

**ESCUELA POLITÉCNICA SUPERIOR DE MONDRAGON
UNIBERTSITATEA**
MONDRAGON UNIBERTSITATEKO GOI ESKOLA POLITEKNIKOA

Trabajo fin de máster presentado para la obtención del título de
Titulua eskuratzeko master bukaerako lana

MÁSTER UNIVERSITARIO EN INGENIERÍA INDUSTRIAL
INDUSTRIA INGENIARITZAKO UNIBERTSITATE MASTERRA

Título del Trabajo *Lanaren izenburua*

**LI-IOI BATERIEN DEGRADAZIO-EREDUEN GARAPENA,
TRANSFERENTZIA BIDEZKO IKASKUNTZA-METODOEN BIDEZ**

Autor *Egilea*

MARKEL AZKUE ETXEANDIA

Curso *Ikasturtea*

2019/2020

Título del Trabajo *Lanaren izenburua*

**LI-IOI BATERIEN DEGRADAZIO-EREDUEN GARAPENA,
TRANSFERENTZIA BIDEZKO IKASKUNTZA-METODOEN
BIDEZ**

Nombre y apellidos del autor

Egilearen izen-abizenak

AZKUE ETXEANDIA, MARKEL

Nombre y apellidos del/los director/es del trabajo

Zuzendariaren/zuzendarien izen-abizenak

LUCU, MATTIN

AIZPURU, IOSU

Lugar donde se realiza el trabajo

Lana egin deneko lekua

IKERLAN, S.COOP.

Curso académico

Ikasturtea

2019/2020



El autor/la autora del Trabajo Fin de Máster, autoriza a la Escuela Politécnica Superior de Mondragón Unibertsitatea, con carácter gratuito y con fines exclusivamente de investigación y docencia, los derechos de reproducción y comunicación pública de este documento siempre que: se cite el autor/la autora original, el uso que se haga de la obra no sea comercial y no se cree una obra derivada a partir del original.

Master Bukaerako Lanaren egileak, baimena ematen dio Mondragon Unibertsitateko Goi Eskola Politeknikoari Master Bukaerako Lanari jendeaurrean zabalkunde emateko eta erreproduzitzeko; soilik ikerketan eta hezkuntzan erabiltzeko eta doakoa izateko baldintzarekin. Baimendutako erabilera honetan, egilea nor den azaldu beharko da beti, eragotzita egongo da erabilera komertziala baita lan originaletatik lan berriak eratortzea ere.

LABURPENA

Li-ioi bateriak garestiak dira eta degradatu egiten dira; hori dela eta, degradazio-eredu bat sortu beharra dago, bateriek xede-aplikazioan zer portaera izango duten eta zenbat iraungo duten simulatzeko. Ereduok sortzeko, bateriak hainbat baldintzatan frogatu behar dira laborategian. Frogok garestiak dira eta denbora luze hartzen dute; hortaz, laborategiko frogak gutxiago egin behar izateko metodo bat bilatu beharra dago. Horretarako, lan honetan, adimen artifizialeko algoritmoak erabiltzea proposatzen da; horien helburua da, bada, baterien degradazioa iragartzea. Behar den entsegu kopurua murrizteko transferentzia bidezko ikaskuntza-teknika erabiltzea proposatzen da. Horren bidez, sare neuronal batek jatorri-ataza batean ikasitakoa erabil dezake xede-atazako helburuak hobetzeko. Horretarako, bi Li-ioi kimikaren datu multzoak erabili dira: NMC eta LFP. Lehenengoa sare neuronala jatorri-atazan entrenatzeko erabili da. Ondoren, sare neuronal hori erabili ahal izan da, transferentzia bidezko ikaskuntza aplikatuta, bigarren Li-ioi bigarren kimikaren degradazioa iragartzeko, bigarren datu multzoko datu gutxi batzuk baliatuta. Hartara, nabarmen txikitu da LFP baterietarako degradazio-eredua garatzeko kostua. Proposatutako metodoa Li-ioi baterietarako degradazio-eredu unibertsalak garatzeko lehen urratsa da, hautatutako kimika gorabehera. Beraz, memoria honetan aurkeztutako ikerketa-lanak interes teknologikoa ez ezik, interes ekonomikoa ere badu, eta energia-biltegitzearen mendeko industria-esfera osoaren egungo eta erorkizuneko erronkei erantzuten die.

ABSTRACT

The cost and degradation of Li-ion batteries make necessary to develop degradation models that simulate how the batteries will behave and how long they will last in the target application. To develop such models, it is necessary to test the batteries in different operating conditions in a laboratory environment. Such tests are time and cost-intensive. Therefore, it is necessary to find a method which allows minimizing laboratory tests. In this work, artificial intelligence algorithms are used to predicting the degradation of batteries. With the purpose of minimizing the necessary number of tests, transfer learning techniques are used, which allow a neural network to use the knowledge acquired in a source task to improve the results in the target task. For this purpose, two data sets from two different chemistries of Li-ion, NMC and LFP, will be used. The first one will be used to train the neural network in the source task. Then, to be able to predict the degradation of the second Li-ion chemistry, transfer learning technique will be applied, retraining the neural network using a few data from the second data set. This way, it is possible to significantly reduce the development cost of the degradation model for LFP batteries. The proposed method represents the first step towards the development of universal degradation models for Li-ion batteries, independent of the selected chemistry. Therefore, the research work presented in this report has not only a technological but also an economic interest, and responds to the current and future challenges of the entire industrial sphere dependent on energy storage.

RESUMEN

El costo y la degradación de las baterías de Li-ion hacen que sea necesario crear un modelo de degradación que simule cómo se comportarán y cuánto durarán las baterías en la aplicación de destino. Para crear dichos modelos es necesario testear las baterías en diversas condiciones en un laboratorio. Esas pruebas son costosas y requieren mucho tiempo, por lo que se ve necesario buscar un método que permita minimizar los ensayos de laboratorio. Para ello, en este trabajo se propone utilizar algoritmos de inteligencia artificial, orientados a predecir la degradación de las baterías. Con el objetivo de minimizar el número necesario de ensayos, se propone utilizar la técnica del aprendizaje por transferencia, que permite que una red neuronal utilice el conocimiento adquirido en una tarea de origen para mejorar los resultados en la tarea objetivo. Con ese fin, se han utilizado dos sets de datos de dos químicas diferentes de Li-ion, NMC y LFP. La primera es la que se ha empleado para entrenar la red neuronal en la tarea de origen, para después poder utilizar esa red neuronal aplicando el aprendizaje por transferencia y así poder predecir la degradación de la segunda química de Li-ion utilizando unos pocos datos del segundo set. De este modo, se consigue reducir de forma significativa el coste de desarrollo del modelo de degradación para baterías LFP. El método propuesto representa el primer paso hacia el desarrollo de modelos de degradación universales para baterías de Li-ion, independientemente de la química seleccionada. Por lo tanto, el trabajo de investigación presentado en esta memoria no solo tiene un interés tecnológico, sino también económico, y responde a los retos actuales y futuros de toda la esfera industrial dependiente del almacenamiento de la energía.

AURKIBIDEA

1. SARRERA	1
1.1 PROIEKTUAREN HELBURUAK ETA PLANGINTZA	2
1.2 BALDINTZEN PLEGUA	3
2. EGUNGO EGOERA	4
2.1 LI-IOI BATERIAK	4
2.1.1 Erabilerak	4
2.1.2 Funtzionamendua eta osagai nagusiak	5
2.1.3 Degradazio-mekanismoak	8
2.2 IKASKUNTZA AUTOMATIKOA, TRANSFERENTZIA BIDEZKO IKASKUNTZA ETA SARE NEURONALAK	10
2.2.1 Ikaskuntza automatikoa: gainbegirada bat	11
2.2.2 Transferentzia bidezko ikaskuntza	15
2.2.3 Sare neuronala eta ikaskuntza sakona	22
2.3 ONDORIOAK	25
3. SARE NEURONALEN EZAUGARRIAK	26
3.1 DATUEN PRESTAKETA	26
3.2 AURRERAELIKADURAKO SARE SAKONA	27
3.2.1 Atzeranzko hedapena	27
3.2.2 Gradiente-jaitsiera	28
3.2.3 Gaindoitzea eta azpidoitzea	30
3.2.4 Erregularizazioa	31
3.2.5 Unitate ezkutuak	33
3.3 SARE NEURONALA ENTRENATZEA: EMAN BEHARREKO URRATSAK	34
4. DEGRADAZIO-EREDUEN GARAPENA ETA TRANSFERENTZIA BIDEZKO IKASKUNTZA	35
4.1 ERABILITAKO DATUAK	35
4.2 NMC EREDUA	39

4.2.1 Dimentsionatzea	40
4.2.2 Erregularizazioa	42
4.2.3 NMC ereduaren emaitzak	46
4.3 LFP EREDUA	49
4.3.1 Erregularizazioa	49
4.3.2 Erreferentziazko LFP ereduaren garapena	51
4.4 TRANSFERENTZIA BIDEZKO IKASKUNTZA.....	55
4.4.1 NMC eredu transferentzia bidezko ikaskuntza gabe.....	56
4.4.2 NMC ereduari transferentzia bidezko ikaskuntza aplikatuta.....	56
4.4.3 Transferentzia bidezko ikaskuntza aplikatzea LFP eredu hobetzeko	57
5. ONDORIOAK	63
6. ETORKIZUNERAKO ILDOAK	65
7. MEMORIA EKONOMIKOA	67
8. PRAKTIKEN ETA MBL-AREN BALORAZIOA PERTSONALA	68
9. BIBLIOGRAFIA	69

Irudien aurkibidea

Irudia 1. Li-ioi bateriaren degradazio-mekanismoak [14]	8
Irudia 2. Ikaskuntza automatiko motak eta bakoitzaren aplikazio-eremuen adibideak [27]	11
Irudia 3. Gainbegiratutako ikaskuntza-eredua (a) Sailkapena eta (b) Erregresioa	13
Irudia 4. Gainbegiratu gabeko ikaskuntza-eredua. Taldekatzea	14
Irudia 5. Ikaskuntza indartua.....	15
Irudia 6. Ikaskuntza-prozesuak (a) makina tradizionala eta (b) transferentzia bidezko ikaskuntza.....	16
Irudia 7. Ataza anitzeko ikaskuntza	17
Irudia 8. Transferentzia-konfigurazioen ikuspegi orokorra [45].....	20
Irudia 9. Sare neuronalaren funtzionamendua.....	22
Irudia 10. Hiru sarrera jasotzen dituen nodoa	23
Irudia 11. Egitura nodo-geruzatan, sare ez oso sakon batean	23
Irudia 12. Geruza bakarreko sare neuronala vs. sare neuronal sakona.....	24
Irudia 13. Gradiente-jaitsiera.....	28
Irudia 14. Azpidoitzea, doiketa zuzena eta gaindoitzea.....	30
Irudia 15. NMC zelulen degradazio-kurbak.....	36
Irudia 16. LFP zelulen degradazio-kurbak	38
Irudia 17. NMC zelulen ΔQ errorea sarearen tamainaren arabera	41
Irudia 18. NMC zelulen Q errorea sarearen tamainaren arabera	42
Irudia 19. Entrenamendu ezberdinen emaitzen aldakortasuna sarearen tamainaren arabera	43
Irudia 20. Gaindoiketa duen sare neuronala	44
Irudia 21. NMC ereduaren errorea, erregularizazioa 0tik 0,3ra 0,01eko igoerarekin	45
Irudia 22. NMC ereduaren errorea, erregularizazioa 0,02tik 0,07ra 0,001eko igoerarekin	46
Irudia 23. NMC zelulen degradazio-kurbaren iragarpena.....	47
Irudia 24. Behin betiko NMC ereduaren	48
Irudia 25. LFP ereduaren errorea, erregularizazioa 0tik 0,3ra 0,01eko igoerarekin	49
Irudia 26. LFP ereduaren errorea, erregularizazioa 0tik 0,05ra 0,001eko igoerarekin.....	50
Irudia 27. LFP ereduaren ΔQ errorea zelulako, entrenamendu-datu ezberdinekin.....	52
Irudia 28. LFP ereduaren Q errorea zelulako, entrenamendu-datu ezberdinekin.....	53
Irudia 29. LFP degradazio-azalera SOH ezberdinetan	54
Irudia 30. LFP ereduaren degradazio-kurbaren iragarpena	55
Irudia 31. NMC ereduak LFP zelulen degradazioa iragartzean lortutako errorea.....	56
Irudia 32. Transferentzia bidezko ikaskuntza-ereduaren Q errorea zelulako, entrenamendu-datu ezberdinekin	57
Irudia 33. Behin betiko LFP ereduaren vs 2 zelularekin entrenatutako LFP ereduaren vs 2 zelularekin entrenatutako IT ereduaren	58
Irudia 34. Behin betiko LFP ereduaren vs 2 zelulekin entrenatutako IT ereduaren vs 5 zelularekin entrenatutako IT ereduaren.....	60
Irudia 35. Transferentzia bidezko ikaskuntza erabiliz ereduaren degradazio-azalera % 99 SOHan.....	61
Irudia 36. IT ereduaren degradazio-kurbaren iragarpenak	62

Taulen aurkibidea

Taula 1. Li-ioi baterien degradazioa: kausak, ondorioak eta inpaktuak [14].....	10
Taula 2. Ikaskuntza-ikuspegiak transferitzea	19
Taula 3. Hainbat inguruetan erabilitako ikuspegiak	22
Taula 4. NMC zelulak frogatu diren baldintzak	35
Taula 5. LFP zelulak frogatu diren baldintzak.....	37
Taula 6. Datu-basearen zatiketa	40
Taula 7. NMC ereduaren errorea.....	48
Taula 8. LFP zelulen izendapena.....	51
Taula 9. LFP ereduaren errorea.....	54
Taula 10. Behin betiko LFP ereduaren vs 2 zelularekin entrenatutako LFP ereduaren vs 2 zelularekin entrenatutako IT ereduaren erroreen alderaketa	59
Taula 11. 2 zelularekin entrenatutako IT ereduaren eta 5 zelularekin entrenatutako IT ereduaren erroreen alderaketa.....	60

Terminoen zerrenda

EU	ES	EN
Azpidoitze	Subajuste	Underfitting
Bereizgailu	Separador	Separator
Degradazio	Degradación	Aging
Degradazio kimikoko mekanismo	Mecanismo de degradación química	Chemical aging mechanism
Degradazio-eredu	Modelo de degradación	Aging model
Degradazio-kurba	Curva de degradación	Aging curve
Degradazio-mekanismo	Mecanismo de degradación	Aging mechanism
Deskarga-prozesu	Proceso de descarga	Discharge process
Dimentsionatze	Dimensionamiento	Dimensioning
Doitze	Ajuste	Fitting
Elektrolito	Electrolito	Electrolyte
Erdigainbegiraturako transferentzia bidezko ikaskuntza	Aprendizaje por transferencia semisupervisado	Semi-supervised transfer learning
Erregresio	Regresión	Regression
Erregularizazio	Regularización	Regularization
Gainbegiratu gabeko transferentzia bidezko ikaskuntza	Aprendizaje por transferencia no supervisado	Unsupervised transfer learning
Gainbegiraturako transferentzia bidezko ikaskuntza	Aprendizaje por transferencia supervisado	Supervised transfer learning
Gaindoitze	Sobreajuste	Overfitting
Galera-funtzio	Función de pérdida	Loss function
Geruza ezkutua	Capa oculta	Hidden layer
Gradiente	Gradiente	Gradient
Gradiente-jaitsiera	Descenso de gradiente	Gradient descent

EU	ES	EN
Ikaskuntza automatiko	Aprendizaje automático	Machine learning
Iragarri	Predecir	Predict
Irteerako geruza	Capa de salida	Output layer
Jatorri-ataza	Tarea de origen	Source task
Jatorri-eremu	Campo de origen	Source domain
Karga-prozesu	Proceso de carga	Charge process
Katodo	Cátodo	Cathode
Korrante-kolektore	Colector de corriente	Current collector
Li-ioi bateria	Batería de Li-ion	Li-ion battery
Neurona	Neurona	Neuron
Nodo	Nodo	Node
Pisu	Peso	Weight
Sare neuronal	Red neuronal	Neural network
Sarrerako geruza	Capa de entrada	Input layer
Transferentzia bidezko ikaskuntza	Aprendizaje por transferencia	Transfer learning
Transferentzia bidezko ikaskuntza inductibo	Aprendizaje por transferencia inductivo	Inductive transfer learning
Transferentzia bidezko ikaskuntza transduktibo	Aprendizaje por transferencia transductivo	Transductive transfer learning
Xede-ataza	Tarea de destino	Target task
Xede-eremu	Campo de destino	Target domain

1. SARRERA

Egun, Li-ioi bateriak gero eta gehiago erabiltzen ari dira hainbat aplikaziotan. Bateria horiek hainbat abantaila dituzte (energia espezifikoa, potentzia eta balio-bizitza, kasu), eta, abantaila horiek direla-eta, teknologia aproposa dira ibilgailu elektrikoetan, energia berriztagarrietan, eta abarretan erabiltzeko.

Bateria horiek abantaila ugari eskaintzen dituzte, baina haien kostua garesti samarra da oraindik ere, eta, beste bateria batzuk baino gutxiago degradatzen diren arren, zahartu ere zahartzen dira.

Hori dela eta, bateria horiek hainbat aplikaziotan duten errentagarritasuna bermatzeko, beren degradazioa iragarri beharra dago. Helburu hori lortzeko, degradazio-ereduak sortu behar dira bateria horiek aukera onena diren ala ez jakiteko.

Degradazio-eredu horiek duten arazo nagusia hau da: ereduok sortzeko test-kanpaina handiak egin behar dira laborategietan, eta horrek denbora asko eta kostu handia dakartza. Gainera, test horiek errepikatu egin behar dira zelula berri bat modelatu nahi den bakoitzean, zelulak erakusten duen degradazioa desberdina izan daitekeelako.

Bien bitartean, adimen artifiziala gero eta protagonismo handiagoa lortzen ari da hainbat arlotan. Adimen artifizialak orain arte izan diren arazoei perspektiba berriak emateko aukera ematen du, bai eta arazoak bestela ulertzeko ere.

Testuinguru horretan, adimen artifizialaren arloan erabiltzen den transferentzia bidezko ikasketa-teknika baliatzeak buelta bat eman diezaioke aurretik aipatutako test-kanpainen arazoari. Izan ere, teknika horrek bateria bat modelatzeko behar diren datuak murrizteko aukera eman dezake, eta, horrela, laborategiko test gutxiago beharko dira.

Hala, lan honetan transferentzia bidezko ikasketa erabiliz Li-ioi baterien bi kimika ezberdinen degradazioa iragarriko duen eredu bat osatuko da. Horretarako, lana zenbait ataletan banatu da.

Bigarren atalean egungo egoeraren azterketa egingo da. Hirugarren atalean, sare neuronalen ezaugarri nagusiak ikusiko dira. Jarraian, laugarren atalean, NMC eta LFP kimikako zelulen degradazio-ereduen garapena eta transferentzia bidezko ikaskuntzaren aplikazioa azalduko dira, eta lortutako emaitzen eta emandako urratsen berri emango da. Bosgarren atalean, lan honetan ateratako ondorio nagusiak azalduko dira. Seigarren atalean, lan honi jarraipena emateko urrats posibleak edo etorkizunerako ildoak adieraziko dira. Zazpigarren atalean, proiektuaren memoria ekonomikoa azalduko da, eta, azkenik, zortzigarren atalean, praktiken eta master bukaerako lanaren balorazio pertsonala egingo da.

1.1 Proiektuaren helburuak eta plangintza

Aurretik aipatu den bezala, lan honen helburu nagusia da degradazio-ereduak garatzeko kostua eta denbora murriztea. Horretarako, adimen artifizialeko algoritmo bat ezarri nahi da; horrek, iraganean sortutako kimika desberdinetako degradazio-datuetan oinarrituta eta baterien kimika batetik bestera egon daitezkeen antzekotasunak baliatuta, kimika berri baten degradazioa aurreikus dezake.

Helburu nagusi hori betetzeko bigarren mailako helburu hauek bete beharko dira ere:

- Adimen artifizialaren mota ezberdinen egungo egoera aztertu eta kasu honetarako mota optimoa ateratzea.
- Bigarren kimikarako lortutako eredia hobetuko duen algoritmo bat sortzea. Horretarako, lehendabizi, lehen kimika motarekin entrenatuko da algoritmoa, eta eredu bat sortu. Ondoren, gauza bera egingo da bigarren kimikarako.

Aipatutako helburuak lortzeko, fase hauek bete dira:

Azaroa-urtarrila. Adimen artifizialaren egungo egoera aztertu da. Hasiera batean azterketa orokorra egin da, eta, gutxika, azterketa horretan egokiena zen algoritmoan sakondu da. Bestalde, Li-ioi baterien inguruko informazio orokorra bilatu da.

Otsaila-martxoa. Matlabek sare neuronalak erabiltzeko duen *toolboxa* nola erabiltzen den ikasi da eta NMC (Li-ioi bateria mota, kobalto oxido manganeso nikela erabiltzen duena) eredia eraikitzen hasi da. Prozesu horretan, hainbat froga egin dira hainbat parametro aldatuta. Fase honetan, *toolboxak* dituen aukerak aztertu dira eta horietako batzuk are sakonago frogatu dira. Fase honen bukaeran, behin betiko NMC eredu bat garatu da.

Apirila. LFP (Li-ioi bateria mota, litio ferrofosfatoa erabiltzen duena) baterien datuak bakarrik erabiliz, degradazio-eredu bat garatu da zelula mota hauentzat. Fase honetan, halaber, sarearen parametroak frogatu dira eredu onena lortzeko.

Maiatza. NMC eredutik abiatuta, eredu hori LFP baterien datuekin berrentrenatuta eta transferentzia bidezko ikaskuntza erabilita, aurreko fasean sortutako LFP eredia hobetu da. Eredu onena lortzeko, algoritmoa berrentrenatzeko erabili diren datuekin hainbat froga egin dira.

Ekaina-uztaila. Proiektuaren memoria idatzi da. Bertan, proiektuaren faseetan ikasitakoak azaldu dira, bai eta horietatik ateratako ondorioak ere. Bestalde, lan honek izan ditzakeen etorkizunerako ildoak adierazi dira. Azkenik, enpresa-praktiken balorazioa egin da.

1.2 Baldintzen plegua

Jarraian, proiektuaren beharrak, proiektu honetan espero direnak eta mugak jasotzen dituen baldintzen plegua aurkezten da.

Aurretik aipatu bezala, proiektu honen helburua da LFP baterien degradazio-kurba iragartzeko gai den eredu bat eraikitzea. Horretarako, sare neuronalak eta transferentzia bidezko ikaskuntza erabiliko dira. Eredu hori LFP kimika erabiltzen duen zelula baten degradazio-kurba iragartzeko gai izango da, eredu horri 4 sarrera ematen bazaizkio: SOH, SOC (kargaren egoera), tenperatura eta zelularen degradazioa iragarri nahi den denbora tartea.

Eredu horrek % 1 baino txikiagoa den errorea izatea espero da. Horretarako, lehenik eta behin, NMC zelulen datuekin eredu bat sortu beharko da; transferentzia bidezko ikaskuntza erabiltzeko oinarri izango da hori. Ereduaren fidagarritasuna aztertzeko, eredu hori entrenatzeko erabili ez diren datuak hartuko dira; hau da, eredu horrek ikusi ez dituen datuak.

Aipatutako ereduak garatzeko, Ikerlanek dituen zenbait baliabide erabili beharko dira: software, hardware eta datu mailakoak izango dira baliabideok. Honako hauek dira, hain zuzen:

- Ordenagailua.
- *Matlab + toolboxak*.
- *Microsoft Office*.
- baterien datuak (NMC eta LFP zelulena).

Arestian esan den moduan, sortutako ereduaren errorea % 1 baino txikiagoa izatea espero da. Horretarako, ereduaren emaitzak laborategian lortutako datuekin alderatuko dira, eta iragarpenaren eta zelularen benetako egoeraren arteko errorea kalkulatu.

Proiektua 2019ko azaroan hasi eta 2020ko uztailean bukatu da. Tarte horretan, aipatutako algoritmoa sortu eta balioztatu da. Gainera, proiektuaren memoria idatzi eta aurkeztuko da; egindako frogak eta lortutako emaitzak jasoko ditu, bada.

Enpresako zuzendariarekin bilerak egin dira bi astez behin, proiektua gauzatzeko eta horren jarraipena egiteko; hots, aurrerapenak eta hurrengo urratsak finkatzeko.

2. EGUNGO EGOERA

Atal honetan, Li-ioi bateriak eta ikaskuntza automatikoa izango dira hizpide. Lehenik eta behin, Li-ioi bateria bat zer den eta zer mota dauden ikusiko da, eta bateriei eragiten dieten degradazio-mekanismoak aztertu. Bestalde, ikaskuntza automatikoaren inguruan hitz egingo da: zer den eta zer mota dauden. Jarraian, transferentzia bidezko ikaskuntza jorratuko da, eta, azkenik, sare neuronalak.

2.1 Li-ioi bateriak

Azken aldian, energia biltegitratzeko teknologiak gero eta interes handiagoa erakartzen ari dira, bizkor ari baikara energia berriztagarriko sistemetarako aldaketa egiten mundu mailan. Paradigma-aldaketa horren arrazoi nagusiak hauek dira: erregai fosilen gehiegizko erabilerak eragindako berotze globala, ingurumen-kutsadura, erregai fosilen iturrien agortzea eta energia-segurtasuneko kezkak. Energia-biltegitratzea energia-iturri berriztagarriak eskala handian erabiltzeko funtsezko teknologia bat da; iturri horiek, bada, aldizkakoak dira.

Energia biltegitratzeko teknologien garapena bereziki desafiatzailea da aplikazio mugikorretarako; izan ere, energia grabimetrikoaren eta bolumetrikoaren dentsitate handia lortzea oso garrantzitsua da, plataforma mugikorretan espazio- eta pisu-mugak daudelako [1]. Energia aplikazio mugikorretan biltegitratzeko teknologia garrantzitsuenetako bat bateriak dira. Komertzialki eskuragarri dauden baterien teknologien artean, Li-ioi bateriek energia grabimetriko eta bolumetrikoaren dentsitate handiena dute eta etorkizun oparoa aurreikusten zaie energia biltegitratzeko sistemen artean. Hala ere, berebiziko erronkei aurre egin behar diete, hala nola ziklo mugatuak, kostua eta errendimendu txikia klima bero eta hotzetan. Aurrerapen hori lortzeko, Li-ioi baterien degradazio-mekanismoak hobeto ulertzea beharrezkoa da [2], [3].

Li-ioi bateria baten degradazioa, askotan, gaitasun-galeragatik eta energia-galeragatik agertzen da, eta jatorri kimiko eta mekanikoak izan ditzake. Li-ioi baterien degradazio-mekanismoen izaera interdependentea dela eta, degradazio-mekanismoen azterketa konplexua da, eta, askotan, karakterizazio-teknika berriak *in situ* eta *ex situ* erabili behar dira nanoeskalako degradazio-mekanismoak ebazteko [4].

Degradazio-mekanismoa hobeto ulertzeak zikloaren bizitza erabilgarri luzea ekarriko luke, bai eta material hobetuak garatzea ere, eta degradazioa mugatzeko kontrol-estrategia optimoak identifikatzen lagunduko luke.

2.1.1 Erabilerak

Li-ioi bateriak abantailatsuak dira beste bateria-kimika batzuekin alderatuta, batetik, energia grabimetriko eta bolumetrikoaren dentsitate handia dutelako, eta, bestetik, autodeskarga-tasa txikia dutelako. Ezaugarri horiek direla-eta, Li-ioi bateriak asko erabili dira azken bi hamarkadetan gailu eramangarri txikietan, bai kontsumo-gailu

elektronikoetan, bai gailu medikoetan; tartean, halakoetan: Bluetooth entzungailuak, GPS gailuak, telefono zelularrak, ordenagailu eramangarriak, kamerak, audifonoak eta osasuna monitorizatzeko gailuak.

