



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών
Τομέας Βιομηχανικών Διατάξεων & Συστημάτων
Αποφάσεων

Πρόβλεψη της διάρκειας ζωής μπαταριών ιόντων λιθίου με χρήση
Συνελικτικών Νευρωνικών Δικτύων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Νίκη Βρούτση

Επιβλέπων : Γρηγόρης Μέντζας
Καθηγητής Ε.Μ.Π

Αθήνα, Οκτώβριος, 2025

Η σελίδα αυτή είναι σκόπιμα λευκή.



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

Σχολή Ηλεκτρολόγων Μηχανικών

και Μηχανικών Υπολογιστών

Τομέας Βιομηχανικών Διατάξεων & Συστημάτων

Αποφάσεων

Πρόβλεψη της διάρκειας ζωής μπαταριών ιόντων λιθίου με χρήση
Συνελικτικών Νευρωνικών Δικτύων

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Νίκη Βρούτση

Επιβλέπων : Γρηγόρης Μέντζας
Καθηγητής Ε.Μ.Π

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 17^η Οκτωβρίου 2025

.....
Γρηγόρης Μέντζας
Καθηγητής, Ε.Μ.Π

.....
Ιωάννης Ψαρράς
Καθηγητής, Ε.Μ.Π

.....
Δημήτρης Ασκούνης
Καθηγητής, Ε.Μ.Π

Αθήνα, Οκτώβριος, 2025

.....
Νίκη Βρούτση

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π

Copyright © Νίκη Βρούτση, 2025

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Η πρόβλεψη της διάρκειας ζωής μπαταριών ιόντων λιθίου (Li-ion) αποτελεί βασικό ζήτημα στη σύγχρονη έρευνα, καθώς συνδέεται άμεσα με την ασφάλεια, την αξιοπιστία και το κόστος χρήσης τους σε εφαρμογές όπως τα ηλεκτρικά οχήματα και τα συστήματα αποθήκευσης ενέργειας. Η σταδιακή μείωση της χωρητικότητας και η αύξηση της εσωτερικής αντίστασης οδηγούν σε φθορά που περιορίζει τη διάρκεια ζωής μιας κυψέλης. Η ακριβής εκτίμηση της υπολειπόμενης διάρκειας ζωής (Remaining Useful Life – RUL) είναι αναγκαία για την ανάπτυξη στρατηγικών προβλεπτικής συντήρησης και τη βέλτιστη διαχείριση μπαταριών σε πραγματικές συνθήκες λειτουργίας.

Τα φυσικά μοντέλα που έχουν χρησιμοποιηθεί παραδοσιακά προσφέρουν σημαντική ακρίβεια αλλά απαιτούν πολύπλοκη παραμετροποίηση και εντατικούς υπολογισμούς, γεγονός που τα καθιστά λιγότερο πρακτικά σε on-line εφαρμογές. Αντίθετα, τα μοντέλα που βασίζονται σε δεδομένα (data-driven models) αξιοποιούν τις πρόσφατες εξελίξεις στη μηχανική μάθηση και έχουν τη δυνατότητα να αναγνωρίζουν μη γραμμικές συσχετίσεις μεταξύ των μετρήσεων και της φθοράς, χωρίς να απαιτείται εκ των προτέρων γνώση της φυσικοχημικής συμπεριφοράς. Στο πλαίσιο αυτό, η παρούσα εργασία μελετά την εφαρμογή Συνελικτικών Νευρωνικών Δικτύων (Convolutional Neural Networks – CNNs) για την πρόβλεψη της διάρκειας ζωής κυψελών Li-ion.

Το μοντέλο που προτείνεται εκπαιδεύεται σε δεδομένα πλήρους κύκλου ζωής, αντλώντας πληροφορίες από χρονοσειρές εκφόρτισης (τάση, θερμοκρασία, εκφορτισθείσα χωρητικότητα) και συνοπτικά χαρακτηριστικά όπως η εσωτερική αντίσταση και ο χρόνος εκφόρτισης. Η μεθοδολογία ενσωματώνει τεχνικές προεπεξεργασίας που περιλαμβάνουν καθαρισμό, κανονικοποίηση και παραθυροποίηση με sliding windows, ώστε να δημιουργηθούν κατάλληλες είσοδοι για τα συνελικτικά υποδίκτυα. Ένα κρίσιμο στοιχείο της μελέτης είναι η αξιολόγηση της ικανότητας του μοντέλου να προβλέπει το RUL νέων κυψελών χρησιμοποιώντας μόνο τα πρώιμα δεδομένα τους. Έτσι, ενώ το CNN έχει εκπαιδευτεί σε όλο το εύρος κύκλων, στο στάδιο του inference περιορίζεται στους πρώτους κύκλους λειτουργίας μιας κυψέλης, προσομοιώνοντας το ρεαλιστικό σενάριο όπου δεν υπάρχει πλήρης ιστορία ζωής διαθέσιμη.

Τα πειραματικά αποτελέσματα δείχνουν ότι η προτεινόμενη μεθοδολογία μπορεί να αξιοποιήσει επαρκώς τις πληροφορίες των πρώιμων κύκλων για να εκτιμήσει με ικανοποιητική ακρίβεια τη συνολική διάρκεια ζωής. Αυτό αναδεικνύει τη δυνατότητα των CNNs να εντοπίζουν πρώιμα πρότυπα φθοράς που σχετίζονται με την εξέλιξη της μπαταρίας, παρέχοντας χρήσιμη βάση για εφαρμογές σε πραγματικά συστήματα παρακολούθησης και διαχείρισης μπαταριών. Η εργασία συμβάλλει στη βιβλιογραφία επιβεβαιώνοντας ότι τα πρώιμα δεδομένα μπορούν να αποτελέσουν αξιόπιστη πηγή πληροφορίας για προγνωστικά μοντέλα, και θέτει τις βάσεις για μελλοντική έρευνα με διευρυμένα σύνολα δεδομένων και πιο σύνθετες αρχιτεκτονικές βαθιάς μάθησης.

Λέξεις Κλειδιά: Μπαταρίες ιόντων λιθίου, Πρόβλεψη διάρκειας ζωής, Remaining Useful Life (RUL), Συνελικτικά Νευρωνικά Δίκτυα (CNNs), Βαθιά Μάθηση, Πρώιμοι Κύκλοι

Η σελίδα αυτή είναι σκόπιμα λευκή.

Abstract

The prediction of the lifetime of lithium-ion (Li-ion) batteries is a major research focus, as it directly affects the safety, reliability, and cost of their use in applications such as electric vehicles and energy storage systems. The gradual decrease in capacity and the increase in internal resistance lead to degradation that limits the operational life of each cell. Accurately estimating the Remaining Useful Life (RUL) is essential for predictive maintenance strategies and for enabling efficient battery management in real-world operating environments.

Traditional physics-based models provide significant accuracy but require extensive parameterization and computational effort, which makes them less practical for online applications. In contrast, data-driven models leverage recent advances in machine learning to capture non-linear relationships between measurements and degradation, without requiring prior knowledge of the electrochemical processes. In this context, the present thesis investigates the application of Convolutional Neural Networks (CNNs) for predicting the lifetime of Li-ion cells.

The proposed model is trained on full cycle life data, incorporating both discharge time series (voltage, temperature, discharged capacity) and summary features such as internal resistance and discharge time. The methodology involves preprocessing steps including cleaning, normalization, and sliding-window segmentation, which transform the raw experimental measurements into inputs suitable for CNNs. A key focus of the study is the evaluation of the model's ability to predict the RUL of unseen cells using only their early-cycle data. While the CNN is trained across the complete life cycle of the training cells, during inference it is restricted to the first cycles of a new cell. This setup reflects the realistic scenario in which only limited early data are available when a cell is first deployed.

Experimental results demonstrate that the proposed CNN approach can effectively use early-cycle information to estimate the total lifetime with satisfactory accuracy. This highlights the ability of CNNs to detect early degradation patterns that are predictive of long-term behavior, offering a promising pathway for integration into battery monitoring and management systems. The study confirms that early-cycle data can serve as a meaningful basis for lifetime prediction models and provides a foundation for future research with larger datasets, alternative architectures, and broader experimental conditions.

KeyWords: Lithium-ion batteries, Lifetime prediction, Remaining Useful Life (RUL), Convolutional Neural Networks (CNNs), Deep Learning, Data preprocessing, Feature engineering, Early cycles.

Η σελίδα αυτή είναι σκόπιμα λευκή.

ΠΕΡΙΕΧΟΜΕΝΑ

1. Εισαγωγή	11
2. Βιβλιογραφική Επισκόπηση	12
2.1 Τεχνολογία Μπαταριών Ιόντων Λιθίου και Μετρικές Αξιολόγησης Υγείας	12
2.2 Μέθοδοι Πρόβλεψης SOH και RUL: Φυσικές, Ημιεμπειρικές και Δεδομενοκεντρικές Προσεγγίσεις	13
2.3 Προσεγγίσεις Μηχανικής Μάθησης και Συνελκτικά Νευρωνικά Δίκτυα στην Πρόβλεψη SOH και RUL.....	16
2.4 Αξιολόγηση Μοντέλων Πρόβλεψης: Μετρικές Απόδοσης και Πρακτικά Ζητήματα Εφαρμογής	17
2.5 Επιλογή Αρχιτεκτονικής CNN και Αιτιολόγηση	19
3. Η Προτεινόμενη Προσέγγιση	20
3.1 Επισκόπηση της Προτεινόμενης Προσέγγισης	20
3.2 Δεδομένα Μπαταριών	22
3.2.1 Συλλογή Δεδομένων	22
3.2.2 Διερευνητική Ανάλυση Δεδομένων	22
3.2.3 Προεπεξεργασία Δεδομένων	23
3.2.4 Μηχανική Χαρακτηριστικών	23
3.3 Μοντέλο Βαθιάς Μηχανικής Μάθησης	24
3.3.1 Θεωρητικό Υπόβαθρο Συνελκτικών Νευρωνικών Δικτύων.....	24
3.3.2 Αρχιτεκτονική CNN στην Προτεινόμενη Προσέγγιση	27
3.4 Αξιολόγηση του Μοντέλου και Παραγωγή Προβλέψεων	30
4 Υλοποίηση και Αξιολόγηση	31
4.1 Τεχνική Υλοποίηση.....	31
4.2 Συλλογή Δεδομένων.....	33
4.3 Διερευνητική Ανάλυση Δεδομένων	35
4.4 Προεπεξεργασία Δεδομένων.....	44
4.4.1 Καθαρισμός Δεδομένων.....	44
4.4.2 Μηχανική Χαρακτηριστικών	45
4.5 Μοντέλο CNN.....	46
4.5.1 Αρχιτεκτονική Μοντέλου	46

4.5.2 Βελτιστοποίηση Υπερπαραμέτρων (<i>Hyperparameter Optimization</i>).....	47
4.5.3 Διαχείριση Εκπαίδευσης και Παρακολούθηση Μοντέλου.....	49
4.5.4 Αξιολόγηση Μοντέλου	51
4.6 Πειραματικά αποτελέσματα - Προβλέψεις	52
5. Συμπεράσματα.....	55
5.1 Σύνοψη και συμπεράσματα.....	55
5.2 Μελλοντικές επεκτάσεις	56

1. Εισαγωγή

Οι μπαταρίες ιόντων λιθίου αποτελούν τον πυρήνα πολλών σύγχρονων τεχνολογιών, με εφαρμογές που εκτείνονται από φορητές ηλεκτρονικές συσκευές έως ηλεκτρικά οχήματα και συστήματα αποθήκευσης ενέργειας. Η διαχείριση και πρόβλεψη της κατάστασης υγείας τους (State of Health, SoH) και ιδιαίτερα της υπολειπόμενης διάρκειας ζωής (Remaining Useful Life, RUL) είναι κρίσιμη για την ασφάλεια και την αποτελεσματικότητα των συστημάτων που τις χρησιμοποιούν.

Η πρόβλεψη του RUL είναι μια σύνθετη διαδικασία που εξαρτάται από πληθώρα παραμέτρων. Η παρούσα διπλωματική εργασία προτείνει μια προσέγγιση που βασίζεται σε τεχνικές βαθιάς μάθησης και συγκεκριμένα στη χρήση Συνελκτικών Νευρωνικών Δικτύων (CNNs), με σκοπό την εξαγωγή προγνωστικών χαρακτηριστικών από πρώιμα δεδομένα κύκλων φόρτισης/εκφόρτισης.

Αντικείμενο και Στόχος της Διπλωματικής Εργασίας

Η εργασία αποσκοπεί στη δημιουργία ενός συστήματος πρόβλεψης της διάρκειας ζωής κυψέλων λιθίου, βασισμένου σε δημόσια διαθέσιμα δεδομένα από το Battery Data Set του MIT. Το μοντέλο εκπαιδεύεται αποκλειστικά σε κύκλους κάθε κυψελών και επιδιώκει να γενικεύσει σε μη ορατά δεδομένα, προσφέροντας αξιόπιστες προβλέψεις της αναμενόμενης διάρκειας ζωής.

Διάρθρωση της Διπλωματικής Εργασίας

Η εργασία οργανώνεται σε πέντε κεφάλαια. Το πρώτο κεφάλαιο παρουσιάζει την εισαγωγή και το αντικείμενο της εργασίας. Το δεύτερο κεφάλαιο αναλύει τη σχετική βιβλιογραφία. Στο τρίτο κεφάλαιο περιγράφεται η προτεινόμενη προσέγγιση, στο τέταρτο παρουσιάζονται τα πειραματικά αποτελέσματα και στο πέμπτο τα συμπεράσματα και προτάσεις για μελλοντική εργασία.

2. Βιβλιογραφική Επισκόπηση

2.1 Τεχνολογία Μπαταριών Ιόντων Λιθίου και Μετρικές Αξιολόγησης Υγείας

Οι μπαταρίες ιόντων λιθίου (Li-ion) έχουν επικρατήσει ως η κυρίαρχη τεχνολογία αποθήκευσης ενέργειας σε εφαρμογές όπως ηλεκτρικά οχήματα, φορητές συσκευές και σταθερές εγκαταστάσεις αποθήκευσης, κυρίως λόγω της υψηλής ενεργειακής πυκνότητας, του χαμηλού βάρους και της σχετικά μεγάλης διάρκειας ζωής [1], [2]. Η βασική δομή τους περιλαμβάνει έναν γραφίτη ανόδου, καθόδους βασισμένες σε οξείδια μετάλλων λιθίου και έναν ηλεκτρολύτη που επιτρέπει τη μεταφορά ιόντων λιθίου μεταξύ των ηλεκτροδίων κατά τη φόρτιση και εκφόρτιση [3].

