

DOI: [10.46793/CIGRE37.D2.02](https://doi.org/10.46793/CIGRE37.D2.02)**D2.02****TRANSFORMER MODELI MAŠINSKOG UČENJA ZA PREDVIĐANJE VREMENSKIH
SERIJA U ELEKTROENERGETICI****TRANSFORMER MACHINE LEARNING MODELS FOR TIME SERIES PREDICTION IN
THE POWER SYSTEM****Saša Milić, Miša Kožićić, Luka Ivanović, Miroslav Dragičević**

Kratak sadržaj: Predviđanje vremenskih serija podataka u elektroenergetici predstavlja ključan izazov za prediciju proizvodnje, optimizaciju upravljanja i izbor strategija održavanja kapitalne opreme i planiranje proizvodnje i potrošnje električne energije. Transformer modeli mašinskog učenja su postali dominantna arhitektura u oblasti obrade prirodnog jezika, ali se njihova upotreba uspešno pokazala u analizi vremenskih serija podataka otvarajući nove mogućnosti za poboljšanje tačnosti njihovih predikcija. Rad se sastoji od dve povezane celine. U prvom delu rada su detaljno prikazane dve osnovne arhitekture transformer modela mašinskog učenja. U drugom delu su analizirane njihove karakteristike kroz praktične zadatke dugoročnog predviđanja vremenskih serija podataka o proizvodnji električne energije iz solarnih izvora. Detaljno su analizirani uticaj različitih hiperparametara modela, veličine prozora ulaznih podataka i horizonta predikcija i mehanizmi pažnje. Za validaciju predloženih transformer modela je upotrebljen skup podataka o proizvodnji solarne električne energije u različitim vremenskim uslovima. Performanse modela su ocenjene primenom nekoliko vrsta standardne metrike. Rezultati eksperimenata sa transformer modelima opravdava njihovu primenu u dugoročnim predikcijama vremenskih serija. Analiza dobijenih rezultata omogućava diskusiju o mogućim primenama ovih modela u elektroenergetici, uključujući predikciju proizvodnje iz obnovljivih izvora i efikasnu integraciju ovih izvora energije u elektroenergetski sistem. U zaključku je jasno naglašen značaj buduće primene transformer modela mašinskog učenja u skoro svim segmentima elektroenergetike.

Ključне reči: Mašinsko učenje, transformer modeli, vremenske serije, obnovljivi izvori energije.

Abstract: Time series forecasting in the electricity power sector represents a key challenge for production prediction, management optimization, maintenance strategy selection for capital equipment, and planning of electricity generation and consumption. Transformer models have become the dominant architecture in the field of natural language processing, but their successful application in time series analysis has opened new opportunities for improving prediction accuracy. This paper consists of two interconnected parts. The first part provides a detailed overview of two fundamental transformer model architectures. The second part analyses their characteristics through practical tasks related to long-term time series forecasting. A detailed examination is conducted on the impact of various model hyper parameters, the size of input data window, the prediction horizon, and attention mechanisms.

The proposed models are validated using a dataset on energy production and consumption from solar renewable sources. Model performance is evaluated using several types of standard metrics. The experimental results with transformer models justify their application in long-term time-series predictions. The analysis of the obtained results enables a discussion on the potential applications of these models in the power sector, including production forecasting from renewable sources and the efficient integration of these renewable energy sources into the power system. The conclusion strongly emphasizes the significance of future applications of transformer-based machine learning models in almost all power system branches.

Key words: Machine learning, transformer models, time series, renewable energy sources.

1 UVOD

Sve veće oslanjanje na obnovljive izvore energije, dovelo je do porasta istraživanja usmerenih na unapređenje efikasnosti i pouzdanosti njihovog rada, kako u smislu samih izvora, tako i njih kao delova šireg elektroenergetskog sistema [1]. Precizno predviđanje proizvodnje energije, dobijene iz obnovljivih izvora, je ključno za njihovu bolju integraciju u energetske mreže, smanjenje operativnih troškova i povećanje stabilnosti sistema.

U radu je fokus istraživanja na primeni modela mašinskog učenja za predikciju vremenskih serija podataka koji se odnosi na proizvodnju električne energije dobijene iz solarnih elektrana. Ova proizvodnja je uslovljena velikim brojem parametara kao što su:

1. Količina sunčeve energije koja dopire do površine solarnih panela i koja direktno utiče na njihovu proizvodnju.
2. Klimatski uslovi.
3. Ugao i orientacija panela prema suncu.
4. Zaprljanost panela.
5. Starost panela.
6. Kvalitet i performance energetskih pretvarača.
7. Arhitektura i koncept elektrane

Modeli dubokog učenja predstavljaju privlačnu alternativu tradicionalnim statističkim modelima koji često ne uspevaju da uhvate složene nelinearne obrasce [2]. Poslednjih godina su se pojavili brojni algoritmi koji koriste mašinsko učenje za predviđanje energije dobijene iz solarnih panela [3, 4]. Zbog često promenljivih vremenskih uslova, upotreba veštačke inteligencije i mašinskog učenja u ovom kontekstu postaje sve značajnija. Sa rastućom potražnjom za električnom energijom i težnjom ka održivim obnovljivim izvorima energije, precizno predviđanje potrošnje i proizvodnje električne energije postalo je od suštinskog značaja. Mašinsko učenje (ML) omogućava preciznije modelovanje kompleksnih odnosa u podacima, uz niže troškove i veću tačnost u odnosu na tradicionalne metode. Velika prednost ML modela je mogućnost obrade velikih količina podataka iz različitih izvora, što omogućava pouzdanija predviđanja. Modeli dubokog učenja kao što su ARIMA (AutoRegressive Integrated Moving Average), rekurentne mreže (Recurrent Neural Network - RNN, Long Short-Term Memory - LSTM i Gated Recurrent Unit - GRU) i Transformer modeli uspešno hvataju vremenske zavisnosti u podacima.

U radu je istraživački fokus na primeni transformer modela mašinskog učenja za predikciju i analizu vremenskih serija podataka.

Za validaciju predloženog modela je korišćen skup podataka “Renewable Power Generation weather condition 2024” [5]. Rad se u osnovi bavi primenom ML modela u istraživanjima globalnih trendova u korišćenju obnovljivih izvora energije, njihovih prednosti i perspektivama za budućnost.