Gailu eramangarriez gain, aplikazio mugikorretan ere asko erabiltzen dira Li-ioi bateria bateriak, besteak beste, segway garraiatzaile pertsonaletan, scooter elektrikoetan, bizikleta elektrikoetan, ibilgailu elektrikoetan eta hegazkin militar eta komertzialen hainbat sistema elikatzen. Formatu handiko bateria horietako batzuk ohiko zelula komertzialekin fabrikatzen dira. Egun, Li-ioi bateria hegazkingintzan erabili da potentzia osagarriko unitatearen, larrialdiko argiztapen-sistemen, hegaldi-kontrolako elektronikaren eta hegaldi-erregistragailuaren elikadura-iturri independente gisa.

Gaur egun, garraioaren sektorea erregai fosilen menpe dago neurri handi batean, eta hidrokarburoz elikatutako barne-errekuntzako motorrak berotegi-efektuko gasen isurketen iturri nagusietako bat dira [5]. Erregai fosiletan oinarritutako ibilgailuen ordez ibilgailu elektriko hibridoak, ibilgailu elektriko hibrido entxufagarriak eta ibilgailu elektrikoak erabiltzeak berotze globala arintzen lagun dezake eta airearen kutsadura murriztu dezake, bereziki metropoli-eremuetan. Beraz, energia elektrokimikoa biltegitratzeko sistemek, bereziki Li-ioi bateriek, berebiziko garrantzia izan dezakete helburu hori lortzeko.

Aplikazio mugikorretan ez ezik, Li-ioi bateriak sareko biltegitratze egonkorreko aplikazioetan ere ezartzea oso interesgarria da. Azken horietan, bada, ziklo handiko bizitza erabilgarria eskatzen da.

2.1.2 Funtzionamendua eta osagai nagusiak

Li-ioi bateria honako osagai nagusi hauek osatzen dute: anodoa, katodoa, bereizgailua eta elektrolitoa. Li-ioi bateriek bi elektrodo dituzte (hau da, katodoa eta anodoa), eta potentzial kimikoak ezberdinak dira. Potentzial kimikoaren ezberdintasun horrek zelularen zirkuitu irekiko tentsioa zehazten du. Bereizgailua Li-ioi bateria baten osagai ez-aktibo bat da, eta bi elektrodoen arteko kontaktu fisikoa saihesten du, elektroien bidea oztopatuz, eroaleak ez diren materialez osatua baitago.

Elektrolitoak litio-ioiak elektrodoen artean hedatzea ahalbidetzen du karga- eta deskarga-zikloetan. Kanpo-zirkuitu batek bi elektrodoak elektronikoki konektatzen dituenean, elektroiak anodotik katodora transferitzen dira, eta horrek potentzial-diferentzia orekatua izatea eragiten du. Elektrolitoak, gainera, Li-ioi positiboak garraiatzen ditu norabide berean. Zelulan biltegitratutako energia kimikoa elektrizitate bihurtzen da kanpoko zirkuituan. Prozesu hori itzulgarria da; alegia, litio ioien zelulak berriz kargatu daitezke, eta, beraz, energia elektrikoa energia kimiko bihurtzen da berriro ere.

Anodo, katodo, elektrolito eta bereizgailuaren elkarrekintzak zehazten ditu zelularen errendimendua, potentzia eta gaitasun energetikoa, zikloaren bizitza

erabilgarria, segurtasun-portaera eta funtzionamendu-tenperaturak. Hurrengo ataletan, zehatzago aurkeztuko dira osagai horiek.

2.1.2.1 Anodoa

Li-ioi bateria baten elektrodo negatiboak (anodoa) kobrezko korrante-kolektorean geruza mehe batean estalitako litio konposatu bat osatzen du. Material aktiboen estaldura uniforme eta mehe bat behar da elektrolito organikoak erabiltzen dituzten zeluletarako. Beraz, material anodikoak nahasteko eta estaltzeko prozesua nagusiki konpainiari berari dagokio, fabrikazio- eta ekoizpen-prozesuaren aldaketek eragina dutelako azken estalduran, eta eragin larria izan dezaketelako korrante-gaitasunean, gaitasun zelularrean eta, oro har, zelulen degradazio-portaeran. Elektrodoaren estaldura negatiboarekin lotutako akatsek zelularen ihes termikoa eta zelulak huts egitea eragin dezakete.

Litioa material anodiko aproposa izan daiteke Li-ioi baterietarako; hala ere, karga- eta deskarga-prozesuetan litioaren metala hauspeatzearen eta, ondoren, dendritak eratzearen ondorioz, zelulak zirkuitulaburra jasateko arriskua dago. Beraz, Li-ioi baterien anodoetarako, nahiago dira material karbonosoak. Material anodiko erabiliena grafitoa da, hauts itxurakoa eta material aglutinatzailearekin konbinatua. Nolanahi ere, karbonoaren izaera nabarmen alda daiteke grafitoaren iturriaren (sintetikoa edo naturala), partikularen tamainaren, purutasunaren, partikularen formaren, partikularen tamainaren banaketaren, partikulen porositatearen, karbono-kristalinen eta trinkotze mailaren arabera [6].

Silizio, titanato eta germaniozko materialez osatutako anodoak ere aztertu dira, baina gaur egun grafitikoak ez diren elektrodo negatiboak ia ez dira ezartzen [7].

2.1.2.2 Katodoa

Katodoaren ohiko materialek metal oxidoak dituzte geruzatan antolaturik. Litio-ioizko zelula komertzialetan katodorako erabiltzen den materialik ohikoena litio kobalto oxidoa da (LiCoO_2) [8]. Kobaltozko katodoak aukera bikaina dira; izan ere, gaitasun bolumetrikoki handia, bero-ahalmen espezifikoki handia, deskarga-tentsio handia, autodeskarga baxua eta ziklo-errendimendu egokia dute. Hala ere, kobaltoa garestia eta toxikoa denez, katodorako beste material batzuk ere garatzen dira. LiCoO_2 ez diren katodoaren material garrantzitsuenak hauek dira: litio eta manganeso oxidoa (LiMn_2O_4), litio eta burdin fosfata (LiFePO_4) eta oxido metaliko mistoak, kobalto, nikel, aluminio eta manganeso oxidoak barnean hartzen dituztenak. Manganesoz egindako materialak erakargarriak dira, manganesoa merkeagoa delako, eta ez hain toxikoa, erabilitako beste material batzuekin alderatuta. Hala ere, mugak dituzte; izan ere, manganesoak zikloan zehar elektrolitoan disolbatzeko joera du, eta horrek katodoaren zikloaren egonkortasun eta biltegitratze-ahalmen eskasak ematen ditu [9].

Arestian aipatutakoen artean, katodoaren materialik berrienak LiFePO_4 bezalakoak izan dira. Tentsio baxuagoan funtzionatzen dute (ia 3,3 V), baina potentzia

eta energia-dentsitate handiagoa erakusten dute, baita egiturazko egonkortasun egokia ere. Gainera, tamaina nanometrikoko partikulak aprobetxatzeak LiFePO_4 -ren eroankortasun baxuena arindu dezake [10].

2.1.2.3 Elektrolitoa

Elektrolito egoki batek honako ezaugarri nagusi hauek izatea espero da:

- Eroankortasun ioniko ona eta isolamendu elektronikoa izan behar ditu, ioien garraioa hobetzeko eta autodeskarga minimizatzen.
- Elektrokimikoki, geldoa izan behar du elektrodoaren gainazal oxidatzaile edo erreduktorearekin zelulako tentsio operatiboko lehoan.
 - Ezin du bateriaren beste osagaiekin erreakzionatu, adibidez, korrante-kolektorearekin eta bereizgailuarekin.
 - Ingurumenaren aldetik ona izan behar du.

Elektrolitoa litio-gatzek eta disolbatzaile likido batek edo gehiagok osatzen dute. Elektrolitoetarako erabiltzen den gatzik ohikoena litio hexafluorofosfata da (LiPF_6). Li-ioi baterietan gaur egun erabiltzen diren elektrolito ohikoenak uretako ez direnak dira. Gehigarriak direla-eta, SEIa eratu daiteke grafitoan, eta, epe luzean, SEIren eraketaren ondorioz ematen den gaitasun-galera itzulezina gutxitu. Gehigarriek, gainera, LiPF_6 -k disolbatzaile organikoen aurkako egonkortasun termiko handiagoa izatea ahalbidetzen dute, katodoaren disoluzioa murrizten dute eta zelularen propietate elektrolitikoak hobetzen ditute [11].

2.1.2.4 Bereizgailua

Bereizgailua, funtsean, elektrodo positibo eta negatiboen artean jartzen den mintz porotsu bat da. Bereizgailuaren funtzio nagusia katodoa eta anodoa fisikoki bereiztea da. Aldi berean, bereizgailuaren poroek litio-ioiak garraiatzea ahalbidetzen dute karga- zein deskarga-prozesuan.

Bereizgailua hautatzeko orduan, funtsezko zenbait faktore daude. Hauek, hain zuzen:

- Isolamendu elektronikoa ona.
- Ioiak garraiatzeko gutxieneko erresistentzia eta elektrolitoak xurgatzeko eta atxikitzeko gaitasun handia.
 - Gurley-ren balio txikia (airearekiko iragazkortasuna), erresistentzia elektriko txikia eta porositate handia dakarrena.
 - Egonkortasun mekaniko eta dimentsional egokia izatea, baita erresistentzia fisiko egokia ere, honako hauek barne: zulaketaren aurkako erresistentzia, nahasketaren sartzearen aurkako erresistentzia eta trakzioaren aurkako erresistentzia.
 - Uniformetasuna lodieran eta bihurduan.
 - Egonkortasun kimikoa eta elektrodoen, elektrolitoen eta ezpurutasunen errektiboek eragindako degradazioaren aurkako erresistentzia.


- Egonkortasun termikoa.
- Elektrolito tipikoek erraz eta azkar bustitzeko modukoa izatea.
- Katodoaren eta anodoaren artean espezie edo partikula disolbagarriak migratzea eragozteko gaitasun handia.

Duela gutxi arte, oso ikerketa gutxi egin dira bereizgailu berriak garatzeko beste osagai zelular batzuekin alderatuta. Uretako ez den Lito-ioi baterietan gehien erabiltzen diren bereizgailuak poliolefina mikroporotsuak dira [12].

2.1.3 Degradazio-mekanismoak

Degradazioa da sistema baten errendimendua, bizitza erabilgarria eta fidagarritasuna murriztea. Bateriaren degradazioak bere gaitasuna edo energia gutxitzea eragin dezake, baita bere inpedantziak gora egitea ere. Bateriak degradazioari lotuta dauden eta elkarrekin konektatuta dauden hainbat osagaiz osatuta daude; hori dela eta, osagai zelular bat degradazioak, eta, ondoren, errendimendua gutxitzeak eragina du beste osagai batzuen baldintza operatiboetan, eta, horrek, aldi berean, sistemaren degradazio orokorra bizkortuko du. Beraz, gaitasuna gutxitzea eta inpedantzia areagotzea arautzen duten mekanismoak nahiko sofistikuak izan daitezke.

Hurrengo irudian (Irudia 1), degradazio-mekanismo nagusien eta horien interakzioen ikuspegi orokorra irudikatu da, eta Li-ioi baterien degradazioaren konplexutasuna erakusten da. Degradazio-mekanismoak zenbait azpiosagaien arteko elkarrekintzen mende daude: anodo, katodo, aglutinatzaile, elektrolito, bereizle eta korrante-kolektorearen elkarrekintzaren mende, hain zuzen. Degradazio-mekanismoek jatorri mekaniko zein kimikoak izan ditzakete [13].



Irudia 1. Li-ioi bateriaren degradazio-mekanismoak [14]

2.1.3.1 Degradazio kimikoko mekanismoak

Degradazio kimikoko mekanismoak, nagusiki, hauek dira: elektrolitoen deskonposizioa eta erredukzioa, SEIaren eraketa, aglutinatzailearen deskonposizioa, disolbatzaileen tartekatzea, material aktiboaren disoluzioa, gas-askatzea eta litioaren galera. Elektrolitoa potentzial baxuko mailan litiatutako elektrodo negatiboaren bidez murriztu daiteke eta potentzial altuetan katodoan oxidatu. Ezpurutasun elektrolitikoek bigarren mailako erreakzioetarako katalizatzaile gisa funtziona dezakete. Bigarren mailako erreakzioen zinetika, hein handi batean, zelularen tenperaturaren eta tentsioaren arabera da. Ilustrazio gisa, material gehien degradazioa tenperatura altuetan azeleratzen da. Bigarren mailako erreakzio horiek aldaketa batzuk eragiten dituzte elektrodoen materialetan. Elektrodoaren eta elektrolitoaren arteko redox erreakzioak interfaze-geruza eratzen laguntzen du, eta, horrek, berez, zelularen inpedantzia areagotzea eta gaitasuna galtzea eragiten du [15].

Oro har, baterien materialen epe luzeko degradazio kimikoak eragin negatiboa izan dezake errendimendu elektrikoan, zelularen bizitza erabilgarrian eta segurtasunean, honako hauen bidez [16]:

- Erresistentzia elektriko handiagoa edo jarraitutasun elektriko galtzea.
- Material aktiboak erasotzen dieten edo horiek pasibatzen dituzten korrosio-produktuak.
- Material aktiboekin erreakzionatzen duten kutsatzaileekiko esposizioa.
- Elektrolito galera.

2.1.3.2 Degradazio-mekanismo mekanikoak

Bigarren mailako erreakzioak ez dira bateriaren degradazioaren arrazoi bakarra. Litioa sartzeak eta ateratzeak elektrodoen bolumena zabaltzea edo uzurtzea ere eragiten du. Prozesu hori, askotan, ez da homogeneoa izaten [17].

Degradazio mekanikoko mekanismoak, batez ere, bolumen-aldaketei eta, litioaren desinterkalazioaren barruan, anodoaren edo katodoaren material aktiboaren partikuletan sortutako tentsioari dagozkie. Trakzio-ahaleginak zera eragiten du: partikula aktiboak pitzatzea, partikulen artean edo partikulen eta korrante-kolektorearen artean ukipenik ez egotea eta are partikulak isolatzea ere. Gainera, bateria baten zikloak eragindako estresak bereizgailuko poroen egitura aldatzen du eta litio ioien mugikortasun txikiagoa eragiten du. Degradazio kimikoan bezala, degradazioak indartzen du degradazio mekanikoa ere, eta kolokan jartzen ditu katodoaren eta anodoaren egiturak, baita bateriaren bestelako osagaien propietate mekanikoak ere; tartean, elastikotasun-modulua eta katodoaren gogortasuna [18], [19].

Degradazio anodikoak pisu handia du bateriaren degradazio-prozesuan. Hurrengo taulan (Taula 1), degradazio anodikoaren kausen eta ondorioen ikuspegi orokorra ematen da, eta, gainera, degradazioa hobetzen edo arintzen duten faktore nagusiak adierazten dira.

Taula 1. Li-oi baterien degradazioa: kausak, ondorioak eta inpaktuak [14]

Kausa	Efektua	Emaitza	Honela arindua	Zerk egina
Elektrolitoen deskonposizioa eta SElaren eraketa	Inpedantzia areagotzea Litioa galtzea	Gaitasun-galera Potentzia-galera	Sei egonkor (gehigarriak) Denborak abiadura murrizten du,	SOC altua Tenperatura altua
Gasaren bilakaera, disolbatzaileen kointerkalazioa eta partikulen pitzadura	Litioa galtzea Grafitoaren esfoliazioa	Gaitasun-galera	Karbonoaren aurretratamendua Gehigarriak	Gainkarga
SElaren egonkortzearen eta hazkundearen ondorioz sortutako gainazal-eremu murriztua	Inpedantzia areagotzea	Potentzia-galera	Gehigarriak	SOC altua Tenperatura altua
Material aktiboko partikulen bolumena aldatzearen, egonkortzearen eta SElaren hazkundearen ondoriozko porositate-aldaketa	Gainpotenzialak Inpedantzia areagotzea	Potentzia-galera	Gehigarriak Kanpoko presioa	SOC altua Korrante altuak
Material aktiboen bolumena aldatzeak eragindako ukipen-galera	Materialaren galera aktiboa.	Gaitasun-galera	Kanpoko presioa	DOD altua Korrante altuak
Aglutinatzailearen deskonposizioa	Ezegonkortasun mekanikoa Litioa galtzea	Gaitasun-galera	Aglutinatzailearen hautaketa egokia	Tenperatura altua SOC altua
Korrante-kolektorearen korrosioa	Inpedantzia areagotzea Korrantearen banaketa eta potentzial ez homogenea Gainpotenzialak	Potentzia-galera	Korrante-kolektorea behar bezala aukeratzea	SOC baxua Gain-deskarga
Litioa estaltzea eta dendritak sortzea	Litioa galtzea	Gaitasun-galera	Potentzialaren eragiketa-tarte estua	Tenperatura baxua Korrante altuak

2.2 Ikaskuntza automatikoa, transferentzia bidezko ikaskuntza eta sare neuronalak

Ikaskuntza automatikoa informatikaren azpieremu bat da, eta algoritmoak eraikitzeaz arduratzen da. Algoritmo horiek, baliagarriak izateko, fenomenoren baten adibideen bilduma batean oinarritzen dira. Adibideok naturatik etor daitezke, edo gizakiek edo beste algoritmo batek sortuak izan daitezke [20].

Ikaskuntza automatikoa arazo praktiko bat konpontzeko prozesu gisa ere defini daiteke, datu multzo bat bilduz eta datu multzo horretan oinarritutako eredu estatistiko baten eraikuntza algoritmikoa eginez. Eredu estatistiko hori arazo praktiko bat konpontzeko erabiltzen da [21].

Beste modu batera esanda, ikaskuntza automatikoak (aurrerantzean, IA) aukera ematen du sistema batek datuak aztertzeke eta ezagutza ondorioztatzeko. Ikastea edo ezagutza ateratzea baino gehiago da; denboran zehar jasotzen duen esperientzia erabiltzen du algoritmoak duen ezagutza hobetzeko. Funtsean, IAren helburua da behatutako datuetan patroi ezkuak identifikatzea eta ustiatzea. Ikasitako patroiak datu ezezagunak aztertzeke erabiltzen dira. Horrek programazio tradizionalaren paradigma aldatzea eragiten du, programek atazak automatizatzea ahalbidetzen baitute. IAko metodoek datuei egokitzen zaien programa bat sortzen dute; hau da, eredia [22].

IAn egin diren azken aurrerapenen ondorioz, teknika horiek malguak dira mundu errealeko hainbat aplikaziotan erabiltzeko. Adibidez, IAak, medikuntzan izugarri hobetu ditu irudi medikoen eta ordenagailuz lagundutako diagnostikoaren arloak [23].

Komunikazioaren arloan, posta elektronikoa bat jasotzean posta hori spama den edo ez sailkatzeko ere erabiltzen dira IAko ereduak.

Iaren disziplina oso zabala da, baina azterketa honen helburua ez da IAk dituen metodoak azaltzea; aitzitik, xedea da metodo horiek ahalbidetzen dituzten atazak identifikatzea eta aurkeztutako helburua (degradazioaren iragarpena) lortzeko balio dezaketen IAko tresnak identifikatzea.

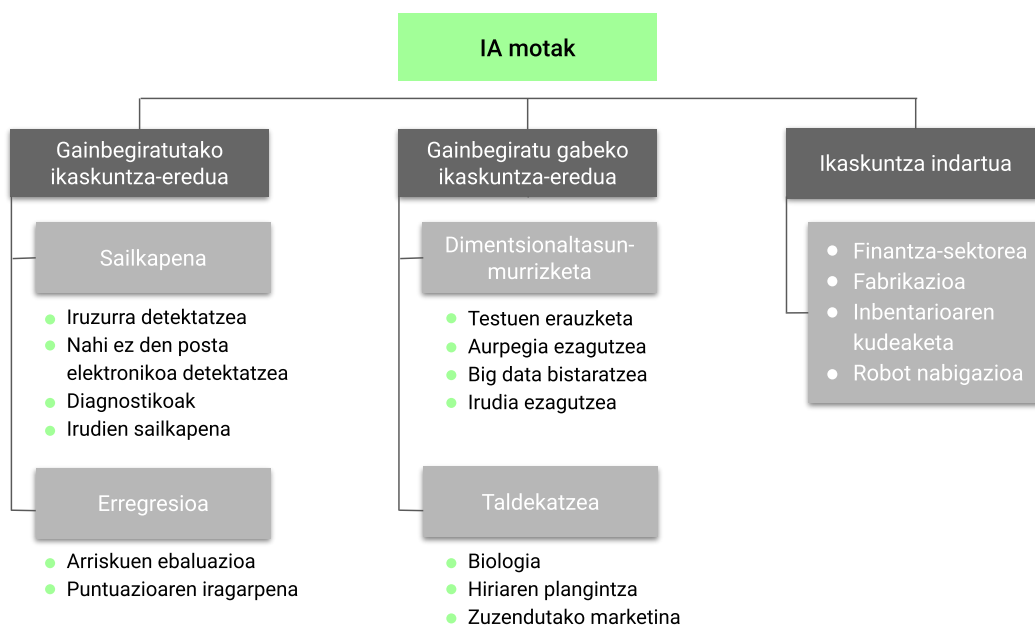
2.2.1 atalean, ikaskuntza automatiko mota ezberdinak azaltzen dira. 2.2.2 atalean, transferentzia bidezko ikaskuntza zer den eta nola aplikatzen den azaltzen da. Azkenik, 2.2.3 atalean sare neuronalak eta ikasketa sakona zer den aurkezten da.

2.2.1 Ikaskuntza automatikoa: gainbegirada bat

Eskura dauden datuen eta helburuaren arabera, algoritmo bat edo beste erabiliko da, eta ikaskuntza-eredu espezifiko bat [24], [25].

Gainbegiraturako ikaskuntza-eredu batean, algoritmoak datu etiketatuen (sarrerako bektore bat irteerako datuekin lotzen duen datu mota) multzo batetik ikasten du, entrenamendu-datuetan oinarrituta erantzun bat ematen du eta modu horretan aurretik behatu gabeko sarrera-bektoreetarako erantzun bat iragartzeko gai da. Gainbegiratu gabeko eredu batean, aldiz, etiketarik gabeko datuak (sarrerako datuak ez daude irteerako datuekin lotuta) erabiltzen dira algoritmoak berez datuetatik ezaugarriak eta patrioiak ateratzen saiatzeko [26].

Hurrengo irudian (Irudia 2), ikaskuntza automatiko moten sailkapena laburbiltzen da.



Irudia 2. Ikaskuntza automatiko motak eta bakoitzaren aplikazio-eremuen adibideak [27]

Erdigainbegiratutako ikaskuntza-eredua erdibidean dago. Etiketatutako datu kopuru txiki bat erabiltzen du, etiketatu gabeko datu multzo handiago bat sendotzen duena. Azkenik, indartze bidezko ikaskuntzak algoritmo bat entrenatzen du sari-sistema batekin, eta atzeraelikadura ematen du agente batek egoera jakin batean ekintzarik onena egiten duenean.

2.2.1.1 Gainbegiratutako ikaskuntza-eredua

Gainbegiratutako ikaskuntza automatikoa ikaskuntza automatiko mota erabilienetako eta arrakastatsuenetako bat da.


Gainbegiratutako ikaskuntza sarrera jakin baten emaitza iragarri nahi denean eta sarrera- eta irteera-pareen adibideak (entrenamendu-datuak) eskuragarri daudenean erabiltzen da. Eredu bat eraikitzen da sarrera-irteera pareetatik abiatuta, entrenamendu-datuak barnean hartzen dituen. Helburua da aurretik inoiz ikusi ez diren datu berrien iragarpen zehatzak egitea.

Gainbegiratutako ikaskuntzak, askotan, giza ahalegina eskatzen du entrenamendu multzoa eraikitzeko, baina, gero, automatizatu eta, askotan, bizkortu egiten du neketsua edo bideraezina izango litzatekeen zeregina.

Gainbegiratutako ikaskuntzak sailkapen-algoritmoak eta erregresio-teknikak erabiltzen ditu eredu prediktiboak garatzeko. Algoritmoen artean hauek daude: erregresio lineala, erregresio logistikoa eta sare neuronalak, erabaki-zuhaitzak, bektore-euskarridun makinak, ausazko basoak, Naive Bayes sailkatzaileak eta K auzokide hurbilenak.


Sailkapenean, helburua klase-etiketa bat iragartzea da, aurrez definitutako aukeren zerranda bateko aukera dena. Sailkapena bi motatakoa izan daiteke: bitarra eta klase anitzekoa. Sailkapen bitarra bi motaren arteko sailkapena da, eta klase anitzeko sailkapena, bi motaren baino gehiagoren artekoa.

Sailkapena



(a)

Erregresioa



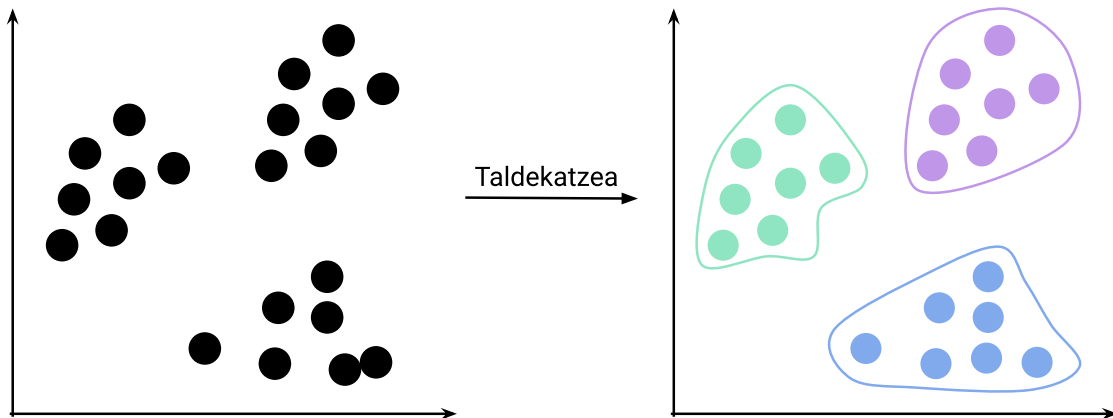
(b)

Irudia 3. Gainbegiraturako ikaskuntza-eredua (a) Sailkapena eta (b) Erregresioa

Erregresio-teknikek erantzun jarraituak iragartzen dituzte. Erregresioa estatistika-prozesu prediktibo bat da, eta eredu mendeko aldagaien eta aldagai independenteen arteko erlazioa kuantifikatzen saiatzen da. Adibidez, eredu batek automobil baten prezioa iragar dezake, ezaugarri multzo bat emanda (kilometro kopurua, adina eta marka, batzuk aipatzearen).

2.2.1.2 Gainbegiratu gabeko ikaskuntza-eredua

Gainbegiratu gabeko ikaskuntza-ereduaren helburua da datuen berezko egitura ezagutzeari, berariaz emandako etiketarik erabili gabe. Etiketarik ematen ez denez, ez dago ereduaren errendimendua konparatzeko modu espezifikorik gainbegiratu gabeko ikaskuntza-metodo gehienetan. Gainbegiratu gabeko ikaskuntzaren barruko zeregin ohikoenak taldekatzea, irudikapenaren ikaskuntza eta dentsitatearen estimazioa dira. Ohiko algoritmo batzuk k batez besteko elkarketa, osagai nagusien analisia eta kodegailu automatikoak dira.



Irudia 4. Gainbegiratu gabeko ikaskuntza-eredua. Taldekatzea

Irudikapenaren ikaskuntzan, ezaugarri indibidualen arteko erlazioak ikasi nahi dira, eta horrek aukera ematen du datuak irudikatzeko hasierako ezaugarriak erlazionatzen dituzten ezkutuko ezaugarriak erabiliz, aurreko irudian (Irudia 4) ikus daitekeen bezala. Ezkutuko egitura bakandu hori, askotan, hasieran baino askoz ezaugarri gutxiago erabiliz irudikatzen da; beraz, datu gehigarrien prozesamendua errazagoa izatea eragin dezake, eta ezaugarri erredundanteak ezaba ditzake. Dimentsioen murrizketa, zutabe edo ezaugarri gutxiago erabiliz datuak irudikatzeko erabiltzen diren metodoei dagokiena, gainbegiratu gabeko irudikapenaren ikaskuntza-metodoen bidez lor daiteke.

