




UNIVERSITATEA NAȚIONALĂ DE
ȘTIINȚĂ ȘI TEHNOLOGIE
POLITEHNICA BUCUREȘTI



Școala Doctorală de Electronică, Telecomunicații
și Tehnologia Informației

Decizie nr. 81 din 19.07.2024

REZUMAT TEZĂ DE DOCTORAT

Husam Mahdi Salih AL-ALWASH

CONTRIBUȚII LA COMUNICATIILE IN
INTERNETUL VEHICULELOR

CONTRIBUTIONS TO THE COMMUNICATIONS
IN INTERNET OF VEHICLES

COMISIA DE DOCTORAT

Prof. Dr. Ing. Ion MARGHESCU National University of Science and Technology Politehnica Bucharest	Președinte
Prof. Dr. Ing. Eugen BORCOCI National University of Science and Technology Politehnica Bucharest	Conducător de doctorat
Prof. Dr. Ing. Sorin ZOICAN National University of Science and Technology Politehnica Bucharest	Referent
Prof. Dr. Ing. Virgil DOBROTA Technical University of Cluj-Napoca	Referent
Prof. Dr. Ing. Florin ALEXA Politehnica University Timisoara	Referent

BUCUREȘTI 2024

Cuprins

1. Introducere	1
1.1 Scopul tezei de doctorat	2
1.2 Conținutul tezei de doctorat	2
2. Abordări de Control Inteligent: Permite Eficientă a Încărcării și Descărcării	5
2.1 Integrarea SDN în rețeaua inteligentă	5
2.2 Probleme de cercetare deschise	6
3. Scheme de Programare Optimizate pentru Încărcarea Vehiculelor Electrice: Prezentare Generală, Provocări și Soluții	7
3.1 Tipuri de vehicule electrice	7
3.2 Modele și tipuri de Încărcare pentru EV	8
3.3 Strategii de Încărcare a EV	9
3.3 Sisteme centralizate, descentralizate și ierarhice	9
3.5 Tehnici de optimizare pentru încărcarea EV	11
3.6 <i>Probleme Deschise și Direcții Viitoare</i>	15
4. Scheme de Rutare și Programare a Încărcării pentru Vehicule Electrice în Rețelele Vehiculare Bazate pe SDN	17
4.1 Metodologie	17
4.2 Rezultate și discuții	20
5. Optimizare Genetică cu Sortare Non-Dominată pentru Programarea Încărcării Vehiculelor Electrice cu Conștientizare a Timpului și Costurilor	23
5.1 Metodologie	23
5.1.2 Optimizarea încărcării EV-urilor utilizând NSGA-II	24
5.1.2 Ant colony optimisation	25
5.1.3 Simulated Annealing	25
5.2 Rezultate și discuții	26
6. Metodă de Încărcare Inteligentă și Adaptabilă pentru Vehicule Electrice, Ținând Cont de Încărcarea Urgentă	31
6.1 Metodologie	31
6.2 Rezultate și discuții	33
7. Concluzii și lucrări viitoare	35
7.1 Contribuții originale	35
7.2 Lista publicațiilor originale	37
7.3 Lucrări viitoare	38
Bibliography	39

Capitolul 1

Introducere

Acest capitol începe cu o scurtă prezentare a internetului vehiculelor (IoV). IoV este un aspect unic și personalizat al internetului lucrurilor (IoT) care permite gestionarea integrată a transportului inteligent și a altor aplicații în cadrul orașelor inteligente [1] (de exemplu, Figura 1.1). În plus, acest capitol prezintă domeniul tezei de doctorat; integrarea vehiculelor electrice (EV) în orașele inteligente prin comunicarea IoV. Se explică beneficiile integrării vehiculelor electrice în orașe, subliniind faptul că acestea pot reduce semnificativ poluarea aerului și emisiile de gaze, fiind o strategie de transport durabilă, producând zero emisii de carbon. De asemenea, IoV facilitează monitorizarea și gestionarea infrastructurii de încărcare a vehiculelor electrice, permițând schimbul de date în timp real între vehiculele electrice, stațiile de încărcare și alți operatori ai rețelei electrice, cum ar fi agregatorii.

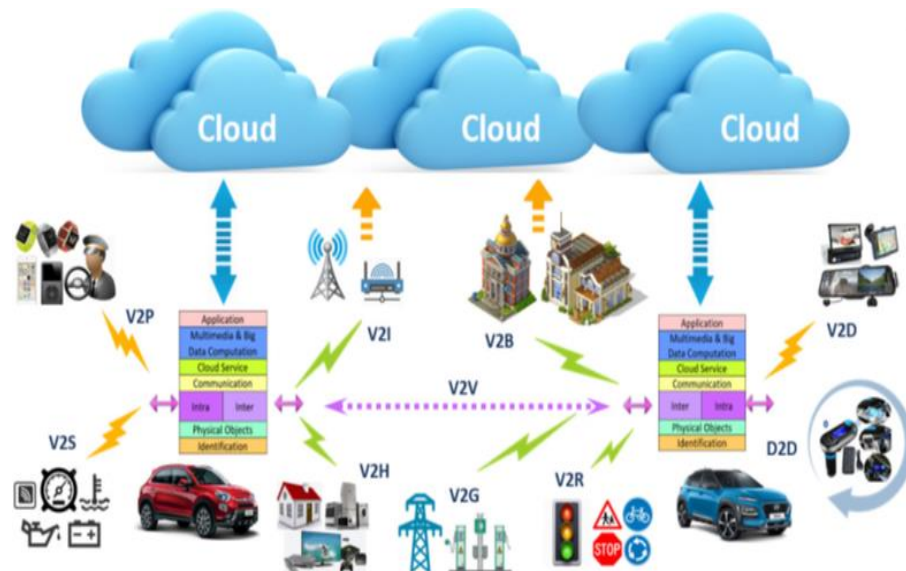


Figura 1.1 Tipuri de comunicare ale vehiculelor în orașele inteligente prin IoV [2].

1.1 Scopul tezei de doctorat

Această teză se concentrează pe problema încărcării EV și cerințele de coordonare. Iată câteva probleme de cercetare provocatoare care sunt abordate în această teză, cu accent pe problemele de încărcare a vehiculelor electrice:

- 1 Care este conceptul tehnologiei grid to vehicle (G2V) and vehicle to grid (V2G) și cum facilitează fluxul bidirecțional de energie între vehiculele electrice și rețea?
- 2 Care sunt diversele aplicații ale tehnologiilor G2V/V2G și cum poate contribui aceasta la sistemul energetic general?
- 3 Care sunt diferitele modele de încărcare observate la încărcarea vehiculelor electrice?
- 4 De ce este necesară coordonarea încărcării și cum pot beneficia atât utilizatorii de vehicule electrice, cât și furnizorii de servicii de implementarea acesteia?
- 5 Cum poate fi proiectat un sistem de încărcare pentru a coordona eficient încărcarea vehiculelor electrice, ținând cont de diverse constrângeri și factori?
- 6 Ce tehnici de optimizare pot fi utilizate pentru a obține un sistem de încărcare optim pentru vehiculele electrice, luând în considerare mai mulți factori, cum ar fi capacitatea și starea actuală a rețelei, preferințele utilizatorilor și costurile energiei?

1.2 Conținutul tezei de doctorat

Lucrarea viitoare este organizată după cum urmează:

Capitolul 2 explorează aspectele esențiale ale încărcării și descărcării EV în rețelele G2V/V2G și analizează integrarea software definind networking (SDN) în rețelele vehiculare pentru o comunicare și coordonare îmbunătățite între vehicule, stațiile de încărcare și rețeaua electrică. Capitolul identifică problemele de cercetare deschise, subliniind necesitatea unor cercetări suplimentare.

Capitolul 3 oferă o revizuire a tehnologiei EV și abordează problemele de optimizare a schemei de încărcare. Sistemele de încărcare sunt prezentate și discutate, inclusiv avantajele și dezavantajele acestora; sunt clasificate în: centralizate, descentralizate și ierarhice. Capitolul acoperă cercetările recente în tehnici de optimizare destinate optimizării încărcării EV și identifică, de asemenea, limitările și lacunele în soluțiile actuale. De asemenea, sunt propuse mai multe provocări împreună cu soluțiile lor potențiale.

Capitolul 4 explorează beneficiile SDN și ale calculului în cloud pentru a introduce un nou model flexibil de sistem de încărcare. Se propune o metodă

optimizată de încărcare pentru a rezolva programarea și rutarea încărcării EV-urilor, având ca scop minimizarea costurilor de timp.

Capitolul 5 se concentrează pe problema optimizării multi-obiective. Studiul utilizează bi-non-dominat genetic algorithm (NSGA-II) pentru a optimiza simultan doi factori, inclusiv costul de încărcare și timpul. Lucrarea compară NSGA-II cu algoritmi genetici (GA) în minimizarea costurilor totale în termeni de timp și preț. În plus, lucrarea a fost extinsă prin compararea optimizării cu ant colony (ACO) și simulated annealing (SA) pentru a optimiza încărcarea EV-urilor în termeni de timp și costuri.

Capitolul 6 propune o strategie de încărcare adaptabilă pentru a reduce creșterile de sarcină de vârf asupra rețelei electrice, luând în considerare situația cererii urgente de încărcare a vehiculelor electrice. Lucrarea folosește algoritmul de partical swarm optimization (PSO) pentru a selecta adaptiv modul de încărcare pentru utilizatorii de vehicule electrice.

În final, contribuțiile acestei teze sunt concluzionate în Capitolul 7, iar lucrările viitoare sunt propuse pentru explorări suplimentare.

Capitolul 2

Abordări de Control Inteligent: Permitere Eficientă a Încărcării și Descărcării

Acest capitol abordează diverse strategii de control inteligent care facilitează încărcarea și descărcarea eficientă a vehiculelor electrice (EV). Sunt discutate mecanismele de dispecerizare a energiei în termeni de G2V și V2G din perspectivele beneficiilor atât pentru rețeaua electrică, cât și pentru utilizatorii de EV-uri. O implementare de succes a G2V/V2G necesită instalarea a trei elemente critice:

- conexiune prin cablu sau fără fir care permite o interfață de încărcare bidirecțională pentru a transfera energia electrică între rețeaua electrică și EV.
- Un subsistem de comunicație cu operatorul rețelei prin conexiuni de control și date pentru a trimite și primi informații de la rețea, de exemplu, indicând în ce direcție ar trebui să fie trimisă puterea (adică cererea de încărcare sau descărcare) și altele.
- Logica de control și monitorizare la bordul vehiculelor.

2.1 Integrarea SDN în rețeaua inteligentă

Această secțiune discută integrarea software define network (SDN) în rețelele inteligente, subliniind potențialul acesteia de a îmbunătăți stabilitatea și gestionarea sistemului. De exemplu, într-o rețea inteligentă bazată pe SDN, se pot realiza echilibrarea și schimbarea sarcinii, modificarea dinamică a rutelor pentru comenzile de control ale rețelei inteligente, detectarea rapidă a defecțiunilor, securitate, auto-vindecare, monitorizarea și programarea fluxurilor esențiale de trafic ale rețelei inteligente [3]. Acest capitol prezintă numeroase contribuții care au abordat integrarea SDN în rețea. De exemplu, studiul din [4] a propus un cadru SDN pe două niveluri utilizat pentru integrarea vehiculelor electrice plug-in (PEV) în rețeaua inteligentă. Studiul din [5] a propus un sistem software definit vehicul-la-rețea (SD-V2G), care integrează tehnologia SDN. Lucrarea [6] a introdus un sistem de încărcare pentru vehicule electrice hibride (HEV), numit green-software-defined-charging-network, care încorporează atât metode wireless, cât și cablate pentru încărcare. În cele din

urmă, studiul din [7] a propus un sistem de multicasting software-definit pentru monitorizarea stării bateriei (BSS-SDM), permițând rețelei inteligente să controleze și să monitorizeze energia distribuită a vehiculelor electrice.