2 ANALIZA I PREDVIĐANJE VREMENSKIH SERIJA

Vremenske serije predstavljaju vremenski sekvencijalne nizove podataka sa jednakim vremenskim intervalima između podataka. Razumevanje njihove strukture i karakteristika ključno je za analizu i predikciju. Analiza i predikcija vremenskih serija igra ključnu ulogu u elektroenergetici, omogućavajući preciznije planiranje proizvodnje, optimizaciju potrošnje, predikciju kvarova i efikasnije upravljanje održavanjem i resursima. Rekurentne neuronske mreže (RNN) i transformer modeli predstavljaju dve grupe savremenih modela mašinskog učenja koje su značajno unapredile tačnost i pouzdanost predikcija u ovoj oblasti.

2.1 Osobine vremenskih serija

Dekompozicija vremenskih serija omogućava dublju analizu njihovih osnovnih komponenti: trend, sezonalnost i slučajnu komponentu. U zavisnosti od broja osobina koje karkaterišu neku vremensku seriju, delimo ih na univariantne i multivariantne. Takođe, vremenske serije mogu biti stacionarne i nestacionarne. Stacionarnost je fundamentalni koncept u analizi vremenskih serija jer omogućava njihovu pouzdanu analizu, modelovanje i predikciju. Nestacionarne serije često zahtevaju transformaciju pre nego što se mogu koristiti u prediktivnim modelima mačinskog učenja. Razlikovanje stacionarnih i nestacionarnih serija je ključno za donošenje ispravnih zaključaka i kreiranje tačnih prognoza. Vremenska serija je stacionarna ako njene statističke osobine, poput srednje vrednosti i varijanse, ostaju konstantne tokom vremena. Stacionarnost se često proverava pomoću Dickey-Fuller testa. Nestacionarne vremenske serije imaju karakteristike koje se menjaju tokom vremena, uključujući trend i sezonalnost. Kako bi se postigla stacionarnost, često se primenjuju različiti matematički postupci. Dekompozicija vremenskih serija podrazumeva razlaganje podataka na tri osnovne komponente:

- Trend (T_t): dugoročna promena podataka u seriji.
- Sezonalnost (S_t): ponavljajući obrasci u određenim vremenskim intervalima.
- Slučajna tj. rezidualna komponenta (R_t): nasumične varijacije podataka koje nisu deo trenda ili sezonalnosti.

U teorijskoj osnovi su dominantna su dva modela dekompozicije vremenskih serija X_t , aditivni (1) i multiplikativni (2).

$$X_t = T_t + S_t + R_t \quad (1)$$

$$X_t = T_t \times S_t \times R_t \quad (2)$$

Adiktivni model se koristi kada su sezonske promene i trend relativno konstantni tokom vremena, dok se multiplikativni model koristi kada su sezonske varijacije i trend izraženiji i kada među njima postoje neke zavisnosti (proporcija i sl.). U istraživačkoj praksi postoji veliki broj metoda i modela koje se koriste za dekompoziciju vremenskih serija. Neki od njih predstavljaju hibridne i ansemplirane modele koji kombinuju više pojedinačnih modela [6] sa modelima neuronskih mreža za poboljšanje prognoza.

2.2 Transformer model za predikciju vremenskih serija

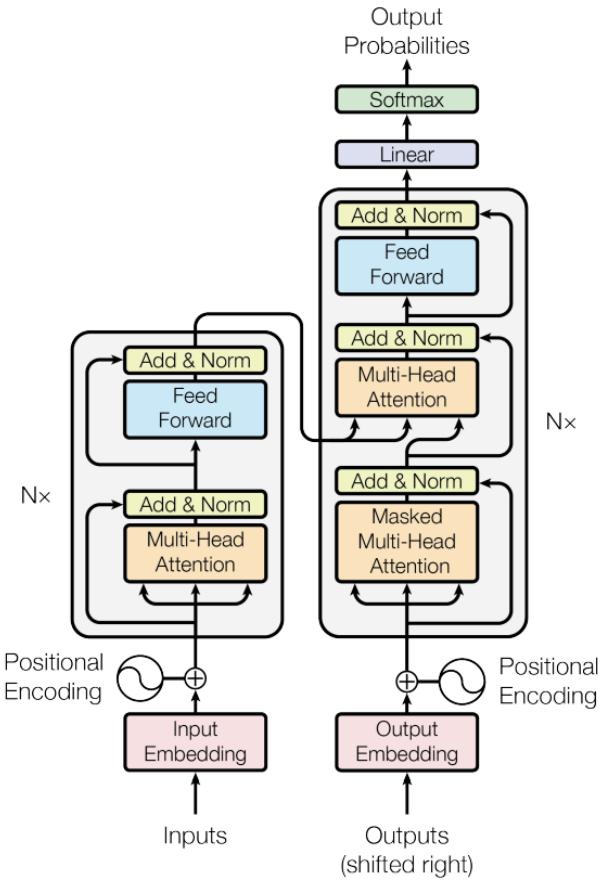
Standardne rekurentne neuronske mreže (RNN) mreže pate od problema dugoročnog pamćenja i gubitka informacija tokom dugih sekvenci podataka. LSTM i GRU su unapređene verzije RNN-a koje koriste specijalne mehanizme za dugoročno pamćenje, što ih čini efikasnijim za analizu složenih vremenskih serija. Za razliku od RNN-a, transformer model istovremeno obrađuje sve vremenske tačke, omogućavajući efikasnije hvatanje dugoročnih korelacija, a pri tome mogu obrađivati velike skupove podataka brže u odnosu na sekvencijalni proces obrade primenom RNN-a. Dok su RNN modeli sa LSTM i GRU arhitekturama korisni za sekvencijalne podatke sa kratkoročnim zavisnostima, Transformer modeli nude bolju skalabilnost i dugoročnu analizu. Kombinacija ovih modela može dodatno poboljšati predikcije i omogućiti pametnije upravljanje elektroenergetskim sistemima u budućnosti. Pored rekurentnih neuronskih mreža, u elektroenergetici se često koriste modeli zasnovani na stablima odlučivanja, kao što su Random Forest, XGBoost, koji su posebno efikasni u analizi nestrukturisanih podataka i vremenskih serija [1, 7].

