literature na predstavljenu temu.

U trećem poglavlju će biti dat predlog definisanja KPI-ova baziranih na rezultatima prediktivnih modela, kao što su tačnost predikcije, uštada energije, efikasnost distribucije i pouzdanost sistema. Na osnovu predloženih KPI-ova, biće urađen predlog nove mera performansi koja je unapredena za svakodnevno korišćenje i lakše razumevanje.

U četvrtom poglavlju će biti urađena simulacija korišćenja definisanog KPI-a.

Posljednje poglavlje će biti posvećeno otvorenim pitanjima, planiranom daljem razvoju i zaključku.

2. PREGLED LITERATURE

Savremena istraživanja ističu prednosti modela mašinskog učenja u energetskom menadžmentu. Tehnike kao što su Long Short-Term Memory (LSTM) mreže i Veštačke Neuronske Mreže (ANN) pokazale su obećavajuće rezultate u tačnoj predikciji potrošnje energije [2][3]. Ipak, integracija ovih modela u praktične sisteme kontrole energetske distribucije ostaje nedovoljno istražena [4].

Radova koji se bave definisanim indikatorom performansi baziranih na mašinskom učenju iz oblasti energetike je veoma malo, pa se može zaključiti da je ova tema akademski slabo zastupljena.

U [6] se diskutuje razvoj hibridnih tehnika mašinskog učenja za predikciju potrošnje energije. Autori kombinuju razne modele mašinskog učenja, uključujući linearnu regresiju, stabla odluke i neuronske mreže, kako bi poboljšali tačnost predikcije. Ključni pokazatelji performansi (KPI) kao što su srednja apsolutna greška (MAE), kvadratna srednja greška (RMSE) i srednja apsolutna procentualna greška (MAPE) korišćeni su za evaluaciju performansi ovih modela. Hibridni pristup pokazuje poboljšanu tačnost u poređenju sa tradicionalnim tehnikama sa jednim modelom.

Autori [7] istražuju primenu modela mašinskog učenja za pametno prediktivno upravljanje distribuiranim obnovljivim izvorima energije. Autori se fokusiraju na optimizaciju integracije i rada obnovljivih izvora kao što su solarna i vetroenergija unutar pametne mreže. Definišu se KPI-ovi vezani za efikasnost integracije obnovljivih izvora, tačnost predikcije proizvodnje iz obnovljivih izvora i pouzdanost sistema. Rezultati pokazuju da mašinsko učenje može značajno poboljšati predvidljivost i stabilnost doprinosa obnovljivih izvora energije mreži.

Rad [8] evaluira različite algoritme mašinskog učenja za predikciju performansi energetskih heuristika korišćenih u industrijskim procesima. Autori istražuju različite modele, uključujući mašine sa potporom vektora (SVM), random forest i neuronske mreže. KPI kao što su tačnost predikcije, računska efikasnost i robustnost istaknuti su kao ključne mere performansi. Studija zaključuje da određeni algoritmi, posebno ansambl modeli poput random forest, nude superiorne performanse u složenim industrijskim okruženjima.

U [9] je predstavljen pristup baziran na mašinskom učenju za prediktivno modeliranje i inteligentan energetski menadžment obnovljivih energetskih sistema. Autori opisuju upotrebu neuronskih mreža i drugih naprednih tehnika mašinskog učenja za predikciju izlaza energije iz izvora kao što su solarni paneli i vetrogeneratori. Diskutovani KPI-ovi uključuju tačnost predikcije, efikasnost integracije i uštade energije. Istraživanje naglašava kako se ovi prediktivni modeli mogu koristiti za optimizaciju energetskog menadžmenta, smanjenje troškova i povećanje pouzdanosti obnovljivih energetskih sistema.

U [10] je predstavljena uporedna analiza metoda za predviđanje mesečne potrošnje električne energije. Autori analiziraju različite pristupe, uključujući tradicionalne statističke metode, kao i savremene tehnike mašinskog učenja. Cilj je razumeti prednosti i nedostatke svake metode u kontekstu njihove primene na stvarne podatke o potrošnji električne energije. Mera performansi korištena za poređenje je Mean average percentage error (MAPE). Autori zaključuju da savremene metode mašinskog učenja nude značajna poboljšanja u tačnosti predikcije u poređenju sa tradicionalnim statističkim metodama. Ipak, naglašeno je da izbor metode zavisi od specifičnog konteksta i dostupnosti podataka. Ovo je jedini rad koji poredi modele sa ciljem srednjoročnih tj. mesečnih predikcija.

Generalni zaključak pregledane literature je da se statističke mere i mere performansi koriste za poređenje modela, te da je menadžmentu potrebno poznavanje statistike i mašinskog učenja da bi umeli da koriste i tumače mere i modele. Uvida se prostor sa kreiranje mera performansi koje bi bile prilagođene svakodnevnom korišćenju i razumljive za tumačenje od strane menadženta.

