

# Tekoäly sähköautojen akkujen hallinnassa ja optimoinnissa

TURUN YLIOPISTO  
Tietotekniikan laitos  
LuK-tutkielma  
Tietojenkäsittelytiede  
Toukokuu 2024  
Juho Aaku

TURUN YLIOPISTO  
Tietotekniikan laitos

JUHO AAKU: Tekoäly sähköautojen akkujen hallinnassa ja optimoinnissa

LuK-tutkielma, 21 s.  
Tietojenkäsittelytiede  
Toukokuu 2024

---

Sähköautot ovat yleistyneet nopeaa tahtia viime vuosien aikana ja ne ovat jo korvanneet osan polttomoottoria hyödyntävistä ajoneuvoista. Sähkömoottorin energianlähteenä toimivan akun lataamiseen voidaan hyödyntää uusiutuvia luonnonvaroja ja samalla voidaan vähentää autoilusta johtuvia päästöjä. Teknologian kehityksestä huolimatta akkujen suorituskyky ja elinkaari eivät vastaa niille annettuja odotuksia.

Tässä tutkielmassa selvitetään, miten tekoälyn avulla voidaan kehittää ja optimoida sähköauton akun käyttöä ja latausta sekä toimintamatkan arviointia. Tarkoituksena tutkielmassa on perehtyä tekoälymenetelmiin akun suorituskyvyn ja käytettävyyden parantamiseksi. Tutkielma on toteutettu kirjallisuuskatsauksena.

Kirjallisuuden perusteella erilaiset koneoppimiseen ja neuroverkkoihin pohjautuvat menetelmät ovat osoittautuneet tehokkaiksi välineiksi akkujen hallinnassa ja optimoinnissa. Menetelmiä, kuten pitkäkestoista lyhytkestomuistia, sateenvirtausyklin laskenta-algoritmia ja Kalman-suodatinta, voidaan hyödyntää sähköauton akun optimointiin. Tutkimustuloksista voitiin päätellä, että menetelmien koulutusdatan tarkkuus on tärkeää tuloksien kannalta. Tuloksien arvioinnissa on syytä huomioida, että niiden soveltuvuus muille kuin litiumakuille vaatii jatkotutkimuksia.

Asiasanat: tekoäly, koneoppiminen, sähköauto, akku

# Sisällys

<b>1</b>	<b>Johdanto</b>	<b>1</b>
<b>2</b>	<b>Sähköautojen akut</b>	<b>3</b>
2.1	Akkujen materiaalit ja ominaisuudet . . . . .	3
2.2	Akun hallintajärjestelmä . . . . .	4
2.3	Kaksisuuntainen lataus . . . . .	7
2.4	Tekoäly . . . . .	8
<b>3</b>	<b>Tekoäly akkujen hallinnassa ja optimoinnissa</b>	<b>11</b>
3.1	Akun lataaminen . . . . .	11
3.2	Akun kunto ja varaustaso . . . . .	14
3.3	Toimintamatka-arvio . . . . .	17
<b>4</b>	<b>Yhteenveto</b>	<b>20</b>
	<b>Lähdeluettelo</b>	<b>22</b>

# 1 Johdanto


Tällä hetkellä suurin osa kulkuneuvoista liikenteessä kuluttaa uusiutumaton energiaa, fossiilisia polttoaineita. Tämän lisäksi polttomoottorikäyttöiset kulkuneuvot tuottavat merkittävän osan kasvihuonekaasupäästöistä (Ghalkhani & Habibi, 2022). Luonnonvarojen säästämiseksi ja päästöjen vähentämiseksi tarvitaan uutta teknologiaa kulkuneuvoihin.

Polttoaineiden hintojen nousun myötä sähköautot ovat yleistyneet ja useat autovalmistajat ovat kehittäneet vaihtoehtoisia käyttövoimia fossiilisille polttoaineille (Umathe & Hiware, 2022). Sähkö on yksi vartenotettava vaihtoehto. Uusiutumattomien luonnonvarojen säästäminen sekä polttoainekustannusten vähentäminen ovat keskeisiä syitä sähköautojen kysynnän kasvulle. Hyvien puolien lisäksi sähköautoiluun liittyy vielä paljon epävarmuutta. Rajoitettu kantama, pitkät latausajat sekä latausasemien rajallisuus ovat useille kuluttajille ratkaisevia esteitä sähköauton hankkimiselle. (Ghalkhani & Habibi, 2022)

Edellä mainittujen epäkohtien ratkaisemiseksi vaaditaan uusia välineitä. Tekoäly on kehittynyt paljon viime vuosien aikana ja sitä hyödynnetään jo monilla eri osa-alueilla. Myös autoteollisuus on huomannut tekoälyn mahdollisuudet ja näitä mahdollisuuksia on alettu hyödyntämään sähköautojen akkujen valmistuksessa ja käytössä (Ahmed ym., 2021).

Tässä tutkielmassa tarkastellaan tekoälyn vaikutuksia sähköautojen akkujen käyttöön ja optimointiin. Tutkielman tutkimuskysymys on, että miten sähköauton akun latausta ja käyttöä voidaan kehittää ja optimoida tekoälyn avulla. Tutkielmassa keskitytään pääosin akun latauksen sekä akun varaustason ja kunnan analysointiin. Tutkielmassa perehdytään myös sähköauton toimintamatka-arvion tarkentamiseen.

Tutkielma on toteutettu kirjallisuuskatsauksena. Tutkielmassa hyödynnetään pääosin konferenssiartikkeleita ja tutkimuksia. Lähdemateriaali on haettu Google Scholarista sekä IEEE Xplore – tietokannasta. Hakutulokset haettiin englannin kielellä käyttäen tutkielman aiheeseen liittyviä keskeisiä avainsanoja, kuten ”artificial intelligence”, ”electric vehicles”, ”battery management”, ”battery charging”, ”battery optimization” ja ”range estimation”. Kirjallisuuskatsauksessa haluttiin keskittyä uusimpiin tutkimustuloksiin, joten lähdemateriaalin julkaisuvuodet rajattiin alkamaan vuodesta 2018. Hakutuloksista karsiutui suurin osa pois jo otsikon perusteella. Tarkempaan tarkasteluun päätyneistä materiaaleista osan pystyi sulkemaan pois tiivistelmän ja johdannon perusteella. Tutkielman lähdemateriaali koostui lopulta yhdeksästätoista lähteestä.