2.2 Probleme de cercetare deschise

Această secțiune identifică mai multe probleme de cercetare deschise în domeniile de încărcare/descărcare a EV pentru explorări ulterioare:

1. *Managementul inteligent al încărcării/descărcării EV-urilor*: Managementul încărcării și descărcării EV-urilor este o problemă complexă care implică echilibrarea mai multor factori, cum ar fi optimizarea experienței utilizatorilor de EV-uri, a rețelei electrice și a costurilor de încărcare. Accentul principal este aici pe modul de coordonare a comportamentului de încărcare/descărcare a EV-urilor și dezvoltarea unei scheme optime care să maximizeze beneficiile pentru utilizatorii de EV-uri în funcție de condițiile rețelei electrice.
2. *Comunicare și notificări*: Utilizatorii de EV-uri pot primi notificări sau pot folosi aplicații mobile care oferă informații în timp real despre prețurile electricității și perioadele de vârf de cerere. Acest lucru le permite să-și ajusteze programul de încărcare în consecință și să își optimizeze consumul de electricitate. Stabilirea unei rețele de comunicații între EV-uri, stații și rețea permite monitorizarea și controlul în timp real.
3. *Algoritmi inteligenți de încărcare*: Algoritmii inteligenți pot optimiza programele de încărcare ale EV-urilor pe baza unor factori precum condițiile rețelei, prețurile electricității și preferințele utilizatorilor. Acești algoritmi pot coordona încărcarea EV-urilor pentru a maximiza utilizarea energiei regenerabile, a minimiza stresul asupra rețelei și a reduce costurile.
4. *Încărcare cu fir și fără fir*: Diverse standarde de încărcare au fost implementate în practică (fie în tehnologia de încărcare cu fir sau fără fir). Ar trebui cercetat și definit un standard unic de încărcare. Încărcarea statică și dinamică pot juca ambele un rol important în încărcarea EV-urilor fără fir.
5. *Sincronizarea între niveluri*: Agregatorii din alimentatoarele primare primesc și implementează instrucțiunile de la nivelul superior. Pe de altă parte, primesc cereri de la dispozitivele fizice din nivelul inferior și răspund corespunzător. Este necesară efectuarea de mai multe cercetări asupra problemei echilibrării și analizării procesului între cererile din nivelul inferior și direcțiile din nivelul superior [4].

Lucrările din capitolele următoare se concentrează pe abordarea provocărilor legate de coordonarea încărcării EV-urilor (adică, problemele 1 și 3) și dezvoltarea schemelor de încărcare optimizate.

Capitolul 3

Scheme de Programare Optimizate pentru Încărcarea Vehiculelor Electrice: Prezentare Generală, Provocări și Soluții

Este important să se implementeze scheme de încărcare inteligentă care să gestioneze și să reglementeze procesele de încărcare ale EV. Cu toate acestea, diverse articole științifice de sinteză privind optimizarea strategiilor de încărcare au fost publicate, precum în [8] [9] [10] [11]. Totuși, cercetările existente au explorat în principal metode generale de încărcare a EV-urilor și s-au concentrat pe programarea standard a încărcării EV-urilor sub strategii de prețuri dinamice și managementul fluxului de energie. Complementar, acest capitol oferă o prezentare generală cuprinzătoare a diferitelor scheme de programare optimizată pentru încărcarea EV-urilor. Clasifică EV-urile și modurile lor de încărcare, inclusiv încărcarea la domiciliu, publică și mobilă. Capitolul revizuieste diferite strategii de încărcare, cum ar fi încărcarea necoordonată și coordonată, și contrastează sistemele centralizate și descentralizate. Diverse tehnici de optimizare, inclusiv programarea liniară, programarea dinamică, algoritmi euristici și abordările de învățare automată, sunt analizate pentru aplicabilitatea lor în încărcarea EV-urilor. Capitolul contribuie cu o discuție despre limitările și lacunele din cercetările actuale și sugerează direcții potențiale pentru studii viitoare.

3.1 Tipuri de vehicule electrice

Există patru tipuri principale de vehicule electrice, clasificate în literatura de specialitate [12] (vezi Tabelul 3.1): battery electric vehicles (BEVs), plug-in hybrid electric vehicles (PHEVs), hybrid electric vehicles (HEVs), and fuel cell electric vehicles (FCEVs).

Tabelul 3.1 Tipurile de EVs

Tip	Cost	Design de Conducere	Accesibilitate pentru Încărcare	Modele	Ref.
HEVs	Mică până la moderată	Toate obiceiurile de conducere	Nu este aplicabil; auto-încărcare	Toyota Prius, Honda Accord Hybrid, Ford Fusion Hybrid	[13] [14] [15]
PHEVs	Moderată până la ridicată	Călătorii scurte zilnice, călătorii mai lungi ocazionale	Stații publice sau la domiciliu	Ford Fusion Energy, Toyota Prius Prime, Chevrolet Volt,	[12] [13] [14]
BEVs	Ridicată	Călătorii scurte până la medii zilnice, călătorii mai lungi ocazionale	Stații publice sau la domiciliu	BMW i3, Tesla Model S, Nissan Leaf,	[12] [16] [17]
FCEVs	Ridicată	Toate obiceiurile de conducere	Stații de hidrogen	Honda Clarity, Toyota Mirai, Hyundai Nexo	[14] [18]

3.2 Modele și tipuri de Încărcare pentru EV

Există patru moduri principale de încărcare bazate pe clasificarea Deltrix Chargers [19]. Modul 1 este cea mai lentă formă de încărcare pentru un EV situat la stațiile de acasă. Modul 2 utilizează de asemenea un priză de acasă pentru încărcarea EV-urilor, oferind protecție împotriva șocurilor electrice atât pentru curenți AC cât și DC. Modul 3 este cea mai populară metodă de încărcare în rândul utilizatorilor de EV-uri. Poate fi implementat atât acasă, cât și la stațiile de încărcare publice, iar cablurile de conectare necesare sunt furnizate la stații. Modul 4, adesea denumit modul de încărcare rapidă, implică utilizarea stațiilor de încărcare care convertesc puterea AC în DC, permițând încărcarea directă a EV-urilor.

Există trei modele primare de încărcare pentru EV-uri: încărcarea la domiciliu, încărcarea publică și încărcarea mobilă. Încărcarea la domiciliu, cunoscută și sub numele de echipament de alimentare a vehiculelor electrice (EVSE), poate fi instalată într-o garaj sau în aer liber, oferind o soluție de încărcare fiabilă și sigură. Încărcarea publică este de obicei situată în zone publice, cum ar fi parcări, centre comerciale sau de-a lungul drumurilor principale [20], Încărcarea mobilă, cunoscută și sub numele de încărcare în mișcare, apare ca o tendință pentru transportul EV-urilor, oferind o soluție de încărcare portabilă pentru proprietarii de EV-uri în locații izolate unde disponibilitatea stațiilor de încărcare acasă și publice este limitată.

3.3 Strategii de Încărcare a EV

Încărcarea bateriilor EV se efectuează de obicei prin două strategii de încărcare: necoordonată și coordonată. Strategia de încărcare necoordonată se referă la un comportament de încărcare aleator, în care proprietarii de EV-uri își pot încărca vehiculele la orice tip de stații de încărcare și în orice moment, după preferință. Problema cu încărcarea necoordonată este că poate duce la suprasarcini ale transformatoarelor, întreruperi de curent și creșterea costurilor cu electricitatea. În contrast, strategia de încărcare coordonată implică scheme planificate și gestionate de încărcare care sunt aplicabile pentru optimizarea și gestionarea operațiunilor de încărcare a EV-urilor, cum ar fi atenuarea stresului asupra rețelei, îmbunătățirea eficienței energetice și minimizarea costurilor. În general, schemele coordonate pot fi implementate utilizând două tipuri de sisteme de încărcare: centralizate, descentralizate sau hibride.

3.3 Sisteme centralizate, descentralizate și ierarhice

În cadrul schemelor centralizate, o entitate centrală coordonează încărcarea EV-urilor într-o zonă geografică specifică, cum ar fi un cartier dintr-un oraș [21]. Entitatea centrală în acest sistem de încărcare, cunoscută sub numele de agregator, comunică atât cu utilizatorii de EV-uri, cât și cu operatorii rețelei. Aceasta obține și transmite cererile, precum și efectuează configurarea sistemului și coordonează alte operațiuni. Pentru a realiza acest lucru, agregatorul colectează mai întâi informațiile de încărcare de la proprietarii de EV-uri, cum ar fi numărul de identificare (ID) al unui EV, capacitatea bateriei, SOC-ul, etc. Apoi, acesta execută un algoritm pentru a optimiza programele de încărcare pe baza datelor colectate, ținând cont de cererea totală de putere și prețurile energiei pe piață.

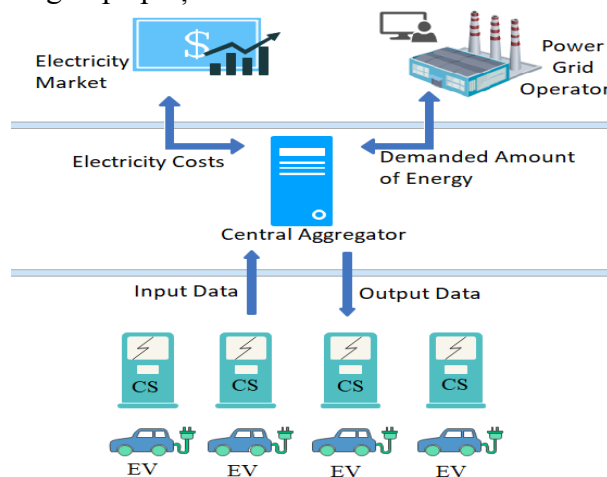


Figura 3.1 Arhitectura sistemului de încărcare centralizat pentru EV-uri.

Figura 3.1 prezintă o arhitectură simplificată de nivel înalt a unui sistem de încărcare centralizat, arătând unitățile funcționale principale responsabile pentru implementarea managementului și controlului sistemului.

În abordarea de încărcare descentralizată, se introduce o strategie bazată pe stimulente, unde programele de încărcare ale EV-urilor sunt influențate indirect de prețurile electricității [22]. Proprietarii de EV-uri joacă un rol activ în luarea deciziilor de încărcare, folosind informațiile furnizate de agregator, cum ar fi prețurile actuale ale electricității și disponibilitatea stațiilor de încărcare în zona gestionată de acel agregator. Obiectivul principal al ajustării prețurilor electricității este de a motiva utilizatorii de EV-uri să își încarce vehiculele în timpul orelor de vârf, reducând astfel sarcina pe rețea în perioadele de cerere ridicată. Similar cu abordarea centralizată, fiecare agregator colectează informații de la utilizatori sau chiar prezice cererea de încărcare a EV-urilor pentru perioada următoare. Aceste informații sunt utilizate pentru a găsi o schemă de încărcare optimă. Figura 3.2 prezintă o arhitectură simplificată de nivel înalt a unui sistem de încărcare descentralizat.

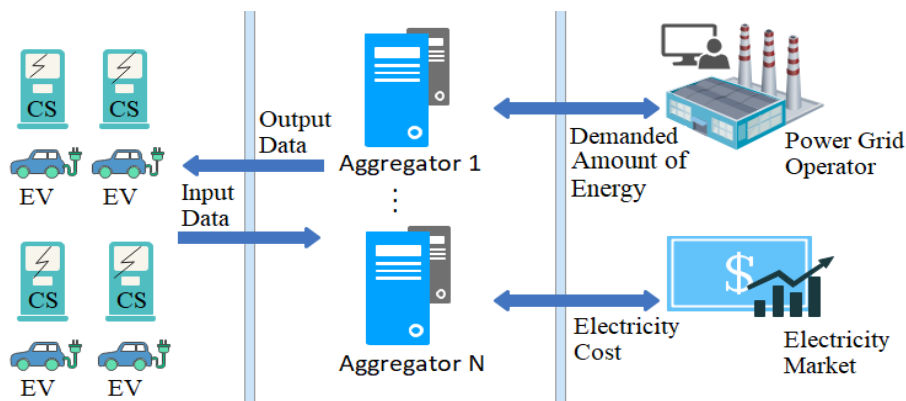


Figura 3.2 Arhitectura sistemului de încărcare descentralizat pentru EV-uri.

Atât sistemele de încărcare centralizate, cât și cele descentralizate discutate mai sus au avantajele și dezavantajele lor, așa cum este rezumat în Tabelul 3.2.

Tabelul 3.2 Sistemele de încărcare centralizate și descentralizate.

Natura sistemului	Centralizat	Descentralizat
Control	Mai mult control asupra încărcării EV-urilor, aliniat cu nevoile rețelei	Mai puțin control, mai multă flexibilitate și scalabilitate mai bună
Informații	Agregatorul are acces la informații globale, potențial pentru programe mai bune	Date incomplete ale vehiculului pot duce la programe suboptimale
Partajarea datelor	Necesită partajarea datelor private ale utilizatorilor cu un agregator	Necesitate mai mică de partajare a datelor cu un agregator
Complexitatea computațională	Ridicată dacă numărul de EV-uri este mare	Complexitate computațională distribuită
Impactul eșecurilor	Pretenție la probleme de eșec care	Natura distribuită oferă mai

	afectează întregul sistem	multă reziliență
Investiția în infrastructură	Investiție semnificativă	Investiție mai mică

Sistemele de încărcare ierarhice combină caracteristici ale sistemelor centralizate și descentralizate. Arhitectura acestor sisteme este pe mai multe niveluri, implicând de obicei agregatori centrali, regionali sau locali. Această caracteristică împarte responsabilitățile de gestionare pe mai multe niveluri pentru a optimiza operațiunile de încărcare pentru EV-uri - luarea deciziilor este distribuită pe diferite niveluri, reducând sarcina asupra unui singur agregator și îmbunătățind timpii de răspuns. Aceste niveluri pot fi categorisite după cum urmează:

- **Nivelul superior:** Acest nivel include un controler central care ia decizii strategice ample bazate pe condițiile rețelei, prețurile energiei și previziunile generale ale cererii.
- **Nivelul intermediar:** Acest nivel este compus din mai mulți agregatori regionali care adună date locale de la stațiile de încărcare și/sau EV-urile din regiunea lor și iau decizii localizate pentru a optimiza programele de încărcare și a gestiona eficient resursele.
- **Nivelul inferior:** Acest nivel include stațiile de încărcare și EV-urile. La acest nivel, pot fi luate decizii operaționale specifice, cum ar fi ajustarea ratelor de putere de încărcare (selectarea modului de încărcare).

