

ДЕКОМПОЗИЦИЈА ДНЕВНОГ ДИЈАГРАМА ПОТРОШЊЕ ЗА ПОТРЕБЕ УПРАВЉАЊА ПОТРОШЊОМ

А. ЈЕВТИЋ, Електротехнички факултет Београд СР Србија

Ж. ЈЕВТИЋ, ЕПС Дистрибуција Београд СР Србија

Б. НИЈЕМЧЕВИЋ, ЕПС Дистрибуција Београд СР Србија

1. УВОД

Управљање потрошњом електричне снаге представља важан део реализације интелигентних електроенергетских мрежа. Главне погодности које доноси управљање потрошњом су лакша интеграција обновљивих извора енергије, смањење вршних оптерећења, смањење губитака електричне енергије, повећање фактора искоришћења електроенергетских капацитета, смањење трошкова експлоатације система, боље очување животне средине, рационалисање изградње додатних капацитета у електроенергетској мрежи.

Са аспекта управљања потрошњом електричне снаге од великог је значаја сазнање о процентуалном учешћу појединих категорија потрошача, електричних уређаја, у потрошњи одређеног електродистрибутивног конзума. Декомпозиција дневног дијаграма потрошње електродистрибутивног конзума обезбеђује информацију о степену заступљености појединих категорија потрошача електричне енергије и о потенцијалу за управљање потрошњом у одређеном електродистрибутивном конзуму.

Декомпозиција потрошње реализује се најчешће вођењем евиденције о потрошњи енергије појединачних електричних уређаја или снимањем дијаграма потрошње, високе резолуције, који карактерише одређен категорија потрошача (таласни облик струје, динамички одзив потрошње на промену напона, тренутна и стварна промена снаге).

С обзиром да су наведени приступи у пракси компликовани, неефикасни и скупи за широку употребу за декомпозицију потрошње нови приступ за декомпозицију потрошње је коришћење методе вештачке неуралне мреже.

Коришћење се заснива на ставу да је метода вештачке неуралне мреже показала добре резултате код задатака који укључују сетове података који нису комплетни или укључују нејасне или непотпуне информације као и да се добро показала код изузетно комплексних и лоше дефинисаних проблема, где се човек углавном ослања на инстинкт и искуство.

2. ДЕФИНИЦИЈА НЕУРАЛНЕ МРЕЖЕ

Неурална мрежа је масовно паралелизован дистрибуирани прецесор са способношћу меморисања искуственог знања и обезбеђивања његовог коришћења. Она наликује људском мозгу из два разлога:


- знање се стиче кроз процес учења,
- складиштење стеченог знања се врши помоћу синаптичких структура.

Неуралне мреже не захтевају детаљне информације о систему. Уместо тога, оне уче о везама између параметара који се уносе и контролисаних и неконтролисаних варијабли на основу претходно унетих или снимљених примера и података. Предност неуралних мрежа је што могу да раде са великим и комплексним системима код којих постоји много међусобно повезаних параметара. Оне игноришу непотребне информације и фокусирају се само на улазне податке од интереса. Основну рачунарску снагу неуралних мрежа чини масивни паралелизам и способност учења и генерализација. Генерализација представља способност испоручивања задовољавајућег излаза неуралне мреже и за улазе који нису били присутни у току процеса учења.

3. МОДЕЛ ВЕШТАЧКОГ НЕУРОНА

Вештачки неурон се састоји од три основна дела:

1. Скуп синаптичких тежинских коефицијената $\{w_{kj}\}$. Синаптички тежински коефицијент има позитивну вредност уколико одговара ексцитирајућој, побудној, синаптичкој вези а негативну вредност ако одговара инхибиторској, онемогућавајућој, вези;
2. Суматор – служи да формира тежинску суму улаза.
3. Активациона функција – служи да лимитира амплитуду излазног сигнала неурона. Излаз се најчешће нормализује на интервал $[-1,1]$ или $[0,1]$.



Слика 1: Нелинеарни модел вештачког неурона

На слици 1 приказан је неурон са више улаза x_1, x_2, \dots, x_m и једним излазом y_k .


