



ISSN 1311-0829

ГОДИШНИК НА ТЕХНИЧЕСКИ УНИВЕРСИТЕТ-СОФИЯ

Том 62, книга 1, 2012

МЕЖДУНАРОДНА КОНФЕРЕНЦИЯ АВТОМАТИКА'2012, ФА
юбилей "50 ГОДИНИ ОБУЧЕНИЕ ПО АВТОМАТИКА"
1 - 4 юни 2012 г., Созопол, България



PROCEEDINGS OF TECHNICAL UNIVERSITY OF SOFIA

Volume 62, Issue 1, 2012

INTERNATIONAL CONFERENCE AUTOMATICS'2012, FA
Anniversary "50 YEARS EDUCATION IN AUTOMATICS"
June 1 - 4, 2012, Sozopol, Bulgaria

34. Албена Танева, Севил Ахмед, Михаил Петров, Ивайло Вантулев	317
<i>Изследване на мрежови системи за управление</i>	
35. Ненчо Делийски, Евгени Янков	327
<i>Моделно предсказващо управление на процесите на размразяване и термично обработване на дървесината</i>	
36. Георги Ценов, Ирина Богатинова, Валери Младенов	337
<i>Предсказване дневната електрическа консумация с използване на невронни мрежи</i>	
37. Коста Бошнаков, Тодор Гинчев, Венко Петков, Емил Михайлов.	345
<i>Стратегия за предсказващо поддържане на Pierce-Smith конвертори</i>	
38. Симона Петракиева, Галя Георгиева-Таскова, Снежана Терзиева	355
<i>Дефиниране на критерии за избор на лампи за улично осветление</i>	
39. Кирил Стойков, Симона Петракиева	361
<i>Магнитна система за електропещни трансформатори – автоматизиране на изчисленията</i>	
40. Николина Петкова, Камелия Стоянова, Мария Кънева	371
<i>Технико-икономически показатели за оценяване функционалността на силовите трансформатори</i>	
41. Стоян Кирилов, Валери Младенов.	377
<i>Изследване на верига с един мемристор и идеален източник на синусоидално напрежение</i>	
42. Камелия Кирилова, Георги Милушев.	387
<i>Калибиране и проверка на средства за измерване с калибратор CX 1651</i>	
43. Юлия Заркова, Георги Милушев	397
<i>Методология на електро-енергиен одит</i>	
44. Михаил Скопчанов.	407
<i>Подобрене на алгоритъма за следене на лица чрез актуализация на шаблона в реално време</i>	
45. Ренгинар Рашид, Веско Узунов, Петър Петров	415
<i>Управление на ОВК система за летищен терминал</i>	
46. Ростислав Райчев, Веско Узунов, Петър Петров.	421
<i>Йерархична система за управление на електрозахранването на бизнес сграда тип МОЛ</i>	

36. Georgi Tsenov, Irina Bogatinova, Valeri Mladenov	337
<i>Daily Electric Load Forecast Prediction with Usage of Neural Networks</i>	
37. Kosta Boshnakov, Todor Ginchev, Venko Petkov, Emil Mihajlov	345
<i>Strategy for Predictive Maintenance of Pierce-Smith Convertors</i>	
38. Simona Petrakieva, Galia Georgieva-Taskova, Snejana Terzieva.	355
<i>Some Criteria Under Consideration of the Light Sources for Electric Street-Lighting</i>	
39. Kiril Stoykov, Simona Petrakieva	361
<i>Automated Calculations in Magnetic System for Electric Furnace Transformers Design</i>	
40. Nikolina Petkova, Kamelia Stoyanova, Maria Kaneva	371
<i>Technical and Economical Indicators for Functionality Assessment of Power Transformers</i>	
41. Stoyan Kirilov, Valeri Mladenov	377
<i>Analysis of a Circuit with One Memristor and Ideal Source of Sine Voltage</i>	
42. Kameliya Kirilova, George Milushev.	387
<i>Calibration and Verification of Measuring Instruments with Calibrator CX 1651</i>	
43. Julia Zarkova, George Milushev	397
<i>Energy Audit Methodology</i>	
44. Michael Scopchanov	407
<i>Improved Face Tracking Algorithm Using Real-Time Update of the Target Image</i>	
45. Renginar Rashid, Vesko Uzunov, Petar Petrov	415
<i>HVAC Management System for Airport Terminal</i>	
46. Rostislav Raychev, VeskoUzunov, Petar Petrov	421
<i>Hierarchical System for Powermanagement of a Business Building Type MALL</i>	