3. MERE PERFORMANSI

Ako bi se posmatralo celokupno poslovanje distributivne kompanije, procesi proizvodnje, analiza mreže i potrošnje i smanjenje gubitaka su bazni procesi na kojim se najviše utiče na finansijski rezultat kompanije. S tim u vezi, mere performansi bazirane na modelima mašinskog učenja koje se mogu koristiti se mogu podeliti u 4 oblasti: tačnost predikcije, uštada energije, efikasnost distribucije i pouzdanost sistema.

3.1 Tačnost predikcije

KPI-ovi u ovoj kategoriji mere koliko dobro model mašinskog učenja predviđa buduću potrošnju ili proizvodnju energije. [11]

3.1.1 Srednja Apsolutna Greška (MAE) Definiše se kao prosečna absolutna razlika između predikovanih i stvarnih vrednosti. Cilj ove mere je minimizirati ovu vrednost radi povećanja tačnosti predikcije. Ukoliko je ova vrednost velika, to znači da model ne uspeva da objasni specifičnosti koje se dešavaju za većinu slučajeva iz testiranih vrednosti. Formula: $MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$, gde je y realna vrednost, \hat{y} predviđena vrednost, i iterator n slučajeva vrednosti nad kojim se vrši testiranje modela.

3.1.2 Kvadratna Srednja Greška (RMSE) definiše se kao Kvadratni koren prosečne kvadratne razlike između predikovanih i stvarnih vrednosti. Cilj ove mere je njena minimizacija. Ima prednost kod statističkih analiza u odnosu na MAE jer kažnjava veća odstupanja dok manja svodi na MAE vrednosti. Formula: $RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$, gde je y realna vrednost, \hat{y} predviđena vrednost, i iterator n slučajeva vrednosti nad kojim se vrši testiranje modela.

3.1.3 Koeficijent Determinacije (R^2) Statistička mera koja pokazuje koliki deo varijanse zavisne promenljive je predikovan nezavisnom promenljivom. S obzirom na to da varijansa pokazuje koliki deo podataka nije objašnjen modelom, ova mera je dobra u cilju otkrivanja zakonitosti između varijanse i promenljivih. Vrednosti bliže 1 ukazuju na bolju performansu modela. Formula: $1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$, gde je y realna vrednost, \hat{y} predviđena vrednost, \bar{y} medijana skupa podataka a i iterator n slučajeva vrednosti nad kojim se vrši testiranje modela.

3.2 Smanjenje gubitaka

KPI-ovi fokusirani na smanjenje energetskih gubitaka u sistemu [12]:

3.2.1 Smanjenje energetskih gubitaka Mera koja za analizira progres smanjenja energetskih gubitaka postignutih kroz optimizaciju. Cilj distributivne kompanije je analizirati progres i maksimizirati ovaj procenat radi smanjenja energetskih gubitaka u sistemu. $SEG(\%) = ((PG - TG)/PG) * 100$, gde su PG prethodni gubici an TG trenutni gubici.

3.2.2 Stopa detekcije ne-tehničkih gubitaka (NTL) Stopa kojom sistem detektuje ne-tehničke gubitke (kao što su krađa ili curenje) koristeći mašinsko učenje. Veće stope detekcije ukazuju na bolju performansu. Formula: $NTL(\%) = (\text{Broj detektovanih NTL} / \text{Ukupan broj NTL}) * 100$

3.3 Efikasnost distribucije

Efikasnost distribucije se ogleda kroz faktore opterećenja, koeficijent efikasnosti distribucije energije i pouzdanost sistema distribucije energije [13].

3.3.1 Faktor opterećenja Definiše se kao odnos prosečnog opterećenja prema vršnom opterećenju tokom određenog perioda. Viši faktor opterećenja ukazuje na efikasnije korišćenje mreže. Formula: $FO = (PO/VO) * 100$, gde je PO prosečno opterećenje, a VO vršno opterećenje.

3.3.2 Koeficijent efikasnosti distribucije Mera efikasnosti distribucije energije poređenjem isporučene energije s primljenom energijom. Vrednosti bliže 1 ukazuju na višu efikasnost. Formula: $KED = IE/PE$, gde je IE isporučena energija a PE primljena energija

3.4 Pouzdanost sistema

KPI-ovi koji ocenjuju pouzdanost i stabilnost sistema distribucije energije su Srednja trajanje prekida rada po korisniku, Srednja frekvencija prekida rada po korisniku, Smanjenje broja kvarova uz pomoć prediktivnog održavanja [14].

