

A magyar városok áramfogyasztásának becslése mesterséges neurális hálózat segítségével

A városok mint komplex rendszerek különböző térségi funkciókat tömörítenek. Ezek a funkciók a digitális fejlődéssel egyidejűleg hálózatosodnak, kölcsönhatásban vannak más települések és városok rendszereivel, azonban a helyi jellegzetességük a mai napig megmaradt. A belső struktúrák városról-városra változnak, melyek a globalizálódó világ ellenére sem tudtak nagymértékben megváltozni, hiszen az épített környezet és az egyéb környezeti adottságok az időben lassan változtathatók meg. Ezek a belső struktúrák határozzák meg a bennük élő népesség társadalmi-gazdasági jellemzőit, életminőségét. Mindezek a tényezők pedig a városok energiaigényét is szignifikánsan befolyásolják. Az energiaszükséglet az egyik kulcstényezője a fenntartható fejlődés koncepciójának is. Shahbaz és társai^[2] valamint számos további szerző kiemeli, hogy az energiafogyasztás és a gazdaság energiaintenzitása közvetlen módon meghatározza az adott társadalom jólétét és közvetetten befolyásolja a gazdasági növekedést is. Mindezt a Központi Statisztikai Hivatal tanulmánya is alátámasztja, miszerint minél nagyobb településről lévén szó, annál nagyobb a hozzáadott érték előállításának volumene, ezzel egyidejűleg javul a helyi életszínvonal és a munkanélküliség is kisebb méreteket ölt.^[3] A tanulmány célja, hogy megvizsgálja, milyen tényezők befolyásolják a városi háztartások villamosenergia fogyasztását. A becsléshez kétféle eljárást mutatunk be. Az egyik eljárás egy hagyományos ökonometriai módszer, a regresszióelemzés. A második eljárás egy módszertanilag lényegesen bonyolultabb eljárás, a mesterséges neurális hálózattal történő elemzés.

A HÁLÓZATELMÉLET ÉS A MESTERSÉGES NEURÁLIS HÁLÓZATOK MŰKÖDÉSI ELVEI

A hálózatok olyan rendszerek, amelyek több részből állnak és amelyek interakció révén hatással vannak egymásra, befolyásolva a rendszer működését. A hálózatelmélet alapját a gráfelmélet adja.^[4] A hálózatoknak alapvetően két fő formáját

[1] SZE, Regionális- és Gazdaságtudományi Doktori Iskola, PhD hallgató. Témavezető: Dr. habil. Csizmadia Zoltán, Apáczai Csere János Kar, Szociális Tanulmányok és Szociológia Tanszék.

[2] RASHID, MUHAMMAD SHAHBAZ – OZTURK, ILHAN: Economic growth, financial development, urbanisation and electricity consumption nexus in UAE, in: *Economic Research-Ekonomika Istraživanja*, 2017/1. szám, 527–549.


[3] KÖZPONTI STATISZTIKAI HIVATAL: *A háztartások életszínvonala*, 2015, 2016, <https://www.ksh.hu/docs/hun/xftp/idoszaki/hazteletszinv/hazteletszinv15.pdf>, letöltve 2020. február 07.

[4] BARABÁSI ALBERT LÁSZLÓ: *Network science*, Cambridge University Press, 2016.

különböztetjük meg: a statikus hálózatokat és a dinamikus hálózatokat. Statikus hálózatok azok a hálózatok, melyekben a pontok és az azokat összekötő élek állandók. Ilyen hálózatok például a tudatosan, előre megtervezett, legyártott technikai eszközök, mint például egy napelemes rendszer. Ezek összetevői többnyire állandók, vagy csak kisebb mértékben bővíthetők, és általában meghatározott funkciókat látnak el. A másik hálózattípus a dinamikus hálózatok, melyekben mind a pontok, mind a pontokat összekötő élek képesek megváltozni, ilyenek például az emberi kapcsolatok, de az agyi neuronok kapcsolatai is ide sorolhatók.^[5] A hálózatok kutatása a hálózatok feltérképezésével, keletkezési folyamataik feltárásával és a hálózatokat irányító különböző folyamatok leírásával, kiszámíthatóságával és befolyásolhatóságával foglalkozó tudomány.^[6]