ПРЕДСКАЗВАНЕ ДНЕВНАТА ЕЛЕКТРИЧЕСКА КОНСУМАЦИЯ С ИЗПОЛЗВАНЕ НА НЕВРОННИ МРЕЖИ

Георги Ценов, Ирина Богатинова, Валери Младенов

Резюме: Успешното точно прогнозиране на потреблението на електрическата енергия е важна задача за електроразпределителните дружества при една непланова икономика със свободни отворени пазари. Прогнозирането на електрическите товари намира множество приложения, като например при планираното включване и изключване на електроцентрали, при планиране на бъдещата електро преносна инфраструктура или при формиране на цените на електрическата енергия в междудържавните пазари за покупко/продажба на електроенергия. В тази статия са показани резултати от дневното прогнозиране на електрически товари представени като времеви редове с използване на пакета за невронни мрежи от Neural Networks Toolbox в работната среда на MATLAB сравнени с метода за усреднена прогнозна оценка от предходни дни.

Ключови думи: прогнозиране, електрически товари, невронни мрежи

DAILY ELECTRIC LOAD FORECAST PREDICTION WITH USAGE OF NEURAL NETWORKS

Georgi Tsenov, Irina Bogatinova, Valeri Mladenov

Abstract: The successful electric grid load forecast prediction is an important task for the companies involved in the energy distribution industry when the economy is deregulated. The electric consumption forecasting finds many applications as is in the cases of planned inclusion or removal of power plants from the electric grid, when planning the future energy distribution infrastructure or in the markets of electrical energy trading between states and etc. In this paper are given results for energy load daily forecasting, when presenting the consumer power load as time series dataset, using Feedforward Error Backpropagation Neural Networks from the MATLAB Neural Networks toolbox, compared with forecasts based on mean average value of the power load data from the previous week.

Keywords: forecasting, grid electric load, neural networks

1. ВЪВЕДЕНИЕ

За да бъде постигната ефективност в доставката, разпределението и потреблението на електрическата енергия, т.е. за да е възможно тези процеси да се управляват е необходима различна информация. Например: информация към дос-

тавчика относно това какъв е размера на потреблението, кои са натоварените клонове на мрежата, кои са натоварените часови зони, какво е качеството на подаваната ел.enerгия, какъв е размера и каква е структурата на загубите, има ли опити за манипулации и кражби и информация към потребителя, какъв е размера на неговото моментно,ежедневно и месечно потребление, кои са неговите натоварени часови зони, какво е качеството на подаваната към него ел.enerгия, какъв е ефекта от предприетите от него мерки за пестене на ел.enerгия и др.

За целта се налага следенето и прогнозиране на товарите в електрическите мрежи, което е и заложено в правилата за управление на електроразпределителните мрежи на ДКЕВР [1] в глава 4. Успешното точно прогнозиране на потреблението на електрическата енергия е важна задача за електроразпределителните дружества при една непланова икономика със свободни отворени пазари. Прогнозирането на електрическите товари намира множество приложения, като например при планираното включване и изключване на електроцентрали, при планиране на бъдещата електро преносна инфраструктура, при формиране на цените на ел. енергия в междудържавните пазари за покупко/продажба на ел.enerгия и др.

За съжаление, при контакти с някои електроенергетици от балканите работещи в електропреносния сектор установихме, че в бранша, в повечето случаи се ползва прекалено елементарен метод за прогнозиране на електрическите товари. В повечето случаи прогнозирането на електрическите товари се извършва на база на елементарни сметки, включващи усредняване товарите от четири предходни дни. Това породи мотивацията за създаването на модели за по-адекватно прогнозиране на електрическите товари.

