

Lokális hálózatok tranziensének vizsgálata és felismerése mesterséges intelligenciával Local networks transient measurement and recognition with Artificial Intelligent

Kohanecz Ádám¹ Kozma Dávid Márk², Deli Tamás³

¹Műszertechinikai és Automatizálási Intézet, Óbudai Egyetem [1084 Budapest, Tavaszmező utca 17. , Magyarország], kadam1265@gmail.com

²Műszertechinikai és Automatizálási Intézet, Óbudai Egyetem [1084 Budapest, Tavaszmező utca 17. , Magyarország], kozmadavidmark@gmail.com

³Szélessávú Hírközlés és Villamosságtan tanszék, Budapesti Műszaki és Gazdaság Tudományi Egyetem [1111 Budapest, Egy József utca 18. , Magyarország], delitamas@edu.bme.hu

Absztrakt: Napjainkban jellemző az élet minden aspektusában való optimalizációs szándék, ebbe beletartozik az otthonunk energia felhasználási hatékonyságának növelése is. A cikkben bemutatunk erre a problémára egy megoldást, melyet a mért eredmények alapján mesterséges intelligencia segítségével dolgoztunk fel.

A dolgozatban ismertetünk mérési eredményeket az elektromechanikus és elektromágneses tranziensekre. Perezentálunk egy speciális visszacsatolt neurális háló általi klasszifikációt, mellyel azonosítani tudjuk a hálózaton lévő aktív fogyasztókat.

Az írás végén bemutatjuk a megoldás felhasználhatóságának határait és kitekintést nyújtunk további megvalósítási módszerek felé.

Kulcsszavak :Tranziensmérés helyi hálózaton, Mesterséges intelligencia, Háztartások energia felhasználásának csökkentése

Abstract: Nowadays it is typical to optimize all aspects of life that includes increasing the energy efficiency of our home. In the article, we introduce a solution to this problem which was processed with the help of artificial intelligent based on the measurement results.

We describe the measurement results for the electromechanical and electromagnetic transient in the paper. We present a special recurrent neural network classification to identify the active devices on the local electrical system.

At the end of the article, we submit limits of applicability of the solution, and we provide an overview of further realisation methods.

Keywords: Transient measurement on local networks, Artificial Intelligent, Home power consumption reduction

1. Bevezetés, avagy honnan indult a projekt

Manapság egyre nagyobb hangsúlyt fektetünk a zöld gondolkodásra és életvitelre. Villamosipari szempontból a zöld gondolkodás egyik legfontosabb területe a fogyasztás optimalizálása. Az iparban valóságos verseny alakult ki, hogy minél több feladatot tudjon egy adott készülék minél kisebb energiafelhasználás mellett ellátni. A másik fontos területe a modern világunknak az információ. Az információt nagyon sokféle módon lehet felhasználni, az első gondolatra visszakanyarodva például felhasználhatjuk a gyűjtött információkat a fogyasztás optimalizálásának érdekében egy adott készülékben, vagy javaslatokat tehetünk a fogyasztás alapján bizonyos eszközök modernizációjára vagy cseréjére.

A mi ötletünk ebből a két területből tevődik össze. Az optimalizálás és az információ. Minden háztartásban egyre több elektromos eszközt használunk az életünk megkönnyítése és a magunk szórakoztatása érdekében. Az elektromos eszközök mennyiségének növekedése fogyasztásnövekedéshez vezet, ami a fogyasztó pénztárcájának nem kedvező, de emellett még földünket is károsítja a túlzott energiafelhasználás. Ezekben a problémákban lehet a fogyasztó számára segítséget nyújtani az információ felhasználásának segítségével.

