



**NEUMANN JÁNOS
INFORMATIKAI KAR**



TUDOMÁNYOS DIÁKKÖRI DOLGOZAT

**OE-NIK
2023**

Szerző: **Holecska Dávid**



**NEUMANN JÁNOS
INFORMATIKAI KAR**



Intézmény: **Óbudai Egyetem**
Kar: **Neumann János Informatikai Kar**
Tanszék: **Szoftvertervezés és -fejlesztés Intézet**
Szerző: **Holecska Dávid**
Szerző képzése, évfolyama: **Mérnökinformatikus MSc, esti tagozat, 4. félév**
Témavezető: **Dr. Dineva Adrienn, egyetemi docens**

A TDK-dolgozat címe:

**Li-ion akkumulátorokkal ellátott háztartási méretű kiserőművek
prediktív energiamenedzsmentje Mesterséges Intelligencia
alkalmazásával**

Beadási határidő: 2023. január 11.

Tartalomjegyzék

1. Bevezetés	3
2. Megújuló energiarendszer Mesterséges Intelligenciával támogatott optimális energiamedzsment megoldásai a szakirodalom tükrében	6
2.1. Megújuló energia rendszerek kialakításai	6
2.2. Megújuló energia rendszerek konfigurációs lehetőségei	7
2.3. Energiatároló technológiák	8
2.4. Méretezési és optimalizálási algoritmusok.....	10
2.5. Akkumulátor menedzsment technológiák.....	14
2.6. Piaci termékek elemzése	18
3. A kutatás módszertana	20
4. Megújuló energiaforráshoz csatlakoztatott akkumulátoros energiátárolóval ellátott felhasználó-együttes energiamedzsment rendszerének tervezésére alkalmas szimulációs modell építése	21
4.1. A szimulációs modell tervezése	21
4.2. A szimulációs modell bemutatása	22
5. Mesterséges Intelligencia alapú energiamedzsment	29
6. Szimulációs vizsgálatok.....	33
6.1. Vizsgálatok bemutatása	33
6.2. Eredmények értékelése.....	35
6.3. Pontenciális továbbfejlesztési irányok	37
7. Összegzés.....	39
Hivatkozások	41
Ábrajegyzék	47
Táblázatok jegyzéke	49
A. Melléklet: Ábrák Gyűjteménye	50

Absztrakt

Korunk egyik legnagyobb kihívása a szükséges energia igény biztosítása fenntartható módon. Az utóbbi években a korábbi, fosszilis energiahordozókból nyert energia ára megsokszorozódott, az ellátás nehézkessé vált. Erre a problémára keres és adhat megoldást a megújuló energiatermelő rendszer. Az Európai Unió szabályozási környezet egyre inkább a megújuló energia közösségek felé tereli a hangsúlyt a központosított, fosszilis energiatermelés helyett. A megújuló források bizonytalanságára adnak megoldást azok a rendszerek, ahol az energiatermelőket valamilyen – rendszerint akkumulátoros – energiátároló berendezéssel látják el. Ezekben a rendszerekben kritikus jelentősége van annak, hogy az akkumulátorok, illetve a rendszer egésze optimális módon működjön a megfelelő méretezés mellett. A dolgozat áttekinti és elemzi azokat a Mesterséges Intelligencia alapú technológiákat, amelyek egy ilyen rendszer méretezési feladatait, optimális kihasználását, illetve a villamosenergia tároló rendszer menedzsmentjét képesek az eddig ismert megoldásoknál hatékonyabban ellátni. A dolgozat célkitűzése egy olyan BMS fejlesztéseket támogató szimulációs keretrendszer építése, amely alkalmas egy hálózatra csatlakoztatott, napelemmel és akkumulátoros energiátárolóval ellátott rendszer Mesterséges Intelligencia alapú energiamenedzsment megoldásainak kidolgozására, amely több lakossági fogyasztó energiaigényét szolgálja ki. A Matlab Simulink környezetben végzett szimulációk valós napsugárzási és terhelési adatok felhasználásával készültek. A szimulációs program lehetőséget nyújt továbbá a rendszerelemek optimális MI alapú méretezési módszereinek fejlesztésére is. A kutatás további célja megvizsgálni, hogy a különböző fogyasztási profilok – a napenergia termelés szezonálisával együtt figyelembe véve – milyen hatással vannak az akkumulátor kihasználtságára.


Kulcsszavak: napelemes háztartási méretű kiserőmű, megújuló energia rendszer, akkumulátor menedzsment, energia menedzsment, megújuló energia közösségek, Mesterséges Intelligencia, LSTM

1. Bevezetés

A klímaváltozás, illetve annak negatív hatásai az elmúlt években egyre nagyobb figyelmet kaptak. Amellett, hogy a mindennapokban érezzük hatását (például az eltűnő tavasz-ősz évszakokkal, a már-már trópusi meleg napok megsokasodásával), az évről-évre növekvő energia-felhasználás is hozzájárul a klímaváltozás egyre drasztikusabb folyamatához. Az 1-1 ábra a világ országainak energiafelhasználását szemléltet, míg az 1-2 ábra azt mutatja meg, hogyan változott a világ négy legnagyobb energia-felhasználójának fogyasztása az 1970-es évektől napjainkig. Legnagyobb mértékben Kína fogyasztása emelkedett (főként a 21. században), de Oroszország kivételével minden nagyfogyasztó állam egyre több energiát használ fel évente.




1-1. ábra. A világ legnagyobb CO2 kibocsátó országai (Forrás: <http://energyatlas.iea.org>)



1-2. ábra. A 4 legnagyobb energia-felhasználó fogyasztása az elmúlt 50 évben (Forrás: <http://energyatlas.iea.org>)

Ezekben az államokban a felhasznált energiának körülbelül 25% -a fordítódik minden évben a lakosság fogyasztására, melynek legnagyobb részét a fűtési- és hűtési-energia teszi ki [1]. Mind az ipar, mind pedig a lakossági szegmens a rá eső energia hányadot javarészt villamos energia formájában fogyasztja, melyek legnagyobb részét központi erőművekben (fosszilis, nukleáris, megújuló) állítják elő. A 1-3 ábrán az látható, hogy ebben a négy országban a villamos energiát körülbelül 70%-ban fosszilis energiahordozók

égetésével állítják elő, ami miatt ezen négy ország a világ legnagyobb CO₂ kibocsátó országa is (1-4 ábra).



1-3. ábra. Fosszilis energiahordozók részaránya a villamosenergia-termelésben[1]

CO ₂ emissions (MtCO ₂)	
2018	
Country	Value
China, People's Republic of	9.5 thousand
United States	4.9 thousand
India	2.3 thousand
Russian Federation	1.6 thousand
Japan	1.1 thousand
Germany	696.1
Korea	605.8
Iran, Islamic Republic of	579.6

1-4. ábra. A világ országainak CO₂ kibocsátása csökkenő sorrendben [1]

Jól látható tehát, hogy az elmúlt évek során az üvegházhatású gázok kibocsátása nagymértékben növekedett, emiatt a Föld minden részén hangsúlyos szerepet kaptak azok a fejlesztések és kutatások, amelyek a meglévő energetikai rendszer kiváltását és korszerűsítését/átalakítását célozzák. A világ CO₂ kibocsátásának csökkentése több módon érhető el:

- a fosszilis tüzelőanyagokat használó erőművek csökkentésével,
- a nukleáris energia nagyobb arányú hasznosításával,
- a közlekedési eszközök/módok korszerűsítésével (például elektromos autók),
- az ipari- és lakossági szegmens energiavesztésének csökkentésével,

- a megújuló energia nagyobb arányú hasznosításával, illetve
- megújuló energia közösségek létrejöttével.

Az alapképzésen írt szakdolgozatomban az ipari szegmens egyik szereplőjének energia-veszteség csökkentésével foglalkoztam. A szakdolgozatom célja egy gyártósor energetikai vizsgálata és korszerűsítése, az energiaveszteségek csökkentésére adott javaslatok – mind hő-, mind villamosenergia vonatkozásában – megfogalmazása volt. Néhány korszerűsítést eszközölve jelentős energiamegtakarításra tudott szert tenni a vállalat, azonban az energiaszükségletét földgáz tüzelésű kazánokkal fedezte, amely se nem fenntartható, se nem költséghatékony módja az energia igény kielégítésének. Jelen dolgozatomban a fenti lista utolsó két elemére koncentrálok, azaz a megújuló energia nagyobb arányú hasznosítása, illetve a megújuló energia közösségek létrejötte kerül előtérbe. A világ számos pontján kutatják ezeket a témaköröket, amelyek középpontjában az esetek döntő többségében a megújuló energiatermelés és az így megtermelt energia tárolása áll [2]. Jelenleg nem az energia termelés módja, hanem a megtermelt energia optimális felhasználása és tárolása a megoldandó feladat [3, 4, 5]. Ahogy különböző fizikai kialakítások léteznek egy megújuló energia termelő rendszer esetében, úgy sokféle szabályozási algoritmus is létezik – ezekből néhány bemutatására sor kerül a következő fejezetben. Ezek az algoritmusok valamilyen mesterséges intelligencián alapulnak a korszerű megoldások esetén.

A fentiekkel összhangban a dolgozat célja egy valós adatokon alapuló, Li-ion akkumulátorral felszerelt háztartási méretű kiserőmű rendszer csoport bemutatása és modellezése méretezési feladatok ellátására és Mesterséges Intelligenciával támogatott optimális energiamenedzsment stratégiák kidolgozásának támogatására, illetve energiaközösséghez való csatlakozási döntés elősegítésére.

2. Megújuló energiarendszer Mesterséges Intelligenciával támogatott optimális energiamenedzsment megoldásai a szakirodalom tükrében

2.1. Megújuló energia rendszerek kialakításai

A megújuló energia rendszerek kialakítását foglalja össze a [2] cikk. Kiemelik, hogy sajnos minden tisztán megújuló energiát alkalmazó rendszernek is megvan a hátránya, például a magas telepítési költség vagy függőség a környezeti hatásoktól (például időjárás). Emiatt lehet a legjobb megoldás a hibrid kialakítás [6]. Ezekben a rendszerekben általában több fajta energiatermelő-, és több fajta energia tároló berendezés telepítésére kerül sor. Energiatermelésre gyakori a napelem, illetve a szélturbina, energia tárolásra pedig az esetek többségében akkumulátorokat használnak, de nagyobb léptékben azonban használható a hidrogén alapú energia tároló is. A hibrid rendszerek csoportosítása több szempont alapján történhet.

Csoportosítás a hálózatra csatlakozás módja szerint

Egyik csoportosítási szempont a hálózatra csatlakozás módja, amely szerint lehetnek hálózatra csatlakoztatott, vagy hálózati csatlakozás nélküli rendszerek. Izolált, azaz csatlakozás nélküli sziget üzemű esetben a megújuló energia termelő rendszernek kell a terhelést minden esetben fedeznie. Ez kockázatokat foglal magában, hiszen a megújuló energiaforrások rendelkezésre állása nem konstans, ami teljesítmény-, illetve megbízhatósági problémákat okozhat. Teljesen izolált rendszereket ezért csak olyan helyekre telepítenek, ahol nincs lehetőség hálózatra csatlakozni, vagy az olyan drága, hogy nem térülne meg. Egy sziget üzemű rendszerre a 1-17. ábrán láthatunk példát. Hálózati csatlakozással rendelkező esetben a rendszer képes energiát felvenni a hálózatról, illetve energiát leadni a hálózat felé (amennyiben a termelés nagyobb, mint a csatlakoztatott terhelés). Ez a kialakítási mód indukálta az energia menedzsment rendszerek létrejöttét és alkalmazását. A hálózati csatlakozással rendelkező esetre a 1-18. ábrán látható egy példa.

