

Паметна аналитика и анализа потрошње електричне енергије

Smart Analytics and Analysis of Electrical Energy Consumption

Марија Остовић, Факултет техничких наука, Нови Сад

Студијски програм – ПРИМЕЊЕНО
СОФТВЕРСКО ИНЖЕЊЕРСТВО

Кратак садржај – Рад истражује како се савремене аналитичке методе могу искористити за праћење временских серија у енергетици. У истраживању су коришћени реални подаци, као и контролисани синтетички скуп у који су намерно убачене грешке ради тестирања алгоритама. Линеарна регресија је примењена за предвиђање потрошње у време највећег дневног ипица у 14 часова, док је autoencoder неуронска мрежа искоришћена за откривање дана који одступају од уобичајених профила. Граница постављена на 95. перцентил грешке реконструкције успешно је издвојила дане са највећим променама, а РСА визуелизација је графички потврдила јасно раздвајање нормалног понашања од аномалија. Повезивање ова два приступа показало се ефикасним за брзо препознавање необичних образаца, што поставља добру основу за боље разумевање података и паметније управљање ресурсима у мрежи.

Кључне речи: паметна аналитика, потрошња електричне енергије, линеарна регресија, autoencoder

Abstract – The paper explores how modern analytical methods can be used to monitor time-series data in the energy sector. The research utilizes real-world datasets alongside a controlled synthetic dataset with intentionally injected errors to test the algorithms. Linear regression is applied to forecast consumption during the peak hour at 2 PM, while an autoencoder neural network is used to detect days that deviate from typical profiles. A threshold set at the 95th percentile of the reconstruction error successfully isolated the days with the most significant shifts, and PCA visualization graphically confirmed a clear separation between normal behavior and anomalies. Combining these two approaches proved effective for rapid recognition of unusual patterns, providing a solid foundation for a better understanding of data and smarter resource management within the grid.

Keywords: smart analytics, electricity consumption, linear regression, autoencoder

НАПОМЕНА: Овај рад проистекао је из мастер рада чији ментор је био проф. др Срђан Вукмировић.

1. УВОД

Савремени електроенергетски системи се под утицајем масовне дигитализације и ширења концепта паметних мрежа (*Smart Grid*) трансформишу у комплексна дигитална окружења. Интеграција паметних бројила и *IoT* сензора омогућила је континуирано прикупљање података о потрошњи електричне енергије у реалном времену. Ови подаци више не представљају само суву историјску метрику, већ динамичан запис корисничких навика, мрежних оптерећења и сигурносних индикатора комплетне инфраструктуре [1], [2].

Изазов у управљању оваквим ресурсима лежи у самој природи података – потрошња струје је временска серија подложна снажним сезонским, месечним и сатним флукуацијама. Да би се ове комплексне законитости и ритмови разумели, визуелизација служи као први, есенцијални корак који апстрактне вредности претвара у препознатљиве обрасце и открива како систем „дише“ током године [3]. Међутим, да бисмо доносили боље одлуке и реаговали пре него што дође до преоптерећења, морамо искористити савремене алате за аутоматску обраду података.

Овај рад се фокусира на практичну примену паметне аналитике кроз два приступа. Први део истраживања посвећен је предвиђању вршног оптерећења, где смо помоћу линеарне регресије покушали да предвидимо потрошњу у најкритичнијем делу дана – у 14 часова. Други део рада бави се сигурношћу система кроз имплементацију autoencoder неуронске мреже, која нам помаже да аутоматски откријемо необичне промене у потрошњи које могу указивати на проблем. Повезивање ова два приступа пружа поуздан оквир за паметније управљање енергетским системима.

2. ПАМЕТНА АНАЛИТИКА У ЕНЕРГЕТСКИМ СИСТЕМИМА

Прелазак са традиционалне електроенергетске мреже на паметну мрежу (*Smart Grid*) заснива се на увођењу нових начина за праћење и обраду података. Главна разлика је у томе што паметна мрежа омогућава двосмерну комуникацију између самог система и потрошача. Преко паметних бројила и сензора, подаци о потрошњи струје пристижу непрекидно. Ова велика количина информација стиже огромном брзином из различитих извора, што ствара потпуно

нове захтеве за анализу у односу на некадашње ручно бележење потрошње [1], [2].


Да би се сви ови прикупљени бројеви практично искористили, паметна аналитика служи као веза између сирових мерења и доношења конкретних одлука. Први корак је припрема података, чиме се издваја користан сигнал, а уклањају грешке у мерењима које могу настати у преносу. Пошто рад са милионима записа захтева велику рачунарску снагу, данас је *Cloud computing* постао незаобилазна технологија у овом процесу. Он омогућава да се велика количина података сигурно чува и обрађује на удаљеним серверима у облаку, без потребе за куповином прескупе локалне опреме [5], [6].

Овакав приступ мења начин рада – анализу потрошње померамо са обичног посматрања прошлости на предвиђање и брзо проналажење неправилности у систему. Када рачунар препозна како се потрошња мења током годишњих доба, како на њу утиче промена температуре или када се јављају највећи дневни шпигеви, добијамо вредне информације. То је основа за развој енергетски ефикасних паметних зграда и градова, где се енергијом управља паметније и економичније.