A mesterséges neurális hálózat a gépi tanulás és a mesterséges intelligencia egyik fontos tényezője. A mesterséges neurális hálózatra – akár csak az előzőekben leírtakra – szintén gondolhatunk gráfként, melynek alapját azonban most az emlősök agyában található idegsejtek adják. Tehát ez egy, az emlősök komplex idegrendszeri hálózatának működési elvén alapuló matematikai predikciós és elemző modell, amely komplex tanulási folyamatok végrehajtására képes. Ennek a mesterséges hálózatnak az alapját az úgynevezett perceptron képezi, ami nem más, mint egy idegsejt (neuron) matematikai modellje.^[7]

1. ábra: A perceptron modellje



Az a_j pontok a bemeneti értékek, tehát a valós megfigyelések értékei. A közepe – rejtett rétegek – csomópontok halmaza az első rejtett réteg. Az egyszerű neurális modell egy rejtett réteget tartalmaz. Az egy – output – csomópont pe-

[5] BARABÁSI ALBERT LÁSZLÓ: Network theory-theemergence of thecreative enterprise, in: *Science*, 2005/5722. szám, 639–641.

[6] WANG, JINGJING (ED.): Big data driven similarity based u-model for online socialnetworks, in: *Global Communications Conference*, IEEE, 2017.

[7] ZINTGRAF, LUISA (ed.): *Visualizing deep neural network decisions, Prediction difference analysis*, in arXiv preprintar Xiv:1702.04595, 2017.

dig a kimeneti pont. Minden rejtett réteg perceptronokból áll, melyhez minden bemeneti réteg külön-külön is kapcsolódik. A bemeneti pontok élei továbbítják az információkat a rejtett csomópontok irányába. Az ide érkező információk súlyozásra kerülnek w_j és ezek szolgálnak későbbi információként az aktivációs függvény belső struktúrájának kialakításához. Minden egyes bemeneti ponthoz tartozik egy nettó bemeneti érték, melyet az alábbi módon kapunk meg:

$$Y_{net} = \sum_{i=1}^N Y_i w_i + w_0$$

ahol N a neuronok száma a bemeneti rétegben, az előző (bemeneti) rétegből érkező i -edik neuron információja, az i -edik kapcsolat súlya és a neurális küszöbérték. A neurális küszöbérték biztosítja, hogy a értéke mindig az elfogadási tartományon belül legyen, így növelve a hálózat rugalmasságát.^[8]

Ezt követően a nettó bemeneti érték átalakul kimeneti adattá, melyet a következőképpen kapunk meg:

$$Y_{out} = f(Y_{net}) = f\left(\sum_{i=1}^N Y_i w_i + w_0\right)$$

ahol $f()$ a kiválasztott neuronátviteli funkciót jelenti. A neuron súlya tulajdonképpen felfogható az adott bemeneti érték relevanciájának a teljes modellen belül. A neurális hálózatok a lineáris és nem lineáris összefüggések modellezésére is kiválóan alkalmasak,^[9] melyet többek között az S alakú küszöbérték-függvény tesz lehetővé. Ennek alakja az alábbi paraméteres formában adható meg:

$$Y_{out} = f(Y_{net}) = \frac{1}{1 + e^{-Y_{net}}}$$

a függvény kimenete pedig 0 és 1 közötti értéket vehet fel. Ennek köszönhetően bináris változók becslésére is alkalmas a fenti eljárás.

Végeredményben tehát közel lineáris paraméterekből álló bemeneti neuronokból egy belső nemlineáris paraméterekkel rendelkező tanulási modellt kapunk, melynek output értékei további transzformációknak köszönhetően ugyancsak lineárisává válnak.