Поред објашњених величина на слици је присутан и праг θ_k . Праг дефинише граничну вредност суме улазних параметара (информација) која доводи до активације неурона. Уколико је сума тежинских улазних параметара већа од прага, долази до активације неурона и преноса излазног параметара за активирано стање неурона. Уколико је сума мања, долази до преноса излазног параметра за неактивирано стање неурона.

Једначине које описују модел са слике 1 су:

$$\begin{aligned} u_k &= \sum_{j=1}^m w_{kj} \cdot x_j \\ y_k &= a(u_k - \theta_k) \end{aligned} \quad (1)$$

4. ВИШЕСЛОЈНЕ НЕУРАЛНЕ МРЕЖЕ СА ПРОСТИРАЊЕМ СИГНАЛА УНАПРЕД (FEEDFORWARD MULTILAYER NEURAL NETWORK)

За потребе овог рада коришћена је вишеслојна неурална мрежа са простирањем сигнала унапред.



Слика 2. Вишеслојна неурална мрежа са простирањем сигнала унапред

Вишеслојна неурална мрежа састоји се од улазног, скривеног и излазног слоја.

Скривени слој може да садржи више слојева.

У вишеслојној неуралној мрежи постоји неколико слојева неурона у виду усмереног графа, а сваки слој је у потпуности повезан са наредним.

У овој структури слојева сваки неурон је повезан са неуронима претходног слоја помоћу прилагодљивих синаптичких тежина.

Изразни чвор једног слоја је улазни чвор наредног слоја.

За складиштење знања користе се синаптички тежински коефицијенти.

Процес учења представља процес модификовања синаптичких тежинских коефицијената коришћењем неког од одговарајућих метода третирања.

Ове мреже су feedforward типа што значи да се сигнал простире унапред и да нема враћања излазних података на улаз мреже (нема повратне петље).

5. МОДЕЛ ПОТРОШЊЕ

Појам "модел потрошње" подразумева аналитичку, односно математичку представу потрошње, која верно описује промене активне и реактивне снаге моделоване потрошње у зависности од неког параметра система (нпр. модула напона или фреквенције).

У овом раду примењен је експоненцијални модел потрошње који описује зависност активне и реактивне снаге од модула напона и фреквенције. Модел је дефинисан следећим изразом:

$$P = P_0 \cdot \left(\frac{U}{U_0}\right)^{k_{pu}} \cdot \left(\frac{f}{f_0}\right)^{k_{pf}} \quad (2)$$
$$Q = Q_0 \cdot \left(\frac{U}{U_0}\right)^{k_{qu}} \cdot \left(\frac{f}{f_0}\right)^{k_{qf}}$$

где су k_{pu} и k_{qu} напонски експоненти а k_{pf} и k_{qf} фреквентни експоненти.

Генерално, током стационарног рада електроенергетског система напон може варирати у опсегу $\pm 10\%$ а фреквенција у опсегу $\pm 0,4\%$. У овом раду занемарена је зависност потрошње од фреквенције у експоненцијалном моделу тако да израз (3) постаје:

$$P = P_0 \cdot \left(\frac{U}{U_0}\right)^\alpha \quad (3)$$
$$Q = Q_0 \cdot \left(\frac{U}{U_0}\right)^\beta$$

где се експоненти $\alpha = k_{pu}$ и $\beta = k_{qu}$ мењају у зависности од категорије потрошње електричног уређаја.

У овом раду третира се статички модели потрошње с обзиром да се методологија декомпозиције потрошње спроводи са подацима о вредностима активне и реактивне снаге и модула напона у стационарном стању.

Укупна или агрегисана потрошња у неком сату P_{Agg} представља се као тежинска сума појединачних потрошњи различитих категорија потрошача P_i :

$$P_{Agg,t} = \sum_{i=1}^N w_{i,t} P_{i,t} \quad (4)$$

У једначини (5) сатни тежински фактори $w_{i,t}$ представљају процентуални удео снаге одређене категорије потрошача $P_{i,t}$ у укупној снази $P_{Agg,t}$ током сатног периода- t у дану. Одређивање сатних тежинских фактора $w_{i,t}$ у укупној потрошњи је главни циљ примене методе вештачких неуралних мрежа за декомпозицију потрошње.

N представља број различитих категорија потрошње, потрошача.

