

Program

Digitalna transformacija robotiziranih tovarnih prihodnosti

DIGITOP

Rezultat D4.5:

Algoritem za napovedovanje porabe energije

Projekt/RRP	DIGITOP/RRP 4 - Aktivnost 4.3 Napovedovanje porabe energije - algoritem
Vrsta dokumenta	Poročilo o rezultatu D4.5
Verzija dokumenta	v1
Sodelujoči partnerji	IJS-E2, Kolektor-Sisteh
Avtorji	Dejan Gradišar, Miha Glavan, Grega Kmet
Datum priprave	31. 07. 2025


Kazalo

1	UVOD.....	3
2	ALGORITMI ZA NAPOVEDOVANJE PORABE VISOKO PONOVLJIVIH PROCESOV.....	4
2.1	MODELIRANJE PORABE POSAMEZNE PROIZVODNE OPERACIJE.....	4
2.2	MODELIRANJE ZAPOREDJA PROIZVODNIH OPERACIJ.....	5
3	ALGORITMI ZA NAPOVEDOVANJE PORABE ZVEZNIH PROCESOV	6
3.1	PRIDOBIVANJE IN PRIPRAVA PODATKOV	6
3.2	IDENTIFIKACIJA VPLIVOV NA PROFIL PORABE PROIZVODNJE	6
3.3	IDENTIFIKACIJA NAPOVEDNIH MODELOV	7
BIBLIOGRAFIJA		9

1 Uvod

V tem poročilu obravnavamo problematiko napovedovanja porabe električne energije proizvodnih procesov. Sposobnost kratkoročnega napovedovanja porabe odpira možnost avtomatiziranega upravljanja z energijo, t.j. optimizacijo stroškov porabe električne energije proizvodnih procesov na podlagi dnevnih proizvodnih planov. Uporaba pristopa je predvsem smiselna v primeru, ko imamo opravka z energetske intenzivnimi procesi, ki proizvajajo različne izdelke in omogočajo fleksibilno razporejanje proizvodnih korakov. Osnovni pogoj za tak pristop pa je, da imamo za razvoj energetskih modelov proizvodnje na voljo dovolj zgodovinskih podatkov iz proizvodnega obratovanja.

Namen napovednih modelov porabe energije posameznih proizvodnih operacij je napoved dnevnih profilov porabe električne energije glede na želen proizvodni plan. Možnost vnaprejšnje napovedi energetske potrebe se lahko izkoristi za sodelovanje z operaterjem omrežja za uravnoteženje električnega omrežja ali lokalno kar najbolje izkoristiti razpoložljive obnovljive vire energije. To pa seveda omogoča tudi nižje stroške za porabnike energije.



Slika 1: Koncept napovedovanja in upravljanja porabe el. energije

Koncept napovedovanja in upravljanja porabe energije delimo na dve fazi (Slika 1): (i) faza razvoj modela iz zgodovinskih podatkov in (ii) faza uporabe modela. Energetski model se lahko uporabi v različnih scenarijih: (i) za Ocenjevanje energetske ustreznosti planov proizvodnje, (ii) Upoštevanje dodatnega energetskega aspekta pri kreiranju planske table in (iii) Dimenzioniranje lokalnih energetskih komponent in njihovo sprotno upravljanje. V tem poročilu se osredotočamo na fazo razvoja modela.

2 Algoritmi za napovedovanje porabe visoko ponovljivih procesov

Visoko ponovljivi procesi imajo za enake operacije fiksne proizvodne poteke in posledično tudi zelo dobro ponovljiv časovni profil energetske porabe. Primer takšnih proizvodnih procesov je kosovna proizvodnja, kjer je za enak izdelek sosledje operacij in izvedba posamezne operacije zelo ponovljivo in so prisotne zgolj manjše variacije med posameznimi izvedbami operacij. Poleg tega se kosovna proizvodnja pogosto izvaja v večjih serijah, kar močno olajša pridobivanje ustreznih referenčnih primerov, potrebnih za razvoj napovednih modelov.