Kuva 1.1: Tutkielman tiedonhakuprosessi

Tutkielman toisessa luvussa perehdytään akun rakenteeseen, akun hallintajärjestelmään, kaksisuuntaiseen lataukseen sekä tekoölyyn sähköautoissa. Kolmannessa luvussa tarkastellaan, miten akun lataamista sekä hallintaa ja toimintamatkan arviointia voidaan kehittää tekoälyn avulla. Neljäs luku on yhteenveto, jossa kerrataan tutkielman olennaisimmat kohdat.

## 2 Sähköautojen akut

Toisin kuin polttomoottorikäyttöiset ajoneuvot, sähköautot kulkevat sähkömoottorin avulla. Polttoaineiden, kuten bensiinin ja dieselin, sijasta sähkömoottori saa tarvitsemansa energian akusta. (Sundararaju ym., 2023) Sähköauton tärkeimpiä komponentteja ovat akku ja sen hallintajärjestelmä. Tehokkaan akun ja luotettavan hallintajärjestelmän kehittäminen ovat oleellisia työvaiheita sähköauton kehityksessä. (Li ym., 2019) Tekoälyn ja koneoppimisen tuomat mahdollisuudet kulkuneuvojen kehitykseen ovat merkittävät.

### 2.1 Akkujen materiaalit ja ominaisuudet

Yleisimmät sähköautoissa käytetyt virtalähteet ovat litiumioni-, nikkelikadmium- ja lyijyhappoakkuja. Tässä tutkielmassa keskitytään pääosin litiumakkuihin. Edellä mainituista litiumakkuja pidetään parhaimpina, sillä ne varastoivat enemmän sähköenergiaa, niiden itsepurkautuminen on vähäistä, niissä on korkeampi jännite sekä pidempi käyttöikä muihin mainittuihin akkutyyppeihin verrattuna (Dewalkar & Nangrani, 2021). Pienen koon ja kevyen rakenteen ansiosta litiumakkujen käyttöalue on laajentunut matkapuhelimista ja kannettavista tietokoneista sähköautoihin. (Hu & Liu, 2022)

Akkukennon keskeisimmät komponentit ovat positiivinen elektrodi (katodi), negatiivinen elektrodi (anodi) ja elektrolyytti. Akkua ladattaessa ja purettaessa litiumionit liikkuvat nestemäisessä elektrolyytissä anodin ja katodin välillä. Sähköauton akku koostuu useista akkukennoista, jotka kytketään joko sarjaan tai rinnakkain. (Zhang ym., 2023)

Akkuteknologian lupaavasta edistyksestä huolimatta litiumakkujen suorituskyky ei ole toivotulla tasolla, joten valmistusmenetelmien ja materiaalien kehittäminen on välttämätöntä. Yksi yleisesti kiinnostusta autovalmistajien keskuudessa herättänyt edistysaskel olisi nestemäisen elektrolyytin korvaaminen kiinteällä. (Zhao ym., 2020) Kiinteä elektrolyytti mahdollistaisi suuremman energiatiheyden, joka tarkoittaa, että akku on kevyempi. Tämän myötä myös sähköauto on kevyempi ja näin ollen tarvitaan vähemmän energiaa auton liikuttamiseen. Kiinteällä elektrolyytillä voidaan myös ehkäistä akkujen tulipaloriskiä, sillä se ei ole yhtä herkästi syttyvää kuin nestemäinen. Kiinteän elektrolyytin kehityksessä ongelmana on valmistukseen liittyvät kustannukset. (Ghalkhani & Habibi, 2022)

Ajan ja käytön myötä litiumakut menettävät kykyään varastoida sekä hyödyntää sähkövirtaa. Tämä vaikuttaa negatiivisesti akun suorituskykyyn ja turvallisuuteen. Akkujen käyttöikään vaikuttavat useat eri tekijät, kuten akun valmistus- sekä käytötapa ja ympäristön olosuhteet. (K. Liu ym., 2022)

## 2.2 Akun hallintajärjestelmä

Akun hallintajärjestelmä (engl. battery management system) seuraa akun jännitettä, sähkövirtaa ja lämpötilaa, diagnosoi vikatilanteita sekä vastaa energiatehokkaasta akun käytöstä (Sharma ym., 2023). Hallintajärjestelmä voi eri parametrien mittauksien perusteella määritellä akun nykyisen kunnon (engl. state of health) ja akun varaustason (engl. state of charge). Akun kunto määrittelee akun nykyisen

kapasiteetin varastoida virtaa verrattuna uuteen akkuun ja varaustaso kertoo, paljonko akussa on jäljellä virtaa tietynä ajanhetkenä. Akun kuntotietojen tarkkailu on tärkeää, sillä niiden perusteella voidaan suunnitella strategioita akun käyttöiän pidentämiseksi. (K. Liu ym., 2022)

Akun varaustason tarkka arvioiminen on yksi tärkeimpiä tehtäviä akun hallinnan kannalta, sillä tarkan arvion ansiosta voidaan välttyä akun ylilataamiselta, joka vahingoittaa akkua (Umathe & Hiware, 2022). Akun kunnan arvioinnin myötä akun hallintajärjestelmä voi mm. ennustaa akun jäljellä olevan käyttöiän (Oji ym., 2021). Akun kunnan heikentyminen johtuu niin yksittäisen akkukennon kulumisesta kuin myös laadullisista eroavaisuuksista akkukennojen välillä. Litiumakun kunnan heikentyminen on melko monimutkainen ilmiö, joka ilmenee useimmiten kapasiteetin tai tehon heikkenemisenä (Y. Liu ym., 2023). Kunnan heikentymiseen vaikuttavat sisäiset tekijät, kuten valmistus- ja kokoonpanoprosessit sekä ulkoiset tekijät, kuten akun pikalataus ja purkaminen sekä lämpötilavaihtelut. Kennojen valmistus- ja kokoonpanoprosessien epäjohtonmukaisuudet johtavat akun nopeampaan kulumiseen, sillä koko akun suorituskyky määräytyy heikoiten suoriutuvan kennon mukaan. (Zhang ym., 2023) Akun sisäinen resistanssi kasvaa akun ikääntyessä, jolloin jännite laskee nopeammin akkua käytettäessä. Tämä vaikuttaa myös akun kunnan heikkenemiseen (Oji ym., 2021).