[8] CHATTERJEE, SANKHADEEP (ed.): Structural failure classification forrein forced concrete buildings using trained neural network based multi-objective genetic algorithm, in: *Structural Engineering and Mechanics*, 2017/4. szám, 429–438.

[9] A belső függvények struktúrája az aktuális problémától és a bemeneti adatok mérési szintjétől is függ. Mindemellett az egyes függvénytípusok egyidejű kombinációja is lehetséges. WANG, QIANG – SHUYU, LI – RONGRONG, LI: Forecasting energy demand in China and India: Usingsingle-linear, hybrid-linear, and non-lineartime series forecast techniques, in: *Energy*, 2018/161. szám, 821–831.


A fentiekben leírt módszertan és annak egyes részletei a teljesség igénye nélkül kerültek bemutatásra, hiszen önmagában a mesterséges neurális hálózat – avagy a mesterséges intelligencia – belső folyamatai a tanulás, tesztelés, validálás egy rendkívül összetett folyamat, melynek leírása, részletekbe menő bemutatása, magyarázata egy külön tanulmányt igényelne, így itt csak a megértés szempontjából legfontosabb részleteket érintettük.

A VIZSGÁLT MINTA BEMUTATÁSA

Kutatásunk során azokat a városokat vontuk be az elemzésbe, melyek lakosainak száma eléri vagy meg is haladja a húszezer főt. Így összesen ötvenöt város került be a mintánkba. Ebből 18 város megyeszékhely, 37 pedig nem megyeszékhelyű város. Fontosnak tartjuk kiemelni azonban, hogy Budapest – sajátos adottságai miatt – nem került be az elemzésbe, hiszen minden témában kiugró értékeket produkálna. Budapesttel történő összehasonlítást egy külön tanulmányban lenne célszerű kivitelezni.

Lakónépeség nagysága tekintetében a települések 67,3%-a 20 000 és 49 999 lakosságot számláló települések közé tartozik, szám szerint ez 37 várost jelent. Ezt követi 11 további település, melynek lakosság száma az 50 000 és 99 999-es osztályközbe tartozik. Ez teszi ki a mintánk 20 százalékát. Végül 7 nagyvárosunk van, melynek lélekszáma meghaladja a százezer főt, ami a minta 12,7%-t teszi ki

2. ábra: A vizsgált városok klaszterei



Forrás: saját szerkesztés – SPSS Statistics 24 output eredményei alapján

A fenti ábrán a település méretének tekintetében jelenítettük meg az egy háztartásra jutó éves villamosenergia fogyasztás mértékét. A grafikonon jól kivehető, hogy három csoportra bontható a minta. Az első, melyet érdemes kiemelnünk – a narancssárgával bekarikázott gócpont – egy olyan településcsoport, amely területi kiterjedtségéhez képest kiemelkedően magas lakossági elektromos áram fogyasztással bír – Gyál, Érde, Budaörs, Szigetszentmiklós, Vecsés, Szentendre, Gödöllő és Dunaharaszti. Ebből máris látszik, hogy olyan városokról van szó

ebben a klaszterben, melyek mindegyike Pest megyében található. Ez a kiugróan magas érték adódhat egyrészt abból, hogy az itt élő népesség – az országon belüli jó fekvésének, a fővároshoz való közelségének következtében – jó anyagi körülmények közt él, így lényegesen több, akár szórakoztató elektronikai, akár más egyéb magasabb fogyasztással bíró eszközt birtokolhat az átlagos magyar háztartáshoz képest. Másrészt a fogyasztás mértékét tekintve sem beszélhetünk tudatos fogyasztókról – legalább is, ami a pénztárca-kímélő megoldásokat illeti – ami szintén magasabb fogyasztási mennyiséget eredményez háztartásonként.