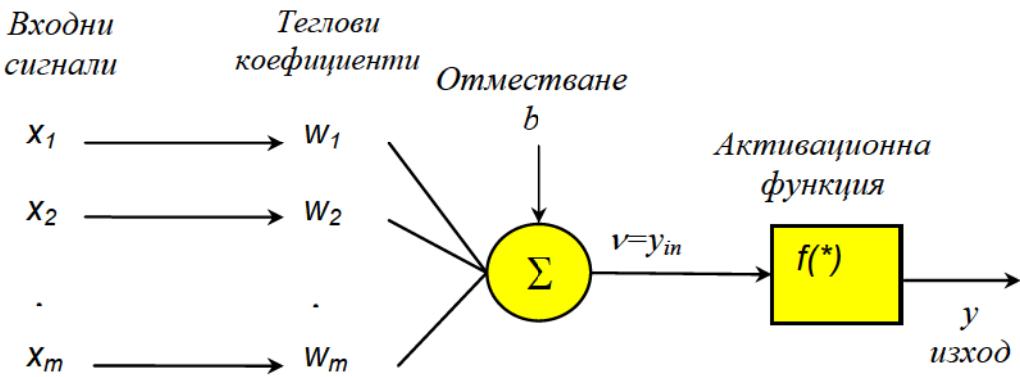
Поради факта, че електрическата консумация се представя като времеви ред ние се спряхме на апарат на невронните мрежи, с които отдавна е доказано, че може да се извършва успешно предсказване на времеви редове и в частност на електрически товари [2],[3],[4].

Статията е организирана в 4 глави. В глава втора е показано кратко въведение в теорията на невронните мрежи. В глава трета са показани примерни резултати от дневното прогнозиране на електрически товари на мрежи с високо напрежение представени като времеви редове с използване на функцията за създаване на невронни мрежи с право предаване на сигнала и обратно разпространение на грешката feedforwardnet от пакета за невронни мрежи от Neural Networks Toolbox в работната среда на MATLAB при подаване на входни данни от предишната седмица и сравнени с метода на прогнозиране включващ усредняване на данни от предходните дни, а Глава 4 включва заключителните изводи.

2. КРАТКО ВЪВЕДЕНИЕ В ТЕОРИЯТА НА НЕВРОННИТЕ МРЕЖИ

Невронната мрежа е система за паралелна обработка на информация, която има свойството за съхранение и използване на експериментални знания. Най-общо невронните мрежи се състоят от прости елементи за обработка на информация наречени неврони или възли. Невроните (фиг.1) са свързани и теглата на връзките между тях определят силата на съответните връзки. Входната информация за всеки неврон е претеглената сума от сигналите от останалите неврони. Тази

информация се акумулира в неврона като изходният му сигнал се определя посредством т. нар. активационна или предавателна функция. Информацията в една невронна мрежа се натрупва в процес на обучение, като силата на връзките между отделните възли се моделира с тегла на съответните връзки, които се използват за съхранение на информацията.



Фиг.1. Абстрактен математически модел на един неврон

Всеки неврон има много входове и един изход. На входовете x_1, x_2, \dots, x_m постъпват сигналите към неврона. Те могат да са външни сигнали или сигнали от изходите на други неврони. С всеки вход е свързан теглови коефициент w_j , $j=1,2,\dots,m$, моделиращ силата на връзката при предаване на сигнала. Агрегирането на входните сигнали в тялото на неврона се моделира със суматора, чийто изходен сигнал се изчислява с формулата:

$$v = y_{in} = \sum_{j=1}^m w_j x_j + b \quad (1)$$

За удобство и възможност за повече степени на свобода, при модела на неврона е въведен и сигнал с постоянна стойност b , наречен отместване (bias).