Csoportosítás az integráció módja szerint

Egy másik csoportosítási szempont lehet az integráció módja szerinti csoportosítás. Ez a típusú besorolás a rendszert a belső összekötő buszrendszer típusa alapján különbözteti meg: AC (váltakozó áramú), DC (egyenáramú) vagy hibrid. Ennek a busznak a szerepe

az egyes elemek fizikai összekötése, és így a termelési - fogyasztási áramok kezelése, irányítása [2].

DC buszt olyan esetben használnak, ahol alacsony a fogyasztás, köszönhetően az alacsony veszteségnek, illetve az egyszerű kezelhetőségnek. Hátránya azonban, hogy sok átalakítás kell a fogyasztói oldalon, mivel a legtöbb fogyasztó berendezést váltakozó (AC) árammal kell ellátni. DC busz kialakításra a 1-19. ábrán láthatunk példát.

A váltakozó áramú (AC) buszt közepes- és nagy teljesítményű alkalmazások esetén használják, mivel a magasabb feszültség miatt kisebb a belső veszteség az egyszerű kialakítás mellett. Hátránya azonban, hogy a váltakozó jellegből adódóan felharmonikusok keletkeznek, amelyek ártanak az áramköri elemeknek, különösen a generátoroknak. Ennek kiküszöbölésére különböző, ún. áramköri szűrőket kell alkalmazni, amelyek növelik a rendszer komplexitását és árát. AC busz kialakításra a 1-20 ábrán láthatunk példát.

A legkomplexebb buszrendszer mód a hibrid buszrendszer. Ez a kialakítás egyaránt használja a DC és AC busz elemeket, amelyekkel az adott típusú termelő egységeket az ugyanolyan típusú fogyasztó berendezésekkel köti össze. Ennek köszönhetően nincs szükség teljesítmény átalakító berendezésekre, azonban a vezérlés sokkal komplexebb feladattá válik. Hibrid busz kialakításra a 1-21 ábrán láthatunk példát.

Csoportosítás az integrált elemek szerint

Harmadik csoportosítási módszer az integrált elemek szerinti csoportosítás. Ezek a beépített elemek fogják meghatározni az energiatermelés és tárolás módját, a csatlakoztatható terhelések típusát. Energia előállítási módok tekintetében a legelterjedtebb a napelem és szélturbina kombináció, mivel a napelem termelés nappal jól prediktálható, a szélturbina pedig éjszaka is biztosítja a szükséges ellátást. Hálózatra kapcsolt esetekben a hálózat szintén megjelenik mint generátor a rendszer elemek között.

Energia tárolás tekintetében 3 fő típust különböztethetők meg: akkumulátorok és szuperkapacitások, – melyeket rövid távra használnak –, illetve hidrogén alapú üzemanyagcellák, amelyeket közép- és hosszú távú energiaraktározásra lehet felhasználni. Ezek a későbbiekben kifejtésre kerülnek.

2.2. Megújuló energia rendszerek konfigurációs lehetőségei


Konfigurációs lehetőségek tekintetében 4 fő típust lehet elkülöníteni, melyek az alábbiak:

- egy energiaforrás – egy energiatároló [7, 8, 9, 10]

- egy energiaforrás – hibrid energiatároló [11, 12]
- hibrid energiaforrás – egy energiatároló [13, 14, 15, 16]
- hibrid energiaforrás – hibrid energiatároló [17, 18, 19, 20, 21, 22]

2.3. Energiatároló technológiák

Az energia tárolása kulcsfontosságú a megújuló energia rendszerekben, hiszen ezeknél a technológiáknál az energia nem folyamatosan áll rendelkezésre, és/vagy nem akkor, amikor a terhelés szükségessé tenné azt. Ennek a kiküszöbölésére energiatárolókat kell beépíteni a rendszerekbe, amelyek közül a leggyakoribb akkumulátoros energiatárolás a [6, 23] alapján kerül bemutatásra. Ezek a berendezések három módon képesek üzemelni: töltés, tárolás, lemerítés. Egyik fő csoportosítási szempont az energiatárolás ideje, ami alapján megkülönböztetünk rövid-, közép- és hosszútávú energiatárolókat [23]. Csoportosíthatók a tárolt energia formája szerint is; ez alapján beszélhetünk mechanikai, kémiai, elektrokémiai, hő vagy elektromos alapú energia tárolásról [24]. A tárolt energia formája szerinti csoportosítást mutatja be a 2-5. ábra.




2-5. ábra. Energiatároló kialakítások [24]

Akkumulátoros energia tárolás

Az újratölthető akkumulátor egyik legrégebbi és legelterjedtebb energia tárolási forma, köszönhetően a rugalmasságának, megbízhatóságának és gyors válaszidejének. Az akkumulátorok gyakorlatilag bárhol elhelyezhetők (közel a terheléshez vagy a megújuló energiatermelők közelében is), modulárisak. Hatásfokuk kb. 60% és 90% között változik (AC/DC átalakítási hatásfok). Az akkumulátor kialakítása széles körben változhat: léteznek például ólomsavas, lítium-ion, nikkel-kadmium, nátrium-kén alapú technológiák. A két legelterjedtebb forma a lítium-ion és az ólomsavas típus.

Az ólom-savas akkumulátor ólom-dioxidból áll, mint pozitív elektródából, és egy negatív elektródából. A kénsavat elektrolitként használják a kisülési reakciók szulfationjainak biztosítására. Népszerű tárolórendszer az áramminőség, a szünetmentes tápegység (UPS) és az időszakos megújuló energiaforrások számára. Azonban az alacsony energiasűrűség (30–50 Wh/kg), a rövid ciklusélettartam (500–1000 ciklus) és az ólom feldolgozása néhány probléma az ólom-savas akkumulátor használatával kapcsolatban [23].


A lítium-ion (Li-ion) akkumulátor egy olyan fejlett akkumulátortechnológia, amely elektrokémiájának kulcsfontosságú elemeként lítium-ionokat használ. A kisülési ciklus során az anódban lévő lítium atomok ionizálódnak és elválnak elektronjaiktól. A lítium-ionok az anódról elmozdulnak és áthaladnak az elektroliton, amíg el nem érik a katódot, ahol rekombinálódnak elektronjaikkal [25]. A lítium-ion akkumulátoroknak számos előnye, illetve hátránya van. Előnye, hogy jelenleg ez a típus képes a legnagyobb energiasűrűsége a többi típushoz képest. A cellafeszültsége egészen 3.6V-ig nőhet, ami miatt nagy mennyiségű áram leadására képesek, lehetővé téve nagy teljesítményű alkalmazások használatát. Nincs szükség rendszeres, tervezett karbantartásra és az önkisülés is csak 1-2% közé tehető havonta [25]. Hátránya azonban, hogy erőteljesen melegszik, ezzel veszélyességi gondok léphetnek fel. Magas feszültségen, sűrű kisütési ciklusok esetén könnyen degradálódik – amellet, hogy az akkumulátor öregedésével a teljesítménye jelentősen csökken(het). A 2-6 ábrán látható Ragone diagramon a különböző akkumulátor típusokat hasonlíthatjuk össze az energiasűrűség és tárolt energia vonatkozásában.



2-6. ábra. Akkumulátor típusok összehasonlítása [25]

2.4. Méretezési és optimalizálási algoritmusok

A megújuló energia rendszerek tervezése során az egyik legfontosabb kérdés, hogy milyen méretezési eljárást válasszunk a rendszer kialakításakor, hiszen a megfelelő rendelkezésre állási- és teljesítmény szempontok mellett a költség tényező is hangsúlyos szerepet kap. A 2-7. ábrán láthatók a lehetséges méretezési megközelítések.



2-7. ábra. A különböző méretezési módok [23]

Méretezés mesterséges intelligenciával

A mesterséges intelligencia (MI) alapú modelleknek nincs szükségük időjárési adatokra a szükséges méretek meghatározásához [23]. Minden esetben valamilyen algoritmus mentén dolgoznak. A szakirodalomban sok fajta ilyen technológia lehetséges fel, például:

- genetikus algoritmusok (GA),

- részecskeraj-optimalizálás (PSO),
- a szimulált lágyítás (SA),
- a hangyatelep-optimalizálás (ACO),
- mesterséges neurális hálózatok (ANN),
- a fuzzy logika (FL),

vagy ezen technológiák keveréke. A továbbiakban ezek rövid ismertetésére kerül sor.

A genetikai algoritmusok létrejöttét Darwin elmélete ihlette meg, mely szerint a legerősebb marad életben. Az optimalizációs függvény bittömbként vagy karakterláncként van kódolva a kromoszómák reprezentálására. Ezeket a karakterláncokat ezután manipulálják, és tesztelik azok alkalmassági értékét az érintett probléma megoldása érdekében. A GA öt folyamatból áll. Ezek egy kezdeti véletlenszerű populációgenerátor, egy „alkalmassági” kiértékelő egység és a genetikai operátorok a „szelekciós”, a „keresztelési” és a „mutációs” műveletekhez. A véletlen populációgenerátor olyan lehetséges megoldásokat generál, amelyek kielégítik a probléma definíciójában felvázolt összes megkötést. Ezután ezeket a megoldásokat az alkalmassági értékeik alapján értékelik. A „Kiválasztás” operátor kiválasztja azokat a megoldásokat, amelyek alkalmassági értéke az előre meghatározott alkalmassági küszöbön belül található. A „keresztelési” operátor olyan új megoldásokat keres/olyan új egyedeket hoz létre, amelyek magasabb alkalmassági értékkel rendelkeznek, mint elődeik. A „mutációs” operátor lehetővé teszi az algoritmus számára, hogy elkerülje a helyi minimumok beékelődési problémáját. Ezeket a lépéseket addig ismételjük, amíg el nem érjük a konvergenciát [6]. A GA hátránya, hogy bonyolultsága a paraméterek számával növekszik, és így a kódolás nehézsége is nő. A [26] cikkben az optimalizálást a GA algoritmus segítségével végezték el.

A részecskeraj-optimalizálás (PSO) alapja az a tény, hogy egy raj mindig együtt mozog egy adott területen ha élelmet keres. Iteratív megoldás, amely adott területen belül keresi a megoldást egy adott célfüggvényre. Itt minden megoldási paraméter egy részecskének tekinthető a rajban, amely információval rendelkezik a saját-, illetve a csoport viselkedéséről. Minden részecske két pozícióértéket követ, amelyek az eddigi legjobb megoldások, amelyeket saját maga, illetve a csoport elért [6]. A PSO alapkoncepciója ezen két pozíció felé gyorsulás egy súlyozott véletlenszerű egész szám nagyságával. A részecskék sebessége és helyzete minden iteráció végén frissül. Nagy előnye az egyszerűség, amelyet a

[27] cikkben bemutatt optimalizálás során láthatunk.

A szimulált lágyítás (SA) egy véletlenszerű keresési technika, amely a fémek lágyítási folyamatán alapszik és optimalizálási feladatokra is alkalmazható. A fémeket magas hőmérsékleten megolvasztják, majd lehűtik és a minimális energiával kristályos állapotba fagyasztják [6]. Ennek eredményeként a fém nagyobb kristálméreteket fejleszt ki, és fém szerkezetének hibái csökkennek. A szabályozó paraméter a hőmérséklet a folyamatban. Minden iterációban adott egy véletlenszerű állapot, amelyet egy másik véletlenszerű állapottal hasonlítanak össze rögzített T hőmérsékleten. Ha a kettes állapot energiaszintje alacsonyabb, mint az egyes állapot energiaszintje, akkor a kettes állapot lesz az aktuális állapot, ha viszont a kettes állapot energiaszintje magasabb, akkor az alábbi valószínűségi függvény alapján kell elfogadni az állapotot:

$$1/(1 + \exp(\Delta E/T))$$

, ahol ΔE az energiaállapotok különbsége, T pedig a hőmérséklet. Tehát ha a hőmérséklet értéke magas (a szimuláció elején), akkor nagyobb valószínűséggel fogad el nem minimum közeli állapotokat. A hőmérsékletet folyamatosan csökkentik az iterációk során, és a formulának köszönhetően a rendszer minimumhoz konvergál. Azonos algoritmus használható kombinációs optimalizálási problémákra, ahol az E energia C költségfüggvénynek, a T hőmérséklet pedig a c szabályozási paraméternek felel meg.