Καθώς οι κύκλοι φόρτισης και εκφόρτισης αυξάνονται, η μπαταρία υπόκειται σε φαινόμενα γήρανσης τα οποία επηρεάζουν την απόδοσή της. Οι κυριότεροι μηχανισμοί υποβάθμισης διακρίνονται σε calendar aging, που σχετίζεται με τον χρόνο αποθήκευσης, και cycling aging, που σχετίζεται με τον αριθμό κύκλων λειτουργίας [4]. Παράγοντες όπως η θερμοκρασία, η ταχύτητα φόρτισης και η κατάσταση φόρτισης συμβάλλουν στην επιτάχυνση της υποβάθμισης [5].

Για την παρακολούθηση της υγείας και της διάρκειας ζωής μιας μπαταρίας, χρησιμοποιούνται οι παρακάτω βασικές μετρικές:

Χωρητικότητα (Capacity): Εκφράζει την ποσότητα ενέργειας που μπορεί να αποδώσει η μπαταρία και μειώνεται σταδιακά με την πάροδο του χρόνου [6].

Κατάσταση Υγείας (State of Health - SOH): Ορίζεται ως το ποσοστό της τρέχουσας χωρητικότητας ως προς την ονομαστική χωρητικότητα. Εκφράζεται ως:

$$SOH(\%) = \frac{Q_{\text{τρέχουσα}}}{C_{\text{ονομαστική}}} \times 100$$


,όπου $Q_{\text{τρέχουσα}}$ /mAh η μέγιστη διαθέσιμη φόρτιση της μπαταρίας και $C_{\text{ονομαστική}}$, η ονομαστική χωρητικότητα της μπαταρίας.

Όταν το SOH πέσει κάτω από 70–80%, θεωρείται ότι η μπαταρία έχει φτάσει στο τέλος της ζωής της (End-of-Life) [7].

Υπόλοιπη Χρήσιμη Ζωή (Remaining Useful Life - RUL): Είναι ο αριθμός κύκλων ή ο χρόνος που απομένει μέχρι η απόδοση της μπαταρίας να πέσει κάτω από ένα αποδεκτό όριο λειτουργίας. Η ακριβής πρόβλεψη του RUL αποτελεί κρίσιμο στοιχείο για την προγνωστική συντήρηση (predictive maintenance) [8].

Εσωτερική Αντίσταση (Internal Resistance): Αυξάνεται σταδιακά λόγω φαινομένων όπως η ανάπτυξη του στερεού ηλεκτρολυτικού φράγματος (SEI layer) και η φθορά των ηλεκτροδίων. Η αυξημένη αντίσταση μειώνει την απόδοση και συμβάλλει στην υποβάθμιση [9].

Χαρακτηριστικά Τάσης (Voltage Profiles): Η καμπύλη τάσης κατά την εκφόρτιση αλλάζει με την ηλικία της μπαταρίας, παρέχοντας σημαντικές ενδείξεις για την κατάστασή της [10]




Εικόνα 1: Τυπική καμπύλη εκφόρτισης που απεικονίζει τα τρία στάδια γήρανσης της κυψέλης: επιτάχυνση, σταθεροποίηση και κορεσμό..

Η παρακολούθηση των παραπάνω χαρακτηριστικών, με την υποστήριξη τεχνικών μηχανικής μάθησης, επιτρέπει την ανάπτυξη αξιόπιστων μοντέλων πρόβλεψης της κατάστασης υγείας και της υπολειπόμενης διάρκειας ζωής.

2.2. Μέθοδοι Πρόβλεψης SOH και RUL: Φυσικές, Ημιεμπειρικές και Δεδομενοκεντρικές Προσεγγίσεις

Η πρόβλεψη της κατάστασης υγείας (SOH) και της υπολειπόμενης χρήσιμης ζωής (RUL) των μπαταριών ιόντων λιθίου έχει προσελκύσει έντονο ερευνητικό ενδιαφέρον τα τελευταία χρόνια, καθώς αποτελεί βασικό παράγοντα για την εξασφάλιση της αξιοπιστίας, της ασφάλειας και της βέλτιστης ενεργειακής διαχείρισης των ηλεκτροχημικών συστημάτων. Οι μεθοδολογίες που έχουν προταθεί στην επιστημονική βιβλιογραφία κατατάσσονται σε τρεις βασικές κατηγορίες: τα φυσικά (physics-based) μοντέλα, τα ημιεμπειρικά (semi-empirical) και τα μοντέλα βασισμένα σε δεδομένα (data-driven).

Η κατηγορία των φυσικών μοντέλων αποτελεί την πλέον θεμελιώδη προσέγγιση, βασιζόμενη στην περιγραφή των υποκείμενων ηλεκτροχημικών και θερμικών διεργασιών μέσω διαφορικών εξισώσεων. Τυπικά παραδείγματα είναι το Doyle-Fuller-Newman μοντέλο, το οποίο μοντελοποιεί τις αντιδράσεις στους ηλεκτροδικούς πόρους μέσω εξισώσεων διάχυσης και μεταφοράς φορτίου, καθώς και το απλοποιημένο μοντέλο ενός σωματιδίου (SPM), το οποίο μειώνει την πολυπλοκότητα του συστήματος διατηρώντας επαρκή ακρίβεια για συγκεκριμένα σενάρια [11].



Εικόνα 2: Διαγραμματική απεικόνιση του Doyle-Fuller-Newman (DFN) μοντέλου.

E

Πηγή https://www.researchgate.net/figure/Diagram-of-the-Doyle-Fuller-Newman-DFN-model-This-figure-has-been-reproduced-from-ref_fig5_366768392

Τα μοντέλα αυτά έχουν το πλεονέκτημα της φυσικής ερμηνευσιμότητας, προσφέροντας δυνατότητες σε βάθος ανάλυσης των φαινομένων γήρανσης, όπως η ανάπτυξη της στιβάδας SEI, η απώλεια ενεργού λιθίου, η μεταβολή της εσωτερικής αντίστασης και η αποσύνθεση του ηλεκτρολύτη. Ωστόσο, απαιτούν εκτενή γνώση των φυσικοχημικών παραμέτρων του συστήματος, οι οποίες ενδέχεται να διαφέρουν σημαντικά μεταξύ διαφορετικών κυψελών, κατασκευαστών ή εφαρμογών. Επιπλέον, η αριθμητική επίλυση των σχετικών μοντέλων μπορεί να είναι υπολογιστικά ακριβή, περιορίζοντας την εφαρμογή τους σε πραγματικό χρόνο [12].

Τα ημιεμπειρικά μοντέλα αποτελούν μία ενδιάμεση κατηγορία, επιχειρώντας να ισορροπήσουν ανάμεσα στην ερμηνευσιμότητα και την απλότητα. Συνδυάζουν βασικές αρχές φυσικής με εμπειρικά προσδιορισμένες παραμέτρους, κατασκευάζοντας εξισώσεις που εκφράζουν την υποβάθμιση της χωρητικότητας ή της απόδοσης συναρτήσει παραγόντων όπως ο αριθμός κύκλων, η θερμοκρασία, το βάθος εκφόρτισης (Depth of Discharge - DoD), ή η τάση λειτουργίας [13]. Ένα κλασικό παράδειγμα είναι τα θερμικά μοντέλα που βασίζονται στην εξίσωση Arrhenius, η οποία εκφράζει την εξάρτηση του ρυθμού υποβάθμισης από τη θερμοκρασία. Παρότι τα ημιεμπειρικά μοντέλα είναι γενικά υπολογιστικά αποδοτικά και εύκολα στην εφαρμογή, παρουσιάζουν περιορισμένη ικανότητα γενίκευσης και απαιτούν πειραματική βαθμονόμηση για κάθε νέα κυψέλη ή τύπο χρήσης [14].

Με την εμφάνιση μεγάλων ποσοτήτων λειτουργικών δεδομένων από αισθητήρες και συστήματα διαχείρισης μπαταριών (Battery Management Systems - BMS), τα τελευταία χρόνια αναπτύχθηκε έντονο ενδιαφέρον για τις λεγόμενες δεδομενοκεντρικές μεθόδους

πρόβλεψης. Τα μοντέλα αυτά αντιμετωπίζουν την πρόβλεψη του SOH και RUL ως πρόβλημα παλινδρόμησης ή ταξινόμησης, το οποίο επιλύεται μέσω μεθόδων μηχανικής μάθησης και τεχνητής νοημοσύνης. Η χρήση αλγορίθμων όπως οι Random Forests, τα Support Vector Machines (SVMs), οι Gaussian Processes και τα μοντέλα Gradient Boosting έχει ήδη δώσει ενθαρρυντικά αποτελέσματα σε πληθώρα ερευνητικών εργασιών [15].

Αξιοσημείωτη είναι η πρόοδος που έχει επιτευχθεί μέσω της βαθιάς μάθησης (deep learning), και ειδικότερα των συνελκτικών νευρωνικών δικτύων (Convolutional Neural Networks - CNN) και των επαναλαμβανόμενων δικτύων (Recurrent Neural Networks - RNN), καθώς και των μοντέλων τύπου LSTM (Long Short-Term Memory). Αυτά τα μοντέλα είναι ικανά να αναλύσουν χρονοσειρές δεδομένων από τάση, ρεύμα, θερμοκρασία ή χωρητικότητα, και να εντοπίσουν μη γραμμικές σχέσεις και μοτίβα που δύσκολα εντοπίζονται με κλασικές μεθόδους [16]. Χαρακτηριστική περίπτωση αποτελεί η εργασία των Severson et al. [17], στην οποία χρησιμοποιούνται τα πρώτα 100 charge-discharge cycles ώστε να προβλεφθεί με ακρίβεια η συνολική διάρκεια ζωής μιας κυψέλης τύπου LFP/Graphite, αποδεικνύοντας τη δυναμική των δεδομενοκεντρικών μεθόδων στην πρόωμη διάγνωση.

Ωστόσο, από τα δεδομενοκεντρικά μοντέλα δεν εκκλίνουν προκλήσεις. Η ακρίβεια και αξιοπιστία τους εξαρτάται σε μεγάλο βαθμό από την ποιότητα των δεδομένων εκπαίδευσης, τη σωστή κανονικοποίηση και την αντιπροσωπευτικότητα των σεναρίων λειτουργίας. Επιπλέον, σε περιπτώσεις που τα δεδομένα είναι περιορισμένα ή μη αντιπροσωπευτικά, παρατηρείται υπερπροσαρμογή και χαμηλή γενικευσιμότητα. Παρόλα αυτά, η δυνατότητα εκπαίδευσης online, η επεκτασιμότητα σε διαφορετικούς τύπους κυψελών και η ελαχιστοποίηση της ανάγκης για φυσικές παραμέτρους καθιστούν τις τεχνικές αυτές ιδιαίτερα ελκυστικές για εφαρμογές μεγάλης κλίμακας.

Συνολικά, η επιλογή κατάλληλης μεθόδου πρόβλεψης εξαρτάται από πολλούς παράγοντες, όπως η διαθεσιμότητα δεδομένων, η πολυπλοκότητα του συστήματος, οι υπολογιστικοί περιορισμοί και η ανάγκη ερμηνευσιμότητας. Πολλές σύγχρονες μελέτες προτείνουν υβριδικές προσεγγίσεις, οι οποίες συνδυάζουν φυσικά και δεδομενοκεντρικά μοντέλα, αξιοποιώντας τα πλεονεκτήματα και των δύο κόσμων [18].

Κατηγορία	Πλεονεκτήματα	Μειονεκτήματα
Φυσικά Μοντέλα	Υψηλή ακρίβεια, κατανόηση φαινομένων	Υψηλή υπολογιστική πολυπλοκότητα, ανάγκη για παραμέτρους
Ημι-εμπειρικά	Ευκολία χρήσης, συνδυασμός γνώσης	Χαμηλή γενικευσιμότητα
Βασισμένα σε Δεδομένα	Ευελιξία, real-time εφαρμογή	Εξάρτηση από ποιότητα δεδομένων

Πίνακας 1: Σύγκριση των διαφορετικών μοντέλων πρόβλεψης SOH και RUL.

2.3. Προσεγγίσεις Μηχανικής Μάθησης και Συνελκτικά Νευρωνικά Δίκτυα στην Πρόβλεψη SOH και RUL

Η ραγδαία ανάπτυξη της τεχνητής νοημοσύνης τα τελευταία χρόνια έχει επεκτείνει σημαντικά τις δυνατότητες πρόβλεψης της κατάστασης υγείας και της υπολειπόμενης ζωής των μπαταριών ιόντων λιθίου. Τα μοντέλα μηχανικής μάθησης (Machine Learning - ML) παρέχουν ένα εναλλακτικό πλαίσιο προσέγγισης, το οποίο βασίζεται κυρίως στην ανάλυση ιστορικών δεδομένων λειτουργίας και όχι στην εξαντλητική μοντελοποίηση των φυσικών φαινομένων. Ειδικά για σύνθετα, μη γραμμικά συστήματα όπως οι ηλεκτροχημικές μπαταρίες, τα ML μοντέλα επιδεικνύουν σημαντική ευελιξία και προσαρμοστικότητα, καθιστώντας τα ιδιαίτερα κατάλληλα για προβλήματα όπως η εκτίμηση SOH και RUL.