3. ПРАКТИЧНА АНАЛИЗА И ВИЗУЕЛИЗАЦИЈА ВРЕМЕНСКИХ СЕРИЈА

Након почетног учитавања реалног скупа података помоћу библиотеке *Pandas*, извршено је спајање датумских и сатних уноса у континуирану временску серију. Припрема је обухватила идентификацију и уклањање некоректних уноса, чиме је обезбеђена висока поузданост каснијих резултата. На основу очишћених података извршено је груписање и статистичко сумирање на три временска нивоа: сатном, дневном и месечном.

Праћење потрошње на дневном нивоу омогућава уочавање прелаза између краткорочних флукуација унутар једног дана и дугорочних сезонских трендова. Иако се у раду детаљно посматрају и преостала два временска нивоа, њихови резултати су усклађени са општом динамиком. Анализа на сатном нивоу открива унутрашњи дневни ритам са израженим минимумом током касних ноћних часова и критичним шпигевима оптерећења у вечерњем периоду, када је активност у домаћинству највећа. Са друге стране, месечни ниво агрегације јасно дефинише макроекономске и климатске циклусе на нивоу године, разграничавајући прелазне периоде од екстремних зимских месеци [3].




Слика 1. Дневна потрошња електричне енергије

За потребе овог рада, као најсвеобухватнији пресек који успешно повезује краткорочне промене и дугорочне циклусе, одабран је приказ на дневном нивоу. На Слици 1 приказана је просечна дневна потрошња електричне енергије кроз посматрани вишегодишњи период.

Визуелизација јасно открива да енергетски систем има цикличну динамику која прати промену годишњих доба. Најнижи нивои активности бележе се средином године, током летњих месеци, док се нагли пораст оптерећења и изражени скокови јављају крајем и почетком године. Овакав тренд директно одсликава промену животних навика корисника услед хладног времена, када долази до интензивније употребе грејних тела и расвете.

Поред чисто временске анализе, за боље разумевање структуре оптерећења извршена је разградња укупне снаге на специфичне категорије потрошача унутар објекта. Овај приступ омогућава да се идентификује који уређаји имају највећи појединачни утицај на систем. На Слици 2 приказана је просечна потрошња електричне енергије по групама уређаја унутар домаћинства кроз три издвојена подбројила.



Слика 2. Потрошња електричне енергије по групама уређаја

Анализа профила са Сlike 2 показује неједнаку дистрибуцију потрошње унутар објекта. Прва група уређаја, која обухвата кухињске апарате, карактерише се повременим и краткотрајним вршним оптерећењима. Друга група, везана за термотехничке системе, показује оштру зависност од сезонских услова. Насупрот њима, трећа група, која покрива расвету и кућну електронику, генерише континуиран и стабилан базни ниво потрошње током целе године. Лоцирањем највећих појединачних потрошача на овај начин ствара се основа за доношење циљаних мера енергетске ефикасности и оптимизацију рада мреже.

4. ПРИМЕНА АНАЛИТИЧКИХ МОДЕЛА И ДИСКУСИЈА РЕЗУЛТАТА

Након припреме података, потрошњу смо анализирали кроз два различита модела: предвиђање потрошње у шпицу помоћу линеарне регресије и откривање грешака и необичних дана помоћу аутоенкодера.

4.1. Линеарна регресија за предвиђање потрошње у шпицу

Линеарна регресија је искоришћена као једноставан модел где је циљ био да предвидимо укупну активну

снагу (*Global_active_power*) у критичном дневног шпицу у 14 часова, користећи сате (*Hour*) као главни параметар из библиотеке *scikit-learn*. Модел повезује доба дана и потрошњу струје, чиме нам показује општи смер кретања потрошње током тог времена. Да бисмо проверили колико је модел тачан, израчунали смо стандардне статистичке грешке: средња апсолутна грешка износи $MAE = 0.831$, средња квадратна грешка је $MSE = 1.234$, док је корен средње квадратне грешке $RMSE = 1.111$. Ови бројеви нам показују да модел успешно прати основни дневни ритам потрошње. Са друге стране, стварни подаци у неким данима доста скачу, због чега долази до одступања од регресионе линије. То се дешава зато што овај модел користи само један улазни податак (сате), док у стварном животу потрошња зависи од много других ствари, као што су температура, рутинске навике или број укључених уређаја. Ипак, линеарна регресија је супер јер се резултати брзо добијају и лако тумаче, па нам служи као одлична основа за поређење са сложенијим алгоритмима.

4.2. Архитектура и тренинг аутоенкодера за детекцију аномалија


За проналажење скривених проблема и чудних промена у потрошњи, искористили смо аутоенкодер – врсту неуронске мреже која сама учи шта је нормално понашање [5]. Модел смо тестирали на синтетичким подацима који верно приказују уобичајен дан у домаћинству (растућу потрошњу ујутру, стабилан дан и велики скок увече), али смо у њих намерно убацили аномалије попут наглих скокова или падова снаге [4]. Сваки податак који убацимо у мрежу представља један цео дан са 24 сатне вредности.