Problem razvoja napovednega modela porabe visoko ponovljivih procesov smo razčlenili na dva koraka. V prvem koraku modeliramo časovni profil posamezne proizvodne operacije, t.j. napoved porabe električne energije za en proizvodni stroj (oz. za eno proizvodno operacijo), kjer poteka preoblikovanje posameznega obdelovanca/kosa. V naslednjem koraku pa razvijemo model zaporedja posameznih operacij in njihovih prehodov.

Oba razvita modela (model napovedi profila posamezne operacije in diskretno-dogodkovni model proizvodnih operacij) nato združimo v končen celovit model, ki omogoča natančno napovedovanje porabe električne energije za celoten proizvodni proces. Za različne proizvodne plane in proizvodnjo različnih izdelkov lahko s takšnim modelom dovolj natančno napovemo profil porabe. Takšen model pa je nato mogoče uporabiti za planiranje in zagotavljanje ustreznih energetskih virov ali pa prilagajanje proizvodnega plana glede na trenutno razpoložljive energetske vire.

2.1 Modeliranje porabe posamezne proizvodne operacije


V prvem koraku razvijemo napovedni model profila porabe posamezne proizvodne operacije. Za razvoj modela je potrebno zagotoviti informacije o operacijah iz proizvodno informacijskega sistema MES (kot so podatki o začetku in koncu aktivnosti na posamezni proizvodni napravi) ter profile porabe energije delovnih postaj, ki se tipično spremljajo v okviru energetskega informacijskega sistema.

Profili porabe za posamezno proizvodno fazo se nato z upoštevanjem proizvodnih dogodkov segmentirajo na: (i) operativne profile porabe ("production operation mode") in (ii) nominalne čakalne profile porabe ("stand-by mode").

Operativni profil porabe ene proizvodne operacije okarakteriziramo s časovnim povprečenjem večih reprezentativnih ponovitev operativnih profilov porabe. Pred povprečenjem profilov porabe pa je potrebno poskrbeti za ustrezno časovno uskladitev (poravnavo) signalov. V ta namen lahko uporabimo metodo DTW (ang. Dynamic Time Warping, [3]) ali pa pristope ERAL (ang. Error In Alignment, [3]). Za namene poravnave primerljivih časovnih profilov je bolj primerna slednja metoda, ki je tudi bila uporabljena v razvitih algoritmihih.

Pristop metode ERAL je zasnovana tako, da ustvari centroid za skupino časovnih vrst. Metoda se začne z začetnim kandidatom za centroid, ki je opisan z več ponovitvami za izdelavo končnega centra. V vsaki iteraciji je kandidat za centroid usklajen s skupino vhodnih časovnih vrst, čemur sledi izračun uteženega povprečja. Primer neporavnanih časovnih profilov porabe in izračun povprečenja na podlagi poravnanih časovnih profilov je

prikazan na Slika 1. Na takšen način dobimo prototip porabe proizvodne operacije, ki opisuje povprečni profil porabe in oceno standardnega odklona porabe opazovanega nabora meritev.



Slika 2: Primer razvoja prototipa porabe proizvodnje z uporabo metode ERAL

Porabo v nominalnih čakalnih stanjih proizvodnega procesa modeliramo kot konstantno preko celotnega obdobja. Takšen pristop je dovolj natančen, saj v večini primerov bistvenih sprememb porabe ni pričakovati.

2.2 Modeliranje zaporedja proizvodnih operacij

Ko imamo razvite prototipe porabe proizvodnih operacij, lahko delovni tok in sosledje operacij opišemo s pomočjo diskretno-dogodkovnega modela (model DES, ang. Discrete Event Simulation Model), ki omogoča simulacijo prehajanja med različnimi fazami procesa. Za razvoj modela DES lahko uporabimo različne pristope, kot so na primer Petrijeve mreže ali Markovi procesi.

Za razvoj DES modelov je potrebno pridobiti podatke o trajanju posameznih operacij in njihovih oznakah. Na podlagi tako pridobljenih podatkov se nato identificirajo dovoljeni prehodi med posameznimi operacijami in časovni parametri prehodov (časi čakanja in časi obratovanja operacij).

Za namene razvoja diskretno dogodkovnega modela za napovedovanje porabe ponovljivih proizvodnih procesov smo izbrali stohastične Petrijeve mreže, ki omogočajo opis prehodov stanj med operacijami ter časi tipičnih prehodov med operacijami.