Τα βασικά βήματα ανάπτυξης ενός μοντέλου ML για τέτοιου τύπου πρόβλεψη περιλαμβάνουν: (α) τη συλλογή και προεπεξεργασία δεδομένων (τάση, ρεύμα, θερμοκρασία, αριθμός κύκλων, χωρητικότητα), (β) την εξαγωγή κατάλληλων χαρακτηριστικών (features), (γ) την επιλογή και εκπαίδευση του αλγορίθμου, και (δ) την αξιολόγηση με βάση μετρικές σφάλματος όπως MAE, RMSE ή R^2 [19]. Οι αλγόριθμοι που έχουν εφαρμοστεί με επιτυχία στο πεδίο περιλαμβάνουν τις Random Forests, τα Support Vector Machines, τις Gaussian Process Regressions, καθώς και ενισχυμένα μοντέλα τύπου Gradient Boosting όπως τα XGBoost και CatBoost [20]. Αντίστοιχα, η εργασία των Sekhar και Domathoti (2023) παρέχει μια συγκριτική αξιολόγηση κλασικών αλγορίθμων ML για πρόβλεψη RUL σε Li-ion μπαταρίες, επιβεβαιώνοντας την αξιοπιστία μοντέλων όπως τα Random Forest και SVM.[27]

Πέρα από τα παραδοσιακά ML μοντέλα, ιδιαίτερο ενδιαφέρον έχει προσελκύσει η χρήση τεχνικών βαθιάς μάθησης (Deep Learning), και πιο συγκεκριμένα των συνελκτικών νευρωνικών δικτύων (Convolutional Neural Networks - CNN). Τα CNN αρχικά αναπτύχθηκαν για προβλήματα επεξεργασίας εικόνας, ωστόσο έχουν αποδείξει εξαιρετική απόδοση και στην ανάλυση χρονοσειρών, επιτρέποντας την αυτόματη εξαγωγή χωρικών και χρονικών χαρακτηριστικών από ακατέργαστα δεδομένα [21]. Στο πλαίσιο της πρόβλεψης SOH και RUL, τα CNN αξιοποιούνται για την αναγνώριση προτύπων υποβάθμισης με βάση τις καμπύλες τάσης/ρεύματος ή ακόμα και μετασχηματισμένες αναπαραστάσεις όπως τα capacity fade profiles.

Ένα χαρακτηριστικό πλεονέκτημα των CNN είναι η ικανότητά τους να δέχονται πολλαπλές εισόδους ταυτόχρονα, για παράδειγμα, ένα κανάλι με στατικά χαρακτηριστικά (π.χ. αριθμός κύκλων, θερμοκρασία) και ένα δεύτερο με χρονικές ακολουθίες (π.χ. καμπύλες τάσης). Αυτή η αρχιτεκτονική επιτρέπει στο δίκτυο να μαθαίνει συσχετίσεις όχι μόνο εντός κάθε μορφής πληροφορίας αλλά και μεταξύ τους. Το γεγονός αυτό είναι ιδιαίτερα κρίσιμο σε εφαρμογές όπου συνυπάρχουν δεδομένα διαφορετικής φύσης και χρονικής πυκνότητας, όπως σε BMS δεδομένα πραγματικού κόσμου.

Η εργασία των Severson et al. [17] αποτελεί μια από τις πιο εμβληματικές προσπάθειες στο πεδίο των data-driven προσεγγίσεων. Οι συγγραφείς ανέπτυξαν ένα μοντέλο πρόβλεψης της διάρκειας ζωής μπαταριών τύπου LFP/Graphite χρησιμοποιώντας ως είσοδο μόνο τα δεδομένα από τους πρώτους 100 κύκλους. Το μοντέλο πέτυχε ποσοστό σφάλματος κάτω του 10%, αποδεικνύοντας ότι τα πρότυπα γήρανσης αποτυπώνονται ήδη από τις πρώτες φάσεις λειτουργίας και μπορούν να αξιοποιηθούν για πρόωμη πρόγνωση μέσω CNN.

Στη διεθνή βιβλιογραφία έχουν αναφερθεί ποικίλες αρχιτεκτονικές CNN για την πρόβλεψη είτε του SOH είτε του RUL. Ορισμένες χρησιμοποιούν 1D συνελκτικά φίλτρα πάνω σε χρονοσειρές τάσης ή θερμοκρασίας, ενώ άλλες ενσωματώνουν πλήρως διασυνδεδεμένα

στρώματα (fully connected layers) και μηχανισμούς attention για βελτίωση της μάθησης. Τα συστήματα αυτά συχνά υλοποιούνται σε πλατφόρμες όπως TensorFlow ή PyTorch και απαιτούν σημαντική ποσότητα δεδομένων για να επιτύχουν καλή γενίκευση. Παράλληλα, προκλήσεις παραμένουν σε θέματα όπως η υπερπροσαρμογή (overfitting), η έλλειψη ερμηνευσιμότητας (black-box nature) και η ανάγκη για βελτιστοποίηση υπερπαραμέτρων [22].

Σε σύγχρονες μελέτες παρατηρείται τάση για διπλής εξόδου δίκτυα (multi-output CNNs), όπου το δίκτυο προβλέπει ταυτόχρονα την εξέλιξη του SOH και το RUL, αξιοποιώντας κοινή αναπαράσταση χαρακτηριστικών. Αυτή η προσέγγιση, η οποία ταυτίζεται και με τη δομή που χρησιμοποιείται στην παρούσα διπλωματική εργασία, επιτρέπει βελτιωμένη αποδοτικότητα και συνεκτική πρόβλεψη των δύο κρίσιμων μετρικών γήρανσης. Επιπλέον, όταν τα δεδομένα δομούνται σε κατάλληλη μορφή (π.χ. τεμάχια χρονοσειρών ή "κύκλοι-παράθυρα"), επιτρέπεται η εκπαίδευση μοντέλων υψηλής απόδοσης ακόμα και με περιορισμένα σύνολα παρατήρησης.

Εν κατακλείδι, τα CNN έχουν καθιερωθεί ως μια ισχυρή προσέγγιση για την πρόβλεψη της υγείας μπαταριών, ειδικά όταν συνδυάζονται με πλούσια δεδομένα και τεχνικές προεπεξεργασίας. Η ικανότητά τους να λειτουργούν ως end-to-end συστήματα που μετατρέπουν ακατέργαστες εισόδους σε αξιόπιστες προβλέψεις τα καθιστά ελκυστικά για εφαρμογές πραγματικού χρόνου και έγκαιρης συντήρησης.

2.4 Αξιολόγηση Μοντέλων Πρόβλεψης: Μετρικές Απόδοσης και Πρακτικά Ζητήματα Εφαρμογής

Η αξιολόγηση των μοντέλων πρόβλεψης SOH και RUL είναι κρίσιμη για τη μετάβασή τους από το ερευνητικό στάδιο στην πρακτική εφαρμογή. Η ακρίβεια των προβλέψεων, η σταθερότητα υπό διαφορετικά σενάρια λειτουργίας και η υπολογιστική αποδοτικότητα συνιστούν βασικά κριτήρια που καθορίζουν τη χρησιμότητα ενός αλγορίθμου σε συστήματα πραγματικού χρόνου.

Η πιο συχνά χρησιμοποιούμενη μετρική στην ποσοτική αξιολόγηση των μοντέλων είναι το Μέσο Απόλυτο Σφάλμα (Mean Absolute Error - MAE), ορίζεται ως:

$$MAE = \frac{1}{n} \sum_{i=1}^n \left| \hat{y}_i - y_i \right|$$

όπου $\hat{y}_i$ είναι η προβλεπόμενη τιμή και y_i η πραγματική. Το MAE μετράει την απόλυτη απόκλιση των προβλέψεων από τις πραγματικές τιμές, χωρίς να τιμωρεί έντονα τις μεγάλες αποκλίσεις.

Εναλλακτικά, το Ριζικό Μέσο Τετραγωνικό Σφάλμα (Root Mean Square Error - RMSE) δίνει έμφαση σε μεγάλες αποκλίσεις λόγω του τετραγωνισμού:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Σε πολλές εργασίες, χρησιμοποιείται επίσης και ο Συντελεστής Προσδιορισμού (R^2 score), ο οποίος εκφράζει το ποσοστό της διακύμανσης των πραγματικών τιμών που εξηγείται από το μοντέλο:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Όσο το R^2 πλησιάζει το 1, τόσο πιο ικανό θεωρείται το μοντέλο.

Ωστόσο, πέρα από τις αριθμητικές μετρικές, η σταθερότητα των προβλέψεων υπό διαφορετικά προφίλ χρήσης, οι απαιτήσεις υπολογιστικής ισχύος, και η ικανότητα γενίκευσης σε νέους τύπους κυψελών είναι εξίσου σημαντικές παράμετροι. Πολλές μελέτες τονίζουν ότι ένα μοντέλο με υψηλή απόδοση σε πειραματικά δεδομένα μπορεί να αποτύχει πλήρως σε πραγματικά σενάρια εάν δεν έχει εκπαιδευτεί σε αντιπροσωπευτικά δεδομένα [23].

Επιπλέον, η ερμηνευσιμότητα των προβλέψεων αποτελεί σημαντικό πρακτικό ζήτημα. Μοντέλα τύπου “black-box”, όπως τα CNN ή τα LSTM, συχνά αποδίδουν εξαιρετικά αλλά δεν προσφέρουν άμεση φυσική ερμηνεία των αποτελεσμάτων, κάτι που περιορίζει τη χρήση τους σε κλάδους που απαιτούν πιστοποίηση και εμπιστοσύνη (π.χ. αεροπορικές εφαρμογές ή ιατρική διάγνωση).

Σε εφαρμογές πραγματικού χρόνου, η υπολογιστική πολυπλοκότητα του μοντέλου είναι κρίσιμη: μοντέλα με μεγάλο αριθμό παραμέτρων (π.χ. βαθιά CNN) απαιτούν μεγαλύτερους χρόνους εκπαίδευσης και inference, κάτι που ενδέχεται να μην είναι αποδεκτό σε embedded περιβάλλοντα ή edge συσκευές [24].

Ορισμένες εργασίες προτείνουν τεχνικές όπως η προεπεξεργασία με PCA ή autoencoders, η εκπαίδευση με data augmentation και η χρήση regularization για βελτίωση της γενίκευσης. Άλλες υιοθετούν cross-validation ή time-series split για την αποφυγή overfitting [25].

Αξιοσημείωτο είναι ότι μελέτες όπως αυτή των Jin et al. [22] συγκρίνουν συστηματικά διαφορετικές κατηγορίες μοντέλων (MLP, RF, CNN, LSTM, GRU) ως προς την ακρίβεια και τη σταθερότητα των προβλέψεων, δείχνοντας ότι δεν υπάρχει μία “καλύτερη” λύση – κάθε επιλογή εμπεριέχει συμβιβασμούς μεταξύ ακρίβειας, πολυπλοκότητας και πρακτικής ευχρηστίας.

2.5 Επιλογή Αρχιτεκτονικής CNN και Αιτιολόγηση

Η παρούσα διπλωματική εργασία βασίζεται σε συνελκτικά νευρωνικά δίκτυα (CNN) για την πρόβλεψη δύο κρίσιμων δεικτών απόδοσης μπαταριών ιόντων λιθίου: την Κατάσταση Υγείας (State of Health - SOH) και την Υπολειπόμενη Διάρκεια Ζωής (Remaining Useful Life - RUL). Η χρήση CNN δικαιολογείται πλήρως από τα πλεονεκτήματα που προσφέρει η αρχιτεκτονική αυτή στην ανάλυση χρονοσειρών.

Τα CNN είναι ιδιαίτερα αποτελεσματικά στην εξαγωγή τοπικών χρονικών προτύπων μέσα από διαδοχικές συνελκτικές και pooling διεργασίες. Σε αντίθεση με τα παραδοσιακά μοντέλα, δεν απαιτείται χειροκίνητη επιλογή χαρακτηριστικών, καθώς το δίκτυο μαθαίνει αυτόματα να εντοπίζει τα πιο διακριτικά μοτίβα από τα σήματα τάσης, ρεύματος και χωρητικότητας κατά τη διάρκεια των κύκλων φόρτισης και εκφόρτισης.


Σύμφωνα με τη μελέτη των Yu και Pan (2025), η ενσωμάτωση CNN σε προβλήματα πρόβλεψης μπαταριών οδηγεί σε σημαντικά χαμηλότερο σφάλμα σε σύγκριση με συμβατικές μεθόδους, ενώ η αρχιτεκτονική CNN προσφέρει και υψηλή γενίκευση σε διαφορετικά είδη κυψελών και λειτουργικών σεναρίων [26]. Στο πλαίσιο αυτό, προτείνουν έναν συνδυασμό CNN με GRU (Gated Recurrent Units), επιτυγχάνοντας ταυτόχρονη εκτίμηση SOH και RUL με ακρίβεια που υπερβαίνει τις τρέχουσες προσεγγίσεις.

Στη δική μας εφαρμογή, η αρχιτεκτονική CNN δέχεται δύο ροές εισόδου: (α) στατικά μονοδιάστατα χαρακτηριστικά και (β) πλήρεις χρονοσειρές από τάση/ρεύμα/χωρητικότητα. Αυτή η διπλή είσοδος επιτρέπει στο δίκτυο να αξιοποιεί τόσο τη στατιστική σύνοψη όσο και τη δυναμική εξέλιξη της κυψέλης, βελτιώνοντας περαιτέρω την ακρίβεια των προβλέψεων.

Επομένως, η επιλογή συνελκτικής αρχιτεκτονικής ανταποκρίνεται πλήρως τόσο στις ανάγκες του προβλήματος όσο και στις σύγχρονες ερευνητικές τάσεις που καταδεικνύουν τη δυναμική των CNN στην πρόβλεψη κατάστασης και διάρκειας ζωής σε συστήματα μπαταριών.

3. Η Προτεινόμενη Προσέγγιση

3.1 Επισκόπηση της Προτεινόμενης Προσέγγισης



Εικόνα 3.: Τα βήματα που ακολουθούνται στην προτεινόμενη προσέγγιση.

Η παρούσα εργασία προτείνει μια προσέγγιση βασισμένη στην αρχιτεκτονική των Συνελικτικών Νευρωνικών Δικτύων (Convolutional Neural Networks – CNNs). Στόχος της προσέγγισης είναι η πρόβλεψη του συνολικού προσδόκιμου διάρκειας ζωής μέσω της ταυτόχρονης εκτίμησης δύο ποσοτήτων: του αριθμού του τρέχοντος κύκλου και των υπολειπόμενων κύκλων λειτουργίας μέχρι την εξάντληση (RUL). Η προτεινόμενη μεθοδολογία ενσωματώνει ταυτόχρονα χρονικές εξαρτήσεις και ηλεκτροχημικές πληροφορίες που απορρέουν από τις χρονοσειρές τάσης, ρεύματος, θερμοκρασίας και χωρητικότητας.

