

ELEKTROMOS KÉSZÜLÉKEK STATISZTIKAI PARAMÉTEREINEK BECSLÉSE IDŐPONT ALAPJÁN

ESTIMATION OF STATISTICAL PARAMETERS OF ELECTRIC APPLIANCES BASED ON TIME OF DAY INFORMATION

Dömötör Zénó István ^{1*}, Dr. Kovács Lóránt ¹, Drenyovszki Rajmund ¹

¹ Informatika Tanszék, GAMF Műszaki és Informatikai Kar, Pallasz Athéné Egyetem, Magyarország

Kulcsszavak:

Smart Grid
fogyasztásengedélyezési eljárás
radiális bázisfüggvényes neurális
hálózat

Keywords:

Smart Grid
consumption admission control
radial basis function neural
networks

Cikktörténet:

Beérkezett 2017. február 6.
Átdolgozva 2017. április 21.
Elfogadva 2017. április 22.

Összefoglalás

A közelmúltban kifejlesztésre került egy a Smart Gridbe illeszkedő fogyasztásengedélyezési eljárás, amely eljárás a fogyasztói oldal befolyásolásának problémáját (Demand Side Management) az egyes fogyasztók statisztikai leírói alapján oldja meg. A fogyasztói oldal befolyásolásával a villamosenergia kereslet a megtermelt mennyiséghez igazítható, lehetővé téve a megújuló energiatermelők nagyobb mértékű kihasználását. Az új eljárás érzékeny a statisztikai leírók pontosságára, amely leírók nemstacionáriusak, sőt további paramétereiktől is függenek, például jelenlét, hőmérséklet, stb. Cikkünkben megvizsgáljuk, hogy radiális bázisfüggvényes neurális hálózattal milyen hatékonysággal becsülhetők meg idővariáns statisztikai leírók. A módszer hatékonyságát nyilvánosan elérhető villamos fogyasztási adatbázis felhasználásával értékeltük numerikusan.

Abstract

Recently the Consumption Admission Control algorithm has been developed in the smart grid framework as a new concept for controlling the demand side by the means of automatically enabling/disabling electric appliances to make sure that the demand is in match with the available supplies. The new method is based on the statistical characterization of the need and it is sensitive to the accuracy of the estimation of the statistical descriptors and furthermore the statistics are generally not stationary and even depend on other parameters (such as presence of the owner, temperature, etc). Our paper introduces an RBF neural network based approximation method, which can be used to estimate the statistical parameters of the appliance load time-series. The estimated parameters can be fed into the Consumption Admission Control Algorithm. The capabilities of the approximation method are demonstrated by numerical analysis based on a publicly available dataset.


* Kapcsolattartó szerző. Tel.: +36 453 83 62
E-mail cím: domotor.zeno@gamf.kefo.hu

1. Bevezetés

A villamosenergia-szolgáltatók egyik legfőbb feladata a termelői és fogyasztói oldal közötti egyensúly megteremtése, úgy, hogy a korábban is meglévő fogyasztói oldali bizonytalanság mellett előtérbe került a termelői oldalon megjelenő bizonytalanság – a fenntarthatósági szempontok miatt megnövelt megújuló energiaforrások bevonása következtében. Mivel a megújuló energiaforrásokon alapuló erőművek termelése nehezen jelezhető előre, továbbá a termelői oldal gyors szabályozása a fosszilis- és atomerőművek nagy időállandója miatt lehetetlen, ezért jelenleg a termelés-fogyasztás egyensúlyát nagy költségigényű extra gáz és olajgenerátorok használatával biztosítják. Intelligens energiaellátó hálózatok esetében (smart grid) ugyanakkor lehetőség nyílik (kihasználva az ilyen rendszerekben feltételezett kétirányú kommunikációs csatornát) a fogyasztói oldal befolyásolására [1] (Demand Side Management). Többféle fogyasztói oldal befolyásolási technika létezik: használat időpontjától függő árazás, a fogyasztás direkt kontrollja, stb. A lakossági szektor egy fontos és mennyiségileg jelentős részét képezi a villamosenergia piacnak, és ez a szegmens nagy számban tartalmaz — a fogyasztás időpontját tekintve — rugalmas fogyasztót. A direkt kontrollba bevont készülékek lehetővé teszik a napi előrejelzés alapú áramtermelés és az aktuális fogyasztás közötti eltérés kiküszöbölését.