Az SA hibrid rendszerméretezésben kevésbé népszerű, mint a GA vagy a PSO, egy példa a használatára a [28] tanulmányban érhető el.

A hangyatelep optimalizálás alapja a hangyák viselkedése az út kijelölésére és követésére. Tanulmányok kimutatták, hogy a hangyák egy speciális feromont használnak az útjuk során azért, hogy ezzel megmutassák az utat a többi hangyának. Minél többen használják azt az utat, annál magasabb lesz a feromon szint, annál inkább arra fognak menni a következő hangyák, ha pedig egy utat nem használnak, akkor idővel a lerakódott feromon eltűnik. Ezáltal a hangyák a legjobb – legrövidebb – utat találják meg a célhoz (ami általában sok étellel kecsegtet számukra). Ezt az elvet használja fel az algoritmus a célfüggvény minél gyorsabb kielégítéséhez. Az algoritmust tesztelték az elosztóhálózat veszteségeinek csökkentésére, és közel 45%-kal jobb eredményt ért el, mint a GA algoritmus [6].

A fuzzy logika az elmúlt évtizedekben számos alkalmazásban jelent meg [29], a terület ennek következtében jól kidolgozott és napjainkban már kevésbé aktuális kutatási terület.

A korábbi modellezési eljárások esetében a célfüggvény és a feltételek egyértelműen meghatározottak voltak. Vannak olyan esetek azonban, amikor vagy a cél, vagy a környezet/feltétel nem egyértelműen beazonosítható: erre ad megoldást a fuzzy logika alapú optimalizálás [30]. A fuzzy következtetés egy olyan módszer, amely nyelvi változókhoz rendelt függvények segítségével, és bizonyos szabályok alapján értékeket rendel a kimeneti vektorhoz [31]. Akkor használjuk, ha egy kérdésre adott válasz nem egyértelműen eldönthető, azaz nem lehet 0-1 értéket hozzárendelni. A fuzzy logika tulajdonképpen a klasszikus halmazelmélet kiterjesztésének tekinthető. Alkalmazása napjainkban is gyakori, például a [5] cikk szerzői egy fuzzy logikán működő energia menedzsment rendszert mutatnak be tanulmányukban, azonban ezen megoldások teljesítménye elmarad a korszerű MI megoldásokétól.

A több, mint 70 éve létező neurális hálózatokat szintén fel lehet használni megújuló energia rendszerek tervezéséhez. Olyan esetekben lehet hasznos a technológia, amikor nem áll rendelkezésre minden szükséges adat ahhoz, hogy meg tudjuk adni a rendszer paramétereit: például napelem panelek száma, energiatárolók mérete stb. Különösen alkalmasak hiányos adatkészleteket, homályos vagy hiányos információkat tartalmazó feladatokra, valamint rendkívül összetett és rosszul meghatározott problémákra, ahol az emberek általában intuíción alapozva döntenek. Tudnak tanulni a példákból, és képesek kezelni a nemlineáris problémákat. Magas robusztusságot és hibatűrést mutatnak. A neurális hálózatok nem képesek hatékonyan kezelni a nagy pontosságú feladatokat [32]. Az elmúlt években cikkek százai jelentek meg a témában: [32, 33, 34, 35, 36]. Ezekben a tanulmányokban a neurális hálózatot valamilyen időjárási adatra programozták fel, amely így képes megadni megfelelő adatok nélkül is a rendszer elemek szükséges méretét.

Méretezés kereskedelmi szoftverek segítségével

A megújuló energiarendszerek tervezéséhez különböző ipari szoftverek állnak rendelkezésre. Az optimális konfiguráció a különböző rendszerkonfigurációk között megtalálható a nettó jelenérték és a teljesítmény alapján. A különféle számítógépes eszközök közül a hibrid optimalizálási modell az elektromos megújuló energiaforrásokhoz (HOMER) az egyik legnépszerűbb eszköz ilyen rendszerek méretezésére. A HOMER képes egy energiaellátó rendszer fizikai viselkedését modellezni az életciklus költsége alapján, amely a rendszer elemek telepítési és karbantartási költségeinek összege a rendszer élettartama alatt. A HOMER lehetővé teszi a programozó számára, hogy számos különféle tervezési konfigurációt összehasonlítsa műszaki és gazdasági előnyeik alapján [23]. A ter-

vezést segítő eszközökben jelenleg kevésbé elterjedt a Mesterséges Intelligencia-alapú méretezéseket, BMS fejlesztéseket támogató funkció, amelyek az ismert megoldásoknál hatékonyabb megoldásokat képesek biztosítani, ezért újabban az MI-alapú megoldások tervezését támogató fejlesztői eszközök iránti igény egyre növekszik, hiszen a tervezők sokszor csak egyik-egyik szakterületen rendelkeznek mélyebb szakismerettel.

2.5. Akkumulátor menedzsment technológiák

Az akkumulátor menedzsment – vagy a szakterületen gyakran alkalmazott betűszót használva BMS (Battery Management System) – kiemelkedően fontos a mindenütt jelen lévő akkumulátorral működő energiarendszerek, például az elektromos járművek és a megújuló energiaforrásokkal működő intelligens hálózatok működési hatékonysága, biztonsága, megbízhatósága és költséghatékonysága szempontjából [37]. Az akkumulátor állapotának becslése már hatalmas kutatási területté fejlődött, és számos megközelítésről számoltak be a szakirodalomban. A főbb mutató számai egy akkumulátornak a következők:

- töltöttségi állapot (SOC),
- energiaállapot (SOE),
- egészségi állapot (SOH),
- teljesítményállapot (SOP),
- hőmérsékleti állapot (SOT),
- biztonsági állapot (SOS).

Az akkumulátorok optimális menedzsmentjére vonatkozóan az évek során számos technika fejlődött ki. Találhatunk leírásokat például a "támogató vektorgép" (SVM), "relevanciavektor gép (RVM)", fuzzy logika (FL), mesterséges neurális hálózat és fuzzy C-means (FCM) klaszterezés technológiákról. A [38, 39] tanulmányban egy intelligens energia menedzsment rendszert fejlesztettek ki a Fuzzy logika segítségével. A rendszer elemei a következők:

- napelem panel,
- diódák,
- feszültség vezérlésű inverter,

- transzformátor,
- felharmonikus szűrők,
- akkumulátoros energiatároló, illetve az
- intelligens energia menedzsment rendszer.

A vezérlő egység két intelligens megközelítés kombinációjaként működik: a fuzzy logikai vezérlőt (FLC) egy átlagos variancia optimalizáló algoritmussal (MVO) kombinálták. A fuzzy logika – a pontatlan és homályos információkkal foglalkozó technika – lehetővé teszi a pontatlan emberi tudás logikus ábrázolását közelítő kifejezésekkel és értékekkel. Egy tipikus FLC három fő modulból áll: a fuzzifikációs folyamatból, a következtetési motorból és a defuzzifikációs folyamatból. A bemutatott fuzzy vezérlő esetén 3 bemenet volt: az aktuális napelem teljesítmény, az aktuális akkumulátor töltöttség, illetve az aktuális terhelés értéke, amely állandó és változó részből tevődik össze. Minden bemenet tagsági függvénye háromszög alakú. Kimenatként a terhelés és akkumulátor teljesítményeket adja meg a rendszer. Az összesen 64 szabállyal rendelkező fuzzy vezérlő állítja elő a súlyokat minden tüzelési szinthez. Az FLC optimalizálásához az MVO algoritmust használták fel. Az FLC és az MVO kombinációja az optimális teljesítmény- és terhelés-elosztás vezérlések folyamatos fejlődését eredményezi a terheléstípusok változó arányával (állandó és változó terhelések). Az MVO algoritmus egyedülálló az utódok mutációjához használt stratégiai transzformáció miatt, amely az n-legjobb dinamikus populáció átlagos varianciája alapján történik. Az MVO alkalmas valós idejű optimalizálásra, mert iterációnként csak egy alkalmassági értékelést igényel, és csak néhány iteráció szükséges az optimális megoldás megtalálásához. Az MVO ezen tulajdonságai potenciálisan vonzó algoritmussá teszik számos valós optimalizálási probléma megoldásához. Az IEMDC teljesítményének összehasonlítására két másik energiagazdálkodási vezérlőt is bemutatnak: egy naiv fuzzy logic vezérlőt és egy PV-prioritás vezérlőt. Azt találták, hogy az optimalizált FLC jobban teljesít, mint a hagyományos PV-prioritású vezérlő és a naiv fuzzy logic vezérlő, így jobb utasításokat ad a felhasználónak a rendelkezésre álló energia felhasználásával kapcsolatban, és fenntartja az akkumulátor magasabb SOC-értékét [38]. Ennek a rendszernek az előnye, hogy jól tanítható a változó időjárási vagy egyéb körülményekhez, illetve a hardver rész költsége elenyésző.

A [40] cikkben bemutatásra kerül egy módosított szürke farkas algoritmuson (MGWO) alapuló energia menedzsment rendszer. Az optimális energiagazdálkodási rendszer műkö-

désének alapelve a különböző energiaforrások (hálózat, megújuló energiaforrások, generátorok és akkumulátorok) közötti kölcsönhatás és energiacsere a felhasználó igényeinek megfelelő terhelési igény kielégítése érdekében. Az MGWO alapú energia menedzsment rendszer egy két lépcsős megközelítés a mikrohálózatokhoz. Első lépésben a megújuló energia források megvalósíthatósági elemzése történik a geofizikai paraméterek figyelembevételével a terhelési igénynek megfelelő méretezés érdekében. Ezt egy metaheurisztikus keresletkezelő rendszer követi a javasolt mikrohálózat optimális kezeléséhez az elektromos energia összköltségének csökkentése érdekében. Az optimalizálás célja, hogy az akkumulátorokat a megújuló rendszer akkor töltse, amikor a legalacsonyabb áron lehetne azt értékesíteni a hálózat felé, és a amikor a lehetséges eladási ár magas, akkor a fel nem használt energia eladásra kerüljön. Az energia menedzsment rendszer folyamatábrája a 1-22. ábrán látható. A javasolt optimalizálási technika egy hibrid technika, amelyet a szürke farkasok mozgása ihletett, ahogy megtámadják zsákmányukat, illetve a madarak rajzása, ahogy táplálékot keresnek. A javasolt hibrid algoritmus tehát egy módosított részecske-raj-optimalizálás (PSO) a szürke farkas optimalizálóval (GWO) kombinálva. A javasolt MGWO csökkenti a PSO alacsony konvergencia rátáját és a GWO pontatlanságát. Az MGWO algoritmust a tesztek során a vegyes-egész lineáris programozási algoritmussal (MILP) hasonlították össze az eredmények értékelése céljából. A teljesítményt változó időjárási körülmények között tesztelték. Arra az eredményre jutottak, hogy az üzemeltetési költség megtakarítás egy napsütéses napon 23,34%, felhős napon 45,55% a MILP algoritmussal szemben. Ezen túlmenően a hálózat terhelése 42,56%-kal, illetve 32,91%-kal csökkent a derült és felhős napokon. Ez a megközelítés a közüzemi hálózathoz származó villamos energia magas és alacsony árú órái közötti árkülönbségen alapszik. A rendszernek köszönhetően az átviteli veszteségek is csökkennek, mivel a megújuló energiaforrásokból származó energiát hasznosítják a hálózati energia helyett.