Transformer modeli su prvo bitno razvijeni za obradu prirodnog jezika, ali se sve više primenjuju u obradi vremenskih serija. Ključna komponenta transformer arhitekture (S1.1) je mehanizam samopažnje (*self-attention*), koji omogućava modelu da obrađuje sve vremenske tačke simultano, umesto sekvencijalno kao kod tradicionalnih rekurentnih neuronskih mreža. Transformer arhitektura sastoji se od sledećih ključnih delova [8]:

- Mehanizam samopažnje (Self-Attention) omogućava modelu, pomoću tri parametra (Query, Key, Value) da proceni važnost različitih vremenski određenih podataka bez obzira na njihovu udaljenost u sekvenci. U praksi, mehanizam pažnje izračunavamo nad skupom upita (queries) istovremeno, koji su objedinjeni u matricu Q . Ključevi (keys) i vrednosti (values) takođe se objedinjavaju u matrice K i V . Matrica izlaza (3) ima ključnu ulogu u određivanju na to na šta model treba da obrati pažnju unutar ulazne sekvence.

$$\text{Attention}(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (3)$$

- Mehanizam višestruke pažnje (Multi-Head Attention) proširuje osnovni koncept samopažnje tako što koristi više pažnje istovremeno i time poboljšava sposobnost modela da identificuje različite obrazce u podacima. Umesto jednog skupa Query, Key i Value vektora, model kreira više njih paralelno, što omogućava obradu različitih aspekata iste sekvence.
- Pozicioni enkoding (Positional Encoding): s obzirom na to da transformer ne obrađuje podatke sekvencijalno kao RNN, neophodno je koristiti pozicione enkodere kako bi očuvao informacije o redosledu podataka u vremenskoj seriji.
- Feedforward slojevi: nakon obrade mehanizma pažnje, podaci prolaze kroz potpuno povezane slojeve koji omogućavaju nelinearne transformacije.
- Normalizacija i Dropout: Ove tehnike se koriste za stabilizaciju učenja i sprečavanje prenaučenosti modela.



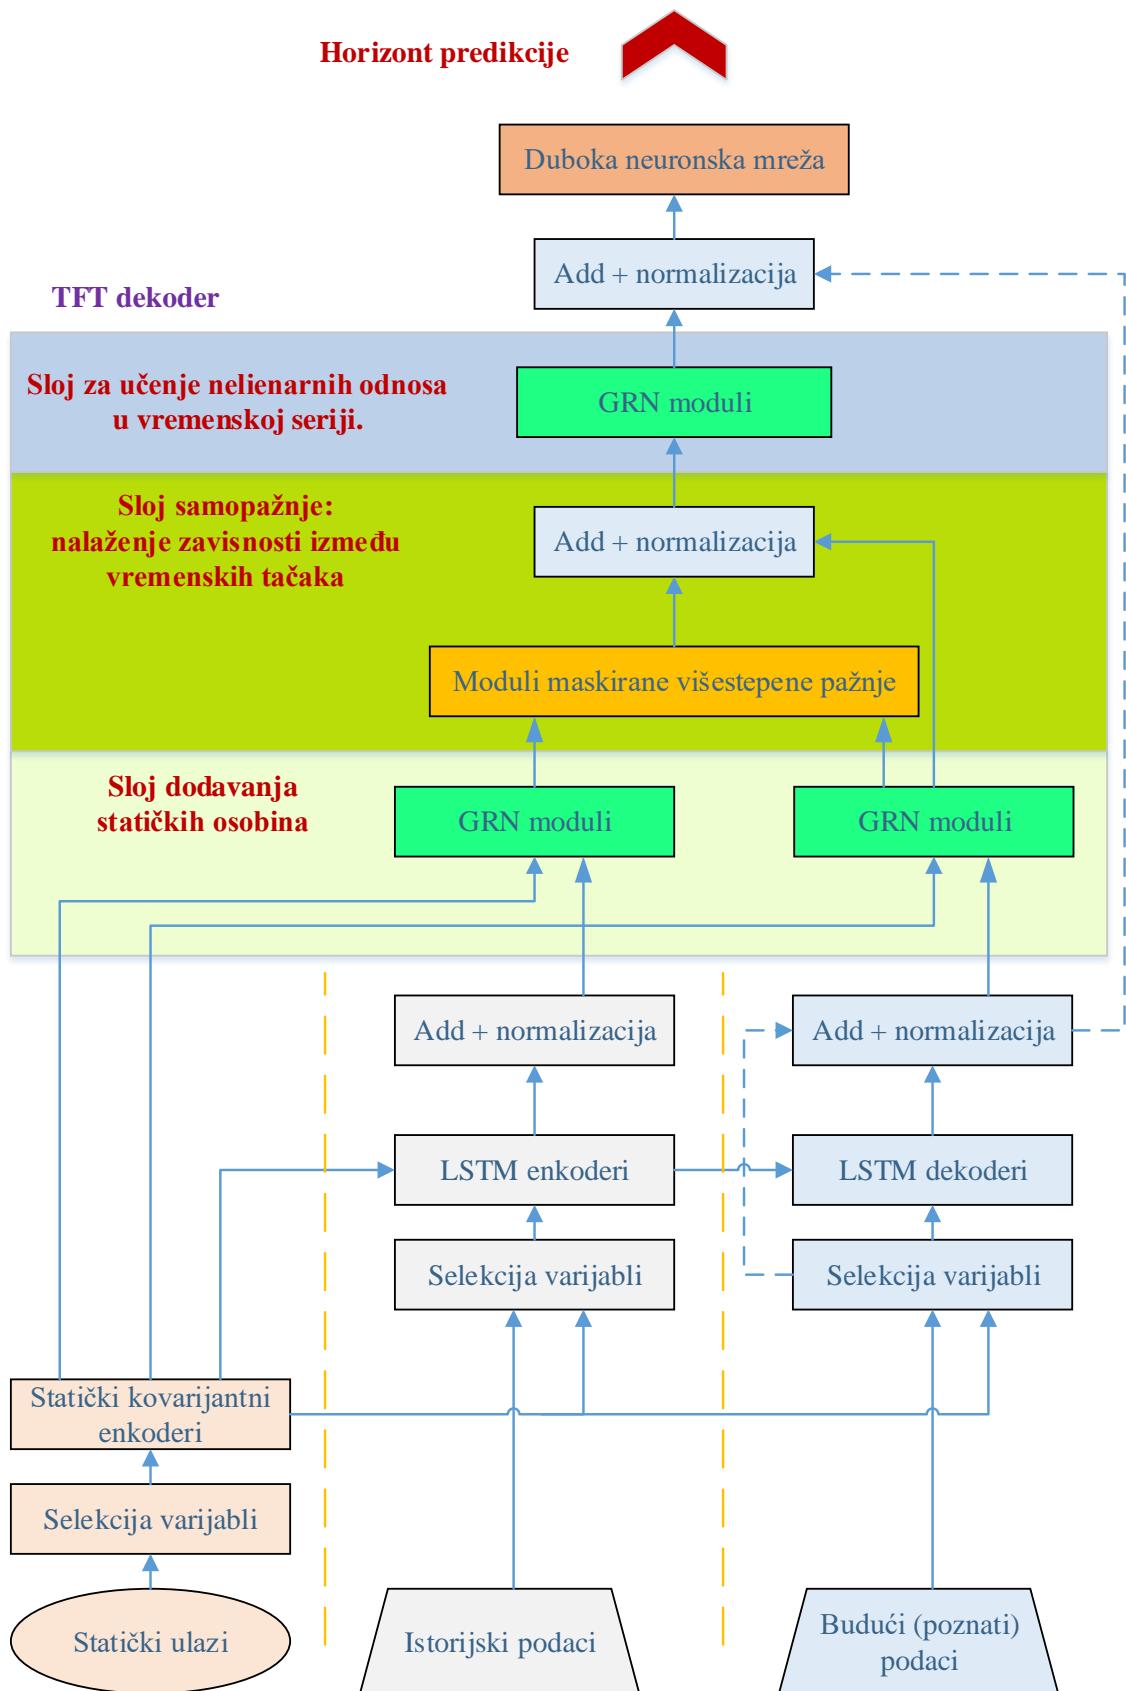
Slika 1: Transformer model [8]