Gainbegiratu gabeko ikaskuntza oso erabilgarria da esplorazio-analisan, datuen egitura automatikoki identifika baitezake. Adibidez, analista bat kontsumitzaileak segmentatzen saiatzen bada, ikuskapenik gabeko taldekatze-metodoak abiapuntu egoki bat izango lirateke horiek aztertzeko. Gizakiontzat ezinezkoa edo praktikotasun gutxikoa denean datuetan joerak proposatzea, gainbegiratu gabeko ikaskuntzak hasierako informazioa eman dezake eta hori, gero, hipotesi indibidualak probatzeko erabil daiteke.

2.2.1.3 Erdigainbegiratutako ikaskuntza


Erdigainbegiratutako ikaskuntzak entrenamendu-datuen multzo bat erabiltzen du; etiketatutako eta etiketatu gabeko datuak daude multzo horretan. Erdigainbegiratutako ikaskuntza-algoritmo gehienak gainbegiratutako eta gainbegiratu gabeko algoritmoen konbinazioak dira. Metodo hori bereziki erabilgarria da datuetatik ezaugarri garrantzitsuak ateratzea zaila denean eta adituak adibideak etiketatzeko denbora asko behar duenean.

Ikasketa mota honetarako ohiko egoerak irudi medikoak dira, hala nola ordenagailu bidezko tomografiak edo erresonantzia magnetikoak. Erradiologo gaitu batek miaketa azpimultzo txiki bat berrikusi eta etiketatu dezake tumoreak edo

gaixotasunak detektatzeko. Luze hartuko luke eskaneatze guztiak eskuz etiketatzeak, eta nekeza izango litzateke, baina ikaskuntza sakoneko sareak oraindik ere onura atera diezaioke etiketatutako datuen proportzio txiki bati, eta haren zehaztasuna hobetu, erabat gainbegiratuta ez dagoen eredu batekin alderatuta.

2.2.1.4 Ikaskuntza indartua

Ikaskuntza indartua IAren azpieremu bat da; makina ingurune batean "bizi" da, eta ingurune horren egoera ezaugarrien bektore gisa hautemateko gai da. Makinak ekintzak egin ditzake egoera guztietan. Ekintza desberdinek sari desberdinak ekartzen dituzte, eta makina inguruneke beste egoera batera mugi dezakete. Indartze ikaskuntza-algoritmo baten helburua da erregela bat ikastea. Erregela bat funtzio bat da (gainbegiratutako ikaskuntzaren-ereduaren antzekoa); egoera baten ezaugarrien bektorea hartzen du sarrera gisa, eta ekintza ezin hobea sortzen du egoera horretan gauzatzeko. Ekintza ezin hobea izango da baldin eta espero den saria maximizatzen badu.



Irudia 5. Ikaskuntza indartua

Ikaskuntza indartuak arazo mota jakin batzuk konpontzen ditu; arazootan erabakiak hartzea sekuentziala da eta, helburua, epe luzekoa. Adibidez, jolasak, robotika, baliabideen kudeaketa eta logistika.

2.2.2 Transferentzia bidezko ikaskuntza

Entrenamendu- eta proba-datuen artean datuen banaketan aldea dagoenean, eredu baten emaitzak okerrenak izatea egin dezake. Egoera jakin batzuetan, zaila eta garestia izan daiteke proba-datuen ezaugarriekin bat datozen entrenamendu-datuak lortzea. Beraz, jatorri-eremu batean entrenatutako errendimendu handiko eredu bat sortu behar da lotutako xede-eremu (bigarren eredu) baterako. Horixe da transferentzia bidezko ikaskuntza erabiltzeko motibazioa [28]–[31].

2.2.2.1 Definizioa

Transferentzia bidezko ikaskuntzan, datu multzoren batean entrenatutako eredu bat aukeratzen da, eta eredu hori egokitu egiten da beste datu multzo baten adibideak iragartzeko, eredu eraiki zen datu multzoaz bestelakoa, hurrengo irudian (Irudia 6) ikus daitekeen bezala. Bigarren datu multzo hori ez da baliozkotzeko eta probatzeko erabiltzen diren multzoak bezalakoa. Beste fenomenoren bat esplikatzeko bildutako

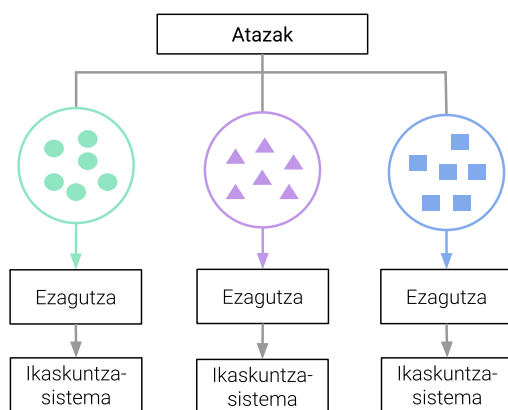
datu multzo bat izan daiteke, edo beste banaketa estatistiko batetik etor daiteke [32]–[34].

Bestela esanda, jatorri-eremu batetik xede-eremu batera ezagutza transferitzeko bide gisa sortu da transferentzia bidezko ikaskuntza. Ikaskuntza automatiko tradizionala ez bezala, transferentzia bidezko ikaskuntza entrenamendu- eta proba-datuen eremuak desberdinak izan daitezkeelako suposizioan oinarritzen da. Ikaskuntza automatikoko algoritmo tradizionalak etorkizuneko datuei buruzko iragarpenak egiten dituzte, aldeaz aurretik etiketatutako edo etiketatu gabeko entrenamendu-datuetan entrenatzen diren eredu matematikoak erabiliz. Transferentzia bidezko ikaskuntzak, aldiz, trebakuntzan eta probetan erabilitako eremuak, atazak eta banaketak desberdinak izatea ahalbidetzen du [35]–[38].

Transferentzia bidezko ikaskuntzari buruzko ikerketari 1995ean ekin zitzaion, eta hainbat izendapen izan ditu: ikasten ikastea, etengabeko ikaskuntza, ezagutzaren transferentzia, xede-ikaskuntza, transferentzia induktiboa, ezagutzaren finkapena, testuinguruarekiko ikaskuntza sentikorra eta ataza anitzeko ikaskuntza [39]–[41].

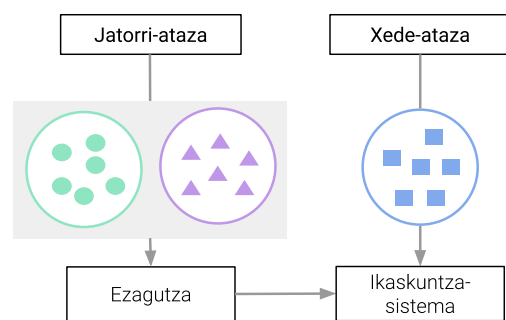
Transferentzia bidezko ikaskuntzaren helburua da xede-eremuan xede-funtzio prediktiboaren ikaskuntza hobetzen laguntzea, jatorri-eremuko ezagutza eta jatorriko ikaskuntza-ataza erabiliz, non jatorri- eta xede-eremua edo jatorri- eta xede-atzak desberdinak diren.

IKASKUNTZA AUTOMATIKO TRADIZIONALAREN IKASKUNTZA-PROZESUA



(a)

TRANSFERENTZIA-BIDEZKO IKASTEAREN IKASKUNTZA-PROZESUA

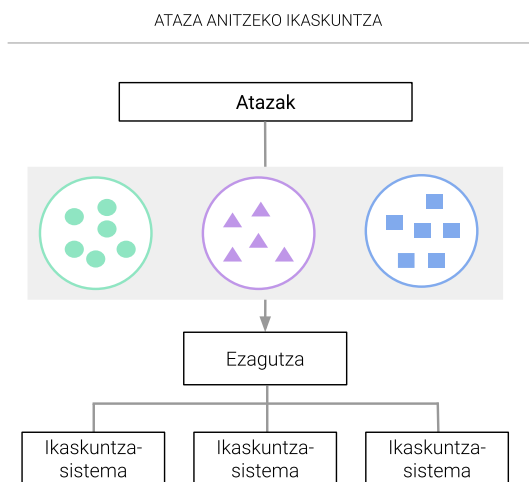


(b)

Irudia 6. Ikaskuntza-prozesuak (a) makina tradizionala eta (b) transferentzia bidezko ikaskuntza

Transferentzia bidezko ikaskuntzarekin lotura estua duen ikaskuntza-teknika bat ere badago, ataza anitzeko ikaskuntza-esparrua, aldi berean ataza ugari ikasi nahi dituen, baita desberdinak direnean ere (ikus Irudia 7). Ataza anitzeko ikaskuntzarako ohiko ikuspegi bat banakako ataza bakoitzari mesede egin diezaioketen ezaugarri komunak aurkitzea da [42].

Beraz, esan daiteke ataza anitzeko ikaskuntza-esparrua transferentzia bidezko ikaskuntzaren teknikaren antzekoa dela, baina alde esanguratsua ere badu. Ataza anitzeko ikaskuntza-esparruan, ez dago atazen arteko bereizketarik, eta helburua ataza guztien errendimendua hobetzea da. Hala ere, xede-ataza baten errendimendua jatorri-atazen laguntzarekin hobetzean datzan transferentzia bidezko ikaskuntzan, xede-atazak jatorri-atazak baino garrantzi handiagoa du. Beraz, ataza anitzeko ikaskuntza-esparruak ataza guztiak berdin tratatzen ditu, baina transferentzia bidezko ikaskuntzan, xede-atazak ataza guztien artean arreta gehienak erakartzen ditu [43].



Irudia 7. Ataza anitzeko ikaskuntza

Ataza anitzeko ikaskuntzaren konfigurazio berri bat ikertzen ari da, ataza anitzeko ikaskuntza asimetrikoa izenekoa, eta konfigurazio horrek beste agertoki bat hartzen du kontuan. Agertoki horretan, ataza berri bat iristen da ataza anitzeko ikaskuntzaren bidez ikasitako sistema batera. Ataza zahar eta berriak hutsetik ikastea irtenbide simple bat da, baina konputazionalki intentsiboa da. Aldiz, ataza anitzeko ikaskuntza asimetrikoak ataza berria ataza zaharren laguntzarekin bakarrik ikasten du eta, beraz, arazo nagusia ataza zaharretan jasotako ezagutza ataza berrira transferitzea da. Alde horretatik, konfigurazio hori transferentzia bidezko ikaskuntzaren antzekoagoa da, ataza anitzeko ikaskuntza-esparruaren aldean [44].

Transferentzia bidezko ikaskuntzarekin egin den bezala, hona hemen ataza anitzeko ikaskuntza-esparruaren definizioa emango da: m ikaskuntza-atazak direla-eta, ataza guztiak edo horien azpimultzo bat erlazionatuta daudenez, ataza anitzeko ikaskuntzaren helburua da eredu baten ikaskuntza hobetzen laguntzea, m ataza guztietan edo batzuetan jasotako ezagutza erabiliz.

2.2.2.2 *Transferentzia bidezko ikaskuntzaren tekniken kategorizazioa*

Transferentzia bidezko ikaskuntzan, hiru ikergai nagusi daude: 1) zer transferitu, 2) nola transferitu eta 3) noiz transferitu.

- Zer transferitu. Eredu edo atazen bidez ezagutzaren zein zati transferi daitekeen galderari erantzuten dio. Ezagutza batzuk espezifikoak dira eremu edo ataza indibidualerako, eta ezagutza batzuk komunak izan daitezke eremu desberdinen artean, xede-eremu edo -atazaren errendimendua hobetzen lagun dezaten.

Transferentzia bidezko ikaskuntzaren ikuspegiak *zer transferitu* galderan oinarritutako lau kasutan laburbil daitezke. Lau kasu horiek hurrengo taulan (Taula 2) laburbilduta daude.

Lehenengo testuinguruari transferentzia bidezko ikaskuntzaren ikuspegi esan dakiok, instantzietan oinarritua (edo instantzien transferentzian), eta horrek jatorri-eremuko datuen zati bat xede-eremuan ikasteko berrerabili daitekeela esan nahi du, parametroak berriro haztatuz. Testuinguru horretan, instantzien haztapena eta garrantziaren laginketa dira bi teknika nagusi.

Bigarren kasuari ezaugarrien irudikapena transferitzeko ikuspegiak dei dakiok. Kasu horren atzean, intuiziozko ideia da xede-eremurako ezaugarrien irudikapen on bat ikastea. Kasu horretan, eremuen bidez transferitzeko erabiltzen den ezagutza ikasitako ezaugarrien adierazpenean kodetzen da. Ezaugarrien irudikapen berriarekin, xede-atazaren errendimendua nabarmen hobetzea espero da.

Hirugarren kasuari parametroen transferentzia-ikuspegiak dei dakiok, eta horrek jatorri-atazek eta xede-atazek ereduaren hiperparametroen aurreko parametro edo banaketa batzuk partekatzen dituztela esan nahi du. Transferitutako ezagutza parametro partekatuetan edo aurrekoetan kodetzen da. Beraz, parametro partekatuetan edo aurrekoetan aurkitzean, ezagutza ataza bidez transferitu daiteke.

Azkenik, azken kasua harreman-ezagutzaren transferentziaren arazotzat jo daiteke, harreman-eremuetarako transferentzia bidezko ikaskuntzarekin lotuta. Testuinguru horren atzean dagoen oinarritzko ustea da antzeko lotura dagoela jatorri- eta xede-eremurako datuen artean. Beraz, transferitu beharreko ezagutza datuen arteko erlazioa da. Oraintsu, harreman-ikaskuntzako estatistika-teknikak nagusi dira testuinguru horretan.

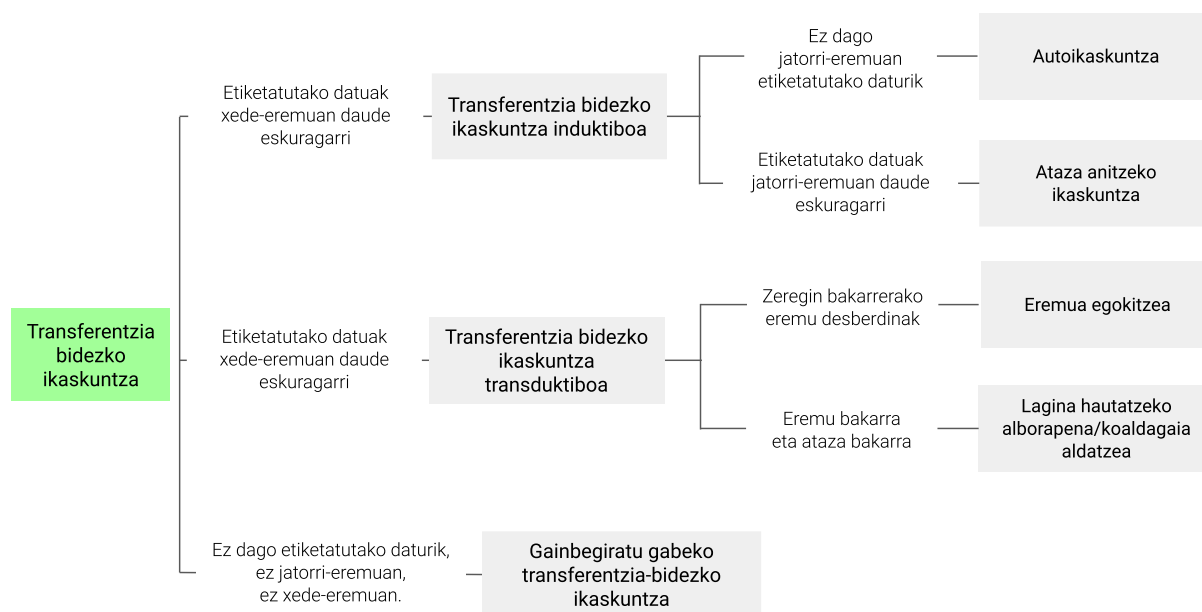
Taula 2. Ikaskuntza-ikuspegiak transferitzea

Ikaskuntza-ikuspegiak transferitzea	Deskribapen laburbildua
Transferentzia bidezko ikaskuntza	Jatorri-eremuan etiketatutako datu batzuk berriz haztatzea, xede-eremuan erabiltzeko.
Ezaugarrien irudikapenaren transferentzia	Jatorri- eta xede-eremuen arteko aldea eta sailkapen- eta erregresio-ereduen errorea murrizten dituen ezaugarrien irudikapen ona aurkitzea.
Parametroen transferentzia	Jatorri- eta xede-eremuen ereduen arteko parametro partekatuak aurkitzea, transferentzia-bidezko ikaskuntzarako onuragarriak izan daitezkeenak.
Harreman-ezagutzaren transferentzia	Ezagutza-mapa erlazionalak sortzea jatorri- eta xede-eremuen artean.

Zer ezagutza transferitu daitekeen jakin ondoren, ikaskuntza-algoritmoak garatu behar dira ezagutza transferitzeko, *nola transferitu* gaiari dagokiona.

- Noiz transferitu. Trebetasunak zer egoeratan transferitu behar diren galderari erantzuten dio. Era berean, interesgarria da jakitea ezagutza zein egoeratan ez den transferitu behar. Egoera batzuetan, jatorri-eremua eta xede-eremua elkarrekin lotuta ez daudenean, baliteke indar gordinaren transferentziak arrakastarik ez izatea. Kasurik okerreanean, ikaskuntzaren errendimenduari eragin diezaioke xede-eremuak, (askotan, transferentzia negatiboa esaten zaio egoera horri). Transferentzia bidezko ikaskuntzari buruzko egungo lan gehienak *zer transferitu* eta *nola transferitu* hartzen dute kontuan, inplizituki suposatuz jatorri- eta xede-eremuak elkarrekin lotuta daudela. Hala ere, transferentzia negatiboa nola saihestu gai garrantzitsua da, eta gero eta arreta handiagoa erakartzen ari da.

Hurrengo irudian (Irudia 8), transferentzia bidezko ikaskuntzaren tekniken kategorizazioaren ikuspegi orokorra ikus daiteke. Transferentzia bidezko ikaskuntza hiru azpimultzotan sailkatzen da: transferentzia bidezko ikaskuntza induktiboa, transferentzia bidezko ikaskuntza transduktiboa eta gainbegiratu gabeko transferentzia bidezko ikaskuntza, jatorri- eta xede-eremu eta -atazen arteko egoeren arabera.



Irudia 8. Transferentzia-konfigurazioen ikuspegi orokorra [45]

Jarraian, aurretik aipatu diren transferentzia bidezko ikaskuntzaren hiru teknikak ikusiko dira [46].

2.2.2.2.1 Transferentzia bidezko ikaskuntza inductiboa

Transferentzia bidezko ikaskuntza inductiboren konfigurazioan, jatorri-ataza eta xede-ataza desberdinak dira, jatorri- eta xede-eremuak berdinak diren ala ez gorabehera. Kasu honetan, xede-eremuan etiketatutako datu batzuk behar dira xede-eremuan erabiltzeko eredu bat lortzeko. Gainera, jatorri-eremuan etiketatutako eta etiketatu gabeko datuen egoera desberdinen arabera, are gehiago kategoriza dezakegu transferentzia bidezko ikaskuntza inductiboaren konfigurazioa bi kasutan.

Lehenengo kasuan, jatorri-eremuan etiketatutako datu asko daude eskuragarri. Kasu honetan, transferentzia inductiboko ikaskuntzaren konfigurazioa ataza anitzeko ikaskuntzaren konfigurazioaren antzekoa da. Hala ere, transferentzia inductiboko ikaskuntzaren konfigurazioak helburu bakarra du: xede-atazan errendimendu handia lortzea jatorri-atazaren ezagutza transferituz; ataza anitzeko ikaskuntza, berriz, jatorri- eta xede-ataza aldi berean ikasten saiatzen da.

Bigarren kasuan, ez dago jatorri-eremuan etiketatutako daturik. Kasu honetan, transferentzia inductiboko ikaskuntzaren konfigurazioa ikaskuntza autodidaktaren konfigurazioaren antzekoa da. Ikaskuntza autodidaktaren ingurunean, jatorri- eta xede-eremuen arteko etiketa-espazioak desberdinak izan daitezke.

Transferentzia bidezko ikaskuntza inductiboaren definizioa honako hau izan daiteke: xede-eremuan funtzio prediktibo objektiboaren ikaskuntza hobetzen laguntzea,

jatorri-eremuaren eta jatorri-ikaskuntzaren ezagutza erabiliz, non jatorri-ataza eta xede-ataza desberdinak diren.

2.2.2.2.2 *Transferentzia bidezko ikaskuntza transduktiboa*

Transferentzia bidezko ikaskuntza transduktiboaren konfigurazioan, jatorri- eta xede-atazak berdinak dira, eta jatorri- eta xede-eremuak, berriz, desberdinak [47].

Egoera horretan, ez dago datu etiketaturik xede-eremuan, eta jatorri-eremuan etiketatutako datu asko eskuragarri daude. Gainera, jatorri- eta xede-eremuen arteko egoera desberdinen arabera, are gehiago, transferentzia bidezko ikaskuntza transduktiboaren konfigurazioa bi kasutan sailka daiteke.

Lehenengoan, jatorri- eta xede-eremuen arteko ezaugarriak desberdinak dira.

Bigarrenean, eremu arteko ezaugarriak dituzten espazioak berdinak dira; sarrera-datuen probabilitate marjinalaren banaketak, ordea, desberdinak.

Transferentzia bidezko ikaskuntza transduktiboaren definizioa honako hau izan daiteke: funtzio prediktibo objektiboaren ikaskuntza hobetzea xede-eremuan, ezagutza jatorri-eremuan eta jatorri-atazan erabiliz, non jatorri- eta xede-eremua desberdinak diren.

2.2.2.2.3 *Gainbegiratu gabeko transferentzia bidezko ikaskuntza*

Azkenik, gainbegiratu gabeko transferentzia bidezko ikaskuntzaren konfigurazioan, transferentzia induktiboko ikaskuntzaren konfigurazioaren antzera, xede-ataza desberdina da, baina jatorri-atazarekin lotuta dago. Hala ere, gainbegiratu gabeko transferentzia bidezko ikaskuntzaren helburua da xede-eremuan gainbegiratu gabeko ikaskuntza-atazak ebatzea, hala nola taldekatzea, dimentsionaltasuna murriztea eta dentsitatea kalkulatzeko. Kasu horretan, ez dago datu etiketaturik entrenamenduaren jatorri- eta xede-eremuetan [48].

Gainbegiratu gabeko transferentzia bidezko ikaskuntzaren helburua da xede-eremuan xede-funtzio prediktiboaren ikaskuntza hobetzen laguntzea, jatorri-eremuko ezagutza eta jatorri-ataza erabiliz, non jatorri-ikaskuntzako ataza eta xede-ikaskuntzako atazak desberdinak diren eta jatorri-eremuko eta xede-eremuko etiketak ez diren behagarriak.

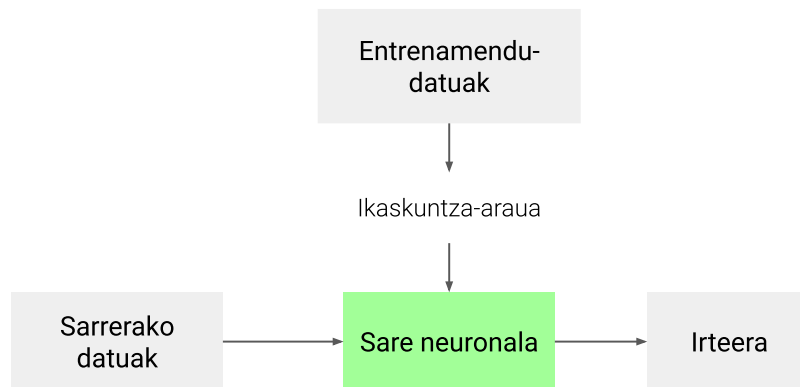
Hurrengo taulan (Taula 3), teknika bakoitzean zer ikaskuntza-ikuspegi transferi daitekeen azaltzen da.

Taula 3. Hainbat inguruetan erabilitako ikuspegiak

	Transferentzia bidezko ikaskuntza induktiboa	Transferentzia bidezko ikaskuntza transduktiboa	Gainbegiratu gabeko transferentzia-bidezko ikaskuntza
Transferentzia bidezko ikaskuntza	•	•	
Ezaugarrien irudikapenaren transferentzia	•	•	•
Parametroen transferentzia	•		
Harreman-ezagutzaren transferentzia	•		

2.2.3 Sare neuronal eta ikaskuntza sakona

Jarraian, sare neuronal ikaskuntza automatikoarekin nola lotzen den ikusiko da. Ikaskuntza automatikoko ereduak hainbat modutan ezar daitezke. Sare neuronal da horietako bat. Hurrengo irudian (Irudia 9), ikaskuntza automatikoaren eta sare neuronalaren arteko harremana irudikatzen da. Kontuan izan behar da sare neuronal dagoela ikaskuntza-ereduaren eta -arauaren ordean, ikaskuntza automatikoaren ordean. Sare neuronalaren testuinguruan, eredu zehazteko prozesuari ikaskuntza-araua esaten zaio [49], [50].

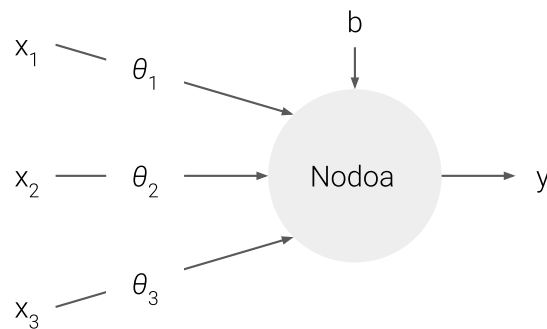


Irudia 9. Sare neuronalaren funtzionamendua

Behin sare neuronalak eta ikaskuntza automatikoa nola lotzen diren ikusita, sare neuronal baten oinarriko osagaia zein den ikusiko da: neurona edo nodoa.

Sare neuronal giza garunaren mekanismoa imitatzen du. Burmuina neurona ugariaren konexioek osatzen dutenez, sare neuronal nodoen konexioekin eraikitzen da; garunaren neuronei dagozkien elementuak direnekin. Sare neuronalak neuronaren asoziazioa imitatzen du (garunaren mekanismo garrantzitsua da), eta, horretarako, pisuaren balioa erabiltzen du.

Hurrengo irudian (Irudia 10), hiru sarrerako nodo baten mekanismoa azaltzen da.



Irudia 10. Hiru sarrera jasotzen dituen nodoa

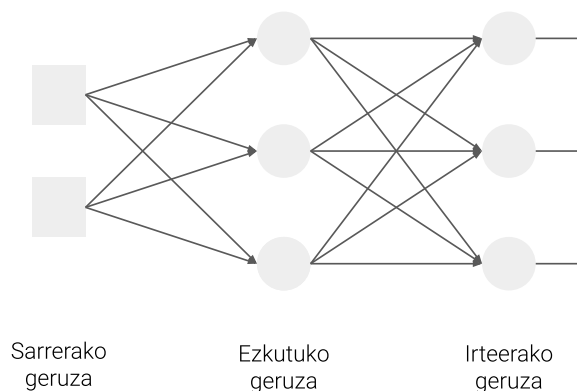
Irudiaren zirkuluak eta geziak seinale-nodoa eta -fluxua adierazten dute. x_1 , x_2 eta x_3 sarrerako seinaleak dira; θ_1 , θ_2 eta θ_3 seinaleen pisuak dira. Azkenik, b alborapena da, informazioa biltegitratzearekin lotutako faktore bat. Bestela esanda, sare neuronaleko informazioa pisu eta alborapen moduan biltegitratzen da.

Kanpotik sartzen den seinalea, pisuarekin biderkatzen da nodora iritsi aurretik. Seinale haztatuak nodoan biltzen direnean, balio horiek batura haztatua izateko gehitzen dira. Adibide honen batura haztatua honela kalkulatzen da:

$$h_{\theta}(x) = y = x_1\theta_1 + x_2\theta_2 + x_3\theta_3 + b \quad (1)$$

Ekuazio horrek adierazten duenez, pisu handiagoa duen seinaleak eragin handiagoa du. Adibidez, θ_1 pisua 1 baldin bada eta θ_2 pisua 5 baldin bada, x_2 seinalea x_1 baino bost aldiz handiagoa da. θ_1 zero denean, x_1 ez zaio inola ere nodoari transmititzen. Horrek esan nahi du x_1 nodotik deskonektatuta dagoela.