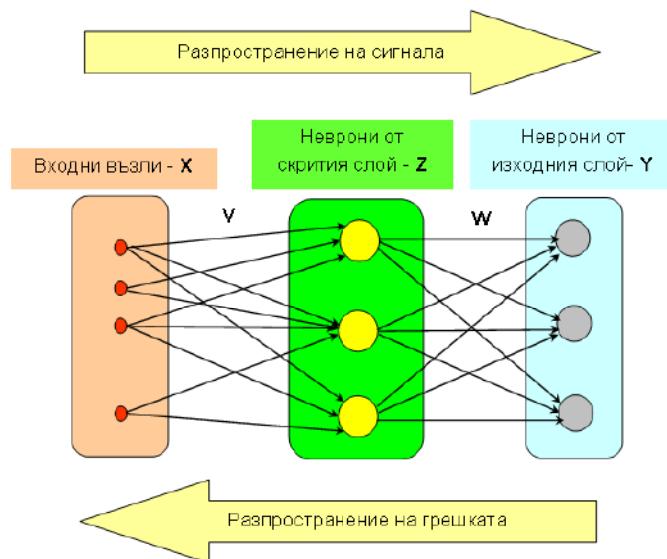
В повечето случаи активационната функция е нелинейна и изходният сигнал на единичен неврон се изчислява като:

$$y = f(y_{in}) = f\left(\sum_{j=1}^m w_j x_j + b\right) \quad (2)$$

Основните компоненти на невронните мрежи, с които са свързани и различните им класификации са на база на: Архитектурата на мрежата – тя се задава от начина на свързване между различните неврони; Алгоритъма за обучение - определя начинът, по който се настройват теглата на връзките между невроните, така че невронната мрежа да изпълнява желаното преобразуване на сигналите; Активационна функция – математическото правило посредством което се определя стойността на изходния сигнал.

За целите на прогнозирането сме се спрели на многослойните мрежи с право предаване и обратно разпространение на грешката, защото е доказано, че с многослойни невронни мрежи, базирани на метода с обратно разпространение на грешката, могат да бъдат представени (апроксимирани) всички L^2 функции. Същевременно при решаване на различни апроксимационни задачи, генерали-

зиращите свойства на мрежите са добри, стига обучаващата извадка да е достатъчна.



Фиг.2. Архитектура на двуслойна невронна мрежа

На примерната структура от фиг.2 мрежата се състои от един входен слой възли, посредством които се подават входните сигнали $\mathbf{X}=[x_1 \ x_2 \ \dots \ x_n]^T$ към мрежата, от един изходен слой неврони, векторът от изходните сигнали на които $\mathbf{Y}=[y_1 \ y_2 \ \dots \ y_m]^T$ е изходният вектор на мрежата, и един скрит слой неврони, изходните сигнали на които са $\mathbf{Z}=[z_1 \ z_2 \ \dots \ z_p]^T$. При този тип мрежи активационната функция на изходния слой неврони е линейна, а на скрития тангенциално сигмоидална. Тегловите коефициенти се настройват с алгоритъм включващ итерационна процедура променяща тегловните коефициенти от изходния към входния слой на база на грешката получена при съпоставка на получения изход на мрежата с желания изход. Многослойни невронни мрежи, базирани на метода с обратно разпространение на грешката работят на принципа на черната кутия и при достатъчно данни за обучение, резултатите при използване са много добри. Не се изисква познаване на същността на проблема, който се апроксири с невронната мрежа, а само достатъчно входно-изходни данни. Също така, тези невронни мрежи са робастни по отношение на шум в данните и в стойностите на теглата на мрежата, при липсващи данни и др.