Proces obrade podataka iz vremenske serije se pokreće tako što se za svaki token (vremenska podsekvenca – npr. podaci za jedan dan ili jedan sat) upit iz Q uparuje sa svim ključevima iz K da bi se dobile pažnje (attention scores). Potom se ove pažnje normalizuju i aktiviraju (softmax) i koriste za kombinovanje odgovarajućih vrednosti iz V. Na ovaj način, svaki token „gleda“ druge delove sekvene i odlučuje koje informacije su mu važne, čime se omogućava razumevanje konteksta bez obzira na poziciju u sekvenci.

2.3 TFT transformer model za predikciju vremenskih serija

Temporal Fusion Transformer (TFT) je novija vrsta transformer modela čija je arhitektura prilagođena za obradu i prognozu vremenskih serija, za razliku od klasičnog transformera koji je inicijalno dizajniran za obradu prirodnog jezika. Ovi transformeri [9] integrišu mehanizme selektivne obrade podataka, mehanizme samoprilagođavanja i imaju sposobnost obrade dugoročnih zavisnosti, omogućavaju kombinaciju statickih i dinamičkih ulaza, što ih čini izuzetno moćnim za predikciju u kompleksnim vremenskim serijama.

TFT arhitekura (Sl.2) je zasnovana na složenoj hijerahiski (i vertikalno i horizontalno) dizajniranoj dubokoj neuronskoj mreži u čijoj osnovi je mehanizam pažnje (kao i kod standardnog transformera) ali tako dadizajniran da omogućava višehorizontalnu prognozu, odnosno niz vremenski definisanih sekvenčijalnih podataka predikcije.



Slika 2: Temporal Fusion Transformer (TFT)

TFT kombinuje najbolje osobine klasičnog transformera i LSTM rekurentne mreže. Model kombinuje visoku tačnost predikcija sa interpretabilnošću i omogućava dubinsku analizu podataka u cilju tačnijih predikcija. Njegove glavne osobine su: automatsko prepoznavanje koji su ulazni podaci najvažniji za buduću predikciju, automatsko prepoznavanje sezonalnosti podataka, prepoznavanje nagle promene u vrednostima podataka (detekcija iskakajućih vrednosti) i eliminacija nevažnih podataka i šuma. TFT arhitektura se sastoji od sledećih ključnih komponenti:

- Mehanizmi selekcije varijabli – omogućavaju osnovnu selekciju relevantnih karakteristika, čime se minimiziraju nepotrebni podaci i poboljšava interpretabilnost.
- Obrada i analiza statičkih informacija – statičke informacije se integrišu u mrežu radi boljeg kontekstualnog razumevanja.
- Sekvencijalna obrada lokalnih obrazaca – koristi LSTM slojeve za određivanje lokalnih i kratkoročnih zavisnosti unutar podataka.
- *Self-Attention* mehanizam služi za analizu dugoričnih vremenskih zavisnosti i sezonskih obrazaca.
- *Multi-Head Attention* mehanizam omogućava analizu dugoročnih zavisnosti i isticanje važnih vremenskih tačaka.
- Dekoder sa interpretabilnim mehanizmom pažnje omogućava analizu vremenskih obrazaca i značajnih događaja
- Predikcija više vremenskih horizonta – za razliku od tradicionalnih metoda koje predviđaju samo sledeći trenutak, TFT omogućava simultano generisanje predikcija za više vremenskih koraka unapred, omogućavajući korisnicima bolje donošenje odluka.
- Kvantilna regresija omogućava generisanje predikcija sa opsegom poverenja. Kvantiili se mogu definisati kao tačke koje dele podatke na određeni broj jednakih delova. Oni omogućavaju analizu raspodele podataka, pomažući u razumevanju gde se određene vrednosti nalaze u odnosu na ostatak skupa podataka.
- Modeli su realizovani primenom *TensorFlow* alata u Pajtonu primenom *DARST* biblioteke. Tok izvršenja modela kroz pseudo kodove.

Pseudo kod standardnog transformer modela:

INPUT:

X = poznata vremenska serija [n vrem. koraka, d karakteristika]

y = stvarna proizvodnja [n vremenskih koraka]

PARAMETRI:

d_model = dimenzija unutrašnje reprezentacije

n_heads = broj glava u multi-head attention mehanizmu

n_layers = broj enkoder slojeva

dropout_rate

prediction_horizon = broj vremenskih koraka koji se predviđaju

1. Preprocesiranje:

- Normalizacija ulaznih vrednosti
- Kodiranje i dodavanje vremenskih karakteristika (dan, sat,...)
- Kreiranje pozicionog enkodinga za redosled za vrem. korake

i formatiranje vremenskih podsekvenči u vektore iste dužine d

2. Tokenizacija vremenske serije:

Formiraje tokena od vremenske serije po ugledu na reči

3. Enkoder

- Slojevi za obradu (ponavljaju se n_layers puta): primena mehanizma privremene samopasnje i primena multi-head attention da model „obrati pažnju“ na pojedine tačke u vremenu