A másik gócpont ennek némileg az ellenkezője – a zölddel bekarikázott klaszter. Ide olyan települések kerültek, mint Hódmezővásárhely, az ország második legnagyobb települése, öt követi Debrecen, amely az ország harmadik legnagyobbja, lakosságszámban pedig a második. Hajdúböszörmény, az ország negyedik legnagyobb kiterjedtségű települése. Kecskemét, közigazgatási mérete szerint a hetedik legnagyobb az országban, lakónépességben pedig a nyolcadik, végül pedig Szentes. Megfigyelhetjük azonban, hogy ezek a települések energiafogyasztásban – az előző klaszter tagjaival ellentétben – nem képeznek kiugró értékeket az energiafogyasztás tekintetében, kizárólag területi kiterjedtségük miatt alkothatnak külön klasztert. Egy rövid kitérő erejéig teszteltük, hogy önmagában a terület és az egy háztartásra jutó villamosenergia fogyasztás között megfigyelhető-e szignifikáns kapcsolat.

Az elemzésből természetesen Gyál, Érd, Dunaharaszti, Budaörs, Szigetszentmiklós, Vecsés, Szentendre. Gödöllő és Dunaharaszti – a „narancssárga klaszter” – kizárásra került, ugyanis rendkívül torzította volna az eredményeket. Így azonban jól láthatóvá vált, hogy önmagában a terület és a településen megfigyelhető villamosenergia fogyasztás mértéke közötti összefüggés gyenge kapcsolatra enged következtetni ($r = 0,240$), mindemellett azonban az eredmény 5%-os szignifikancia mellett sem szignifikáns. Így arra a következtetésre juthatunk, hogy a fent megfigyelhető csoportosulás mindössze annak a következménye, hogy a keleti területeken a nagyobb kiterjedtség annak köszönhető, hogy lényegesen ritkábban helyezkednek el települések a földrajzi térben, mint Magyarország középső és nyugati területein. Így, mivel „senki földjeként” ma már nem létezhet egy terület, a környező települések közigazgatása alá kerültek, míg más térségben sokkal kevesebb szabad területet kellett felosztani sűrűbben elhelyezkedő települések között. Ezt a hipotézist azzal is alá tudjuk támasztani, ha klaszterelemzést végzünk a megfigyelt települések mérete és egy háztartásra jutó energiafelhasználási mennyisége alapján.

A REGRESSZIÓS ELJÁRÁS ÉS EREDMÉNYEI

Annak meghatározására, hogy mely változók segítségével becsülhető a legpontosabban egy városi háztartás energiafogyasztása, az úgynevezett forward stepwise – legjobban talán „lépésenként előre haladó”-ként fordíthatjuk magyarrá – eljárást alkalmaztuk. Ez az eljárás a független változókat egyesével vonja be az elem-

zésbe. Úgynevezett alulról építkező eljárás, amely minden lépésben a modellépítés folyamata alatt az előre megadott magyarázóváltozók listájából azt a változót vonja be a modellbe, amely a modell illeszkedését statisztikailag szignifikánsan javítja. A folyamat addig ismétlődik, amíg a modell javulása egy bizonyos érték felett marad. Ennek az eljárásnak az a viszonylagos előnye, hogy a modellben végül relatíve kevés számú magyarázó változó marad, ami az eredmények értelmezését nagymértékben könnyíti.

Ennek eredményeképp három független változó került be a modellbe:

- az egy háztartáson belül élők száma – ennek magyarázóereje a modellen belül 49%,
- a nyilvántartott álláskeresők száma, melynek magyarázóereje 28% és
- az állandó népességen belül a hatvanadik életévét betöltött lakosok aránya a városban – ennek értéke 22%.

Ez tehát az a három fontos tényező, amely a modell szerint meghatározza egy városi háztartás energiafelhasználásának alakulását. A továbbiakban a modellek felállítását is erre a három kulcstényezőre alapozzuk. Első körben a regressziós eljárás eredményeit foglaljuk össze.