Myös lämpötilan tarkkailu on yksi akun hallintajärjestelmän tärkeistä tehtävistä. Korkeissa lämpötiloissa akussa tapahtuva kemiallinen reaktio kiihtyy, mikä voi johtaa akun ylilatautumiseen tai purkautumiseen. Akun lämpötilan äärimmäinen nousu voi johtaa jopa akun räjähtämiseen. Vastaavasti alhaisissa lämpötiloissa akun kemiallinen reaktio hidastuu. Akun jäätyessä sen lataaminen tai purkaminen voi olla mahdotonta. (Hu & Liu, 2022) Varsinkin litiumakkujen kanssa lämpötilan ja jännitteen seuranta on erityisen tärkeää. Yleisesti litiumakkujen kennojen jännite tu-



lisi olla 2,5 – 4,2 voltia ja lämpötila -13 – +60 celsiusastetta. Akun toiminnan ja turvallisuuden kannalta on tärkeää, että pysytään näissä lukemissa. Akun hallintajärjestelmä voi rajoittaa tai pysäyttää auton laitteita, jotka akkua hyödyntävät, jotta akun jännite tai lämpötila ei mene sallittujen rajojen ulkopuolelle. (Umathe & Hiware, 2022)

Yleisimpiä ratkaisuja akun lämpötilanhallintaan ovat ilmajäähdytys, nestejäähdytys, faasimuutosmateriaalit (engl. phase change materials) ja lämpöputket. Ilma- ja nestejäähdytys ovat aktiivisia jäähdytysjärjestelmiä, sillä ne tarvitsevat toimiakseen apujärjestelmiä, kuten pumppuja tai tuulettimia. Ilmajäähdytyksen etuja ovat luotettavuus ja yksinkertainen suunnittelu, mutta ne ovat usein tehottomia. Ilmajäähdytykseen verrattuna nestejäähdytys on huomattavasti tehokkaampi keino. Faasimuutosmateriaalit ja lämpöputket ovat puolestaan passiivisia jäähdytysjärjestelmiä, koska ne eivät yleensä tarvitse ylimääräisiä osia toimiakseen. Faasimuutosmateriaalit varastoivat lämpöä faasimuutoksen avulla. Lämpöputkessa oleva neste höyrystyy lämmön takia ja höyry tiivistyy takaisin nesteeksi putken kylmässä päässä, jossa lämpö siirtyy putkesta ulos. Faasimuutosmateriaalien heikkoutena on huono lämmönjohtavuus sekä riski nestevuodoille faasimuutoksen aikana. Lämpöputket ovat useimmiten metallia, joten niiden heikkous on ylimääräinen paino. Eri jäähdytysmenetelmiä voidaan myös käyttää rinnakkain tehokkaamman jäähdytyksen takaamiseksi. (Ghalkhani & Habibi, 2022)

Sähköautojen yleistymisen myötä myös niihin liittyvät onnettomuudet ovat keränneet huomiota, etenkin akkujen paloturvallisuus on usein kyseenalaistamisen kohteena. Hengenvaaran lisäksi akkupaloista aiheutuu merkittäviä kustannuksia niin autojen omistajille kuin latausasemillekin. Akun lataamisen voi vaarantaa esimerkiksi akun ylilataaminen tai oikosulku. (Diao ym., 2023)

Älykkäiden akkujen kehityksessä sensoriteknologia on tärkeässä osassa. Akun eri parametrien, kuten lämpötilan, sähkövirran ja jännitteen, tarkkailuun tarvitaan edistyneet sensorit. Algoritmien ja matemaattisten mallien avulla akun hallintajärjestelmä voi edellä mainittujen parametrien perusteella tehdä akun suorituskykyyn ja kuntoon liittyviä havaintoja. (K. Liu ym., 2022)


Sähkövirran tarkkailuun käytetyt sensorit voidaan jakaa kahteen ryhmään, Hallantureihin (engl. Hall effect sensors) ja shunttivastuksiin (engl. shunt resistors). Hall-anturit ovat kestäviä, mutta niiden haittapuolia ovat alttius sähkömagneettisille häiriöille, heikompi tarkkuus pienillä sähkövirroilla ja korkeat kustannukset. Yksinkertainen shunttivastus on tarkempi, mutta se on herkempi ympäristön lämpötilan muutoksille. (K. Liu ym., 2022)

## 2.3 Kaksisuuntainen lataus

Kaksisuuntaisen latauksen (engl. vehicle to grid, V2G) ideana on, että sähköauton akkua voidaan lataamisen lisäksi myös purkaa. Akun energiaa voidaan siirtää takaisin sähköverkkoon tarvittaessa, kun auto ei ole käytössä. Esimerkiksi akusta saatua energiaa voidaan käyttää tarpeen vaatiessa talon hätävirtalähteenä. Näin voidaan hyödyntää tehokkaammin uusiutuvia energianlähteitä sekä suojautua sähkön hintapiikkejä vastaan tai sähkökatkoksen varalta. Kaksisuuntaisen latauksen yhtenä etuna on myös mahdollisuus toisen sähköauton akun lataamiseen, jos lähellä ei ole latausasemaa. (Abdullah ym., 2021) Kaksisuuntaisen latauksen haasteita ovat mm. akun kunnan heikkeneminen jatkuvan lataamisen ja purkamisen takia sekä tekniikan käyttöönottoon liittyvät korkeat kustannukset (Li ym., 2023).