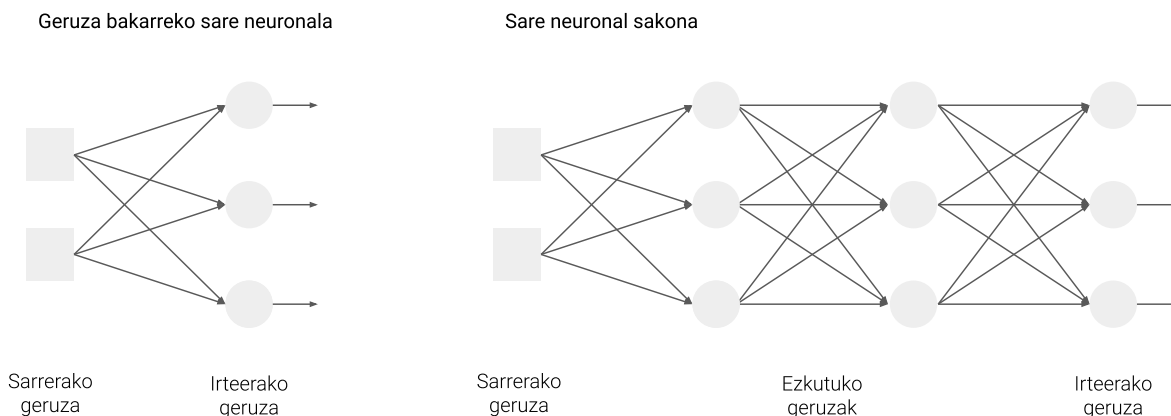
Sare neuronalak nodoen sare bat da. Sare neuronal ezberdinak bat sor daiteke, nodoak nola dauden konektatuta. Gehien erabiltzen den sare neuronal mota batek, hurrengo irudian (Irudia 11) ikus daitekeen bezala, nodo-geruzatan dagoen egitura bat erabiltzen du.



Irudia 11. Egitura nodo-geruzatan, sare ez oso sakon batean

Aurreko irudian (Irudia 11) agertzen den nodo karratuen multzoari sarrerako geruza esaten zaio. Sarrerako geruzako nodoek sarrerako seinaleak hurrengo nodoetara transmititzen dituen pasarte gisa baino ez dute jokatzeko. Beraz, ez dute kalkulatu batura haztatua eta aktibazio-funtzioa. Hori dela eta, karratu bidez adierazten eta beste nodo zirkularretatik bereizten dira. Eskuinerago dagoen nodoen taldeari irteera geruza esaten zaio. Nodo horien irteeran sare neuronalaren azken emaitza lortzen da. Sarrerako eta irteerako geruzen arteko geruzak ezkutuko geruzak dira (izen hori ematen zaie ezin direlako eskuratu sare neuronalaren kanpoaldetik).

Sare neuronalaren arkitektura simple batetik egitura gero eta konplexuago bat garatu da (ikus Irudia 12). Hasiera batean, sare neuronalaren aitzindariak oso arkitektura simplea zuten sarrerako eta irteerako geruzei dagokienez; geruza bakarreko sare neuronalak deitzen dira horiek. Geruza bakarreko sare neuronal bati ezkutuko geruzak gehitzen zaizkionean, horrek geruza askoko sare neuronal bat sortzen du. Beraz, geruza askoko sare neuronalak sarrerako geruza bat, ezkutuko geruza bat edo batzuk eta irteerako geruza bat ditu. Geruza ezkutuko bakarra duen sare neuronalari gainazaleko sare neuronalak edo banilla sare neuronalak deitzen zaio. Geruza askoko sare neuronalari (bi geruza ezkutuko edo gehiago dituen) sare neuronal sakon esaten zaio. Aplikazio praktikoetan erabiltzen diren egungo sare neuronal gehienak sare neuronal sakonak dira.



Irudia 12. Geruza bakarreko sare neuronal vs. sare neuronal sakona

Geruzetako sare neuronalean, seinalea sarrerako geruzan sartzen da, ezkutuko geruzetatik igarotzen da eta irteerako geruzatik irteten da. Prozesu horretan, seinaleak geruzaz geruza egiten du aurrera. Bestela esanda, geruza bateko nodoek seinalea jasotzen dute aldi berean eta prozesatutako seinalea hurrengo geruzara bidaltzen dute aldi berean.

Sare neuronal batek zenbat eta geruza gehiago izan, orduan eta gaitasun handiagoa izango du funtzio gero eta konplexuagoak aztertzeko. Izan ere, sare neuronal sakona ikaskuntza automatikoaren adar bat da, eta ezaugarriak eraldatzeko eta

erauzteko geruza ugari hartzen dituzten prozesamendu ez linealeko unitate batzuk baliatzen ditu.

2.3 Ondorioak

Lan honetan, aurretik aipatu diren Li-ioi baterien degradazio-datuak erabiliko dira. Ikusi den bezala, Li-ioi bateriek katodoan zein anodoan material ezberdinak erabiltzen dituzte ezaugarri ezberdinak lortzeko. Materialok, baterien propietateak aldatzeaz gain, beren degradazio-mekanismoak ere aldatzen dituzte.

Aipatu den bezala, lan honen helburua da hainbat kimikaren degradazioa aztertzeko balio duen algoritmo bat sortzea. Zehazki, anodoan LFP eta NMC erabiltzen duten Li-ioi baterien bizi-iraupena iragarri nahi da. Horretarako, aurrerago ikusiko diren degradazio-datuak erabiliko dira, non bateriak baldintza ezberdinetan frogatu diren.

Bateria horien degradazioa iragartzeko, adimen artifizialeko algoritmoak erabiliko dira. Erabiliko den ikaskuntza-eredua gainbegiratutako ikaskuntza-eredua izango da, datu guztiak etiketatuta baitaude. Ikusi den bezala, gainbegiratutako ikaskuntza-ereduak sailkapena edo erregresioa egiteko balio du. Kasu honetan, bateriaren bizi-estimazioa iragarri nahi denez, erregresioa da erabili beharreko teknika.

Adimen artifizialeko algoritmoen barruan, sare neuronalak erabiliko dira, duten balioaniztasuna dela eta. Eraiki nahi den eredua ahalik eta zehatzena izatea lortu nahi da, eta baterien degradazio-mekanismoak ikasteko gaitasun handia izatea nahi da. Hori dela eta, sare neuronal sakon bat sortuko da.

Azkenik, ikusi den bezala, bi Li-ioi kimika erabiltzen dituzten baterien datuak erabiliko dira. Beraz, transferentzia bidezko ikaskuntza aplikatu beharko da. Jatorri- eta xede-eremuan datuak ezagunak izango direnez, transferentzia bidezko ikasketa induktiboa erabiliko da.

3. SARE NEURONALEN EZAUGARRIAK

Aurreko atalean azaldu da adimen artifiziala egiteko aukera asko daudela. Lan honetan sare neuronal sakon bat erabiliko da baterien degradazioa iragartzeko. Baina, sare neuronal bat egiteko aukera asko daude.

Kapitulu honetan, erabiliko den sarearen hainbat ezaugarri eta sarea entrenatzeko jarraitu beharreko pausoak azalduko dira. Lehenik eta behin, erabiliko den sarearen inguruko informazio sakonagoa emango da.

3.1 Datuen prestaketa

Sarea sortu aurretik, lehenik eta behin, erabiliko diren datuak prestatu behar dira. Sarea entrenatzeko erabiliko diren sarrerako zein irteerako datuak (tenperatura, SOC, etab.) balio-tarte ezberdinetan daude; aldiz, sare neuronal bat entrenatzen denean, balioak tarte berdinean edo antzeko batean egotea gomendatzen da ikaskuntza-abiadura azkartzeko [51].

Horretarako, normalizazioa erabiltzen da. Normalizazioa balio-tarte erreala bat balio-tarte estandar bihurtzeko prozesua da, $[-1, 1]$ edo $[0, 1]$ tartetan, tipikoki. Gainera, normalizazioari esker, sarrerak gutxi gorabehera tarte txiki samarrean daudela ziurtatzen da, ordenagailuek zenbaki txikiekin edo handiekin lan egiten dutenean dituzten arazoak saihesteko.

Bestalde, datu-basea ere hiru talde ezberdinetan banatu behar da. Talde hauetan, hain zuzen:

- entrenamendu multzoa
- balidazio multzoa
- proba multzoa

Entrenamendu multzoa handiena izaten da, eta eredia eraikitzeke erabiltzen da. Balidazio eta frogak multzoak gutxi gorabehera tamaina berekoak izaten dira, entrenamendu multzoa baino askoz txikiagoak. Ikaskuntza-algoritmoak ezin ditu bi azpimultzo horien adibideak erabili eredu bat eraikitzeke. Horregatik, bi multzo horiei erresistentzia multzo esaten zaie askotan.

Ez dago datu multzoa hiru azpimultzo horietan banatzeko proportzio optimorik. Iraganean, arau orokorra zen datu guztien % 70 entrenamendurako erabiltzea, % 15 balidaziorako erabiltzea eta % 15 probetarako erabiltzea. Hala ere, gaur egun, datu multzoek milioika adibide izaten dituzte askotan. Kasu horietan, arrazoizkoa izango litzateke % 95ari eustea gaikuntzarako, eta % 2,5ari balidazioa/proba egiteko [52].

Hiru multzo izateko arrazoia sinplea da. Eredu bat eraikitzen denean, ez da nahi ereduak ondo egitea soilik ikaskuntza-algoritmoek ikusi dituzten adibideen etiketak iragartzeko. Algoritmo arrunt batek entrenamenduaren adibide guztiak memorizatu

bestarik ez du egingo, eta gero memoria erabiliko du bere etiketak "iragartzeko". Ez du akatsik egingo entrenamenduaren adibideen etiketak iragartzeko eskatzen zaionean, baina algoritmo hori alferrik izango da praktikan. Benetan nahi dena da eredia ikaskuntza-algoritmoak ikusi ez zituen adibideak iragartzeko gai izatea. Beraz, errendimendu ona nahi da erresistentzia multzo batean.

Bi erresistentzia multzo izatea beharrezkoa da jarraian azaltzen diren arazoiengatik. Balidazio multzoa erabiltzen da 1) ikaskuntza-algoritmoa aukeratzeko eta 2) hiperparametroen baliorik onenak aurkitzeko. Probaren multzoa erabiltzen da eredia ebaluatzeko, ekoizpenean jarri aurretik.

3.2 Aurreraelikadurako sare sakona

Erabiliko den sare mota erregresio lineala egingo duen aurreraelikadurako sare sakona izango da. *Feed-forward* sare neuronal edo geruza askoko pertzeptroi ere esan ohi zaie, eta ikaskuntza sakoneko eredu nagusiak dira. Aurreraelikadurako sare baten helburua f funtzio-hurbilpena da.

Eredu horiei *feed-forward* esaten zaie, informazioa x -tik ebaluatzen den funtzioaren bidez doalako, f definitzeko erabilitako bitarteko kalkuluen bidez, eta, azkenik, y irteerara. Ez dago ereduaren irteerak berrelikatu egiten diren berrelikadura-konexiorik.

3.2.1 Atzeranzko hedapena

Aurreraelikadurako sare neuronal bat erabiltzen dugunean x sarrera bat onartzeko eta y irteera bat sortzeko, informazioa aurrera doa sarean zehar. x sarrerek hasierako informazioa ematen dute, gero geruza bakoitzean ezkutatutako unitateetara zabaltzen dena, eta azkenik y sortzen du. Horri aurreranzko hedapena deitzen zaio. Entrenamenduan, aurreranzko hedapenak aurrerantz jarrai dezake, harik eta $J(\theta)$ eskalako kostu bat sortu arte. Atzeranzko hedapeneko algoritmoari esker, kostuaren informazioa atzeraka joan daiteke sarean zehar, gradientea kalkulatzeko [24].

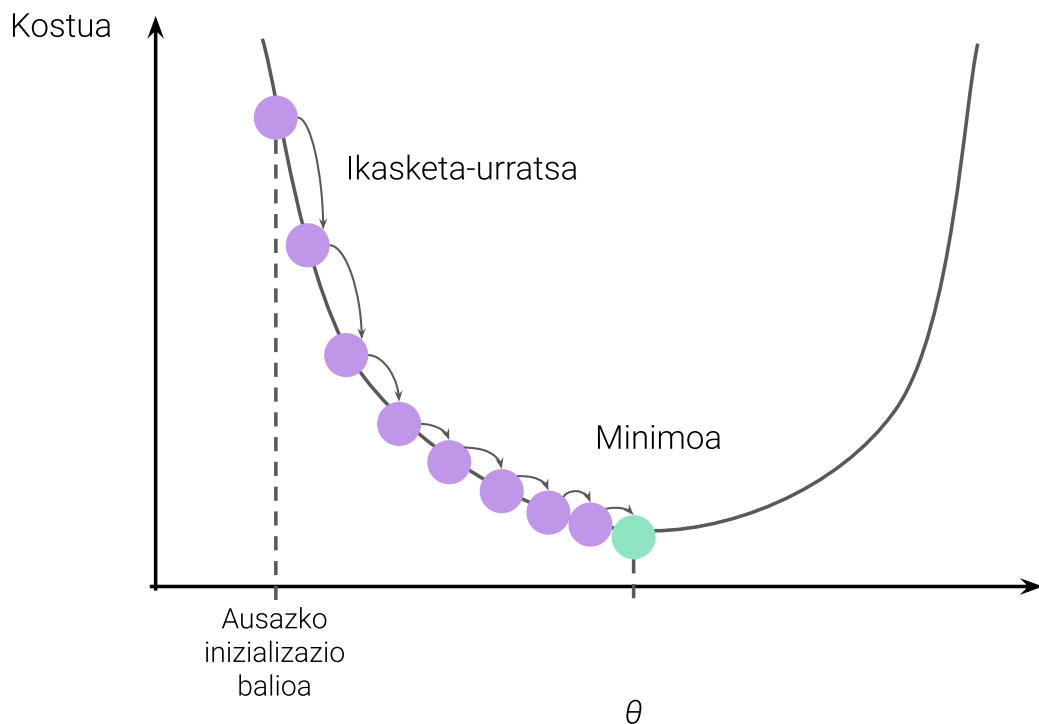
Hau da, entrenamendu-instantzia bakoitzerako, algoritmoak sarea elikatzen du eta neurona bakoitzaren irteera kalkulatu ondoren ondoko geruza bakoitzean (hau da zuzeneko igarotzea, iragarpenak egiten direnean bezala). Gero, sarearen irteera-errorea neurtzen du (hau da, nahi den irteeraren eta sarearen benetako irteeraren arteko aldea), eta kalkulatu zenbat ekarpen egin dion neurona bakoitzak irteera-neurona bakoitzaren erroreari ezkutuko azken geruzan. Ondoren, neurona bakoitzetik datozen errore-ekarpen horien kantitatea neurtzen du aurreko geruza ezkutuan, eta horrela hurrenez hurren, algoritmoa sarrera-geruzara iritsi arte. Alderantzizko urrats horrek modu eraginkorrean neurtzen du errore-gradientearen sareko konexio-pisu guztietan, errore-gradientearen sarean atzerantz zabaltzean (hortik datorkio algoritmoaren izena) [21].

3.2.2 Gradiente-jaitsiera

Gradiente-jaitsiera optimizazio-algoritmo oso generikoa da, eta gai da arazo mota askotarako konponbide optimoak aurkitzeko. Gradiente-jaitsieraren ideia orokorra parametroak iteratiboki doitzea da, kostu-funtzio bat minimizatzen.

Kostu-funtzioaren gradiente lokala neurtzen du, parametroen bektoreari dagokionez, eta beheranzko gradientearen noranzkoan doa. Gradiente zero denean, minimo bat lortu da.

Zehazki, θ ausazko balioekin (horri ausazko initalizazioa deitzen zaio) betetzen hasten da, eta, gero, pixkanaka hobetzen du, urrats txiki bat emanaz aldiro, urrats bakoitza kostu-funtzioa murrizten saiatzen da (adibidez, MSE), algoritmoak minimo batean konbergitzen duen arte, hurrengo irudian (Irudia 13) ikus daitekeen bezala.



Irudia 13. Gradiente-jaitsiera

Gradiente-jaitsieraren parametro garrantzitsu bat urratsaren tamaina da; hori, bada, ikaskuntza-abiaduraren hiperparametroaren bidez zehazten da. Ikaskuntza-tasa txikiegia bada, algoritmoak iterazio asko igaro beharko ditu bat egiteko, eta horrek denbora asko beharko du.

Bestalde, ikaskuntza-tasa handiegia bada, haranean zehar salto egin dezake eta beste aldean amaitu, beharbada lehen baino puntu altuago batean. Horrek

algoritmoaren dibergitzea ekar lezake, gero eta balio handiagoekin, balio optimorik aurkitu gabe.

Azkenik, kostu-funtzio guztiek ez dute bol erregularren forma; aitzitik, forma irregularrak dituzte eta ondorioz gradiente-jaitsierak minimo lokal batera joan daitezke.

Gradiente-jaitsiera ezartzeko, kostu-funtzioaren gradientea kalkulatu behar da, θ_i ereduaren parametro bakoitzarekiko. Bestela esanda, kostu-funtzioa zenbatean aldatuko den kalkulatu behar da, baldin eta θ_j oso gutxi aldatzen bada. Hau da, deribatu partziala kalkulatu behar da. Hona hemen erregresio linealaren MSE kostu-funtzioaren ekuazioa:

$$J(\theta) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta} \cdot x^{(i)} - y^{(i)})^2 \quad (2)$$

Non

$$h_{\theta}(x) = \theta^T x \quad (3)$$

Non m datu multzoaren ezaugarri kopurua eta i datu multzoaren zenbatgarren datua diren.

Gradiente horiek banaka kalkulatu beharrean, jarraian dagoen ekuazioa erabil daiteke denak batera kalkulatzeko. Gradiente-bektoreak kostu-funtzioaren deribatu partzial guztiak ditu (bat ereduaren parametro bakoitzerako).

$$\begin{pmatrix} \frac{\partial}{\partial \theta_0} J(\theta) \\ \frac{\partial}{\partial \theta_1} J(\theta) \\ \vdots \\ \frac{\partial}{\partial \theta_j} J(\theta) \end{pmatrix} = \frac{1}{m} \sum_{i=1}^m (h_{\theta} \cdot x^{(i)} - y^{(i)}) x_j^{(i)} \quad (4)$$

Non j ezaugarri kopurua den. Gorantz jotzen duen gradiente-bektorea lortzen denean, kontrako norabidean joan besterik ez dado beherantz joateko. Horrek esan nahi du θ -ri $\alpha \frac{\partial}{\partial \theta_j} J(\theta)$ kendu behar zaiola. Hor sartzen da jokoan α ikaskuntza-tasa. Gradiente-bektorea α -z biderkatzen da, maldan behera pasabidearen tamaina zehazteko.

$$\theta_j = \theta_j - \alpha \frac{\partial}{\partial \theta_j} J(\theta) \quad (5)$$

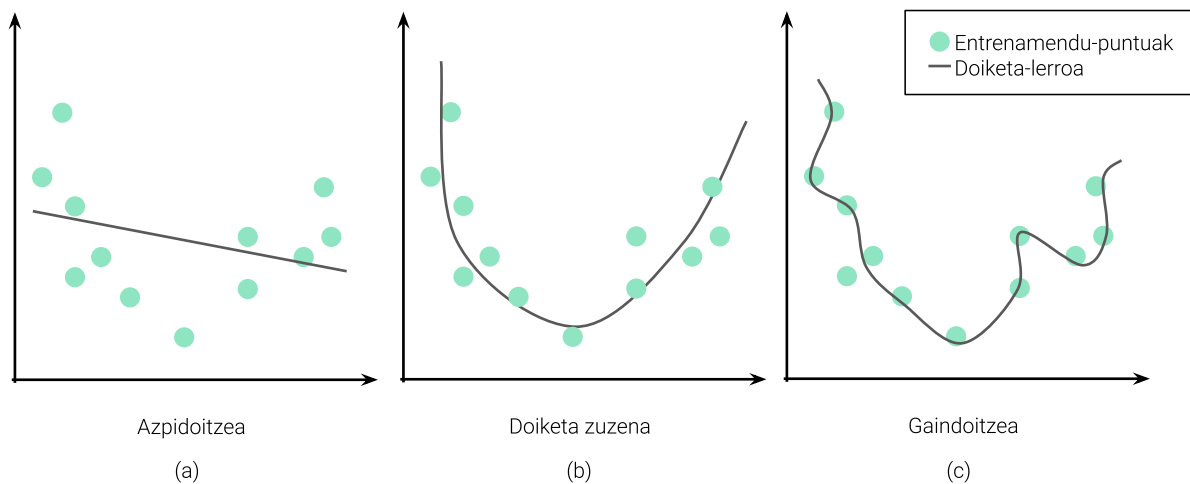
3.2.3 Gaindoitzea eta azpidoitzea

Eredua entrenatzen denean, bi fenomeno gerta daitezke: gaindoitzea eta azpidoitzea. Horietan, ereduak ez du ondo jarraitzen doitu behar duen kurba.

Ereduek errore handia erakusten badu entrenamendu-datueta, ereduak alborapen handia du edo ereduaz azpidoitu egiten da. Hainbat arrazoi direla kausa gertatzen da azpidoitzea. Hauek dira garrantzitsuenak:

- Eredua sinplegia da datuetarako (adibidez, eredu lineal batekin prozesu ez lineal bat doitu nahi denean).
- Ereduari ezarritako ezaugarriak ez dira behar bezain informatiboak.

Lehenengo kasuaren adibidea hurrengo irudian (Irudia 14 (a)) ikus daiteke. Kasu horretan, datu multzoak lerro kurbatu baten antza izan dezake, baina ereduaz lerro zuzena da.



Irudia 14. Azpidoitzea, doiketa zuzena eta gaindoitzea

Bigarren kasua honela adieraz daiteke: demagun paziente batek minbizia ote duen iragarri nahi dela, eta ereduari ezartzen zaizkion ezaugarriak altuera, presio arteriala eta bihotz-maiztasuna direla. Hiru ezaugarri horiek ez dira minbizi-iragarle onak; beraz, ereduak ezin izango du ezaugarri horien eta etiketaren arteko lotura esanguratsurik ikasi.

Azpidoitzearen arazoari aurre egiteko bi gauza egin daitezke: eredu konplexuago batekin saiatzeta edo iragartzeko ahalmen handiagoa duten ezaugarriak diseinatzea.

Gaindoikuntza eredu batek izan dezakeen beste arazo bat da (ikus Irudia 14 (c)). Gehiegi doitzen den ereduak oso ondo iragartzen ditu entrenamendu-datuak, baina gaizki erresistentzia multzoetako bat gutxienez. Hainbat arrazoik eragin diezaiokete gaindoikuntzari: eredu sinpleenak ere (linealak, kasu) datuak gaindoitu ditzake. Hori gertatu ohi da datuen dimentsioa oso handia denean, baina entrenamendu-adibideen kopurua, aldiz, nahiko baxua. Izan ere, ezaugarri-bektoreak oso handiak direnean, ikaskuntza linealeko algoritmoak, θ_i parametroen bektorean, θ dimentsio gehienei zero ez diren balioak esleitzen dizkien eredu bat eraiki dezake, eta eskuragarri dauden ezaugarri guztien artean erlazio oso konplexuak aurkitzen saiatzen da, entrenamendu-adibideen etiketak behar bezala iragartzeko.

Eredu konplexu batek, ziur asko, gaizki iragarriko ditu erresistentzia multzoaren etiketak. Izan ere, entrenamendu-adibide guztien etiketak behar bezala iragartzen saiatzean, ereduak entrenamendu multzoaren idiosinkrasiak ere ikasiko ditu; hauek, hain zuzen: zarata entrenamendu-adibideen ezaugarrien balioetan, laginketaren inperfekzioa datu multzoaren tamaina txikiagatik entrenamendu multzoan presente dagoen erabaki-arazoaz kanpoko beste tresna batzuenagatik. Garrantzitsuenak hauek dira:

- Eredua konplexuegia da datuetarako (adibidez, sare neuronal oso sakon batekin prozesu sinple bat doitzen denean).
- Funtzio gehiegi ditu, baina trebakuntzaren adibide gutxi.

Literaturan bada beste termino bat gehiegizko doikuntzaren arazorako, estatistikaren arlotik datorrena; hots, bariantza altuaren arazoa. Bariantza eredu-akats bat da, entrenamendu multzoko gorabehera txikiakiko sentikortasuna dela eta. Horrek esan nahi du bere entrenamendu-datuak modu desberdinean lagindu izan balira, ikaskuntzaren emaitza nabarmen bestelakoa izango litzatekeela. Horregatik, gehiegi doitzen den eredu batek iragarpen okerrak egiten ditu proba-datuetan. Gaindoikuntzaren arazoari hainbat irtenbide eman dakizkioke:

- Frogatu-eredu sinpleagoa.
- Adibideen dimentsionaltasuna murriztea datu guztietan (adibidez, dimentsionaltasuna murrizteko tekniketako bat erabiliz).
- Entrenamendu-datu gehiago gehitzea, ahal bada.
- Eredua erregularizatzea.

Erregularizazioa gaindoitzea ekiditeko teknika erabiliena da [53].

3.2.4 Erregularizazioa

Erregularizazioa termino orokor bat da, eta ikaskuntza-algoritmoa hain konplexua ez den eredu bat eraikitza behartzen duten metodoak biltzen ditu. Praktikan, horrek, askotan, alborapen handiago batera eramaten du, baina bariantza nabarmen murrizten du. Arazo hori, literaturan, alborapen-bariantza oreka gisa ezagutzen da.

Gehien erabiltzen diren bi erregularizazio motei L1 erregularizazio eta L2 erregularizazio deitzen zaie. Eredu erregularizatu bat sortzeko, funtzio objektiboa aldatzen dugu, eredu konplexuagoa denean balio handiagoa duen termino penalizatzaile bat gehituz.

Jarraian, erregularizazioa irudikatu da erregresio linealaren adibidea erabiliz. Printzipio bera eredu mota askori aplika dakieke. Lehenik eta behin, L1 erregularizazioa nolakoa den ikus daiteke:

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m (h_{\theta} \cdot x^{(i)} - y^{(i)})^2 + \lambda \sum_{j=1}^n |\theta_j| \quad (6)$$

Non λ erregularizazioaren garrantzia kontrolatzen duen hiperparametroa den. λ zeroan ezartzen badugu, erregularizatu gabeko erregresio linealeko eredu estandar bihurtzen da eredu. Bestalde, λ balio altua ezartzen badugu, ikaskuntza-algoritmoak θ_j gehiena balio oso txiki edo zerora doitzen saiatuko da helburua minimizatzen, eredu oso sinplea bihurtuko da, eta horrek doikuntza eskasa ekar dezake. λ hiperparametroaren balio egokia aurkitzean, balio horrek ez du alborapena gehiegi handituko; aitzitik, gaindoikuntza murriztuko du.

Bestalde, L2 erregularizazioa honela ikusiko da:

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m (h_{\theta} \cdot x^{(i)} - y^{(i)})^2 + \lambda \sum_{j=1}^n (\theta_j)^2 \quad (7)$$

Praktikan, L1 erregularizazioak eredu sakabanatu bat sortzen du, eta eredu horrek parametro gehienak ditu (eredu linealen kasuan, θ_i gehienak zero dira (betiere λ hiperparametroa nahiko handia bada) [54]. Orduan, L1ek ezaugarrien hautaketa egiten du, iragarpeneko funtsezkoak diren eta ez diren ezaugarriak erabakitzean. Hori baliagarria izan daiteke ereduaren azalgarritasuna handitu nahi izanez gero. Hala ere, bere helburu bakarra atxikitako datuetan ereduaren errendimendua maximizatzea bada, L2k emaitza hobek ematen ditu oro har [55].

L1 eta L2 erregularizazio-metodoak ere konbinatzen dira erregularizazio sare elastiko deritzonetan, eta L1 eta L2 erregularizazioak kasu bereziak dira. L2rako gandorraren erregularizazioa eta L1erako begizta izena aurki daitezke literaturan.

