

Határkeresztező áramlások számítása neurális hálózat segítségével

Az Európai Unió tagországok villamosenergia-rendszereinek összehangolásához különösképpen fontos az országhatárokat keresztező szállításokra vonatkozó nettó átviteli kapacitás (NTC) és áramlás alapú kapacitászámítási módszertanok pontosítása. Azonban ezen eljárások jelenlegi számítási módjának vannak hiányosságai. Ez a cikk célja, hogy ezeket a hátrányokat a napjainkban fontos kutatási terület, a soft computing módszerek segítségével kiküszöbölje. A módszerek közül kiemelkedőek a neurális hálók, melyek számos területen sikeresebbek lehetnek, mint a korábbiak. A kutatásunk során megvizsgáltuk, hogy a mesterséges neurális hálók hogyan könnyíthetik meg a határkeresztező áramlások számítását.

To coordinate the electricity system of the member states of the European Union, it is important to use the Network Transfer Capacity (NTC) and flow-based capacity calculation methodologies. However, the current calculation of these values has deficiency. We want to eliminate these inaccuracies by means of soft computing methods. Among these methods, neural networks are prominent, which can be more successful in many fields than previous methods. In our research, we have investigated how artificial neural networks can facilitate the calculation of cross-border flows.

Kulcsszavak: határkeresztező áramlás, soft computing, neurális hálók, gépi tanulás, hálózatszámítás, load flow, kapacitászámítás

1. HATÁRKERESZTEZŐ ÁRAMLÁSOK

Jelenleg a hálózati áramlások pontos számításához determinisztikus load flow algoritmust használnak. Pillanatnyilag ez a bevett módszer a hálózati teljesítmények számításához és a hálózat analízishez, melynek segítségével meghatározható a teljesítményáramlás egy összetett rendszerben. Az algoritmus megadja a hálózat minden gyűjtősinére a feszültség amplitúdóját és az áramhoz viszonyított szögét. [1] A számításhoz teljeskörű hálózatmodellre van szükség, tovább nehezíti ezt, hogy a módszerhez szükséges jövőbeli értékek meghatározása, amelyet az algoritmus közelítés vagy becslés segítségével ad meg.

A load flow számításnak is több fajtája van, mivel egy-egy algoritmus más-más előnnyel szolgálhat. A legnépszerűbb módszer a Newton-Raphson algoritmus, mely az számítás indulásakor feltételezi az ismeretlen értékeket, majd ezeket pontosítja futás közben. A másik népszerű módszer a Gauss-Seidel algoritmus, melynek nagy előnye az előzővel szemben, hogy megoldásához kevés memória kell és nem szükséges mátrix műveletek megoldása. Természetesen ezeken kívül is léteznek load flow algoritmusok, de a számítógépes szoftverek legtöbbször az említett kettő módszerek keverékét használják. Ilyenkor a két algoritmus előnyei egyszerre kihasználhatóak.

A határkeresztező áramlások jelenlegi kalkulációs módszerei nem tökéletesek, nagy hálózatoknál jelentős számításigénnyel járnak. A komplex mátrix műveletek elvégzése miatt nem csak lelassulnak az algoritmusok, hanem nagyon nagy memória igényük is van, ami nagyban megnehezíti az áramlások számítását. Ez a tulajdonság azért nem elhanyagolható, mivel az Európai Unió regulációs követelményei egy teljes Európára kiterjedő közös hálózatmodell alkalmazását írják elő. Ennek köszönhetően még aktuálisabb a kérdés, annak ellenére, hogy rendelkezésre álló számítási kapacitás folyamatosan növekszik.

A jelenlegi load flow algoritmusoknak még egy nagy hátránya, nem lehet őket futtatni adathiányos hálózaton. Csak abban az esetben lehet használni őket, ha minden adatot pontosan ismerünk a gyűjtősinék és az azokat összekötő vezetékek fizikai tulajdonságairól. A load flow algoritmus csak azokkal az adatokkal számol, amelyeket ismer, így a hiányos hálózaton az elvégzése lehetetlen. Ezen hátrányok kiküszöbölése érdekében vizsgáltuk meg azt a lehetőséget, hogy az áramlások számítását soft computing módszerek segítségével végezzük el.