Yleisimmät litiumakun lataukseen käytettävät latausprotokollat ovat vakiovirta-vakiojännite (engl. constant current-constant voltage, CCCV) ja monivaiheinen vakiovirta (engl. multistage constant-current, MSCC) (Xu ym., 2019). Vakiovirta-

vakiojännitelataus lataa akkua vakiovirralla, kunnes akku on lähes täynnä. Puolestaan monivaiheinen vakiovirtalataus vähentää asteittain latausvirtaa akun täyttyessä. Monivaiheinen vakiovirtalataus on nopeampi menetelmä, jossa akun lämpötila säilyy maltillisena koko latauksen ajan. (Imran ym., 2020)



Kuva 2.1: Kaksisuuntainen lataus. Kuva: Tommaso Sansone, 2021, ([https://commons.wikimedia.org/wiki/File:Electric\\_car\\_as\\_storage\\_battery\\_for\\_electricity\\_grid\\_-\\_Vehicle-to-grid\\_-\\_V2G\\_icon.png](https://commons.wikimedia.org/wiki/File:Electric_car_as_storage_battery_for_electricity_grid_-_Vehicle-to-grid_-_V2G_icon.png)). Kuva lisensoitu CC0 1.0 Universal -lisenssillä (<https://creativecommons.org/publicdomain/zero/1.0/deed.en>).


## 2.4 Tekoäly

Tekoälylle (engl. artificial intelligence) on kehitetty useita määritelmiä. Yleisesti sitä voidaan kuvata koneen tai ohjelman kykyä toimia älykkäänä pidetyllä tavalla jonkin tehtävän tai toiminnon suorittamiseksi. Tekoälyä hyödynnetään jo monella tavalla, kuten esimerkiksi hakukoneissa (Google) tai erilaisissa virtuaaliavustajissa (Siri, Alexa).

Koneoppiminen (engl. machine learning) on tekoälyn osa-alue, jossa ohjelma tai kone kykenee oppimaan itsenäisesti sille annetun tiedon perusteella päästäkseen haluttuun lopputulokseen. Yleisimpiä koneoppimisalgoritmityyppisiä ovat ohjattu oppi-

minen (engl. supervised learning), ohjaamaton oppiminen (engl. unsupervised learning) ja vahvistus oppiminen (engl. reinforcement learning) (Ahmed ym., 2021). Ohjatussa oppimisessa opetusdata sisältää syötteet ja niiden tulokset, jotka koneen tulee osata yhdistää toisiinsa. Ohjaamattomassa oppimisessä haluttu tulos ei ole koneen tiedossa. Vahvistus oppimisessä oppiminen tapahtuu ympäristöstä saadun palautteen perusteella. Algoritmi pyrkii löytämään ratkaisun, josta se saa eniten positiivista palautetta. (Abdullah ym., 2021)

Neuroverkko (engl. neural network) jäljittelee ihmisen aivojen toimintaa ja se koostuu neuroneista, jotka suorittavat laskentaa ja lähettävät laskennasta saadun painotetun summan seuraavalle neuronille. Neuroverkossa on useita kerroksia, kuten syöte-, ulostulo- sekä piilokerrokset. Neuroverkon tulisi antaa syötettä vastaava tulos, jos näin ei kuitenkaan käy, oppimisprosessin aikana neuronien painoja säädetään halutun tuloksen saavuttamiseksi. (Mijwel, 2021)



Kuva 2.2: Yksinkertainen neuroverkko. Kuva: Dake & Mysid, 2006, ([https://commons.wikimedia.org/wiki/File:Neural\\_network.svg?uselang=fi](https://commons.wikimedia.org/wiki/File:Neural_network.svg?uselang=fi)). Kuva lisensoitu CC BY 1.0 Generic -lisenssillä (<https://creativecommons.org/licenses/by/1.0/>).

---

Sähköautojen akkujen valmistuksessa sekä käytössä tekoälyä hyödynnetään monella tavalla. Akun valmistusprosessissa koneoppimista voidaan esimerkiksi käyttää uusien akkumateriaalien löytämiseen ja niiden kemiallisten ominaisuuksien ennustamiseen. Akkujen hallinnassa tekoälymenetelmiä sovelletaan akun varaustason ja kunnan muutoksien sekä toimintamatkan arvioinneissa. Koneoppimista voidaan hyödyntää myös akun lataamisen sekä kaksisuuntaisen lataamisen optimoinneissa, latausinfrastruktuurin sijoittelussa sekä lataustarpeiden ennakoinnissa latausasemilla. (Ahmed ym., 2021)

# 3 Tekoäly akkujen hallinnassa ja optimoinnissa

Akkuihin liittyvien ongelmien ratkaiseminen on tärkeää, jotta sähköautot olisivat yhtä luotettavia kuin polttomoottoriautot. Tekoälyratkaisuista akkujen hallinnassa on tehty kattavasti tutkimusta useista eri näkökulmista. Esimerkiksi tekoälyn avulla voidaan kehittää uusia havainnointitekniikoita, joilla voidaan tarkkailla akun kuntoa ja varaustasoa (Ahmed ym., 2021). Tekoälysovelluksiin pohjautuvien diagnostiikkatyökalujen avulla voidaan selvittää milloin akun suorituskyky heikkenee huomattavasti. Akun sähkövirran varastointi- ja toimituskykyä tarkkaillaan sen koko elinkaaren ajan. Suorituskykyyn vaikuttavat ikääntymisen lisäksi myös akun käyttöolosuhteet, joiden tarkkailuun tarvitaan erilaisia mallinnustekniikoita. (K. Liu ym., 2022)

## 3.1 Akun lataaminen

Sähköauton käyttö vaatii säännöllistä akun lataamista, joten latausprosessin optimoiminen on tärkeää akun kunnan ylläpitämiseksi ja latausajan minimoimiseksi. Varaustason tarkkailussa on hyvä ottaa huomioon, että akun yllilataaminen tai purkamisen tyhjäksi voivat johtaa akun käyttöiän lyhenemiseen (Umathe & Hiware, 2022).

Dynaamista ohjelmointia (engl. dynamic programming) voidaan hyödyntää tehokaimman latausprotokollan löytämiseksi. Dynaamisen ohjelmoinnin ideana on jakaa ongelma pieniin osiin, jotka ratkaistaan yksi kerrallaan. (K. Liu ym., 2022) Kyseisellä lähestymistavalla Xu ym. (2019) löysivät latausprotokollan, jonka ansiosta 3300 latauskerran jälkeen litiumakun kapasiteetti heikkeni vain 4,6 prosenttia ja lämpötilan nousua ladattaessa voitiin hillitä 16,3 prosentilla. Dynaamisen ohjelmoinnin avulla löydettyä latausprotokollaa verrattiin vakiovirtaa hyödyntävään latausprotokollaan. Akku ladattiin 20 prosentista 80 prosenttiin ja purettiin takaisin 20 prosenttiin. Latausprotokollaa optimoitiin aina 150 lataussyklin välein. Dynaaminen ohjelmointi on joustava menetelmä, mutta se vaatii paljon muistia ja laskentatehoa.