Minden elektromos eszköz, amely a hálózatra csatlakozik, önálló, az eszközre jellemző „lábnyommal” rendelkezik. Miből is tevődik össze ez a „lábnyom”? Az első és talán az átlag felhasználó számára is a legszembe tűnőbb paramétere egy eszköznek a fogyasztása. A hálózaton a legtöbb elektromos eszköz eltérő fogyasztással rendelkezik. A második fontos jellemző szintén a fogyasztáshoz tartozik, ez a felvett áramnak a jelalakja. Ez azért fontos mert eszközönként nagyon különböző áram jelalakok léteznek, például egy mosógép motorja ingadozva veszi föl az áramot annak függvényében, hogy a ruha hogyan kavarog benne, egy egyszerű kapcsolóüzemű tápegység pedig a klasszikus elméleti áram jelalakjára ráülteti a kapcsolófrekvenciát is eltérő mértékben, még akkor is, ha a tápegység rendelkezik bemeneti szűréssel. A harmadik jellemző a feszültség a hálózaton, az előbb említett kapcsolóüzemű eszközök például képesek adott esetben nagymértékű zajt ültetni a hálózatra, ami szintén egyedi azonosítója lehet egy-egy eszköznek. Végül de nem utolsósorban a tranzienis jelenségek is mind áram és mind feszültség tartományban sokat elárulhatnak egy eszközről, és akár annak műszaki állapotáról is.

Ezek alapján egy hálózatról és az arra kapcsolódó eszközökről nagyon sok információt ki lehet deríteni egy eszközzel, ami áramot és feszültséget mér a háztartás betáplálási pontján. Ezzel a sok információval viszont egy ember nem sokat tud kezdeni önmagától, itt jön képbe a mesterséges intelligencia, amely ezeket az információkat megkapja és ezek alapján tanulja meg, hogy melyik eszköznek mi is a „lábnyoma” a hálózaton. Miután a neurális hálózat meg tudja különböztetni az éppen bekapcsolt eszközöket, rögtön hozzájuk is lehet rendelni a fogyasztásukat mert fogyasztás alapján könnyű szétválogatni darabszámban a bekapcsolt eszközöket.

Rövid bevezetés után felmerül a kérdés, hogy miért is jó a felhasználó számára, ha egy eszköz adatokat gyűjt a hálózatról? Azért jó, mert így pontos eszközökre lebontott elektromos fogyasztási statisztikákat tud csinálni a hálózatról anélkül, hogy minden eszközt külön okos hosszabbítóba csatlakoztatná, vagy folyamatosan külön-külön méregetné az eszközeinek fogyasztását. Pontos percekre lebontott statisztikát kaphat, hogy melyik eszközt mennyit használta, ez mennyi energiafelhasználást jelentett és akár az adott valutára lebontva ez mennyibe kerül neki. Javaslatokat tehetünk akár bizonyos eszközök cserélésére, korszerűsítésére egy webes felületen keresztül akár felhasználóra szabott megtérülési számítással is.

Egy olyan eszközt és hozzá tartozó szoftveres környezetet tervezünk, amely képes az előbb említett mérésekre, valamint képes a felhasználó számára átláthatóbbá tenni a háztartáson belüli villamosenergia fogyasztást és segíteni a környezettudatosabb fogyasztásban és gazdaságosabb eszközhasználatban.

2. Tranziensek, zajok vizsgálata a hálózaton


Mielőtt a zajokat, tranzienseket megtudnánk különböztetni egymástól előtte meg kell mérni őket és meg kell ismerni a jelalakjukat, amire majd a mesterséges intelligenciát betanítjuk. A tanításhoz nagy mennyiségű mintát kell rögzíteni, hogy pontos legyen a modell.

A méréseket több körben végeztük el és különböző tranzienseket rögzítettünk a hálózaton. Annak érdekében, hogy megtudjuk határozni mit is érdemes mérni. Végeztünk méréseket feszültség, áram frekvencia és idő tartományra is.

2.1 A jelalakok vizsgálata a hálózaton

A mérés során szeretnénk volna meg állapítani, hogy milyen mérőáramkört tervezünk és azt is, hogy mi alapján lenne érdemes a betanítást végezni (feszültség vagy áram jelalak alapján és frekvencia vagy az időtartomány hordoz több információt.)