A további gondolatmenet során feltételezzük, hogy a szóban forgó háztartások intelligens mérőkkel/vezérlőkkel (ún. smart meter) vannak felszerelve, amelyek (i) kommunikálnak az intelligens készülékekkel, (ii) képesek a készülék statisztikák gyűjtésére, (iii) képesek a készülékek engedélyezésére/tiltására. A smart meterek által kinyert statisztikai jellemzők felhasználhatók a fogyasztásengedélyezési eljárásban [2,3]. A készülékszintű fogyasztási adatokból készülékszintű statisztikai modellek készíthetők. A nehézséget ebben az jelenti, hogy a statisztikai modellek nemstacionáriusak, illetve más környezeti paraméterektől is bonyolult módon függhetnek, ezért célszerű lehet az érvényes statisztikai leírók és a változók közötti ismeretlen leképezés approximálására, hiszen a korábban kidolgozott statisztikai alapú fogyasztásengedélyezési módszer hatékonysága azon múlik, hogy a készülék-szintű statisztikai modellek elegendően pontosak-e [2,3].

Jelen tanulmányunkban arra a konkrét kérdésre keressük a választ, hogy a radiális bázisfüggvényes függvény approximátor milyen hatékonysággal képes közelíteni adott háztartási készüléktípusok egyes statisztikai paramétereinek időfüggését. A koncepciót az alábbi ábra mutatja:



1. ábra. A approximátor célja

2. Matematikai modell


A fenti probléma matematikai szempontból nem más, mint egy ismeretlen leképezés környezeti paraméterek (időpont, a hét napja, hőmérséklet, páratartalom, fényerő, jelenlét, stb.) és a megfelelő villamos fogyasztási idősor modell statisztikai leírói (pl. valószínűségi eloszlásfüggvény, Markov állapotátmeneti mátrix, stb.) között, amely leképezést egy erre alkalmas eszközzel approximálhatunk. Az approximátor optimalizálása a $\tau^{(K)} := \{(\mathbf{u}_k, \mathbf{z}_k), k = 1, \dots, K\}$ a K hosszúságú, bemeneti-kimeneti adatpárokból álló tanítóhalmaz alapján történik. Az ismeretlen függvényt $\Psi(\mathbf{u})$ jelöli, ahol $\mathbf{z}_k = \Psi(\mathbf{u}_k)$. Az \mathbf{u} bemeneti változó a környezeti paraméter vektort reprezentálja, míg a \mathbf{z} változó a statisztikai paraméter vektor.

2.1. Radiális bázisfüggvény hálózat

A függvényapproximációs feladat megoldására több hatékony megoldás létezik, a létező megoldások közül jelen tanulmányban a radiális bázisfüggvényes neurális hálózat (RBF)

hatékonyságát vizsgáltuk meg a jelzett feladatra vonatkozóan. Az RBF három rétegből áll: bemeneti réteg, rejtett réteg, kimeneti réteg. Az előbb felsorolt három réteg közül a rejtett réteg és a kimeneti réteg lát el jelfeldolgozó, processzáló feladatot, a bemeneti réteg pedig puffer szerepet tölt be.

A rejtett rétegben lévő feldolgozó elemek (neuronok) kiszámolják a bemeneti vektor (\mathbf{u}) és a középpont vektoruk (\mathbf{c}_i) közötti euklideszi távolságot, melynek egy nemlineáris függvénye adja a kimenetet. A kimeneti rétegben egyetlen lineáris elem található, amely a rejtett réteg neuronjai kimenetének súlyozott összegét állítja elő.