Latauksen turvallisuuden valvomiseksi on kehitetty menetelmä, joka hyödyntää sopeutuvaa pitkäkestoista lyhytkestomuistia (engl. adaptation long short term memory), jonka syötteinä käytetään akun varaustasoa, jännitettä, latausvirtaa sekä lämpötilaa. Lyhytkestomuistin avulla voidaan ennustaa akun parametrien muutoksia latauksen aikana. Menetelmän avulla voidaan tuottaa varoitus, jos latauksessa jokin akun parametri, kuten jännite, latausvirta tai lämpötila, menee laskettujen dynaamisten kynnsarvojen ulkopuolelle. Kiinteisiin kynnsarvoihin verrattuna dynaamisilla kynnsarvoilla saavutettiin keskimäärin 4,52 prosenttia parempi tarkkuus latausvirheiden ennustamisessa. (Diao ym., 2023)

Kaksisuuntaisen lataamisen yksi keskeisimmistä ongelmista on akun kulumisen toistuvan lataamisen ja purkamisen seurauksena. Tämän ongelman ratkaiseminen on välttämätöntä akkujen suorituskyvyn ja kohtuullisen käyttöiän takaamiseksi. Akun käyttäminen itsessään kuluttaa akkua, mutta myös perusteellinen akun purkaminen on vahingollista. Li ym. (2023) käyttivät akun käyttöiän turvaamiseksi ohjattuun oppimiseen perustuvaa koneoppimismetodia, äärimmäinen oppimiskone (engl. extreme learning machine) sekä sateenvirtausykin laskenta-algoritmia (engl. rainflow

cycle counting algorithm), joita hyödyntämällä kehitettiin kaksisuuntaiseen lataukseen malli, joka pidentää akun käyttöikä. Mallin avulla pystyttiin rajoittamaan akun lataussyklejä 39,3 prosentilla sekä hillitsemään akun käyttöiän lyhenemistä 50,5 prosentilla verrattuna jo olemassa olevaan malliin.

Li ym. (2023) vertailivat tutkimuksessaan kehitettyä latausmallia kahteen jo olemassa olevaan malliin, sääntöpohjaiseen- ja optimointipohjaiseenmalliin. Tutkimuksessa kehitetty äärimmäistä oppimiskonetta ja sateenvirtaussyklin laskenta-algoritmia hyödyntävä malli suoriutui selvästi paremmin akun lataussykliä vähentämisessä verrattuna sääntöpohjaiseenmalliin. Akun kunnon kannalta tutkimuksessa esitettyä mallia paremmin suoriutui optimointimalli, joka onnistui vähentämään lataussyklejä noin 34 prosentilla tutkimuksen malliin verrattuna, mutta hyödynsi vain 73,2 prosenttia saatavilla olevasta uusiutuvasta energiasta. Tutkimuksessa esitetty malli pystyi hyödyntämään 94,6 prosenttia uusiutuvasta energiasta. Tämän perusteella voidaan todeta, että useampaa menetelmää hyödyntävä malli pystyy kokonaisuudessaan suoriutumaan paremmin verrattuna yksinkertaisempiin, yhden menetelmän malleihin. Toisaalta, 34 prosentin ero lataussykleissä on merkittävä pitkällä aikavälillä. Tulevaisuutta ajatellen latausmallien valinnassa ja kehityksessä saattaa joutua valitsemaan hieman nopeamman akun kulumisen ja uusiutuvan energian tehokkaamman hyödyntämisen välillä, ellei löydetä tapaa yhdistää molempien mallien vahvuudet. Kaksisuuntaisen latauksen käyttöönotossa akun käyttöiän säilyttäminen tulee ottaa huomioon. Tulosten perusteella latausmenetelmien kehittämiseen on selkeästi kannattavaa panostaa, sillä akun käyttöiän puolittuminen on vakava ongelma kaksisuuntaisen latauksen positiivisista puolista huolimatta.



## 3.2 Akun kunto ja varaustaso

Sensoreista kerättyä tietoa voidaan hyödyntää koneoppimismenetelmien avulla akkujen mallinnuksessa. Li ym. (2019) kehittivät pilvipohjaisen akkumallin tukivektori regression (engl. support vector regression) avulla. Akkumallin ideana on jäljitellä akun toimintaa (Imran ym., 2020). Akkumallin ja sateenvirtaussyklin laskenta-algoritmin avulla voitiin mallintaa akun ikääntymistä tarkasti. Kyseisen akkumallin mallinnusvirhe on enintään 3,5 prosenttia, kun taas tavanomaisen akkumallin mallinnusvirhe voi olla jopa 10,5 prosenttia. Tavanomaiseen akkumalliin verrattuna Li ym. (2019) kehittämä akkumalli huomioi sensoreista kerättyjen tietojen lisäksi myös lataussyklit sekä sen, että kuinka tyhjäksi akku puretaan. Edellisessä alaluvussa myös Li ym. (2023) hyödynsivät sateenvirtaussyklin laskenta-algoritmia akun kunnan muutosten tarkkailussa.

Koneoppimiseen pohjautuva autoregressiivinen integroitu liukuvan keskiarvon malli (engl. autoregressive integrated moving average model) eli ARIMA-malli soveltuu akun varaustason arviointiin useasta syystä. Varaustason arviointiin vaikuttavat akun jännite, lämpötila sekä sähkövirta, joiden vaihteluja pystytään ARIMA-mallin avulla seuraamaan ja tallentamaan. ARIMA-malli pystyy myös käsittelemään puutteellista dataa ja tällaisen mallin tulkitseminen on suhteellisen helppoa. Sundararaju ym. (2023) hyödynsivät ARIMA-mallia akun varaustason ennustamiseen. Samalla voitiin myös ennustaa tarkasti akun sähkövirran, jännitteen ja lämpötilan muutoksia varaustason muuttuessa.