3.5 Tehnici de optimizare pentru încărcarea EV

Această secțiune prezintă diverse tehnici de optimizare, inclusiv programarea liniară (LP), programarea dinamică (DP), algoritmi euristici de optimizare și învățarea automată (ML), care pot fi utilizate sau dezvoltate (individual sau în combinație) pentru optimizarea încărcării EV. Tabelul 3.3 oferă o analiză cuprinzătoare care rezumă diverse algoritme pentru încărcarea EV-urilor și prezintă aplicațiile lor, avantajele, limitările, precum și complexitatea computațională.

Tabelu 3.3 Tehnici de optimizare pentru încărcarea EV-urilor.

Algoritm	Avantaje	Limitări	Complexitate computațională
LP	Eficient în optimizarea multi-scenariu, potrivit pentru strategii de reducere a vârfurilor și de umplere a văilor	Poate fi complex în scenarii cu un număr mare de variabile	Variabilă; poate fi ridicată în scenarii de mare amploare
DP	Eficient pentru probleme de decizie multi-etapă, adaptabil la condiții în schimbare	Costisitor din punct de vedere computațional (blestemul dimensionalității), necesită resurse substanțiale	Ridicată datorită calculelor recursive

Algoritmi Euristici (e.g., PSO, GA, ACO)	Buni la găsirea soluțiilor aproape optime pentru probleme mari sau complexe, adaptabili la diferite scenarii	Reglarea parametrilor poate fi complexă, nu întotdeauna găsesc optimul global	Variabilă: mai mică decât metodele exacte, dar poate crește odată cu dimensiunea problemei
Machine Learning Techniques	Adaptabile la noi date, pot îmbunătăți acuratețea în timp, potrivite pentru sisteme dinamice	Necesită seturi mari de date pentru antrenare, unele modele pot fi "cutie neagră" cu interpretabilitate scăzută	Depinde de model; modelele de învățare profundă pot fi intensive computațional

Mai mult, soluțiile actuale din tehnologia de vârf care au fost introduse pentru a rezolva problemele de încărcare a EV sunt analizate critic în această secțiune și identifică limitările și lacunele lor (detalii pot fi găsite în teză). De exemplu, LP a fost utilizată în multe studii, cum ar fi [23] [24], dovedindu-se eficientă în optimizarea programelor de încărcare care cuprind mai multe EV-uri, stații de încărcare și rețele electrice. Studiile din [25][26] au utilizat MILP pentru a formula programarea încărcării și descărcării EV-urilor. Studiul din [27] a formulat problema programării încărcării online ca o problemă de DP pe un orizont finit. În timp ce în [28] a fost propusă o metodă de programare optimă integrată cu DP pentru a minimiza costurile de înlocuire a bateriilor pe durata întregii vieți de serviciu a electric bus fleets (EBFs).

Algoritmii euristici de optimizare, cum ar fi algoritmul genetic (GA), optimizarea coloniilor de furnici (ACO) și optimizarea roiului de particule (PSO), s-au dovedit a fi benefici în abordarea problemelor de programare a încărcării, cum ar fi în [29][30][31][32][33][34].

Algoritmii de învățare automată (ML) pot analiza și interpreta seturi mari de date, identifica modele și lua decizii sau face predicții pe baza modelelor descoperite. De exemplu, studiul din [35] a dezvoltat patru tehnici de DL pentru a prognoza cererea de încărcare a EV-urilor: gated recurrent units (GRUs), long short-term memory (LSTM), recurrent neural networks (RNNs), and artificial neural networks (ANNs). Studiul din [36] a introdus un program optim de încărcare utilizând deep reinforcement learning (DRL) pentru a aborda provocările selecției rapide a stațiilor de încărcare și planificării traseelor pentru EV-uri în rețeaua inteligentă.

Tabelul 3.4 rezumă multiple soluții populare de optimizare a încărcării, evidențiind descoperirile și contribuțiile lor, abordând fezabilitatea integrării și subliniind limitările și lacunele acestora.

Tabelul 3.4 Exemple de soluții de optimizare a încărcării

Ref.	Descoperiri/Cuprinde re	Alg.	Sistem de Încărcare	Integrare	Limitări și Lacu
[23]	A dezvoltat un model LP pentru optimizarea consumului de energie în parcări, demonstrând strategii eficiente de	LP	Descentraliza t	Niciun a	<ul style="list-style-type: none"> Studiul a fost realizat într-o zonă mică (o universitate) cu un număr limitat de EV-uri și locuri de parcare. Lipsa luării în considerare a

	reducere a vârfurilor și umplerea văilor (optimizarea laturii rețelei)				preferințelor utilizatorilor EV, cum ar fi SOC-ul necesar și modul de încărcare sau un timp specific pentru încărcare.
[24]	A utilizat LP pentru a îmbunătăți auto-consumul de PV într-o micro-rețea, arătând o reducere semnificativă a cererii de vârf și o eficiență crescută (optimizarea operatorilor rețelei)	LP	Descentralizat	V2G și Energie regenerabilă	<ul style="list-style-type: none"> ▪ Studiul este limitat la zone de mică scară, deci poate necesita îmbunătățiri pentru aplicarea la scară mare. ▪ Incertitudine în factori diverși, cum ar fi predicțiile puterii PV și cererea de sarcină, timpii de călătorie EV și utilizarea energiei. ▪ Lipsa luării în considerare a constrângerilor EV (de exemplu, SOC, modul de încărcare, locația EV).
[25]	A demonstrat managementul cost-eficient al încărcării EV-urilor cu PV și minimizarea costurilor de încărcare a EV-urilor și a sarcinii pe rețea pentru a îmbunătăți stabilitatea rețelei (optimizarea atât a laturii rețelei, cât și a laturii utilizatorului)	MILP	Descentralizat	V2G, Energie regenerabilă (PV) și TOU	<ul style="list-style-type: none"> ▪ Studiul este limitat la o zonă mică și poate întâmpina dificultăți în implementarea la scară largă. ▪ Modelul se bazează pe date de predicție ale generării solare și prețurilor energiei. ▪ Lipsa luării în considerare a constrângerilor EV (de exemplu, SOC, modul de încărcare, capacitatea bateriei).
[26]	A prezentat o abordare nouă pentru optimizarea încărcării EV-urilor, maximizând semnificativ veniturile agregatorului și utilizarea stocării energiei (optimizarea operatorului rețelei)	MILP + Algoritm euristici bazat pe LP	Centralizat	Niciuna	<ul style="list-style-type: none"> ▪ Modelul se bazează pe simulări și eficacitatea sa necesită validare în aplicațiile din lumea reală.
[27]	A propus algoritmi eficienți pentru gestionarea sosirilor dinamice ale EV-urilor și a încărcării, concentrându-se pe minimizarea costurilor de încărcare a EV-urilor, sarcinii de putere și timpului de calcul (optimizarea laturii rețelei), potrivit pentru numere și cereri fluctuante ale EV-urilor.	DP + MPC	Centralizat	Niciuna	<ul style="list-style-type: none"> ▪ Studiul se bazează pe simulări și poate necesita o validare suplimentară cu date din lumea reală. De exemplu, informații precum sosirile EV-urilor nu sunt cunoscute. Acest lucru face ca potențialul de aplicare a scenariilor în timp real integrate într-un sistem V2G să fie de explorat.
[28]	A sugerat o metodă bazată pe DP pentru reducerea costurilor de înlocuire a bateriilor în EBF-uri, îmbunătățind sustenabilitatea și	DP	Centralizat	Niciuna	<ul style="list-style-type: none"> ▪ Studiul a fost realizat într-un sistem de transport public pentru cinci EBF-uri cu cinci rute pe zi. Aplicabilitatea în sisteme de transport diferite sau la scară mai mare nu este

	eficiența economică (optimizarea operatorului utilizatorului)				discutată.
[30]	A dezvoltat o metodă bazată pe PSO pentru a minimiza costurile și timpul de încărcare în parcări (optimizarea atât a laturii rețelei, cât și a laturii utilizatorului)	PSO	Centralizat	Energie regenerabilă (turbine eoliene și cinci PV)	<ul style="list-style-type: none"> Studiul a considerat un număr mic de EV-uri și nu a luat în considerare comportamentele și preferințele variabile ale utilizatorilor în încărcare.
[31]	A implementat PSO pentru managementul eficient al încărcării EV-urilor pentru minimizarea costurilor de încărcare a parcarilor (optimizarea operatorului rețelei)	PSO	Centralizat	V2G	<ul style="list-style-type: none"> Studiul nu a utilizat tehnica de agregare.
[32]	A introdus un schema bazată pe GA pentru optimizarea profilului de sarcină, prin uniformizarea sarcinii pentru a preveni îmbătrânirea elementelor sistemului de putere (optimizarea operatorului rețelei)	GA	Centralizat	Niciuna	<ul style="list-style-type: none"> Lipsa luării în considerare a preferințelor sau constrângerilor EV (de exemplu, SOC, modul de încărcare, capacitatea bateriei).
[33]	A propus un schema bazată pe GA pentru a minimiza timpul de așteptare și distanța pentru încărcarea de urgență a EV-urilor în timpul orelor de vârf (optimizarea laturii utilizatorului)	GA + NJF și EDF	Centralizat	Niciuna	<ul style="list-style-type: none"> Studiul a fost realizat pentru încărcarea de urgență a EV-urilor în regiuni de mare densitate și nu a luat în considerare aspectul costurilor de încărcare.
[34]	A optimizat eficiența operațiunilor de încărcare pentru latura rețelei prin minimizarea întârzierii totale în încărcarea EV-urilor la stații cu trafic ridicat	ACO	Centralizat	Niciuna	<ul style="list-style-type: none"> Studiul nu a abordat variabilitatea în nevoile sau preferințele individuale ale încărcării EV-urilor.
[35]	A dezvoltat modele DL pentru a prezice cu acuratețe cererea de încărcare a EV-urilor, în special eficient în contextul Marocului (optimizarea operatorilor rețelei)	GRU	Centralizat sau Descentralizat	Niciuna	<ul style="list-style-type: none"> Studiul este specific pentru piața de energie din Maroc, iar aplicabilitatea constatărilor studiului în alte regiuni sau structuri de piață poate varia. Studiul nu a luat în considerare variabilitatea comportamentului utilizatorilor EV și impactul acestuia asupra predicțiilor cererii de încărcare.

[36]	A utilizat DRL pentru selecția eficientă a stațiilor și planificarea rutelor, reducând costurile și timpul de încărcare a EV-urilor (optimizarea laturii utilizatorului)	DRL	Centralizat	SDN, VEC, și TOU	<ul style="list-style-type: none"> ▪ Inflexibil în selecția modului de încărcare al utilizatorului EV, adaptabilitatea sa la diferite medii urbane cu trafic variabil necesită explorări suplimentare.
------	--	-----	-------------	------------------	---

3.6 Probleme Deschise și Direcții Viitoare

Această secțiune discută domeniile de cercetare deschise și direcțiile viitoare în optimizarea programelor de încărcare a EV-urilor:

1. *Disponibilitatea limitată a seturilor de date publice pentru încărcare:* Dezvoltarea modelelor de învățare automată pentru optimizarea încărcării EV-urilor este împiedicată de lipsa seturilor de date publice cuprinzătoare. Antrenamentul și validarea eficientă a acestor modele necesită date extinse. Pentru a aborda această provocare, este esențial să se promoveze colaborarea între industrie, guvern și mediul academic pentru a crea seturi de date standardizate și anonimizate și a dezvolta modele de afaceri care să încurajeze partajarea datelor.
2. *Maximizarea utilizării RES:* Integrarea RES-urilor în programul de încărcare a EV-urilor este crucială pentru maximizarea utilizării energiei verzi, minimizarea impactului asupra mediului și reducerea costurilor [37]. Cu toate acestea, variabilitatea limitată a producției de energie solară și eoliană poate fi o provocare, sugerând nevoia de mai multe cercetări în incorporarea EV-urilor ca unități de stocare mobile care pot stoca și ulterior furniza această energie, ajutând la stabilizarea rețelei în timpul vârfurilor de cerere.
3. *Eficiența timpului și confortul utilizatorului:* Dezvoltarea unei metode optime de încărcare a EV-urilor care se adaptează la schimbările în timp real și gestionează cererile pe scară largă eficient este crucială. Un astfel de sistem trebuie să minimizeze timpii de așteptare și să asigure accesul fiabil la stațiile de încărcare, îmbunătățind astfel confortul utilizatorului. În scenarii precum evenimente mari în oraș sau orele de vârf de muncă, cererea de încărcare poate crește brusc, variind considerabil din cauza unor factori precum capacitatea bateriei și SOC. Pentru a aborda acest aspect, monitorizarea în timp real a datelor este esențială pentru ajustarea dinamică a planurilor de încărcare în funcție de condițiile curente.
4. *Stabilitatea rețelei și accesibilitatea utilizatorului:* Echilibrarea sarcinii este o problemă critică în încărcarea EV-urilor, în special având în vedere capacitatea rețelei și cererea fluctuantă la stațiile de încărcare. Provocarea pentru operatorii rețelei este să gestioneze stațiile de încărcare suprasolicitate, în timp ce se adaptează la cererile mari de încărcare în timpul orelor de vârf.