Η καινοτομία της παρούσας προσέγγισης δεν έγκειται αποκλειστικά στη δομή του νευρωνικού μοντέλου, αλλά και στον τρόπο προεπεξεργασίας των δεδομένων, στην εξαγωγή κατάλληλων χαρακτηριστικών (featurization), καθώς και στη χρήση τεχνικών sliding windows για την ενίσχυση της χρονικής συνοχής των εισόδων. Ο συνδυασμός συνοπτικών (summary) και χρονοσειριακών χαρακτηριστικών επιτρέπει την έγκαιρη αναγνώριση υποκείμενων μοτίβων υποβάθμισης, βελτιώνοντας τη δυνατότητα γενίκευσης του μοντέλου σε κυψέλες που δεν έχουν παρατηρηθεί κατά την εκπαίδευση.

Η συνολική μεθοδολογία που ακολουθείται στην παρούσα εργασία περιλαμβάνει πέντε βασικά στάδια, τα οποία καλύπτουν όλο το φάσμα της ροής δεδομένων από τη συλλογή έως την παραγωγή προβλέψεων:

(1) Συλλογή και Οργάνωση Δεδομένων:

Τα δεδομένα προέρχονται από ανοιχτές βάσεις που περιλαμβάνουν λεπτομερείς καταγραφές λειτουργίας δεκάδων κυψελών ιόντων λιθίου, όπως το σύνολο δεδομένων του Severson et al. (2019) από το MIT. Οι πληροφορίες οργανώνονται ανά κύκλο και ανά κυψέλη, περιλαμβάνοντας μεταβλητές όπως τάση, ρεύμα, θερμοκρασία και χωρητικότητα. Η δομή τους επιτρέπει τη δημιουργία πολυδιάστατων χρονοσειρών για μετέπειτα επεξεργασία και εκπαίδευση.

(2) Προεπεξεργασία (Preprocessing):

Στο στάδιο αυτό εφαρμόζεται καθαρισμός των δεδομένων (π.χ. αφαίρεση outliers, χειρισμός ελλειπών τιμών), επαναδειγματοληψία ώστε να επιτευχθεί ομοιομορφία ανάμεσα στους κύκλους και κανονικοποίηση χαρακτηριστικών. Έπειτα, δημιουργούνται χρονοπαράθυρα σταθερού μήκους με τεχνική sliding windows, επιτρέποντας στο μοντέλο να "παρατηρεί" διαδοχικούς κύκλους και να εντοπίζει εξελικτικά μοτίβα υποβάθμισης.

(3) Εξαγωγή Χαρακτηριστικών (Featurization):

Από κάθε παράθυρο κύκλων εξάγονται δύο είδη χαρακτηριστικών: (α) χρονοσειριακά χαρακτηριστικά υψηλής ανάλυσης (π.χ. γραμμικοποιημένη εκφόρτιση Qdlin), τα οποία εισάγονται σε 2D-CNN υποδίκτυα και (β) συνοπτικά scalars όπως η εσωτερική αντίσταση, η εκφόρτιση (QD) και ο χρόνος εκφόρτισης, τα οποία υποβάλλονται σε 1D-CNN επεξεργασία. Η διττή αυτή αναπαράσταση επιτρέπει την εκμετάλλευση τόσο χρονικών μοτίβων όσο και γενικών τάσεων (Zhang et al., 2019).

(4) Εκπαίδευση Μοντέλου (Model Training):

Το συνελκτικό μοντέλο (CNN) δέχεται τις δύο μορφές εισόδου και εκπαιδεύεται ώστε να ελαχιστοποιεί ένα σύνθετο loss function για δύο εξόδους: τον αριθμό του τρέχοντος κύκλου και τους εναπομείναντες κύκλους μέχρι την εξάντληση ζωής της κυψέλης (dual-output regression).

(5) Αξιολόγηση και Παραγωγή Προβλέψεων (Evaluation & Inference):

Οι προβλέψεις αξιολογούνται με βάση μετρικές όπως το MAE (Mean Absolute Error) και MSE (Mean Squared Error), καθώς και το R^2 score. Τα αποτελέσματα αποθηκεύονται σε αρχεία .csv και οπτικοποιούνται με διαγράμματα μέσω Plotly, επιτρέποντας την ερμηνεία των αποκλίσεων και την κατανόηση της συμπεριφοράς του μοντέλου σε νέες κυψέλες.

3.2 Δεδομένα Μπαταριών

3.2.1 Συλλογή Δεδομένων

Για την παρούσα εργασία χρησιμοποιήθηκε σύνολο δεδομένων γήρανσης κυψελών (battery ageing dataset) το οποίο περιλαμβάνει λεπτομερή δεδομένα κύκλων φόρτισης και εκφόρτισης για σειρά εμπορικών κυψελών ιόντων λιθίου τύπου 18650. Τα δεδομένα καταγράφουν μετρήσεις όπως τάση, ρεύμα, θερμοκρασία και ικανότητα εκφόρτισης σε κάθε χρονικό σημείο του κύκλου, καθώς και συνοπτικά μεγέθη (summary features) όπως η εσωτερική αντίσταση και ο συνολικός χρόνος εκφόρτισης.

Η συλλογή των δεδομένων πραγματοποιήθηκε υπό ελεγχόμενες εργαστηριακές συνθήκες, με στόχο τη μελέτη της συμπεριφοράς της κυψέλης κατά τη διάρκεια της χρήσης της. Κάθε κυψέλη υπόκειται σε διαδοχικούς κύκλους φόρτισης–εκφόρτισης μέχρι να φτάσει στο προκαθορισμένο όριο τέλους ζωής (End of Life), όπως ορίζεται από τη μείωση της αποδοτικότητάς της. Το συνολικό dataset περιλαμβάνει εκατοντάδες τέτοιες κυψέλες με διαφορετικά μοτίβα χρήσης, προσφέροντας πλούτο πληροφορίας για την πρόβλεψη της διάρκειας ζωής τους.

3.2.2 Διερευνητική Ανάλυση Δεδομένων

Η διερευνητική ανάλυση (Exploratory Data Analysis – EDA) αποτελεί αναπόσπαστο στάδιο σε κάθε εφαρμογή μηχανικής μάθησης, καθώς επιτρέπει την αρχική κατανόηση της δομής, της ποιότητας και των συσχετίσεων των διαθέσιμων δεδομένων. Στην παρούσα εργασία, η EDA εφαρμόστηκε τόσο στα συνοπτικά χαρακτηριστικά (summary features) όσο και στα χρονικά χαρακτηριστικά (time-series), με στόχο την εξαγωγή χρήσιμων παρατηρήσεων που καθοδήγησαν τις επόμενες φάσεις προεπεξεργασίας και επιλογής μοντέλου.

Η ανάλυση των summary χαρακτηριστικών περιλάμβανε τη μελέτη των κατανομών των μεταβλητών (όπως IR, QD, discharge time και remaining cycles), καθώς και τον υπολογισμό πίνακα συσχέτισης, ώστε να εντοπιστούν τυχόν γραμμικές εξαρτήσεις ή αντιθέσεις μεταξύ τους. Μέσα από αυτές τις οπτικοποιήσεις αναδείχθηκαν μοτίβα σταθερότητας και φθοράς, όπως η σταδιακή μείωση της αποθηκευμένης ενέργειας (QD) σε σχέση με τον χρόνο.

Σε επίπεδο χρονοσειρών, οπτικοποιήθηκε η συμπεριφορά της καμπύλης εκφόρτισης (Qd vs Voltage) και της θερμοκρασίας (T vs Voltage) για αντιπροσωπευτικούς κύκλους κατά τη διάρκεια ζωής της κυψέλης. Οι καμπύλες αυτές φανερώνουν μορφολογικές μεταβολές που συνδέονται με τη γήρανση και ενισχύουν τη σημασία της μορφής της καμπύλης ως στοιχείο πρόγνωσης.

Επιπλέον, εφαρμόστηκε ανάλυση κύριων συνιστωσών (PCA) στα summary χαρακτηριστικά, αποκαλύπτοντας τη σχετική ομοιογένεια του πληθυσμού των κυψελών, αλλά και την ύπαρξη

outlier συμπεριφορών. Αυτή η παρατήρηση ανέδειξε την ανάγκη για κατάλληλη κανονικοποίηση και ενίσχυση της γενικευσιμότητας του μοντέλου.

Συνολικά, η EDA επέτρεψε την καλύτερη κατανόηση των διαθέσιμων δεδομένων, την επιβεβαίωση υποκείμενων συσχετίσεων και την ανάδειξη σημαντικών μοτίβων φθοράς, παρέχοντας ενδείξεις για τις επιλογές του επόμενου σταδίου προεπεξεργασίας.

3.2.3 Προεπεξεργασία Δεδομένων

Η προεπεξεργασία στοχεύει στον καθαρισμό των δεδομένων και στη μετατροπή τους σε μορφή κατάλληλη για εκπαίδευση μοντέλου. Αρχικά, πραγματοποιήθηκε φιλτράρισμα των κυψελών με βάση τη διάρκεια ζωής τους, απορρίπτοντας όσα δείγματα παρουσίαζαν αριθμό κύκλων μικρότερο των 150, καθώς θεωρήθηκαν ανεπαρκή για ασφαλή εκπαίδευση.

Ακολούθως, από το πλήρες σύνολο δεδομένων διατηρήθηκαν μόνο τα στάδια εκφόρτισης κάθε κύκλου, δεδομένου ότι φέρουν την κυρίαρχη πληροφορία που σχετίζεται με τη γήρανση της κυψέλης. Για κάθε κύκλο, το target ορίστηκε ως ο αριθμός κύκλων που απομένουν μέχρι το τέλος ζωής της κυψέλης (Remaining Useful Life – RUL), υπολογιζόμενος ως η διαφορά μεταξύ του συνολικού αριθμού κύκλων και του τρέχοντος κύκλου.

Τέλος, οι αριθμητικές μεταβλητές υποβλήθηκαν σε κανονικοποίηση με κλίμακα min–max βάσει του συνόλου εκπαίδευσης, ώστε να διασφαλιστεί αριθμητική σταθερότητα κατά την εκπαίδευση του νευρωνικού δικτύου.

3.2.4 Μηχανική Χαρακτηριστικών

Η μηχανική χαρακτηριστικών (feature engineering) συνιστά ένα από τα σημαντικότερα στάδια στην ανάπτυξη μοντέλων μηχανικής μάθησης, καθώς καθορίζει τον τρόπο με τον οποίο αποτυπώνεται η διαθέσιμη πληροφορία και διαμορφώνεται η είσοδος προς το μοντέλο. Στο πλαίσιο πρόβλεψης της διάρκειας ζωής των κυψελών λιθίου, η επιλογή των κατάλληλων χαρακτηριστικών δεν περιορίζεται μόνο στην ακρίβεια των μετρήσεων, αλλά επεκτείνεται στη φυσική σημασία των μεταβλητών, στη συσχέτισή τους με τη γήρανση και στη συμβατότητά τους με τη μορφή του επιλεγμένου αρχιτεκτονικού μοντέλου.

Για την παρούσα εργασία αξιοποιήθηκαν δύο διακριτές κατηγορίες χαρακτηριστικών: συνοπτικά (summary features) και χρονοσειρές (time-series features). Τα summary χαρακτηριστικά αποτελούν αριθμητικά μεγέθη που συνοψίζουν τη συμπεριφορά της κυψέλης στο τέλος κάθε κύκλου, παρέχοντας πληροφορία για τη συνολική της κατάσταση. Συγκεκριμένα, χρησιμοποιήθηκαν η εσωτερική αντίσταση (IR), η αποδιδόμενη χωρητικότητα εκφόρτισης (QD) και η συνολική διάρκεια του σταδίου εκφόρτισης (discharge time), τα οποία θεωρούνται κοινώς αποδεκτοί δείκτες γήρανσης των κυψελών και χρησιμοποιούνται ευρέως στη βιβλιογραφία για την πρόγνωση της διάρκειας ζωής.

Ωστόσο, η μορφή της καμπύλης εκφόρτισης, όπως αποτυπώνεται μέσω της συσχέτισης της χωρητικότητας ή της θερμοκρασίας με την τάση, ενέχει κρίσιμη πληροφορία για τη λειτουργική υποβάθμιση της κυψέλης που δεν μπορεί να συλληφθεί πλήρως από ένα μόνο συνοπτικό μέγεθος. Για τον λόγο αυτό, από τα δεδομένα των χρονικών μετρήσεων κάθε κύκλου εξήχθησαν χαρακτηριστικά σε μορφή σταθερού μήκους χρονοσειρών μέσω παρεμβολής (interpolation). Πιο συγκεκριμένα, τα χαρακτηριστικά Qd (αποδιδόμενη χωρητικότητα) και T (θερμοκρασία) προσεγγίστηκαν με χρήση παρεμβολής γραμμικού τύπου επί ενός κοινού πλέγματος τάσης, το οποίο ορίστηκε ως γραμμικά κατανεμημένη ακολουθία

1000 σημείων μεταξύ των ορίων λειτουργίας της κυψέλης. Το αποτέλεσμα αυτής της διαδικασίας είναι δύο διανύσματα σταθερού μήκους, τα Qdlin και Tdlin, τα οποία διατηρούν τη μορφολογία της αρχικής καμπύλης εκφόρτισης, ανεξάρτητα από τον αριθμό μετρήσεων στον αρχικό κύκλο.

Η επιλογή της τάσης ως ανεξάρτητης μεταβλητής (αντί του χρόνου ή του δείκτη μέτρησης) επιτρέπει τη συγκρίσιμη αναπαράσταση διαφορετικών κύκλων μεταξύ κυψελών, καθώς η εξέλιξη της τάσης κατά την εκφόρτιση είναι πιο ομοιόμορφη και σταθερή σε σχέση με άλλους άξονες μέτρησης. Παράλληλα, η παρεμβολή εξαλείφει το πρόβλημα μεταβλητού αριθμού δειγμάτων ανά κύκλο, το οποίο αποτελεί σημαντικό εμπόδιο στην εκπαίδευση συνελκτικών μοντέλων, που απαιτούν σταθερό σχήμα εισόδου.