Eredu linealekin asko erabiltzeaz gain, L1 eta L2 erregularizazioa sare neuronalekin eta beste eredu mota askorekin ere erabiltzen da.

Sare neuronalak, erregularizatzeko, beste bi teknikaz ere baliatzen dira: abandonua eta lotekako normalizazioa. Badira erregularizazio-efektua duten metodo ez matematikoak ere: datuen gehikuntza eta geldiketa goiztiarra.

Behin erregularizazioa eta honek ekar ditzakeen abantailak ikusita, jarraian, aurreraelikadurako sare neuronaletan bakarrik dagoen arazo bat ikusiko da: nola aukeratu unitate ezkutuko mota ereduaren geruza ezkutuetan erabiltzeko. Ezkutuko unitateen diseinua ikerketa-eremu oso aktibo bat da, eta oraindik ez ditu behin betiko printzipio teoriko gidari asko.

3.2.5 Unitate ezkutukoak

Unitate lineal zuzenduak aurrez zehaztutako ezkutuko unitatearen aukera proposak dira. Ezkutuko beste unitate mota asko eskuragarri daude. Zaila izan daiteke zehaztea noiz erabili behar den (nahiz eta unitate lineal zuzenduak aukera onargarria izan ohi diren) [56]. Diseinu-prozesua proba eta errore batean datza, ezkutuko unitate mota batek ondo funtziona dezakeelakoan egonda. Ondoren, ezkutuko unitate mota hori duen sare bat gaitzen da eta balidazio multzo batean duen jarduna ebaluatzen da.

Ezkutuko unitate gehienak honela deskriba daitezke: x sarrera-bektore bat onartzea, $z = \theta x + b$ transformazio bat kalkulatzeko, eta, ondoren, $g(z)$ elementuen arabera aktibazio-funtzio ez lineal bat aplikatzea. Ezkutuko unitate gehienak $g(z)$ aktibazio-funtzioaren formaren aukeragatik bakarrik bereizten dira bata bestearengandik.

Unitate lineal zuzenduak eta horien orokortzeak

Unitate lineal zuzenduek (relu) $g(z) = \max\{0, z\}$ aktibazio-funtzioa erabiltzen dute.

$$g(z) = \text{relu}(z) = \begin{cases} 0, & (\text{baldin eta } z < 0) \\ z, & (\text{bestelako kasuetan}) \end{cases} \quad (8)$$

Unitate lineal zuzenduak erraz optimizatzen dira, unitate linealen oso antzekoak direlako. Unitate lineal baten eta unitate lineal zuzendu baten arteko alde bakarra da unitate lineal zuzendu batek zero sortzen duela bere eremuaren erdian. Horren ondorioz, unitate lineal zuzendu baten bidez, deribatuek handiak izaten jarraitzen dute unitatea aktibo dagoenean.

Gradienteak handiak dira, bai eta sendoak ere. Zuzenketa-eragiketaren bigarren deribatua 0 da ia leku guztietan, eta zuzenketa-eragiketaren deribatua 1 da unitatea aktibo dagoen leku guztietan. Horrek esan nahi du gradientearen norabidea askoz erabilgarriagoa dela bigarren mailako ondorioak dituzten aktibazio-funtzioekin izango litzatekeena ikasteko.

Sigmoide logistikoa eta tangente hiperbolikoa

Unitate lineal zuzenduak erabiltzen hasi aurretik, sare neuronal gehienek aktibatze funtzio gisa sigmoide logistikoa erabiltzen zuten:

$$H = g(\theta x + b) \quad (9)$$

Unitate lineal zuzenduak sartu aurretik, sare neuronal gehienek sigmoide logistikoko aktibatze-funtzioa zerabilten:

$$g(z) = \sigma(z) \quad (10)$$

Edo tangente hiperbolikoko aktibatze-funtzioa:

$$g(z) = \tanh(z) \quad (11)$$

Zatikako unitate linealak ez bezala, unitate sigmoidalak euren eremuaren zatirik handienean asetzen dira: z oso positiboa denean balio altu batean saturatzen dira, z oso negatiboa denean balio baxu batean saturatzen dira eta z '0' inguru dagoenean bakarrik dira oso sentikorak. Unitate sigmoidalen saturazio orokorrak gradienteetan oinarritutako ikaskuntza zaildu dezake. Hori dela eta, ez da gomendagarria aurrerapen-sareetan ezkutututako unitate gisa erabiltzea. Irteera-unitate gisa erabiltzea bateragarria da gradienteetan oinarritutako ikaskuntza erabiltzearekin, irteera-geruzako sigmoidearen saturazioa desegin dezakeen kostu-funtzio egoki bat erabiltzen bada [57].

3.3 Sare neuronala entrenatzea: eman beharreko urratsak

Sare neuronala osatzeko orduan kontuan hartu beharrekoak ikusita, jarraian, sare neuronala entrenatzeko jarraitu beharreko pausoak adieraziko dira:

1. Pisuak ausaz abiaraztea.
2. Aurreranzko hedapena ezartzea.
3. Kostu-funtzioa ezartzea.
4. Atzeranzko hedapena ezartzea deribatu partzialak kalkulatzeko.
5. Aurrerazko eta atzeranzko hedapena egitea entrenamendu-datuak erabiliz.
6. Beheranzko gradientearen erabiltzea atzeranzko hedapenarekin, $J(\theta)$ minimizatzen saiatzeko, θ parametroen arabera.

Sare neuronal egonkor bat lortzeko, aurreranzko eta atzeranzko hedapena eta beheranzko gradientearen pausoak behin eta berriz errepikatu beharko dira nahi diren emaitzak lortu arte.

4. DEGRADAZIO-EREDUEN GARAPENA ETA TRANSFERENTZIA BIDEZKO IKASKUNTZA

Lan honen helburua da Li-ioi bateria baten bizi-itxaropena iragartzeko gai den ikaskuntza automatikoko eredu bat eraikitzea, transferentzia bidezko ikaskuntzaren teknika aplikatuta. Eredu honek bateriaren egutegiko degradazio-efektuak ikusiko ditu bakarrik, ziklatzean ematen diren degradazio-mekanismoak alde batera utzita.

Transferentzia bidezko ikaskuntza-eredu on bat lortzeko, eta eredu hori ona dela ziurtatzeko, datu-matrize zabal bat izan behar da, eredua doitu eta frogatu ahal izateko eta bateriaren erabilpen-leiho zabal batean eredu hori baliagarria den edo ez ikusteko.

4.1 Erabilitako datuak

Lan honetan, bi bateria motarekin egingo da lan. Bateria motetako batean, NMC zelulei dagokien horretan, datu-base zabal bat dago, eta erabilpen-baldintza bakoitzean hiru bateria frogatu dira. Hala, hurrengo taulan (Taula 4) ikus daitekeen bezala, tenperatura eta SOC (degradazio-faktore nagusiak egutegian) bakoitzari dagokion egoeran hiru bateriaren datuak izango dira.

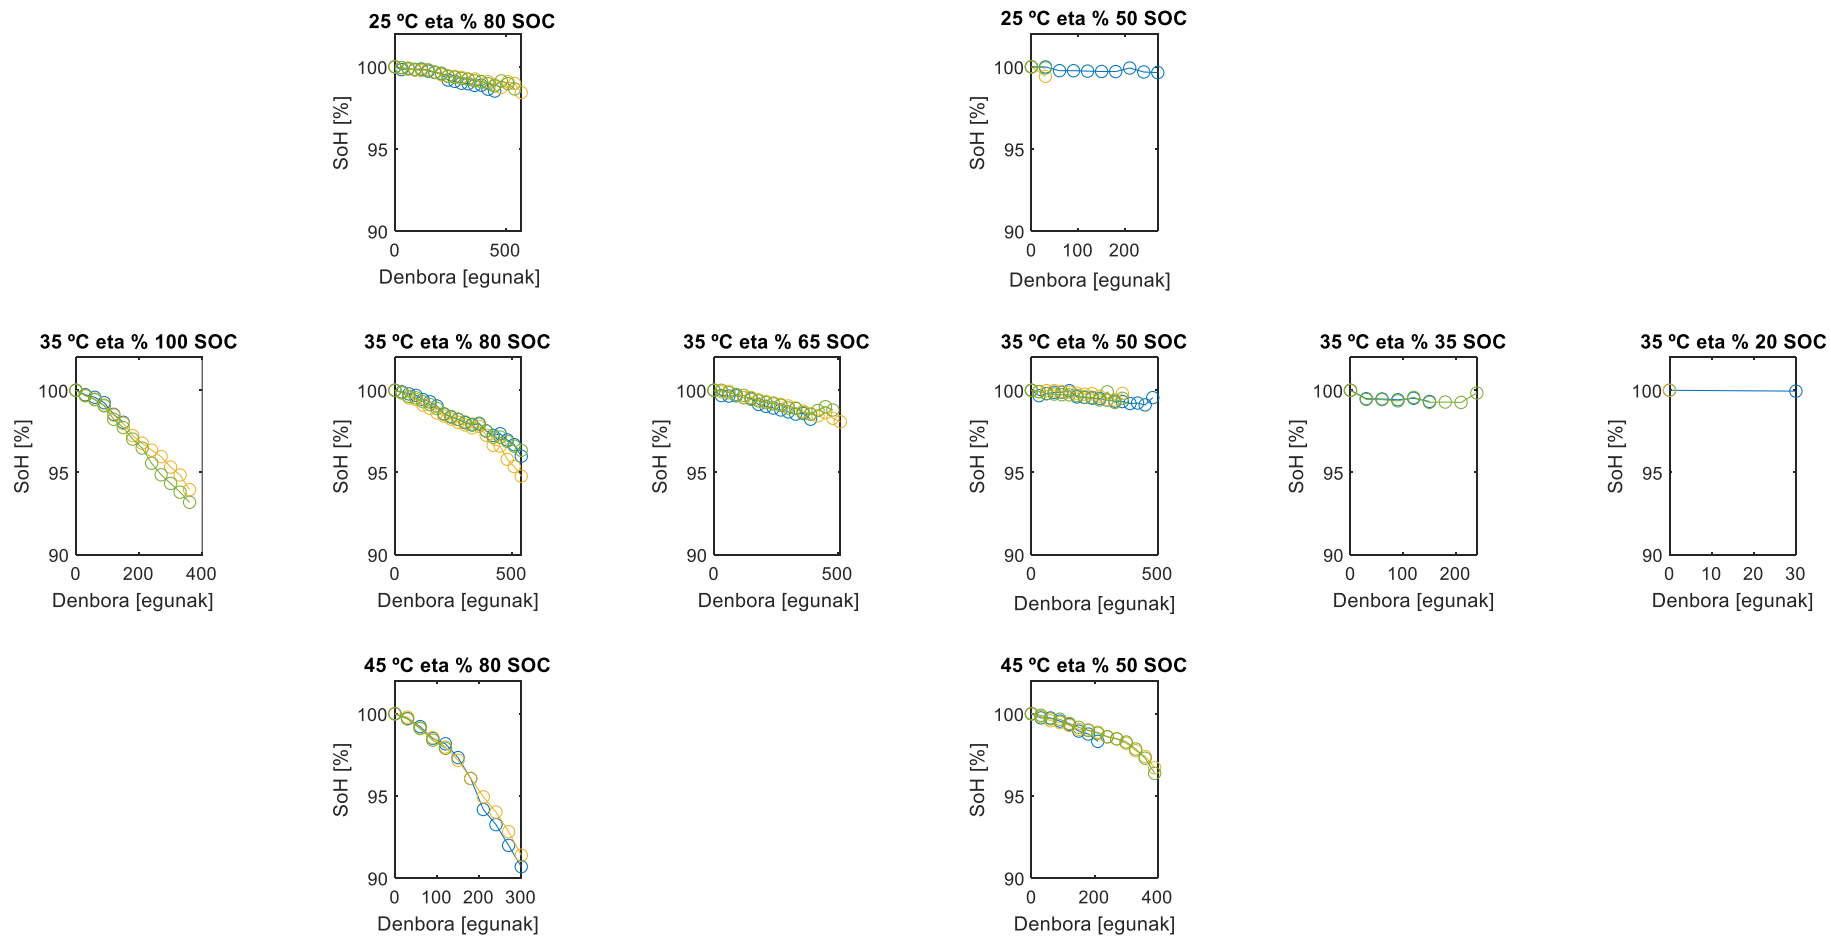
Taula 4. NMC zelulak frogatu diren baldintzak

T \ SOC	% 100	% 80	% 65	% 50	% 35	% 20
25 °C		•		•		
35 °C	•	•	•	•	•	•
45 °C		•		•		

Aurreko taulan (Taula 4) ikus daitekeen bezala, NMC zelulak 10 egoeratan frogatu dira; horrek esan nahi du 30 zelula frogatu direla guztira.

Hurrengo irudian (Irudia 15), 30 zelula horiei dagokien degradazio-kurbak ikus daitezke. Zelulen degradazio-kurbak hirunaka taldekatu dira frogatu diren erabilpen-baldintzen arabera.

Aurreko taulan (Taula 4) ikus daitekeen bezala, zelulak hiru tenperatura ezberdinetan frogatu dira, 25 °C-an, 35 °C-an eta 45 °C-an. Bestalde, 6 SOC ezberdinetan frogatu dira. Hiru tenperaturek bi SOC balio ezberdin partekatzen dituzte, % 80 eta % 50. Aldiz, 35 °C-an beste 4 SOC balio daude, % 100, % 65, % 35 eta % 20.



Irudia 15. NMC zelulen degradazio-kurbak

Aurreko irudian (Irudia 15) baldintza berdinean frogatu diren (tenperatura eta SOC berdina) hiru zelulen portaera oso antzekoa dela ikus daiteke; hau da, hiru zelulek joera berdina edo oso antzekoa jarraitzen dutela ikus daiteke.

Temperaturaren eta SOCaren eragina ikus daiteke. SOC altuetan eta tenperatura altuetan zelulen balio-bizitzak azkarrago behera egiten duela ikusten da.

Azkenik, grafiko horrek (Irudia 15) erakusten duen bezala zelulek izaten duten hasierako irabazpena eta bizitzaren bukaeran ematen den degradazioaren azkartzea (ukondoa) alde batera utzi dira, modelatu nahi diren degradazio-mekanismoak ez datozelako bat horiekin.

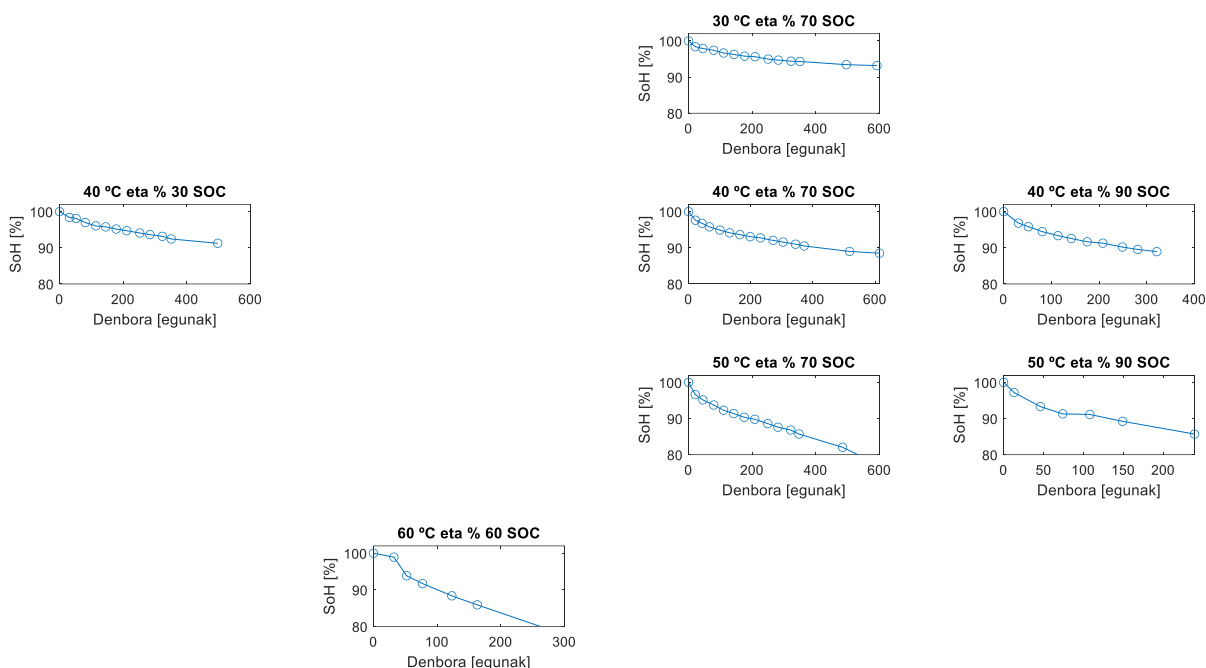
LFP zelulen kasuan, aldiz, baldintza bakoitzeko zelula bakarra frogatu da eta, hurrengo taulan (Taula 5) ikus daitekeen bezala, 7 baldintzatan frogatu dira. Ikus daiteke baldintza horietako bakar batek ere ez duela bat egiten NMC zelulak frogatu diren baldintzekin.

Taula 5. LFP zelulak frogatu diren baldintzak

T \ SOC	% 90	% 70	% 60	% 30
30 °C		•		
40 °C	•	•		•
50 °C	•	•		
60 °C			•	

Aurretik aipatu den bezala, datu-basea askoz ere txikiagoa da LFP zelulen kasuan NMC zelulen kasuan baino. Hori dela eta, aproposa da ikaskuntzaren transferentzia aplikatzeko. Datu gutxi izateak algoritmoa SOH kurba horretara gaizki moldatzea ekar lezake eta.

Hurrengo irudian (Irudia 16) ikus daitekeenez, LFP zelulen degradazio-kurba eta NMC zelulena (Irudia 15) ezberdinak dira. Hasieran, SOHa azkar erortzen eta, gero, kurba hori linealagoa eta lauagoa da.



Irudia 16. LFP zelulen degradazio-kurbak

NMC datuen kasuan, ezaugarritze-testak 30 egunean behin eginda zeuden. Aldiz, LFP datuen kasuan, ezaugarritze-testetik ezaugarritze-testerako denbora-tartea ezberdina da; 25 egunetik 150 egunerainoko tartea egon daiteke, hain zuzen ere.

Aipatutako datuak bi multzotan banatu dira. Batetik, sarrerako datuak; datu horiek sare neuronalak elikatzeko erabiliko dira, eta lau aldagai izango dira: Δt (ezaugarritze-testetik ezaugarritze-testera igarotako denbora, egunetan), T (zelula tarte horretan egon den temperatura, °C-an), SOC (zelularen karga egoera tarte horretan, %-tan) eta Q (bateriaren balio-bizitzaren balioa tarte hori hasi aurretik, %-tan). Bestetik, irteerako datua; hau da sare neuronala iragartzen saiatuko den balioa. Kasu honetan, aldagaia ΔQ izango da (aipatutako denbora tartean bateriak galdu duen gaitasuna, %-tan).

Erabiliko diren datuak azaldu ondoren, LFP zelulentzat transferentzia bidezko ikaskuntza-teknika erabiliz eredu bat lortu den arte jarraitu diren pausoak azalduko dira.

Lehenik eta behin, NMC zelulekin ikaskuntza automatikoko eredu zehatz bat eraiki da. Horretarako, aurrerago ikusiko den bezala, hainbat froga egin behar izan dira; hala nola, sare neuronalaren tamaina ezberdinak frogatzea, ezkutuko geruzetan neurona kopuru ezberdinak jartzea eta erregularizazio-balio ezberdinak frogatzea.

NMC zeluletarako ereduak garatu ondoren, LFP zelulekin bakarrik entrenatutako eredu bat egin da. Kasu honetan ere, aurreko kasuan aipatu diren zenbait froga egin dira.

Azkenik, ikasketaren transferentzia erabiliz LFP zelulentzako eredua lortzeko asmoarekin, NMC eredutik abiatuta, LFP zelulen datuen zati bat erabilia, LFP zelulen degradazioa iragartzeko gai den eredu bat lortu da. Eredua baliagarria den ikusteko, hainbat froga egin dira.

Transferentzia bidezko ikaskuntza erabiltzearen arrazoia da LFP degradazio-datuetatik ahalik eta datu gutxien erabiltzea. Izan ere, datu horiek guztiak lortzeko, bateria ezberdinak baldintza ezberdinetan frogatu behar dira laborategian. Froga horiek guztiak egiteko, denbora asko eta instalazioak behar dira, horrek guztiak dakarren kostu ekonomikoa barne.

Matlabeko toolboxak hainbat sare neuronal konfigurazio dakartza, sarea nola erabiliko den. Kasu honetan sarea degradazio-kurbak doitzeko erabili nahi da. Horretarako, *Matlabek* "fitnet" sarea erabiltzea gomendatzen du [58].

Sare neuronala entrenatzeko orduan, *Matlabeko toolboxak* lehenetsita dakartzan balioak mantendu dira, jarraian aipatuko direnak izan ezik.

Entrenamendu/balioztatze/froga ehunekoa. Kasu honetan, aldiz, aurretik aipatu den bezala, sare neuronalean sartuko diren datuen % 85 entrenatzeko izango dira eta % 15 balioztatzeko. Frogatzea aparteko datuekin egingo da.

Kostu-funtzioa. Propietate honek sarearen errendimendua neurtzeko erabiltzen den funtzioa definitzen du. Errendimendu-funtzioa entrenamenduan zehar sareak duen errendimendua kalkulatzeko erabiltzen da. Kasu honetarako interesgarriagoa da MAE edo batez besteko errore absolutua erabiltzea, iragarpena benetako baliotik zenbat aldentzen den erakutsiko du-eta.

Entrenamendu-funtzioa. Propietate horrek sarea entrenatzeko erabiltzen den funtzioa definitzen du. Kasu honetan, sare neuronaletan horren hedatua dagoen gradiente-jaitsiera erabili da, aldaketa batzuekin erabili ere. Kasu honetan gradiente-jaitsiera horrek momentua eta ikaskuntza-abiadura egokitzaila izango du. Algoritmoak era efiziente eta azkarrago batean entrenatu dezan.

Aktibazio-funtzioak. Sarearen lehenengo hiru geruzetan tangente hiperbolikoko aktibazio-funtzioa erabili da. Aldiz, azkeneko geruzan, hau da, irteerako geruzan, aktibazio-funtzio lineala erabili da.

Jarraian, aurretik aipatu diren pauso horiek guztiak xehe-xehe aztertuko dira.

4.2 NMC eredua

Aurretik aipatu den bezala, transferentzia bidezko ikaskuntza-eredu zehatz bat lortzeko, lehenik eta behin, horrek oinarri izango dituen NMC zelulekin ikaskuntza automatikoko eredu on bat sortu behar da.

Lehenengo pauso honetan, eredia entrenatzeko zenbat eta zein datu erabiliko diren aukeratu da datu-basetik. Hurrengo taulan (Taula 6) ikus daitekeen bezala, NMC zelulen datu-basetik hiru tenperatura erabili dira eta bi SOC (taulan, puntu urdinak), hiru tenperaturek partekatzen dituztenak; hau da, % 50 eta % 80 SOC hiru tenperaturatan. Beraz, 6 baldintza ezberdin erabili dira.

Taula 6. Datu-basearen zatiketa

T \ SOC	% 100	% 80	% 65	% 50	% 35	% 20
25 °C		•		•		
35 °C	•	•	•	•	•	•
45 °C		•		•		

Datu horietatik % 85 sare neuronalak entrenatzeko erabiliko da eta % 15 sare hori balioztatzeko. Falta diren 4 baldintzak sare neuronalak frogatzeko erabili dira (taulan puntu moreak).

4.2.1 Dimentsionatzea

NMC zelulek osatzen duten matrizea deskribatzen duen degradazio-eredua lortzeko egin den lehenengo froga sarearen dimentsionatzea izan da. Sarea ondo dimentsionatu behar da. Izan ere, tamaina handiko sareek parametro gehiago dituzte kurba doitzeko, eta, horrek, baldintza jakin batzuetan, sareak gaindoiketa jasatea eragin dezake. Aldiz, gerta daiteke tamaina txikiko sare bat datuak doitzeko sinpleegia izatea. Ondorioz, datuen azpidoiketa emango da, sareak dituen parametro kopuru urria dela eta.

Horretarako, 1x1etik 15x15erainoko sare neuronalak entrenatu eta frogatu dira. Erabilitako sare neuronalaren konfigurazioa karratua izan da beti; hots, sarearen geruza kopurua eta geruza bakoitzak duen neurona kopurua berdinak izan dira. Hau da, sarea 6x6koa bada, sareak 6 geruza ditu eta geruza bakoitzean 6 neurona daude.


Lehenengo froga honetan, sare neuronalaren tamaina bera 25 aldiz errepikatu da emaitzak ahalik eta fidagarrienak izateko; izan ere, entrenamendutik entrenamendura, sarearen barne-balioak, hots, neuronatik neuronara dauden pisuak ausaz inzializatzen dira.

Hurrengo irudian (Irudia 17) hiru grafiko daude. Goikoa entrenamenduko zelulei dagokiena da. Erakusten duenez, iragarpen-balioaren batez besteko MAE errorea 0,5 inguruan dago, hau da, ΔQ -rekiko errorea % 0,5 izan da. Erdiko grafikoak frogatzeko erabili diren zelulen batez besteko MAE errorea erakusten du. Lortutako emaitza entrenamenduko emaitzen antzekoa da. Horrek esan nahi du algoritmoa ikasitako datuak eta inoiz ikusi ez dituen datuak antzekoa den errore-balioarekin iragartzeko gai

delat. Azkeneko grafikoak zelula guztien batez besteko MAE errorea erakusten du; hau da, entrenatzeko erabili diren zelulena eta frogatzeko erabili diren zelulena.

Hurrengo irudi horretan bertan ere (Irudia 17) ikus daitekeenez, sarearen tamainak ez du eragin handirik lortutako emaitzetan, nahiko egonkorak dira-eta. Baina, ahal den neurrian, sarearen tamaina ahalik eta txikiena izatea gomendatzen da; hartara, datu gehiago izango dira sarearen barneko pisu horiek doitzeko. Gainera, entrenamendua egiteko behar den denbora murriztuko da.

Bestalde, ikus daitekeenez, entrenamenduan okerren egin duten tamainak frogatzean ere okerren egin dutenak izan dira. Adibidez, 12x12ko sarea okerrena izan da bai entrenamenduan, bai frogatzean; beraz, sarea ez da gai izan beste kasuetan bezain ondo ikasteko degradazio-mekanismoen eragina.




Irudia 17. NMC zelulen ΔQ errorea sarearen tamainaren arabera

Aurretik aipatu den moduan, sarea ahalik eta txikien mantendu behar da datuak ahalik eta modu egokienean erabili ahal izateko. Kasu honetan, guztira 660 daturekin ari da entrenatzen sare neuronalak. Sarea 8x8koa baino handiagoa bada, parametro kopurua (alegia, sareak egokitu behar dituen neuronen arteko pisu kopurua) datu kopurua baino handiagoa izango da. Ondorioz, sareak gaindoitzeko joera izango du edo neuronen arteko pisua egokitu gabe geldituko da. Aldiz, 3x3ko sare neuronalak aukeratzen bada, parametro bakoitza 20 daturekin entrenatuko da, eta MAE errorea gutxitu egingo da.

Sare neuronalaren tamaina aukeratzeko, eta ΔQ -ren erroreak informazio handirik ematen ez duela ikusita, sareak egiten duen iragarpenaren errore metatua aztertu da, hau da, Q -ren errorea.

Hurrengo grafikoan (Irudia 18) ikus daitekeenez, errore honek informazio gehiago ematen du sare neuronalaren iragarpen-gaitasunaren inguruan. Entrenamenduaren grafikoan ikus daitekeenez, sarea gai da kasu guztietan entrenamenduko informazioa ondo ikasteko eta iragarpen onak egiteko. Aldiz, frogatzearen grafikoak erakusten duenez, sareak ikusi ez dituen datuetan errorea oso aldakorra da. Sarearen tamaina oso txikia denean edo oso handia denean, sarea ez da gai ikusi ez dituen erabilpen-baldintzak zehatz-mehatz iragartzeko. Aldiz, 3x3ko saretik 5x5eko sarera, sareak ikusi ez dituen baldintzetan iragarpen-gaitasun zehatza duela ikus daiteke; are gehiago, Q errorea, % 1 baino txikiagoa da.