A modellünk a teljes variancia 51,9%-át magyarázza, ami közepesen jó modellnek mondható.

1. táblázat: Modellparaméterek

ANOVA ^a						
	Model	Sum of Squares	df	MeanSquare	F	Sig.
1	Regression	2,298	3	,766	17,201	,000 ^b
	Residual	1,871	42	,045		
	Total	4,169	45			

a. Dependent Variable: 47 A háztartások részére szolgáltatott villamosenergia mennyisége (1000 kWh/háztartás)

b. Predictors: (Constant), 78 Nyilvántartott álláskeresők aránya (%), 12 Állandó népességből a 60-x évesek aránya (%), 22 Egy háztartáson belül élők száma (fő/házt)

Forrás: Saját szerkesztés – SPSS statistics 24 output eredményei alapján

Az F statisztika szignifikáns léte a nullhipotézis elutasítását vonja maga után, ennek alapján biztosra vehetjük, hogy az általunk bevont változók közt szignifikáns összefüggés van.

A vizsgált változók mindegyike szignifikáns hatást gyakorol a függő változóra. A legnagyobb hatást a városi háztartások energiafogyasztására az egy háztartáson belül élők száma gyakorolja. Amennyiben egy fővel emelkedik az egy háztartásban élők száma, abban az esetben az elfogyasztott áram mennyisége a városi háztartásokban átlagosan 729 kilowattórával emelkedik. Ez az érték a becslés alapján

minimum 67, maximum pedig 1390 kWh lehet 95%-os valószínűség mellett. Az intervallum szélessége minden bizonnyal azzal magyarázható, hogy a háztartások felszereltsége és műszaki cikkeinek korszerűsége is viszonylag széles palettán szóródik az ország egyes térségeiben – Pest megyében pedig kiemelkedően magas volt a fogyasztás aránya.^[10]

A sorban másodikként a legerősebb hatást a városi népességen belül a hatvan év feletti aránya határozza meg. Amennyiben egy város esetében a lakosság körében a hatvan év feletti aránya egy százalékponttal emelkedik, a városi háztartások átlagos energiafogyasztási mértéke 61 kilowattórával csökken. E fordított irányú összefüggés lehetséges oka, hogy azokban a háztartásokban, melyekben jellemzően idősebb generáció lakik, egyrészt lényegesen kevesebb az elektronikai eszközök száma, másrészt az alacsony jövedelem miatt jobban odafigyelnek a fogyasztási kiadásokra.

A harmadik kulctényező a munkanélküliségi ráta a városi lakosságon belül. Amennyiben a lakónépességen belül egy százalékkal emelkedik a munkanélküliek aránya, abban az esetben a városi energiafogyasztás átlagosan 110 kilowattórával csökken. Ez utóbbi tényező hatása 99%-os megbízhatósági szinten is szignifikánsnak bizonyult.

A MESTERSÉGES NEURÁLIS HÁLÓVAL TÖRTÉNŐ BECSLÉS EREDMÉNYEI

Második eljárásunk a mesterséges neurális hálózattal történő becslés. Függő változóként ismét a háztartások energiafelhasználásának adatait vittük be a rendszerbe, a három független változó pedig újra az egy lakáson belül élők száma, a hatvan évet betöltött személyek aránya a teljes lakosságon belül, illetve a regisztrált álláskereső aránya.

A hálózati modellbe három egységet vontunk be, az eljárás során pedig mindössze egy rejtett réteget alkalmaztunk. Ennek lényege, hogy az egy rejtett réteggel rendelkező neurális hálózat bármely folytonos függvény megtanulására képes. A perceptronok aktivációs funkciója hiperbolikus tangens függvényt tartalmazott. Mivel végső soron arra szeretnénk volna választ kapni, hogy mennyire képesek az egyes módszerek bizonyos paraméterek ismerete mellett megbecsülni egy városi háztartás energiaintenzitását, ezért – az előbbi regressziós modellből is – az utolsó 16 város energiafogyasztási értékét töröltük – tulajdonképpen hiányzó értéként definiáltuk.