2. SOFT COMPUTING MÓDSZEREK

Napjainkban vitathatatlanul a tudomány összes területére betört a mesterséges vagy gépi intelligencia használata. Főleg azoknál az alkalmazásoknál, ahol olyan problémák megoldása a feladat, amelyeket a hagyományos módszerekkel nem lehetne megoldani, valamint korábbi problémák gyorsabb, így – egy rendelkezésre álló szűk időtartományon belül – jobb megoldására használhatóak. Ilyen területek például az döntéstámogatás, -elemzés, statisztika és a szabályozástechnika. [2]

2.1 Alapgondolatuk

Mindegyik soft computing módszer a következtetési folyamatot, emberi problémamegoldást vagy a heurisztikus megközelítéseket modellezi, ezért is hívjuk őket intelligens módszereknek. [2] A soft computing módszereket különböző csoportokba sorolhatjuk őket, azonban alapgondolatuk megegyezik, amely a biológiai inspirációjú információfeldolgozás.

2.2 A soft computing főbb fajtái

A soft computing módszereket különböző csoportokba soroljuk:

A **fuzzy rendszerek** bizonytalan bemenő adatok esetén, determinisztikus jellegű folyamatokat közelítő következtetéssel modellezi a problémamegoldást. Jól strukturált, azaz kis egységekre, összefüggésekre bontható numerikus ismeretek feldolgozására alkalmas, azonban nem megfelelő optimalizálásra.

A **neurális háló** azon módszer, mely példák alapján tanulja meg az objektumok vagy minták felismerését. Példákat feldolgozva az adatok közti rejtett összefüggések felismerésével asszociáción alapuló, illetve optimalizációs feladatokat old meg. Jól alkalmazható rosszul strukturált, numerikus jellegű ismeretek feldolgozásához.

A **genetikus algoritmusok** számos tulajdonsága megegyezik a neurális hálókéval. Ez a módszer is jól használható rosszul strukturált, numerikus jellegű feladatok esetén, és a genetikus algoritmusok is a tanulás tulajdonságát használják a feladatok megoldásához.

A **szakértői rendszerek** az emberi problémamegoldást modellezik egy szűk szakterületen. Jól használható strukturálható szimbolikus ismeret esetén. Logikai kifejezések, objektumok segítségével leírható feladatokat kezel, valamint a módszer precíz, deduktív, esetleg induktív következtetést alkalmaz. A fuzzy-rendszerekhez hasonlóan ez sem alkalmas optimalizálásra.

2.3 A mesterséges neurális hálózat

A kutatás során a soft computing módszerek közül a mesterséges neurális hálózat segítségével végeztük el a számításokat. Ezért ebben az alfejezetben a neurális hálózatok tulajdonságait mutatjuk be.

A mesterséges neurális háló egy olyan speciális információfeldolgozó rendszer, amely sok egyszerű feldolgozóelemből áll. Ezen elemek egymással irányított, súlyozott kapcsolatokkal vannak összekötve. A bemeneti adatok ezen a hálón mennek keresztül, mégpedig minden egyes elem a hozzá érkező információt feldolgozza és a kapcsolatnak megfelelő más feldolgozóelemekhez továbbítja. A háló elemeit különböző választható függvények határozzák meg, az elemek közötti kapcsolatokat pedig a kapcsolat erősségét kifejező súlyok jellemzik. Ezen súlyokat a rendszer a nagy számú bemenet-kimenet párok alapján állítja be.

A neurális hálók legfontosabb tulajdonságai a következők:

- Tanulóképesség: egy tanuló algoritmus segítségével a bemenetére adott példákban tanul mindaddig, amíg a megfelelő bemenő és kimenő adatként elő nem állítja.
- Párhuzamos feldolgozás: A bemenetek feldolgozása gyorsan megy végbe, mivel egyes

elemek párhuzamosan is tudnak számításokat végezni.

- Osztott tudásábrázolás: A legtöbb neurális hálóban a tudás az elemek közötti kapcsolatok súlyában van szétosztva.
- Asszociatív információátvitel: A neurális háló a minták információtartalmát tárolja, ezért az újabb mintához könnyen társítható, hívható elő a rendszerben tárolt hasonló minta tartalma. [2]

3. HÁLÓZATI ÁRAMLÁSOK SZÁMÍTÁSA

A kutatásunk célja egy olyan algoritmus meghatározása volt, amely előzetes adatok alapján meg tudja határozni Magyarország határkeresztező áramlásainak mértékét.

3.1 Adatok

A keresett algoritmus meghatározásához a neurális hálót nagy számú adat segítségével tanítani kell. Nagyon fontos olyan mért értékeket használni, amelyek azonos időtartományt fednek le és azonos időpontokban kerültek felvételre. A háló tanításához az ENTSO-E [3] és a MAVIR Zrt. [4] honlapján található publikus adatokat használtuk.