Pripravljen model DES povezuje prototipe proizvodnih porab posameznih operacij in omogoča, da za poljuben proizvodni plan ovrednotimo oceno celotne porabe proizvodnje vseh operacij.

3 Algoritmi za napovedovanje porabe zveznih procesov

Zvezni proizvodni procesi tipično ne izkazujejo velike ponovljivosti proizvodnega obratovanja, zato ni mogoče na tipično porabo sklepati na podlagi statističnega povprečenja večih zgodovinskih potekov. Mogoče pa je iz podatkov razbrati vplivne parametre in na takšen način razviti surogatni model porabe proizvodnega procesa, ki vključuje najmočnejše vplive procesnih variacij, ki vplivajo na njegovo električno porabo.

3.1 Pridobivanje in priprava podatkov

Za učinkovito napovedovanje porabe energije v zveznih proizvodnih procesih je ključno zagotoviti kakovostne, celovite in časovno usklajene podatke. V tovrstnih procesih, kjer poteka proizvodnja neprekinjeno, so podatki praviloma na voljo z visoko časovno ločljivostjo, pogosto v obliki časovni vrst, ki jih beležijo raznoliki viri. Uporabljajo se nameščeni senzorji, merilniki, zgodovinski podatki shranjeni v različnih sistemih za vodenje proizvodnje (npr. MES, SCADA), zgodovinski podatki o porabi energije ter zunanji dejavniki, kot so vremenske razmere in cene energije (zunanji viri podatkov). Za razvoj modelov so posebej pomembni podatki o porabi energije, shranjeni v energetskega informacijskega sistemu (EMS, ang. *Energy Management System*) ter podatki o proizvodnih operacijah in obratovalnih razmerah procesa, ki so tipično shranjeni v MES sistemu.

Ker so potrebni podatki shranjeni v različnih bazah in imajo različno frekvenco zajema, jih je potrebno predhodno ustrezno obdelati. Predobdelava podatkov vključuje:

- Usklajevanje frekvenc vzorčenja. Podatki so pogosto zajeti z različno časovno ločljivostjo (npr. energija na 1 min, procesni parametri na 1s). Potrebno jih je uskladiti z agregacijo ali interpolacijo manjkajočih vrednosti.
- Obravnava manjkajočih in okvarjenih podatkov. V zveznih procesih je pomembno hitro zaznati izpade senzorjev, nerealne vrednosti ali sistemske napake. V primeru izpadov uporabimo metode za interpolacijo, odstranjevanje ali označevanje anomalij v primeru motenj ali nepričakovanih dogodkov.
- ter označevanje pomembnih stanj strojev in opreme (npr. mirovanje strojev, prehodi med obratovalnimi režimi, zagoni). Ta obdobja so pogosto netipična z vidika porabe energije in lahko vplivajo na kakovost modelov.

V primeru, da obravnavamo procese z izrazito dinamiko, si lahko pri modeliranju pomagamo z ustvarjanjem zakasnenih regresorjev iz razpoložljivih podatkov. To je še posebej pomembno pri podatkih o porabi energije, kjer je odziv pogosto zakasnen glede na vhodne veličine. Poleg zakasnitev je smiselno razmisliti tudi o uporabi izpeljanih parametrov, kot so npr. odvod ali integral hitrosti, če je ta podatek na voljo.

3.2 Identifikacija vplivov na profil porabe proizvodnje

Ko imamo vse podatke pripravljene v enotni obliki in shranjene v skupni bazi, se lotimo analize korelacij med posameznimi parametri ter študije njihovega vpliva na porabo energije. Ustrezno morajo biti vključeni vsi ključni vplivi na variabilnost porabe, pri tem pa je ključnega pomena dobro poznavanje samega procesa. Pri znanih fizikalnih zakonitostih uporabimo deterministične modele, ki temeljijo na prvih načelih.