A méréshez egy mű hálózatot hoztunk, létre, hogy a villamos energia hálózattól függetlenül tudjunk méréseket végezni. A mérés előlépéseként összeállítottuk a mérő kört majd oszcilloszkóp segítségével megmértük az aktuális feszültség és áram zajsztintjét, hogy tudjunk kompenzálni vele, majd bekapcsoltuk az izzót és felvettük az áram és feszültség jelalakokat.




Ábra 1
Mérési elrendezés




Ábra 2
Kompakt fénycső Áram-idő jelalak




Ábra 3
LED lámpa Áram-idő jelalak




Ábra 4
Kompakt fénycső Áram-frekvenciatartomány



Ábra 5
LED lámpa Áram-frekvenciatartomány



Ábra 6
Kompakt fénycső Feszültség-frekvenciatartomány




Ábra 7
LED lámpa Feszültség-frekvenciatartomány

A mérés során azt tapasztaltuk, hogy a betanításhoz legjobban használható jelalak az idő áram jelalak, mert ezen mérés során még két hasonló elven működő eszköz is könnyedén megkülönböztethető egymástól. A mérési eredményekből az is megállapítható, hogy ha az áram idő jelalakját szeretnénk felhasználni akkor a mérést nyugodtan sáv korlátozhatjuk, 10-20 KHz-re. A feszültség idő és frekvencia tartománybeli jelalakok, nem igen használhatóak, hiszen időben egy torzult szinuszjelről beszélünk, míg frekvencia tartomány esetén megjelenik az a probléma, hogy az izzók melegedésének hatására a frekvencia összetevői a jelnek megváltoznak, egymáshoz képest eltolódnak.

2.2 A betanításhoz szükséges minták mérése


A mesterséges intelligencia betanításához nagy mennyiségű mintára van szükségünk ezért külön erre a célra kifejlesztett mérőkört is készítettünk, amit majd a végleges eszközbe is implementálni fogunk.

A mérés során továbbra is mérjük mind az áramot, mind a feszültséget, hogy ebből teljesítményt is tudjunk számolni. A mérőkör annyiban módosult, az előzőhöz képest, hogy az áram és a feszültség jeleknek levágtuk a negatív komponensét, hogy a mérést egy A/D átalakító segítségével el tudjuk végezni a későbbiekben, de a mérést továbbra is oszcilloszkóp segítségével végeztük el. Egy rövid mérőprogram is megírásra került annak érdekében, hogy gyorsan és könnyedén tudjuk a mérést elvégezni. A mérés során négy eszköz jelalakját vizsgáltuk, egy porszivót, egy LED lámpát, egy hagyományos izzót és egy kompakt fénycövet.




Ábra 8

Kompakt Fénycső




Ábra 9

LED lámpa



Ábra 10

Hagyományos



Ábra 11

Porszívó

A mérés sikeres volt mert a betanítás a mért eredmények alapján elvégezhető volt.

3. Mesterséges intelligencia fejlesztése, tesztelése és optimalizációja

A feladatot többféleképpen is meg lehetett közelíteni. Detektálhatjuk az időtartománybeli, illetve a frekvenciatartománybeli különbségeket a különböző tranziens jelenségek között. Ezekben belül is vehetjük az áram, illetve a feszültség időtartománybeli vagy spektrális képét. Mivel egyszerűbb feldolgozási módszernek tartottuk az időtartománybeli feldolgozást, ezért a dolgozat keretein belül ezzel foglalkoztunk. Végeztünk vizsgálatot spektrális különbségeket megvalósító neurális hálózattal, ám ezt a hálózatot nem tartottuk jó modellnek, így időtartományban végeztünk betanításokat. Mivel a neurális háló modellünk, mellyel frekvenciatartományban vizsgáltunk nem konvolúciós neurális hálózat volt, ezért nem vetjük el annak lehetőségét, hogy frekvenciatartományban jobb eredményre juthatnánk. A spektrális képek neurális hálózattal való klasszifikációja egy következő módszer melyet érdemes volna vizsgálni. Időtartománybeli betanításokat az áram tranziens jelenségeivel végeztünk, ennek okai a neurális hálózat pontosságából adódó megfontolásokból következtek.