A fizikai áramlásokat a bruttó és nettó erőművi termelés, a bruttó tényleges rendszerterhelés, valamint az átviteli kapacitás következő napi előrejelzése alapján határoztuk meg. Azaz egy olyan algoritmust szeretnénk megkapni a neurális háló segítségével, amely ezen adatok közötti kapcsolatot írja le.

Mindegyik adatsor a 2017-es évi értékeket tartalmazza, óránkénti felbontásban, ami összesen 8760 értéket jelent. Az előre jelzett átviteli kapacitás és a fizikai áramlások Magyarország és egyes szomszédos országok (Ausztria, Horvátország, Románia, Szerbia és Szlovákia) közötti értékek. A rendelkezésre álló 8760 darab összetartozó értéket három csoportba bontottuk, úgy, hogy három egymás követő érték közül mindegyik különböző csoportba kerüljön. Az így kapott csoportok 2920 darab adathalmazt tartalmaz. Az egyik csoporttal elvégeztük a rendszer tanítását, másikkal a kapott algoritmus tesztelését és a harmadik csoportot egyéb diagnosztikákhoz vettük külön.

A MAVIR Zrt. honlapján elérhetőek a Magyarország és szomszédos országok közötti fizikai áramlási értékek, mindkét irányban (export-import).

A kutatás során kettő esetet vizsgáltuk. Az első, amikor csak a Magyarország felé tartó áramlások értékeit kerestük az algoritmussal, ilyenkor a tanításnál is csak a Magyarország felé tartó áramlás értékekkel tanítottuk a hálózatot. Ebben az esetben 9 darab bemenő érték alapján szeretnénk meghatározni 5 darab keresett adatot. Azért ezt az irányt választottuk, mert Magyarország legtöbbször villamos energia importőr, gyakran szinte az összes irányból (határmetszéken).


A második esetben mind az országból kimenő, mind az országba érkező áramlás értékeit meghatározására használtuk a neurális hálót. Az első esettel ellentétben itt is már a tanításnál is mind kettő irányhoz tartozó értékek segítségével tanítottuk a rendszert. Ilyenkor 15 darab bemenő adatot használtunk 10 darab adat meghatározásához.

1. Táblázat. A bemeneti és kimeneti adatok

Bemeneti adatok	Bemeneti adatok mértékegysége	Kimeneti adatok
Magyarország pillanatnyi villamosenergia fogyasztása.	Bruttó tényleges rendszerterhelés [MW]	Fizikai áramlások [MW] Magyarország határait metsző távvezetéseken pillanatnyi átfolyó teljesítménye.
Magyarország erőművei bruttó termeléseinek összege.	Bruttó tervezett erőművi termelés [MW]	
Magyarország erőművei bruttó termeléseinek összege.	Nettó tervezett erőművi termelés [MW]	
Magyarország és a szomszédos országok közötti határokon keresztül szállítható maximális teljesítmény.	Átviteli kapacitás előrejelzés [MW]	

3.2 A neurális hálózat tulajdonságai

A keresett algoritmus meghatározásához egy négy rejtett réteget tartalmazó kaszkád előreccatoló (cascade-forward backpropagation) neurális hálót használtunk, amelyet a MATLAB dokumentációja [5] javasolt adatsorok közötti kapcsolat kutatásához. Ezeken felül a hálózat tartalmaz egy kimeneti réteget is, így a teljes hálózat összesen öt rétegből áll, amely összesen 34 neuront tartalmaz a 1. Ábrán látható elosztásban.



1. Ábra. A neurális hálózat rétegei és a neuronok száma rétegenként


A tanításhoz a Levenberg-Marquardt algoritmust választottuk, mivel ez a leggyorsabb módszer a közepes méretű előreccatoló neurális hálózat tanításához. [6]

3.3 A neurális hálózat tanítása

A hálózat létrehozása után a következő lépés a rendszer tanítása. Ilyenkor a háló a beadott bemenet és kimenet párok segítségével beállítja a neuronok közötti kapcsolatok súlyát. Ezen súlyok segítségével kapjuk azt az algoritmust, amely végül a bemenő adatok függvényében meghatározza a határkeresztező áramlások értékét.