Irudia 18. NMC zelulen Q errorea sarearen tamainaren arabera

Beraz, grafiko hori ikusita 3x3ko sarearekin jarraitzea erabaki da, tamaina egokia delako eta lortutako emaitzak egindako frogen artean onenak izan direlako.

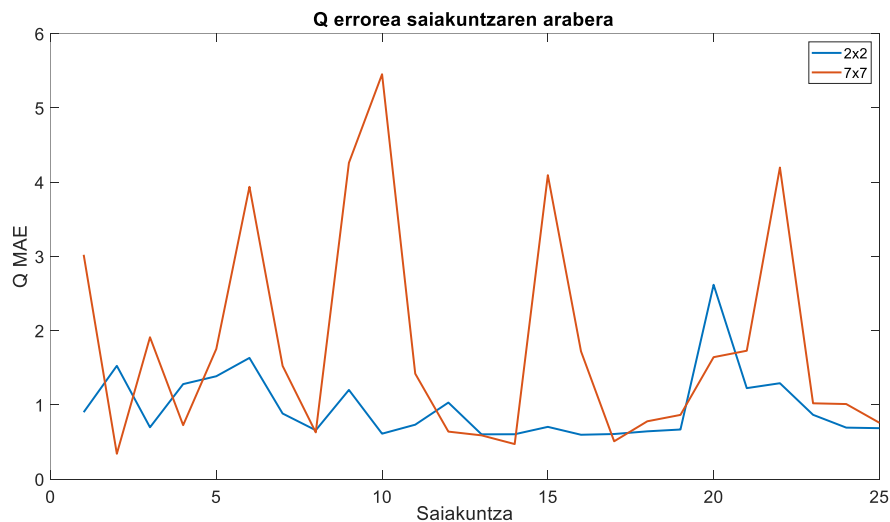
4.2.2 Erregularizazioa

Aurretik aipatu den bezala, sarea zenbat eta handiagoa izan, orduan eta datu gutxiago izango dira parametroen balioak egokitzeko. Ondorioz, emaitzek errore handiagoa izango dute eta sortutako sare neuronala ezegonkorragoa izango da.

Hasierako parametroen balioak ausazkoak dira, eta horrek entrenamendutik entrenamendura aldaketak egotea ekarriko du. Zenbat eta handiagoa izan tamaina,

orduan eta handiagoa izango da sareak parametroak egokitzeko egin beharreko lana, eta okerrago egokituko ditu parametroak, datu gutxiago dituelako parametroak doitzeko eta parametro kopuru handiagoa izango duelako doitzeko.

Ondorioz, entrenamendutik entrenamendura lortzen diren emaitzak aldakorragoak izango dira. Hori guztia hurrengo grafikoan (Irudia 19) ikus daiteke.

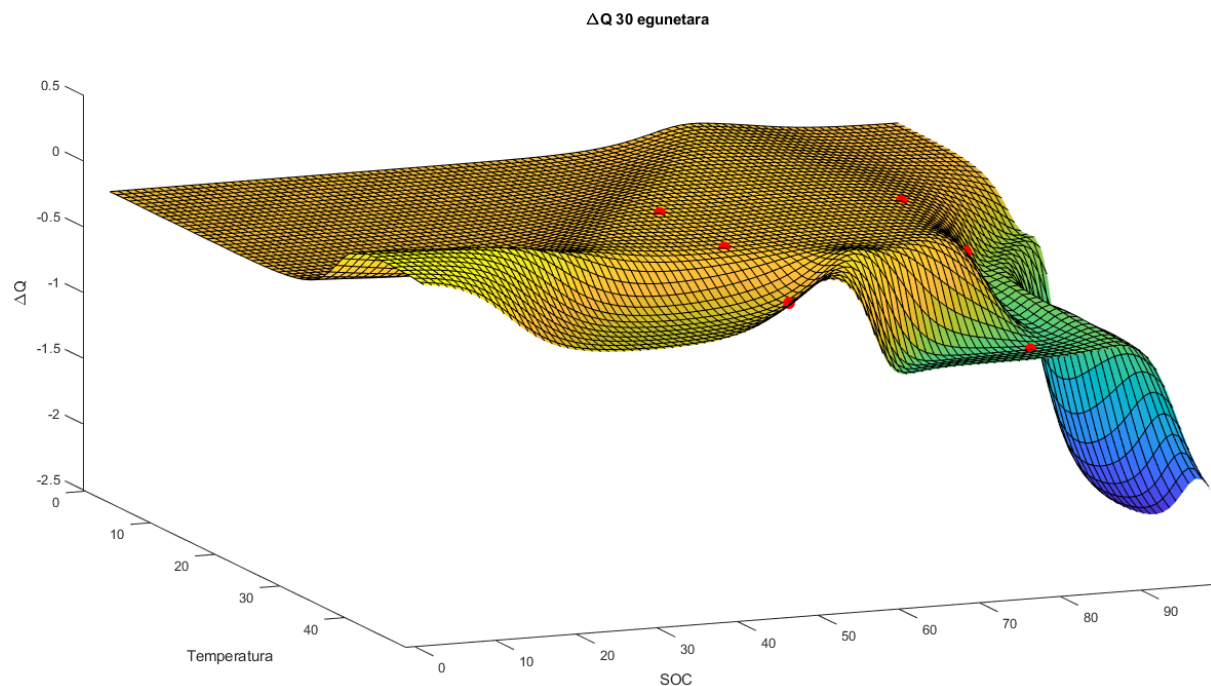


Irudia 19. Entrenamendu ezberdinen emaitzen aldakortasuna sarearen tamainaren arabera

Irudian bi sare tamaina ezberdinen 25 entrenamendu ezberdinen Q errorea azaltzen da. Sareak 2x2koa eta 7x7koa dira. 7x7ko sarean, entrenamendutik entrenamendura ematen den errorearen aldaketa 2x2ko sarean ematen dena baino aldakorragoa da; hots, sarea ezegonkorragoa da eta hasierako parametroen balioarekiko mendekotasun handiagoa izango du.

Aurreko irudietan (Irudia 17 eta Irudia 18) ikusi da sarearen tamainak ez duela eragin handirik entrenamenduetako datuetan; hau da, frogatzeko datuetan ez bezala, entrenamendu-datuetan errorea beti antzekoa da. Hori gertatzen denean, sarean gaindoitzea gertatzen ari dela esan nahi du.

Jarraian dagoen 3D irudian (Irudia 19) SOC eta tenperaturaren arabera 30 egunetara ematen den gaitasun-galera ikusten da, 7x7ko sare neuronalaren 10. entrenamenduan. 3D irudi horretan, hortaz, gaindoitzea duen sare neuronal baten emaitzak agertzen dira.



Irudia 20. Gaindoiketa duen sare neuronal

Puntu gorriak sare neuronalaren entrenamendu-baldintzei dagozkie. Puntuei dagozkien datuek, aurreko irudian (Irudia 17) ikusten den bezala, errore txikia dute. Aldiz, puntu horietatik kanpo (frogatze-baldintzak), errorea handiagoa da, eta iragarpen txarrak egiten dira.

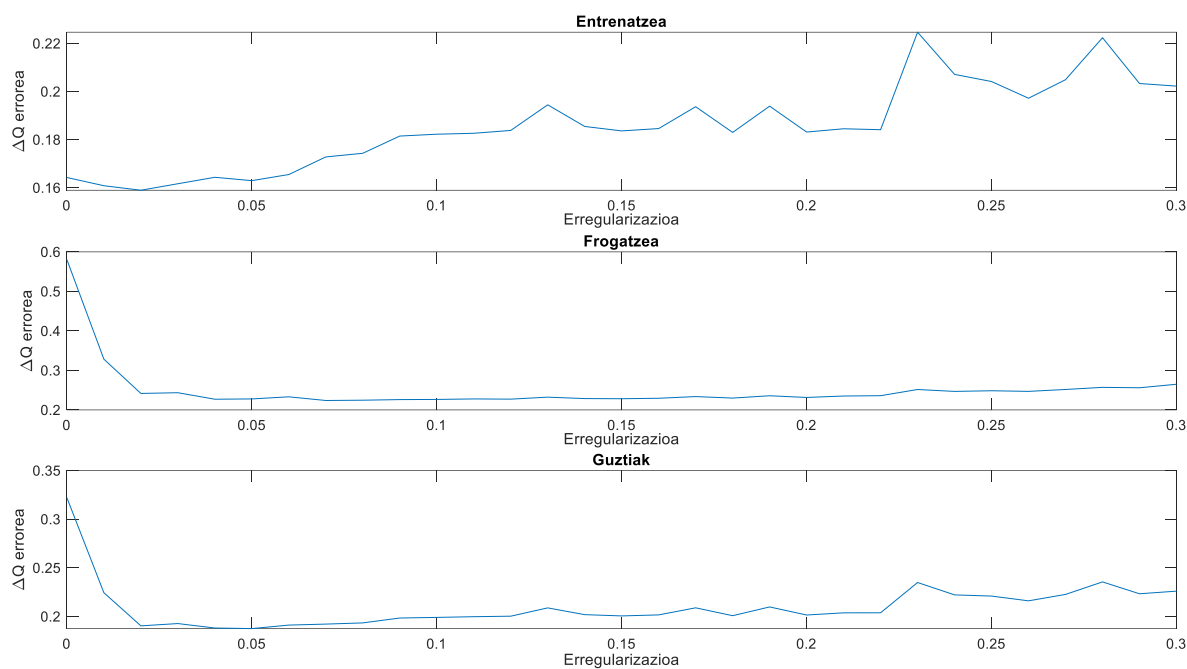
Aurreko irudian (Irudia 20) ikus daitekeenez, gaitasun-galera erakusten duen azalera fluktuatu egiten du. Aurrerago ikusiko den moduan, azalera horrek askoz ere lauagoa izan beharko luke, eta ez litzuke forma horiek izan beharko.

Gaindoitzea ematen denean, sarearen konfigurazioa aldatu egin beharko da hori ekiditeko. Hauek egin beharko dira, esate baterako: erregularizazio-metodoak erabili edo ezaugarrien kopurua gutxitu, edota sarearen tamaina gutxitu. Kasu honetan, gaindoitzea erabiliko da.

Sarearen tamaina aukeratuta eta sare horrek izan ditzakeen arazoak ikusita, hurrengo pausoa erregularizazioaren balio on bat aukeratzea izan da. Horretarako, sare neuronal bera, hasierako balio berberak dituena, erregularizazio-balio ezberdinekin entrenatu da.

Lehenengo pauso batean erregularizazioa 0tik 0,3ra frogatzen joan da 0,01eko igoerarekin. Froga horren helburua da erregularizazioaren balio tarte optimoa bilatzea, errore txikiena duen sare neuronal lortzeko eta sarearen doiketa- eta orokortze-gaitasunen arteko oreka egokia lortzeko.

Hurrengo irudian (Irudia 21) ikus daitekeenez, entrenatze-zelulen erroreak gora egiten du erregularizazioaren balioak gora egiten duen neurrian. Aldiz, frogatze-zelulen erroreak behera egiten du hasiera batean eta, behin minimora iritsita, malda txiki batekin gora egiten du. Zelula guztien errorea kontuan hartzen bada, erregularizazio-balio optimoena 0,02ren eta 0,07ren artean egongo dela dirudi.

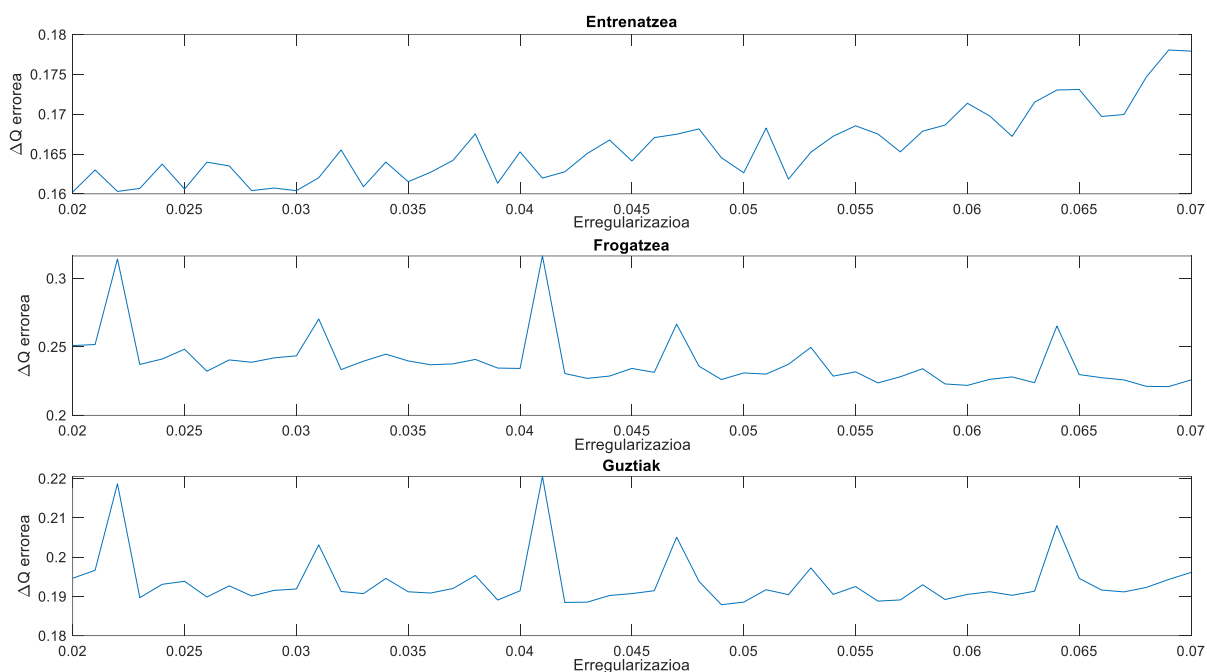


Irudia 21. NMC ereduaren errorea, erregularizazioa 0tik 0,3ra 0,01eko igoerarekin

Bigarren froga bat egin da erregularizazio-balio optimoa bilatzeko. Kasu honetan, erregularizazio-balioa 0,02tik 0,07ra frogatu da 0,001eko igoerarekin. Froga horren helburua da erregularizazio-balio optimoa bilatzea; alegia, errore txikiena izango duena.

Erregularizazio-balioa ahalik eta txikiena izatea nahi da horrek dakarren penalizazioa ahalik eta txikiena izateko. Hurrengo irudian (Irudia 22) ikus daitekeenez, aurreko kasuan bezala, entrenamenduan errorea erregularizazio-balioak gora egin ahala gora egiten du. Frogatze-zelulen erroreak behera egiteko joera dauka erregularizazioak gora egiten duen neurrian.

Aldiz, zelula guztien grafikoak erakusten duenez, errorea nahiko konstante mantentzen da tarte oso horretan, puntu jakin batzuetan izan ezik.



Irudia 22. NMC ereduaren errorea, erregularizazioa 0,02tik 0,07ra 0,001eko igoyerarekin

Aurretik aipatu den bezala, erregularizazio-balioa ahalik eta txikiena izatea nahi da. Tarte osoko minimoa ez den arren, minimoak duen errore-balio oso antzekoa duen puntua aukeratu da erregularizazio-balioztat, errore txikia duelako eta erregularizazio-balioa txiki delako. Beraz, aurrerantzean NMC zelulentzat entrenatuko diren sare neuronalek 0,026ko erregularizazio-balioa erabiliko dute.

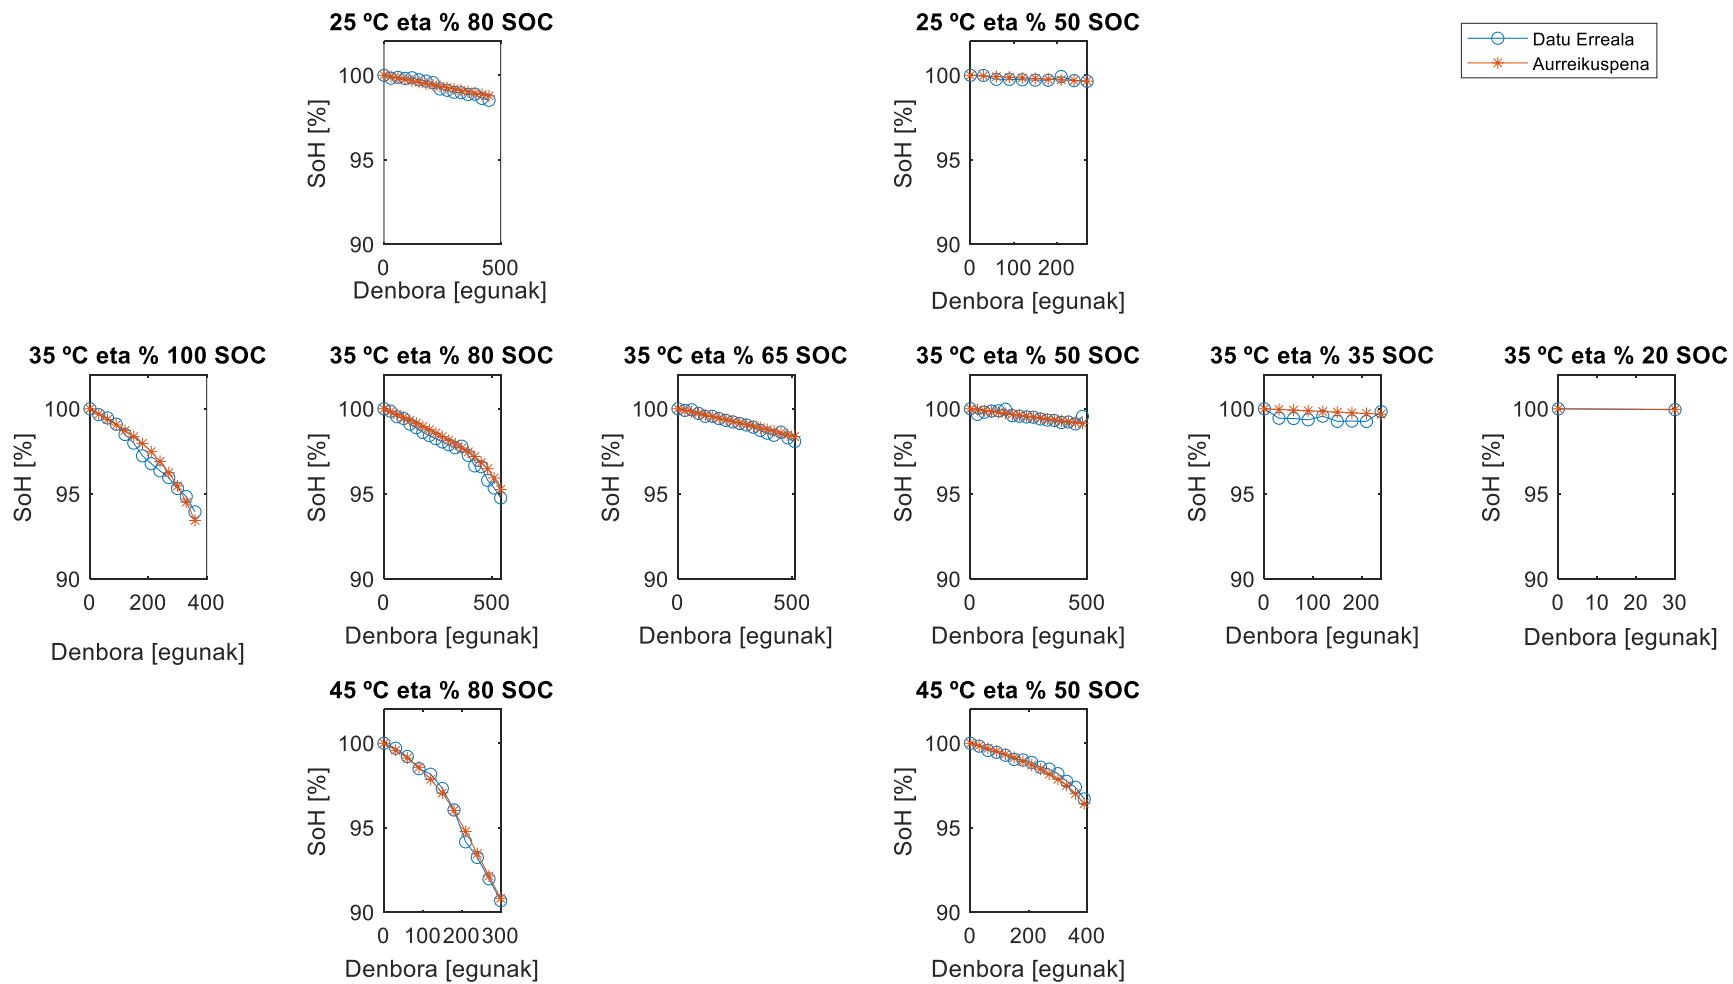
4.2.3 NMC ereduaren emaitzak

Beraz, eraikitako sare neuronala 3x3koa izango da eta 0,026ko erregularizazio-balioa erabiliko du. Bestalde, entrenamendu-funtzioa gradiente-jaitsiera momentua eta ikaskuntza-abiadura egokitzailearekin izango da, eta errendimendu-funtzioa batez besteko errore absolutua izango da.

Behin sare neuronalaren propietateak aukeratuta, sare neuronal hori 100 aldiz entrenatu da horietatik onena aukeratzeko, hori izango baita transferentzia bidezko ikaskuntza egiteko erabiliko den oinarritzko sare neuronala. Izan ere, froga horren bitartez, hasierako parametro egokienak topatu nahi dira, parametroen esleipena ausaz egiten baita.

Hurrengo irudian (Irudia 23), aurretik aipatutako propietateekin entrenatutako sare neuronalek ematen dituen iragarpenak ikus daitezke. 100 entrenamenduetatik emaitza onenak erakusten dituen sare neuronala aukeratu da.

Irudian, baldintza bakoitzeko zelula bakarraren datu errealak eta iragarpenak agertzen dira, irudiak hobeto ulertu ahal izateko.



Irudia 23. NMC zelulen degradazio-kurbaren iragarpena


Hurrengo taulan (Taula 7), entrenatzeko eta frogatzeko errore-datuak eta zelula guztien errore-datuak ematen dira. Ikus daitekeenez, bi aldagairekiko kalkulatu da errorea: Q eta ΔQ .

Taula 7. NMC ereduaren errorea

Errorea (MAE)	Entrenamendua	Frogatzea	Guztiak
ΔQ	0,16	0,23	0,18
Q	0,14	0,20	0,16

Sare neuronal honek, inoiz ikusi ez dituen baldintzetan, % 0,23ko errorea dauka ΔQ -rekiko eta % 0,20koa Q -rekiko. Errorea % 1etik beherakoa bada, sare neuronalak iragarpenak egiteko gaitasun oso ona dauka. Hori horrela, NMC zelulentzat lortutako sare neuronalak egokia dela esan daiteke.

Lortu berri den sare neuronalaren 3D irudi berdina egiten bada, hurrengo irudia (Irudia 24) lortuko da.



Irudia 24. Behin betiko NMC eredu

Kasu honetan ere puntu gorriek entrenamendu-puntuak non dauden azaltzen dute. Irudi honetan ikus daiteke, aurrekoan ez bezala, azalerak ez duela fluktuazio arrarorik egiten; aitzitik, leuna da azalera. Ondoriozta daiteke, beraz, sare honek ez duela gaindoitzerik.

4.3 LFP ereduak

NCM ereduarekin egin den bezala, LFPko zelulen datuak bakarrik erabiliz, ahalik eta eredu zehatzena sortu da. LFP eredu hau eraikitzeke helburua da ondoren transferentzia bidezko ikaskuntza erabiliz egingo den sare neuronalarentzat erreferentziatzeko zehaztasun-balio batzuk edukitzea.

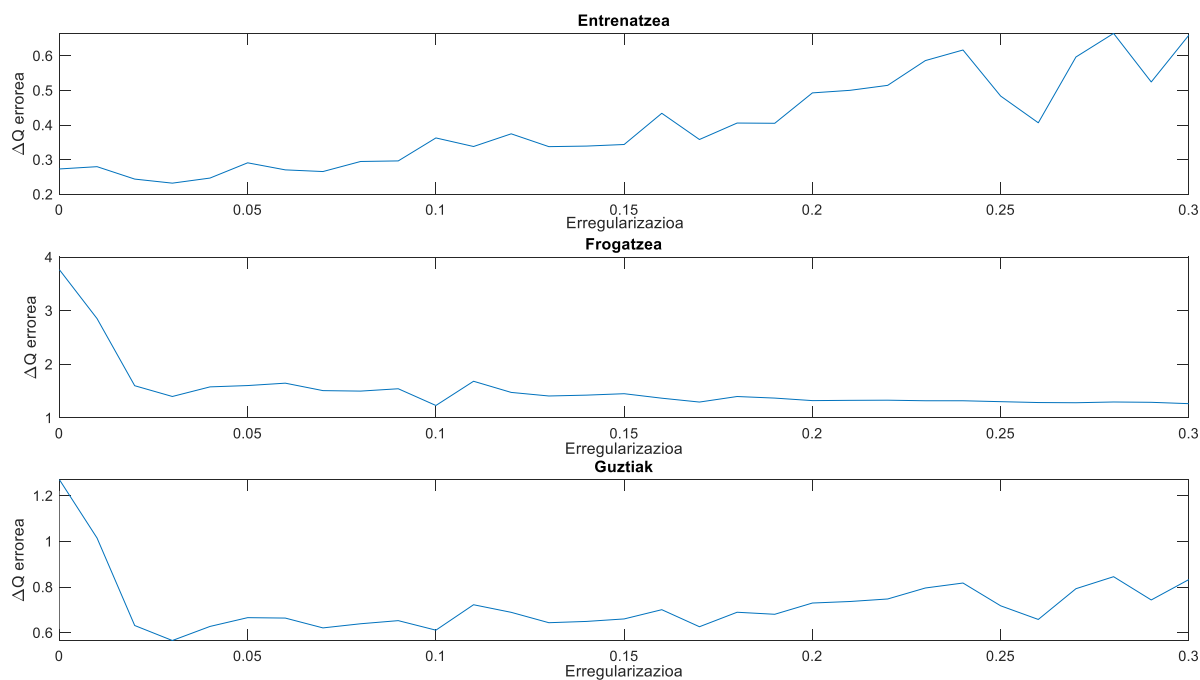
LFP ereduak sortzeko, NMC ereduak eraikitzeke erabili den sare neuronalaren konfigurazioa berbera erabili da, erregularizazio-balioa izan ezik.

4.3.1 Erregularizazioa

3x3ko sare neuronalak erabiliko duen ereduak eraikitzeke egin den lehenengo urratsa erregularizazio-balioa aukeratzea izan da. Horretarako, erregularizazio-balioa 0tik 0,3ra aldatzen joan da 0,01eko igoserarekin. Erregularizazio-balio bakoitza 10 froga ezberdinetan errepikatu da.

Hurrengo irudian (Irudia 25) ikus daitekeenez, entrenatzean, erroreak gora egiten du erregularizazio-balioak gora egiten duen heinean. Aldiz, frogatzean, hasieran beherakada handi bat ematen da, erregularizazioak ezartzen duen penalizazio horrek sareak gaindoitzea ez izatea ekartzen duelako.

Zelula guztien grafikoa begiratzen bada, hasieran beherakada bat ikusten da, eta, minimo batera iritsi ondoren, erroreak berriz ere gora egiten du.




Irudia 25. LFP ereduaren errorea, erregularizazioa 0tik 0,3ra 0,01eko igoserarekin

Hori dela eta, minimoa zehazki non dagoen ikusteko, froga errepikatu egin da. Kasu honetan, erregularizazio-balio 0tik 0,05era frogatu da 0,001eko igoerarekin, eta froga bakoitza 10 aldiz errepikatu da berriz ere.