6. МЕТОДОЛОГИЈА И ОБРАДА ПОДАТАКА

Улази у неуралну мрежу су подаци о:

- годишњој сезони када се остварује потрошња,
- сатном периоду дана када се остварује потрошња,
- амбијенталној температури када се остварује потрошња,
- модулу напона при коме се остварује потрошња,
- агрегисаној активној снази потрошње и
- агрегисаној реактивној снази потрошње.

Излаз из неуралне мреже је податак о сатном тежинском фактору једне од категорија потрошње, потрошача.

Подаци који се генеришу за обучавање и валидацију неуралне мреже су вредности напона, амбијенталних температура и сатних тежинских фактора за сваки сат у дану у одређеној годишњој сезони.

Методологија декомпозиције потрошње применом методе вештачке неуралне мреже спроводи се у следећим корацима:

A. Дефинисање релевантних категорија потрошача и њихових статичких коефицијента напонске зависности

B. Категорије потрошње, потрошача, које су разматране у овом раду су:

1. Осветљење: инкадесцентно (70%) и флуоресцентно (30%);
2. Резистивни уређаји (акумулациони бојлери, шпорети, ТА пећи, ...);
3. Фрижидери;
4. Монофазни клима уређаји;
5. Електронски уређаји;
6. Такозвани "wet load" уређаји: машине за прање посуђа (30%) и машине за прање веша (70%).

Статички напонски коефицијенти различитих категорија потрошача дати су у табели број 1.

Категорије потрошача		α	β
1. Осветљење	инкадесцентно	1,55	0
	флуоресцентно	0,96	7,4
2. Резистивни уређаји		2	0
3. Фрижидери		0,77	2,5
4. Монофазни клима уређаји		0,202	2,3
5. Електронски уређаји		2	5,1
6. „wet load”	машине за посуђе	1,8	3,6

машине за веш	0,08	1,6
---------------	------	-----

ТАБЕЛА 1 - СТАТИЧКИ НАПОНСКИ КОЕФИЦИЈЕНТИ РАЗЛИЧИТИХ КАТЕГОРИЈА ПОТРОШАЧА

С. Генерисање произвољних вредности, по сатним периодима у дану- t , амбијенталне температуре- T у зависности од посматране годишње сезоне и напона

Временска променљива t означава сатне вредности у дану: $t = 1 - 24$.

За сваку сатну вредност у дану генерисана је случајна вредност амбијенталне температуре- T из опсега карактеристичног за посматрану годишњу сезону. Температурни сезонски опсеги приказани су у табели број 2.

Сезона	Ознака сезоне	Опсег температуре T
Пролеће и јесен	I	(0)-(+20) °C
Лето	II	(+20)-(+40) °C
Зима - даљинско грејање	III	(-20)-(+10) °C
Зима – грејање на струју	IV	(-20)-(+10) °C

ТАБЕЛА 2 - КАРАКТЕРИСТИЧНИ ОПСЕЗИ СЕЗОНСКИХ ТЕМПЕРАТУРА

Напони- V узорковани су из опсега [0,9 , 1,1] p.j.

D. Генерисање за тренинг могућих комбинација сатних тежинских фактора у функцији сатног периода- t у дану, амбијенталне температуре- T , годишње сезоне- S и категорије потрошача.

E. Одређивање активних и реактивних снага појединачних категорија потрошача за све комбинације напона и сатних тежинских фактора помоћу усвојених модела потрошње са коефицијентима који су одређени у кораку А.

F. Одређивање агрегисане активне и реактивне снаге коришћењем сатних тежинских фактора који су одређени у кораку С.

G. Обучавање неуралне мреже;

H. Генерисање података за валидацију неуралне мреже понављањем корака од А до F ;

I. Тестирање неуралне мреже.

7. РЕАЛИЗАЦИЈА ОБУЧАВАЊА И ТЕСТИРАЊА ОБУЧАВАНЕ НЕУРАЛНЕ МРЕЖЕ

За реализацију обучавања и тестирања обучаване неуралне мреже генерисан је скуп дефинисаних података.

За сваки уређени низ (S, t, T) одређени су сатни тежински фактори поједних категорија потрошача у укупној потрошњи према одређеним правилима која су приказана у табели број 3. На тај начин одређен је за сваку сезону скуп сатних тежинских фактора потрошача $\{w_i\} (i = 1, \dots, 6)$.