3.4.1 Srednja trajanje prekida rada po korisniku (SAIDI) Predstavlja ukupno trajanje prekida rada za prosečnog korisnika tokom određenog perioda. Niže vrednosti ove mere ukazuju na pouzdaniji sistem. Formula: $SAIDI = TPRK / UBK$, gde je TPRK trajanje prekida rada korisnika, a UBK ukupan broj korisnika

3.4.2 Srednja frekvencija prekida rada po korisniku (SAIFI) Definiše se kao prosečan broj prekida rada koje korisnik doživi tokom određenog perioda. Niže vrednosti ukazuju na manje prekida i višu pouzdanost. Formula: $SAIFI = \Sigma BPRK / UBK$, gde je BPRK broj prekida rada korisnika, a UBK ukupan broj korisnika.

3.4.3 Smanjenje broja kvarova uz pomoć prediktivnog održavanja Predložena mera se može definisati sa ciljem da se prati koliko prediktivno održavanje, potpomognuto mašinskim učenjem, smanjuje neočekivane kvarove. Viši procenat ukazuje na efikasnije prediktivno održavanje. Formula: $SBK(\%) = (PK - TK) * 100 / PK$, gde je PK broj prethodnih kvarova, a TK broj trenutnih kvarova

3.5 Predlog nove mere performansi - Indeks Prediktivne Efikasnosti Distribucije (PDEI)

Praćenjem trenda definisanja kombinovanih mera performansi viđenih u [15] i [16], autori predlažu novu mjeru Indeks Prediktivne Efikasnosti Distribucije. Indeks Prediktivne Efikasnosti Distribucije (PDEI) je kompozitni KPI koji meri efikasnost modela mašinskog učenja u predikciji potrošnje energije i procenjuje njihov uticaj na efikasnost distribucije. Ovaj indeks integriše metrike tačnosti predikcije (MAE i R^2) sa metrima efikasnosti distribucije energije (npr. faktor opterećenja) ili metrikama energetskih gubitaka.

Formula: $PDEI = (\alpha / MAE + \beta * R^2) * ED$, gde je

MAE je srednja apsolutna greška prediktivnog modela, R^2 je koeficijent determinacije prediktivnog modela. ED je mera efikasnosti distribucije energije, koja može biti faktor opterećenja ili koeficijent efikasnosti distribucije, dok su α i β faktori težine koji balansiraju uticaj MAE i R^2 na PDEI.

Primer Implementacije KPI-ova korišćenjem Mašinskog Učenja

Scenario: Kompanija za distribuciju energije koristi modele mašinskog učenja za predikciju potrošnje energije i optimizaciju distribucije radi povećanja efikasnosti i pouzdanosti.

4. SIMULACIJA KORIŠĆENJA NOVE MERE PERFORMANSI

Uzimajući u obzir da:

- A. **Mean Absolute Error (MAE):** Mera tačnosti predikcije.
- B. **R-squared (R^2):** Pokazuje procenat varijanse koju objašnjava model.
- C. **Faktor opterećenja:** Mera efikasnosti sistema distribucije energije.

možemo simulirati sledeću kalkulaciju. Prepostavimo da imamo sledeće vrednosti:

- A. MAE: 50
- B. R^2 : 0.85
- C. Faktor opterećenja: 0.75 (75%)
- D. Faktori težine: ($\alpha = 1$), ($\beta = 1$)

PDEI bi se računao kao $PDEI = (1 / 50 + 1 * 0.85) * 0.75 = 0.653$, što bi se moglo interpretirati kao veća vrednost koja ukazuje na to da prediktivni model nije samo tačan, već i pozitivno doprinosi efikasnosti distribucije energije. Integracijom MAE i R^2 , ovaj KPI reflektuje kako preciznost predikcija tako i njihov praktični uticaj na efikasnost sistema. Faktori težine (α i β) mogu biti prilagođeni u zavisnosti od relativnog značaja tačnosti predikcije i podudarnosti modela sa merom efikasnosti. Ovi faktori pomažu prilagodenju PDEI za različite sisteme i prioritete. Kombinovanjem ovih prediktivnih i efikasnosnih metrika u jedan KPI, organizacije mogu imati holistički pogled na uticaj prediktivnih analitika na sisteme distribucije energije, osiguravajući da modeli ne samo pružaju tačne prognoze već i doprinose ukupnim poboljšanjima sistema.

5. ZAKLJUČAK

Uvođenjem ove mere performansi, donosiocima odluka se približava razumevanje statističkih modela, neuronskih mreža i drugih alata iz oblasti mašinskog učenja, i dobija se holistički pristup uticaja predikcije na celokupan sistem. Ova mera se može primeniti i na srednjoročne i na kratkoročne prognoze, a može imati i specifične primene kao što su detekcija anomalija u potrošnji energije u realnom vremenu, gde mere modela mogu u kazati na koje modele treba pristupiti sa više pažnje i gde leže uzroci u neefikasnosti distribucije. Kvalitet modela samim tim predstavlja alarm za kritične tačke distributivnog sistema.