Осмислили смо потпуно симетричну мрежу са распоредом слојева 24–12–3–12–24. Први слој прихвата 24 сатне вредности, затим средњи слој са 12 неурона смањује податке, док се у самом центру налази латентни простор од само 3 неурона који чува најважнију, сажету слику целог дана. Након тога, други део мреже (декодер) ради супротно – шири податке преко 12 неурона назад до излазних 24, покушавајући да поново нацрта оригинални дан.

У скривеним слојевима користили смо *ReLU* активациону функцију која помаже мрежи да боље учи, а током тренинга смо пратили средњу квадратну грешку (*MSE*). Кроз више понављања, мрежа је научила да обичне дане нацрта скоро савршено, док код чудних и аномалних дана прави велику грешку у реконструкцији, што нам је главни знак да нешто није у реду [5].


4.3. Грешка реконструкције и PCA визуелизација

Разлика између оригиналног дана и оног који је мрежа покушала да нацрта зове се грешка реконструкције (*reconstruction error*). Да бисмо аутоматски препознали необичне дане, границу смо поставили на 95. перцентил укупне грешке. То значи да смо издвојили 5% дана који имају највеће математичко одступање од нормале [4]. Све вредности ове грешке заједно са постављеном границом приказане су на Слици 3.



Слика 3. Reconstruction error и праг за детекцију аномалија

Да бисмо проверили како мрежа „размишља“, искористили смо *PCA* методу која податке из латентног простора претвара у обичан дводимензионални график [3]. Тај просторни приказ дана можете видети на Слици 4.



Слика 4. PCA визуелизација латентног простора

Положај тачака на Слици 4 јасно показује колико је овај модел паметан: нормални дани се држе заједно и праве велику густу групу у средини, док су аномални дани разбацани далеко изван те групе као изоловане тачке.

Ипак, модел има неколико ограничења. Мрежа нам јавља да дан одступа од нормале, али не може сама да нам каже зашто се то десило (да ли је у питању квар, преоптерећење мреже или је неко само укључио више уређаја одједном). Такође, ако се неки дан дешава ретко, а потпуно је исправан, мрежа га може лажно означити као грешку ако га пре тога није видела током тренинга. Упркос томе, ова комбинација рачунања грешке и графичког приказа је одличан систем за брзо откривање чудног понашања мреже у реалном времену.

5. ЗАКЉУЧАК

Праћење потрошње електричне енергије данас има много већи значај од простог записивања бројева са бројила. Овај рад је показао да кроз паметну анализу података можемо сазнати много тога о навикама корисника, оптерећењу мреже и потенцијалним проблемима. На тај начин добијамо корисне информације које нам помажу да боље и сигурније управљамо енергијом.

У раду смо успешно повезали неколико различитих корака. Прво смо кроз графиконе уочили како се потрошња мења кроз годишња доба и који уређаји у кући троше највише струје. Затим смо користили

линеарну регресију као једноставан алат који нам је брзо дао процену потрошње у вријеме највећег дневног шпица у 14 часова. На крају, главни део рада посвећен је моделу аутоенкодера који је сам научио како изгледа један нормалан дан, па је успјешно пронашао и издвојио оне дане у којима се потрошња понашала чудно и нетипично, што смо и графички потврдили.

Суштина ових резултата је у томе што нам овакви модели омогућавају да пређемо са пасивног посматрања на брзо деловање. То значи да кризне ситуације, кварове или преоптерећења мреже можемо препознати и ријешити на вријеме, прије него што настане стварна штета. Овај приступ поставља добру основу за развој паметних зграда и градова, а у будућности систем вреди проширити и додатним подацима, као што је спољашња температура.

6. ЛИТЕРАТУРА

- [1] C. W. Gellings, The Smart Grid: Enabling Energy Efficiency and Demand Response. Lilburn, GA, USA: Fairmont Press, 2009.
- [2] M. Amin and B. F. Wollenberg, "Toward a Smart Grid: Power Delivery for the 21st Century," IEEE Power and Energy Magazine, vol. 3, no. 5, pp. 34–41, Sep.–Oct. 2005.
- [3] J. Han, M. Kamber, and J. Pei, Data Mining: Concepts and Techniques, 3rd ed. Waltham, MA, USA: Morgan Kaufmann, 2012.
- [4] V. Chandola, A. Banerjee, and V. Kumar, "Anomaly Detection: A Survey," ACM Computing Surveys, vol. 41, no. 3, Article 15, pp. 1–58, 2009.
- [5] I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. Cambridge, MA, USA: MIT Press, 2016.
- [6] Kaggle, "Individual Household Electric Power Consumption Dataset." Accessed: 2026. [Online]. Available: <https://www.kaggle.com/datasets/uciml/electric-power-consumption-data-set>

Кратка биографија:

Марија Остовић рођена је у Фочи 2001. год. Мастер рад на Факултету техничких наука из области Електротехнике и рачунарства – Примењено софтверско инжењерство одбранила је 2026.год.

Контакт:

marijaostovic31@gmail.com