Броят на невроните от скрития слой е много важен при използване на многослойните невронни мрежи с обратно разпространение на грешката. Обикновено броят на невроните се избира от емпирични съображения на база на формулата на Оја. Ако със Z бележим броят на невроните в скрития слой, с P броят на елементите от обучаващата извадка, m е броя на входовете, а n броя на изходите, то тогава ще получим според формулата на Оја че:

$$Z = \frac{P}{5(m+n)} \quad (3)$$

3. РЕЗУЛТАТИ ОТ ДНЕВНОТО ПРОГНОЗИРАНЕ НА ЕЛЕКТРИЧЕСКИ ТОВАРИ

При прогнозирането на електрическата консумация са необходими данни от предходни периоди, които да служат като база за прогнозиране консумацията в

бъдещи периоди. В правилата за управление на електроразпределителните мрежи на ДКЕВР [1] в Чл. 41. е зададено, че при прогнозирането за отделните периоди се използва информация за деновонощно, за седмично, за месечно и за годишно планиране. По-трудната задача е постигането на адекватно ежедневно прогнозиране. Екипът имаше на разположение полеви данни снети за период от една година за 24 възела от високоволтови електропреносни системи. Тези данни са достатъчни за обучението на невронни мрежи за ежедневно отчитане, но недостатъчни по големина за обучение на невронни мрежи прогнозиращи седмичната или годишна консумация. Предоставените ни данни бяха в следния вид:

Таблица 1 – Данни от 24 възела на мрежи с високо напрежение

година	месец	ден	възел 1	възел 2	възел 3	възел 4	***	възел 22	възел 23	възел 24	Р дневна сумарна
2006	1	1	4293	4186	4026	3877	***	4301	4346	4335	29364
2006	1	2	4030	3823	3678	3571	***	4806	4809	4684	29401
2006	1	3	4307	4045	3897	3811	***	5017	5044	4868	30989
2006	1	4	4568	4319	4119	4024	***	5136	5229	4990	32385
2006	1	5	4625	4289	4128	4088	***	5248	5281	5045	32704
2006	1	6	4741	4412	4268	4183	***	5379	5389	5310	33682
2006	1	7	4872	4612	4445	4362	***	5107	5213	5147	33758
2006	1	8	4915	4614	4421	4282	***	5514	5631	5343	34720
2006	1	9	4936	4538	4494	4379	***	5609	5800	5512	35268
2006	1	10	5116	4775	4646	4589	***	5688	5806	5574	36194
2006	1	11	5139	4749	4652	4514	***	5801	5879	5593	36327

където за всеки един възел е налична дневната консумация през 2006 година. От тези данни ние формирахме обучаващата извадка за подаване към невронна мрежа като всяка една комбинация от 7 последователни дни се комплектова като един образец от обучаващата извадка, на която записът на следващия 8-ми ден съответства на нейната целева функция, както е показано на фиг.3.

Времеви ред на консумираната енергия от даден възел

1	95504
2	103402
3	114264
4	118232
5	119511
6	122034
7	118660
8	120041
9	130508
10	131010
11	131177
12	132705
13	133014
14	127635
15	124561
16	132288

Резултантната обучаваща извадка при избран прозорец за прогнозиране на база на предходни данни с дължина 7 дни

1	2	3	4	5	6	7	8
1	95504	103402	114264	118232	119511	122034	118660
2	103402	114264	118232	119511	122034	118660	120041
3	114264	118232	119511	122034	118660	120041	130508
4	118232	119511	122034	118660	120041	130508	131010
5	119511	122034	118660	120041	130508	131010	131177
6	122034	118660	120041	130508	131010	131177	132705
7	118660	120041	130508	131010	131177	132705	133014

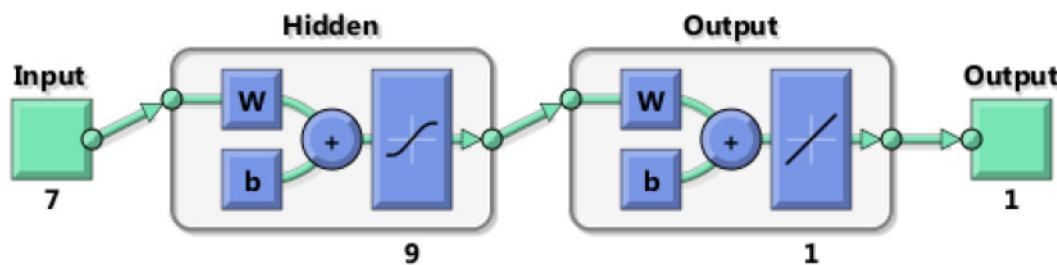
Вектор на целевата функция на обучаващата извадка