Προκειμένου να ενσωματωθεί και η διαχρονική πληροφορία, εφαρμόστηκε τεχνική παραθύρων μεταβλητού χρόνου (sliding window), κατά την οποία κάθε είσοδος του μοντέλου προκύπτει από ομάδα 20 διαδοχικών κύκλων, μετατοπιζόμενη ανά 5 κύκλους. Με αυτόν τον τρόπο, η είσοδος του μοντέλου περιλαμβάνει τόσο τα summary όσο και τα time-series χαρακτηριστικά για κάθε κύκλο εντός του παραθύρου, αποτυπώνοντας την πρόσφατη ιστορία λειτουργίας της κυψέλης σε επίπεδο τόσο στατιστικό όσο και μορφολογικό.

Τέλος, όλα τα χαρακτηριστικά υποβλήθηκαν σε κανονικοποίηση με βάση το εύρος min-max του συνόλου εκπαίδευσης. Η κανονικοποίηση αυτή ήταν απαραίτητη ώστε να διασφαλιστεί αριθμητική σταθερότητα κατά τη διαδικασία εκπαίδευσης και να αποτραπεί η υπερενίσχυση ορισμένων χαρακτηριστικών έναντι άλλων.


3.3 Μοντέλο Βαθιάς Μηχανικής Μάθησης

Η ανάγκη για μοντέλα που μπορούν να εντοπίζουν πρότυπα φθοράς σε πρώιμα στάδια λειτουργίας μπαταριών οδήγησε στην υιοθέτηση μεθόδων βαθιάς μάθησης (deep learning), με στόχο τη μάθηση από χρονοσειρές δεδομένων χωρίς να απαιτείται χειροκίνητη εξαγωγή χαρακτηριστικών. Στην προτεινόμενη προσέγγιση, βασικός μηχανισμός είναι το Συνελκτικό Νευρωνικό Δίκτυο (Convolutional Neural Network – CNN), το οποίο αξιοποιεί τόσο τη χρονική πληροφορία όσο και τη δομή της εκφόρτισης για την πρόβλεψη κρίσιμων ποσοτήτων όπως ο αριθμός κύκλων που απομένουν (RUL – Remaining Useful Life).

3.3.1 Θεωρητικό Υπόβαθρο Συνελκτικών Νευρωνικών Δικτύων

Τα Συνελκτικά Νευρωνικά Δίκτυα (Convolutional Neural Networks - CNNs) αποτελούν μία από τις πιο διαδεδομένες αρχιτεκτονικές βαθιάς μάθησης, με αφετηρία την επεξεργασία εικόνων, αλλά με σημαντική επέκταση τα τελευταία χρόνια σε ανάλυση χρονοσειρών, ιατρικά δεδομένα, και πρόβλεψη φθοράς σε τεχνικά συστήματα όπως οι μπαταρίες ιόντων λιθίου. Οι συνελκτικοί πυρήνες λειτουργούν ως τοπικά φίλτρα, επιτρέποντας στο δίκτυο να ανιχνεύσει επαναλαμβανόμενα πρότυπα μέσα στα δεδομένα, ενώ η ιεραρχική τους διάταξη οδηγεί στην εκμάθηση αναπαραστάσεων διαφορετικού επιπέδου αφαιρετικότητας (Goodfellow et al., 2016).

Σε αντίθεση με τα πλήρως συνδεδεμένα (Dense) δίκτυα, τα CNNs αξιοποιούν τη χωρική ή χρονική συσχέτιση των εισόδων μέσω της παραθύρωσης, μειώνοντας δραστικά τον αριθμό των παραμέτρων και ενισχύοντας τη γενίκευση. Αυτό καθιστά τα CNNs ιδανικά για




Εικόνα 4: Τυπική αρχιτεκτονική ενός Συνελκτικού Νευρωνικού Δικτύου (CNN) για ανάλυση χρονοσειρών: περιλαμβάνει στρώση εισόδου με δεδομένα χρόνου, συνελκτικές και pooling στρώσεις για εξαγωγή χαρακτηριστικών, και πλήρως συνδεδεμένη στρώση για την τελική πρόβλεψη

προβλήματα χρονοσειρών, όπως η παρακολούθηση κύκλων φόρτισης/εκφόρτισης σε μπαταρίες, όπου η πληροφορία εντοπίζεται τοπικά στον χρόνο. Οι τεχνικές MaxPooling και Global Average Pooling προσφέρουν επιπλέον συμπίεση και ανθεκτικότητα στον θόρυβο.

Η εφαρμογή των CNNs στην πρόβλεψη της κατάστασης υγείας (SOH) και της εναπομείνουσας διάρκειας ζωής (RUL) των μπαταριών έχει καταγραφεί εκτενώς στη βιβλιογραφία. Οι πρώτες προσπάθειες, όπως αυτή των Severson et al. (2019), χρησιμοποίησαν πρόωρους κύκλους δεδομένων για την πρόβλεψη της διάρκειας ζωής. Στη συνέχεια, μελέτες όπως των Wu et al. (2020) και Li et al. (2021) εφάρμοσαν CNNs σε μονοδιάστατες (1D) και δισδιάστατες (2D) αναπαραστάσεις των δεδομένων εκφόρτισης, με σκοπό την εξαγωγή χαρακτηριστικών που σχετίζονται με τη φθορά της μπαταρίας.

Πρόσφατα, η έρευνα έχει στραφεί στην ανάπτυξη πιο γενικευμένων και ευέλικτων αρχιτεκτονικών, όπως τα πολλαπλής εισόδου–πολλαπλής εξόδου (Multi-Input Multi-Output, MIMO) CNNs, τα οποία επιτρέπουν την ταυτόχρονη επεξεργασία ετερογενών τύπων δεδομένων και την πρόβλεψη πολλαπλών στόχων. Σε τέτοια πλαίσια, οι διαφορετικές εισοδοί μπορούν να αφορούν χρονοσειρές, στατικά χαρακτηριστικά, ακόμη και εξωτερικές παραμέτρους (π.χ. θερμοκρασία περιβάλλοντος), ενώ οι εξοδοί μπορεί να περιλαμβάνουν ταυτόχρονα εκτιμήσεις για την κατάσταση υγείας (SOH), τον αριθμό κύκλου, την υπολειπόμενη διάρκεια ζωής (RUL), ή και την προβλεπόμενη συμπεριφορά σε μελλοντικές συνθήκες λειτουργίας.




Εικόνα 5: Ενδεικτικό διάγραμμα αρχιτεκτονικής CNN πολλαπλών εισόδων - εξόδων

Η υιοθέτηση MIMO αρχιτεκτονικών επιτρέπει την παράλληλη εκμάθηση κοινών και ειδικών αναπαραστάσεων μεταξύ των εισροών και των επιμέρους στόχων, ενισχύοντας τη γενίκευση και την ακρίβεια. Στο πλαίσιο των συνελικτικών δικτύων, αυτό επιτυγχάνεται με διακλαδώσεις (branches) που συγχωνεύονται σε κοινό ενδιάμεσο χώρο χαρακτηριστικών, ο οποίος στη συνέχεια διαχωρίζεται σε πολλαπλά κανάλια εξόδου, καθένα από τα οποία εξειδικεύεται στην πρόβλεψη μιας συγκεκριμένης μεταβλητής. Επιπλέον, η κοινή βελτιστοποίηση των επιμέρους στόχων προσφέρει μια πιο σταθερή καμπύλη εκπαίδευσης, καθώς το μοντέλο καθοδηγείται από πλούσιες και συμπληρωματικές πληροφορίες.

3.3.2 Αρχιτεκτονική CNN στην Προτεινόμενη Προσέγγιση


Η αρχιτεκτονική που υιοθετείται στην παρούσα εργασία βασίζεται σε ένα συνελκτικό μοντέλο δύο κλάδων (dual-branch CNN). Συγκεκριμένα, σχεδιάστηκαν δύο παράλληλες ροές επεξεργασίας:

- Ο πρώτος κλάδος δέχεται ως είσοδο χρονοσειρές φυσικών μετρήσεων (όπως καμπύλες τάσης-χωρητικότητας) και τις επεξεργάζεται μέσω διαδοχικών συνελκτικών και pooling στρώσεων. Ο στόχος του είναι να εντοπίσει επαναλαμβανόμενα πρότυπα και ρυθμούς υποβάθμισης της κυψέλης.




Εικόνα 6: Απεικόνιση της ροής επεξεργασίας στον χρονικό βραχίονα (time-series branch) του προτεινόμενου συνελκτικού νευρωνικού δικτύου.

- Ο δεύτερος κλάδος επεξεργάζεται συνοπτικά αριθμητικά χαρακτηριστικά (summary features), όπως μέσες τιμές θερμοκρασίας, μέγιστη χωρητικότητα ή διάρκεια κύκλου, μέσω πλήρως συνδεδεμένων (Dense) στρώσεων, επιτρέποντας στο δίκτυο να ενσωματώσει στατιστική πληροφορία χαμηλής διαστατικότητας.



Εικόνα 7: Διαγραμματική απεικόνιση της ροής επεξεργασίας στον βραχίονα συνοπτικών χαρακτηριστικών (scalar branch) του προτεινόμενου δικτύου.

Οι δύο κλάδοι συγχωνεύονται σε ενδιάμεσο στάδιο (feature fusion), δημιουργώντας ένα ενοποιημένο ενδιάμεσο επίπεδο χαρακτηριστικών, το οποίο οδηγείται σε τελικές στρώσεις πρόβλεψης (fully connected layers) με στόχο την εκτίμηση του SOH και του RUL.



Εικόνα 8: Διαγραμματική αναπαράσταση της πλήρους αρχιτεκτονικής του προτεινόμενου μοντέλου πρόβλεψης διάρκειας ζωής κυψελών ιόντων λιθίου

Ας θεωρήσουμε ότι κάθε δείγμα κυψέλης περιγράφεται από ένα ζεύγος εισόδων ($\mathbf{X}_1, \mathbf{X}_2$), όπου:

- $\mathbf{X}_1 \in \mathbb{R}^{T \times V \times C}$: χρονικές σειρές με T κύκλους, V σημεία παρεμβολής και $C = 2$ κανάλια (Qdlin και Tdlin),
- $\mathbf{X}_2 \in \mathbb{R}^{T \times S}$: συνοπτικά χαρακτηριστικά με $S = 3$ μεταβλητές (IR, QD, Discharge Time).

Ο στόχος του μοντέλου είναι η εκμάθηση μιας μη γραμμικής συνάρτησης:

$f_{\theta}: (\mathbf{X}_1, \mathbf{X}_2) \rightarrow \hat{\mathbf{y}} = [\hat{\mathbf{y}}^{\{\text{curr}\}}, \hat{\mathbf{y}}^{\{\text{RUL}\}}]$, όπου θ είναι το σύνολο παραμέτρων του μοντέλου και η έξοδος περιλαμβάνει τόσο την πρόβλεψη του τρέχοντος αριθμού κύκλου όσο και την υπολειπόμενη διάρκεια ζωής της κυψέλης.

Ο πρώτος κλάδος (time-series branch) επεξεργάζεται δεδομένα τύπου εικόνας τριών διαστάσεων (κύκλοι $\times$ voltage grid $\times$ κανάλια). Σε κάθε συνελκτική στρώση, το δίκτυο εφαρμόζει φίλτρα $W^{(l)} \in \mathbb{R}^{k_h \times k_w}$, μαθαίνοντας να εντοπίζει χωροχρονικά πρότυπα στα δεδομένα εκφόρτισης. Η έξοδος κάθε στρώσης δίνεται από:

$$H_{i,j}^{(l)} = \sigma \left(\sum_{m=0}^{kh-1} \sum_{n=0}^{kw-1} W_{m,n}^{(l)} \cdot H_{i+m,j+n}^{(l-1)} + b^{(l)} \right),$$

με $\sigma(\cdot)$ συνήθως ReLU. Οι διαδοχικές στρώσεις συνελίξεων επιτρέπουν στο δίκτυο να αναγνωρίσει μοτίβα μορφολογικής φθοράς, όπως αλλαγές στην κλίση της καμπύλης χωρητικότητας, τοπικά "γονατίσματα" στη θερμοκρασία ή σταθερά offset σε συγκεκριμένες περιοχές τάσης.

Ο δεύτερος κλάδος (scalar branch) επεξεργάζεται τις IR, QD και Discharge Time σε διανύσματα μήκους T . Χρησιμοποιούνται συνελικτικές στρώσεις τύπου 1D:

$$h_t^{(l)} = \sigma \left(\sum_{k=0}^{K-1} w_k^{(l)} \cdot h_{t+k}^{(l-1)} + b^{(l)} \right).$$

Αυτό επιτρέπει την αναγνώριση τοπικών τάσεων στα στατιστικά χαρακτηριστικά.

Τα διανύσματα εξόδου z_1 και z_2 από τους δύο κλάδους συγχωνεύονται: $z = [z_1 ; z_2]$. Η τελική έξοδος προκύπτει μέσω πλήρως συνδεδεμένης στρώσης: $\hat{y} = \text{ClippedReLU}(W \cdot z + b)$, όπου $\text{ClippedReLU}(x) = \min(\max(x, 0), M)$. Η ενεργοποίηση αυτή διασφαλίζει ότι οι προβλέψεις παραμένουν εντός φυσικών ορίων.

Το μοντέλο εκπαιδεύεται με μέση τετραγωνική απόκλιση ως συνάρτηση κόστους:

$$\mathcal{L} = \frac{1}{N} \sum_{i=1}^N \left[\left(y_i^{(\text{curr})} - \hat{y}_i^{(\text{curr})} \right)^2 + \left(y_i^{(\text{RUL})} - \hat{y}_i^{(\text{RUL})} \right)^2 \right].$$

Η εκπαίδευση γίνεται με οπισθοδιάδοση και ο αλγόριθμος βελτιστοποίησης εφαρμόζεται ταυτόχρονα για την πρόβλεψη του παρελθόντος και του μέλλοντος.

3.4 Αξιολόγηση του Μοντέλου και Παραγωγή Προβλέψεων

Η αξιολόγηση του μοντέλου πραγματοποιείται με βάση δύο κύρια κριτήρια: το Root Mean Squared Error (RMSE) και το Mean Absolute Error (MAE). Οι μετρικές αυτές επιλέγονται ώστε να ποσοτικοποιήσουν τόσο την απόλυτη όσο και τη σχετική απόκλιση των προβλέψεων του μοντέλου από τις πραγματικές τιμές.