A modell a megmaradt minta – tehát a 16 város kimeneti adatának törlése után – 70%-át tanulásra, 20%-át tesztelésre, 10%-át pedig érvényesítésre használta fel. A tanulási folyamat a felügyelt tanulási eljárás volt, melynek lényege, hogy az inputokból kreált output értékeket a valós output értékekhez (az ismert villamose-

[10] KAPITÁNY BALÁZS: Kárpát-medencei népszámlálási körkép, in: Demográfia, 2013/1. szám, 25–64.

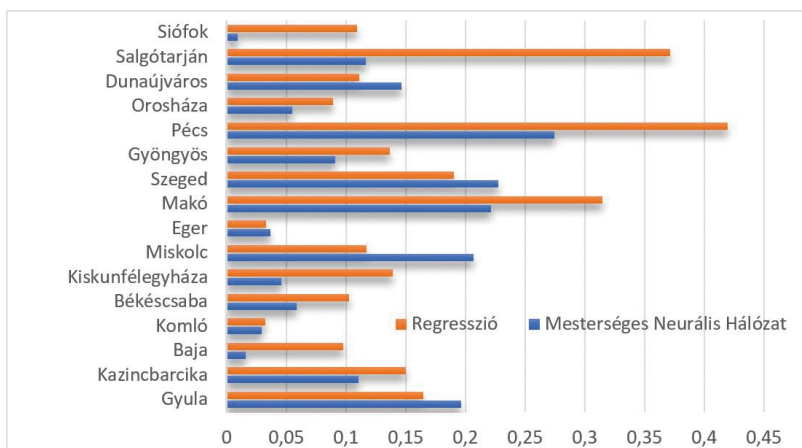
nergia fogyasztáshoz) viszonyítja, és ezek különbségének függvényében módosítja a súlymátrix kapcsolatait. Végül a tanulási folyamat idejét 4 percben maximalizál-
tuk, bár ekkora adatmennyiségnél ennek különösebb jelentősége nincs.

Az egyes ismérvek fontosságát illetően a mesterséges neurális hálózat eltérően ítélte meg. A legfontosabb a hatvan év felettek aránya, ezt követi az álláske-
resők aránya végül lényegesen kisebb mértékben segítette a modellt a becslésben az egy háztartáson belül élők száma.

Ezt követően mindkét kapott modellünket, a regressziós egyenletet és a mesterséges neurális hálózati modellt is arra használtuk, hogy a 16 törölt vá-
ros értékeit kizárólag a független paraméterek felhasználásával megbecsüljük. Az eredeti érték és a becslés eredményeként kapott érték különbségét abszolút értékben a harmadik ábra mutatja be. Az eredeti értéket – amiket előzőleg töröltünk az adatbázisból – most a becslt eredmények pontosságának meghatá-
rozásához használtuk.

Összességében elmondhatjuk, hogy a túlbecslés sokkal inkább a regressziós eljárásra volt jellemző, míg az alulbecslés a mesterséges neurális háló sajátossága volt a modellünk esetében. A regressziós becslés hibáinak átlaga 161,3 kilowattóra volt, míg szórása 112,3 kilowattóra. Ezzel szemben a mesterséges neurális háló hibaátlagja lényegesen alacsonyabb, mindössze 115,2 kilowattóra, szórása pedig 86,4 kilowattóra, ami lényegesen kevesebb, mint a regresszió esetében. Annak megállapítása azonban, hogy egyes városok esetében, mint Salgótarján vagy Pécs, mi okozta a kimagasló regressziós túlbecslést, vagy éppen Siófok és Baja esetében miért tudta rendkívüli pontossággal megbecsülni a neurális hálózat a fogyasztást, míg Miskolc esetében lényegesen túlbecsülte azt, további, leginkább módszertani tanulmányokban lenne vizsgálható.