Cercetările viitoare ar trebui să propună o abordare mai dinamică și adaptivă. Această abordare ar trebui să stabilească limitări, cum ar fi stabilirea unui prag maxim de SOC pentru EV-uri în timpul orelor de vârf.

5. *Confortul utilizatorului:* Concentrându-se pe cerințele specifice ale utilizatorilor EV-urilor, serviciul poate asigura o experiență de încărcare convenabilă, eficientă și rentabilă. Furnizorii de servicii ar trebui să permită proprietarilor de EV-uri să își specifice preferințele de încărcare, cum ar fi infrastructura de încărcare preferată (de exemplu, acasă, publică sau mobilă), modurile de încărcare, rata de preț dorită și încărcarea la ore specifice.
6. *Optimizarea costurilor:* Provocarea cu încărcarea rapidă constă în rata sa de putere mai mare, care are potențialul de a solicita rețeaua și, în cazuri extreme, poate duce la pene de curent dacă cererea totală depășește capacitatea rețelei. Pentru a depăși această provocare, trebuie optimizate programele de încărcare pe baza nevoilor utilizatorilor și a capacității rețelei utilizând strategia de prețuri TOU pentru a gestiona cererea de încărcare în timpul orelor de vârf.

Capitolul 4

Scheme de Rutare și Programare a Încărcării pentru Vehicule Electrice în Rețelele Vehiculare Bazate pe SDN

Acest capitol abordează problema încărcării aleatorii a EV-urilor și introduce o schemă inovatoare de rutare și programare a încărcării pentru EV-uri în cadrul unei rețele vehiculare bazate pe SDN. Metodologia implică un model de sistem și un cadru matematic destinat optimizării procesului de încărcare. Capitolele utilizează două algoritme, inclusiv controlul fuzzy și Dijkstra, pentru a dezvolta un algoritm avansat. Algoritmul dezvoltat este conceput pentru a realiza echilibrarea sarcinii între mai multe stații de încărcare, asigurând în același timp rutare și programare eficientă pentru EV-uri. Mai mulți factori sunt luați în considerare în acest studiu, inclusiv SOC, capacitatea bateriei EV-ului, modul de încărcare (rapid sau lent) și disponibilitatea stațiilor de încărcare. În plus, acest capitol propune o nouă schemă optimizată care prioritizează cerințele de încărcare rapidă ale EV-urilor față de cerințele de încărcare lentă. Obiectivul principal al acestei propuneri este de a minimiza atât timpul de serviciu (în termeni de timp de călătorie, timp de așteptare și timp de încărcare), cât și costurile de încărcare. Mecanismul TOU este aplicat pentru a calcula costurile de încărcare. Această lucrare este evaluată folosind instrumentele MATLAB. Algoritmul dezvoltat este aplicat în două scheme: prima venită, prima servită (FCFS) și schema propusă (prioritate pentru încărcare rapidă), ambele fiind comparate cu schema de încărcare aleatorie. Rezultatele simulării demonstrează eficacitatea algoritmului dezvoltat cu schema propusă în reducerea timpului de serviciu.

4.1 Metodologie

Acest studiu propune arhitectura calculului bazat pe SDN pentru încărcarea EV-urilor (vezi figura 4.1), care permite interacțiunea în timp real între utilizatorii EV-urilor și

operatorii de rețea. Această arhitectură se compune din trei straturi: stratul de aplicație, stratul de control și stratul fizic. Modelul matematic al schemelor propuse este rezumat în această subsecțiune. În primul rând, timpul de serviciu pentru fiecare utilizator EV este formulat.

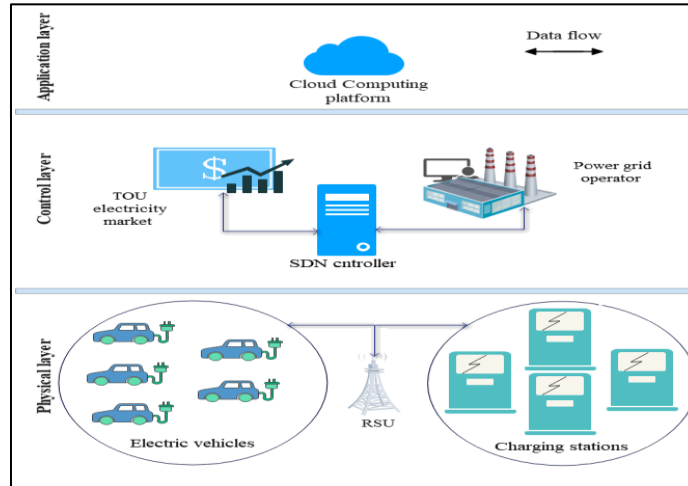


Figura 4.1 Arhitectura de cloud computing bazată pe SDN.

Timpul de serviciu ($T_{v,c}^{service}$) reprezintă timpul total necesar pentru ca un EV să fie complet încărcat, inclusiv timpul de călătorie, timpul de așteptare și timpul de încărcare. Acesta poate fi calculat astfel:

$$T_{v,c}^{service} = T_{v,c}^{travel} + T_{v,c}^{waiting} + T_{v,c}^{charging}, \quad (4.1)$$

$T_{v,c}^{traveling}$ reprezintă timpul de călătorie, care este cantitatea de timp necesară pentru ca EV-ul să se deplaseze între noduri, și poate fi obținut prin:

$$T_{v,c}^{traveling} = \frac{D_{v,c}}{V_v}, \quad (4.2)$$

$D_{v,c}$ este distanța dintre cele două noduri (de exemplu, de la locația curentă a EV-ului v la stația de încărcare c). V_v este viteza medie de deplasare a EV-ului. Prin urmare, un EV poate avea o cantitate foarte mică de energie și nu poate ajunge la toate stațiile de încărcare din oraș. În consecință, această studiu a considerat [38] distanța maximă pe care EV-ul o poate parcurge, reprezentată de D_{max} care poate fi calculată astfel:

$$D_{max,v} = \frac{B^{size} B^{soc}}{e}, \quad (4.3)$$

e indică câtă energie utilizează bateria EV-ului pentru o anumită distanță (0.15 kWh/km). B^{size} denotă capacitatea bateriei, iar B^{SOC} eprezintă starea de încărcare a bateriei. Totuși, un EV ar trebui să aștepte la coadă dacă toate unitățile de încărcare de la stație sunt ocupate. Așadar, această cercetare utilizează modelul M/M/S [39] pentru a estima timpul de așteptare pentru fiecare EV. Timpul de așteptare pentru un EV este reprezentat de $T_{v,c}^{waiting}$:

$$T_{v,c}^{waiting} = \frac{L_{q,c}}{\gamma_{c,\tau}}, \quad (4.4)$$

$\gamma_{c,t}$ reprezintă rata de sosire a EV-urilor la intervalul de timp τ . $L_{q,c}$ reprezintă lungimea cozii la o stație de încărcare. Totuși, așa cum s-a menționat anterior, această cercetare presupune că fiecare utilizator de EV trebuie să selecteze una dintre cele două moduri de încărcare, adică încărcare lentă sau rapidă. Selecția unuia dintre aceste moduri depinde de preferințele utilizatorului, unde fiecare mod are o rată de putere specifică care afectează timpul de încărcare al EV-ului. Timpul de încărcare este reprezentat de $T_{v,c}^{charging}$, și poate fi obținut prin:

$$T_{v,c}^{charging} = \frac{B^{size}(\sigma - B^{soc})}{\vartheta_c^o}, \quad (4.8)$$

Where, ϑ_c^o denotă rata de încărcare a unui mod EV. Modurile de încărcare sunt indexate de o , (e.g., de exemplu, dacă $o = 1$, este rapid, altfel, $o = 0$, este lent). Procentul de încărcare a bateriei EV așteptat este denotat de σ (i.e., $\sigma = 95\%$). În plus, acest studiu utilizează mecanismul de prețuri TOU pentru a calcula costul de încărcare pentru fiecare EV. Astfel, ziua poate fi împărțită în trei perioade, inclusiv perioadă de vârf (P^{peak}), regulată ($P^{regular}$), și de vale (P^{valley}). Costul de încărcare, reprezentat de $C_{v,c}^o$, poate fi calculat prin:

$$C_{v,c}^o = \begin{cases} P^{regular} \\ P^{valley} * E_{v,c}^{amount} \\ P^{peak} \end{cases}, \quad (4.9)$$

$E_{v,c}^{amount}$ reprezintă cantitatea de energie cerută de un EV. Este de notat că, în modelul de încărcare aleatoriu, se consideră în mod special prețul clasic al energiei electrice, $P^{classical}$, care este fix. În plus, funcția obiectiv propusă este modelată pentru a reprezenta costul total pentru încărcarea EV-urilor. Acest cost total este denumit $T_{v,c}^{total}$ și este definit după cum urmează:

$$T_{v,c}^{total} = \min[w_1 T_{v,c}^{traveling} + w_2 T_{v,c}^{waiting} + w_3 T_{v,c}^{charging}] + C_{v,c}^o \quad (4.11)$$

$w_1, w_2,$ and w_3 reprezintă coeficienții de ponderare pentru cele trei metrici, respectiv timpul de călătorie, timpul de așteptare și timpul de încărcare. Aceasta este subiectul următoarelor condiții:

$$D_{v,c} \leq D_{max} \quad (4.12)$$

$$B^{size} B^{soc} + E_{v,c}^{amount} - D_{v,c} e = B^{size} \quad (4.13)$$

$$E_{total} < E_{supply} \quad (4.14)$$

Restricția din (4.12) indică faptul că distanța de călătorie al unui EV către o stație de încărcare este egal sau mai mic decât distanța maximă. Restricția din (4.13) garantează că EV-ul este complet încărcat. Restricția din (4.14) menține stabilitatea rețelei electrice.

Algoritmul propus pentru rezolvarea acestei probleme și gestionarea încărcării EV-urilor este împărțit în două părți. Prima parte utilizează algoritmul Dijkstra, care este utilizat pe scară largă pentru rezolvarea problemei rutării pe distanța cea mai scurtă. În a doua parte, Algoritmul utilizează controlul logicii fuzzy pentru a gestiona și distribui sarcina EV-urilor pe stațiile de încărcare.

Algorithm: Pseudocode of routing and scheduling EVs charging [Annex A.1.1]

Input: information of EVs profile, graph of charging network, and information of charging stations.

Initial: SDN controller receive charging demands from certain number of EVs at $t =$ certain moment, the availability of charging stations, the queue length at each charging units at each available station

- 1: Set $EV^{profile}[User^{id}, B^{size}, B^{SOC}, \text{charging mode } o, \text{current location}]$.
- 2: **For** each EV **do**
- 3: Determine the $T_{v,c}^{charging}$.
- 4: Determine the D_{max} .
- 5: Search for available charging stations within EV range using *Dijkstra* and considering D_{max} .
- 6: Determine the $T_{v,c}^{travelling}$ for EV at each available charging station.
- 7: Evaluate the *wating time* ($T_{v,c}^{waiting}$) at each available charging station.
- 8: **if** the available charging stations satisfied the constraints of (4.12) (4.13) and (4.14) **then**
 - 9: Make Fuzzy input as a MATRIX of *travelling time* and *waiting time*.
 - 10: Determines the *Max. Weight* value from the Fuzzy output.
 - 11: Scheduling the EV at a charging station with minimum time cost.
- 12: **else**
 - 13: The EV cannot reach any charging station.
- 14: **end if**
- 15: Determine the objective function $T_{v,c}^{total}$ using (4.11).
- 16: Update the queue length at the selected charging station.
- 17: **end do**
- 18: **Repeat** steps 2-16 for all EVs
- 19: **end**

4.2 Rezultate și discuții

Acest studiu a utilizat instrumentele MATLAB pentru a evalua performanțele algoritmului propus, considerând graficul orașului București pentru a imita simularea reală [40]. Tabelul II ilustrează parametrii care sunt utilizați ca repere în acest studiu.

Tabelu 4.1 Parametrii simulării..