Bigarren froga honetatik bi ondorio atera dira. Alde batetik, froga batetik bestera aldakortasun oso handia dagoela. Izan ere, frogok egiteko LFP zelulen datu gehienak erabili diren arren, sarea entrenatzeko datuak urriak dira. NMC zelulentzako sarea eraiki denean ikusienez, 3x3ko sarea erabiliz gero, sare horren pisu bakoitza doitzeko 20 datu izango dira; aldiz, pisu bakoitza doitzeko 4 datu baino gutxiago daude.

Bigarrena erregularizazio-balioa da. Kasu honetan, hurrengo irudia (Irudia 26) ikusita erregularizazio-balio on bat aukeratzea ez da hain argia. Hala ere, NMC eredu irizpide berak jarraitu dira, hau da, ahalik eta erregularizazio-balio txikiena erabiltzea sareari ezartzen zaion penalizazioa ahalik eta txikiena izateko. Ondorioz, aukeratutako erregularizazio-balioa 0,021 izan da.



Irudia 26. LFP ereduaren errorea, erregularizazioa 0tik 0,05era 0,001eko igoerarekin

Behin erregularizazio-balioa aukeratua, transferentzia bidezko ikaskuntza egiten denean erreferentzia bat izateko asmoarekin, entrenamendu ezberdinak egin dira zelulak gehituz. Erabili den sare neuronalaren konfigurazioa berbera izan da froga guztietan.

4.3.2 Erreferentziazko LFP ereduaren garapena

Froga honetan, entrenamendu-datuak gehitzen joan dira. Hau da, hasiera batean zelula bakarrarekin entrenatu da zelula, eta, jarraian, bi zelulen datuekin. Hartara, banaka joan dira zelulen datuak gehitzen, zelula guztien datuak erabili arte.

Hurrengo taulan (Taula 8), baldintza bakoitzean frogatu den zelula bakoitzaren zelula izena agertzen da.

Taula 8. LFP zelulen izendapena

T \ SOC	% 90	% 70	% 60	% 30
30 °C		ZELULA01		
40 °C	ZELULA04	ZELULA03		ZELULA02
50 °C	ZELULA06	ZELULA05		
60 °C			ZELULA07	

Aurretik aipatu den bezala, bigarren froga honetan, zelulen datuak ereduaren entrenamendu datu-basean banaka integratzen joan dira, ordena jakin bat jarraikiz: 1/ ZELULA01-en datuak, 2/ ZELULA03-ren datuak, 3/ ZELULA02-ren datuak, 4/ ZELULA05-en datuak, 5/ ZELULA04-ren datuak, 6/ ZELULA06-ren datuak eta 7/ ZELULA07-ren datuak.

Lehenengo urratsean, ZELULA01-ekin entrenatu da sare neuronala. Lehenengo entrenamendu horretan sarea ez da gai izango SOCaren eta tenperaturaren eragina ikasteko; aldiz, Δt -ren eragina ikasten hasiko da, bai eta Q -rena ere. Bigarren urratsean, ZELULA03-ren datuak gehitu dira. Datu horiekin, tenperaturaren eragina ikastea espero da.

Hirugarren urratsean, ZELULA02-ren datuak gehitu dira; hala, sarea SOCaren eragina ikasten hasiko da. Laugarren urratsean, 'ZELULA05'-aren datuak gehitu dira, eta tenperatura berri bat gehitu da, tenperaturaren ikasketa indartze aldera. Bostgarren entrenamenduan, gauza bera egiten da, baina, kasu honetan SOCaren eragina hobeto ikasi da eta SOC balio berri bat gehitu da. Horretarako, ZELULA04-aren datuak gehitu dira.

Ondoren, ZELULA06-ren datuak gehitu dira. Horrek sareak tenperaturaren eta SOCaren inguruan duen ulermena indartzeko balioko du. Azkenik, ZELULA07-ren datuak gehitu dira, eta SOC eta tenperatura balio berriak sartu.

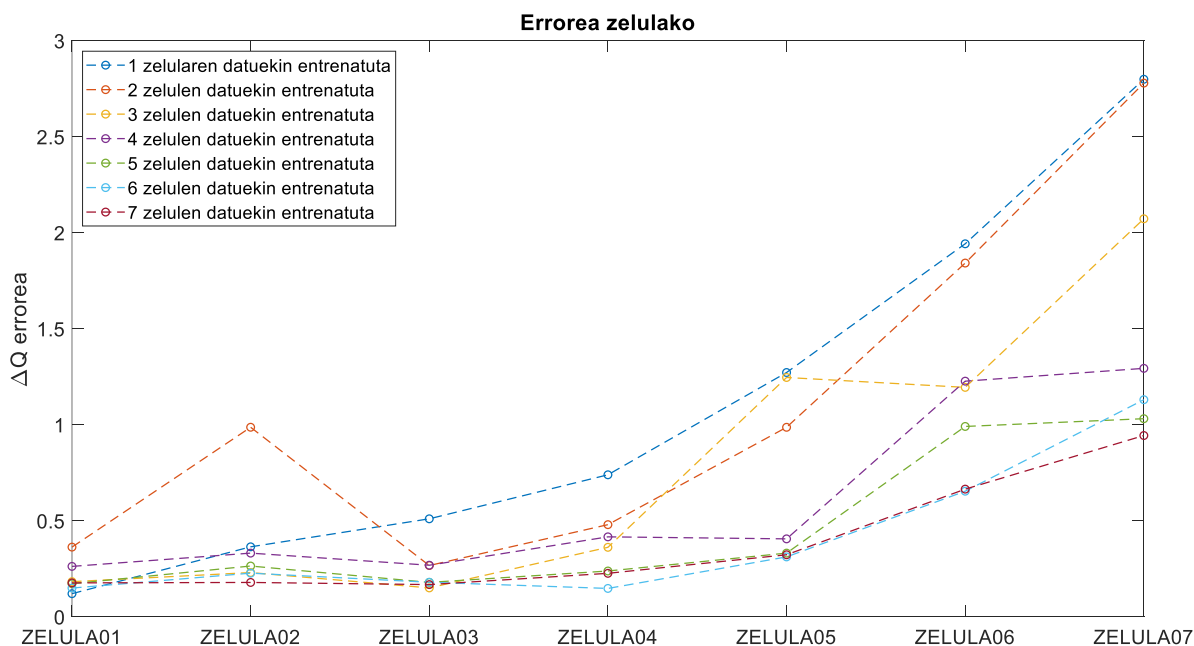
Hurrengo irudian (Irudia 27) egindako frogen emaitzak azaltzen dira. Bertan, froga eta zelula bakoitzean lortu den errorea ikus daiteke. Espero den bezala, datuak gehitzen diren heinean, errorea txikitu egiten da.

Zelula guztien datuekin edo 6 zelulen datuekin entrenatu den sare neuronalak emaitza onenak igortzen dituen ereduak da. Baina, errorea txikiena bada ere, ezin esan daiteke sarea ondo dagoenik, ez dagoelako sarea frogatzeko daturik, datu guztiak edo gehienak sarea entrenatzeko erabili direlako.

Bi irudietan bistaratutako emaitzak bat datoz, ikus daitekeenez. Kasu honetan ere argi ikusten da: sareak zenbat eta datu gehiago izan entrenatzeko, orduan eta emaitza onagoak emango ditu.

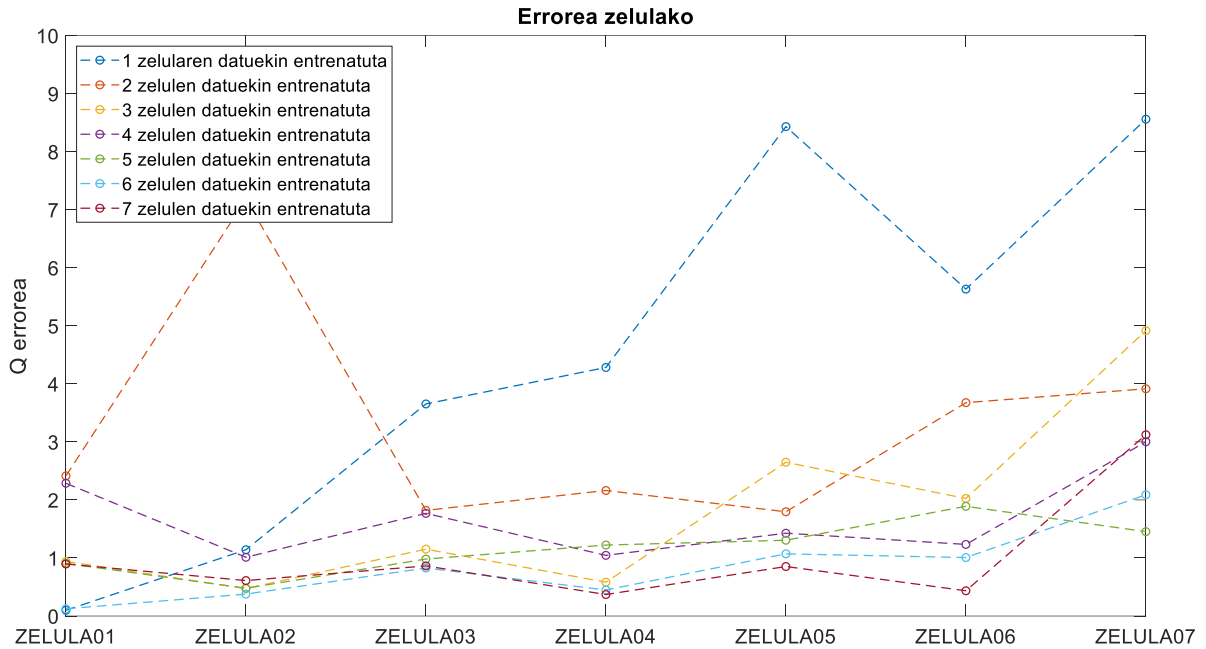
2 zelulekin entrenatutako sarean, ZELULA02ren errorea altua da. Errore horrek adierazten duenez, sareak ez du ondo ikasi SOCaren eragina SOC baxuetan, horren ondorioz sareak duen errorea altua da.

Bestalde, zelula bakarrarekin entrenatutako sareak ZELULA01en oso iragarpen onak ematen ditu, datu horiek baino ez dituelako doitu. Aldiz, baldintza horietatik kanpo, emaitzak okerrera doaz, sareak ez duelako ikasi ez SOCaren, ez tenperaturen eragina.



Irudia 27. LFP ereduaren ΔQ errorea zelulako, entrenamendu-datu ezberdinekin


Hurrengo irudian (Irudia 28) aurreko irudian agertzen den informazio bera ematen da; baina, kasu honetan, kalkulaturako errorea Q -rekiko dagoen errorea da, hau da, SOH-arekiko dagoen errorea.



Irudia 28. LFP ereduaren Q errorea zelulako, entrenamendu-datu ezberdinekin

LFP zelulen degradazio-kurba erakutsi den irudiaren arabera (Irudia 16), hasieran ematen den gaitasun-galera askoz handiagoa da; ondorioz, sareak hasierako uneetan iragartzen duen ΔQ galerak handiagoa izan beharko luke kurba hori egonkortu denean baino.

Hurrengo irudian (Irudia 29) argi ikus daiteke nola aldatzen den ΔQ -ren balioa zelularen SOHaren arabera 30 eguneko tarte batean. Kasu honetan, 5 zelularekin entrenatutako sarearen emaitzak bistaratzen dira. 3D grafikoek erakusten dutenez, sareak ez du gaindoikuntzarik jasaten, azalera leuna eta fluktuaziorik gabekoa da-eta.



Irudia 29. LFP degradazio-azalera SOH ezberdinetan

LFP eredu bi helbururekin egin dela aipatu da. Batetik, LFP datuekin bakarrik ahalik eta eredu zehatzena sortzeko eta, bestetik, transferentzia bidezko ikaskuntza erabiltzen denean emaitzak alderatzeko aukera izateko.

Sortu daitekeen eredu zehatzena hau da: zelula guztien datuak erabiltzen dituen. Nolanahi ere, esan bezala, ez litzateke daturik geldituko sare horren fidagarritasuna aztertzeko, eta, ondorioz, datu gutxiago erabiltzen dituen sare bat erabili behar da. Hori dela eta, 5 zelularekin entrenatutako sarea erabiliko da behin betiko LFP eredu gisa.

Hurrengo taulan (Taula 9), eredu horrek duen errorea ikus daiteke. Entrenamenduan errorea nahiko txikia den arren, frogako datuetan errorea handitzen dela ikus daiteke. Frogako zelulak ZELULA06 eta ZELULA07 dira. Sarea datu guztiekin entrenatu denean ere bi zelula horiek duten errorea handiagoa da (Irudia 27). Hain zuzen ere, zelulak laborategian frogatzeko orduan neurketa-erroreak egon daitezkeelako edo sarea ez delako gai kurba horiek doitzeko (datu gehiago behar dituelako edo sarearen tamaina ez delako egokia).

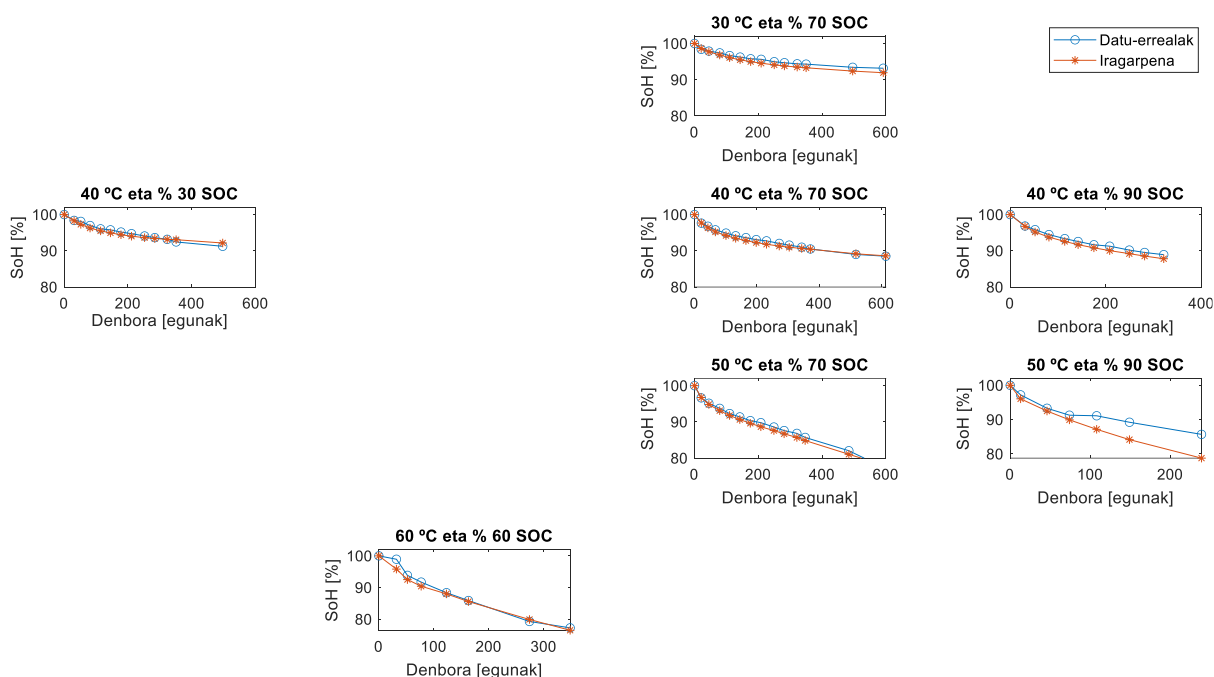
Taula 9. LFP ereduaren errorea

Errorea (MAE)	Entrenamendua	Frogatzea	Guztiak
ΔQ	0,24	1,01	0,46
Q	0,98	1,67	1,18

Azkenik, hurrengo irudian (Irudia 30), sareak egiten dituen iragarpenak ikus daitezke. Bertan, ikus daiteke orokorrean sareak ondo jarraitzen dituela degradazio-kurbak.

Espero den bezala, entrenamendu-datueta iragarpenak ondo jarraitzen du degradazio-kurba. Aldiz, ZELULA06 edo 50 °C-an eta % 90eko SOCean dagoen zelulan, iragarpena okerragoa da. Horren zergatia izan daiteke zelulak bat-bateko irabazpen bat duela; izan ere, 100 egun inguruan dagoenean, ez du gaitasunik galtzen aurreko ezaugarritze-testarekiko. Sareak, aldiz, zelula horrek dakarren joerari jarraitzea espero du. Hori dela eta, zelula honetan izan den errorea besteetan izan dena baino handiagoa da.

Bestalde, ikus daitekeenez, 60 °C-an eta % 60ko SOCean dagoen zelulak ondo jarraitzen du degradazio-kurba, eta, ondorioz, SOCaren eta tenperaturaren eragina estrapolatu egin dezake baldintza hauetara.



Irudia 30. LFP ereduaren degradazio-kurbaren iragarpena

4.4 Transferentzia bidezko ikaskuntza


Kapitulu honen hasieran aipatu den bezala, azken pausoa, NMC ereduatik abiatuta, LFP zelulen degradazioa iragarriko duen eredu bat sortzea da, LFP datuetatik ahalik eta datu gutxien erabiliz.

Sortutako eredu LFP eredu bezain ona edo hobea izatea espero da. Hau da, ΔQ -rekiko batez besteko MAE errorea % 0,45etik behera egotea espero da, eta SOH-rekiko % 1,2tik behera.

4.4.1 NMC ereduak transferentzia bidezko ikaskuntza gabe

Lehenik eta behin, NMC ereduak transferentzia bidezko ikaskuntza egin gabe LFPko datuekin lortzen dituen iragarpenak ikusi dira.

Hurrengo irudian (Irudia 31) ikus daitekeenez, lortutako emaitzak lortu nahi diren emaitzetatik urrun daude. Q -rekiko errorea % 2,95 da eta ΔQ -rekiko % 0,91 da, batez beste.

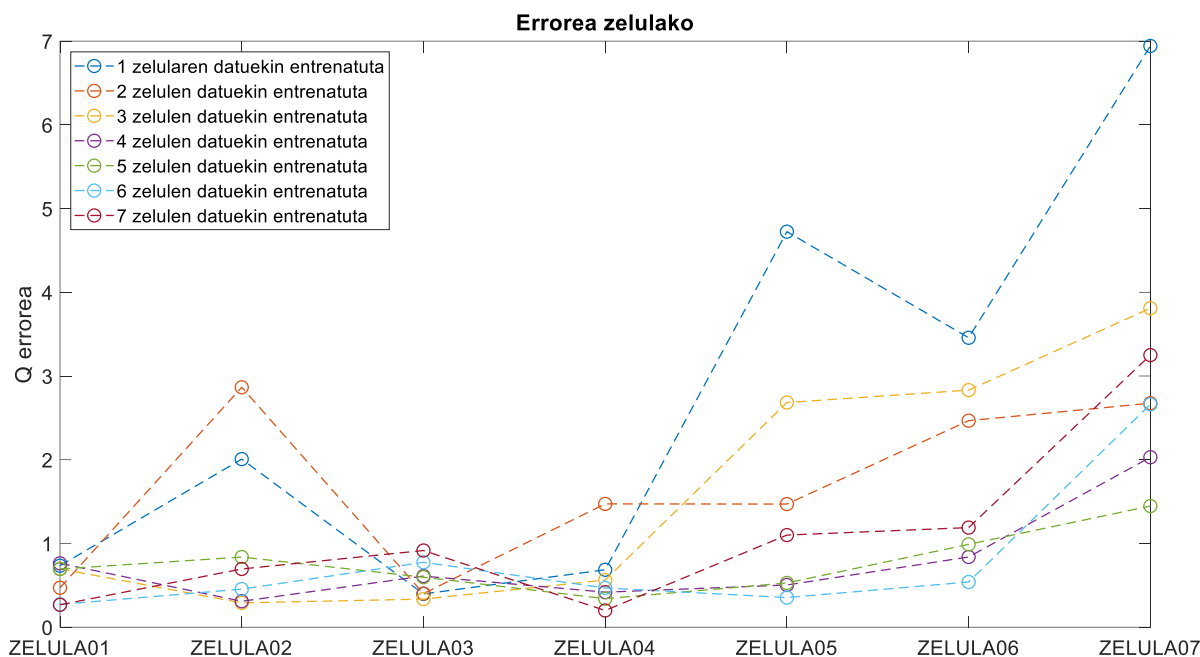


Irudia 31. NMC ereduak LFP zelulen degradazioa iragartzean lortutako errorea

NMC ereduaren portaera ikusi ondoren, jarraian, eredu horri LFP datuak gehituz sare neuronal berrentrenatu da transferentzia bidezko ikaskuntza aplikatuta. Transferentzia bidezko ikaskuntza erabiltzeko, sare berri ere entrenatu da NMC ereduak LFP datuekin berri entrenatuz. Horrela, sarearen parametroen balioak berri ere doitu dira LFP datuei egokitzuz.

4.4.2 NMC ereduari transferentzia bidezko ikaskuntza aplikatuta

LFP ereduarekin egin den bezala, entrenamenduak egin dira zelula ezberdinen datuak gehituz LFP ereduaren ordena berari jarraituz.



Irudia 32. Transferentzia bidezko ikaskuntza-ereduaren Q errorea zelulako, entrenamendu-datu ezberdinekin

Aurreko irudian (Irudia 32) ikus daitekeenez, lortutako emaitzak LFP eredu (ikus Irudia 27) hutsean lortutakoa baino zehatzagoak dira. Oro har, lortutako erroreak baxuagoak dira, eta, zelula bakarraren datuak erabiltzen direnean sarea entrenatzeko, ZELULA01-en, ZELULA03-ren eta ZELULA04-ren emaitzak LFP ereduarenak baino askoz hobekak dira. Hain zuzen ere, sareak tenperaturaren efektua ikasi duela (NMC datuekin ikasi du). Hau da, zelula horiek guztiak SOC berean daude, baina hiru tenperaturan.

Ikus daiteke, halaber, sarea zelula gehiagoren datuekin entrenatuta ere, azkeneko bi zelulen emaitzei dagokienez, errorea beste zelulekin konparatuta handiagoa dela, LFP ereduaren gertatzen den bezala.


4.4.3 Transferentzia bidezko ikaskuntza aplikatzea LFP eredu hobetzeko

Aurreko grafikoan ikusi da transferentzia bidezko ikaskuntzak hainbat onura dituela, eta lortutako sareak errore txikiagoa duela. Dituen onurak hobeto ulertzeko, beste froga bat egin da.

Bigarren froga horretan, sarea bi zelularekin entrenatu da; alegia, ez zaio lehenago aipatu den ordenari jarraitu. Entrenamendu horretan ZELULA03-ren eta ZELULA05-aren emaitzak erabili dira sarea berentrenatzeko. Izan ere, bi zelula horien datuak osagarria dira NMC ereduarekiko.

Lortutako emaitzak LFP ereduaren bi emaitzekin alderatu dira hurrengo irudian (Irudia 33) ikus daitekeen bezala. Froga horren helburua da informazio gehiago ematen duen konparaketa bat izatea.

- Alde batetik, LFP ereduak aurretik aipatu diren bi zelulen datu berdinekin entrenatu da (ZELULA03 eta ZELULA05) eta emaitzak bistaratu dira.
- Bestetik, behin betiko LFP ereduaren (5 zelulekin entrenatuta dago) emaitzak bistaratu dira.
- Azkenik, 2 zelularekin entrenatutako transferentzia bidezko ikaskuntza-ereduaren emaitzak ikus daitezke.



Irudia 33. Behin betiko LFP ereduak vs 2 zelularekin entrenatutako LFP ereduak vs 2 zelularekin entrenatutako IT ereduak

Aurreko irudian (Irudia 33) ikus daitezkeen bezala, transferentzia bidezko ikaskuntza erabiltzeak onura handiak dakarzkio sare neuronalari. Izan ere, sare neuronal horrek NMC zelulen datuetatik kuantifikatuta dakar aldeaz aurretik tenperaturak, SOHak, ezaugarritze-testetik ezaugarritze-testera dagoen denbora tartek eta SOCak degradazioan duten eragina. Transferentzia bidezko ikaskuntzaren metodoa erlazio horren doitzean datza, LFP katodoko zeluletara egokituz.

Horri esker, sareak parametroak doitzeko behar duen datu kopurua txikitzen da. NMC datuekin entrenatuta dagoen sareak, transferentzia bidezko ikaskuntzaren bidez LFPko 2 zelularen datuekin birdoituz gero, 4.3 atalean LFPko 5 zelularekin entrenatuta dagoen sareak baino emaitza hobetoak lortzen ditu.

Transferentzia bidezko ikaskuntza egitearen helburua da zelula gutxiago erabiliz behin betiko LFP ereduaren emaitzak hobetzea, aurreko irudian (Irudia 33) ikus daitezkeen bezala. Hala, hurrengo taulan (Taula 10) ikusten denez, transferentzia bidezko

ikaskuntza egiteak zelula berdinekin entrenatutako sarea nabarmenki hobetzen du, baina, gainera, zelula gehiagorekin entrenatutako sareak baino emaitza hobekak ere lortzen ditu.

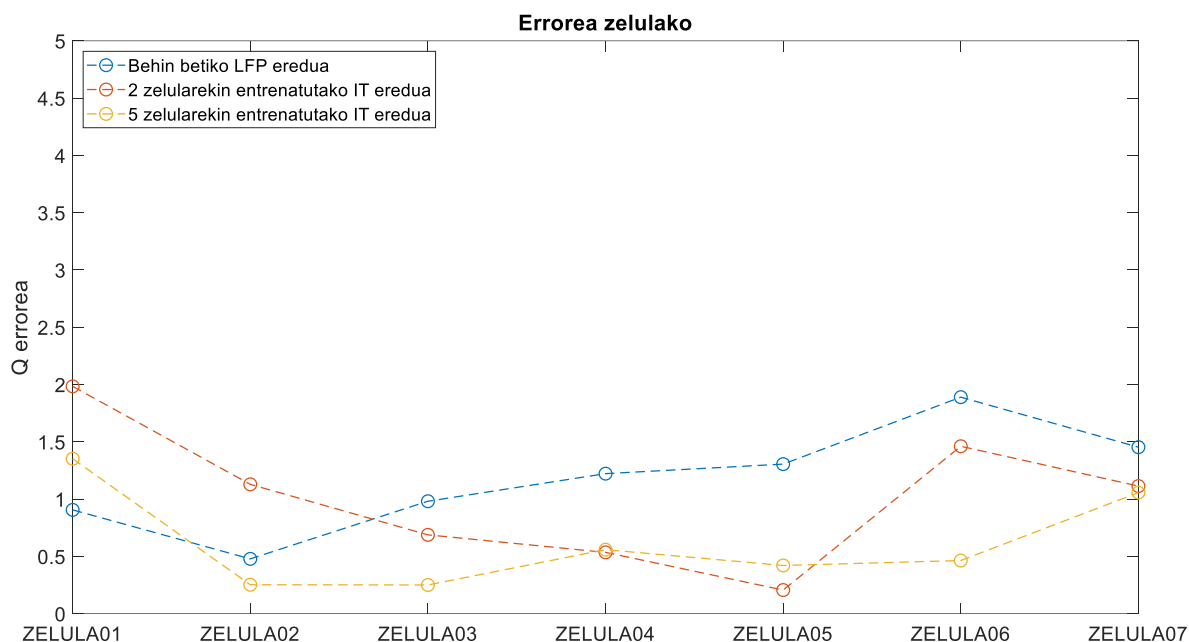
Taula 10. Behin betiko LFP ereduaren vs 2 zelularekin entrenatutako LFP ereduaren vs 2 zelularekin entrenatutako IT ereduaren erroreen alderaketa

Errorea (MAE)		Entrenamendua	Frogatzea	Guztiak
ΔQ	<i>LFP 2 zelula</i>	0,16	0,95	0,73
	<i>LFP 5 zelula</i>	0,24	1,01	0,46
	<i>IT 2 zelula</i>	0,21	0,54	0,45
Q	<i>LFP 2 zelula</i>	0,20	3,15	2,31
	<i>LFP 5 zelula</i>	0,98	1,67	1,18
	<i>IT 2 zelula</i>	0,45	1,24	1,01

Taulan ikusten den bezala, kapitulu honen hasieran proposatu diren helburuak 2 LFP zelularen datuak bakarrik erabiliz betetzen dira. Transferentzia bidezko ikaskuntza erabiltzean, degradazio-test gutxiago egin daitezke laborategian, eta, beraz, denbora eta dirua aurrezten dira.