V primeru zveznih procesov moramo upoštevati lastnosti kot so zakasnitve, visoka koreliranost med signali in dinamične povratne zanke. Pri takih sistemih pogosto prihaja do močnih soodvisnosti med značilkami, pri čemer lahko nekatere značilke vplivajo na porabo šele z določeno zakasnitvijo. Zato so pri analizi vplivov pogosto smiselne tudi metode, ki vključujejo časovna okna ali uporabo zakasnenih regresorjev.

V primeru, da razpolagamo z velikim številom značilk, je običajno nujno, za doseg boljšega napovednega modela, izvesti postopek selekcije. Na ta način ohranimo le tiste značilke, ki najbolj vplivajo na izhodno vrednost [3]. Postopka filtriranja se lahko lotimo z različnimi metodami, ki jih med sabo lahko tudi kombiniramo.

Korelacijska analiza - omogoča hitro prepoznavanje redundantnih spremenljivk [4]. Za vse neodvisne spremenljivke izračunamo Pearsonove korelacijske koeficiente in jih prikažemo v simetrični korelacijski matriki, kjer vsak element predstavlja korelacijo med dvema spremenljivkama. Identificiramo močno korelirane značilke in jih odstranimo, saj ne prinašajo dodatnih informacij in lahko povzročijo težave zaradi kolinearnosti.

Izračun skupne informacije (MI - mutual information) - s to metodo lahko preverimo ali obstajajo nelinearne povezave in ocenimo informacijsko vrednost izbranih značilk. Ta analiza nam pove, v kolikšni meri posamezna značilka vpliva na ciljno spremenljivko. Ker je analiza MI računsko zahtevnejša, jo je smiselno izvesti šele po korelacijski analizi.

Parcialna korelacija - meri korelacijo med dvema spremenljivkama ob upoštevanju vpliva vseh ostalih značilk. Na ta način lahko ugotavljamo povezanost dveh značilk tudi po tem, ko odstranimo vpliv drugih značilk. Za filtriranje na osnovi te metode uporabljamo dva kriterija: absolutno korelacijo in p-vrednost. Absolutna korelacija nam pove, ali ima značilka zadostno linearno povezavo s ciljno spremenljivko, medtem ko p-vrednost določa, ali je ta povezava statistično značilna. Značilke ohranimo le, če sta izpolnjena oba pogoja.

PCA (glavna komponentna analiza) – metoda za zmanjševanje dimenzionalnosti, ki lahko pomaga pri obvladovanju visoko koreliranih vhodnih značilk. Čeprav PCA ne ohranja interpretabilnosti posameznih vhodnih parametrov, lahko omogoča učinkovitejše učenje modelov in vizualizacijo dominantnih smeri variabilnosti.

LASSO regresija – pri gradnji napovednih modelov lahko uporabimo tudi metodo LASSO (Least Absolute Shrinkage and Selection Operator), ki poleg prilagajanja modela samodejno izvaja selekcijo značilk. Manj pomembnim značilkam priredi ničelne uteži in jih s tem izključi iz modela.

3.3 Identifikacija napovednih modelov

Z metodami strojnega učenja poiščemo vzorce v zgodovinskih podatkih in razvijemo modele za napovedovanje porabe energije v zveznih proizvodnih procesih. Ti procesi potekajo neprekinjeno, zato zanje velja visoka frekvenca meritev in časovno povezan potek podatkov. To zahteva uporabo metod, ki znajo učinkovito obravnavati časovna zaporedja, odvisnosti med spremenljivkami ter morebitne nelinearnosti v obnašanju sistema.

Za enostavnejše primere, kjer ostajajo odvisnosti med spremenljivkami približno linearne, uporabimo osnovne modele, kot je linearna regresija. V primerih, ko podatki kažejo nelinearno obnašanje ali kompleksne interakcije med parametri, pa uporabimo naprednejše pristope, kot so nevronske mreže ali Gaussovi procesi.

Preden se lotimo učenja modela podatke standardiziramo. Vsaki značilki odvzamemo povprečje in jo delimo s standardno deviacijo. S tem zagotovimo enakovredno obravnavo vseh spremenljivk, kar je posebej pomembno pri metodah, občutljivih na velikost vhodnih vrednosti.

Podatke nato razdelimo na učno in testno množico, s čimer omogočimo neodvisno oceno napovedne uspešnosti modela. Po potrebi uporabimo tudi validacijsko množico ali navzkrižno validacijo.