A [41] cikkben arra keresték a választ, hogy hogyan lehet minimalizálni az energia költséget akkumulátoros energiatároló rendszer optimális vezérlésének segítségével háztartási méretű megújuló rendszerek esetén. A megoldáshoz megalkották a költségfüggvényt az alábbiak szerint:

$$Cost_{ppd}(t) = \sqrt{(\zeta_1(t)C(t))^2 + (f_{pc}(C)\zeta_2(t))^2} \quad (2.1)$$

, ahol

$$\zeta_1(t) = L(t) - P_{sT}(t) + u(t)\zeta_2(t) = BL_{max} - (BL + u(t))$$

ahol:

- $L(t)$ a terhelés mértéke,
- $P_{sT}(t)$ a napelem panelek termelése,
- $u(t)$ az akkumulátor vezérlő parancsa,
- BL_{max} az akkumulátor maximum kihasználtsági szintje,
- $BL(t)$ az akkumulátor jelenlegi kihasználtsági szintje,
- $f_{pc}(C) = k - C(t)$

Az (2.1) egyenlet első fele az akkumulátor kisütésért, míg a második része – amely kritikus az optimális akkumulátor vezérlés szempontjából – az akkumulátor töltéséért felel. A k érték megváltoztatása direkt hatással van az elektromos áram költségeire. A fenti költségfüggvény minimuma idézi elő a kisütést akkor, amikor kevés a napelem termelés és az árak magasak, illetve a töltést, amikor a termelés magas és az árak alacsonyak. Az optimális (minimum) állapot megtalálásához a PSO algoritmust alkalmazták. Arra jutottak, hogy ezzel a költségfüggvénnyel 4,2%-os megtakarítás érhető el a korábbiakban publikált költségfüggvényekkel szemben.

A [42] cikkben a szerzők egy olyan rendszert mutatnak be, ahol mély tanuló algoritmus segítségével érik el az optimális kihasználását a megújuló energiával működő, akkumulátoros energiatárolóval ellátott, áramot és fordított ozmózis útján ivóvizet biztosító rendszernek. A rendszer blokkvázlata a 1-23 ábrán látható.

Az optimális szabályozási probléma Markov-döntési folyamatként (MDP) van megfogalmazva, és a proximális irányelv optimalizálás (PPO) algoritmus – amely egy mélytanuló (DL) algoritmus – segítségével betanítja a rendszert az MDP megoldására, hogy megkapja az optimális kihasználását a rendszernek. A tanulási folyamat során figyelembe vették a megújuló energiaforrások szakaszosságát, a keresleti oldal bizonytalanságát (beleértve a friss vizet és a villamos energiát), valamint az akkumulátor rendszer és a víztartály rugalmasságát. A tanuláshoz 10000 adatsort használtak fel. Az eredmények értékeléséhez a következő három másik algoritmust használták fel: sztochasztikus programozás (SP), "dupla mély Q hálózat" (DDQN), illetve a "mély determinisztikus irányelv gradiens" (DDPG). Az eredmények értékelésénél az alábbira jutottak:

- a víztartály helyettesítheti bizonyos esetekben és részben az akkumulátor rendszert, így csökkentve annak a terhelését, amivel napi 2,6% költségmegtakarítás érhető el,

- a rendszer képes megtanulni az optimális energiagazdálkodást a tanító folyamatnak köszönhetően, és így költségcsökkentést tud elérni,
- a bemutatott MI technika jobb eredményt ért el a többi MI algoritmussal szemben, ezzel 14,17%-kal csökkentve a havi költségeket.

A fenti példákból jól látható, hogy az elmúlt évek során egyre nagyobb hangsúlyt kapott az akkumulátor menedzsment és számos megoldás elérhető az optimalizálási feladat megoldására. Fontos megjegyezni azonban, hogy a betanított mesterséges intelligencia alapú módszerek nem képesek leírni az akkumulátor belső elektrokémiai viselkedését, ami korlátozza alkalmazásukat változó működési feltételek mellett. Ennél is fontosabb, hogy a mesterséges intelligencia alapú módszerekhez gyakran nagy mennyiségű adatra van szükség a tanításhoz, és a tanulási folyamat gyakran időigényes. A különböző állapotváltozók becslésének tanulmányozása, a belső elektrokémiai paraméterek beépítése az algoritmusoktatásba, valamint a számítási hatékonyság javítása segíthet a mesterséges intelligencia alapú módszerek teljesítményének javításában [37], ezért ez fontos kutatási terület lesz a jövőben.

2.6. Piaci termékek elemzése

Az ILLUMINE projektet/szoftvert a MAN csoport energetikáért felelős üzletága fejleszti. A projekt bemutatására Augsburgban hoztak létre egy pilot projektet, ahol szél- és naperőművet kombináltak és egy központi, energia menedzsment rendszer irányításával működnek. Ez a központi energia menedzsment rendszer felügyeli mind a termelés, mind a raktározást az akkumulátorokban, mind pedig a változtatható terhelés aktuális állapotát. A vezérlő rendszerrel információt azonban nem osztanak meg, üzleti titkora hivatkozva [43].

Az IBM szintén foglalkozik MI alapú energia menedzsment rendszerek fejlesztésével napelemes rendszerekhez [44]. A szoftverük amit fejlesztettek minden felhasználó esetén egyedi, mivel minden helyszín (háztető) más és más elmondásuk szerint. A rendszernek mindössze az elmúlt két hét adataira van szüksége a napelem termelés-előrejelzés szignifikáns javulásához anélkül, hogy komplex rendszereket építettek volna fel.

A Nuvation Energy kaliforniai székhelyű cég kifejezetten akkumulátor menedzsment rendszerekkel foglalkozik szinte bármilyen iparág számára. A nagy feszültségű BMS rendszerük 1250 V feszültség szintig képes üzemelni blokkonként. Minden blokk több

akkumulátor cellából épül fel. Minden blokkban ún. cellainterfész modulok csatlakoznak az egyes cellákhoz a cellák feszültségének és hőmérsékletének mérésére, valamint a cellák kiegyensúlyozására. Minden blokkhoz tartozik egy kapcsolóberendezés, ami összefogja a cellákat és az energia menedzsment rendszer DC buszára csatlakoztatja őket. A kapcsolóberendezés mágneskapcsolókat és előtöltési ellenállást tartalmaz az egyenáramú buszra való csatlakozás és leválasztás kezelésére, kézi vészleállítási (E-Stop) funkciót, valamint csatlakozási lehetőségek széles skáláját az ESS-hez való integrációhoz. Ezeket a kapcsolóberendezéseket fogja össze egy ún. multi-blokk vezérlő, amely központi szerepéből adódóan lehetővé teszi a párhuzamosan kapcsolt blokkok egyben történő vezérlését/egy akkumulátorként való kezelését akár 36 ilyen blokkig.

Amellett, hogy egy kész, komplett és referenciákkal működő rendszerről van szó, sajnos semmit nem írnak a honlapjukon a vezérlési algoritmusról, ami az egyes elemeket működteti [45].

3. A kutatás módszertana

A kutatás módszertanához a Matlab 2022/9.12-es, 64 bites verziójának Simulink keretrendszerét használtam fel. A MATLAB teljes értékű fejlesztői környezetet biztosít alkalmazások és felhasználói felületek létrehozásához a rendszermodellek és BMS-algoritmusok végrehajtásához, valamint az eredmények megjelenítéséhez és értékeléséhez. A kutatás célkitűzésének értelmében olyan keretprogram építését kezdtem el, ami alkalmas MI alapú akkumulátor menedzsment megoldások fejlesztésére és tesztelésére, illetve az egyes rendszerelemek méretezésére. Bemeneti paraméterként terhelési-, illetve napsugárzásra vonatkozó adatokat használtam fel rendre a [46] és a [47] forrásokból. A terhelési adathalmaz 2016 és 2020 között tartalmazza egy kb. 200 négyzetméteres ház óránkénti fogyasztási adatait. Feltüntetetésre került, hogy a hét melyik napján volt a mérés, illetve hogy éppen otthon tartózkodtak-e a lakók, vagy épp nyaralni voltak.

A 2019-es egész éves adatokat használtam a szimulációk során, amelyből előállt a terhelési profil egy éves időintervallumra, ami a 1-24. ábrán látható.

A napsugárzási adatokat a "National Renewable Energy Laboratory" nevű szervezet adatbázisából vettem, amely a világ számos pontjáról rendelkezik adatokkal a múltbeli napsugárzási értékekről, így Magyarországról is. Ebben az esetben is a 2019-es adatokat használtam fel a szimulációkhoz, szintén órás bontásban. Az így előállt napsugárzási görbe a 1-25. ábrán látható.


4. Megújuló energiaforráshoz csatlakoztatott akkumulátoros energiatárolóval ellátott felhasználó-együttes energiamenedzsment rendszerének tervezésére alkalmas szimulációs modell építése

4.1. A szimulációs modell tervezése

A modellt úgy terveztem meg, hogy szimulálja a megújuló energia háztartási környezetben történő előállítását és felhasználását, az egyes elemek méretezését és a BMS tervezését, illetve tesztelését lehetővé téve a felhasználó számára. Ebből kifolyólag a modellnek gondosan rendszerezettnek és strukturálnak kell lennie, világos és jól dokumentált modellel. Azt is tesztelni és validálni kell, hogy a modell pontosan tükrözze a valós megújulóenergia-rendszer viselkedését. A feladat céljával összhangban a Simulink környezetben kellett felépítenem egy modellt, amely az alábbi elemeket tartalmazza:

- napelem panel,
- boost converter MPPT ("Maximum Power Point Tracking") algoritmussal,
- akkumulátor,
- akkumulátor menedzsment rendszer (BMS),
- AC/DC feszültségváltó inverter,
- hálózati elemek: generátor, kapacitív szűrők, illetve
- a házak, mint változó terhelési profilok.

A rendszerről készült blokkvázlat a [4-8. ábrán](#) látható.



4-8. ábra. Az elkészült szimulációs rendszer egyszerűsített blokkvázlata

Az egyes elemek bemutatására a következő alfejezetben kerül sor.

4.2. A szimulációs modell bemutatása

Napelem rendszer

A szimulációk során a Simulink beépített napelem modulját használtam, amely a bemenő napsugárzás és hőmérséklet értékekre megadja kimenetként a napelem feszültség és áramerősség értékét, melyek szorzatából előáll a napelem rendszer leadott teljesítménye. A modulba közel 10 000 létező napelem adatait táplálták be előre, amelyekből lehet választani a szimulációk során, illetve lehetőség van egyéni típus definiálására is. A napelem rendszer napelem cellák soros és párhuzamos kapcsolásából áll elő a megfelelő teljesítmény elérése érdekében. A soros kapcsolású cellák a feszültség szintet, míg a párhuzamosak a teljesítményszintet határozzák meg. A szimuláció során – a beépített elemek közül – a Sunpower gyártó SPR-250NX-BLK-D napelem modulját használtam fel, melynek feszültsége 30.7 V, áramerőssége 8.15 A az MPP pontban. 15 db ilyen modul került sorba kapcsolásra, így a napelem kimenő feszültsége 460.5 V lett. A rendszerbe egy 60 kW maximum teljesítményű napelem került beépítésre, így a 4.1 és 4.2 egyenleteket felhasználva 16 db párhuzamos modul modellezésére volt szükség.

$$P = UI \quad (4.1)$$

$$N = \frac{I}{I_{MPP}} \quad (4.2)$$

Ha a rendszerben lévő napelem panelek száma N_{PV} , akkor a teljes kiadott teljesítmény az alábbiak szerint adódik [13]:

$$P_{pv-total}(t) = N_{PV} P_{pv}(t) \quad (4.3)$$

A használt napelem modul I-V és P-V görbéi a 1-26. ábrán láthatók. A 4-1. táblázat tartalmazza összefoglalóan a napelem panel adatait.