4. Dekoder

- Kombinovanje informacije iz prošlosti i budućnosti za predikciju
- Primena dense sloja za dodavanje nelineranosti i mapiranje (definisanje trenutka) vrednosti proizvodnje u vremenskom Koraku

- Optimizer: Adam

- Normalizacija

- Bekpropagacija i ažuriranje težina

6. Funkcija gubitaka (MSE ili MAE) i process treniranja:

- Računanje gubitaka između predikcije i stvarnog y

- Optimizer: Adam

- Backpropagacija i ažuriranje težina

Pseudo kod TFT transformer modela:

INPUT:

X_past = poznata vremenska serija [n vrem. koraka, d karakteristika]

X_future = poznati budući podaci [n_future koraka, d karakteristika]

S: statički ulazi [lokacija, tip panela]

y: ciljna vrednost – proizvodnja solarne energije [n vremenskih koraka]

PARAMETRI:

d_model = dimenzija unutrašnje reprezentacije

n_heads = broj glava u attention mehanizmu

n_layers = broj encoder slojeva

dropout_rate

prediction_horizon = broj koraka koji se predviđaju

1. Preprocesiranje:

- Normalizacija ulaznih vrednosti

- Kodiranje i dodavanje vremenskih karakteristika (dan, sat,...)

- Kreiranje pozicionog enkodinga za redosled za vrem. korake i formatiranje vremenskih podsekvenči u vektore iste dužine d

2. Obrada statičkih karakteristika (S):

- Primena dense sloja za dobijanje vektora statičkog konteksta

3. Mreža za selekciju varijabli:

- Računanje težine (uticaja) svake promenljive

- Težinska kombinacija ulaza prema njihovoj važnosti

4. LSTM enkoder:

- X_past i X_future obrada kroz LSTM za hvatanje sekv. konteksta

- Obogaćivanje statičkim vrednostima: kombinovanje LSTM izlaza sa statičkim vrednostim radi integracije stat. vr. u izlazne informacije

- Primena mehanizma privremene samopažnje i primena multi-head attention da model „obrati pažnju“ na pojedine tačke u vremenu

5. TFT dekoder:

- Kombinovanje informacije iz prošlosti i budućnosti za predikciju
- Primena dense sloja za dodavanje nelineranosti i mapiranje
(definisanje trenutka) vrednosti proizvodnje u vremenskom koraku

6. Funkcija gubitaka (MSE ili MAE i process treniranja:

- Računanje gubitaka između predikcije i stvarnih vrednosti y
- Optimizer: Adam
- Normalizacija
- Bekpropagacija i ažuriranje težina

OUTPUT:

- Predikcija proizvodnje za horizont budućih vremenskih koraka

TFT je moćan model za prognozu vremenskih serija sa više horizonata koji omogućava visoku tačnost, dok istovremeno pruža interpretabilnost rezultata. Njegove ključne osobine kao što su selekcija varijabli, višeslojna pažnja, statičko obogaćivanje i sekvensijalno procesiranje omogućavaju mu da se prilagodi različitim vrstama podataka i problema.

3 REZULTATI VALIDACIJE TRANSFORMER MODELA

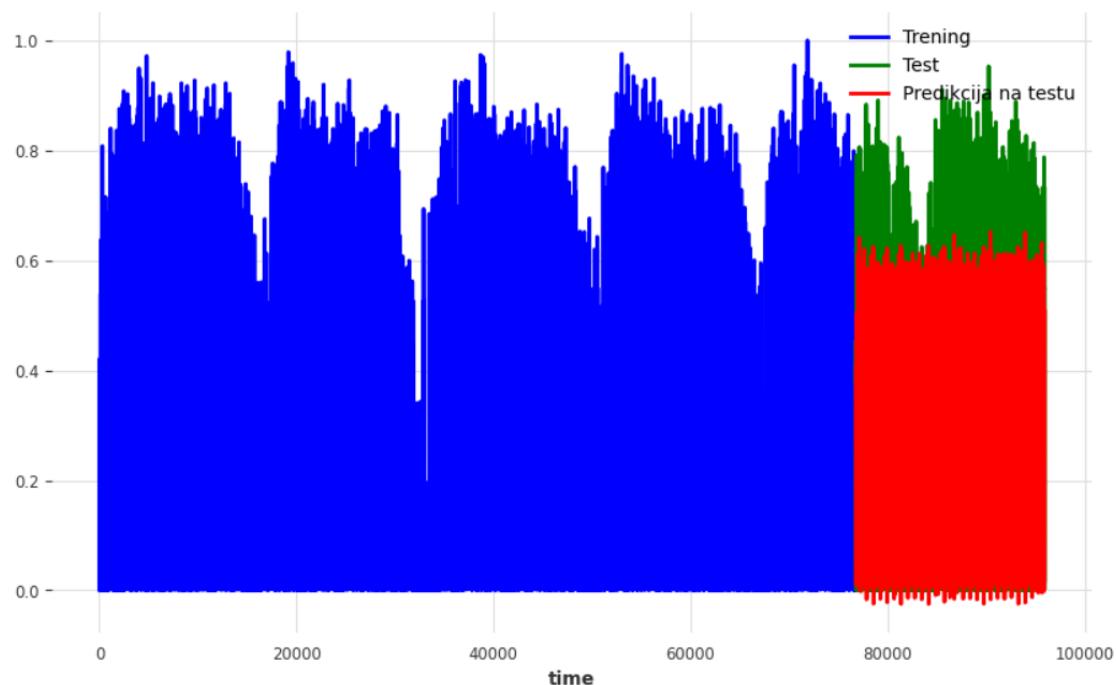
Za validaciju prikazanih transformer modela je upotrebljen skup podataka “*Renewable Power Generation weather condition 2024*” [5], o proizvodnji obnovljive solarne energije u različitim vremenskim uslovima. Ovaj skup podataka sadrži merenja različitih vremenskih parametara i njihov uticaj na proizvodnju solarne energije, pružajući uvid u to kako solarno zračenje, temperatura, vlažnost i padavine utiču na proizvodnju energije. Vrednosti parametara ML modela su prikazani u Tabeli 1.