Varaustason ennustamiseen voidaan hyödyntää myös neuroverkkoja. Umathe ja Hiware (2022) keräsivät akun sensoridataa pilvipalveluun analysoitavaksi, jonka jälkeen takaisinkytketty neuroverkko (engl. recurrent neural network) koulutettiin kerätyllä datalla. Kyseinen neuroverkkomalli saavutti lähes 97 prosentin tarkkuuden akun parametrien ennustamisessa. Tämän jälkeen neuroverkkomallin ennustamaa

akun varaustason muutosta verrattiin saatuihin testituloksiin todellisesta varaustasosta. Neuroverkon ennustus oli lähes identtinen verrattuna tosiasialliseen varaustasoon.

Dewalkar ja Nangrani (2021) vertailivat kahta menetelmää, coulombin laskemista (engl. coulomb counting) ja neuroverkkoa akun varaustason arvioinnissa. Coulombin laskeminen on yksi yleisimmistä ja tavanomaisista menetelmistä varaustason arviointiin, jossa varaustaso arvioidaan sähkövirran perusteella. Kyseisen menetelmän virrankulutus on vähäistä ja se on helppo toteuttaa, mutta menetelmän yksinkertaisuus voi johtaa epätarkkoihin tuloksiin. Neuroverkko koulutettiin akun jännitteellä ja sähkövirralla varaustason arviointia varten. Menetelmien vertailussa ilmeni, että neuroverkon avulla voitiin varaustasoa arvioida tarkemmin verrattuna coulombin laskemiseen.

Laajennettua Kalman-suodatinta (engl. extended Kalman filter) voidaan hyödyntää varaustason arvioinnissa alhaisten laskennallisten kustannuksien sekä helpon implementoinnin vuoksi. Laajennettu suodatin on epälineaarinen versio Kalman-suodattimesta. Imran ym. (2020) tutkimuksessa huomattiin, että laajennetulla Kalman-suodattimella keskimääräinen arviointivirhe on vain 6,4 prosenttia akun varaustason ollessa 50 prosenttia. Varaustason ollessa 100 prosenttia arviointivirhe putosi noin 1,9 prosenttiin. Kalman-suodattimella voitiin myös arvioida tarkasti akun kapasiteetin heikkenemistä 18 lataussyklin ajalta.

Akun kunnan määrittelyyn on useita erilaisia tapoja. Tavallisesti ne voidaan jakaa neljään ryhmään: kokeellisen analyysin lähestymistapa, akkumallinnus, datalähtöinen lähestymistapa ja fuusiomenetelmä. Kokeellisessa analyysissä käytetään erilaisia laitteita akun suorituskyvyn diagnosoinnissa ja analysoinnissa, jonka seurauksena saadaan tarvittavia parametrejä, kuten jännite ja sähkövirta, akun kunnan arviointiin. Differentiaalisessa jänniteanalyysissä (engl. differential voltage analysis) luo-

daan parametrejä erottelemalla käyrä, josta saadaan malli akun kunnan arviointia varten. Käyrän arvojen analysoinnissa hyödynnetään koneoppimisalgoritmia satunnaismetsä (engl. random forest), jonka avulla löydetään käyrästä tärkeimmät pisteet. Näitä pisteitä käytetään syötteinä neuroverkkoihin, joiden tarkoituksena on löytää yhteys käytettyjen parametrien ja akun kunnan välillä. Kokeellisen analyysin lähestymistavan ongelmana on tarvittavien testauslaitteiden kustannukset. (Zhang ym., 2023)

Tutkimuksien perusteella uskotaan, että litiumakkujen sisäisellä resistanssilla on yhteys akun kuntoon. Tämän tiedon avulla akkumallinnuksessa pyritään muodostamaan malli, joka tunnistaa koneoppimismenetelmien avulla kokeellisesta datasta akun ominaisuuksia kunnan arviointia varten. Akkumallinnus vie yleensä paljon aikaa ja se on kallista. (Zhang ym., 2023) Datalähtöisessä lähestymistavassa käytetään testeistä saatuja akun parametrejä koneoppimismenetelmissä, joiden tarkoituksena on selvittää akun kunnan heikentymiseen liittyviä syitä ja arvioida akun kuntoa. Oji ym. (2021) vertailivat akun kunnan arviointia varten useita datalähtöisiä menetelmiä, kuten esimerkiksi laajennettua Kalman-suodatinta, hiukkassuodatinta (engl. particle filter), pitkäkestoista lyhytkestomuistia, ARIMA-mallia, äärimmäistä oppimiskonetta ja tukivektoreita. Näistä menetelmistä selkeästi parhaiten suoriutuivat kolme ensimmäiseksi mainittua. Tässä tutkimuksessa menetelmien suoriutumista tarkasteltiin kolmessa erässä, joissa jokaisessa menetelmien koulutukseen käytettiin erikokoisia aineistoja. Datalähtöinen lähestymistapa vaatii paljon dataa, jotta mallinnus on tarkka.

Fuusiomenetelmän ideana on hyödyntää kahta eri lähestymistapaa tarkempien tuloksien saavuttamiseksi. Testien perusteella tämän metodin avulla voidaan hyödyntää molempien tapojen hyödyt sekä samalla voidaan vähentää testaukseen tarvittavien välineiden kuormitusta. Fuusiomenetelmän heikkoutena on monimutkaisempi

laskentaprosessi. (Zhang ym., 2023) Esimerkkinä Liu ym. (2023) keräsivät akusta sensoridataa, joka suodatettiin ensin Gauss-suodattimella (engl. Gaussian filter) ja tämän jälkeen suodatettua dataa käytettiin neuroverkon syötteenä. Tuloksena oli akun kuntoarvio. Menetelmää kokeiltiin kahdella eri litiumakulla ja kuntoarvion virheprosentti oli lopulta vain noin 1,5 prosenttia.