4-1. táblázat. A napelem panel főbb paraméterei

Gyártó	SunPower Corporation
Típus	SPR-250NX-BLK-D
Teljesítmény/modul [W]	250
Sorosan kapcsolt modulok [db]	15
Párhuzamosan kapcsolt modulok [db]	16
MPP feszültség [V]	30.7
MPP Áramerősség [A]	8.15
Kimeneti feszültség [V]	460.5
Max. teljesítmény [kW]	60

Boost converter Maximum Power Point Tracking algoritmussal

A 4-8. ábrán bemutatott DC busz feszültségét folyamatosan 700 V-on szerettem volna tartani, ezért úgy kellett befolyásolnom a napelem termelését, hogy ez a 700 V tartható legyen, és minden időpillanatban a lehető legmagasabb teljesítményt szolgáltatassa. Ehhez azért van szükség egy ún. MPPT algoritmusra, mert ahogy a 1-26. ábrán is látszik, a napelem termelése egy ponton túl (az MPP ponton túl) drasztikusan lecsökken a feszültség növekedésével. Ahhoz, hogy ezt a pontot tartani tudjuk, ehhez szükség van egy MPPT algoritmusra, amelyből két fő típus létezik: a "Perturb and Observation (P&O)" – amely a legelterjedtebb –, illetve az "Incremental Conductance (IC)". A [48] alapján az (IC) algoritmus jobban teljesít az ilyen típusú szimulációkban, ezért ezt a fajta algoritmust választottam a feladat megoldásakor. Az IC algoritmust tehát a napelem P-V görbéje alapján tervezték a P&O algoritmus hátrányainak kiküszöbölésére. Az IC lényege, hogy a reakció idő csökken, ezért nagy napsugárzási érték változáskor is gyorsan és hatékonyan reagálja le a napelem a változást, és hamar eléri az új MPP pontot. Az MPP pont megtalálható a 4.4 egyenlet segítségével [48]:

$$\frac{dI}{dV} = -\frac{I}{V} \quad (4.4)$$

Az MPP helye a $\frac{dI}{dV}$ hányadostól függ:

- ha $\frac{dI}{dV} > 0$, akkor $V < V_{mpp}$, azaz a P-V görbe bal oldalán vagyunk, a PV feszültséget növelni kell,
- ha $\frac{dI}{dV} = 0$, akkor $V = V_{mpp}$, azaz az MPP pontban vagyunk,
- ha $\frac{dI}{dV} < 0$, akkor $V > V_{mpp}$, azaz a P-V görbe jobb oldalán vagyunk, a PV feszültséget csökkenteni kell.

Az iterációkat addig kell végezni, amíg el nem érünk az MPP pontba. Az IC algoritmus folyamatábrája a 1-27. ábrán látható.

Ahhoz, hogy a 700 V-os DC busz feszültséget tartani lehessen, a napelem kiadott feszültségét erre a szintre kell hozni, amelyet egy boost konverterrel lehet megtenni. A konverter elemei a következők:

- induktivitás,
- 2 db kapacitás,
- dióda,
- IGBT.

Az egyes elemeket aszerint kell méretezni, hogy mekkora a bemeneti (napelem oldali)-, illetve a kimeneti (DC busz oldali) feszültség értéke. Az ehhez szükséges egyenletek az alábbiak:

$$I_{outmax} = \frac{P}{V_{out}} \quad (4.5)$$

$$\Delta I_L = 0.1 I_{outmax} \left(\frac{V_{out}}{V_{in}} \right) \quad (4.6)$$

$$\Delta V_{out} = 0.1 V_{out} \quad (4.7)$$

$$C = \frac{I_{outmax} \left(1 - \left(\frac{V_{in}}{V_{out}} \right) \right)}{F_s \Delta V_{out}} \quad (4.8)$$

$$L = \frac{V_{in} (V_{out} - V_{in})}{\Delta I_L F_s V_{out}} \quad (4.9)$$

Ahol:

- P a teljesítmény [W],
- V_{out} a kimeneti feszültség [V],
- V_{in} a bemeneti (napelem) feszültség [V],
- F_s a kapcsolási frekvencia [Hz].

A használt C és L értékek a 4-4. táblázatban, a Simulink beli megvalósítás a 1-28. ábrán látható.

4-2. táblázat. A boost konverterhez felhasznált áramköri elemek paraméterei

Kapacitás (C) [F]	4.1929e-05
Induktivitás (L) [H]	0.0012


Akkumulátoros energiatároló

A Simulink keretrendszer rendelkezik beépített akkumulátor blokkal is, amely több típusú (Li-ion, ólomsavas, Nikkel-kadmium stb.) akkumulátor szimulálását teszi lehetővé. Ahogy a dolgozat címe is jelzi, a szimulációk során Li-ion akkumulátort használtam fel. A pontos adatokat a 4-3. táblázat tartalmazza.

4-3. táblázat. A felhasznált akkumulátor paraméterei

Típus	Li-ion
Feszültség [V]	12*35
Kapacitás [Ah]	48
Nominális kisütési áram [A]	20.9
Kezdeti töltöttségi állapot [%]	50

Az akkumulátorok töltés-kisütés görbéje alapvetően 3 részre osztható, a kisütési görbe a 4-9. ábrán, míg a töltési görbe a 1-29. ábrán látható. Az első rész az exponenciális feszültségesést mutatja az akkumulátor feltöltésekor. A görbe szélessége az akkumulátor típusától függ. A második szakasz az akkumulátorból kinyerhető töltést mutatja, amíg a feszültség az akkumulátor névleges feszültsége alá nem esik. Végül a harmadik rész az akkumulátor teljes kisülését mutatja, amikor a feszültség drasztikusan lecsökken [49].




4-9. ábra. Az akkumulátorok tipikus kisütési görbéje (forrás:[49])

Amikor az akkumulátor árama negatív, akkor töltési fázisban van. A tipikus töltési karakterisztika a 1-29. ábrán látható.

Az akkumulátor vezérlése kezdetben egy egyszerű szabály elvű logika mentén történik:

- ha a napelem termelés nem tudja fedezni a fogyasztási igényt, és az akkumulátor által leadott teljesítmény elegendő, akkor az akkumulátor szolgáltatja a szükséges teljesítményt,
- ha a napelem és az akkumulátor által kiadott teljesítmény nem elegendő a terhelés fedezésére, akkor a hálózat becsatlakozik, és a napelem termelésével együtt (ha van) fedezik a háztartások igényét, illetve az akkumulátor töltését,
- amennyiben a napelem termelés nagyobb, mint a pillanatnyi terhelés, abban az esetben az akkumulátorokba és a hálózatba történik visszatöltés.

A logika megvalósítását a 4-10. ábra mutatja:



4-10. ábra. Az akkumulátor vezérlési logikája

Ahhoz, hogy az akkumulátor névleges feszültségét, és a 700 V-os DC buszt szinkronba hozzassuk, illetve a töltés-kisütés ciklusokat kezelhessük, kétirányú DC-DC konverterre van szükség, amelyet "Buck-Boost" konverternek hívnak. Felépítésében annyiban különbözik a napelemtől használttól, hogy ebben az esetben 2 IGBT kerül beépítésre, illetve egyel kevesebb kapacitás. Az áramköri elemek paraméterei a korábbiakhoz hasonlóan, a 4.8 és 4.9 egyenlettel számolhatók. A Simulink belső megvalósítás a 1-30. ábrán látható.

4-4. táblázat. A Buck-Boost konverterhez felhasznált áramköri elemek paraméterei

Kapacitás (C) [F]	6.1224e-06
Induktivitás (L) [H]	0.0094

Fogyasztók

A szimulációk során valós fogyasztási adatokat használtam fel a lakóépületek fogyasztására vonatkozóan. A mérésből származó értékek óránkénti bontásban álltak rendelkezésre, minden mérésnél más-más értékkel. Ahhoz, hogy ezeket fel tudjam használni, a Simulink beépített "három fázisú terhelés" blokkját használtam, ami három fázisú AC terhelést állít elő a bemeneti hatásos és meddő teljesítmény értékekből. A terhelést kW mértékegységben adtam meg bemenetként.

Három fázisú inverter


Az egyenfeszültségi (DC) és a váltó feszültségi (AC) oldal között a kapcsolatot az inverter teremti meg, amely DC feszültségből AC-t és fordítva állít elő. A szimulációk során a (dq) szinkronvezérlés ("Synchronous Reference Frame Theory") alapú invertert használtam fel. A hálózati feszültséget és az áramot olyan keretté alakítja, amely szinkronban forog a hálózati feszültségvektorral a Park Transzformáció segítségével, így a háromfázisú időben változó jelek egyenáramú jelekké alakulnak [50].

Három fázisú elosztó hálózat

A hálózat egy 400 V-os, 50 Hz-es beépített generátor blokkból áll. A felharmonikusok szűrésére kapacitív szűrők kerültek beépítésre/modellezésre.

5. Mesterséges Intelligencia alapú energiamenedzsment

A fent bemutatott szimulációs környezet akkumulátor menedzsment rendszere tovább fejleszthető Mesterséges Intelligencia alkalmazások segítségével. Az alap modellben az akkumulátor vezérlése a pillanatnyi termelési és terhelési adatokat veszi figyelembe, hogy mikor kell tölteni, illetve mikor kell a kisütési fázisba lépni. Lehetőség van azonban a várható terhelési és napsugárzási értékek figyelembe vételére is. A 5-11. ábrán látható a rendszer egyszerűsített blokkvázlata.



5-11. ábra. A Mesterséges Intelligencia alapú energiamenedzsment egyszerűsített blokkvázlata

A fogyasztói terhelés előre jelzése az ún. LSTM algoritmus ("Long Short-Term Memory") segítségével lehetséges, amely neurális háló algoritmus képes előre jelzést adni a várható terhelés értékéről a tanító adathalmaznak köszönhetően. A napsugárzási adatok figyelésére és előrejelzésére egy külső adatbázis bekötésére lenne szükség, például egy időjárásállomásról. Azért az LSTM modell került kiválasztásra, mert a szakirodalmi ismeretek alapján azokban az időszaki előrejelzési feladatokban, ahol különböző időállandójú jellemzők együttesen hatnak a jövőbeni kimenetre, ez a modell az ismert megközelítések közül a leghatékonyabbnak tartott széles körben. Jól illeszkedik a dolgozatban vizsgált problémához, ahol a különböző fogyasztási profilok és a napelem termelés napi, napszakon belüli, szezonális hatásainak együttes figyelembe vételét igényli a predikció.

Az LSTM algoritmust az RNN-ek ("Recurrent Neural Network") hátrányainak kiküszö-

bölésére fejlesztették ki azáltal, hogy memória- vagy cellaállapotot adnak a hálózathoz [51]. A cella állapota felelős a múltbeli információk hozzáadásáért vagy eltávolításáért, azok relevanciája és az előrejelzés szempontjából fontosságuk alapján. Az LSTM szerkezete összetettebb, mint az RNN. Sorba kapcsolt S cellablokkokkal rendelkezik, ahol S a teljes időlépések vagy a bemeneti adatok hossza. Az 1-31. ábra egy C jellemzőkkel és D rejtett egységgel rendelkező LSTM architektúráját mutatja, az előbbi megegyezik a klasszikus neurális hálózat neuronjainak számával. Minden LSTM cella három beállító kapu blokkból áll az állapotának szabályozására. A kapuk egyszerű neurális hálózatok, amelyek súlyokból, torzításokból és aktiválási függvényekből állnak. A 3 fajta LSTM kapu az alábbi:

- Forget gate, amelynek feladata eldönteni, hogy mely információkra nincs szükség a továbbiakban, azaz melyek "felejtendőek el",
- Update gate, amelynek feladata a Forget gate által szabályozott cellaállapot vagy memória frissítése,
- Output gate feladata pedig az aktuális (rejtett) állapot kiszámítása.