2. ábra. Az RBF struktúra

Az általunk alkalmazott RBF hálózatot az alábbi egyenletek írják le:

$$f(\mathbf{u}) = \sum_{i=1}^K a_i \varphi(\mathbf{c}_i, \mathbf{u}) \quad (1)$$

ahol K jelöli a rejtett réteg neuronjainak a számát (amely a jelen esetben megegyezik a tanulóhalmaz méretével is). A rejtett rétegbeli neuronokban Gauss-nemlinearitást (radiális bázisfüggvény) alkalmaztunk:

$$\varphi(\mathbf{c}_i, \mathbf{u}) = \exp\left(-\frac{\|\mathbf{c}_i - \mathbf{u}\|^2}{2\sigma_i^2}\right) \quad (2)$$

ahol σ az ún. szélességi paraméter, amely az adott neuron érzékenységi paraméterének felel meg.

2.2. A szélességparaméter beállítása

A fenti hálózati struktúrában minden bázisfüggvényhez különböző szélességi paraméter tartozhat, azonban bevett gyakorlat, hogy minden egyes neuronhoz tartozó szélesség azonos értékre van állítva. Ebben a munkában mi is ezt a megoldást követtük, a következő empirikus képletet használva [6]:

$$\sigma = \frac{1}{K} \sum_{i=1}^K \|\mathbf{c}_i - \mathbf{c}_j\| \quad (3)$$

ahol \mathbf{c}_j a legközelebbi szomszédja \mathbf{c}_i -nek Eukleidészi értelemben.

2.3. A hálózat tanítása

A hálózat tanítása tanulóhalmazon alapul, vagyis az RBF esetében felügyelt tanítást alkalmazunk. A tanulóhalmaz esetünkben azt jelenti, hogy az approximálandó függvény bizonyos pontjai ismertek. Ha az ismert pontok száma viszonylag kicsi, akkor az ismert pontokat közvetlenül fölhasználhatjuk a bázisfüggvények középpont-vektoraiként [5], ahogy tettük ezt a mi esetünkben is.

Ebben az esetben a hálózatban alkalmazott súlyok lineáris egyenletrendszer megoldásával számíthatók az alábbi formula szerint:

$\mathbf{U}\mathbf{a} = \mathbf{d}$, (ahol \mathbf{d} a kívánt válasz (azaz a tanulópontokban az ismert függvényértékek), \mathbf{U} pedig egy interpolációs mátrix, melynek elemei az alábbiak szerint adódnak:

$$U_{ij} = \varphi(\mathbf{u}_i - \mathbf{u}_j) \quad (5)$$

Az implementáció során a (4) egyenlet megoldása numerikus problémákat vethet föl, amennyiben az \mathbf{U} interpolációs mátrix kondíciószáma túl nagy; ilyen esetekben a numerikus eredményeket taglaló fejezetben említett megvalósítás figyelmeztetést küld.

Az RBF implementációnak általában az alábbi előnyei vannak, amelyek fölhasználása mellett szólnak:

- az L_2 térben univerzális függvény approximátor;
- a tanulás analitikusan végezhető (egy lineáris egyenletrendszer megoldásával);
- a hálózat komplexitása (és ennél fogva az approximációs képessége) a bemeneti vektor dimenziójával kontrolálható.

3. Numerikus eredmények

A korábban hivatkozott fogyasztásengedélyezési megközelítésben különböző bonyolultságú készülék-szintű fogyasztási idősor modelleket használnak, úgymint Bernoulli iid (independent identically distributed), Markov illetve semi-Markov modelleket [2,3]. Ebben a cikkben a legegyszerűbb eset vizsgálatával foglalkozunk: kétállapotú (Bernoulli-eloszlású) iid idősor esetén a bekapcsoltsági valószínűségbecslésére szorítkoztunk. A rövideb időtávon stacionér idősorok hosszú távon már nemstacionérnek bizonyulnak, pl. a különböző napszakokban más-más bekapcsoltsági valószínűség jellemez bizonyos készülék-típusokat. Ezért a vizsgálat tárgya a bekapcsoltsági valószínűség vizsgálata, mint az idő függvénye.