Το RMSE ορίζεται ως

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

όπου y_i είναι η πραγματική τιμή του RUL για τον κύκλο i , $\hat{y}_i$ η αντίστοιχη πρόβλεψη του μοντέλου, και n το πλήθος των παρατηρήσεων στο σύνολο ελέγχου (validation set).

Παράλληλα, η απόδοση του μοντέλου αξιολογείται μέσω της R-squared (R^2) μετρικής, η οποία εκφράζει το ποσοστό της διακύμανσης των δεδομένων που εξηγείται από το μοντέλο.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

όπου $\bar{y}$ η μέση τιμή των πραγματικών τιμών.

Ο διαχωρισμός των παρατηρήσεων σε σύνολο εκπαίδευσης και σύνολο αξιολόγησης πραγματοποιείται βάσει προκαθορισμένου αρχείου διαχωρισμού, εξασφαλίζοντας την αποφυγή overfitting κατά τη φάση της εκπαίδευσης. Το δίκτυο εκπαιδεύεται αποκλειστικά στα δεδομένα του training set, ενώ η αξιολόγηση της απόδοσής του γίνεται στο validation set.

Οι προβλέψεις που παράγει το μοντέλο στο σύνολο αξιολόγησης αξιοποιούνται για την εκτίμηση της ακρίβειάς του ως προς την πρόβλεψη της υπολειπόμενης διάρκειας ζωής (RUL). Πριν την αποτίμηση των σφαλμάτων, οι προβλεπόμενες τιμές αποκλιμακώνονται, ώστε να επανέλθουν στην αρχική τους κλίμακα, μέσω αντιστροφής των παραμέτρων κανονικοποίησης που εφαρμόστηκαν κατά το στάδιο της προεπεξεργασίας. Η επαναφορά αυτή είναι απαραίτητη για την ερμηνεία των αποτελεσμάτων σε ερμηνεύσιμες μονάδες (κύκλοι ζωής).

Η συνολική διαδικασία πλαισιώνεται από γραφικές απεικονίσεις, όπως διαγράμματα διασποράς (scatter plots) μεταξύ προβλεπόμενων και πραγματικών τιμών, διαγράμματα υπολοίπων σφαλμάτων (residual plots) και ιστογράμματα κατανομής σφαλμάτων. Οι

απεικονίσεις αυτές παρέχουν οπτική ερμηνεία της συμπεριφοράς του μοντέλου και συμβάλλουν στην ανίχνευση ελλείψεων του μοντέλου.

4 Υλοποίηση και Αξιολόγηση

Στο παρόν κεφάλαιο παρουσιάζεται η διαδικασία υλοποίησης της προτεινόμενης προσέγγισης, όπως αυτή περιγράφηκε στο Κεφάλαιο 3, καθώς και τα αποτελέσματα της αξιολόγησής της με βάση τις επιλεγμένες ποσοτικές μετρικές. Σκοπός της ενότητας αυτής είναι να καταδειχθεί ο βαθμός αποτελεσματικότητας του συνελκτικού νευρωνικού μοντέλου που αναπτύχθηκε.

Η υλοποίηση πραγματοποιήθηκε με χρήση εργαλείων ανοικτού λογισμικού και γλωσσών προγραμματισμού. Το σύνολο της μεθοδολογίας αναπτύχθηκε με γνώμονα τη δυνατότητα αναπαραγωγής των πειραμάτων και την ευκολία ενσωμάτωσης σε πρακτικές εφαρμογές, όπως ένα σύστημα διαχείρισης μπαταρίας (Battery Management System – BMS).

4.1 Τεχνική Υλοποίηση

Η υλοποίηση της πειραματικής διαδικασίας πραγματοποιήθηκε εξ ολοκλήρου σε περιβάλλον Python, αξιοποιώντας σύγχρονες βιβλιοθήκες ανοικτού κώδικα για ανάλυση δεδομένων, κατασκευή και εκπαίδευση μοντέλων Μηχανικής Μάθησης, καθώς και για την οπτικοποίηση των αποτελεσμάτων. Οι τεχνολογίες που επιλέχθηκαν είναι οι εξής:

Python

Η γλώσσα προγραμματισμού Python αποτελεί σήμερα το βασικότερο εργαλείο για την ανάπτυξη εφαρμογών Μηχανικής Μάθησης και Ανάλυσης Δεδομένων. Διακρίνεται για την απλότητά της, τη μεγάλη κοινότητα υποστήριξης και τη διαθεσιμότητα βιβλιοθηκών για κάθε στάδιο της ροής εργασίας. Στην παρούσα εργασία, χρησιμοποιήθηκε η έκδοση 3.10.2, η οποία προσφέρει συμβατότητα με τα πιο πρόσφατα APIs των TensorFlow και Scikit-learn.

Jupyter Notebooks

Η πλατφόρμα Jupyter Notebooks χρησιμοποιήθηκε ως το βασικό περιβάλλον ανάπτυξης κώδικα, πειραμάτων και οπτικοποίησης. Παρέχει τη δυνατότητα συγγραφής επαναλήψιμου και τεκμηριωμένου κώδικα, ενσωματώνοντας υπολογιστικά blocks και ερμηνευτικό κείμενο σε κοινό περιβάλλον. Ιδιαίτερα κατάλληλο για EDA, ανάλυση σφαλμάτων και documentation της πειραματικής διαδικασίας.

TensorFlow

Το TensorFlow αποτελεί μια ισχυρή πλατφόρμα υπολογισμού για την κατασκευή και εκπαίδευση νευρωνικών δικτύων, η οποία αναπτύσσεται και συντηρείται από την Google. Η υλοποίηση βασίστηκε στη χρήση του API υψηλού επιπέδου tf.keras, που επιτρέπει την εύκολη διαχείριση layers, optimizer, loss functions και callbacks. Επιπλέον, χρησιμοποιήθηκαν τα

modules του TensorFlow για την αποθήκευση δεδομένων σε μορφή TFRecord και τη δημιουργία αποδοτικών data pipelines με χρήση `tf.data.Dataset`.

NumPy

Η βιβλιοθήκη NumPy προσφέρει αποτελεσματικές δομές και λειτουργίες για αριθμητικό υπολογισμό και διαχείριση πολυδιάστατων πινάκων. Στο πλαίσιο της παρούσας εργασίας, αξιοποιήθηκε εκτενώς για την υλοποίηση vectorized λειτουργιών, παρεμβολών, κανονικοποίησης τιμών και μετασχηματισμών δεδομένων. Ο πυρήνας της λειτουργίας `ndarray` αποτέλεσε τη βάση για την αποδοτική προετοιμασία των input δεδομένων για το μοντέλο.

Pandas

Η βιβλιοθήκη Pandas χρησιμοποιήθηκε για τη δομημένη ανάγνωση, οργάνωση και διαχείριση δεδομένων σε μορφή πινάκων (dataframes). Με χρήση συναρτήσεων όπως `.groupby()`, `.merge()` και `.interpolate()`, πραγματοποιήθηκε καθαρισμός και ευθυγράμμιση των δεδομένων ανά κύκλο και ανά κυψέλη. Επιπλέον, προσέφερε λειτουργίες εύκολης μετατροπής των δεδομένων σε μορφή κατάλληλη για visualizations και debugging.

Pandas

Η βιβλιοθήκη Pandas χρησιμοποιήθηκε για τη δομημένη ανάγνωση, οργάνωση και διαχείριση δεδομένων σε μορφή πινάκων (dataframes). Με χρήση συναρτήσεων όπως `.groupby()`, `.merge()` και `.interpolate()`, πραγματοποιήθηκε καθαρισμός και ευθυγράμμιση των δεδομένων ανά κύκλο και ανά κυψέλη. Επιπλέον, προσέφερε λειτουργίες εύκολης μετατροπής των δεδομένων σε μορφή κατάλληλη για visualizations και debugging.

Scikit-learn

Το Scikit-learn αποτέλεσε βασικό εργαλείο για την εφαρμογή κλασικών τεχνικών προεπεξεργασίας και στατιστικής αξιολόγησης. Χρησιμοποιήθηκαν modules όπως `StandardScaler` και `MinMaxScaler` για την κανονικοποίηση χαρακτηριστικών, καθώς και η PCA για τη διερεύνηση της διαστατικότητας των δεδομένων. Παράλληλα, αξιοποιήθηκαν συναρτήσεις υπολογισμού μετρικών απόδοσης όπως το RMSE και το R^2 score.

Pickle

Η βιβλιοθήκη Pickle αξιοποιήθηκε για την αποθήκευση και επαναφόρτωση ενδιάμεσων αρχείων δεδομένων σε μορφή δυαδικών αντικειμένων (.pkl). Με τον τρόπο αυτό διατηρήθηκε η συνέπεια στην πειραματική αναπαραγωγή και επιταχύνθηκε η διαδικασία επανεκτέλεσης του pipeline χωρίς την ανάγκη επαναπροετοιμασίας των δεδομένων.

Τεχνολογία / Βιβλιοθήκη	Έκδοση	Περιγραφή
Python	3.10.2	Γλώσσα προγραμματισμού που χρησιμοποιήθηκε για όλη την υλοποίηση
TensorFlow	2.8.0	Βιβλιοθήκη βαθιάς μάθησης, χρησιμοποιήθηκε για το μοντέλο CNN
Keras API	Ενσωματωμένο	Εσωτερικό API του TensorFlow για ορισμό και εκπαίδευση νευρωνικών δικτύων
Pandas	1.4.1	Επεξεργασία, καθαρισμός και μετασχηματισμός δεδομένων (DataFrames)
NumPy	1.26+	Υπολογιστικές πράξεις, πίνακες και επεξεργασία χρόνιων σειρών
SciPy	1.11+	Παρεμβολή, smoothing φίλτρα και στατιστική επεξεργασία
Scikit-learn	1.1.1	Διαχωρισμός σε train/test sets, MSE/MAE, κανονικοποίηση
Plotly	—	Διαδραστικά διαγράμματα αξιολόγησης σε HTML
TensorBoard	—	Παρακολούθηση της εκπαίδευσης και των validation μετρικών
Argparse	—	Διαχείριση παραμέτρων εκτέλεσης σε scripts

Πίνακας 2: Συνοπτικός Πίνακας Τεχνολογιών που χρησιμοποιήθηκαν.


4.2 Συλλογή Δεδομένων

Η αξιοπιστία και η εγκυρότητα κάθε μεθοδολογίας πρόβλεψης διάρκειας ζωής μπαταριών εξαρτάται σε μεγάλο βαθμό από την ποιότητα των δεδομένων που χρησιμοποιούνται για την εκπαίδευση και την αξιολόγηση των μοντέλων. Στη διεθνή βιβλιογραφία έχουν παρουσιαστεί αρκετά πειραματικά σύνολα δεδομένων, όπως το NASA Ames dataset (Saha & Goebel, 2007) και τα δεδομένα του CALCE (Baumhöfer et al., 2014), τα οποία αποτέλεσαν πρώιμα σημεία αναφοράς για την ανάπτυξη αλγορίθμων πρόγνωσης. Ωστόσο, τα περισσότερα από αυτά χαρακτηρίζονται από περιορισμένο αριθμό κυψελών, ετερογενείς συνθήκες λειτουργίας ή έλλειψη συστηματικής τεκμηρίωσης, περιορίζοντας έτσι τη δυνατότητα γενίκευσης των μοντέλων και τη χρησιμότητά τους σε πραγματικά σενάρια.

Για την παρούσα εργασία επιλέχθηκε το MIT/Stanford Battery Cycle Life Dataset, το οποίο δημιουργήθηκε από ερευνητικές ομάδες του MIT και του Stanford σε συνεργασία με το Toyota Research Institute και δημοσιεύθηκε στο *Nature Energy* (Severson et al., 2019). Το σύνολο αυτό, που είναι διαθέσιμο δημόσια μέσω της πλατφόρμας Matr.io, θεωρείται ορόσημο στην έρευνα καθώς συγκεντρώνει δεδομένα από 124 εμπορικές κυψέλες LiFePO₄/graphite (A123 Systems APR18650M1A), ονομαστικής χωρητικότητας 1.1 Ah και τάσης 3.3 V, οι οποίες υποβλήθηκαν σε συστηματικά πειράματα ταχείας φόρτισης. Το dataset περιλαμβάνει περίπου 96.700 κύκλους λειτουργίας, γεγονός που το καθιστά ένα από τα μεγαλύτερα και πιο ολοκληρωμένα πειραματικά σύνολα που είναι σήμερα διαθέσιμα για μπαταρίες ιόντων λιθίου.

Τα πειράματα διεξήχθησαν σε θάλαμο ελεγχόμενης θερμοκρασίας 30 °C, με συνεχή παρακολούθηση κρίσιμων παραμέτρων όπως τάση, ρεύμα, θερμοκρασία και εσωτερική αντίσταση. Για το τμήμα φόρτισης 0–80% SOC εφαρμόστηκαν 72 διαφορετικές πολιτικές ταχείας φόρτισης, οι οποίες είχαν σχεδιαστεί έτσι ώστε να προκαλέσουν διαφοροποιήσεις στον ρυθμό γήρανσης. Οι πολιτικές αυτές διακρίνονταν σε μονοβηματικές, όπου η φόρτιση πραγματοποιούνταν με σταθερό ρεύμα μεταξύ 3.6C και 6C, και σε διβηματικές, όπου το αρχικό τμήμα της φόρτισης (π.χ. 0–50% SOC) πραγματοποιούνταν με υψηλότερο ρεύμα (π.χ. 6C), ενώ το υπόλοιπο (50–80% SOC) με χαμηλότερο (π.χ. 4C). Μετά το 80% SOC, όλες οι κυψέλες ακολούθησαν ένα κοινό πρωτόκολλο CC–CV στο 1C μέχρι τα 3.6 V, με cutoff ρεύμα C/50, ενώ στο ίδιο σημείο πραγματοποιούνταν και μέτρηση της εσωτερικής αντίστασης με παλμούς $\pm 3.6C$ διάρκειας 30–33 ms. Η εκφόρτιση σε όλες τις περιπτώσεις ακολουθούσε ενιαίο

πρωτόκολλο CC–CV σε 4C μέχρι τα 2.0 V, με cutoff C/50, ώστε να διασφαλίζεται ότι οι διαφορές στη διάρκεια ζωής οφείλονται αποκλειστικά στις συνθήκες φόρτισης.