A neurális hálózatot először fel kellett tanítanom a szimulációk futtatása előtt. Ehhez a 2019. évi adatokat használtam fel: a tanítás során 8500 órányi adatot adtam meg bemenetként. A bemenetet 80% tanító, és 20% teszt adathalmazra bontottam fel. A tanítás eredményéről készült diagram az 1-32. ábrán látható.

A hálózat a feltanítása után képes elfogadható pontossággal előre becsülni jövőbeli fogyasztási igényeket. A betanított hálózat teljesítményét a MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error) és az RMSE (Root Mean Square Error) metrikák segítségével értékeltem, melyeket a 5.1, 5.2 és 5.3 egyenletekkel számítottam ki:

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n}, ahol : \quad (5.1)$$

- y_i a prediktált érték,
- x_i a tényleges érték,
- n az illesztett pontok száma.

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{x_i} \right|, ahol : \quad (5.2)$$

- y_i a prediktált érték,
- x_i a tényleges érték,
- n az illesztett pontok száma.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}}, ahol : \quad (5.3)$$

- y_i a prediktált érték,
- x_i a tényleges érték,
- n az illesztett pontok száma.

Az eredményeket a 5-5. táblázat foglalja össze:

5-5. táblázat. A MAE, MAPE, RMSE metrikák értékei

MAE	206
MAPE	0.21
RMSE	339


Az eredményekből látható, hogy az LSTM modell elfogadható pontosságot biztosít. Az LSTM modell paraméterei a 5-6. táblázatban láthatók.

5-6. táblázat. Az LSTM modell paraméterei

Num. of HiddenLayers	2
Num. of Units in First Layer	100
Num. of Units in Second Layer	100
Num. of Units in Third Layer	75
Num. of Units in Fourth Layer	75
Max. Epochs	200
Mini batch size	64

Ezután a kész modellt implemetáltam a Simulink szimulációs keretrendszerbe. A prediktált fogyasztási igényekkel kiegészítve az 5-12. ábrán látható BMS logikát alkottam meg,

az MI alapú optimális energiamenedzsment rendszer tervezésére irányuló munkáim első vizsgálati lépéseként.



5-12. ábra. A BMS logika az LSTM algoritmussal előre jelzett terhelés figyelembe vételével

A szimulációk során 12 óra előre becslését végzi el a rendszer. A Simulink modellbe beépítésre került egy "Callback Button" block, amely lehetővé teszi futási idő közben újabb becslések létrehozását, így az aktuális állapot frissítését. A prediktált adatok összegzésre kerülnek, mint várható maximum szükséges energia a következő 12 órában, ez adja az akkumulátor vezérlés alapját.

Az LSTM logika alapú vezérlés a korábbi logika kiegészítése. A szabályelvű logikába bekerült a várható összterhelés predikciója. Abban az esetben, ha az akkumulátorból adott időpillanatban kivethető összes teljesítmény értéke nem éri el a neurális hálózat által prediktált összes energia igény mértékét, abban az esetben az akkumulátor töltését írja elő a vezérlő, akár a hálózatról is. Ezáltal az akkumulátor 12 órára szükséges teljesítmény eltárolására törekszik, így elősegítve az ellátás-biztonságot.

6. Szimulációs vizsgálatok

A kutatás során a szimulációkkal arra kerestem a választ, hogy vajon a Li-ion akkumulátor megfelelő-e egy ilyen rendszerhez, és ha igen, az hogyan viselkedik a különböző fogyasztási profilok esetén. A következő alfejezetben az alábbi kutatási kérdésekre – RQ (Research Question) jelölést alkalmazva – mutatom be a kezdeti szimulációs vizsgálatok során gyűjtött tapasztalataimat:


RQ1: Hogyan hatnak a különböző fogyasztási profilok az akkumulátor kihasználtságára? Milyen különbségek fedezhetők fel?

RQ2: Az éghajlat szezonalitása milyen hatással van az optimális energiamenedzsment tervezésére?

RQ3: Hogyan és milyen MI technikák használhatók háztartási méretű kiserőművek prediktív energiamenedzsmentjére?

6.1. Vizsgálatok bemutatása


A feladat első lépéseként a [46] forrásból származó adatokból fogyasztási profilokat készítettem. A forrásban a mért értékek elkülönítésre kerültek hétköznap, hétvége, illetve vakáció/nyaralás alapján. A profilok kialakításakor ezeket vettem figyelembe. A terhelési szcenáriók alakulása két napos esetre a 6-13. ábrán láthatók.




6-13. ábra. A különböző terhelési profilok alakulása

A vizsgálatokat kettő időhorizontra osztottam fel az alábbi módon: 2 napos, illetve 10 napos szimulációkat végeztem, melyekhez 2019 júliusi napsugárzási adatokat használtam.


A szezonális elemzéséhez téli és nyári napsugárzási értékeket vettem alapul. Egy ábrán belül legfelül megjelenítésre került a napsugárzási érték, illetve alatta a napelem termelési görbéje. Jól látható, hogy a napelem leköveti a napsugárzás értékeit, annak megfelelően termel. Ezután az adott időszakra vonatkozó terhelés alakulása látható, míg legalul az akkumulátor töltöttségének alakulása %-ban. A két napos szimulációk eredmény diagramjai a 6-14. ábrákon láthatók, a többi pedig az ábrák között a dokumentum végén.



(a) A vakáció időszak alatti eredmények



(b) A hétvége időszak alatti eredmények



(c) A hétköznapi időszak alatti eredmények

6-14. ábra. A két napos szimuláció eredmény diagramjai (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)

6.2. Eredmények értékelése

A futtatások során azt tapasztaltam, hogy mivel a terhelési profilok nagyon hasonlóak, ezért jelentős eltérés az akkumulátor töltöttségének alakulásában nem volt. Az SOC görbék lekövetik a napelem termelés ütemét, azonban a magasabb terheléseknek köszönhetően egyes esetekben jobban merül az akkumulátor az éjszakai időszak alatt. Azt tapasztaltam továbbá, hogy az akkumulátorok reakció ideje és töltési/kisütési mechanikája kémiai paraméter az adott akkumulátorra vonatkozóan, ezért a töltöttségi görbe változásának sebessége fix paraméter az adott akkumulátor típusra nézve. Ennek köszönhetően a fel nem használt, napelem által termelt teljesítményt nap közben a hálózatba kell visszatölteni, illetve amennyiben éjszaka nem elegendő az akkumulátor által leadott teljesítmény, a hálózat becsatlakozására van szükség. A 6-7 táblázatban összegyűjtöttem az akkumulátor töltöttségi szintjének változását %-ban megadva az egyes szimulációk során az egyszerű logikával, a 6-8 táblázatban pedig az LSTM alapú logikával.

A 6-7 táblázat első sorában a nyaralás esetén kiugróan magas a %-os változás értéke. Ez annak köszönhető, hogy a logika szerint a hálózat akkor kapcsolódik be a fogyasztói igények fedezésébe, amikor a napelem és/vagy az akkumulátor pillanatnyi teljesítménye nem elég magas. Mivel nyaralás közben a terhelés alacsony, így nincs szükség a hálózatra, az akkumulátor gyakorlatilag folyamatosan tud merülni, ezért az időszak végére lényegesen nagyobb SOC változást tapasztalunk.


Futási idő [nap]	Fogyasztási profil		
	Hétvége	Hétköznapi	Nyaralás
2	6.5	3	16
10	28	31	31

6-7. táblázat. Az akkumulátor töltöttségének változásai a futási idők alatt %-ban

A 6-8 táblázat alapján jól látható, hogy az SOC csökkenése jelentősen kevesebb az LSTM logika alapú vezérlésnél. Ennek az az oka, hogy a logika nem engedi lemerülni az akkumulátort az alá a töltöttségi szint alá, ahol már nem tudja a következő 12 óra terhelését ellátni szükség esetén. Az 6-15. ábrán látható SOC görbe hullámozása is ennek köszönhető: amikor a megadott szint alá csökken a tárolt energia mennyisége, akkor a hálózaton keresztüli töltés kezdődik meg.


Futási idő [nap]	Fogyasztási profil		
	Hétféje	Hétköznap	Nyaralás
2	4.2	2.8	4.5
10	5.8	6	5.5

6-8. táblázat. Az akkumulátor töltöttségének változásai a futási idők alatt %-ban az LSTM hálózat alapú logikával




6-15. ábra. LSTM alapú BMS vezérléssel futtatott 10 napos szimuláció eredmény diagramjai hétköznap esetén

A szezonális vizsgálatához a 2019 januári napsugárzási adatokat használtam, azonos (hétfégi) fogyasztási profil mellett. A referencia szimuláció eredményeit a júliusi napsugárzási adatokkal, 30 napra, hétféjére végzett futtatás adta. Ahogy a 6-16. ábrán látható, jelentős különbség van az akkumulátor töltöttségi állapotai között: a téli esetben 12%-kal kevesebb a futtatási időszak végén az akkumulátor SOC értéke. A példa remekül rávilágít arra, hogy a téli, gyengébb napsugárzással rendelkező időszakban jóval kisebb a napelem termelése, ami magasabb akkumulátor kihasználtságot eredményez azonos fogyasztási profil mellett. Ennek a jelenségnek a hatásait egyrészt a nagyobb napelem kapacitás beépítésével (amennyiben van rá lehetőség), vagy a megemelkedett hálózathoz vételezett energia mennyiségéből adódó többletköltségek megfizetésével lehet ellensúlyozni.



(a) Szimuláció téli esetre



(b) Szimuláció nyári esetre

6-16. ábra. A szezonális vizsgálatának eredmény diagramjai (lentől felfelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)

6.3. Pontenciális továbbfejlesztési irányok

A dolgozatban megfogalmazott célkitűzés és a bemutatott eredmények alapján több továbbfejlesztési irányt lehet megjelölni. Egy következő munkában tervezem megvizsgálni további, különböző MI alapú technikák (pl.: MLP, fuzzy logika, CNN stb.) teljesítményeinek összehasonlítását a napenergia termelés és fogyasztási igény előrejelzésében. További célfeladat a prediktív energiamenedzsment hatékonyságának megvalósítása érdekében az optimális vezérlési feladat megfogalmazása és implementálása a BMS-ben, figyelembe véve az energiaköltségeket is. Jelenleg alacsony azoknak a rendszereknek a száma, amelyek kifejezetten a BMS optimalizálására, azon belül is MI alapú optimalizálására képesek, ezért indokolt olyan rendszer fejlesztése, amely bizonyos szempontok szerint előre optimalizált BMS-eket tartalmaz. A vizsgálatokat tervezem kibővíteni egy nagyobb háztartás csoportra, ahol nagyobb mértékű és változatosabb terhelési profilok vizsgálatára

nyílik lehetőség, egyúttal a neurális hálózatok által vezérelt akkumulátor menedzsment fejlesztésére. Vizsgálati célkitűzéseim között szerepel hosszabb időhorizontok vizsgálata, akár több évszakos időintervallumok is, amelyekkel alaposabban elemezhető a szezonális hatása az akkumulátor kihasználtságára.