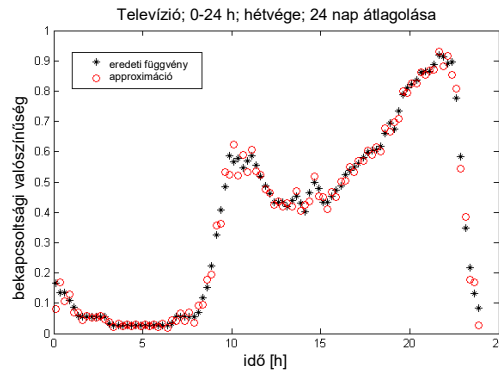
A tanulóhalmazt az ECO Data Set nevű nyilvánosan elérhető adatbázisból állítottuk össze [4]. Az ECO adatbázis fogyasztási idősorokat tartalmaz, amelyek különböző háztartásokban található készülékekhez tartoznak. Az adatbázisban szereplő adatok mintavételi frekvenciája 1 Hz, az adatok gyűjtése 6 hónapig tartott. A bekapcsoltsági valószínűség időfüggését leíró függvény adott pontjait az alábbi előfeldolgozó lépések során kaptuk meg az eredeti mérési eredményekből:

- ON-OFF-izálás (rekvantálás két állapotra) a következő szabály alapján: a várható érték és a csúcserték megegyezik az eredeti idősor várható értékével és csúcsertékekkel, illetve az ON-OFF idősor egyik állapota definíció szerűen zérus.
- Egy adott készülék egymást követő napjainak mérési eredményeit átlagoltuk (eltekintettünk a szezonális hatásától, és úgy tekintettük, mintha különböző készülékek azonos napra vonatkozó mérési eredménye lenne, hiszen az adatbázisban több azonos típusú készülék fogyasztási adata nem volt elérhető).
- A hétköznapokra és a hétvégi napokra vonatkozó mérési eredményeket külön kezeltük (azaz ezen kategóriákban jelentkező eltérő fogyasztási viselkedéstől nem tekintettünk el); 15 perces szegmenseket stacionáriusnak tekintettünk.

Az RBF hálózatot a (4)-es és (5)-ös egyenlet által tanítottuk. A tanítás sikerességét keresztvalidációs eljárással ellenőriztük. Az approximáció minőségét az átlagos négyzetes hiba és átlagos abszolút hiba értékekkel jellemeztük.

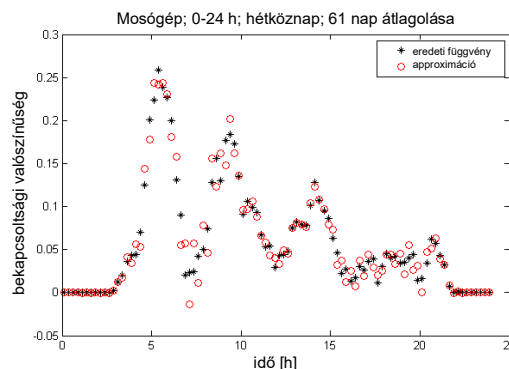
A 3. ábrán egy szórakoztatóelektronikai cikk bekapcsoltsági valószínűségének időfüggése, valamint ennek approximációja látható. A bekapcsoltsági valószínűség értékei egyetlen készülék 24 hétvégi napjának mérési eredményéből származnak a fent leírtak szerint. A keresztvalidáció úgy történt, hogy rendre végig mentünk az eredeti tanulóhalmaz értékein (az ábrán fekete csillag jelöli a tanulóhalmaz pontjait). Az adott kiválasztott értéket tesztelésre használtuk, míg az összes többi függvényértéket a hálózat tanítására használtuk. A tanítást követően a tesztelésre használt

függvényértéket megbecsültük. Az így adódó approximált értékeket piros körrel jelöltük az ábrán. Az approximáció átlagos négyzetes hibája (MSE) $5,98 \cdot 10^{-4}$ -nek, míg az átlagos abszolút hiba 0,0189-nek adódott, amely – figyelembe véve, hogy az approximálandó függvényértékek a 0...1 tartományba esnek – kellően kicsinek tekinthetők a fogyasztásengedélyezési algoritmus szempontjából.