Категорија потрошача	Вредности релевантних улаза $t(h)$ или $T (^\circ C)$	Опсег вредности тежинских фактора за различите сезоне (%)		
		I	III	IV
Осветљење	$t=06-17h$	0-10	0-10	0-10
	$t=17-19h$	0-10	20-30	20-30
	$t=19-06h$	20-30	20-30	20-30

Резистивна потрошња		20-50	20-50	/
	$t=00-08h$	/	/	$[45-55]+f(T)$
	$t=08-24h$	/	/	$[35-45]+f(T)$
Фрижидери	$t=00-06h$	30-40	30-40	10-20
	$t=06-24h$	10-20	10-20	10-20
Клима уређаји	$T<30$	0-10	0	0
	$T>30$	0-10	0	0
Електронски уређаји	$t=00-06h$	0-15	0-15	0-15
	$t=06-17h$	5-10	5-10	5-10
	$t=17-24h$	5-20	5-20	5-20
Машине за веш и посуђе	$t=06-22h$	5-10	5-10	5-10
	$t=22-06h$	10-20	10-20	10-20

ТАБЕЛА 3 - ВРЕДНОСТИ САТНИХ ТЕЖИНСКИХ ФАКТОРА ЗА РАЗЛИЧИТЕ КАТЕГОРИЈЕ ПОТРОШАЧА У РАЗЛИЧИТИМ СЕЗОНАМА

За одређени уређени низ (S, t, T) могу се имати прозволне напонске прилике због чега је укупан број података за обучавање мреже

$$n = N_s \cdot N_v \cdot N_w$$

где је:

- N_s број сезона које се разматрају,
- N_v је број напонских узорака,
- $N_w = 24 \cdot n_d$,
- n_d број дана у сезони са карактеристичним сезонским температурама.

За сваки уређени низ (S, t, T, V) одређује се агрегисана активна и реактивна снага категорије потрошача:

$$(S, t, T) \mapsto (w_1, w_2, w_3, w_4, w_5, w_6) \quad (6)$$

$$(V, (w_1, w_2, w_3, w_4, w_5, w_6)) \mapsto (P_{Agg}, Q_{Agg}) \quad (7)$$

Дакле, за обучавање неуралне мреже користи се n различитих улаза $[S_i, t_i, T_i, V_i, P_{Aggi}, Q_{Aggi}]$, $1 \leq i \leq n$, који представљају редове матрице A :

$$A = \begin{bmatrix} P_{Agg1}, P_{Agg2}, \dots, P_{Aggn} \\ Q_{Agg1}, Q_{Agg2}, \dots, Q_{Aggn} \\ V_1, V_2, \dots, V_n \\ t_1, t_2, \dots, t_n \\ T_1, T_2, \dots, T_n \\ [Sezona_1, \dots, Sezona_n] \end{bmatrix}$$

Специфициране вредности сатних тежинских фактора за сваку од комбинација улаза поређане су у колоне матрице B :

$$B = \begin{bmatrix} w_{1,1} & \dots & w_{1,n} \\ \vdots & \dots & \vdots \\ w_{6,1} & \dots & w_{6,n} \end{bmatrix}$$

где је $w_{i,j}$ сатни тежински фактор, односно удео категорије потрошача i , $1 \leq i \leq 6$ за j -ту комбинацију улазних података, $1 \leq j \leq n$.

За потребе овог рада дефинисан је скуп који се састоји од генерисаних података за 9984 часова, односно од 416 дана која су једнако расподељена на 4 сезоне. Дефинисаних 70% узорка скупа коришћено је за тренирање а 30% за тестирање неуралне мреже.

8. ПРОВЕРА КВАЛИТЕТА ОБУЧАВАНЕ НЕУРОНСКЕ МРЕЖЕ

Дефинисани скуп за потребе провере квалитета обучавања неуронске мреже састоји, као и код спровођења обуке и тестирања, од генерисаних података за 9984 часова, односно од 416 дана која су једнако расподељена на 4 сезоне.


Квалитет обучавања неуронске мреже оцењиван је на основу израчунатог апсолутног и релативног одступања излазне вредности сатног тежинског фактора од задатог тежинског фактора за сваки појединачни час скупа.