Εικόνα 9: Ενδεικτική απεικόνιση πρωτοκόλλων φόρτισης και εκφόρτισης.

Η διάρκεια ζωής κάθε κυψέλης ορίστηκε ως ο αριθμός κύκλων μέχρι η χωρητικότητα να μειωθεί στο 80% της αρχικής τιμής, κριτήριο που αποτελεί τον καθιερωμένο ορισμό του τέλους ζωής (End of Life – EoL). Το σύνολο δεδομένων οργανώνεται σε τρεις πειραματικές σειρές, οι οποίες πραγματοποιήθηκαν σε διαφορετικές ημερομηνίες και διαφοροποιούνται σε ορισμένες λεπτομέρειες του σχεδιασμού τους. Η πρώτη παρτίδα δεδομένων, που συλλέχθηκε στις 12 Μαΐου 2017, περιλαμβάνει κυψέλες που φορτίστηκαν με μονοβηματικά ή διβηματικά πρωτόκολλα ταχείας φόρτισης, με ρεύματα μεταξύ 3.6C και 6C μέχρι το 80% SOC. Κατά τη διάρκεια αυτών των πειραμάτων εφαρμόστηκαν μικρά διαλείμματα διάρκειας ενός λεπτού και ενός δευτερολέπτου μετά την επίτευξη του 80% SOC τόσο στη φόρτιση όσο και στην εκφόρτιση, ενώ η φόρτιση ολοκληρωνόταν μέχρι το 100% SOC με πρωτόκολλο CC–CV στο 1C έως τα 3.6 V, με cutoff ρεύμα C/50. Όπως σε κάθε batch, πραγματοποιήθηκε αρχικός κύκλος C/10 για τη σταθεροποίηση των κυψελών. Η εσωτερική αντίσταση μετρήθηκε μέσω παλμών $\pm 3.6C$ διάρκειας 30 ms. Παρά την υψηλή ποιότητα των δεδομένων, ορισμένα κανάλια, όπως τα 4 και 8, δεν απέδωσαν έγκυρες καταγραφές λόγω τεχνικών αστοχιών κατά την εκκίνηση.

Η δεύτερη παρτίδα δεδομένων συλλέχθηκε στις 30 Ιουνίου 2017 και σχεδιάστηκε με στόχο τον έλεγχο της διάρκειας φόρτισης, η οποία σταθεροποιήθηκε σε περίπου 10 λεπτά για το διάστημα 0–80% SOC. Σε αυτή την παρτίδα περιλήφθηκαν και πέντε κυψέλες από την πρώτη σειρά πειραμάτων, των οποίων οι μετρήσεις συνεχίστηκαν με τα ίδια πρωτόκολλα (3.6C και 4C). Προστέθηκαν επίσης μεγαλύτερα διαλείμματα πέντε λεπτών μετά την επίτευξη του 80% SOC και μετά την εκφόρτιση, ενώ το πρωτόκολλο CC–CV για το τμήμα 80–100% SOC παρέμεινε ίδιο με το πρώτο batch (1C έως 3.6 V, cutoff C/50). Η μέτρηση της εσωτερικής αντίστασης συνέχισε να πραγματοποιείται με παλμούς $\pm 3.6C$ διάρκειας 30 ms. Κατά τη διάρκεια των δοκιμών καταγράφηκαν ορισμένα τεχνικά προβλήματα, όπως αυτόματες επανεκκινήσεις του υπολογιστή που προκάλεσαν κενά στα δεδομένα γύρω από τον 250ό κύκλο, καθώς και αστοχίες στους αισθητήρες θερμοκρασίας σε ορισμένα κανάλια.

Η τρίτη παρτίδα δεδομένων διεξήχθη στις 12 Απριλίου 2018 και διαφοροποιείται σημαντικά από τις προηγούμενες, καθώς εφαρμόστηκαν αποκλειστικά πρωτόκολλα φόρτισης δύο βημάτων με σταθερό χρόνο περίπου 10 λεπτών στο εύρος 0–80% SOC. Για τη συγκεκριμένη παρτίδα, ο στόχος χωρητικότητας ορίστηκε στο 80% της ονομαστικής, ενώ καθιερώθηκαν τέσσερα σύντομα διαλείμματα πέντε δευτερολέπτων, τα οποία εισάγονταν σε κρίσιμα σημεία της διαδικασίας: μετά την επίτευξη του 80% SOC κατά τη φόρτιση, μετά τη μέτρηση της εσωτερικής αντίστασης, πριν από την εκφόρτιση και μετά την εκφόρτιση. Όπως και στα προηγούμενα batches, πραγματοποιήθηκε αρχικός κύκλος C/10 για σταθεροποίηση, αλλά το cutoff ρεύμα στη φάση CV διαφοροποιήθηκε, μειούμενο σε C/20. Παράλληλα, το πλάτος των παλμών IR αυξήθηκε στα 33 ms. Στην παρτίδα αυτή παρατηρήθηκαν σποραδικά σφάλματα ανοικτού κυκλώματος (OCV errors) που οφείλονταν στη διαδικασία μέτρησης της εσωτερικής αντίστασης, καθώς και πρόωρος τερματισμός ορισμένων καναλιών (π.χ. 33 και 41) πριν από την επίτευξη του τέλους ζωής.

Η ερευνητική αξία του dataset είναι ιδιαίτερα υψηλή για τρεις λόγους. Πρώτον, καταγράφει ένα ευρύ φάσμα κύκλων ζωής, από 150 έως 2300, καλύπτοντας έτσι τη φυσική διακύμανση που εμφανίζεται σε εμπορικές κυψέλες. Δεύτερον, περιλαμβάνει μεγάλο αριθμό δειγμάτων (124 κυψέλες), γεγονός που επιτρέπει στατιστικά αξιόπιστες αναλύσεις και την εκπαίδευση μοντέλων με μεγαλύτερη ικανότητα γενίκευσης. Τρίτον, οι συνθήκες ταχείας φόρτισης στις οποίες βασίστηκε το πείραμα αντικατοπτρίζουν ρεαλιστικά σενάρια χρήσης, με υψηλή σημασία για τις σύγχρονες εφαρμογές ηλεκτροκίνησης.

4.3 Διερευνητική Ανάλυση Δεδομένων

Η Διερευνητική Ανάλυση Δεδομένων (Exploratory Data Analysis – EDA) αποτελεί κρίσιμο και θεμελιώδες στάδιο σε κάθε pipeline Μηχανικής Μάθησης, καθώς θέτει τις βάσεις για την πλήρη κατανόηση της φύσης, της ποιότητας και της εσωτερικής δομής των διαθέσιμων δεδομένων. Η σημασία της EDA καθίσταται ακόμη πιο έντονη σε προβλήματα πρόβλεψης που βασίζονται σε σύνθετες και πολυδιάστατες ηλεκτροχημικές διεργασίες, όπως οι κύκλοι φόρτισης και εκφόρτισης κυψελών ιόντων λιθίου, όπου η πληροφορία είναι ενσωματωμένη τόσο σε χρονικές ακολουθίες όσο και σε συμπυκνωμένες μεταβλητές ανά κύκλο.

Μέσω της EDA, αποκαλύπτονται κρυμμένα στατιστικά μοτίβα, ακραίες τιμές (outliers), μη αναμενόμενες συσχετίσεις, καθώς και πιθανές πηγές θορύβου ή μεροληψίας, τα οποία ενδέχεται να επηρεάσουν την εκπαίδευση και τη γενίκευση του μοντέλου. Επιπλέον, η ανάλυση της διακύμανσης, της κανονικότητας των κατανομών, αλλά και της συσχέτισης μεταξύ μεταβλητών καθοδηγεί την επιλογή κατάλληλων χαρακτηριστικών, τον καθαρισμό των δεδομένων, την εφαρμογή τεχνικών κανονικοποίησης ή μετασχηματισμού, και τελικώς τη διαμόρφωση του κατάλληλου αρχιτεκτονικού σχήματος (feature selection και input design).

Η ενσωμάτωση μιας συστηματικής διερευνητικής φάσης είναι χρήσιμη για την αποφυγή υπερπροσαρμογής σε ανώμαλα μοτίβα (overfitting to noise), ενώ επιτρέπει τη διατύπωση εύλογων υποθέσεων για τις εξαρτήσεις μεταξύ εισόδων και εξόδων. Στο πλαίσιο της παρούσας εργασίας, η EDA συνεισφέρει όχι μόνο στην κατανόηση της εξέλιξης της φθοράς των κυψελών, αλλά και στη θεμελίωση της διττής προσέγγισης με ταυτόχρονη χρήση τόσο χρονικών χρονοσειρών όσο και summary χαρακτηριστικών, προσαρμοσμένη στις ιδιαιτερότητες των δεδομένων εκφόρτισης.

Περιγραφική Στατιστική των Summary Χαρακτηριστικών


Ως πρώτο βήμα της διερευνητικής ανάλυσης, εφαρμόστηκε η συνάρτηση `describe()` της βιβλιοθήκης Pandas στο σύνολο των summary χαρακτηριστικών, με στόχο την εξαγωγή βασικών στατιστικών δεικτών (μέση τιμή, ελάχιστο, μέγιστο, τυπική απόκλιση κ.ά.). Η διαδικασία αυτή παρείχε μια αρχική επισκόπηση της δομής και της μεταβλητότητας των δεδομένων, εντοπίζοντας ενδείξεις σταθερών προτύπων, αλλά και πιθανών ακραίων τιμών. Η ανάλυση βασίστηκε σε 98.822 επιμέρους κύκλους εκφόρτισης και συνέβαλε καθοριστικά στην κατανόηση της γενικής συμπεριφοράς των μεταβλητών πριν την οπτική διερεύνηση ή την κανονικοποίησή τους.

	Cycle_Index	IR	QD	Discharge_Time	Remaining_Cycles
count	98822.000000	98822.000000	98822.000000	98822.000000	98822.000000
mean	484.161401	0.016590	1.033611	13.535397	485.798152
std	383.747122	0.001234	0.048867	0.889094	384.043812
min	0.000000	0.000000	0.874198	6.280923	0.000000
25%	199.000000	0.015566	1.016400	13.188018	200.000000
50%	401.000000	0.016588	1.050074	13.797432	403.000000
75%	673.000000	0.017333	1.067931	14.178830	675.000000
max	2233.000000	0.023757	2.884085	24.197272	2236.000000

Πίνακας 3: Περιγραφικά Στατιστικά των Summary Χαρακτηριστικών

Ανάλυση Κατανομής Κύκλων Ζωής

Η μεταβλητή *Cycle_Life* αποτυπώνει τον συνολικό αριθμό κύκλων εκφόρτισης που εκτελεί κάθε κυψέλη έως τη στιγμή που θεωρείται μη λειτουργική. Η ανάλυσή της βοηθά στην καλύτερη κατανόηση της διάρκειας ζωής των κυψελών και δίνει χρήσιμα στοιχεία για το πόσο ανθεκτικές είναι σε βάθος χρόνου.




Εικόνα 10: Κατανομή συνολικών κύκλων ζωής ανά κυψέλη

Στην Εικόνα 10 παρουσιάζεται η κατανομή των συνολικών κύκλων ζωής ανά κυψέλη, ομαδοποιημένη σε διαστήματα τιμών (bins). Παρατηρείται ότι η πλειονότητα των κυψελών διαθέτει κύκλο ζωής μεταξύ 400 και 1100 κύκλων, με ιδιαίτερη συγκέντρωση γύρω από το εύρος 400–600, όπου εντοπίζεται και η μεγαλύτερη συχνότητα εμφάνισης. Αντίθετα, ένα μικρότερο ποσοστό κυψελών εμφανίζει παρατεταμένη διάρκεια ζωής, ξεπερνώντας τους 1500 κύκλους, ενώ καταγράφονται και μεμονωμένες περιπτώσεις με εξαιρετικά υψηλό κύκλο ζωής (>2000 κύκλοι).

Η διακύμανση αυτή τεκμηριώνει την έντονη ετερογένεια στο dataset, τόσο σε επίπεδο πειραματικών συνθηκών όσο και σε επίπεδο υλικών και τεχνολογικής προέλευσης των κυψελών. Η ανομοιογένεια αυτή, αν και αποτελεί πρόκληση για τη διαδικασία κανονικοποίησης, προσφέρει παράλληλα τη δυνατότητα εκπαίδευσης ενός μοντέλου που είναι ικανό να γενικεύει σε ευρύ φάσμα πραγματικών περιπτώσεων.

Ανάλυση Κατανομών των Summary Χαρακτηριστικών

Ιδιαίτερη έμφαση δόθηκε στη μελέτη της κατανομής των βασικών χαρακτηριστικών τύπου summary, τα οποία περιγράφουν συνοπτικά την κατάσταση της κυψέλης ανά κύκλο: την εσωτερική αντίσταση (IR), την εκφορτισθείσα χωρητικότητα (QD), τον χρόνο εκφόρτισης (Discharge Time) και τους υπολειπόμενους κύκλους ζωής (Remaining Cycles).



Εικόνα 11: Ιστογράμματα των Summary Χαρακτηριστικών

Η κατανομή της εσωτερικής αντίστασης (IR) εμφανίζει συγκέντρωση γύρω από μικρές τιμές (με κυρίαρχα peaks μεταξύ 0.015 και 0.018 Ω), στοιχείο που υποδηλώνει χαμηλή και σχετικά σταθερή αντίσταση για τη συντριπτική πλειονότητα των παρατηρήσεων. Παρά τη μικρή διασπορά, διακρίνονται διακριτά τοπικά μέγιστα στην πυκνότητα κατανομής (multimodal behavior), κάτι που πιθανώς σχετίζεται με διαφορετικές κατηγορίες κυψελών ή διαφοροποιημένα προφίλ φόρτισης.