Analiza uticaja praćenja ovih mera može se sprovesti kroz studiju pre i posle: Evaluacija KPI-ova kao što su Smanjenje energetskih gubitaka, Faktor opterećenja, SAIDI i MAE pre i posle implementacije modela mašinskog učenja. Više prediktivnih modela može biti implementirano u isto vrijeme nad različitim podacima o proizvodnji, potrošnji, geografski podeljenim podacima, te njihova analiza kroz novu meru performansi treba da se posmatra kao ukaz na kvalitet podataka, predikciju anomalija u sistemu i prostor za napredovanje u različitim aspektima poslovanja distributivnog preduzeća.

Dalji rad na ovu temu bi trebao da rezultuje u realnoj upotrebi ovih mera performansi kako bi se utvrdio njihov uticaj na doношење odluka i praćenje sistema. Nove mere performansi kao derivati ove mera se takođe očekuju u budućem radu autora.

Redovno praćenje KPI-ova radi održavanja poboljšanja u efikasnosti, pouzdanosti i tačnosti. Fokusiranjem na ove KPI-ove, organizacije mogu koristiti mašinsko učenje za unapređenje svojih sistema upravljanja energijom, što vodi ka efikasnijim, pouzdanim i isplativijim operacijama.

LITERATURA

- [1] Ghaffarian Hoseini A, et al, 2017, "IoT-based smart energy grid with renewable energy sources (RES)." "Energy Procedia", "143", 277-282
- [2] Ahmad T, and Jamshed I C, 2013, "A study on energy consumption prediction using machine learning techniques.", "Journal of Renewable and Sustainable Energy", "5.2", 023119
- [3] Amasyali K, and El-Gohary N M, 2018 "A review of data-driven building energy consumption prediction studies.", "Renewable and Sustainable Energy Reviews", "81", 1194-1205
- [4] Oldewurtel F, et al., 2012. "Data-driven predictive control for building energy management.", "Proceedings of the IEEE", "100.1", 240-253.
- [5] Kong W, et al., 2018, "Short-term residential load forecasting based on LSTM recurrent neural network.", "IEEE Transactions on Smart Grid", "10.4", 841-850.
- [6] Al-Ati J A, Iqbal M A, Benkrid K, 2021, "Forecasting Energy Consumption using Hybrid Machine Learning Techniques", "IEEE Access", "9", 10606-10620
- [7] Bucciarelli M, Bellini A, Ciampi A, and Pezzotta G, 2020, "Smart Predictive Management of Distributed Renewable Energy Sources with Machine Learning", "Energy reports", "6", 441-456
- [8] Sayed-Mouchaweh M, Lugofer E and Schirru M, 2020, "Evaluation of Machine Learning Algorithms for Energy Heuristic Performance Prediction", "Applied Energy", "260"
- [9] Wang J, Li K, Tan J and Jian X, 2020, "Machine Learning-Based Predictive Modeling and Intelligent Energy Management of Renewable Energy Systems", "IEEE Transactions on Sustainable Energy", "11.3", 1630-1638
- [10] Krstev S, Forcan J and Krneta D, 2023, "An Overview of Forecasting Methods for Monthly Electricity Consumption", "Technical Gazette", "30.3", 993-1001
- [11] Wang B, Wang H, Xiao Y, Peng Y and Zhu Z, 2015, "Electric load forecasting using an improved PSO-based LSSVM model", "Energy", "90.2", 1599-1607
- [12] Amini M H, Haghbin S and Kargarian A, 2021, "Techniques for evaluating electric power grid data and reducing energy losses through machine learning", "IEEE Transactions on Smart Grid", "12.3", 2345-2356
- [13] Khatib T, Mohamed A and Mustafa M W, 2018, "Enhancing the Efficiency of Electric Power Distribution using Machine Learning Models", "Applied Energy", "230", 1595-1603
- [14] Zhang Y, Hodge B M and Lu S, 2020, "Improving Power System Reliability with Predictive Maintenance Using Machine Learning", "Renewable and Sustainable Energy Reviews", "127", 109398
- [15] Praktiknjo A and Erdmann G, 2016, "Renewable electricity and backup capacities: An (un) resolvable problem?", "Journal of Energy", "114", 1106-1117
- [16] Chicco G and Mancarella P, 2009, "Assessment of the greenhouse gas emissions from cogeneration and trigeneration systems. Part II: Analysis techniques and application cases", "Energy", "34.3", 359-367