У табели број 4. приказане су просечне, средње вредности, апсолутне и релативне грешке за 9984 узорака.

Категорија потрошача	Просечна апсолутна грешка процентуалног удела потрошње [%]	Просечна процентуална грешка процентуалног удела потрошње [%]
Осветљење	2.85	7.74
Резистивна потрошња	2.56	6.18
Фрижидери	2.39	10
Монофазни клима уређаји	1.88	3.82
Електронски уређаји	2.38	8.91
Машине за веш и посуђе	1.71	10.8

ТАБЕЛА 4 - ПРОСЕЧНЕ АПСЛУТНЕ И РЕЛАТИВНЕ ГРЕШКЕ

На слици број 3 приказани су хистограми апсолутне грешке за све категорије потрошње.



Слика 3. Хистограми апсолутне грешке: а) Осветљење б) Резистивна потрошња в) Фрижидери г) Монофазни клима уређаји д) Електронски уређаји ђ) Машине за веш и посуђе

9. АНАЛИЗА РЕЗУЛТАТА

Анализа резултата рада модела неуралне мреже показује да модел мреже декомпонује третирану потрошњу у одређеној граници тачности с обзиром на квалитет дефинисаних улазних података.

Показује се да су подаци за сезону, часовни период дана и амбијенталну температуру поуздани подаци за квалитет рада модела неуралне мреже. Модул напона, укупна активна и рекатвина снага нису довољно поуздани показатељи за одређивање учешћа појединих категорија потрошње у укупној потрошњи.

С обзиром да су узорци за одређене категорије потрошње вештачки генерисани са малим бројем правила и да су вредности удела појединих категорија потрошача одређени насумично модел неуралне мреже прави веће грешке, односно није искоришћена адекватно главна предност примене модела неуралних мрежа а то је способност да уочи компликована правила и шаблоне.

На основу резултата израчунатих апсолутних и релативних одступања излазне вредности сатног тежинског фактора од задатог тежинског фактора уочавају се мање грешке модела неуралне мреже код категорија потрошње које карактеришу јаснија правила, мањи опсези из којих се бирају насумична учешћа у потрошњи и већа и разноврснија зависност од улазних параметара.

Да би се превазишли наведени проблеми и постигао потребан ниво поузданости и квалитета модела неуралне мреже потребно је обучавати модел са реалним узорцима снимљеним на електродистрибутивном конзуму или полигону који симулира услове електродистрибутивног конзума.

У том циљу неопходно је дефинисати и устројити систем који би служио за прикупљање и обраду поузданих и репрезентативних података неопходних за обучавање модела неуралне мреже. Основ за базу података представљају прикупљени и обрађени профли мерених и регистрованих величина посредством даљинског или непосредног преузимања података из дигиталних бројила електричне енергије која региструју појединачна оптерећења, индивидуална мерна места, или групно оптерећење, трансформаторске станице.

Поред профила мерених оптерећења и регистрованих електричних величина неопходно је прикупљати и податке о амбијенталним температурама, техничким карактеристикама појединачних категорија потрошача, карактеристикама сезонског и сатног коришћења електричне енергије с обзиром на навике корисника по типовма насеља.

Модел неуралне мреже има способност, уз правилан начин обучавања и са квалитетним и меродавним подацима потрошње, да уочи и предвиди комплексне шаблоне промена оптерећења у дистрибутивном конзуму у циљу реализације задатка да се квалитетно и поуздано спроведе декомпозиција потрошње.

ЛИТЕРАТУРА

1. Yizheng Xu, Jovica V. Milanović, 2015, "Artificial-Intelligence-Based Methodology for Load Disaggregation at Bulk Supply Point", "IEEE TRANSACTIONS ON POWER SYSTEMS", "VOL. 30", "NO. 2"
2. Turan Gönen, 2008, "Electric Power Distribution System Engineering", "CRC Press"
3. James Momoh, 2012, "Smart Grid – Fundamentals of Design and Analysis ", "IEEE Press"
4. Clark W. Gellings, 2009, "The Smart Grid - Enabling Energy Efficiency and Demand Response", "CRC Press"

*Контакт информације аутора:
Андреја Јевтић, дипл.инж.ел.
т.тел.:064 / 566 30 83
е-mail:andrija.jevtic@energomontaza.com*