3.1 Időtartománybeli klasszifikáció


Az alapkoncepció a következő: Amennyiben teljesítményváltozást észlelünk, elkezdjük minta vételezni az áramerősséget egy bizonyos ideig. Ezzel egy szekvenciális adathalmazt, sorvektort kapunk. Ezek az azonos hosszúságú sorvektorok tartalmazzák a tranziens jelenséget, melyek feltételezéseink szerint elég karakterisztikusak, hogy különböző eszközök tranziens jelenségeit meg tudjuk különböztetni egymástól.

A nyers adatokon különböző transzformációkat végezve, igyekszünk kiemelni a jel egyes tulajdonságait, melyek jól korrelálnak az egyes csoportokkal, illetve elhatárolják ezeket más csoportoktól. Ezeket a tulajdonságokat normális eloszlás szerint standardizáljuk, majd betápláljuk a neurális hálózat bemeneteire.

Mivel ismerjük a mért eredményeink csoportjait, ezért egy címkézett adathalmazunk van, így supervised learning metodikát használunk.

3.1.1 LSTM és biLSTM rétegek működése

A neurális hálózatok elterjedésének oka a jó függvényközelítési képesség [2]. Jelen időszakban az LSTM visszacsatolt neurális háló rétegek uralják az időtartománybeli feldolgozás méretes szegmensét az ARMA és az ARIMA rendszerek mellett [1][7]. Az egyszerű felépítésű RNN, illetve egy sokkal bonyolultabb struktúrájú GRU több betanításbeli problémával rendelkezik, ahol is nem általánosítható a betanítás konvergenciája az elszálló és a nullához tartó gradiens miatt. A lent látható struktúrájú LSTM cella kialakításából adódóan a hibafüggvény súlyok szerinti deriváltja nem fog nullához tartani, illetve elszállni, valamint a gradiens haladásának ez az elrendezés előnyös, mivel a Back Propagation Through Time (BPTT) során, egyszerűbb mátrixszorzásokkal frissíthetőek a súlyok [4].



Ábra 12


LSTM cella struktúrája [3]

Ez a kialakítás több megkülönböztethető logikai komponens kombinációja, melyek a felejtés, tárolás, frissítés és a kimenet előállításával illelhetők. A kimenet (h_t) feleltethető meg a rövid idejű időbeli függőségek tárolójának, míg a belső állapot egy hosszabb idejű memóriát képvisel (C_t).

BiLSTM réteget használva, kiaknázzuk a teljes sorvektor meglétből fakadó lehetőségeket. A sorvektoron két irányból végig haladva a neurális hálóval több információt nyerhetünk, mint ha ezt csak egy irányban tennénk, ezért használtunk ilyen réteget.

3.1.2 Neurális hálózat rétegei

Az alábbi neurális hálózat rétegstruktúrája érte el a legjobb pontosságot a betanítás során.




Ábra 13

Neurális hálózat rétegei

3.1.3 Betanítás folyamata

Az alábbi ábrán megfigyelhető a betanítási görbe, ahol is a narancssárga színnel a betanító adatokon vett, illetve a fekete pontokkal jelölt helyeken a validációs adatokon vett klasszifikációs hiba abszolút értéke látható.



Ábra 14

Betanítási görbe

Megfigyelhető, hogy a hiba konvergál 0-hoz. A pontosság ezen esetben három eszköz klasszifikációjánál valóban tendál a 100%-os pontossághoz, ennek okai a kevés betanító adat és a kis számú csoport.

3.1.4 Tesztelés és optimalizálás

Az optimalizálás során a nyers adat különböző transzformációit és normalizációs technikáit, illetve az LSTM réteg szélességét állítottuk a legjobb pontosságot szem előtt tartva.

3.2 Alternatív megoldások

A megoldásunk csoportszerinti és dinamikabeli behatároltságából következik, hogy érdemes más megoldási módszereket is közelebbről megvizsgálni.