Egy másik továbbfejlesztési irány a rendszerben használt fizikai elemek megváltozásából következő hatások szimulációjára képes keretrendszer fejlesztése, mivel a gyakorlati megvalósítással foglalkozó szakemberek nem rendszerfejlesztéssel, hanem implementálással és teszteléssel kívánnak foglalkozni. A Li-ion akkumulátorok fizikai kialakításukból adódóan nem ideálisak az általam szimulálthoz hasonló rendszerek esetében, mivel élettartamuk a kisütési ciklusok számának növekedésével drasztikusan lecsökken. Számos kutatás zajlik jelenleg a világban a vanádium alapú akkumulátorok működésére, amely gyorsabb reakció időt, magasabb energiasűrűséget ígér. A rendszerben lévő energia tároló, illetve energia termelő berendezések kombinálására is lehetőség van: a napelem modult szélturbinával, míg az akkumulátort szuperkapacitással, vagy más egyéb energiatárolóval lehet kiegészíteni, amelyek együttes optimális energiamenedzsmentjének kidolgozása jelenleg is számos kutatás tárgyát képezi.

7. Összegzés

Az elmúlt években világossá vált, hogy korunk egyik legnagyobb kihívása a folyamatosan, drasztikusan növekvő energia-igényünk kielégítése lesz. A fosszilis energiahordozók mennyisége nem csak véges, de használatuk káros is, ezért a társadalom fókuszát a megújuló energiák felé kell fordítani. A megújuló energiák azonban nem folyamatosan állnak rendelkezésre, azok jelentősen időjárásfüggőek. Erre a problémára adhat egy megoldást az energiatárolóval (jelen esetben akkumulátorral) ellátott háztartási méretű kiserőmű, amely megújuló energia termelésére, raktározására és így felhasználására képes. A dolgozatom célja egy olyan keretrendszer tervezése volt Matlab Simulink környezetben, amely ezen energia menedzsment rendszerek tervezését és modellezését teszi lehetővé. Bemutatásra kerültek méretezési algoritmusok, fizikai kialakítások és egy LSTM neurális hálózat alapú BMS vezérlés is. A State-of-the-Art értelmében az LSTM modellek nyújtják pillanatnyilag a legjobb teljesítményt az időszori előrejelzési feladatokban, ahol az idősor tipikus eseményei között ismeretlen időtartamú késések is előfordulhatnak, különböző időállandójú jelenségeket/ hatásokat kell figyelembe venni. Ilyen jellegű idősorok tipikusan az energiafogyasztás szokás profilok, időjárásfüggő megújuló termelési adatai, ezért ez a modell illeszkedik leginkább a feladathoz.

A kutatás 3 fő céllal rendelkezik, amelyet három kérdés köré szerveztem:

RQ1: Hogyan hatnak a különböző fogyasztási profilok az akkumulátor kihasználtságára? Milyen különbségek fedezhetők fel?

RQ2: Az éghajlat szezonális hatással van az optimális energiamenedzsment tervezésére?

RQ3: Hogyan és milyen MI technikák használhatók háztartási méretű kiserőművek prediktív energiamenedzsmentjére?

A megépített szimulációs környezet által nyújtott kezdetleges eredmények segítségével megállapítható, hogy rövid- és közép távon a fogyasztási profilok különbsége nem okoz jelentős eltérést az akkumulátorok kihasználtságában. A napsugárzási adatok szezonálisából adódó jelentős változások azonban már kihívás elé állíthatja a rendszer tervezőit. Az elkészült rendszer az energia – azon belül az akkumulátor – menedzsment rendszer vezérlésére ad javaslatot, az optimális energia menedzsment meghatározásához pedig további vizsgálatok szükségesek. A szakirodalmi feltárással összhangban fentiekben leírtak okán az LSTM neurális hálózatot választottam a várható villamosenergia fogyasztás előrejelzésére, amelyet beépítettem az akkumulátor menedzsment rendszerbe, ezzel biztosítva

a lehetőséget az akkumulátor töltöttségének közvetlen vezérlésére. Az említett modell szintén alkalmas a napsugárzási adatok alakulásának előrejelzésére, azonban az időjárás sztochasztikus változása miatt itt sztochasztikus modellek alkalmazása válhat szükségessé, időjárásállomások adatainak figyelembe vétele mellett, amely szükséges az akkumulátor optimális kihasználtságát megvalósító energiamenedzsment stratégia kidolgozásához. Az egyszerű szabály alapú és az LSTM-et alkalmazó BMS működésének összehasonlító szimulációs vizsgálatai alátámasztják, hogy az LSTM hálóval optimálisabb kihasználtság érhető el a kisütési ciklusok mélységének csökkentésével, amely hozzájárul a lítium alapú akkumulátor élettartamának növeléséhez (a fogyasztói szokásokba történő beavatkozás nélkül), ezáltal pedig a gazdaságosabb üzemeltetéséhez. Tekintettel arra, hogy a lítium alapú akkumulátoroknak sokféle, eltérő karakterisztikájú változata érhető el a piacon, illetve a szimulációban alkalmazott modell bizonyos egyszerűsítésekkel él (pl., hőmérsékleti hatások nincsenek figyelembe véve), ez a kérdéskör az optimális szabályozással együtt szintén a jövőbeni kiterjedtebb vizsgálatok részét képezi.

Hivatkozások

- [1] <http://energyatlas.iea.org/#!/tellmap/-1002896040/>, 2022 (utoljára megtekintve: 2022. 11. 01.).
- [2] F. Vivas, A. De las Heras, F. Segura, and J. Andújar, „A review of energy management strategies for renewable hybrid energy systems with hydrogen backup,” *Renewable and Sustainable Energy Reviews*, vol. 82, pp. 126–155, 2018.
- [3] F. Ceglia, P. Esposito, A. Faraudello, E. Marrasso, P. Rossi, and M. Sasso, „An energy, environmental, management and economic analysis of energy efficient system towards renewable energy community: The case study of multi-purpose energy community,” *Journal of Cleaner Production*, vol. 369, p. 133269, 2022.
- [4] H. Liu, B. Wu, A. Maleki, and F. Pourfayaz, „An improved particle swarm optimization for optimal configuration of standalone photovoltaic scheme components,” *Energy Science Engineering*, vol. 10, 01 2022.
- [5] F. Vivas, F. Segura, and J. Andújar, „Fuzzy logic-based energy management system for grid-connected residential dc microgrids with multi-stack fuel cell systems: A multi-objective approach,” *Sustainable Energy, Grids and Networks*, vol. 32, p. 100909, 2022.
- [6] A. H. Fathima and K. Palanisamy, „Optimization in microgrids with hybrid energy systems – a review,” *Renewable and Sustainable Energy Reviews*, vol. 45, pp. 431–446, 2015.
- [7] Y. Wu, Z. Liu, B. Li, J. Liu, and L. Zhang, „Energy management strategy and optimal battery capacity for flexible pv-battery system under time-of-use tariff,” *Renewable Energy*, vol. 200, pp. 558–570, 2022.
- [8] I. Tégani, A. Aboubou, M. Y. Ayad, M. Becherif, and M. Bahri, „Power flow management in wt/fc/sc hybrid system using flatness based control,” in *3rd International Symposium on Environmental Friendly Energies and Applications (EFEA)*, pp. 1–7, 2014.
- [9] M. E. Talebian, S. Sobhani, and A. Borzooi, „New hybrid system of fuel cell power plant and wind turbine for household consumption,” in *2013 3rd International Conference on Electric Power and Energy Conversion Systems*, pp. 1–6, 2013.

- [10] M. Hatti, A. Meharrar, and M. Tioursi, „Power management strategy in the alternative energy photovoltaic/pem fuel cell hybrid system,” *Renewable and Sustainable Energy Reviews*, vol. 15, no. 9, pp. 5104–5110, 2011.
- [11] N. Karami, N. Moubayed, and R. Outbib, „Energy management for a pemfc–pv hybrid system,” *Energy Conversion and Management*, vol. 82, pp. 154–168, 2014.
- [12] G. Bruni, S. Cordiner, M. Galeotti, V. Mulone, M. Nobile, and V. Rocco, „Control strategy influence on the efficiency of a hybrid photovoltaic-battery-fuel cell system distributed generation system for domestic applications,” *Energy Procedia*, vol. 45, pp. 237–246, 2014. ATI 2013 - 68th Conference of the Italian Thermal Machines Engineering Association.
- [13] A. Azad, H. Shateri, and V. Vahidinasab, „Optimal planning of a stand-alone hybrid energy farm encompassing wind, pv, diesel generator and storage unit,” 12 2020.
- [14] X. Wang, C. Tong, A. Palazoglu, and N. H. El-Farra, „Energy management for the chlor-alkali process with hybrid renewable energy generation using receding horizon optimization,” in *53rd IEEE Conference on Decision and Control*, pp. 4838–4843, 2014.
- [15] M. Rouholamini and M. Mohammadian, „Heuristic-based power management of a grid-connected hybrid energy system combined with hydrogen storage,” *Renewable Energy*, vol. 96, pp. 354–365, 2016.
- [16] R. Cozzolino, L. Tribioli, and G. Bella, „Power management of a hybrid renewable system for artificial islands: A case study,” *Energy*, vol. 106, pp. 774–789, 2016.
- [17] A. Brka, G. Kothapalli, and Y. M. Al-Abdeli, „Predictive power management strategies for stand-alone hydrogen systems: Lab-scale validation,” *International Journal of Hydrogen Energy*, vol. 40, no. 32, pp. 9907–9916, 2015.
- [18] N. Bizon, M. Oproescu, and M. Raceanu, „Efficient energy control strategies for a standalone renewable/fuel cell hybrid power source,” *Energy Conversion and Management*, vol. 90, pp. 93–110, 2015.
- [19] J. P. Torreglosa, P. García, L. M. Fernández, and F. Jurado, „Energy dispatching based on predictive controller of an off-grid wind turbine/photovoltaic/hydrogen/battery hybrid system,” *Renewable Energy*, vol. 74, pp. 326–336, 2015.

- [20] P. García, J. P. Torreglosa, L. M. Fernández, and F. Jurado, „Improving long-term operation of power sources in off-grid hybrid systems based on renewable energy, hydrogen and battery,” *Journal of Power Sources*, vol. 265, pp. 149–159, 2014.
- [21] M. H. Cano, S. Kelouwani, K. Agbossou, and Y. Dubé, „Power management system for off-grid hydrogen production based on uncertainty,” *International Journal of Hydrogen Energy*, vol. 40, no. 23, pp. 7260–7272, 2015.
- [22] P. García-Triviño, F. Llorens-Iborra, C. A. García-Vázquez, A. J. Gil-Mena, L. M. Fernández-Ramírez, and F. Jurado, „Long-term optimization based on pso of a grid-connected renewable energy/battery/hydrogen hybrid system,” *International Journal of Hydrogen Energy*, vol. 39, no. 21, pp. 10805–10816, 2014.
- [23] A. Chauhan and R. Saini, „A review on integrated renewable energy system based power generation for stand-alone applications: Configurations, storage options, sizing methodologies and control,” *Renewable and Sustainable Energy Reviews*, vol. 38, pp. 99–120, 2014.
- [24] B. B. Adetokun, O. Oghorada, and S. J. Abubakar, „Superconducting magnetic energy storage systems: Prospects and challenges for renewable energy applications,” *Journal of Energy Storage*, vol. 55, p. 105663, 2022.
- [25] U. o. W. Clean Energy Institute, „What is a lithium-ion battery and how does it work?,” 2022 (utoljára megtekintve: 2022. 11. 01.).
- [26] G. Merei, C. Berger, and D. U. Sauer, „Optimization of an off-grid hybrid pv–wind–diesel system with different battery technologies using genetic algorithm,” *Solar Energy*, vol. 97, pp. 460–473, 2013.
- [27] P. Paliwal, N. Patidar, and R. Nema, „Determination of reliability constrained optimal resource mix for an autonomous hybrid power system using particle swarm optimization,” *Renewable Energy*, vol. 63, pp. 194–204, 2014.
- [28] A. Askarzadeh, „A discrete chaotic harmony search-based simulated annealing algorithm for optimum design of pv/wind hybrid system,” *Solar Energy*, vol. 97, pp. 93–101, 2013.
- [29] M. team, „What is fuzzy logic?,” 2022 (utoljára megtekintve: 2022. 11. 01.).