Rata modului de încărcare		Încărcare lentă= 22 kw	Încărcare rapidă= 50 kw								
Prețuri de încărcare (TOU)	Perioade obișnuite: 12 - 6 a.m., 10 p.m. - 12 a.m.	1.53 lei/kwh	2.29 lei/kwh								
	Perioade de vale: 6 - 8 a.m., 11 a.m. - 5 p.m., and 8 - 10 p.m.	2.88 lei/kwh	4.30 lei/kwh								
	Perioade de vârf: 8 -11 a.m., 5 - 8 p.m.	3.92 lei/kwh	5.86 lei/kwh								
Preț de încărcare clasic		1.45 lei/kwh	1.95 lei/kw								
Stație de încărcare		1	2	3	4	5	6	7	8	9	10
Număr de unități de încărcare		4	3	3	4	3	3	3	5	4	5

Figura 4.6 ilustrează timpul de așteptare al EV-urilor la stația de încărcare, iar figura 4.7 ilustrează timpul de serviciu al EV-urilor, comparate între trei scheme de încărcare: aleatorie, FCFS cu algoritmul propus și prioritizare încărcare rapidă cu algoritmul propus. Rezultatele arată că algoritmul propus cu schema propusă depășește alte scheme, deoarece multe EV-uri sunt distribuite în mod egal la stațiile de încărcare, obținând astfel cele mai mici timpuri de așteptare și de serviciu.




Figura 4.6 Timpul total de așteptare pentru EV-uri la stațiile de încărcare.




Figura 4.7 Timpul total de serviciu pentru EV-uri la stațiile de încărcare..

În cele din urmă, în Figura 4.9 este prezentat costul de încărcare pentru fiecare EV cu algoritmul propus, comparat între prețurile TOU și cele clasice. Rezultatele arată că aplicarea prețurilor TOU poate crește veniturile totale pentru furnizorii de servicii în comparație cu prețurile de încărcare clasice.

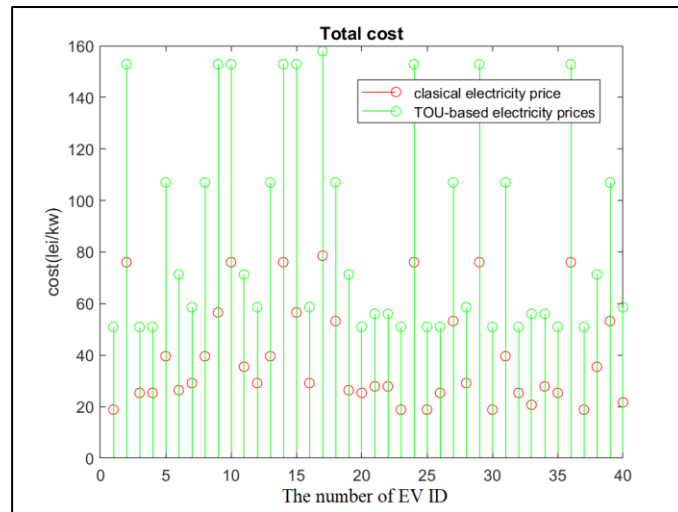


Figura 4.9 Costul de încărcare pentru EV-uri.

Capitolu 5

Optimizare Genetică cu Sortare Non-Dominată pentru Programarea Încărcării Vehiculelor Electrice cu Conștientizare a Timpului și Costurilor

Echilibrarea explorării și exploatării pentru încărcarea vehiculelor electrice (EV) este încă o problemă deschisă și necesită studii suplimentare. Prin urmare, acest capitol formulează problema programării încărcării EV-urilor în termeni multi-obiective, în ceea ce privește timpul și costul. Acesta introduce un model de optimizare bi-obiectiv utilizând algoritmul genetic de sortare bi-nedominată (NSGA-II) pentru a aborda compromisurile între timpul de încărcare și costuri, oferind un set divers de soluții nedominate. Soluțiile nedominate reprezintă un set de soluții în care niciuna nu este superioară în toate obiectivele, dar fiecare este superioară în unele și inferioară în altele. Evaluările empirice demonstrează superioritatea NSGA-II față de algoritmi genetici tradiționali (GA). Rezultatele arată că NSGA-II oferă o soluție echilibrată în ceea ce privește timpul de încărcare și costurile comparativ cu GA. În plus, lucrarea din acest capitol este extinsă prin compararea performanței algoritmilor de ant colony optimisation (ACO) și recoacere simulată (SA). Cele mai bune soluții obținute de ACO și SA reprezintă programarea unui număr de EV-uri la stațiile de încărcare cu scopul de a minimiza costul total în termeni de timp de serviciu și cost de încărcare. Rezultatele arată că ACO are capacități superioare în optimizarea încărcării comparativ cu SA.

5.1 Metodologie

Acest studiu presupune implementarea algoritmului de optimizare propus (de exemplu, NSGA-II, ACO și SA) într-un sistem de încărcare centralizat. Procedurile de programare a încărcării încep prin transmiterea de către EV-uri a informațiilor precum SOC, capacitatea bateriei, modul de încărcare și locația către agregator. Între

timp, stațiile de încărcare își împărtășesc locațiile, capacitățile, statusul disponibilității și tarifele de preț cu agregatorul, actualizând continuu orice modificări. Informațiile despre timpul de călătorie și distanțele dintre EV-uri și stații sunt presupuse disponibile pentru simplificare. Agregatorul central analizează și procesează informațiile de la EV-uri și stațiile de încărcare și rulează algoritmul NSGA-II. Obiectivul optimizării în acest sistem este de a minimiza costul total pentru încărcarea EV-urilor (în termeni de timp și preț). Această lucrare utilizează un model matematic similar celui utilizat în capitolul patru, unde problema încărcării EV-urilor are două obiective majore: timpul de serviciu și costul de încărcare. Conform ecuației (4.1), primul obiectiv este timpul de serviciu notat cu $T_{v,c}^{service}$. Acesta cuprinde trei parametri: timpul de călătorie (notat cu $T_{v,c}^{traveling}$), timpul de așteptare (notat cu $T_{v,c}^{waiting}$), și timpul de încărcare (notat cu $T_{v,c}^{charging}$), respectiv, urmând ecuațiile (4.2), (4.4) și (4.8).

Al doilea obiectiv este costul de încărcare, care variază în funcție de factori precum prețurile energiei, modul de încărcare și cantitatea totală de energie necesară pentru a încărca bateria. Pentru a reduce costul de încărcare, această lucrare utilizează tarifele TOU. Costul de încărcare cu aplicarea TOU poate fi exprimat după cum urmează:

$$C_{v,c} = \begin{cases} p_{off-peak,class(i)} E_{v,c}^{amount} \\ p_{peak,class(i)} E_{v,c}^{amount} \end{cases} \quad (5.1)$$

Where $C_{v,c}$ denotă costul de încărcare și $E_{v,c}^{amount}$ este cantitatea de energie necesară pentru încărcarea EV-ului. $p_{class(i),off-peak}$ and $p_{peak,class(i)}$, reprezintă, respectiv, tarifele de preț pentru încărcare în perioada de vârf și în perioada de non-vârf la o stație de încărcare. Unde class(i) este modul de încărcare (de exemplu, rapid, lent, regulat).

5.1.2 Optimizarea încărcării EV-urilor utilizând NSGA-II

Acest studiu propune utilizarea NSGA-II pentru a rezolva problema multi-obiectivă a încărcării EV-urilor. NSGA-II începe prin inițializarea unei populații de soluții aleatorii $P(0)$ pentru a găsi o soluție la problema încărcării EV-urilor. Pseudocodul de mai jos ilustrează procesul algoritmului NSGA-II.

Algorithm – Pseudocode of optimisation EV charging using NSGA-II [Annex A.1.2]

Input: population size (N), number of generations (G), crossover probability P_c , and mutation probability (P_m)

Output: Pareto-optimal solutions

1: Initialise population $P(0)$ of size N with random solutions (initial random schedule of EVs at stations)

2: Evaluate the objective values (service time (4.1) and charging cost eq. (5.1)) of each solution in $P(0)$

3: $t \leftarrow 0$

4: While $t < G$ do

- 5: Perform non-dominated sorting on $P(t)$ to rank solutions based on dominance
- 6: Calculate the crowding distance for each solution in $P(t)$
- 7: Create an empty offspring population $Q(t)$
- 8: Apply crossover with probability P_c to generate two offspring solutions
- 9: Apply mutation with probability P_m to each offspring solution
- 10: Evaluate the objective values of the offspring solutions
- 11: Add offspring solutions to $Q(t)$
- 12: $P(t+1) \leftarrow Q(t)$
- 13: $t \leftarrow t + 1$
- 14: End while
- 15: Return Pareto-optimal solutions from the final population $P(G)$

5.1.2 Ant colony optimisation

În această lucrare, metoda propusă ACO începe prin inițializarea unei matrice de feromoni uniforme, reprezentând probabilitatea de a aloca fiecare EV la o stație de încărcare (vezi anexa A.1.2 partea 2). La fiecare iterație, fiecare furnică construiește soluții prin atribuirea probabilistică a EV-urilor la stații, pe baza nivelurilor de feromoni. Funcția obiectiv în această lucrare este costul total în termeni de timp și preț, utilizând ecuațiile (4.1) și (5.1). Aceasta poate fi scrisă astfel:

$$cost_{v,c}^{total} = w_1 T_{v,c}^{service\ time} + w_2 C_{v,c}^o \quad (5.4)$$

Fiecare soluție este evaluată folosind funcția obiectiv (5.4), iar cea mai bună soluție a iterației este identificată. Dacă această soluție îmbunătățește soluția generală cea mai bună, aceasta este salvată ca fiind cea mai bună curentă. După ce toate furnicile și-au finalizat alocările, matricea de feromoni este actualizată. Nivelurile de feromoni se degradează parțial și sunt adăugate feromoni suplimentari pe alocările de succes, pe baza calității soluției. Acest proces iterativ continuă până la finalizarea unui număr specificat de iterații, rezultând o alocare optimizată a EV-urilor la stațiile de încărcare în termeni de timp și cost minim, așa cum este produsul metodei ACO.

5.1.3 Simulated Annealing

În această lucrare, algoritmul SA propus începe prin generarea unei soluții inițiale aleatorii care alocă fiecare EV la stațiile de încărcare (vezi anexele A.1.2 partea 2). Similar cu metoda ACO, funcția obiectiv din ecuația (5.4) este utilizată pentru a evalua soluția inițială, având ca scop minimizarea costului total în termeni de timp și preț. Soluția inițială servește atât ca soluție curentă, cât și ca cea mai bună soluție. Algoritmul generează iterativ soluții vecine prin modificarea alocării la stațiile de încărcare pentru EV-urile selectate aleatoriu. Valoarea funcției obiectiv (5.4) este calculată pentru fiecare soluție vecină, iar apoi se decide dacă aceasta va fi acceptată ca soluție curentă sau nu. Dacă soluția vecină are un cost mai mic, aceasta este

acceptată; dacă nu, poate fi totuși acceptată cu o probabilitate influențată de temperatura curentă și diferența de obiectiv, încurajând explorarea în etapele incipiente. Temperatura este redusă treptat printr-un factor de răcire, permițând algoritmului să îmbunătățească soluțiile găsite. Acest proces continuă până la atingerea limitei de iterații predefinite, moment în care cea mai bună soluție găsită este salvată ca rezultat al SA.

5.2 Rezultate și discuții

Evaluarea experimentală a fost realizată utilizând MATLAB 2020b. Tabelul 5.1 prezintă parametrii utilizați pentru evaluarea experimentală.

Tabelul 5.1 Parametrii utilizați pentru evaluarea experimentală.

Parametrii	valoare	Parametrii	valoare
EVs	100	crossover fraction	0.7, 0.9
EV battery sizes	[40,100]	EVs in the queue	10
prices of off-peak period	[0.10, 0.15, 0.20]	ACO iterations no.	1000
prices of peak period	[0.20, 0.25, 0.30]	ACO ants no	100
population size	[50, 100, 200]	pheromone decay rate	0.5
stations no.	20	SA iterations no.	1000
generations	200	SA initial temperature	100
mutation probability	0.08, 0.1	SA cooling rate	0.8
crossover fraction	0.7, 0.9		

În primul rând, au fost generate șase fronturi Pareto distincte corespunzătoare celor șase experimente individuale.