Myös Sharma ym. (2023) hyödynsivät pitkäkestoista lyhytkestomuistia akun kunnon arviointiin, jossa neuroverkko koulutettiin akusta kerätyllä datalla sekä lataus- ja purkamissykleillä. Menetelmää kokeiltiin ilman optimointialgoritmia sekä optimointialgoritmin kanssa. Optimointialgoritmin avulla voitiin akun kunnan heikkenemistä ennustaa hyvin tarkasti.

Näiden tulosten perusteella on hyvä ottaa huomioon, että useimpien menetelmien kohdalla opetusdatan määrä ja tarkkuus ovat ratkaisevia tekijöitä tulosten tarkkuudessa. Esimerkiksi akun hallintajärjestelmän sensorien tarkkuus voi vaikuttaa opetusdatan tarkkuuteen, jonka myötä myös koneoppimismenetelmien tuloksiin. Tutkimustulosten yleistettävyydessä on hyvä huomioida, että nämä tutkimukset ja tulokset ovat pääosin toteutettu litiumakuilla. Esitettyjen menetelmien mahdollinen käyttökelpoisuus muille akkutyypeille vaatii jatkotutkimuksia.

### 3.3 Toimintamatka-arvio

Sähköauton tehokkaan käytön kannalta on tärkeää, että sen toimintamatka-arvio (engl. range estimation) on realistinen. Tarkka tieto jäljellä olevista kilometreistä ennen lataustarvetta auttaa kuljettajaa etenkin pidemmällä matkoilla suunnittelemaan tarvittavat pysähdykset. Suunnittelun tärkeys korostuu varsinkin, jos matkan varrella on vain muutamia latausasemia.

Toimintamatkan arviointi on yksi tärkeimpiä tutkimuskohteita sähköautoilussa. Tavanomaiset menetelmät johtavat usein epätarkkoihin toimintamatka-arvioihin, sillä auton kulutukseen vaikuttaa useat eri tekijät. Lisälaitteiden käyttö (mm. valot, radio), ajotyyli, tien kaltevuus, auton kuorma ja renkaiden paineet vaikuttavat kaikki kulutukseen. Esimerkkinä autovalmistaja Teslan Model S arvioi jäljellä olevaa toimintamatkaa aikaisempien ajokilometrien energiankulutuksen perusteella, mutta arviossa ei oteta huomioon mahdollisia muuttuvia ajo-olosuhteita tai ajotapoja. (Ahmed ym., 2021)

Perinteisistä toimintamatka-arvioon käytetyistä menetelmistä poiketen tekoälyn avulla voidaan tarkemmin seurata ja analysoida ajonaikaisia tapahtumia ja niiden vaikutusta toimintamatkaan (Ahmed ym., 2021). Tekoälyalgoritmeja voidaan käyttää ajo-olosuhteiden ennustamiseen aikaisempien ja nykyisten tietojen perusteella. Toimintamatkan arviointiin hyödynnettäviä menetelmiä ovat esimerkiksi moninkertainen lineaarinen regressio (engl. multiple linear regression) sekä neuroverkot. (Zhao ym., 2020)

Toimintamatka-arvion tekemisessä tulee huomioida ennakoitu energian kulutus sekä akun sen hetkinen varaustaso. Zhao ym. (2020) käyttivät kahta ohjattua koneoppimismenetelmää, äärimmäistä gradientin tehostus regressiopuuta (engl. extreme gradient boosting regression tree, XGBoost) ja kevyttä gradientin tehostus regressiopuuta (engl. light gradient boosting regression tree, LightGBM) toimintamatka-arvion muodostamisessa. Edellä mainitut algoritmit koulutettiin akun sekä sähkömoottorin parametreilla ja ajotiedoilla. Nämä menetelmät asettavat koulutusdataan päätöspuita ja muodostavat ennusteen näiden päätöspuiden perusteella. Lopputuloksena näiden menetelmien avulla toimintamatka-arvio voitiin tehdä 0.8 kilometrin virhemarginaalilla.

Edellä mainitussa tutkimuksessa Zhao ym. (2020) myös vertailivat eri koneoppimisalgoritmeja toimintamatkan arvioinnissa. Vertailussa mukana olivat regressiopuiden lisäksi monikerroksinen perseptroniverkko (engl. multilayer perceptron), satunnaismetsä sekä lineaarinen regressioanalyysi. Näistä menetelmistä toimintamatkan arvioinnissa pienimmät virheprosentit olivat aikaisemmin mainituilla regressiopuilla.

## 4 Yhteenveto

Polttomoottorilla varustettujen autojen korvaaminen sähköautoilla on uusiutumattomien luonnonvarojen säästämisen sekä hiilidioksidipäästöjen vähentämisen kannalta tärkeää. Sähköautojen yleistyessä haasteisiin, kuten rajalliset kantamat, pitkät latausajat ja akkujen lyhyet käyttöiät, tarvitaan ratkaisuja. Tekoälymenetelmien nopean kehittymisen ansiosta näitä ongelmia voidaan ratkaista.

Tutkielmassa esitettiin koneoppimista ja neuroverkkoja hyödyntäviä menetelmiä, joiden tavoitteina oli sähköautojen akkujen latauksen ja käytön parantaminen. Akun varaustason ja kunnan seuraaminen sekä ennustaminen ovat kriittisiä tehtäviä akun käytön optimoinnin ja elinkaaren selvittämisen kannalta. Varaustason ja kunnan selvittämistä varten tarvitaan sensoritietoa akun parametreista, kuten jännitteestä, sähkövirrasta ja lämpötilasta. Menetelmät, kuten esimerkiksi pitkäkestoinen lyhytkestomuisti, sateenvirtaussyklin laskenta-algoritmi ja Kalman-suodatin osoittautuivat tehokkaiksi menetelmiksi akkujen optimoinnissa.

Tutkimustuloksia tarkasteltaessa tulee ottaa huomioon niiden rajoitteet. Saatavilla oleva algoritmien koulutusdata on kirjallisuuden perusteella usein rajallista ja mahdollisesti myös puutteellista tai virheellistä. Huomioitavaa on myös, että esitettyjen menetelmien soveltuvuudesta muille kuin litiumakuille ei ole varmuutta. Menetelmien yleistettävyys muille akkutyypeille vaatii jatkotutkimuksia.