3. ábra: A valódi és a becslt értékek különbsége abszolút értékben



Forrás: Saját szerkesztés

ÖSSZEFOGLALÁS

Napjainkra nyilvánvalóvá vált, hogy a károsanyag kibocsátás döntő többségét városaink adják, melynek kezelése megfelelő stratégiák és technológiák kidolgozását és alkalmazását követeli meg. Mindehhez azonban meg kell ismernünk ezeknek a folyamatoknak a belső tényezőit, struktúráját. Meg kell értenünk, hogy egy település sajátosságai milyen hatást gyakorolnak egy város energia felhasználására.

Elemzésünkéből kiderült, hogy a magyarországi városok esetében az időskorú emberek aránya, az álláskeresők száma, valamint az egy háztartáson belül élők száma is szignifikánsan meghatározza egy település háztartási szektorának energiaigényét. Ezzel szemben a település földrajzi kiterjedtsége, népsűrűsége nincs befolyással az energiaintenzitásra. Vannak tényezők, mint az országon belüli elhelyezkedés, amely bizonyos mértékig meghatározó tényező lehet, azonban ez településspecifikus.

A Magyarországon fellelhető statisztikai adatok sajnos annál nehezebben hozzáférhetők, minél jobban csökkentjük az adatok területi aggregálását. Ez azt a problémát veti fel, hogy olyan tényezőket, mint a fás utcák száma, építmények átlagéletkora, felújítottság, energiaszerkezet, energetikai besorolás nem elérhető adat, azonban minden bizonnyal szignifikánsan befolyásolja a háztartási energiafelhasználást.

Reményeink szerint a következő népszámlálás adataiból lényegesen pontosabb képet tudunk majd alkotni a fent bemutatott témáról, hiszen a háztartásokon belül használt elektronikai cikkek koráról, számáról is pontosabb képet kaphatunk majd. Addig pedig igyekszünk továbbfejleszteni modellünket és további meghatározó változókat feltárni, hogy tovább növelhessük annak magyarázóerejét és gyakorlati hasznosságát.

FELHASZNÁLT IRODALOM

- BARABÁSI ALBERT LÁSZLÓ: *Network science*, Cambridge University Press, 2016.
- BARABÁSI ALBERT LÁSZLÓ: Network theory - the emergence of the creative enterprise, in: *Science*, 2005/5722. szám, 639–641.
- CHATTERJEE, SANKHADEEP (ed.): Structural failure classification for reinforced concrete buildings using trained neural network based multi-objective genetic algorithm, in: *Structural Engineering and Mechanics*, 2017/4. szám, 429–438.
- KAPITÁNY BALÁZS: Kárpát-medencei népszámlálási körkép, in: *Demográfia*, 2013/1. szám. 25–64.
- KÖZPONTI STATISZTIKAI HIVATAL: *A háztartások életszínvonala*, 2015, 2016, <https://www.ksh.hu/docs/hun/xftp/idoszaki/hazteletszin/hazteletszin15.pdf>, Letöltve: 2020. február 07.

- RASHID, MUHAMMAD SHAHBAZ – OZTURK, ILHAN: Economic growth, financial development, urbanisation and electricity consumption nexus in UAE, in: *Economic Research-Ekonomska Istraživanja*, 2017/1. szám, 527–549.
- WANG, JINGJING (ed.): Big data driven similarity based u-model for online social networks, in: *Global Communications Conference*, IEEE, 2017.
- WANG, QIANG – SHUYU, LI – RONGRONG, LI: Forecasting energy demand in China and India: Using single-linear, hybrid-linear, and non-linear time series forecast techniques, in: *Energy*, 2018/161. szám, 821–831.
- ZINTGRAF, LUISA (ed.): *Visualizing deep neural network decisions. Prediction difference analysis*, in arXiv preprint arXiv:1702.04595, 2017.