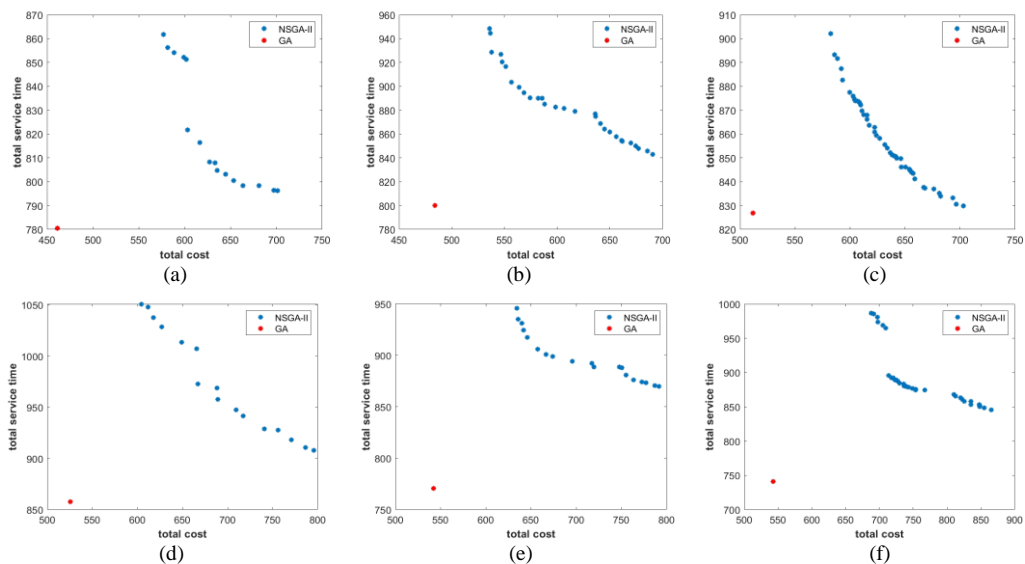


Figura 5.1 Frontul Pareto pentru cele șase experimente generate din NSGA-II și GA tradițional cu fracție de încrucișare de 0,7 și 0,9, probabilitate de mutație de 0,08 și 0,1, și dimensiunea populației (a,d) 50 (b,e) 100 (c,f) 200.

Rezultatele au arătat că NSGA-II oferă soluții non-dominante diverse în ceea ce privește cele două obiective de optimizare: costul de încărcare și timpul de serviciu. În contrast, GA-ul convențional a produs de obicei o soluție singulară cu timp de serviciu și cost de încărcare reduse (a se vedea Figura 5.2). NSGA-II a oferit constant soluții mai optimizate decât GA, o limitare în cazul acestuia din urmă provenind din ponderarea obiectivelor. Rezultatele studiului au dezvăluit că, prin creșterea dimensiunii populației de la 50 la 200, menținând ceilalți parametri constanți, nu au fost observate modificări semnificative în costul mediu de încărcare sau timpul de serviciu. NSGA-II a prezentat soluții diverse și non-dominante în ceea ce privește cele două obiective de optimizare: costul de încărcare și timpul de serviciu).

Figura 5.3 prezintă o soluție obținută prin metoda convențională GA, în care distribuția neuniformă este simptomatică pentru limitările inerente ale GA, evidențiind inadecvarea acesteia în optimizarea alocărilor într-un mod uniform. În schimb, soluția generată de NSGA-II în termeni de timp de serviciu (Figura 5.4 (a)) și cost de încărcare (Figura 5.4 (b)) prezintă o distribuție mai echilibrată a EV-urilor între mai multe stații de încărcare.




Figura 5.3 Alocarea a 100 EV-uri la 20 de stații generată de GA cu o fracțiune de încrucișare de 0,7, probabilitate de mutație de 0,08 și o dimensiune a populației de 50 în termeni de timp de serviciu și cost.

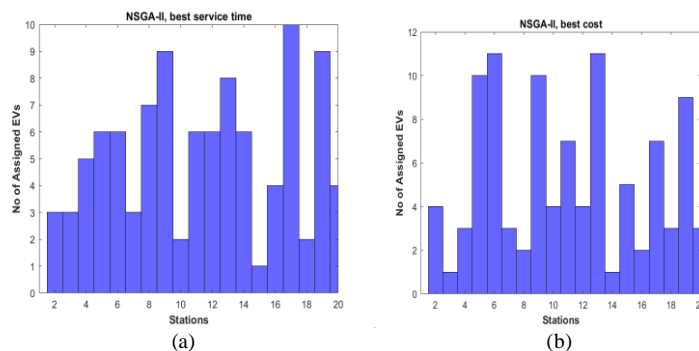


Figura 5.4 Alocarea a 100 EV-uri la 20 de stații generată de NSGA-II cu o fracțiune de încrucișare de 0,7, probabilitate de mutație de 0,08 și o dimensiune a populației de 50 în termeni de (a) timp de serviciu și (b) cost de încărcare

Pentru analize suplimentare, experimentul a fost repetat, iar fracția de încrucișare a fost schimbată până la 0,9, probabilitatea de mutație până la 0,1, și dimensiunea populației până la 200. Rezultatul din Figura 5.5 este aproape același cu cel anterior.

Aceasta subliniază că schimbarea valorilor parametrilor în GA sau NSGA-II nu are efecte secundare semnificative.




Figura 5.2 Atribuirea a 100 de EV-uri la 20 de stații cu fracție de încrucișare 0,9, probabilitate de mutație 0,1 și dimensiune a populației de 200 în ceea ce privește (a) GA și (b) NSGA-II; costul de încărcare (c) NSGA-II; timpul de serviciu

Numărul de EV-uri a fost extins la 200 pentru a evalua eficacitatea soluției noastre propuse cu un număr mai mare de vehicule. Figura 5.6 (a) prezintă soluția produsă de GA, indicând îmbunătățiri notabile cu atribuirea crescută a EV-urilor. În contrast, soluțiile NSGA-II în (b) timp de serviciu și (c) cost de încărcare demonstrează o mai bună atribuire a EV-urilor comparativ cu GA.




Figura 5.6 Atribuirea a 100 EV-uri distribuite pe 20 de stații în timpul perioadei de vârf, generată de GA și NSGA-II.

Figura 5.7 arată cele mai bune soluții obținute din (a) SA și (b) ACO. Rezultatele demonstrează că ACO aduce îmbunătățiri prin atribuirea unui număr mai mare de EV-uri fiecărei stații de încărcare comparativ cu SA.

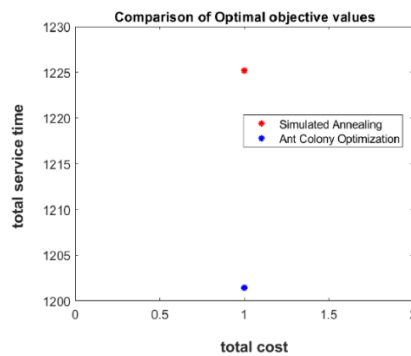


Figura 5.7 Cele mai bune valori ale funcției obiectiv obținute prin ACO și SA.




Figura 5.7 Numărul de EV-uri programate la stațiile de încărcare utilizând (a) soluția SA (b) soluția ACO.

Capitolul 6

Metodă de Încărcare Inteligentă și Adaptabilă pentru Vehicule Electrice, Ținând Cont de Încărcarea Urgentă

Acest capitol propune un sistem de încărcare inteligent și adaptabil pentru vehiculele electrice (EV-uri) care ia în considerare cerințele urgente de încărcare. Schema ajustează dinamic ratele de încărcare în funcție de urgența cererii, folosind metoda optimizării prin roiuri de particule (PSO) pentru a preveni supraîncărcarea rețelei. Performanța sistemului este evaluată sub diferite numere de EV-uri și două modele de încărcare (acasă și publice). Schema propusă este comparată cu două scheme normale: una care satisface SOC minim și alta care satisface SOC maxim. Rezultatele demonstrează că schema propusă reduce eficient sarcina EV și deplasează cererea de energie de la orele de vârf la orele de ne-vârf, îmbunătățind stabilitatea și eficiența rețelei.

6.1 Metodologie

Similar lucrărilor anterioare, propunerea metodei de încărcare inteligentă și adaptabilă este presupusă a fi efectuată într-un sistem centralizat. Cu toate acestea, fiecare șofer de EV are o cerere specifică de încărcare și trebuie să partajeze informațiile despre cererea sa de încărcare cu un agregator. În această lucrare, informațiile EV considerate sunt SOC, dimensiunea capacității bateriei, ora de sosire și ora de plecare (de exemplu, la stațiile de acasă sau publice). Acest studiu a adoptat formula din [41], pentru a genera datele de sosire (t_{1a}) și plecare (t_{1l}) ale EV-urilor, conform funcției de distribuție a probabilității (PDF) și simulării Monte Carlo:

$$f(t_{1a}) = \begin{cases} \frac{1}{\sqrt{2\pi}\sigma_{1t_a}} \exp\left(\frac{-(t_{1a} + 24 - \mu_{1t_a})^2}{2\sigma_{1t_a}^2}\right) & 0 < t_{1a} \leq \mu_{1t_a} - 12 \\ \frac{1}{\sqrt{2\pi}\sigma_{1t_a}} \exp\left(\frac{-(t_{1a} - \mu_{1t_a})^2}{2\sigma_{1t_a}^2}\right) & \mu_{1t_a} - 12 < t_{1a} \leq 24 \end{cases} \quad (6.1)$$

$$f(t_{1l}) = \begin{cases} \frac{1}{\sqrt{2\pi}\sigma_{1t_l}} \exp\left(\frac{-(t_{1l} - \mu_{1t_l})^2}{2\sigma_{1t_a}^2}\right) & 0 < t_{1l} \leq \mu_{1t_l} + 12 \\ \frac{1}{\sqrt{2\pi}\sigma_{1t_l}} \exp\left(\frac{-(t_{1l} - 24 - \mu_{1t_l})^2}{2\sigma_{1t_a}^2}\right) & \mu_{1t_l} + 12 < t_{1l} \leq 24 \end{cases} \quad (6.2)$$

În cazul încărcării publice, ora de sosire (t_{2a}) și ora de plecare (t_{2l}) a EV-urilor urmează distribuția normală și se calculează similar cu ecuațiile (6.1 and 6.2). În plus, acest studiu a considerat că perioada de timp pentru programarea încărcării EV-urilor într-o zi este împărțită în 96 de intervale de timp, ceea ce permite un tratament discret al controlului procesului de încărcare. Fiecare interval este reprezentat de j și este egal cu 15 minute. În plus, în această schemă, sarcina totală a rețelei de energie constă în sarcina de bază (p_j^{basic}) și sarcina de încărcare a EV-urilor ($\sum_{v=1}^N k_{v,j} p_v$), care se calculează astfel:

$$\mathcal{P}_j^{total} = \mathcal{P}_j^{basic} + \sum_{v=1}^N k_{v,j} \mathcal{P}_v \quad (6.7)$$

$k_{v,j}$ reprezintă o variabilă binară pentru a indica starea de încărcare a EV-ului (adică, dacă $k_{v,j} = 0$, EV-ul nu se încarcă, iar dacă $k_{v,j} = 1$, EV-ul se încarcă). După cum s-a menționat mai sus, în această metodă propusă sunt aplicate două moduri de încărcare (rate de încărcare), inclusiv încărcare lentă (\mathcal{P}^{slow}) și încărcare rapidă (\mathcal{P}^{fast}). Selectarea ratei de încărcare pentru fiecare utilizator de EV este considerată a fi aplicată de agregator (adaptabil între \mathcal{P}^{slow} and \mathcal{P}^{fast}) ținând cont de urgența cererii de încărcare a EV-ului (adică, o rată de încărcare mai mare este atribuită EV-ului care este urgent și o rată de încărcare mai mică este atribuită EV-ului care nu este urgent). Aceasta poate fi simplificată astfel:

$$\mathcal{P}^{slow} \leq \mathcal{P}_v \geq \mathcal{P}^{fast} \quad (6.8)$$

Principalul obiectiv al acestui studiu este de a minimiza variația sarcinii de energie pe rețea. Acest lucru poate fi realizat prin deplasarea cererii de energie a EV-urilor din orele de vârf în orele de ne-vârf, ceea ce poate fi exprimat astfel:

$$\min [\mathcal{P}_{max}^{total} - \mathcal{P}_{min}^{total}], \quad (6.9)$$

Where, p_{max}^{total} and p_{min}^{total} , sunt, respectiv, cererea maximă și minimă de sarcină totală de energie de la rețea. O constrângere de prag de putere este considerată în această schemă propusă pentru a menține SOC-ul tuturor EV-urilor într-un interval specificat atunci când acestea se deconectează de la rețea. Astfel, SOC-ul unui EV ar trebui să fie între valoarea minimă și maximă, ceea ce poate fi exprimat astfel:

$$B_{v,min}^{SOC} \geq B_{v,discon}^{SOC} \geq B_{v,max}^{SOC}, \quad (6.10)$$

$B_{v,max}^{SOC}$ and $B_{v,min}^{SOC}$ sunt valorile minime și maxime ale SOC-ului unui EV, respectiv. $B_{v,discon}^{SOC}$ reprezintă SOC-ul unui EV atunci când se deconectează de la rețeaua de energie. $B_{v,con}^{SOC}$ reprezintă SOC-ul unui EV atunci când este conectat la rețeaua de energie. În plus, pentru a asigura că în metoda propusă nu apare o nouă sarcină de vârf a rețelei de energie comparativ cu schema de încărcare aleatorie, se oferă o altă constrângere pentru rețeaua de energie:

$$\mathcal{P}_{max}^{total} \leq \mathcal{P}_{max, B_{N,max}^{SOC}}^{total-random}, \quad (6.13)$$

$\mathcal{P}_{max, B_{N,max}^{SOC}}^{total-random}$ reprezintă valoarea maximă a sarcinii totale de energie a rețelei în schema de încărcare aleatorie, având în vedere că toate EV-urile trebuie să atingă valoarea maximă a SOC.