Tabela 1: Parametri standardnog transformer i TFT transformer modela

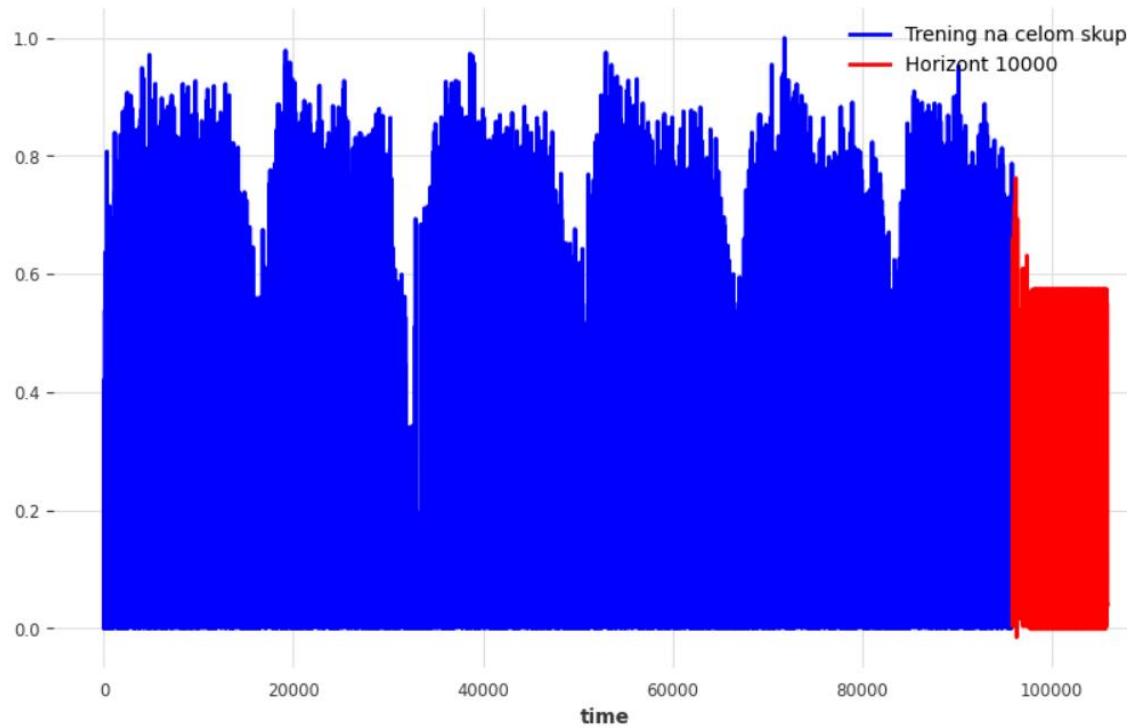
Komponenta	Transformer model	Temporal Fusion Transformer (TFT) model
Ulazni podaci	Vremenska serija (n vremenskih koraka, d karakteristika)	Vremenska serija podeljena na: - prošle vrednosti (X_past) - buduće poznate vrednosti (X_future) - statički ulazi (S)
Tokenizacija / enkodovanje	Spajanje karakteristika u vektor + dodavanje pozicionog enkodovanja	Svaka promenljiva prolazi kroz varijabilnu selekciju; enkodovanje kroz statički i vremenski kontekst
Pozicioni enkoding	Sinusni ili trenirani pozicioni enkoding dodaje se na vektore	U kombinaciji sa vremenskim kontekstom (dan, sat, itd.)
Modeliranje sekvence	Višeslojni enkoder sa samopažnjom mehanizmom	LSTM enkoder + statičko dodavanje + mehanizam “pažnje”
Mehanizam pažnje	Multi-head self-attention u svim slojevima	Temporal attention koristi se na kraju da istakne važne vremenske trenutke
Statički ulazi	Nisu direktno uključeni	Aktivno se koriste za obogaćivanje konteksta kroz „static enrichment“
Selekcija promenljivih	Nema	Ima – varijabilni selekcioni mehanizam koji određuje važnost svake ulazne karakteristike

Komponenta	Transformer model	Temporal Fusion Transformer (TFT) model
Dekoder izlazni sloj	Linearni sloj na izlazu attention sloja	Nelinerani sloj kroz duboku nn mrežu nakon attention + obogaćen statičkim i vremenskim informacijama
Cilj predikcije	Predikcija proizvodnje za naredni vremenski korak(e)	Predikcija proizvodnje za više vremenskih koraka unapred
Prednosti	Jednostavni, skalabilan, sposoban za paralelnu obradu	Bogatiji model sa boljom interpretabilnošću i selektivnim mehanizmima
Primena	NLP (analiza jezika) i predikcija opšte vremenske serije (npr. električna potrošnja, vremenska prognoza)	Složenije vremenske serije sa mešavinom statičkih, dinamičkih i budućih poznatih ulaza
Hiperparametri modela	<pre> # duzina ulazne vremenske sekvence: input_chunk_length=100 # dužina izlaznog prozora predikcije: output_chunk_length=100 # dimenzija modela: d_model=64, # broj glava u mehanizmu pažnje: nhead=8 # broj slojeva enkodera: num_encoder_layers=4 # broj slojeva dekodera: num_decoder_layers=4 # dimenzija feedforward NN mreže: dim_feedforward=256 # stopa odbacivanja neurona u procesu treniranja: dropout=0.1 # aktivaciona funkcija: activation='relu' # broj epoha-ciklusa treniranja: n_epochs=10 # br. istovremenih vrem.ser. u jednom koraku treniranja: batch_size=32 </pre>	<pre> # duzina ulazne vremenske sekvence: input_chunk_length=500 # dužina izlaznog prozora predikcije: output_chunk_length=100 # dimenzija skrivenih sklojeva - memorija za učenje: hidden_size=64 # broj LSTM slojeva: lstm_layers=1 # broj glava u multi-head attention mehanizmu: num_attention_heads=8 # stopa odbacivanja neurona u procesu treniranja: dropout=0.1 # broj istovremenih vrem.ser. u jednom koraku treniranja: batch_size=32 # broj epoha-ciklusa treniranja n_epochs=10 # pozicija vremenskog koraka u sekvenci: add_relative_index=True # fukcija gubitaka za određene kvantile: loss_fn=QuantileRegression(quantiles=[0.1, 0.5, 0.9]), # verovatnoća predikcije za istu kvantilnu regresiju: likelihood=QuantileRegression(quantiles=[0.1, 0.5, 0.9]) # learning rate (brzina učenja) optimizer_kwargs={"lr": 1e-3}, # Izbor GPU ili CPU za treniranje: pl_trainer_kwargs={"accelerator": "cpu"} </pre>

Sledeće dve slike prikazuju rezultate predikcije vremenske serije proizvodnje solarne električne energije primenom standardnog transformer modela koji je “nateran” da vrši obradu i predikciju vremenske serije koja opisuje proizvodnju solarne električne energije. Na Sl.3 je prikazan model treniran na delu skupa za treniranje i predikcija na validacionom skupu, dok je na Sl.4 model treniran na celom skupu, a potom je izvršena predikcija proizvodnje koje se odnosi na 10000 budućih vremenski sekvencijalnih podataka.