1	2	3	4	5	6	7	8
1	120041	130508	131010	131177	132705	133014	124561

Фиг.3. Оформяне на обучаващата извадка

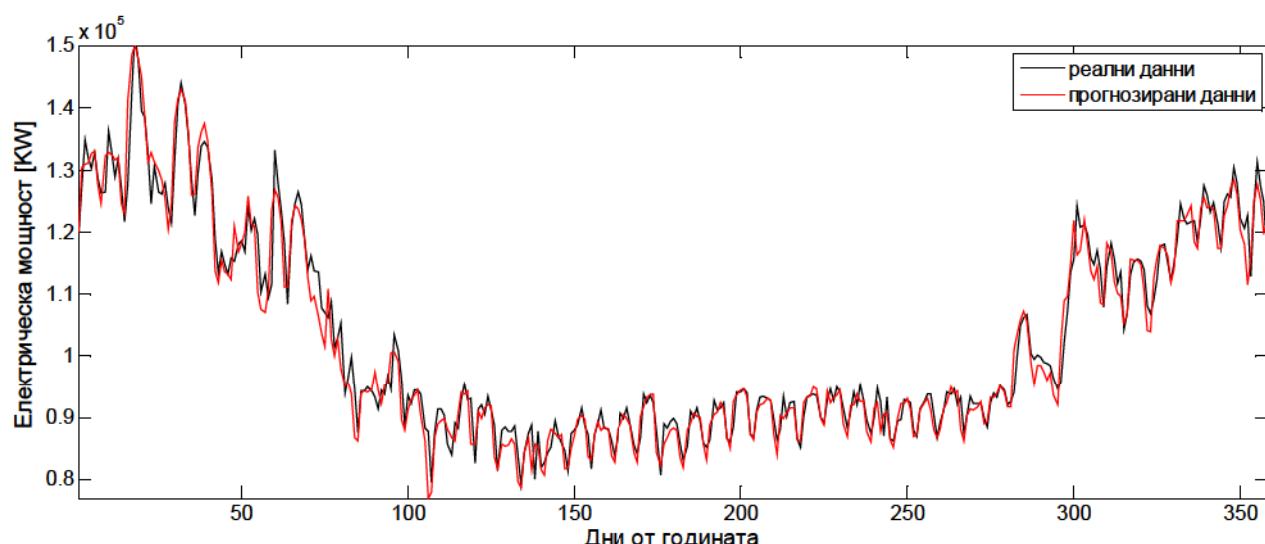
След като се оформи обучаващата извадка се минава към процес на обучение на невронна мрежа с право предаване на сигнала в MATLAB. Тъй като, дълбочината на прозореца за предсказване формиран от предходните данни е 7 дни и

дискретния отчет е на база на един ден, то входовете на невронната мрежа са седем на брой, т.е. ден1 е вход1, ден2 е вход2 и т.н. и входният слой ще бъде изграден от 7 неврона. Желания прозорец за предсказване е един ден и на тази база изходният слой на мрежата трябва да е изграден от един неврон. Броят на невроните в скрития слой се определя емпирично по формула 3, което след елементарно пресмятане води до 9 неврона в скрития слой. Получената резултантна структура на невронната мрежа при използване на функцията feedforwardnet от пакета за невронни мрежи на MATLAB е показана на фиг.4.



Фиг.4. Архитектура на невронната мрежа за дневно прогнозиране при използване на данните от предходната седмица

След обучението на мрежата с данни от 2006 година за тестването ѝ използвахме данни за потреблението през възлите, но от 2007 година. На фиг.5 е показва съпоставка между предсказана и действителна стойност на ел. консумация. От графиката на съпоставката може да се види, че невронната мрежа много добре апроксимира данните така, че да няма някакви големи разлики между предсказаната и действителната стойност за консумираната ел.enerгия.