Pentru a rezolva problema abordată a încărcării EV-urilor, algoritmul PSO este utilizat în acest studiu. Funcția de fitness reprezintă funcția obiectivă, în acest studiu, sarcina de vârf a EV-urilor care trebuie să fie mutată din perioada de vârf în perioada de vale. În plus, metoda de ponderare aditivă simplă (SAW) este aplicată pentru a formula funcția de fitness. SAW este responsabilă pentru stabilirea unei greutăți de prioritate pentru toate EV-urile în funcție de starea lor de urgență. Funcția de fitness poate fi formulată matematic astfel:

$$\max_i \sum_{b=1}^B w_b f_b(i) = w_1 B^{SOC}(i) + w_2 j^{con}(i) + w_3 j^{discon}(i) \quad (6.14)$$

$f_b(i)$ denotă valoarea funcției de fitness pentru particula i în spațiul de căutare al PSO. w_b reprezintă valoarea de greutate corespunzătoare pentru fiecare criteriu. Deoarece cele trei criterii sunt diferite și au unități și scale variate, normalizarea este esențială în luarea deciziilor multicriteriale. Astfel, funcția de fitness poate fi ca:

$$\max_i \sum_{b=1}^B w_b f_b(i) = w_1 NB^{SOC}(i) + w_2 Nj^{con}(i) + w_3 Nj^{discon}(i) \quad (6.19)$$

În plus, spațiul de căutare include toate soluțiile fezabile, care pot fi alese între valorile limită superioare și inferioare. În această propunere, soluția reprezintă programarea EV-urilor pentru încărcare, ținând cont de cererile urgente ale EV-urilor. Astfel, spațiul de căutare pentru soluția optimă este între valorile \mathcal{P}^{slow} și \mathcal{P}^{fast} . Spațiul de căutare poate fi reprezentat:

$$S(i) = (\mathcal{P}^{slow}, \mathcal{P}^{fast}) \quad (6.20)$$

6.2 Rezultate și discuții

Această secțiune oferă modelul de simulare și evaluarea metodei propuse de încărcare utilizând instrumentul MATLAB. În acest studiu, se consideră un număr diferit de EV-uri (de exemplu, 100 și 500) în ambele tipare de încărcare acasă și încărcare publică. Conform [42], valoarea $B_{v,discon}^{SOC}$ este generată uniform între, $B_{v,min}^{SOC}$ între (0.4-0.6), și $B_{v,max}^{SOC}$ între (0.8-1.0). Parametrii ratelor de încărcare sunt dați ca $p^{slow} = 3.5$ kW, și $p^{fast} = 10$ kW. Figura 6.6 și figura 6.7 prezintă un grafic al sarcinii zilnice în funcție de timpul într-o zi, comparând metoda propusă de încărcare inteligentă și adaptabilă cu două metode de încărcare normală în încărcarea acasă. Rezultatele demonstrează că sarcina de energie necesară de la EV este redusă semnificativ în metoda propusă comparativ cu cele două metode normale de încărcare, în special când numărul de EV-uri crește. Prima metodă normală satisface SOC-ul minim pentru EV-uri, în timp ce a doua metodă satisface SOC-ul maxim pentru EV-uri.

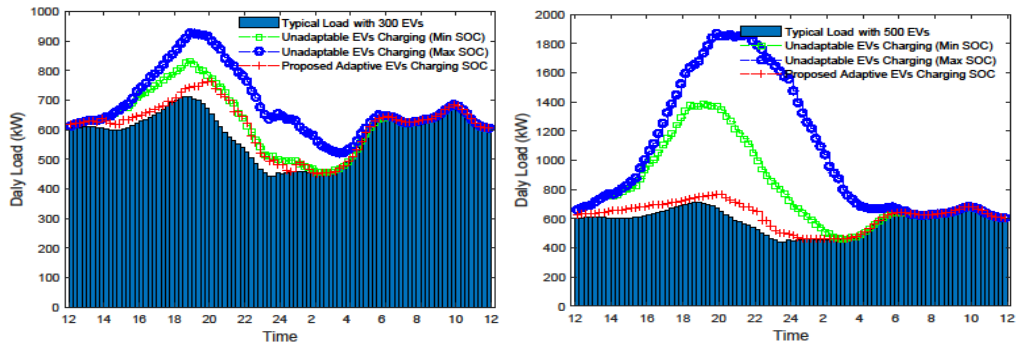


Figura 6.6 și Figura 6.7 Graficele sarcinii zilnice comparate între metoda adaptivă propusă și cele două metode normale de încărcare acasă pentru 100 și 500 de EV.

Figura 6.8 și Figura 6.9 arată graficele sarcinii zilnice în funcție de timp, comparând metoda propusă de încărcare inteligentă și adaptabilă cu două metode normale de încărcare în încărcarea publică. Rezultatul arată că cererea EV-urilor a crescut sarcina de vârf, unde sarcina de bază în încărcarea publică poate fi acoperită doar de câteva EV-uri.




Figure 6.8 și Figure 6.9 Graficele sarcinii zilnice comparate între metoda adaptivă propusă și două metode normale de încărcare acasă și publică pentru 100 și 500 EV.

Figura 6.11 arată distribuția unui număr mare de EV-uri la stațiile de încărcare, comparând metoda propusă de încărcare și metoda normală. Rezultatele arată eficacitatea metodei propuse de încărcare care prioritizează cererea urgentă de încărcare în distribuția sarcinii.




Figura 6.11 Compararea distribuției EV-urilor la stațiile de încărcare între încărcarea normală și metoda propusă.

Capitolul 7

Concluzii și lucrări viitoare

EV reprezintă o componentă critică în orașele inteligente și în rețeaua Internet of Vehicles (IoV). Această teză a explorat și a abordat provocările asociate cu optimizarea programelor de încărcare pentru vehiculele electrice. Domeniul de aplicare al acestei teze a inclus examinarea abordărilor sistemelor de încărcare (de exemplu, centralizate și descentralizate), optimizarea schemelor de programare și diverse metode de optimizare pentru încărcarea vehiculelor electrice. Studiul a investigat și integrarea SDN în mediile rețelelor inteligente pentru a permite gestionarea eficientă a energiei și a comunicațiilor între vehicule, infrastructura de încărcare și rețeaua electrică. Cu toate acestea, există mai multe scheme de încărcare propuse în cercetare pentru a rezolva problema modelelor de încărcare aleatorii și, de asemenea, multe tehnici de optimizare sunt investite sau dezvoltate în acest scop. Complexitatea apare din necesitatea de a echilibra diferiți factori, cum ar fi viteza de încărcare, costul, sustenabilitatea sursei de energie, stabilitatea rețelei și comoditatea utilizatorului. Această natură de problemă de încărcare a vehiculelor electrice cu criterii multiple, în care fiecare dintre aceste criterii poate avea diferite niveluri de importanță în funcție de utilizator, rețea sau prioritățile părților interesate. Prin urmare, nu există o schemă optimă de încărcare care să se potrivească tuturor cerințelor, iar o schemă dinamică și adaptabilă ar fi o soluție mai eficientă pentru problema încărcării vehiculelor electrice.

7.1 Contribuții originale

Această secțiune prezintă principalele contribuții ale acestei teze, specificând lucrările originale care au fost publicate. Fiecare contribuție este identificată în formatul (m,p), unde “m” reprezintă contribuția menționată și “p” denotă lucrarea publicată corespunzătoare (așa cum este numerotată în secțiunea 7.3).

(1,1) a furnizat un sondaj al tehnologiilor V2G/G2V. Identifică mai multe provocări cu care se confruntă tehnologia V2G din perspectiva comunicației, inclusiv gestionarea standardelor de încărcare cu fir și fără fir, sincronizarea transmisiei de date între diferitele niveluri ale arhitecturii rețelei și integrarea V2G cu concepte emergente precum Internetul Energiei și computația Fog și Cloud pentru rețelele 5G.

(2,1) a introdus conceptul de utilizare a SDN ca soluție de control pentru gestionarea interacțiunii între vehiculele electrice și rețeaua inteligentă. Discută avantajele potențiale ale rețelelor inteligente bazate pe SDN, cum ar fi creșterea stabilității sistemului, eficienței și fiabilității, oferind un sistem de management centralizat. Documentul include studii de caz care ilustrează aplicarea recentelor cadre propuse bazate pe SDN în scenarii reale, evidențiind implicațiile practice și beneficiile integrării vehiculelor electrice în rețeaua inteligentă.

(3,1) a propus unele soluții la unele dintre provocările identificate, inclusiv un cadru general V2G bazat pe SDN, menit să îmbunătățească eficiența, fiabilitatea și stabilitatea sistemului. Discută, de asemenea, soluții specifice, cum ar fi utilizarea comunicațiilor multicast pentru detectarea stării bateriei și coordonarea între vehiculele electrice pentru operațiunile de încărcare/descărcare.

(4,6) a furnizat o prezentare cuprinzătoare legată de schemele de încărcare optimizate pentru vehiculele electrice în cadrul infrastructurii de încărcare existente, concentrându-se pe cerințele utilizatorilor. Studiul a evidențiat impactul comportamentelor de încărcare aleatorii asupra rețelei electrice și a subliniat necesitatea unei scheme optime de încărcare.

(4,6) a discutat mai multe aspecte asociate cerințelor de încărcare ale vehiculelor electrice, cum ar fi tipurile de vehicule electrice, modurile de încărcare, modelele de încărcare (de exemplu, acasă, public și mobil), și sistemele centralizate și descentralizate.

(5,6) a prezentat o recenzie critică a tehnicilor de optimizare, analizând apoi soluțiile recente din stadiul de artă și identificând, de asemenea, limitările și lacunele lor. A propus mai multe soluții potențiale pentru problema schemei optime de încărcare, bazate pe limitările și lacunele identificate.

(6,6) a propus unele direcții de cercetare potențiale relevante pentru programarea încărcării vehiculelor electrice, menite să ajute alți ingineri și cercetători să dezvolte astfel de scheme sustenabile, eficiente și prietenoase cu utilizatorul pentru încărcarea vehiculelor electrice.

(7,2) a dezvoltat un model de sistem de încărcare bazat pe SDN, care optimizează distribuția energiei atât din perspectiva rețelei electrice, cât și a utilizatorilor de vehicule electrice, îmbunătățind fiabilitatea rețelei și comoditatea utilizatorilor de vehicule electrice.

(8,2) a propus un algoritm avansat de programare și rutare pentru problema încărcării vehiculelor electrice. Studiul a efectuat o simulare pentru trei scheme, având în vedere harta orașului București, demonstrând eficacitatea algoritmului propus cu schema propusă în minimizarea timpului de serviciu pentru vehiculele electrice, în timp ce se realizează echilibrarea încărcării între stațiile de încărcare.

(9,4) a propus o schemă de încărcare inteligentă și adaptabilă care ajustează dinamic ratele de încărcare pentru utilizatorii de vehicule electrice, ținând cont de starea cerințelor urgente. Această schemă poate transfera cererea de încărcare a vehiculelor electrice de la orele de vârf la orele de vârf scăzut. Algoritmii PSO au fost utilizați pentru a găsi soluția optimă în această schemă.

(10,5) a propus utilizarea NSGA-II pentru a optimiza simultan costul încărcării și timpul de serviciu pentru încărcarea vehiculelor electrice. Această abordare oferă o metodă nouă de a gestiona conflictele între două obiective (de exemplu, costul încărcării și timpul de serviciu) care apar în încărcarea vehiculelor electrice. NSGA-II a fost comparat cu GA și rezultatele au arătat superioritatea sa în obținerea unui set divers de soluții non-dominante.

(11,7) a extins lucrarea din (10,5) și a investigat algoritmi ACO și SA pentru a evalua performanțele lor în minimizarea costului total de încărcare pentru vehiculele electrice în termeni de timp și preț pentru vehiculele electrice.