Ez a folyamat nagyon hosszadalmas tud lenni, mivel a súlyok minél pontosabb meghatározása érdekében nagy számú adatot kell a hálózat bemenetére küldeni. Az algoritmus pontosságát szolgálja még a nagyobb réteg és neuron szám is, azonban ezek mind tovább növelik a tanulás időtartamát.

A tanítás sikerességét regresszió ábrázolásával tehetjük láthatóvá. A neurális hálózat a futtatás közben a várt adatok és a kimeneti eredmények közötti lineáris viszonyt jelöli a 2. Ábrán a színes egyenes. A program kiszámította, hogy mekkora a legnagyobb eltérés az általa számított egyenes és a megadott adatpontok között, ebből következtethetünk, hogy mennyire pontos a neurális hálónk, mennyire tudja megtalálni a keresett összefüggést.

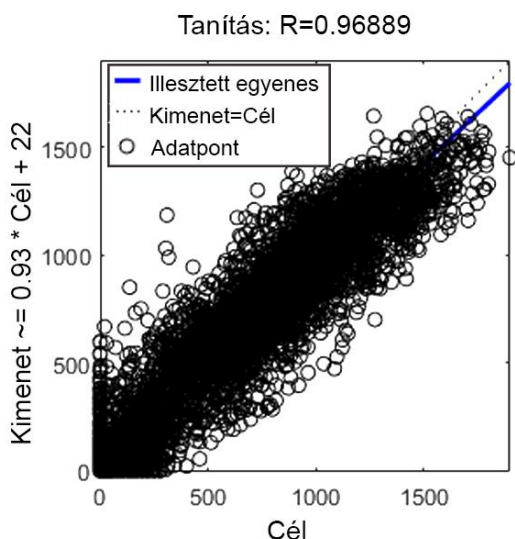


2. Ábra. A tanítással kapott, a cél értékek, valamint a tanítás által meghatározott lineáris egyenes

A 2. Ábrán látható példa grafikonokon a kék egyenes mutatják a legjobban illeszkedő regressziós egyenest, matematikai leírására szolgál az R érték, amely megmutatja, hogy mennyire lineáris a kapcsolat a várt adatok és a hálózat kimenete között. Ha az R=1, akkor közel lineáris az összefüggés. [7]

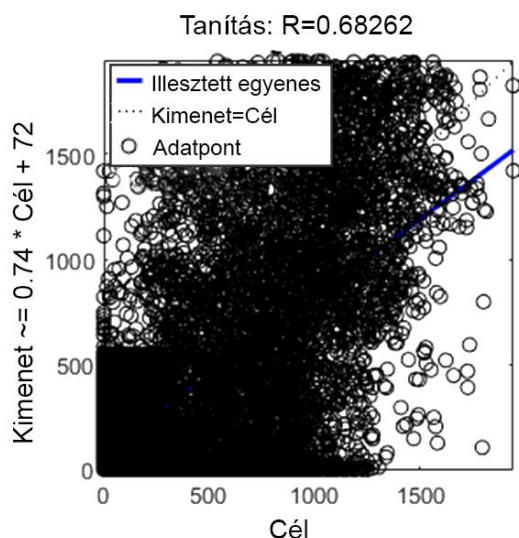
Abban az esetben, amikor csak a Magyarország felé folyó áramlásokat akartuk meghatározni, akkor a 3. Ábrán látható regressziós eredményeket kaptuk.

A kapott ábra alapján megállapíthatjuk, hogy a neurális háló jól felismerte az adatok közötti összefüggést, így a tanítás után az R értéke közelebbi a kívánt egy értékhez.



3. Ábra. A Magyarország felé tartó áramlások számított regressziója

Azonban, ha a határokon mindkét irányba átfolyó áramlásokhoz tartozó adatok alapján tanítjuk a hálózatunkat jóval rosszabb eredményt kapunk, amely a 4. Ábrán is látható.



4. Ábra. A mindkét irányú áramlásokhoz számított regresszió

Megfigyelhetjük, hogy az adatpontok elhelyezkedése nagyban különbözik az előző esethez képest, aminek hatására a hálózat kevésbé talált összefüggést. Így az R értéke csak 0.68262, ami jóval kisebb, mint az előző esetenél felvett.

3.4 A kapott algoritmus tesztelése

A tanítás után meg kell bizonyosodnunk arról, hogy az algoritmus használható olyan bemeneti adatokra is, amelyek nem szerepeltek a betanítás során az adatsorokban. Ezzel biztosítjuk, hogy a neurális háló által adott algoritmus, nem csak a betanításra használt adatokhoz ad megfelelő eredményt, hanem az előfordulható összes értékre. A teszteléshez 2920 darab adathalmazt használtuk.