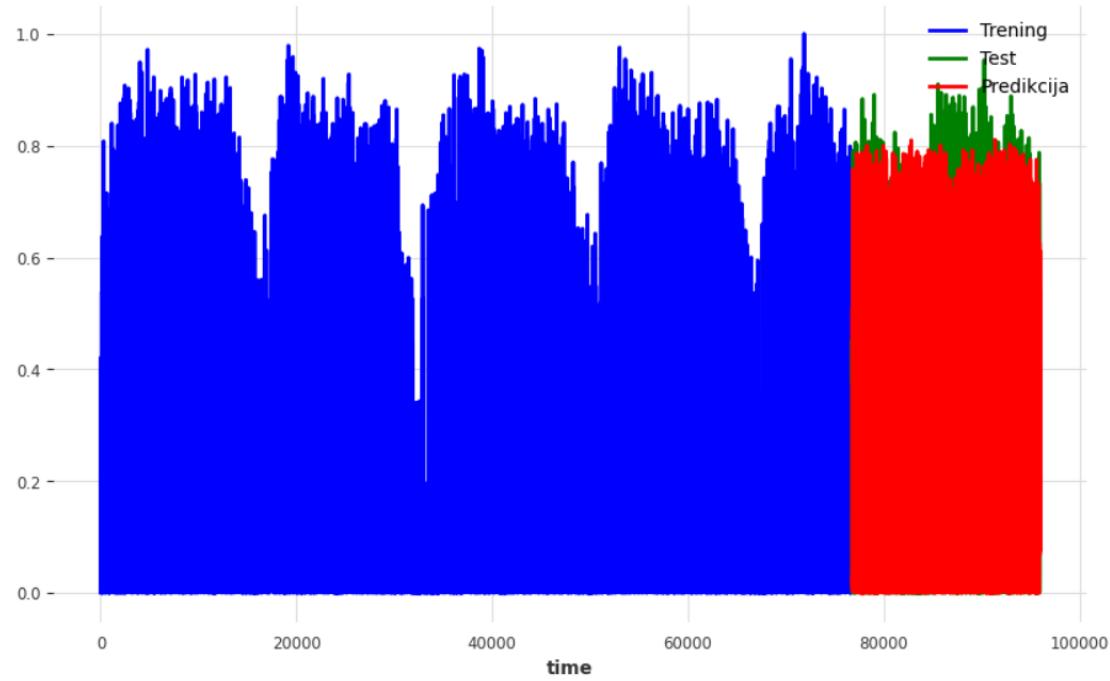
Slika 3: Treniranje i validacija transformer modela na odvojenim skupovima za treniranje i testiranje



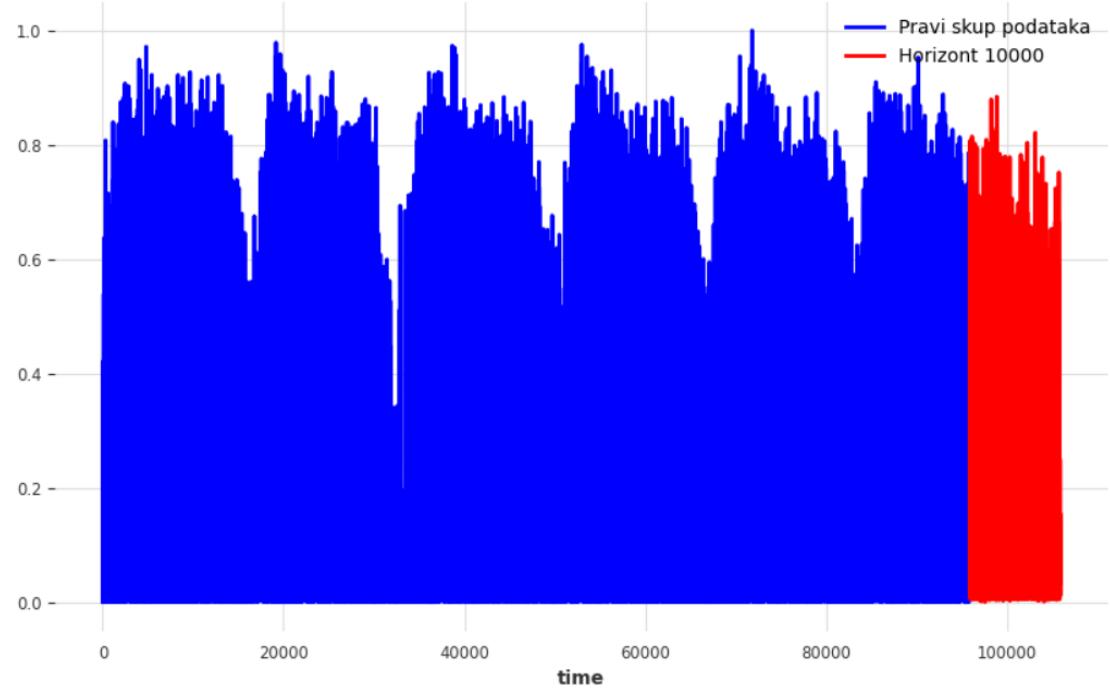
Slika 4: Treniranje transformer modela na celom skupu i predikcija niza od 10000 podataka

Jasno se vidi na Sl.4 da horizont predikcije ne može da bude suviše veliki (prema izabranim parametrima) i da predikcija postaje značajnije loša posle 1000 budućih vrednosti.

Sledeće dve slike prikazuju rezultate predikcije vremenske serije proizvodnje solarne električne energije primenom TFT transformer modela koji je prilagođen za obradu i predikciju vremenskih serija podataka. Na Sli.5 je prikazan model treniran na delu skupa za treniranje i predikcija na validacionom skupu, dok je na Sli.6 model treniran na celom skupu a potom je izvršena predikcija proizvodnje koje se odnosi na 10000 budućih vremenski sekvensijalnih podataka.



Slika 5: Treniranje i validacija TFT modela na odvojenim skupovima za treniranje i testiranje



Slika 6: Treniranje TFT modela na celom skupu i predikcija niza od 10000 podataka

Slika 5 prikazuje prilično dobro slaganje predikcije na test skupu sa validacion podacima primenom TFT modela. Slika 6 prikazuje daleko veći horizont (10000 podataka) pouzdane predikcije nego što je to slučaj prikazan na Sl.4 za standardni transformer model.