7.2 Lista publicațiilor originale

Toate lucrările menționate în această teză, cum ar fi în capitolul doi, capitolul trei, capitolul patru, capitolul cinci și capitolul șase, au fost publicate. Ele sunt enumerate după cum urmează:

- 1- **H.M. Al-alwash**, M.K. Hamadani, *Vehicular to Grid Technologies – A Survey on Architectures and Solutions*, The Eighteenth International Conference on Networks Vehicular - ICN 2019, pp. 25–30, March 24-28, Valencia, Spain, 2019.
- 2- **H. Al-Alwash**, E. Borcoci, *Optimal Charging Scheme for Electric Vehicles (EVs) in SDN-based Vehicular Network, Scheduling, and Routing*, The 14th International Conference on Communications - COMM 2022, pp. 1–8, June 16-18, Bucharest, Romania, 2022.
- 3- M.K. Hamadani, **H.M. Al-alwash**, *Centralised Multi-hop Routing for Device-to-Device communication: simulation and results*, The 11th International Conference on Electronics, Computers and Artificial Intelligence - ECAI, pp. 1–6, June 27-29, Pitesti, Romania, 2019.
- 4- **H.M. Al-Alwash**, E. Borcoci, *a Smart Adaptable Charging Method for Electric Vehicles, Considering Urgent Charging Demand*, UPB Scientific Bulletin, Series C: Electrical Engineering and Computer Science, 85(3), pp. 307–318, 2023.
- 5- **H.M. Al-alwash**, E. Borcoci, I. The, *Non-Dominated Sorting Genetic Optimisation For Charging Scheduling Of Electrical*, UPB Scientific Bulletin, Series C: Electrical Engineering and Computer Science, 86(1), pp. 117–128, 2024.
- 6- **H.M. Al-Alwash**, E. Borcoci, M.C. Vochin, I.A.M. Balapuwaduge, F.Y. Li, *Optimization Schedule Schemes for Charging Electric Vehicles: Overview, Challenges, and Solutions*, IEEE Access, 12(March), pp. 32801–32818, 2024.
- 7- **H.M. Al-alwash**, E. Borcoci, *Optimising Charging Scheduling for Electrical Vehicles*, SD–ETTI 2023: 1st Doctoral Symposium on Electronics, Telecommunications, and Information Technology, pp. 2–5, June 27-29, Bucharest, Romania, 2023.

7.3 Lucrări viitoare

Se pot face următoarele sugestii pentru lucrări viitoare:

1. Studiile viitoare ar putea să se concentreze pe investigarea metodelor de învățare automată sau inteligență artificială pentru a prezice modelele de încărcare ale EV, optimizarea consumului de energie sau optimizarea schemelor de încărcare a EV-urilor.
2. Integrarea de RES, cum ar fi solarul, vântul și altele, cu stațiile de încărcare a EV-urilor este încă o problemă deschisă de cercetare. Cercetările viitoare ar putea să se concentreze pe optimizarea utilizării acestor resurse în stațiile de încărcare pentru a reduce dependența de combustibili fosili și pentru a reduce emisiile de carbon.
3. Investigarea implicațiilor mai ample ale tehnologiilor V2X și integrarea acestora cu rețelele inteligente și IoV pentru o comunicare îmbunătățită a vehiculelor, managementul energiei și mobilitatea urbană.

Bibliography

- [1] M.K. Priyan, G. Usha Devi, *A survey on internet of vehicles: Applications, technologies, challenges and opportunities*, International Journal of Advanced Intelligence Paradigms, 12(1–2), pp. 98–119, 2019.
- [2] L.M. Ang, K.P. Seng, G.K. Ijamaru, A.M. Zungeru, *Deployment of IoV for Smart Cities: Applications, Architecture, and Challenges*, IEEE Access, 7, pp. 6473–6492, 2019.
- [3] T. V. Theodoropoulos, I.G. Damousis, A.J. Amditis, *Demand-Side Management ICT for Dynamic Wireless EV Charging*, IEEE Transactions on Industrial Electronics, 63(10), pp. 6623–6630, 2016.
- [4] N. Chen, M. Wang, N. Zhang, X.S. Shen, D. Zhao, *SDN-Based Framework for the PEV Integrated Smart Grid*, IEEE Network, 31(2), pp. 14–21, 2017.
- [5] S. Zhang, Q. Li, J. Wu, J. Li, G. Li, *A security mechanism for software-defined networking based communications in vehicle-to-grid*, The 4th IEEE International Conference on Smart Energy Grid Engineering - SEGE 2016, pp. 386–391, August 21–24, Oshawa, Canada, 2016.
- [6] Y. Sun, X. Hu, X. Liu, X. He, K. Wang, *A Software-Defined Green Framework for Hybrid EV-Charging Networks*, IEEE Communications Magazine, 55(11), pp. 62–69, 2017.
- [7] G. Li, J. Wu, J. Li, T. Ye, R. Morello, *Battery status sensing software-defined multicast for v2g regulation in smart grid*, IEEE Sensors Journal, 17(23), pp. 7838–7848, 2017.
- [8] J.C. Mukherjee, A. Gupta, *A Review of Charge Scheduling of Electric Vehicles in Smart Grid*, IEEE Systems Journal, 9(4), pp. 1541–1553, 2015.
- [9] A. Amin, W.U.K. Tareen, M. Usman, H. Ali, I. Bari, B. Horan, S. Mekhilef, M. Asif, S. Ahmed, A. Mahmood, *A review of optimal charging strategy for electric vehicles under dynamic pricing schemes in the distribution charging network*, Sustainability (Switzerland), 12(23), pp. 1–28, 2020.
- [10] T.U. Solanke, V.K. Ramachandaramurthy, J.Y. Yong, J. Pasupuleti, P. Kasinathan, A. Rajagopalan, *A review of strategic charging–discharging control of grid-connected electric vehicles*, Journal of Energy Storage, 28(November 2019), pp. 101193, 2020.
- [11] S.M. Arif, T.T. Lie, B.C. Seet, S. Ayyadi, K. Jensen, *Review of electric vehicle technologies, charging methods, standards and optimization techniques*, Electronics (Switzerland), 10(16), pp. 1–21, 2021.
- [12] O. Sadeghian, A. Oshnoei, B. Mohammadi-ivatloo, V. Vahidinasab, A. Anvari-Moghaddam, *A comprehensive review on electric vehicles smart charging: Solutions, strategies, technologies, and challenges*, Journal of Energy Storage, 54, pp. 105241, 2022.
- [13] M. Shokri, H. Kebriaei, *Mean field optimal energy management of plug-in hybrid electric vehicles*, IEEE Transactions on Vehicular Technology, 68(1), pp. 113–120, 2019.
- [14] F. Un-Noor, S. Padmanaban, L. Mihet-Popa, M.N. Mollah, E. Hossain, *A comprehensive study of key electric vehicle (EV) components, technologies, challenges, impacts, and future direction of development*, Energies, 10(8), 2017.
- [15] G. Hemanth, B. Suresha, Ananthapadmanabha, *Hybrid and electric vehicle tribology: a review*, Surface Topography: Metrology and Properties, 9(4), pp. 043001, 2021.
- [16] A.R. Gopal, W.Y. Park, M. Witt, A. Phadke, *Hybrid- and battery-electric vehicles offer low-cost climate benefits in China*, Transportation Research Part D: Transport and Environment, 62, pp. 362–371, 2018.
- [17] J. Van Mierlo, M. Messagie, S. Rangaraju, *Comparative environmental assessment of alternative fueled vehicles using a life cycle assessment*, Transportation Research

- Procedia, 25, pp. 3435–3445, 2017.
- [18] B. Bendjedia, N. Rizoug, M. Boukhnifer, F. Bouchafaa, M. Benbouzid, *Influence of secondary source technologies and energy management strategies on Energy Storage System sizing for fuel cell electric vehicles*, International Journal of Hydrogen Energy, 43(25), pp. 11614–11628, 2018.
- [19] EV Charging Modes | Deltrix Chargers, <https://deltrixchargers.com/about-embility/charging-modes/> (accessed August 2, 2023).
- [20] M. Pagani, W. Korosec, N. Chokani, R.S. Abhari, *User behaviour and electric vehicle charging infrastructure: An agent-based model assessment*, Applied Energy, 254, pp. 113680, 2019.
- [21] P. Balram, L.A. Tuan, L.B. Tjernberg, *Centralized charging control of plug-in electric vehicles and effects on day-ahead electricity market price*, Power Systems, 88, pp. 267–299, 2015.
- [22] Y. Zheng, S. Niu, Y. Shang, Z. Shao, L. Jian, *Integrating plug-in electric vehicles into power grids: A comprehensive review on power interaction mode, scheduling methodology and mathematical foundation*, Renewable and Sustainable Energy Reviews, 112(June), pp. 424–439, 2019.
- [23] C.S. Ioakimidis, D. Thomas, P. Rycerski, K.N. Genikomsakis, *Peak shaving and valley filling of power consumption profile in non-residential buildings using an electric vehicle parking lot*, Energy, 148, pp. 148–158, 2018.
- [24] M. van der Kam, W. van Sark, *Smart charging of electric vehicles with photovoltaic power and vehicle-to-grid technology in a microgrid; a case study*, Applied Energy, 152, pp. 20–30, 2015.
- [25] G.R.C. Mouli, M. Kefayati, R. Baldick, P. Bauer, *Integrated PV charging of EV fleet based on energy prices, V2G, and offer of reserves*, IEEE Transactions on Smart Grid, 10(2), pp. 1313–1325, 2019.
- [26] C. Jin, J. Tang, P. Ghosh, S. Member, *Optimizing Electric Vehicle Charging With Energy Storage in the Electricity Market*, IEEE Transactions on Smart Grid, 4(1), pp. 311–320, 2013.
- [27] W. Tang, Y.J. Zhang, *A Model Predictive Control Approach for Low-Complexity Electric Vehicle Charging Scheduling: Optimality and Scalability*, IEEE Transactions on Power Systems, 32(2), pp. 1050–1063, 2017.
- [28] J. Wang, L. Kang, Y. Liu, *Optimal scheduling for electric bus fleets based on dynamic programming approach by considering battery capacity fade*, Renewable and Sustainable Energy Reviews, 130, pp. 109978, 2020.
- [29] Y. Zhou, Z. Li, X. Wu, *The multiobjective based large-scale electric vehicle charging behaviours analysis*, Complexity, 2018, pp. 1–16, 2018.
- [30] G.F. Savari, V. Krishnasamy, V. Sugavanam, K. Vakesan, *Optimal Charging Scheduling of Electric Vehicles in Micro Grids Using Priority Algorithms and Particle Swarm Optimization*, Mobile Networks and Applications, 24(6), pp. 1835–1847, 2019.
- [31] G. Konstantinidis, F.D. Kanellos, K. Kalaitzakis, *A simple multi-parameter method for efficient charging scheduling of electric vehicles*, Applied System Innovation, 4(3), pp. 1–22, 2021.
- [32] M. Alonso, H. Amaris, J.G. Germain, J.M. Galan, *Optimal charging scheduling of electric vehicles in smart grids by heuristic algorithms*, Energies, 7(4), pp. 2449–2475, 2014.
- [33] R. Junming, H. Wang, Y. Wei, Y. Liu, K.F. Tsang, L.L. Lai, L.C. Chung, *A Novel Genetic Algorithm-based Emergent Electric Vehicle Charging Scheduling Scheme*, The 45th Annual Conference of the IEEE Industrial Electronics Society I - ECON 2019, pp. 4289–4292, October 14-17, Lisbon, Portugal, 2019.
- [34] M. Mavrovouniotis, G. Ellinas, M. Polycarpou, *Electric Vehicle Charging Scheduling Using Ant Colony System*, IEEE Congress on Evolutionary Computation - CEC 2019, pp. 2581–2588, June 10-13, Wellington, New Zealand, 2019.
- [35] M. Boulakhbar, M. Farag, K. Benabdelaziz, T. Kousksou, M. Zazi, *A deep learning approach for prediction of electrical vehicle charging stations power demand in*

- regulated electricity markets: The case of Morocco*, Cleaner Energy Systems, 3, pp. 100039, 2022.
- [36] J. Liu, H. Guo, J. Xiong, N. Kato, J. Zhang, Y. Zhang, *Smart and Resilient EV Charging in SDN-Enhanced Vehicular Edge Computing Networks*, IEEE Journal on Selected Areas in Communications, 38(1), pp. 217–228, 2020.
- [37] A.Y. Saber, G.K. Venayagamoorthy, S. Member, *Plug-in Vehicles and Renewable Energy Sources for Cost and Emission Reductions*, IEEE Transactions on Industrial Electronics, 58(4), pp. 1229–1238, 2016.
- [38] Z. Moghaddam, I. Ahmad, D. Habibi, Q.V. Phung, *Smart Charging Strategy for Electric Vehicle Charging Stations*, IEEE Transactions on Transportation Electrification, 4(1), pp. 76–88, 2017.
- [39] N. Chee-Hock, S. Boon-Hee, *Queueing Modelling Fundamentals: With Applications in Communication Networks: Second Edition*, Wiley, p. 1–271, ISBN: 9780470994672, 2008.
- [40] PlugShare - EV Charging Station Map - Find a place to charge your car!, <https://www.plugshare.com/> (accessed June 28, 2021).
- [41] Y. Zheng, Y. Shang, Z. Shao, L. Jian, *A novel real-time scheduling strategy with near-linear complexity for integrating large-scale electric vehicles into smart grid*, Applied Energy, 217(February), pp. 1–13, 2018.
- [42] L. Jian, Y. Zheng, Z. Shao, *High efficient valley-filling strategy for centralized coordinated charging of large-scale electric vehicles*, Applied Energy, 186, pp. 46–55, 2017.