3. ábra Szórakoztatóelektronikai cikk bekapcsoltsági valószínűségének approximációja

A 4. ábrán egy mosógép fogyasztási idősoraira kapott eredmény látható. 61 munkanapot átlagoltunk össze, (illetve a fentebb leírt előfeldolgozó lépések mindegyikét végrehajtottuk) annak érdekében, hogy megkapjuk a bekapcsoltsági valószínűséget időfüggvényként. A teljesítménymutatók az előző példánál bemutatott nagyságrendbe esnek: Az átlagos négyzetes hiba $1,97 \cdot 10^{-4}$, míg az átlagos abszolút hiba $96 \cdot 10^{-4}$



4. ábra Mosógép bekapcsoltsági valószínűségének approximációja

4. Következtetések, további feladatok

Ebben a munkában radiális bázisfüggvényes neurális hálózatot használtunk függvényapproximációra az időpont és a bekapcsoltsági valószínűség közötti leképezés megtanulása érdekében. Bebizonyosodott, hogy ez az eszköz képes megbecsülni a bekapcsoltsági valószínűséget 0,02-nél kisebb átlagos abszolút hiba mellett – a vizsgált esetek vonatkozásában –, amely alkalmassá teszi ezt az eszközt arra, hogy a fogyasztásengedélyezési eljárás számára használható legyen a statisztikai leírók időfüggésének approximációjára.

A jövőben szeretnénk a módszer hatékonyságát megvizsgálni többdimenziós bemenet esetére, ahol az idő mellett a további bemeneti paraméterek a külső hőmérséklet, napsugárzás erőssége, jelenlét, stb. lehet. Ezeket is figyelembe véve az approximáció hibájának csökkenését várjuk.

Köszönetnyilvánítás

Köszönettel tartozunk a kutatás támogatásáért, amely az **EFOP-3.6.1-16-2016-00006** „A kutatási potenciál fejlesztése és bővítése a Pallas Athéné Egyetemen” pályázat keretében valósult meg. A projekt a Magyar Állam és az Európai Unió támogatásával, az Európai Szociális Alap társfinanszírozásával, a Széchenyi 2020 program keretében valósul meg.

Acknowledgement

This research is supported by **EFOP-3.6.1-16-2016-00006** "The development and enhancement of the research potential at Pallas Athena University" project. The Project is supported by the Hungarian Government and co-financed by the European Social Fund.

5. Irodalomjegyzék

- [1] G. Strbac, Demand side management: Benefits and challenges, Energy Policy, vol. 36, Issue 12, pp. 4419-4426, Dec. 2008.
- [2] L. Kovacs, J. Levendovszky, A. Olah, R. Drenyovszki, D. Tisza, K. Tornai and I. Pinter: A probabilistic approach for admission control of smart appliances in Smart Grids, TEAM 2013, pp. 18-21.
- [3] L. Kovacs, R. Drenyovszki, A. Olah, J. Levendovszky, K. Tornai, I. Pinter: A probabilistic demand side management approach by consumption admission control, TEHNICKI VJESNIK-TECHNICAL GAZETTE 24:(1) pp. 199-207. (2017).
- [4] Christian Beckel, Wilhelm Kleiminger, Romano Cicchetti, Thorsten Staake, Silvia Santini: The ECO Data Set and the Performance of Non-Intrusive Load Monitoring Algorithms, Proceedings of the 1st ACM International Conference on Embedded Systems for Energy-Efficient Buildings (BuildSys 2014). Memphis, TN, USA. ACM, pp. 80-89, November 2014.
- [5] S. Haykin, Neural Networks. A comprehensive foundation, Macmillan College Publishing, 2nd editon, New York, 2001.
- [6] M. Altrichter, G. Horváth, B. Pataki, Gy. Strausz, G. Takács, J. Valyon: Neurális hálózatok, Budapest: Hungarian Edition Panem Könyvkiadó Kft., 2006.