Azkeneko test bat egin da, eta horren honen helburua ez da izan datuak iragartzea, baizik eta eskuragarri dauden datuak erabiltzea eredu hobetzeko. Honako honetan, NMC eredu LFP zelulen lehenengo 5 datuekin berrentrenatu da, ahalik eta eredu onena lortzeko.

Froga horretatik lortutako emaitzak hurrengo irudian (Irudia 34) erakusten dira. Zelulen erroretik ikus daitekeenez, sarea 5 zelularekin entrenatzeak onurak dakartza, bai entrenamendu-zeluletan (espero izatekoa da), bai frogatze-zeluletan ere.



Irudia 34. Behin betiko LFP eredu vs 2 zelulekin entrenatutako IT eredu vs 5 zelularekin entrenatutako IT eredu

Hurrengo taulan (Taula 11) erakusten da azken eredu horrek duen errorea 2 zelularekin entrenatutako ereduarekin alderatuta. Ikus daitekeenez, erroreak nabarmen egiten du behera, eta eredu zehatzago bat sortzen da.


Taula 11. 2 zelularekin entrenatutako IT ereduaren eta 5 zelularekin entrenatutako IT ereduaren erroreen alderaketa

Errorea (MAE)		Entrenamendua	Frogatzea	Guztiak
ΔQ	IT 2 zelula	0,21	0,54	0,45
	IT 5 zelula	0,22	0,89	0,41
Q	IT 2 zelula	0,45	1,24	1,01
	IT 5 zelula	0,57	0,76	0,62

Sarearen entrenamenduari zelula gehiago gehitzeak entrenamenduko errorea handiagoa izatea ekarri du, sareak datu gehiago doitu behar dituelako. Aldiz, datu gehiago doitzen dituen ereduak modu zehatzagoan doitu dituzte degradazio-kurbak eta inoiz ikusi ez dituen baldintzak hobeto iragarriko ditu; beraz, sare fidagarriago bat sortuko da.

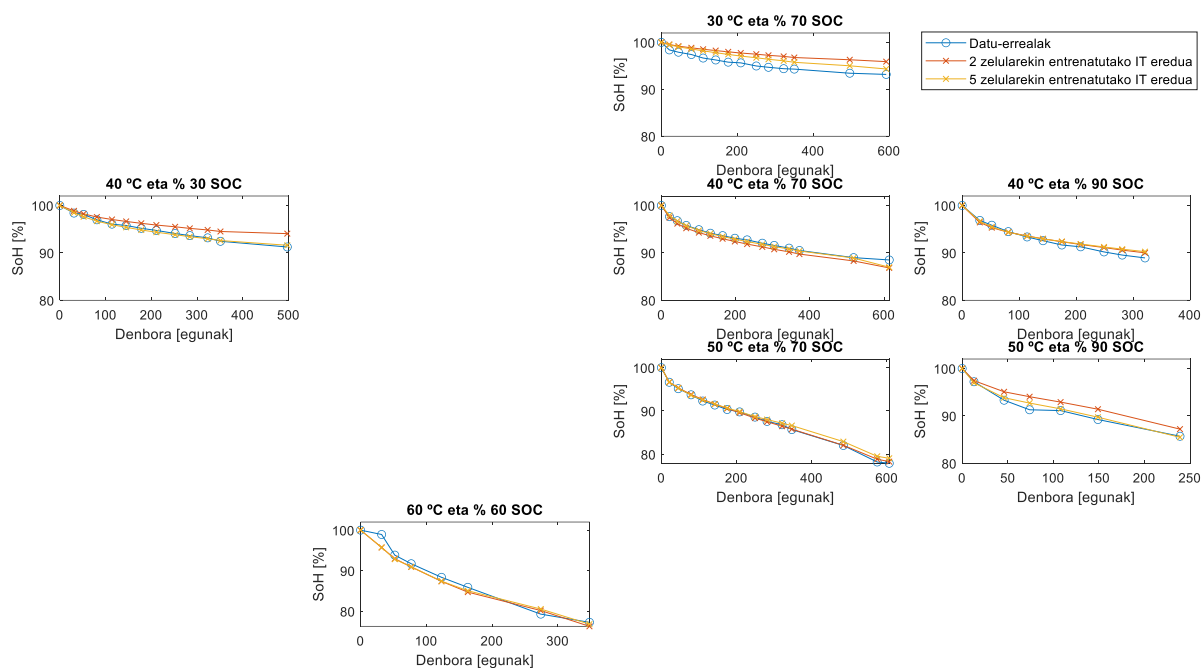
LFP ereduak sortu denean, tenperatura eta SOC altuetan kurbak behera egin zuen, 3D grafikoan (Irudia 29) ikusten denez. Hau da, tenperatura eta SOC altuetan, ΔQ balio

altua hartzen zuela ikusi da. Transferentzia bidezko ikaskuntza duen 5 zelularekin entrenatuko ereduaren 3D grafikoa (Irudia 35) ateratzean ikusten da ΔQ balioa askoz ere txikiagoa dela tenperatura eta SOC altuetan, sareak tenperatura altuak (50 °C) behatu dituelako.



Irudia 35. Transferentzia bidezko ikaskuntza erabiliz ereduaren degradazio-azalera % 99 SOHan

Azkenik, transferentzia bidezko ikaskuntza aplikatu zaien bi ereduren iragarpenak erakusten dira hurrengo irudian (Irudia 36). Bada, bien emaitzako oso antzekoak diren arren, 5 zelularekin entrenatutako ereduak benetako kurbatik gertuago dagoela ikus daiteke. Hala ere, esan daiteke bi ereduak degradazio-faktoreen eragina ondo ikasi dutela eta bi zelularekin entrenatutako ereduak oso emaitza onak ematen dituela, kontuan izanik bi zelularekin baino ez dela entrenatu.



Irudia 36. IT ereduaren degradazio-kurbaren iragarpenak

5. ONDORIOAK

Master bukaerako lan honetan proposatutako faseak eta helburuak bete dira. Ondoren, ateratako ondorioak aztertuko dira.

Bateria mota hauek kimika ezberdinak erabiltzen dituzte anodoan zein katodoan, beraz beren degradazio-mekanismoak ere aldatu egingo dira. Hori dela eta, kimika bakarra erabiltzen duten Li-ioi baterien datuekin ezinezkoa izango da Li-ioi bateria guztiak modelatzen dituen eredu bakarra sortzea.

Li-ioi kimika ezberdinak modelatzeko, transferentzia bidezko ikasketaren metodoak aplikatu dira, eta degradazio-frogetatik atera diren datuak erabili dira. Lan honetan, bi kimikaren degradazio-datuak erabili dira. Batetik, NMC baterien datuak (datu-base zabal bat zegoen eskuragarri), eta, bestetik, LFP baterienak (datu-basea txikiagoa da).

Adimen artifizialaren algoritmoen barruan, sare neuronal sakonak erabili dira; izan ere, zehaztasun handiko iragarpenak egin ditzakete, geruza bakarreko sare neuronalekin alderatura.

Egungo egoeraren azterketatik atera den azken ondorioa izan da aipatutako ereduak sortzeko teknika egokiena transferentzia bidezko ikaskuntza dela. Izan ere, modelatu nahi diren atazak antzekoak dira eta kimika batean dagoen datu-basea oso zabala da eta bestean, aldiz, txikia.

Ikusi da sarearen tamainak ez duela eragin handirik sarearen zehaztasunean. Nolanahi ere, sarea zenbat eta handiagoa izan, orduan eta ezegonkorragoa da, eta sareak gaindoiketa izateko arriskua handiagoa da. Sarea oso handia bada, parametro kopurua datu kopuruaren antzekoa izango da; ondorioz, sarea ezegonkorra izango da.

Sarearen optimizazioan erregularizazioa aplikatzen denean, sarearen iragarpenen errorea murriztu egiten da frogatzean, eta horrek ereduaren orokortze-gaitasuna hobetzen du, entrenamenduan behatutako baldintzetatik harago. Izan ere, erregularizazioak sareari ezartzen dion penalizazioari esker, sareak entrenamenduan ez ditu datuak guztiz doitzen, entrenamenduko errorea 0 edo 0tik gertu egon arte, eta, ondorioz, gaindoiketa ekidin egingo da.

LFP ereduaren kasuan ikusi denez, datu gutxi daudenean (2 zelularen datuak) sortutako ereduak ez da datu asko daudenean sortutakoa bezain zehatza izango. Izan ere, datu gutxi izatean, parametro kopurua datu kopurura hurbilduko da, eta doiketa okerragoa egingo du. Aldiz, transferentzia bidezko ikaskuntza erabiltzen denean, xede-atazan datu gutxi izan arren (2 zelularen datuak), lortu daitekeen eredu zehatzagoa izan daiteke, sareak jatorri-atazan ikasitakoa erabiltzen duelako datu berrietatik ikasteko.

Horren adibide da hau: transferentzia bidezko ikaskuntza erabiltzen denean, 2 zelularen datuekin berrentrenatutako sare neuronal batek % 0,45eko MAE errorea lortzen du. Aldiz, 5 zelularen datuekin entrenatu den eta transferentzia bidezko ikaskuntza erabili ez duen sareak % 0,46ko MAE errorea lortzen du. Baten zein bestearen errorea antzekoa izan arren, transferentzia bidezko ikaskuntza erabili duen sareak % 60 datu gutxiago erabili ditu. Ondoriozta daiteke, beraz, transferentzia bidezko ikaskuntza erabiltzen denean datu gutxiago behar direla. Froga gutxiago egin beharko dira laborategian eta dirua aurreztuko da, beraz.

Transferentzia bidezko ikaskuntza bigarren helburu baterako ere erabil daiteke; sare baten zehaztasuna hobetzeko, hain zuzen. 5 zelularen datuekin transferentzia bidezko ikaskuntza erabiliz berrentrenatutako ereduak, zelula berdinekin soilik entrenatutako ereduarekin alderatuta, Q -rekiko ematen duen errorea ia erdia da (% 1,18ko MAE errorea LFP datuekin soilik entrenatutako sarean eta % 0,62koa transferentzia bidezko ikaskuntza erabiliz berrentrenatu den sarean).

6. ETORKIZUNERAKO ILDOAK

Egindako lanak arlo horretan lan egiten jarraitzeko aukera ematen du. Besteak beste, algoritmoarekin hainbat froga egin daitezke, algoritmoaren ezargarritasuna azter daiteke eta algoritmoak dituen mugak ezagut daitezke. Jarraian, puntu horiek sakonago azaltzen dira.

Adibidez, transferentzia bidezko ikaskuntza egitean, sarea datu ezberdinekin berrentrenatzeak duen eragina ikustea eta zein zelularen datuekin lortzen diren emaitza hoberenak ikustea.

Sortutako algoritmoak egutegiko degradazio-mekanismoak baino ez ditu kontuan hartzen. Eredu hori zabaldu egin daiteke, eta zikladoko degradazio-mekanismoak modelatzeko gai den algoritmo bat sortu.

Bestalde, gomendagarria izan daiteke algoritmoak muturreko baldintzetan degradazioa nola iragartzen duen ikustea. Adibidez, tenperatura altuetan edo baxuetan eta SOC altuetan edo baxuetan. Erabili diren datu guztiak 25 °C eta 60 °C artean zeudenez, interesgarria izan daiteke jakitea 0 °C-etik behera algoritmoak baldintza horretan degradazioa iragartzeko zer-nolako gaitasun duen.

Eredua baldintza dinamikoetan eta profil errealistikoetan frogatu beharko litzake, gainera, zer-nolako portaera duen ikusteko. Izan ere, erabili diren datu guztiak baldintza estatikoetan lortu dira.

Transferentzia bidezko ikaskuntzaren mugak zeintzuk diren jakiteko, beste froga batzuk egitea gomendagarria izango litzake. Baterien arteko degradazio-mekanismoak oso ezberdinak direnean edo bestelako degradazio-mekanismoak dituzten baterietan (berun azidoko baterietan, kasu) transferentzia bidezko ikaskuntza egiteak zentzua duen edo ez ikustea edo egiteak ekarriko lituzkeen onurak ikustea.

Lortutako algoritmoa sistema erreal batean erabiltzeko jarraitu beharreko urratsak aztertu beharra dago. Datuak tratatzeko, zer prozedura jarraitu behar den jakin beharra dago. Izan ere, laborategiko entseguak beti baldintza berberetan egin dira, karga- eta deskarga-korrante jakin batean, tenperatura jakin batean, eta ezaugarritze-testa ere baldintza jakin batzuetan egin da. Aldiz, aplikazio errealetan, karga- eta deskarga-korrantea ez da beti berdina (adibidez, ibilgailu elektriko batean, korrantea etengabe aldatuko da, baita tenperatura ere. Ondorioz, aplikazio erreal batean, datuak prozesatu egin beharko dira garatutako degradazio-ereduak entrenatu ahal izateko.

Bestalde, datu horiek guztiak prozesatzeko behar den hardwarea bilatu behar da. BMS bat ez da nahikoa izango prozesamendu hori guztia egiteko, ez eta denboran zehar jasoko dituen datuak gordetzeko ere. Beraz, algoritmo eta datu horiek beste sistema batean exekutatu eta gorde beharko dira; zerbitzari batean edo Raspberry batean,

adibidez. Algoritmoak mikrokontrolagailu batean funtzionatu dezan, hizkuntza aldatu beharko zaio. Izan ere, algoritmoa *Matlab* softwarea erabiliz sortu da, baina Raspberry edo mikrokontrolagailu batean erabili ahal izateko, Python edo C hizkuntzara pasatu beharko da.

7. MEMORIA EKONOMIKOA

Jarraian, master bukaerako lanaren azterketa ekonomikoa egingo da. Azterketa bi zatitan banatu da: alde batetik, hardwarearen kostua eta, bestetik, softwarearen kostua.

Hardwarearen kostua adierazteko orduan, ekipoak duten kostu totala adierazi da, hau da, erosketa-kostua. Proiektuan ekipo hauek erabiltzearen kostua kalkulatzeko, amortizazioa eta beste hainbat alderdi izan beharko dira kontuan.

Proiektu hau egiteko erabili den hardware bakarra ordenagailu eramangarria izan da; 1.300 euro inguruko kostua du.

Erabilitako softwareak *Matlab* eta *Microsoft Office* izan dira. Batetik, erabilitako *Matlab* lizentzia ikasle-lizentzia izan denez, ez du inolako kosturik izan. Enpresaren lizentzia erabiliz gero, *Matlab*eko lizentzia erabili den *toolbox*ek 10.000 euro inguruko kostua izan dezake. Bestetik, erabilitako *Office*a enpresaren lizentzia izan da, eta software hori erabiltzeko kostua urtean 500 eurokoa da erabiltzaileko.

Laburbilduz, erabilitako *Matlab* lizentzia ikasle-lizentzia dela kontuan izanik eta ordenagailuaren kostu osoa kontuan hartzen ari dela kontuan izanik, proiektu honek 1.800 euroko kostua izan du.

8. PRAKTIKEN ETA MBL-AREN BALORAZIOA PERTSONALA

Lau urte baino gehiago eman ditut Ikerlanen lanean. Lehenik, graduan lan-ikaste partekatzea eginez, graduko ikasketak GBLarekin bertan egin arte; ondoren, masterrean berriz ere sekuentzia berdinean: lan-ikaste partekatzea eta MBLa.

Urte hauetan guztietan gauza asko ikasi ditut Ikerlanen, bai teknikoki, bai pertsonalki, GBLan eta MBLan landu ditudan gaiez bestelakoak. Enpresan egiten den lana ikasi dut, bai eta nola egiten den ere. Proiektu bat burutu behar denean jarraitu beharreko pausoak zeintzuk diren ikasi dut.

COVID-19aren eraginez, martxotik aurrera MBLa etxetik egin behar izan dut. Hasiera batean etxetik lan egiteak arazo izan zitekeen arren, baldintzetara ondo egokitu nintzen, eta lan egiten jarraitu dut inolako arazorik gabe. Gainera, proiektuko zuzendariarekin bilerak berdin-berdin egiten jarraitu dut, telematikoki egin ere. Bere laguntza behar izan dudanean, ez dut inolako arazorik izan berarekin hitz egiteko.

MBLan jorratu dudana oso interesgarria iruditu zait, eta gaiaren inguruan asko ikasi badut ere, gauza asko gelditu zaizkit ikasteko. Izan ere, adimen artifizialaren eta sare neuronalen mundua oso zabala da, eta milaka eta milaka aplikaziotan erabiltzeko aukera ematen du.

Azken urteotan Ikerlanen izan dudana esperientzia onak hurrengo urtetik aurrera doktorego-tesia egitera eramanez. Beraz, hurrengo hiru urteetan Ikerlanen jarraituko dut doktoregai, MBLan jorratutakoen antzeko gaiak lantzen.

9. BIBLIOGRAFIA

- [1] David E. Newton, *Fracking: A Reference Handbook*. ABC-CLIO, 2015.
- [2] D. Chen, «Microscopic Investigations of Degradation in Lithium-Ion Batteries», *Control Syst. IEEE*, or. 104, 2012.
- [3] J. M. Tarascon eta M. Armand, «Issues and challenges facing rechargeable lithium batteries», *Nature*, libk. 414, zenb. 6861. Nature Publishing Group, or. 359–367, 15-aza-2001, doi: 10.1038/35104644.
- [4] K. W. Noh eta S. J. Dillon, «Morphological changes in and around Sn electrodes during Li ion cycling characterized by in situ environmental TEM», *Scr. Mater.*, libk. 69, zenb. 9, or. 658–661, aza. 2013, doi: 10.1016/j.scriptamat.2013.07.028.
- [5] M. D. Stepp, J. J. Winebrake, J. S. Hawker, eta S. J. Skerlos, «Greenhouse gas mitigation policies and the transportation sector: The role of feedback effects on policy effectiveness», *Energy Policy*, libk. 37, zenb. 7, or. 2774–2787, uzt. 2009, doi: 10.1016/j.enpol.2009.03.013.
- [6] F. Kong *et al.*, «In situ studies of SEI formation», in *Journal of Power Sources*, 2001, libk. 97–98, or. 58–66, doi: 10.1016/S0378-7753(01)00588-2.
- [7] J. Y. Lin, C. C. Hsu, H. P. Ho, eta S. H. Wu, «Sol-gel synthesis of aluminum doped lithium titanate anode material for lithium ion batteries», *Electrochim. Acta*, libk. 87, or. 126–132, urt. 2013, doi: 10.1016/j.electacta.2012.08.128.
- [8] J. B. Goodenough, «Cathode materials: A personal perspective», *J. Power Sources*, libk. 174, zenb. 2, or. 996–1000, abe. 2007, doi: 10.1016/j.jpowsour.2007.06.217.
- [9] N. Nitta, F. Wu, J. T. Lee, eta G. Yushin, «Li-ion battery materials: Present and future», *Materials Today*, libk. 18, zenb. 5. Elsevier B.V., or. 252–264, 01-eka-2015, doi: 10.1016/j.mattod.2014.10.040.
- [10] S. C. Nagpure, B. Bhushan, eta S. S. Babu, «Multi-Scale Characterization Studies of Aged Li-Ion Large Format Cells for Improved Performance: An Overview», *J. Electrochem. Soc.*, libk. 160, zenb. 11, or. A2111–A2154, 2013, doi: 10.1149/2.001311jes.
- [11] M. H. Kjell, *Performance of Conventional and Structural Lithium-Ion Batteries*. 2013.
- [12] P. Arora eta Z. Zhang, «Battery separators», *Chem. Rev.*, libk. 104, zenb. 10, or. 4419–4462, urr. 2004, doi: 10.1021/cr020738u.
- [13] D. E. Demirocak eta B. Bhushan, «Probing the aging effects on nanomechanical properties of a LiFePO₄ cathode in a large format prismatic cell», *J. Power*

- Sources, libk. 280, or. 256–262, apr. 2015, doi: 10.1016/j.jpowsour.2015.01.114.
- [14] C. R. Birkel, M. R. Roberts, E. McTurk, P. G. Bruce, eta D. A. Howey, «Degradation diagnostics for lithium ion cells», *J. Power Sources*, libk. 341, or. 373–386, ots. 2017, doi: 10.1016/j.jpowsour.2016.12.011.
- [15] P. Arora, R. E. White, eta M. Doyle, «Capacity Fade Mechanisms and Side Reactions in Lithium-Ion Batteries», *J. Electrochem. Soc.*, libk. 145, zenb. 10, or. 3647–3667, 1998, doi: 10.1149/1.1838857.
- [16] M. Broussely *et al.*, «Main aging mechanisms in Li ion batteries», in *Journal of Power Sources*, 2005, libk. 146, zenb. 1–2, or. 90–96, doi: 10.1016/j.jpowsour.2005.03.172.
- [17] A. Mukhopadhyay eta B. W. Sheldon, «Deformation and stress in electrode materials for Li-ion batteries», *Progress in Materials Science*, libk. 63. Elsevier Ltd, or. 58–116, 01-eka-2014, doi: 10.1016/j.pmatsci.2014.02.001.
- [18] S. Ramdon eta B. Bhushan, «Nanomechanical characterization and mechanical integrity of unaged and aged Li-ion battery cathodes», *J. Power Sources*, libk. 246, or. 219–224, urt. 2014, doi: 10.1016/j.jpowsour.2013.07.078.
- [19] L. Norin, R. Kostecky, eta F. McLarnon, «Study of membrane degradation in high-power lithium-ion cells», *Electrochem. Solid-State Lett.*, libk. 5, zenb. 4, or. A67, apr. 2002, doi: 10.1149/1.1457206.
- [20] G. Shobha eta S. Rangaswamy, *Machine Learning*, 1. arg., libk. 38. Elsevier B.V., 2018.
- [21] A. Burkov, *The Hundred-Page Machine Learning Book*. 2019.
- [22] R. Boutaba *et al.*, «A comprehensive survey on machine learning for networking: evolution, applications and research opportunities», *J. Internet Serv. Appl.*, libk. 9, zenb. 1, 2018, doi: 10.1186/s13174-018-0087-2.
- [23] T. Hirasawa *et al.*, «Application of artificial intelligence using a convolutional neural network for detecting gastric cancer in endoscopic images», *Gastric Cancer*, libk. 21, zenb. 4, or. 653–660, uzt. 2018, doi: 10.1007/s10120-018-0793-2.
- [24] A. Géron, *Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems*. 2017.
- [25] A. C. Muller eta S. Guido, *Introduction to machine learning with Python: a guide for data scientists*. .
- [26] S. Raschka eta V. Mirjalili, *Python Machine Learning: Machine Learning and Deep*

Learning with Python, scikit-learn, and TensorFlow 2, zenb. January 2010. 2019.

- [27] K. Sultan, H. Ali, eta Z. Zhang, «Big data perspective and challenges in next generation networks», *Futur. Internet*, libk. 10, zenb. 7, eka. 2018, doi: 10.3390/fi10070056.
- [28] H. Shimodaira, «Improving predictive inference under covariate shift by weighting the log-likelihood function», *J. Stat. Plan. Inference*, libk. 90, zenb. 2, or. 227–244, 2000, doi: 10.1016/s0378-3758(00)00115-4.
- [29] I. H. Witten, E. Frank, eta M. a Hall, *Data Mining: Practical Machine Learning Tools and Techniques (Google eBook)*. 2011.
- [30] W. Dai, Q. Yang, G. R. Xue, eta Y. Yu, «Boosting for transfer learning», *ACM Int. Conf. Proceeding Ser.*, libk. 227, or. 193–200, 2007, doi: 10.1145/1273496.1273521.
- [31] S. J. Pan eta Q. Yang, «A Survey on Transfer Learning», 2009, doi: 10.1109/TKDE.2009.191.
- [32] S. J. Pan, J. T. Kwok, eta Q. Yang, «Transfer learning via dimensionality reduction», *Proc. Natl. Conf. Artif. Intell.*, libk. 2, or. 677–682, 2008.
- [33] J. Lu, V. Behbood, P. Hao, H. Zuo, S. Xue, eta G. Zhang, «Transfer learning using computational intelligence: A survey», *Knowledge-Based Syst.*, libk. 80, or. 14–23, 2015, doi: 10.1016/j.knosys.2015.01.010.
- [34] M. E. Taylor eta P. Stone, «Transfer Learning for Reinforcement Learning Domains: A Survey», *J. Mach. Learn. Res.*, libk. 10, zenb. 56, or. 1633–1685, 2009.
- [35] X. (Jerry) Zhu, «Semi-Supervised Learning Literature Survey», 2005.
- [36] K. Nigam, A. K. McCallum, S. Thrun, eta T. Mitchell, «Text classification from labeled and unlabeled documents using EM», *Mach. Learn.*, libk. 39, zenb. 2, or. 103–134, 2000, doi: 10.1023/A:1007692713085.
- [37] T. Joachims, «Transductive Inference for Text Classification using Support Vector Machines».
- [38] X. Yin, J. Han, J. Yang, eta P. S. Yu, «Efficient classification across multiple database relations: A crossMine approach», *IEEE Trans. Knowl. Data Eng.*, libk. 18, zenb. 6, or. 770–783, eka. 2006, doi: 10.1109/TKDE.2006.94.
- [39] S. Thrun eta L. Pratt, *Learning to Learn*. Springer US, 1998.
- [40] Z. Li eta D. Hoiem, «Learning without Forgetting», libk. 8828, zenb. c, or. 1–13, 2017, doi: 10.1109/TPAMI.2017.2773081.

- [41] S. Shen, M. Sadoughi, eta C. Hu, «Online Estimation of Lithium-Ion Battery Capacity Using Transfer Learning», or. 1–4, 2019.
- [42] T. Evgeniou eta M. Pontil, «Regularized multi-task learning», *KDD-2004 - Proc. Tenth ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, or. 109–117, 2004, doi: 10.1145/1014052.1014067.
- [43] Y. Zhang eta Q. Yang, «A Survey on Multi-Task Learning».
- [44] J. Yosinski, J. Clune, Y. Bengio, eta H. Lipson, «How transferable are features in deep neural networks?», libk. 27, 2014.
- [45] S. J. Pan eta Q. Yang, «A Survey on Transfer Learning», *IEEE Trans. Knowl. Data Eng.*, libk. 22, zenb. 10, or. 1345–1359, 2010, doi: 10.1109/TKDE.2009.191.
- [46] K. Weiss, T. M. Khoshgoftaar, eta D. Wang, *A survey of transfer learning*. Springer International Publishing, 2016.
- [47] B. Zadrozny, «Learning and Evaluating Classifiers under Sample Selection Bias», 2004.
- [48] W. Dai, «Self-taught Clustering», or. 200–207, 2008.
- [49] W. M. Learning eta P. Kim, *MATLAB Deep Learning*. .
- [50] Y. Bengio, «Deep Learning of Representations for Unsupervised and Transfer Learning», or. 17–37, 2012.
- [51] T. S. Openai eta D. P. K. Openai, «Weight Normalization: A Simple Reparameterization to Accelerate Training of Deep Neural Networks».
- [52] G. L. Colmenares eta R. Perez, «Data reduction method to train, test, and validate neural networks», in *Conference Proceedings - IEEE SOUTHEASTCON*, 1998, or. 277–280, doi: 10.1109/secon.1998.673349.
- [53] G. Mustafa, A. Ghaffar, eta M. Aslam, «A Subdivision-Regularization Framework for Preventing Over Fitting of Data by a Model», *Appl. Appl. Math. An Int. J.*, libk. 8, zenb. 1, or. 178–190, 2013.
- [54] M. Y. Park eta T. Hastie, «L 1 Regularization Path Algorithm for Generalized Linear Models», 2006.
- [55] C. Cortes, G. Research, N. York, M. Mohri, eta A. Rostamizadeh, «L 2 Regularization for Learning Kernels».
- [56] F. Agostinelli, M. Hoffman, P. Sadowski, eta P. Baldi, «LEARNING ACTIVATION FUNCTIONS TO IMPROVE DEEP NEURAL NETWORKS».

- [57] I. Goodfellow, Y. Bengio, eta A. Courville, *Deep Learning*. 2017.
- [58] «Function fitting neural network - MATLAB fitnet». [Sarean]. Available at: <https://www.mathworks.com/help/deeplearning/ref/fitnet.html>. [Eskuratua: 15-eka-2020].