Sähköautojen tulevaisuus on riippuvainen akkuteknologian kehityksestä. Akkujen valmistusprosessien lisäksi lataukseen ja käytön optimointiin tulee panostaa, jotta sähköautojen käytettävyydet ja käyttöiät vastaavat niille asetettuihin vaatimuksiin. Sähköautokanta tulee todennäköisesti kasvamaan lähivuosien aikana, joka on tärkeää, kun tavoitellaan ympäristöystävällisempää tieliikennettä.



# Lähdeluettelo

- Abdullah, H. M., Gastli, A., & Ben-Brahim, L. (2021). Reinforcement Learning Based EV Charging Management Systems—A Review. *IEEE Access*, *9*, 41506–41531. <https://doi.org/10.1109/access.2021.3064354>
- Ahmed, M., Zheng, Y., Amine, A., Fathiannasab, H., & Chen, Z. (2021). The role of artificial intelligence in the mass adoption of electric vehicles. *Joule*, *5*, 2296–2322. <https://doi.org/10.1016/j.joule.2021.07.012>
- Dewalkar, S. G., & Nangrani, S. (2021). State of Charge Estimation System for Electric Vehicle Batteries using ANN. *2021 International Conference on Computational Intelligence and Computing Applications (ICCICA)*, 1–7. <https://doi.org/10.1109/iccica52458.2021.9697203>
- Diao, X., Jiang, L., Gao, T., Zhang, L., Zhang, J., Wang, L., & Wu, Q. (2023). Research on Electric Vehicle Charging Safety Warning Based on A-LSTM Algorithm. *IEEE Access*, *11*, 55081–55093. <https://doi.org/10.1109/access.2023.3281552>
- Ghalkhani, M., & Habibi, S. (2022). Review of the Li-Ion Battery, Thermal Management, and AI-Based Battery Management System for EV Application. *Energies*, *16*, 185. <https://doi.org/10.3390/en16010185>
- Hu, Y., & Liu, H. (2022). Design and Application of Power Lithium-Ion Battery Management System: from the Perspective of System Optimization. *2022*

- Second International Conference on Artificial Intelligence and Smart Energy (ICAIS)*, 1579–1582. <https://doi.org/10.1109/icaais53314.2022.9742747>
- Imran, R. M., Li, Q., & Flaih, F. M. F. (2020). An Enhanced Lithium-Ion Battery Model for Estimating the State of Charge and Degraded Capacity Using an Optimized Extended Kalman Filter. *IEEE Access*, 8, 208322–208336. <https://doi.org/10.1109/access.2020.3038477>
- Li, S., He, H., Li, J., Yin, P., & Wang, H. (2019). Machine learning algorithm based battery modeling and management method: A Cyber-Physical System perspective. *2019 3rd Conference on Vehicle Control and Intelligence (CVCI)*, 1–4. <https://doi.org/10.1109/cvci47823.2019.8951635>
- Li, S., Zhao, P., Gu, C., Li, J., Cheng, S., & Xu, M. (2023). Battery Protective Electric Vehicle Charging Management in Renewable Energy System. *IEEE Transactions on Industrial Informatics*, 19, 1312–1321. <https://doi.org/10.1109/tii.2022.3184398>
- Liu, K., Wei, Z., Zhang, C., Shang, Y., Teodorescu, R., & Han, Q.-L. (2022). Towards Long Lifetime Battery: AI-Based Manufacturing and Management. *IEEE/CAA Journal of Automatica Sinica*, 9, 1139–1165. <https://doi.org/10.1109/jas.2022.105599>
- Liu, Y., Yu, H., Guo, X., Li, Q., & Wei, Z. (2023). Multi-feature Extraction and Fusion-based State of Health Estimation of Large-format Lithium-ion Batteries under Uncertain Aging Mode. *2023 IEEE Transportation Electrification Conference amp; Expo (ITEC)*, 1–4. <https://doi.org/10.1109/itec55900.2023.10186912>
- Mijwel, M. (2021). Artificial Neural Networks Advantages and Disadvantages. *Mesopotamian Journal of Big Data*, 2021, 29–31. <https://doi.org/10.58496/mjbd/2021/006>

- Oji, T., Zhou, Y., Ci, S., Kang, F., Chen, X., & Liu, X. (2021). Data-Driven Methods for Battery SOH Estimation: Survey and a Critical Analysis. *IEEE Access*, *9*, 126903–126916. <https://doi.org/10.1109/access.2021.3111927>
- Sharma, R., Bala, A., Singh, A., & Singh, M. (2023). State of Health Estimation for Li-Ion Battery Using Machine Learning. *2023 IEEE International Conference on Metrology for eXtended Reality, Artificial Intelligence and Neural Engineering (MetroXRINE)*, 406–411. <https://doi.org/10.1109/metroxraine58569.2023.10405658>
- Sundararaju, K., Jagadeesh, S., Madhumithra, N., & Manikandan, K. (2023). Machine Learning Based SoC Estimation For Lithium-Ion Battery In Electric Vehicle. *2023 9th International Conference on Electrical Energy Systems (ICEES)*, 85–88. <https://doi.org/10.1109/icees57979.2023.10110259>
- Umathe, S., & Hiware, R. (2022). Artificial Intelligence and IoT based Smart Battery Management System for Electric Vehicle. *2022 International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON)*, 1–7. <https://doi.org/10.1109/smartgencon56628.2022.10083768>
- Xu, M., Wang, R., Zhao, P., & Wang, X. (2019). Fast charging optimization for lithium-ion batteries based on dynamic programming algorithm and electrochemical-thermal-capacity fade coupled model. *Journal of Power Sources*, *438*, 227015. <https://doi.org/10.1016/j.jpowsour.2019.227015>
- Zhang, X., Zhang, X., & Zhang, W. (2023). Current Status of Research on Factors Causing Lithium-ion Battery Packs Performance Degradation and their State of Health Estimation. *2023 5th International Conference on Power and Energy Technology (ICPET)*, 306–311. <https://doi.org/10.1109/icpet59380.2023.10367695>

---

Zhao, L., Yao, W., Wang, Y., & Hu, J. (2020). Machine Learning-Based Method for Remaining Range Prediction of Electric Vehicles. *IEEE Access*, 8, 212423–212441. <https://doi.org/10.1109/access.2020.3039815>