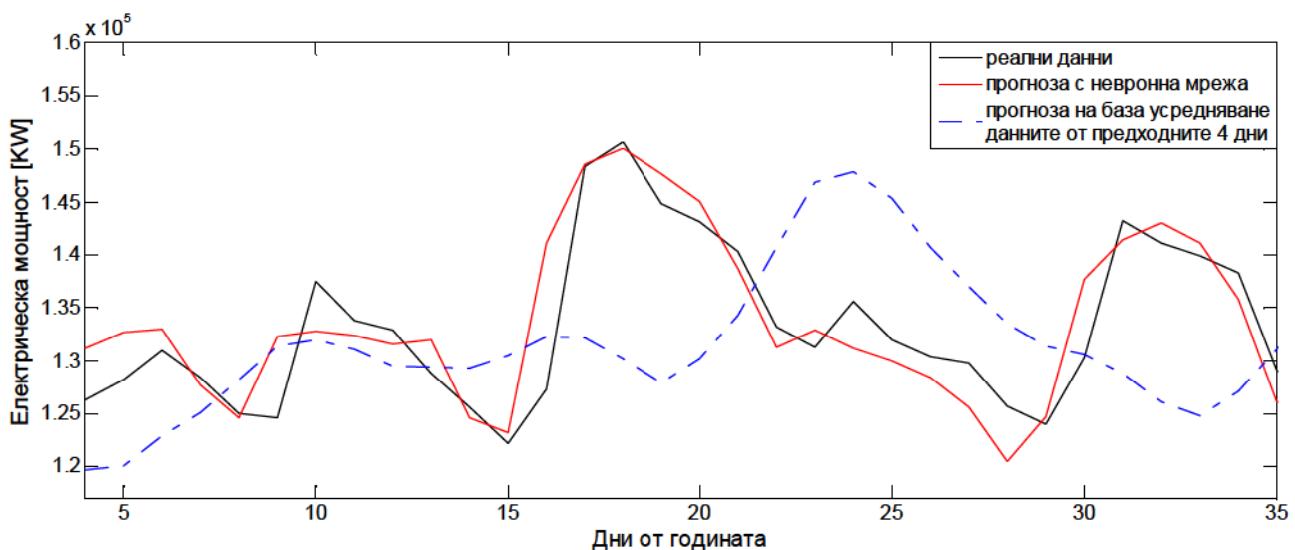
Фиг.5. Ежедневна съпоставка на реалната консумация с предсказаната за период от една година за един възел от мрежата.

Така обучената невронна мрежа върши работа само за възела, чийто данни са ползвани при обучението ѝ. При желание да се прави прогнозна оценка за всеки един възел е необходимо създаването на софтуерен модел на невронна мрежа за

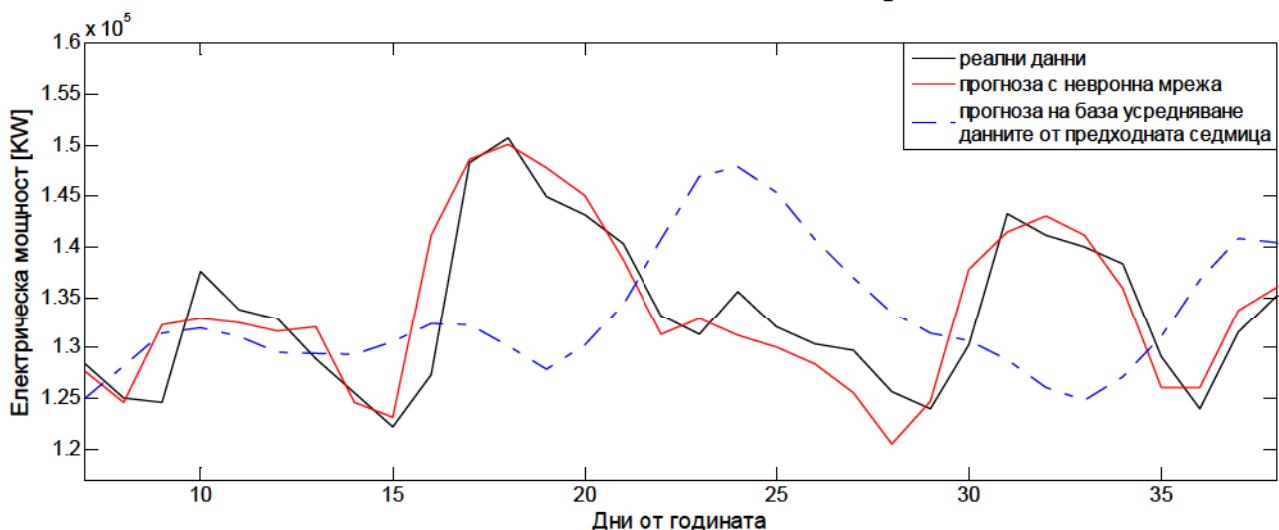
всеки един възел или комбинирането на всички данни за всички възли в една обобщена невронна мрежа, имаща m броя изходи, като всеки един изход представлява прогнозната стойност на един от възлите. В практиката много често се ползва следния елементарен подход за прогнозиране на електрическите товари използваш усреднена стойност при използване на n броя от предходните дни:

$$P_{\text{прогнозна}} = \frac{\sum_{\text{дн}=\text{1}}^n P_{\text{дн}}}{n} \quad (4)$$

Много често се използват такава прогноза от електро енергетици при използване на 4 предходни дни. На тази база при отделяне на данни за един месец направихме две съпоставки между прогнозната оценка получавана при този метод и при метода с използването на обучената невронна мрежа за даден възел (фиг.6, фиг.7).



Фиг.6. Съпоставка на двата метода при $n=4$



Фиг.7. Съпоставка на двата метода при $n=7$

От така направената съпоставка на резултатите получени с обучената невронна мрежа и метода с осредняването на база на данните от няколко предходни дни

може да се види, че с използването на невронни мрежи се постига по-точно предсказване на данните.

4. ЗАКЛЮЧЕНИЕ

Направеният анализ и съпоставка между резултатите на прогнозиране с използване на невронни мрежи или с усреднена стойност на предходните отчети показва, че с използването на апарата на невронните мрежи може да се постигне по-точно прогнозиране на потреблението на електрическата енергия спрямо класическите използвани в практиката методи.

БЛАГОДАРНОСТИ

Научните изследвания, резултатите от които са представени в настоящата публикация, са финансиирани от вътрешния конкурс на ТУ – София със съдействието на НИС на ТУ - София, предложение за финансиране на научноизследователски проекти в помощ на докторанти Номер, на тема: “Методи и алгоритми за изчисляване и прогнозиране на товарите в мрежите за високо напрежение”, сесия 2011 - 2012 г.

ЛИТЕРАТУРА

- [1] *Правила за управление на електроразпределителните мрежи*, Издадени от ДКЕВР Приложение към т. 1 на Решение № П-6 от 18 юни 2007 г., Обн. ДВ. бр.66 от 14 Август 2007г.
- [2] Младенов В., Йорданова С.(2006), *Размито управление и невронни мрежи*, учебник, издателство на ТУ-София
- [3] Ценов.Г, Петрова Р., Младенов В., Йорданова С. (2008), *Размито управление и невронни мрежи*, учебно помагало, издателство на ТУ-София
- [4] Danilo Bassi, Oscar Olivares, *Medium Term Electric Load Forecasting Using TLFN Neural Networks*, International Journal of Computers, Communications & Control Vol. I (2006), No. 2, pp. 23-32.
- [5] The MathWorks, Inc., MATLAB 2010b, 24 Prime Park Way, Natick MA, 2010.

Автори: Георги Ценов, гл. ас. маг. инж., катедра „Теоретична електротехника”,
email: gogotzenov@tu-sofia.bg; Ирина Богатинова, докторант, маг. инж., катедра „Теоретична електротехника”; Валери Младенов, проф. д-р, катедра „Теоретична електротехника”, *email: valerim@tu-sofia.bg*

Постъпила на 28.04.2012

Рецензент Доц. д-р Симона Петракиева