3.2.1 Konvolúciós neurális hálózat frekvenciatartományban

Adaptív modulációnál létező megoldás, hogy a rádiós csatorna minőségét a jelszint spektrális képeivel kívánják prediktálni [5]. Ez a klasszifikációs módszer, mely szintén szekvenciális adatokon dolgozik, validálja ezen irány relevanciáját. Ettől függetlenül intuitív a frekvenciatartománybeli vizsgálat, ezt a tranziensek spektrogramjai is alátámasztják.

3.2.2 Klaszterezés időtartományban

Egy nagyságrendbeli lépés a megoldás dinamika tartományában a klaszterezés. Az irodalomkutatás során láttunk erre példát [6], ahol is a világ 3 nagyobb városában a mobilkommunikáció terheltségi szintjeit mérő számok időbeli mintái alapján csoportosították a város különböző pontjait. Tehát a város egy bizonyos pontján egy hét hosszú intervallumban (672 minta) 5 különböző terheltséggel korreláló mennyiséget figyelünk (SMS, hívás, Request, UL adat, DL adat), így egy 3360 dimenziójú vektoron végzett K-means klaszterezéssel ($K=6$) meg tudjuk különböztetni az időbeli terheltség függvényei alapján, hogy mely csoportba tartozik az adott térség.

Ezt a megoldást tekintjük a legjobb továbblépési lehetőségnek, mivel nem kell az egyes adatok címkéit ismernünk (unsupervised learning), hanem a klaszterező algoritmus magától megtalálja az egyes adatok közötti összefüggéseket és próbálkozik ezeket a csoportokat minél jobban elhatárolni egymástól, illetve a csoport tagjait minél közelebbi pontba hozni.

4. Konklúzió

A cikk keretein belül bizonyítottuk, hogy időtartománybeli klasszifikáció lehetséges háztartások tranziensének vizsgálatára. Tovább lépésként szeretnénk más mesterséges intelligencia koncepcióval próbálkozni mint például a K-means klaszterezés. Kutatásunk során sikeresen megvizsgáltuk, megismertünk különböző eszközök tranziensét.

Reméljük, hogy jelen cikk kellő információval szolgál azoknak a szakembereknek akik energetikai területen szeretnének mesterséges intelligenciát használni.

Források

- [1]. Goodfellow, Y. Bengio és A. Courville, Deep Learning. MIT Press, 2016, <http://www.deeplearningbook.org>
- [2]. M. T. Hagan, H. B. Demuth, M. H. Beale és O. De Jesús, Neural network design, 2nd edition. s.L: Martin T. Hagan, 2014, 1 old., isbn: 978-0-9717321-1-7
- [3]. W. Feng, N. Guan, Y. Li, X. Zhang és Z. Luo, “Audio visual speech recognition with multimodal recurrent neural networks”, 2017. máj. doi:10.1109/IJCNN.2017.7965918
- [4]. A. Amini. (2021. máj.). “MIT 6.S191 Introduction to Deep Learning”. English <http://introtodeeplearning.com/>, MIT, cím: <http://introtodeeplearning.com/>.
- [5]. S. Kojima, K. Maruta és C.-J. Ahn, “High-precision SNR Estimation by CNN using PSD Image for Adaptive Modulation and Coding”, 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring), 2020, 1–5. old. doi:10.1109/VTC2020-Spring48590.2020.9129413. learning series sor. Cambridge, MA: MIT Press, 2012, 1067 old., isbn:978-0-262-01802-9
- [6]. Sebastian Grauwin, , Stanislav Sobolevsky , Simon Moritz , István Góodor, Carlo Ratti, Towards a comparative science of cities: using mobile traffic records in New York, London and Hong Kong, <https://arxiv.org/pdf/1406.4400.pdf>
- [7]. K. P. Murphy, Machine learning: a probabilistic perspective, Adaptive computation and machine learning series sor. Cambridge, MA: MIT Press, 2012, 1067 old., isbn:978-0-262-01802-9