

СЪЗДАВАНЕ НА ПРОФИЛ ЗА ДНЕВНАТА ЕЛЕКТРИЧЕСКА КОНСУМАЦИЯ НА ПРЕДПРИЯТИЯ С ИЗПОЛЗВАНЕ НА НЕВРОННИ МРЕЖИ

Верица Бабамова-Ценова
ТУ - София, България
verica.tsenova@gmail.com

Огнян Андреев
ТУ - София, България
oandre@tu-sofia.bg

Георги Ценов
ТУ - София, България
gogotzenov@tu-sofia.bg

GENERATION OF PLANT ELECTRIC CONSUMPTION PROFILE WITH USE OF NEURAL NETWORKS

Verica Babamova-Tsenova
TU-Sofia, Bulgaria
verica.tsenova@gmail.com

Ognyan Andreev
TU-Sofia, Bulgaria
oandre@tu-sofia.bg

Georgi Tsenov
TU-Sofia, Bulgaria
gogotzenov@tu-sofia.bg

Abstract: In the modern free electricity market, the successful electricity consumption forecasting of is important aspect in the optimization of the production activity and the production plan costs. The forecasting of electrical loads can be done daily or hourly using the methods of artificial intelligence for training and setting up a forecasting module, which can be set up with data accumulated on the basis of reports of consumed electricity in short periods of time. These forecasts would be used in the formation of electricity prices in the interstate markets for the purchase / sale of electricity. This article presents the results for creating an energy user profile of an plant, by implementing forecasts of the electrical loads, presented as time series using the neural network package from Neural Networks Toolbox in the MATLAB when capturing data on current consumption at 15 minute time intervals.

Keywords: time series, forecasts, electric loads, neural networks, plant optimization.

1. Въведение

Електрическата енергия е необходим продукт в съвременните производствени предприятия. Електрическата енергия може да бъде разглеждана като една стока и като всички останали стоки може да се произвежда и търгувана на пазарни начала. На база на параграф 15 от Закон за изпълнение и допълнение на Закона за енергетиката, публикуван в бр. 57 на Държавен вестник на Република България от 26.06.2020 г., считано от 1 Октомври 2020 година в България стартира процедура по избор на доставчици на енергия по свободно договорени цени за всички небитови клиенти, присъединени на ниво ниско напрежение към електроразпределителната мрежа. В случай, че до 1 юли 2021 г. производствените предприятия не сключат договор с търговец на електрическа енергия по свободно договорени цени, то считано от тази дата те ще бъдат снабдявани с електрическа енергия при условията на чл. 95а от Закона за енергетиката от доставчик от последна инстанция, което ще повиши техните разходи. Участниците на свободния енергиен пазар на електроенергия са производителите, разпределителните предприятия (ЕРП), търговците в ролята им на доставчици и крайните потребители. Лицензираните дружества, търговци

на електрическа енергия на свободен пазар, предлагат на своите клиенти различни цени, продукти, тарифи и услуги. По този начин те се конкурират, а потребителите имат възможност да направят избор на доставчик на ел енергия и договарят търговски условия. 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 доставчика относно това какъв е размера на потреблението, кои са натоварените клонове на мрежата, кои са натоварените часови зони, какво е качеството на подаваната ел.енергия, 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.енергия, какъв е ефекта от предприетите от него мерки за пестене на ел.енергия 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 и производствените предприятия при текущата 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.енергия при определяне на натоварените часови зони с повишена консумация и синхронизирането и планирането на производството във време, когато доставчиците на зелена енергия имат най-големи добиви др. което би довело до по-ниски нива на емисии на въглероден двуокис и намалени разходи с директното приоритетно използване на генериранта ел. енергия от ветрогенератори или соларни панели. При месечното отчитане на електромерите няма как да се нарави коректна прогноза на консумацията, т.к. отчета се прави еднократно и показва отчет на сумарно консумираната ел. енергия, т.е. електромерите се явяват едно интегриращо звено, докато за изготвяне на прогнози е необходимо измерване на моментната мощност или интеграл от консумираната мощност за кратки времеви интервали. С използване на устройства за запис на консумираната ел. енергия през кратки времеви интервали е възможно прилагане на методи за изготвяне на прогнози. Поради факта, че електрическата консумация традиционно се представя като времеви ред ние се спряхме на апарата 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 използваните устройства за запис на ел. енергия и примерни резултати от ежедневното прогнозиране на електрическата консумация в едно предприятие представена

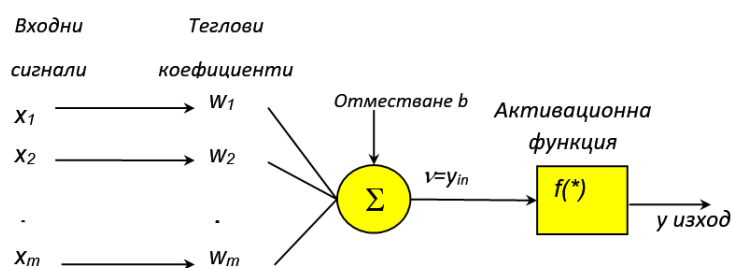
като времеви ред с използване на функцията за създаване на невронни мрежи с право предаване на сигнала и обратно разпространение на грешката feedforwardnet от пакета за невронни мрежи от Neural Networks Toolbox в работната среда на MATLAB. Глава 4 включва заключителните изводи.