Na voljo imamo več metod podatkovnega modeliranja, ki jih uporabimo za napovedovanje porabe energije v zveznih procesih:

- **Linearna regresija** je uporabna pri procesih, kjer je odvisnost med vhodnimi parametri in porabo energije približno linearna. Njena prednost je enostavna interpretacija rezultatov in nizka računska zahtevnost, vendar ne zajame kompleksnejših dinamik, ki so pogosto prisotne v zveznih procesih.
- **Nevronske mreže** so primerne za modeliranje nelinearnih, večdimenzionalnih relacij v podatkih, kar je značilno za zvezne proizvodne procese z velikim številom vplivnih dejavnikov. Dobro zajamejo zapletene vzorce, a zahtevajo večjo količino podatkov in računske moči. Njihova interpretabilnost je praviloma slabša.
- **Gaussovi procesi** predstavljajo zmogljivo metodo za modeliranje nelinearnih relacij, ki poleg napovedi omogoča tudi oceno negotovosti. To je posebej koristno v industrijskih okoljih, kjer je pomembna tudi ocena zaupanja v napoved. Zaradi kvadratne računske kompleksnosti so primerni predvsem za manjše podatkovne nize ali pa za uporabo aproksimativnih tehnik.
- **Regresijska drevesa** so primerna za modeliranje porabe energije, kadar so odvisnosti med vhodnimi parametri in porabo kompleksne, a segmentirane v diskretne "režime" delovanja. Zaradi hierarhične razdelitve podatkov so uporabna za identifikacijo pragovnih vrednosti (npr. temperatura, pri kateri poraba skokovito naraste) in interakcij med dejavniki.

Pridobljene modele moramo na koncu še ovrednotiti. Za kvantitativno oceno uspešnosti napovedi največkrat uporabljamo naslednje metrike:

- **MAE (Mean Absolute Error)** – povprečna absolutna napaka; ni občutljiva na izstopajoče vrednosti, enostavna za interpretacijo.
- **MSE (Mean Squared Error)** – kvadratna napaka; bolj kaznuje večje napake, zato je občutljiva na ekstreme.
- **Koeficient R^2** – razlaga, kolikšen delež variance v ciljni spremenljivki pojasni model.

Za preverjanje robustnosti in generalizacijske sposobnosti modela lahko uporabimo k -kratno navzkrižno validacijo (*k-fold cross-validation*), ki zmanjša vpliv naključne delitve podatkov. Podatke razdelimo na več enakovrednih delov in model treniramo večkrat, vsakič z drugo kombinacijo učne in testne množice. Končna ocena je povprečje napovednih metrik čez vse ponovitve.

Bibliografija

- [1] Berndt, D.J., Clifford, J.: Using dynamic time warping to find patterns in time series. In: Proceedings of the 3rd International Conference on Knowledge Discovery and Data Mining. AAAIWS'94, pp. 359–370. AAAI Press, 1994.
- [2] Ž. Stržinar, B. Pregelj, I. Škrjanc: Non-elastic time series fuzzy clustering for efficient analysis of industrial data sets. *Applied Soft Computing* 167, 112398 (2024)
- [3] M. Glavan, D. Gradišar, M. Atanasijević-Kunc, S. Strmčnik, G. Mušič. Input variable selection for model-based production control and optimisation. *International journal of advanced manufacturing technology*. 2013, vol. 68, no. 9/12, str. 2743-2759. DOI: [10.1007/s00170-013-4840-1](https://doi.org/10.1007/s00170-013-4840-1).
- [4] James, G., Witten, D., Hastie, T., Tibshirani, R. *An Introduction to Statistical Learning*. Springer, 2023. <https://doi.org/10.1007/978-3-031-38747-0>.
- [5] D. Gradišar, M. Glavan, G. Kmet. Rezultat D8.1: Izvedba in testiranje napovedovanja porabe energije, DIGITOP, 2025.
- [6] D. Gradišar, M. Glavan, G. Kmet, Napovedovanje enegetske porabe proizvodnih procesov s pomočjo podatkovne analitike, Konferenca AIG, 2025.