4 DISKUSIJA

Predikcija vremenskih serija predstavlja izazov zbog složenih obrazaca sezonalnosti, trenda i autokorelacije. U praksi se koriste kako tradicionalni statistički modeli, tako i moderni modeli bazirani na veštačkoj inteligenciji. Među najčešće korišćenim modelima su:

- ARIMA (AutoRegressive Integrated Moving Average) - statistički model.
- LSTM (Long Short-Term Memory Networks) - rekurentna neuronska mreža (RNN).
- GRU (Gated Recurrent Unit) - rekurentna neuronska mreža (RNN)
- Temporal Convolutional Networks (TCN) - konvolucionna neuronska mreža za vremenske serije.
- Transformer modeli (npr. PatchTST, Informer, TFT) - modeli bazirani na mehanizmu pažnje.
- XGBoost / LightGBM - ansambl metoda (stabla odlučivanja)

Izbor modela zavisi od prirode podataka, dužine vremenskih nizova, broja varijabli i zahteva u pogledu interpretabilnosti. Za kratke i stacionarne serije i dalje su korisni ARIMA modeli i modeli rekurentnih mreža, dok su za složene i duge vremenske serije transformer arhitekture, posebno TFT i PatchTST, trenutno najnapredniji pristup.

S obzirom na činjenicu da su u radu korišćeni vremenski serije zavisne od vremenskih uslova, transformer modeli, naročito Temporal Fusion Transformer (TFT) i varijante kao što su Informer i PatchTST, pokazuju izuzetne rezultate u njihovoј predikciji. U dosadašnjoj praksi TFT model je postigao MAPE u rasponu od 6,5% do 9,2% za dnevne prognoze insolacije, u zavisnosti od regije, količine oblaka i broja ulaznih meteoroloških varijabli. Rezultati se poboljšavaju dodatnom obradom ulaza (npr. uključivanjem vremenskih kovarijata i eksternih faktora poput sezonalnosti i oblačnosti). Produženje vremenskog perioda za obuku modela sa 3 na 6 godina rezultovalo je u proseku sa 10–15% boljim MAPE rezultatima, posebno kod sezonski izraženih regija. U prognozi insolacije i drugih zavisnih meteoroloških parametara, zasnovanoj na krećim vremenskim serijama i sa kraćim hotizontom predikcije, još uvek su dominantne LSTM i GRU rekurentne neuronske mreže.

5 ZAKLJUČAK

Kako se elektroenergetski sistemi nastavljaju razvijati uz sve veću složenost i integraciju obnovljivih izvora energije, napredni modeli predikcije vremenskih serija poput rekurentnih neuronskih mreža i transformer modela igrat će ključnu ulogu u obezbeđivanju pouzdanog i efikasnog upravljanja energijom putem predikcije prizvodnje i potrošnje i unapređenja održavanja sistema. U radu je istraživačka pažnja posvećena primeni novim naprednim transformer modelima za procesiranje i predviđanje vremenskih serija koje prikazuju proizvodnju solarne električne energije. Komparativna analiza prikazanih modela potvrđuje opravdanost primene Temporal Fusion Transformer modela za predikciju većeg horizonta podataka koji zavise od brojnih osobina koje utiču na proces proizvodnje električne energije.

Buduća istraživanja će biti fokusirana na primenu i razvoj novih transformer modela sa ugrađenim slojevima rekurentnih mreža koje mogu detektovati "uslovno rečeno" kratkoročne vremenske zavisnosti, a potom primenom mehanizama pažnje, mehanizama za selekciju i odabir, kako parametara, tako i obrazaca zavisnosti, i pronalaženju nelineranih zavisnosti primenom dubokih neuronskih mreža, vršiti veće horizonte predikcije.

ZAHVALNICA

Ovaj rad je podržalo Ministarstvo nauke, tehnološkog razvoja i inovacija Republike Srbije kroz Ugovor o realizaciji i finansiranju naučnoistraživačkog rada NIO u 2025. godini.

6 LITERATURA

- [1] Ivanović Luka, Milić Saša D, Sokolović Živko, Rakić Aleksandar, "Komparativna analiza dubokih neuronskih mreža i algoritama sa pojačanjem gradijenta u dugoročnom predviđanju snage vetra", *Zbornik radova, Elektrotehnički institut "Nikola Tesla"*, 2024, ISSN 0350–8528. <https://doi.org/10.5937/zeint34-51258>
- [2] Saša Milić, Luka Ivanović, Žarko Janda, Miroslav Dragićević, "Transformer Machine Learning Models for Time Series Electricity Power Forecasting", 24rd International Symposium INFOTEH-JAHORINA, 19-21 March 2025.
- [3] <https://infoteh.etf.ues.rs.ba/radovi.php>
- [4] B. Gao, X. Huang, J. Shi, Y. Tai, J. Zhang, "Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks," *Renewable Energy*, vol. 162, 2020, pp. 1665-1683.
- [5] F. Yang, Z. Chen, Y. Liang, "Precise solar radiation forecasting for sustainable energy integration - A hybrid model for day-ahead power and hydrogen production," *Renewable Energy*, vol. 237, part C, 2024, 121732.
- [6] Skup podataka: *Renewable Power Gen Prediction with Time Series*, Renewable.csv. Licenca: Apache 2.0. Dostupno na sajtu: <https://www.kaggle.com/datasets/sheemazain/renewable-power-generation-weather-condition-2024>
- [7] H. Iftikhar, S. M. Gonzales; J. Zywiółek, J. L. López-Gonzales, "Electricity Demand Forecasting Using a Novel Time Series Ensemble Technique," *IEEE Access*, vol. 12, 2024, pp. 88963 – 88975.
- [8] L. Zhang, D. Jánošík, "Enhanced short-term load forecasting with hybrid machine learning models: CatBoost and XGBoost approaches," *Expert Systems with Applications*, vol. 241, 2024, 122686. <https://doi.org/10.1016/j.eswa.2023.122686>
- [9] A. Vaswani, et al., "Attention Is All You Need," In the Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS), 2017, Long Beach, CA, USA. <https://doi.org/10.48550/arXiv.1706.03762>
- [10] B. Lim, S. Ö. Arik, N. Loeff, T. Pfister, "Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting," *International Journal of Forecasting*, vol. 37, 2021, pp. 1748–1764.