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 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.

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

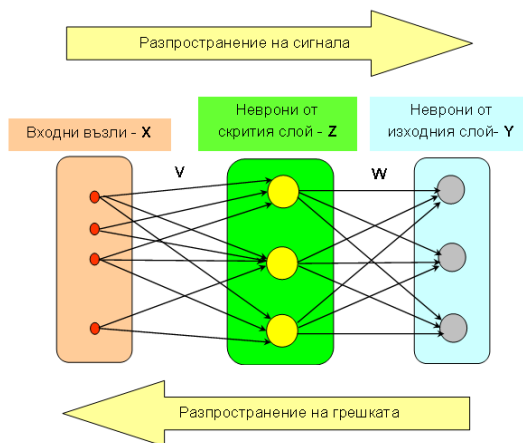
При модела на неврона е въведен и сигнал с постоянна стойност b , наречен отместване (bias). В повечето случаи активационната функция е нелинейна и изходният сигнал на единичен неврон се изчислява с: $y = f(y_{in}) = f\left(\sum_{j=1}^m w_j x_j + b\right)$ (2)



Фигура 1. Абстрактен математически модел на един неврон

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, генерализиращите свойства на мрежите са добри, стига обучаващата извадка да е достатъчно голяма.



Фигура 2. Архитектура на двуслойна невронна мрежа

На примерната структура от Фигура 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 апроксимира 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 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. За постигане на тази цел използваме смарт електромер модел SM-0001, предлагащ възможност за запис на данни през различни интервали.



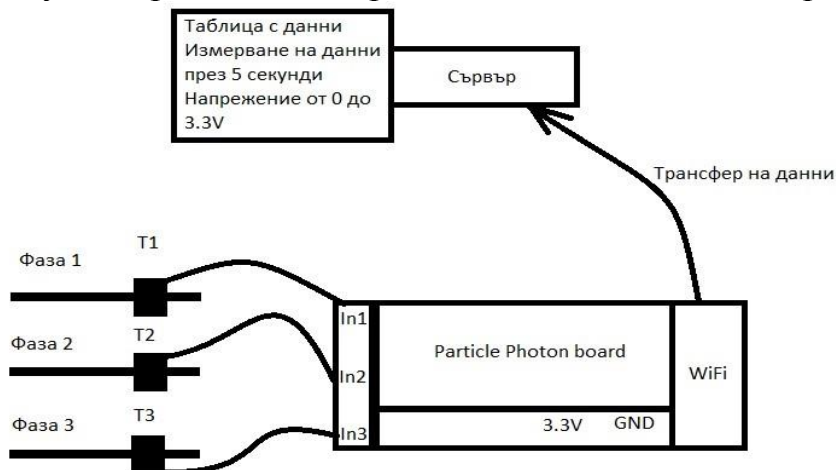
Фигура 3. Общ изглед на IoT смарт електромера

Устройството разполага с вграден микроконтролер с процесор STM32F205 120Mhz и 128KB RAM. Микроконтролерът се захранва с напрежение от 3.3V. Към микроконтролерът са свързани 3 токови-трансформатора, които дават възможност за измерване на инсталации до 100A. Трансформаторите се свързват неинвазивно като не се правят механични изменения по изолацията на проводниците. Устройството е подходящо за измерване на реалната мощност по една, две или три фази.



Фигура 4. Общ изглед на токовия трансформатор

Измерванията и събиранията на данните може да се извършват в най-кратки интервали от 5 минути, но за разглеждан пример от предприятие се извършват през интервали от 15 мин., като за трансфер на данните се използва MQTT протокол. Използването на IoT електромери позволява с уеб платформа да се обработват и визуализират данните предоставяни от повече на брой устройства.