- [30] F.-C. Li and C.-X. Jin, „Study on fuzzy optimization methods based on principal operation and inequity degree,” *Computers Mathematics with Applications*, vol. 56, no. 6, pp. 1545–1555, 2008.
- [31] M. team, „Foundations of fuzzy logic,” 2022 (utoljára megtekintve: 2022. 11. 01.).
- [32] A. Mellit, M. Benghanem, A. H. Arab, and A. Guessoum, „An adaptive artificial neural network model for sizing stand-alone photovoltaic systems: application for isolated sites in algeria,” *Renewable Energy*, vol. 30, no. 10, pp. 1501–1524, 2005.
- [33] P. Jienkulsawad, K. Eamsiri, Y.-S. Chen, and A. Arpornwichanop, „Neural network-based adaptive control and energy management system of a direct methanol fuel cell in a hybrid renewable power system,” *Sustainable Cities and Society*, vol. 87, p. 104192, 2022.
- [34] A. Izadi, M. Shahafve, and P. Ahmadi, „Neural network genetic algorithm optimization of a transient hybrid renewable energy system with solar/wind and hydrogen storage system for zero energy buildings at various climate conditions,” *Energy Conversion and Management*, vol. 260, p. 115593, 2022.
- [35] X. Guo, L. Zhou, Q. Guo, and B. D. Rouyendegh, „An optimal size selection of hybrid renewable energy system based on fractional-order neural network algorithm: A case study,” *Energy Reports*, vol. 7, pp. 7261–7272, 2021.
- [36] S. Abedi and S. Kwon, „Rolling-horizon optimization integrated with recurrent neural network-driven forecasting for residential battery energy storage operations,” *International Journal of Electrical Power Energy Systems*, vol. 145, p. 108589, 2023.
- [37] X. Hu, F. Feng, K. Liu, L. Zhang, J. Xie, and B. Liu, „State estimation for advanced battery management: Key challenges and future trends,” *Renewable and Sustainable Energy Reviews*, vol. 114, p. 109334, 2019.
- [38] Y. Liu and G. Venayagamoorthy, „An intelligent energy management system for a photovoltaic-battery system,” *IFAC Proceedings Volumes*, vol. 45, no. 21, pp. 115–120, 2012. 8th Power Plant and Power System Control Symposium.
- [39] S. Behera and N. Choudhury, „Modeling and simulations of modified slime mould algorithm based on fuzzy pid to design an optimal battery management system in microgrid,” *Cleaner Energy Systems*, p. 100029, 10 2022.

- [40] A. Kumar, M. Alaraj, M. Rizwan, and U. Nangia, „Novel ai based energy management system for smart grid with res integration,” *IEEE Access*, vol. 9, pp. 162530–162542, 2021.
- [41] M. A. Hossain, H. R. Pota, and C. M. Moreno, „Real-time battery energy management for residential solar power system,” *IFAC-PapersOnLine*, vol. 52, no. 4, pp. 407–412, 2019. IFAC Workshop on Control of Smart Grid and Renewable Energy Systems CSGRES 2019.
- [42] G. Zhang, W. Hu, D. Cao, W. Liu, R. Huang, Q. Huang, Z. Chen, and F. Blaabjerg, „Data-driven optimal energy management for a wind-solar-diesel-battery-reverse osmosis hybrid energy system using a deep reinforcement learning approach,” *Energy Conversion and Management*, vol. 227, p. 113608, 2021.
- [43] M. Group, „Project illumine: Energy for a smart planet,” 2022 (utoljára megtekintve: 2022. 11. 01.).
- [44] E. . I. I. R. A. Dr. Julian De Hoog, Technical Lead, „How ai will help to accelerate the transition to renewables and energy storage,” 2019 (utoljára megtekintve: 2022. 11. 01.).
- [45] N. E. Group, „High-voltage battery management system,” 2022 (utoljára megtekintve: 2022. 11. 01.).
- [46] S. POLU, „Residential power usage 3years data - timeseries,” 2020 (utoljára megtekintve: 2022. 11. 01.).
- [47] N. R. E. L. (NREL), „Historical irradiation data of hungary,” 2022 (utoljára megtekintve: 2022. 11. 01.).
- [48] R. I. Putri, S. Wibowo, and M. Rifa’i, „Maximum power point tracking for photovoltaic using incremental conductance method,” *Energy Procedia*, vol. 68, pp. 22–30, 2015. 2nd International Conference on Sustainable Energy Engineering and Application (ICSEEA) 2014 Sustainable Energy for Green Mobility.
- [49] M. team, „Generic battery model,” 2022 (utoljára megtekintve: 2022. 11. 01.).
- [50] I. Jayathilaka, L. Lakpriya, D. De Alwis, G. Jayakody, K. Hemapala, J. Karunadasa, and H. Lakshika, „Dq transform based current controller for single-phase grid connected inverter,” in *2018 2nd International Conference On Electrical Engineering (EECon)*, pp. 32–37, 2018.

- [51] A. I. Hamad, Z., „Deep learning-based load forecasting considering data reshaping using matlab,” *Int J Energy Environ Eng* 13, 853–869, <https://doi.org/10.1007/s40095-022-00480-x>, 2022.

Ábrajegyzék


1-1. A világ legnagyobb CO ₂ kibocsátó országai (Forrás: http://energyatlas.iea.org)	3
1-2. A 4 legnagyobb energia-felhasználó fogyasztása az elmúlt 50 évben (Forrás: http://energyatlas.iea.org)	3
1-3. Fosszilis energiahordozók részaránya a villamosenergia-termelésben[1]	4
1-4. A világ országainak CO ₂ kibocsátása csökkenő sorrendben [1]	4
2-5. Energiatároló kialakítások [24]	8
2-6. Akkumulátor típusok összehasonlítása [25]	10
2-7. A különböző méretezési módok [23]	10
4-8. Az elkészült szimulációs rendszer egyszerűsített blokkvázlata	22
4-9. Az akkumulátorok tipikus kisütési görbéje (forrás:[49])	26
4-10. Az akkumulátor vezérlési logikája	27
5-11. A Mesterséges Intelligencia alapú energiamenedzsment egyszerűsített blokkvázlata	29
5-12. A BMS logika az LSTM algoritmussal előre jelzett terhelés figyelembe vételével	32
6-13. A különböző terhelési profilok alakulása	33
6-14. A két napos szimuláció eredmény diagramjai (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)	34
6-15. LSTM alapú BMS vezérléssel futtatott 10 napos szimuláció eredmény diagramjai hétköznap esetén	36
6-16. A szezonális vizsgálatának eredmény diagramjai (lentől felfelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)	37
1-17. Izolált, hálózatra nem kapcsolt rendszer egyszerűsített blokkvázlata [2]	50
1-18. Hálózatra kapcsolt rendszer egyszerűsített blokkvázlata [2]	50
1-19. DC busz kialakítás egyszerűsített blokkvázlata [2]	51
1-20. AC busz kialakítás egyszerűsített blokkvázlata [2]	52
1-21. Hibrid busz kialakítás egyszerűsített blokkvázlata [2]	52
1-22. A javasolt hibrid energia menedzsment rendszer folyamatábrája [40]	53
1-23. A bemutatott rendszer blokkvázlata [42]	53
1-24. Az összerterhelés alakulása az év során	54
1-25. A napsugárzás alakulása az év során	54

1-26. A felhasznált napelem panel I-V és P-V görbéi	55
1-27. Az IC folyamatábrája	56
1-28. A megépített rendszer boost konverter része	57
1-29. Az akkumulátorok tipikus töltési görbéje [49].....	57
1-30. A megépített rendszer Buck-Boost konverter része	58
1-31. Az LSTM algoritmus felépítése (forrás: [51]).....	58
1-32. A betanított LSTM modell teljesítménye. Mért- (kék vonal) és prediktált (piros vonallal) fogyasztási értékek W-ban	59
1-33. A 10 napos vakáció szimuláció eredmény diagramjai a szabály elvű logikával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Ter- helés értéke (kW), Akkumulátor töltöttségi állapot (%).....	59
1-34. A 10 napos hétköznapi szimuláció eredmény diagramjai a szabály elvű logikával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Ter- helés értéke (kW), Akkumulátor töltöttségi állapot (%).....	60
1-35. A 10 napos hétvége szimuláció eredmény diagramjai a szabály elvű logi- kával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)	60
1-36. A 30 napos vakáció szimuláció eredmény diagramjai a szabály elvű logikával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Ter- helés értéke (kW), Akkumulátor töltöttségi állapot (%).....	61
1-37. A 30 napos hétvége szimuláció eredmény diagramjai a szabály elvű logikával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Ter- helés értéke (kW), Akkumulátor töltöttségi állapot (%).....	62
1-38. Az elkészített rendszer Simulink környezetben	63
1-39. Az elkészített rendszer Simulink környezetben	63


Táblázatok jegyzéke

4-1. A napelem panel főbb paraméterei	23
4-2. A boost konverterhez felhasznált áramköri elemek paraméterei	25
4-3. A felhasznált akkumulátor paraméterei	25
4-4. A Buck-Boost konverterhez felhasznált áramköri elemek paraméterei	27
5-5. A MAE, MAPE, RMSE metrikák értékei	31
5-6. Az LSTM modell paraméterei	31
6-7. Az akkumulátor töltöttségének változásai a futási idők alatt %-ban	35
6-8. Az akkumulátor töltöttségének változásai a futási idők alatt %-ban az LSTM hálózat alapú logikával	36


A. Melléklet: Ábrák Gyűjteménye




1-17. ábra. Izolált, hálózatra nem kapcsolt rendszer egyszerűsített blokkvázlata [2]




1-18. ábra. Hálózatra kapcsolt rendszer egyszerűsített blokkvázlata [2]




1-19. ábra. DC busz kialakítás egyszerűsített blokkvázlata [2]




1-20. ábra. AC busz kialakítás egyszerűsített blokkvázlata [2]




1-21. ábra. Hibrid busz kialakítás egyszerűsített blokkvázlata [2]




1-22. ábra. A javasolt hibrid energia menedzsment rendszer folyamatábrája [40]




1-23. ábra. A bemutatott rendszer blokkvázlata [42]




1-24. ábra. Az összerhelés alakulása az év során




1-25. ábra. A napsugárzás alakulása az év során




1-26. ábra. A felhasznált napelem panel I-V és P-V görbéi




1-27. ábra. Az IC folyamatábrája




1-28. ábra. A megépített rendszer boost konverter része




1-29. ábra. Az akkumulátorok tipikus töltési görbéje [49]




1-30. ábra. A megépített rendszer Buck-Boost konverter része




1-31. ábra. Az LSTM algoritmus felépítése (forrás: [51])




1-32. ábra. A betanított LSTM modell teljesítménye. Mért- (kék vonal) és prediktált (piros vonal) fogyasztási értékek W-ban




1-33. ábra. A 10 napos vakáció szimuláció eredmény diagramjai a szabály elvű logikával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)




1-34. ábra. A 10 napos hétvége szimuláció eredmény diagramjai a szabály elvű logikával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)



1-35. ábra. A 10 napos hétköznapi szimuláció eredmény diagramjai a szabály elvű logikával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)




1-36. ábra. A 30 napos vakáció szimuláció eredmény diagramjai a szabály elvű logikával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)




1-37. ábra. A 30 napos hétvége szimuláció eredmény diagramjai a szabály elvű logikával (fentről lefelé): Napsugárzás értékei (W/m^2), Napelem termelés (kW), Terhelés értéke (kW), Akkumulátor töltöttségi állapot (%)

Three Phase Grid Connected solar PV and Battery system



1-38. ábra. Az elkészített rendszer Simulink környezetben



1-39. ábra. Az elkészített rendszer Simulink környezetben