A tanítás által meghatározott súlyozás kiszámította a Magyarország és a szomszédos országok közötti határokon átmenő áramlások értékét.

3.5 Az eredmények értékelése

A teszteléssel kapott eredményeket a valós eredményekkel hasonlítottuk össze. A kapott és a várt eredményeknek abszolút és relatív különbségét képeztem, hogy ez alapján vonjunk le következtetést.

A relatív különbséget a (1)-es képlet használatával számítottuk ki. [8]

$$\text{Relatív eltérés}(x,y) = \frac{\text{Abszolút eltérés}}{f(x,y)} \quad (1)$$

ahol

$$f(x,y) = \max(|x-y|) \quad (2)$$

amit behelyettesítve a

$$\text{Relatív eltérés}(x,y) = |x-y|/\max(|x-y|) \quad (3)$$

A (3)-as képlettel meghatározott értékek alapján megkaphatjuk, hogy a load flow vagy a neurális hálózat számította ki a kívánt értékeket kisebb hibával. A számított relatív eltéréseket három csoportba soroltuk. Első csoport, amely kisebb, mint a load flow számítás relatív hibája. Ebbe a csoportba a Magyarország felé tartó áramlásokra kapott értékek 15,53%-a tartozik bele. A következő kategóriába a 0,1222% és a 1,5%-os hibahatárok közötti értékek tartoztak, a számított értékek 26,22%-a számított ide. Az utolsó csoport pedig a 1,5%-nál nagyobb hibával kiszámított pontok halmaza, ebbe a meghatározott értékek 58,25%-a tartozott. Azért volt szükség egy köztes csoportot létrehozni, mert annak ellenére, hogy a load flow számításnak 0,1222% a hibája, a load flow-hoz használt adatok nem pontosak. Egyes hálózati elemek modellezésénél közelítésekkel élünk, illetve a valós értéke mérésénél ideálisnak veszünk bizonyos elemeket és tényezőket. A MAVIR Zrt. Üzemi Szabályzata alapján a nemzetközi távvezetéseken a teljesítmény mérésének pontossága 0,5% és 1,5% között kell lennie. Ez a hiba az adatok alapján számított load flow értékekhez is hozzáadódik, amivel tovább romlik az ilyen módon kapott eredmények pontossága.

Ha mindkét irányú határkeresztesző áramlásokat vizsgáljuk, megfigyelhetjük, hogy a 0,1222% alatti hibával rendelkező értékek száma, az összes érték 28,29%-a. A 0,1222% és 1,5% közötti hibájú értékek aránya 46,26%. A fentiekből adódik, hogy a 1,5% hibahatárnál a pontok 22,45%-a nagyobb hibával lett kiszámolva. Ezen eredményeket a 2. Táblázat tartalmazza.

Következőekben a kapott és elvárt értékek különbségét a határkeresztesző áramlások értékének biztonsági tartalékával hasonlítottuk össze. A MAVIR minden magyarországi határon átvihető teljesítményre megad egy margint (TRM), amelyen belül nem kerül publikálásra az eltérés. A TRM nagysága operatív időszakban 200 MW, míg tervezési időszakban 500 MW.

2. Táblázat. A határkeresztező áramlások számított értékeinek hibájának eloszlása.

Hiba kategóriák	Import irány	Import és export irány
Kevesebb mint 0,1222%	15,53%	28,29%
0,1222% és 1,5% közötti	26,22%	46,26%
Több mint 1,5%	58,25%	22,45%

Az első vizsgált esetben, amikor csak a Magyarország felé tartó áramlásokat vizsgáltuk a kapott értékek 47,30%-ban voltak bent a 200 MW-os határon belül, valamint a számított értékek 49,58%-e nem lépte át a 500 MW-os határt.

A másik esetben ezek az értékek is megnövekedtek, ilyenkor az számított értékek 76,76%-a nem lépte át a 200 MW-os határt, továbbá az 500 MW-os határon belül szinte mindegyik számított érték bent volt. A pontosan 94,92% volt az előírt határon belül.

3.6 Következtetések

A fenti eredményeket ismeretében megállapíthatjuk, hogy a neurális hálózat nem tudja pontosabban meghatározni a határkeresztező áramlások értékeit, mint a load flow algoritmus, azonban az előírt korlátokon belül tudja számítani a kívánt értékeket. A soft computing módszernek egy nagy előnye van az eddig használt algoritmussal szemben, mégpedig, hogy a load flow számítást csak pontosan meghatározott hálózaton lehet elvégezni. A neurális hálózat ezzel szemben, akár egy hiányos hálózaton is jó becslést tud adni a hálózati áramlásokra, különösen a jövőbeli, eredendő bizonytalan scenáriók kapcsán.