Фигура 5. Схема на софтуерната и хардуерната инфраструктура

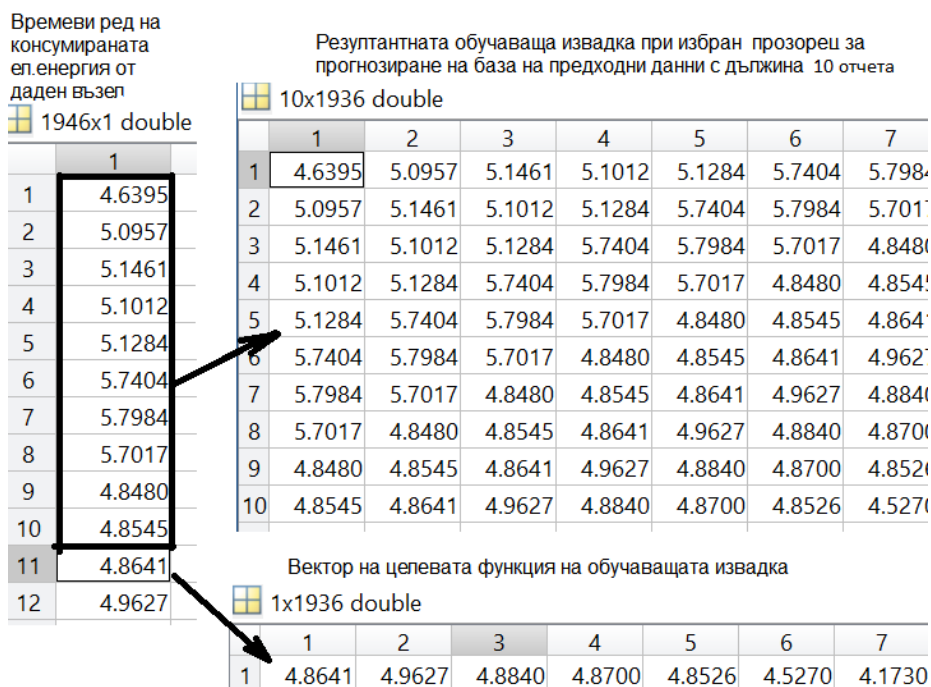
По-трудната задача е постигането на адекватно ежедневно прогнозиране. Екипът имаше на разположение полеви данни снети за период от един месец за едно предприятие. Тези данни би трябвало да са достатъчни за обучението на невронни мрежи за ежедневно отчитане и прогнозиране, но за постигането на по-добри резултати е препоръчително използването на данни за по-големи времеви периоди.

Измерените и записани в база данни измервания са в следния табличен вид:

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


name	time	devId	value
sm-0001fifteen	2021-05-17T09:14:45.057462933Z	sm-0001	4.639475
sm-0001fifteen	2021-05-17T09:29:48.922862151Z	sm-0001	5.095667
sm-0001fifteen	2021-05-17T09:44:52.789837614Z	sm-0001	5.146074
sm-0001fifteen	2021-05-17T09:59:47.324949599Z	sm-0001	5.101224

където за всеки един IoT умен електромер е налична консумацията през 15 минутни интервали, нормирана и анонимизирана по желание на предприятието. От тези данни ние формирахме обучаващата извадка за подаване към невронна мрежа като всяка една комбинация от 10 последователни дни се комплектова като един образец от обучаващата извадка, на която записът на следващия 11-ти отчет съответства на нейната целева функция, както е показано на Фигура 6. 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 10 отчета, то входовете на невронната мрежа са десет на брой, т.е. отчет1 е вход1, отчет2 е вход2 и т.н. и входния слой ще бъде изграден от 10 неврона. Желания прозорец за предсказване е един отчет напред във времето и на тази база изходния слой на мрежата трябва да е изграден от един неврон.



Фигура 6. Оформяне на обучаващата извадка

Броят на невроните в скрития слой се определя емпирично по формула 3, което след елементарно пресмятане води до 35 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.7.



Фигура 7. Архитектура на невронната мрежа за прогнозиране на ел. енергия

След обучението на мрежата с данни от един работен месец за тестването ѝ използвахме данни за потреблението измерено за друг месец, данните от което не са участвали в обучаващата извадка. На Фигура 8 е показана 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 никакви големи разлики между предсказаната и действителната стойност за консумираната ел. енергия.

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 отделен възел или е възможно комбинирането на всички данни за всички възли в една обобщена невронна мрежа, имаща m броя изходи, при която всеки един изход представлява прогнозната стойност на един от възлите.



Фигура 8. Съпоставка на реалната консумация с предсказаната за период от един месец

4. Заключение

Направеният модел за прогнозиране показва, че при наличие на данни за потребителското потребление с използването на апарата на невронните мрежи може да се постигне доста точно прогнозиране на потреблението на електрическата енергия, на база на което може да се постигнат по-ниски производствени разходи, със задаване на времевите производствени норми да съвпадат с периодите, когато електрическата енергия се продава на ниска цена.

Благодарности

Научните изследвания, резултатите от които са представени в настоящата публикация, са финансирани от вътрешния конкурс на ТУ-София със съдействието на НИС при ТУ-София, предложение за финансиране на научноизследователски проекти в помощ на докторанти № 212пд0019-15, на тема: „Прогнозиране и управление на потреблението на електрическа енергия с използване на невронни мрежи”, сесия 2021 - 2022 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.