A neurális hálózatot tovább lehetne finomítani, megvizsgálni, hogy egyes számítási algoritmusok hogyan befolyásolják a számított értékeket. Az kimeneti értékeket tovább lehet pontosítani, ha további rétegeket és neuronokat használunk a tanuló hálózatban. Természetesen ez a számítási idő és memóriaigény növekedésével járna. A hálózati korrigálásán kívül még újabb magyarázó változók (pl.: németországi megújuló energiaforrások termelése) felvételével lehetne a kapott eredményeket a valós értékekhez jobban közelíteni.

A fentiek alapján úgy gondoljuk, hogy habár a neurális háló kiváltani nem fogja a load flow számítási módszereket, a jelenlegi módszer számítását tudná megkönnyíteni, úgy, hogy a Newton-Raphson módszer kezdeti értékeihez egy viszonylag pontos becslést ad. Ezáltal gyorsabb lehet az algoritmus lefutása.

A továbbiakban mindenképpen szükséges foglalkozni a neurális háló és a load flow számítási módszereinek összehasonlításával. Érdemes lenne megvizsgálni, hogy mennyire tudja meggyorsítani, esetleg pontosítani a számítást, ha a két módszert egyszerre használjuk.

4. ÖSSZEFOGLALÁS

A kutatás során megvizsgáltuk a neurális hálózatok alkalmazhatóságát határkeresztező áramlások számításánál. A mesterséges neurális hálókat a gépi tanulás módszerét használva, a bemeneti és cél adatpárok segítségével, olyan összefüggéseket találnak a vizsgált tulajdonságok között, amellyel kiszámíthatóak a keresett határkeresztező értékek.

A cél az volt, hogy egy olyan módszert találjunk, amely ki tudja küszöbölni a jelenlegi load flow algoritmusok egyre inkább élessé váló hiányosságát, miszerint csak hiánytalan hálózaton futtathatók. Emellett igen nagyméretű hálózatok (pl. a közös európai hálózati modell) esetében az új módszertani megközelítés segítheti a kapacitászámítási eljárások robusztusságának megőrzését a reguláció által támogatott követelmények teljesítésénél.

A számítások alapján kimondhatjuk, hogy – ha bár nincsen minden aspektusból megvizsgálva – a neurális hálózat a tartalékhoz képest kicsi hibával tudja előrejelezni a keresett értékeket, azaz jó eséllyel orvosolni tudja a load flow számítás ezen hiányosságát.

5. IRODALOMJEGYZÉK

- [1] **Grainger, J., Stevenson, W.:** *Power System Analysis.* New York: McGraw-Hill. ISBN 0-07-061293-5. 1994.
- [2] **Borgulya István:** *Neurális hálókat és fuzzy-rendszerek.* Dialóg Campus Kiadó, Budapest-Pécs, 1998.
- [3] **ENTSO-E Transparency Platform:** <https://transparency.entsoe.eu>
- [4] **MAVIR Zrt. Adatbuzlikáció/Aktuális VER adatok:** <http://mavir.hu/web/mavir/eromuvi-termeles-forrasok-megoszlasa-szerint-netto-uzemiranyitasi>
- [5] **The MathWorks Inc. cascadeforwardnet Documentation** <https://www.mathworks.com/help/nnet/ref/cascadeforwardnet.html>
- [6] **The MathWorks Inc. Levenberg-Marquard backpropagation Documentation** <https://www.mathworks.com/help/nnet/ref/trainlm.html>
- [7] **Sebastian Raschka:** *Single-Layer Neural Networks and Gradient Descent* http://sebastianraschka.com/Articles/2015_singlelayer_neurons.html
- [8] **Törnqvist, Leo; Vartia, Pentti; Vartia, Yrjö:** *How Should Relative Changes Be Measured?, The American Statistician, 39 (1): 43–46, doi:10.2307/2683905* 1985.
- [9] **Wei-Tzer Huang; Kai-Chao Yao; Chun-Ching Wu:** *Real-time calculation of power system bus voltage using a hybrid approach combining the Newton-Raphson method and dynamic programming.* 2015 <https://doi.org/10.1002/tee.22162>