Η εκφορτισθείσα χωρητικότητα (QD) παρουσιάζει κατανομή έντονα επικεντρωμένη γύρω από την τιμή του 1.03 Ah, με ελάχιστες περιπτώσεις να ξεφεύγουν αισθητά από αυτό το εύρος. Το γεγονός αυτό αντανάκλα τη θερμική και δομική σταθερότητα των περισσότερων κυψελών στο μεγαλύτερο μέρος του κύκλου ζωής τους.


Ο χρόνος εκφόρτισης (Discharge Time) καταγράφει τιμές που κυμαίνονται κυρίως μεταξύ 12.5 και 14.5 λεπτών, με αιχμή γύρω από τα 13.5 λεπτά. Η έντονη συγκέντρωση στο συγκεκριμένο εύρος φανερώνει επαναληψιμότητα στις συνθήκες αποφόρτισης, αν και εντοπίζονται λιγότερο συχνά περιπτώσεις με σημαντικά μεγαλύτερους ή μικρότερους χρόνους.

Η μεταβλητή των υπολειπόμενων κύκλων ζωής (Remaining Cycles) παρουσιάζει μια μονοτονικά φθίνουσα κατανομή, γεγονός που είναι αναμενόμενο λόγω του τρόπου που καταγράφεται (ξεκινώντας από το συνολικό cycle life της κυψέλης και μειούμενη κατά έναν σε κάθε κύκλο). Η μεγάλη πυκνότητα στις χαμηλότερες τιμές οφείλεται στον μεγάλο αριθμό κύκλων που καταγράφονται προς το τέλος της ζωής κάθε κυψέλης. Αντίθετα, οι υψηλές τιμές εμφανίζονται λιγότερο συχνά, αφού κάθε κυψέλη εισφέρει μόνο μία ή λίγες παρατηρήσεις στα αρχικά της στάδια.

Η συνολική εικόνα των κατανομών επιβεβαιώνει ότι τα χαρακτηριστικά IR, QD και Discharge Time είναι κατάλληλα για χρήση ως προγνωστικοί παράγοντες, λόγω της σταθερής και ερμηνεύσιμης συμπεριφοράς τους. Αντίθετα, η μεταβλητή Remaining Cycles αντιμετωπίζεται ως στόχος πρόβλεψης.

Ανάλυση Summary Χαρακτηριστικών σε Επίπεδο Κυψέλης

Μετά την επισκόπηση των συνολικών χαρακτηριστικών στο σύνολο του dataset, πραγματοποιήθηκε μελέτη σε επίπεδο μεμονωμένης κυψέλης, ώστε να μελετηθεί η συμπεριφορά των μεταβλητών στη διάρκεια ζωής της. Συγκεκριμένα, επιλέχθηκε μία αντιπροσωπευτική κυψέλη από το dataset (batch 1 cell 0) και απεικονίστηκαν τα summary χαρακτηριστικά της.



Εικόνα 12: Ιστογράμματα Summary Χαρακτηριστικών Ανά Κυψέλη

Η Εικόνα 12 παρουσιάζει τις κατανομές των μεταβλητών IR, QD, Discharge Time και Remaining Cycles για τη συγκεκριμένη κυψέλη. Σε αντίθεση με την προηγούμενη συγκεντρωτική ανάλυση, η παρούσα απεικόνιση αποτυπώνει τη συμπεριφορά μίας μόνο κυψέλης διαχρονικά, επιτρέποντας την παρατήρηση εσωτερικών μεταβολών ανά κύκλο.


Η μεταβλητή IR δείχνει συγκέντρωση γύρω από συγκεκριμένες τιμές, χωρίς ιδιαίτερη διασπορά, υποδηλώνοντας σταθερή ηλεκτρική συμπεριφορά για το μεγαλύτερο μέρος της ζωής της κυψέλης.

Η χωρητικότητα (QD) φαίνεται ιδιαίτερα συγκεντρωμένη σε συγκεκριμένο εύρος, αποκαλύπτοντας πιθανή γραμμική ή ήπια φθίνουσα πορεία κατά τη διάρκεια των κύκλων.

Αντίθετα, ο χρόνος εκφόρτισης εμφανίζει σταδιακή μετατόπιση προς χαμηλότερες τιμές, στοιχείο ενδεικτικό της μείωσης της ενεργειακής απόδοσης, ενώ οι υπολειπόμενοι κύκλοι ζωής κατανέμονται αναμενόμενα ομοιόμορφα σε καθοδική φορά, καθώς ξεκινούν από το συνολικό cycle life της κυψέλης και μειώνονται κατά έναν σε κάθε επόμενο κύκλο.


Ανάλυση Χρονοσειρών σε Επίπεδο Κυψέλης

Στο επόμενο στάδιο της διερευνητικής ανάλυσης, μελετήθηκε η χρονοσειριακή μεταβολή των βασικών χαρακτηριστικών κατά τη διάρκεια ζωής της. Η στόχευση σε ένα μόνο cell επιτρέπει την εις βάθος κατανόηση της δυναμικής φθοράς, καθώς και την παρακολούθηση των κρίσιμων μεταβλητών σε διαδοχικούς κύκλους φόρτισης–εκφόρτισης. Για την οπτικοποίηση χρησιμοποιήθηκαν τόσο interpolated χαρακτηριστικά (Qdlin, Tdlin) όσο και summary χαρακτηριστικά (IR, QD, Discharge Time), σε συνδυασμό με τους υπολειπόμενους κύκλους ζωής (Remaining Cycles).




Εικόνα 13: Καμπύλες εκφόρτισης Qd–Voltage για αντιπροσωπευτικούς κύκλους λειτουργίας.

Η καμπύλη Qd ως προς την τάση (Voltage) για χαρακτηριστικούς κύκλους (π.χ. 10, 100, 900, 1850) δείχνει σαφή μετατόπιση προς χαμηλότερες τιμές όσο προχωρά η φθορά. Στις αρχικές φάσεις, η καμπύλη είναι σχεδόν επίπεδη, ενώ στα τελευταία στάδια (π.χ. cycle 1850) η χωρητικότητα μειώνεται αισθητά, γεγονός που καταδεικνύει την απώλεια ενεργειακής ικανότητας.




Εικόνα 14: Μεταβολή θερμοκρασίας ως προς την τάση για επιλεγμένους κύκλους εκφόρτισης.

Η θερμοκρασία (T vs Voltage) παρουσιάζει διαφοροποιημένα μοτίβα ανάλογα με το στάδιο ζωής της κυψέλης. Σε πρώιμους κύκλους, η θερμοκρασία διατηρείται σταθερή, ενώ σε προχωρημένους κύκλους παρατηρούνται αυξήσεις, ενδείξεις αυξημένης θερμικής επιβάρυνσης και πιθανής αποσταθεροποίησης των υλικών.




Εικόνα 15: Εξέλιξη της εσωτερικής αντίστασης (IR) ως συνάρτηση των υπολειπόμενων κύκλων ζωής.

Το διάγραμμα Internal Resistance vs Remaining Useful Life καταγράφει ελαφρώς αυξητικές τάσεις της εσωτερικής αντίστασης IR με τη μείωση της υπολειπόμενης ζωής, χωρίς όμως ξεκάθαρη γραμμική συσχέτιση. Το φαινόμενο αυτό είναι ενδεικτικό της αργής αλλά σταθερής υποβάθμισης της ηλεκτρικής αγωγιμότητας.



Εικόνα 16: Μεταβολή της εκφορτισθείσας χωρητικότητας (QD) ως προς τους υπολειπόμενους κύκλους.

Αντίστοιχα, η εκφορτισθείσα χωρητικότητα QD εμφανίζει σταδιακή μείωση όσο μειώνονται οι Remaining Cycles, επιβεβαιώνοντας ότι η φθορά των κυψελών επηρεάζει άμεσα την αποδοτικότητα φόρτισης και εκφόρτισης.




Εικόνα 17: Χρόνος εκφόρτισης σε συνάρτηση με τον αριθμό κύκλων.

Η γραφική απεικόνιση του Discharge Time ανά κύκλο δείχνει ξεκάθαρη καθοδική πορεία, η οποία επιταχύνεται σε προχωρημένα στάδια ζωής της κυψέλης. Η μείωση αυτή

αντικατοπτρίζει την υποβάθμιση της λειτουργικότητας και τον περιορισμό της διαθέσιμης ενέργειας ανά κύκλο.

Ανάλυση Συσχετίσεων Μεταβλητών

Στο τελικό στάδιο της διερευνητικής ανάλυσης, υπολογίστηκε ο πίνακας Pearson συσχετίσεων μεταξύ των βασικών summary χαρακτηριστικών: εσωτερική αντίσταση (IR), εκφορτισθείσα χωρητικότητα (QD), χρόνος εκφόρτισης (Discharge Time) και υπολειπόμενοι κύκλοι ζωής (Remaining Cycles). Η απεικόνιση έγινε με χρήση διαγράμματος θερμότητας, προσφέροντας μια συγκεντρωτική επισκόπηση των γραμμικών σχέσεων μεταξύ των μεταβλητών.



Εικόνα 18: Πίνακας συσχέτισης μεταξύ συνοπτικών χαρακτηριστικών (IR, QD, discharge time, remaining cycles).

Το heatmap αποκαλύπτει υψηλό βαθμό συσχέτισης μεταξύ του QD και του Discharge Time (0.95), κάτι που είναι αναμενόμενο καθώς και οι δύο μεταβλητές συνδέονται με την αποδοτικότητα εκφόρτισης της κυψέλης. Ισχυρή θετική συσχέτιση παρατηρείται επίσης μεταξύ του Discharge Time και των Remaining Cycles (0.68), γεγονός που ενισχύει τη σημασία του ως δείκτη πρόβλεψης διάρκειας ζωής.

Αντίθετα, η εσωτερική αντίσταση (IR) εμφανίζει ασθενείς έως μέτριες αρνητικές συσχετίσεις με όλες τις υπόλοιπες μεταβλητές (π.χ. -0.44 με Discharge Time, -0.34 με Remaining Cycles), γεγονός που ενδέχεται να σχετίζεται με τη διαφορετική φύση και χρονική δυναμική αυτής της παραμέτρου, η οποία συχνά αυξάνεται απότομα μόνο σε προχωρημένα στάδια υποβάθμισης.

Η ανάλυση αυτή καθοδηγεί τη διαδικασία επιλογής χαρακτηριστικών εισόδου για το μοντέλο πρόβλεψης, επιβεβαιώνοντας ότι οι μεταβλητές QD και Discharge Time ενσωματώνουν κρίσιμες πληροφορίες για την πρόγνωση των κύκλων ζωής, ενώ η IR προσφέρει συμπληρωματική εικόνα για την υγεία της κυψέλης.


4.4 Προεπεξεργασία Δεδομένων

4.4.1 Καθαρισμός Δεδομένων

Στην παρούσα εργασία εφαρμόστηκε μία σειρά από ελέγχους και καθαρισμούς στα δεδομένα των τριών αρχικών παρτίδων (batch1, batch2, batch3), με στόχο τη διασφάλιση συνέπειας, πληρότητας και φυσικής αξιοπιστίας των μετρήσεων. Αρχικά, απορρίφθηκαν κυψέλες των οποίων η συνολική διάρκεια ζωής ήταν μικρότερη από 150 κύκλους, καθώς κρίθηκε ότι δεν παρείχαν επαρκή πληροφορία για ασφαλή εκπαίδευση του μοντέλου.


Επιπλέον, απομακρύνθηκαν μεμονωμένες μετρήσεις που παρουσίαζαν μη ρεαλιστικές τιμές στη μεταβλητή της εσωτερικής αντίστασης (IR). Για τον σκοπό αυτό εφαρμόστηκε φίλτρο κατωφλίου, διατηρώντας μόνο τις τιμές στο εύρος $0.005 < IR < 0.023$.

Τέλος, από το σύνολο των δεδομένων διατηρήθηκαν αποκλειστικά τα στάδια εκφόρτισης κάθε κύκλου, καθώς αυτά περιέχουν τη μορφολογική πληροφορία που σχετίζεται με τη φθορά και τη λειτουργική υποβάθμιση της κυψέλης. Στο Σχήμα 4.4.2 παρουσιάζεται ενδεικτικά η αφαίρεση του charging τμήματος, με την προεπεξεργασία να κρατά μόνο τις καμπύλες εκφόρτισης.



Εικόνα 19: Διαχωρισμός και εξομάλυνση δεδομένων εκφόρτισης μετά την προεπεξεργασία.

Στο επίπεδο των χρονοσειρών, εφαρμόστηκε φίλτρο Savitzky–Golay στις ακολουθίες Q και T κάθε κύκλου, προκειμένου να απομακρυνθεί ο θόρυβος χωρίς να χαθεί η βασική μορφολογία των καμπυλών. Ταυτόχρονα, πραγματοποιήθηκε παρεμβολή των μετρήσεων πάνω σε κοινό voltage grid, εξαλείφοντας το πρόβλημα του μεταβλητού αριθμού μετρήσεων ανά κύκλο.



Εικόνα 20: Εφαρμογή φίλτρου Savitzky–Golay για εξομάλυνση των καμπυλών Q και T .

Τέλος, όλες οι αριθμητικές μεταβλητές που χρησιμοποιούνται ως είσοδος στο δίκτυο υποβλήθηκαν σε κανονικοποίηση min–max, με βάση τις τιμές του συνόλου εκπαίδευσης. Η επιλογή αυτή διασφαλίζει αριθμητική σταθερότητα κατά την εκπαίδευση και ισορροπεί τη συνεισφορά των διαφορετικών χαρακτηριστικών στη συνάρτηση κόστους. Η τελική έξοδος της διαδικασίας ήταν η δημιουργία καθαρού και συνεπούς συνόλου δεδομένων (processed_data.pkl), το οποίο χρησιμοποιήθηκε για την παραγωγή των χαρακτηριστικών στην επόμενη φάση.

4.4.2 Μηχανική Χαρακτηριστικών


Η διαδικασία παραγωγής χαρακτηριστικών βασίστηκε στον θεωρητικό διαχωρισμό μεταξύ συνοπτικών αριθμητικών χαρακτηριστικών και χρονοσειρών. Η δομή του μοντέλου CNN απαιτεί εισόδους σταθερού σχήματος, γεγονός που καθόρισε τον τρόπο αναπαράστασης των μετρήσεων και των μεταβλητών.

Για τα summary χαρακτηριστικά, επιλέχθηκαν οι μεταβλητές εσωτερική αντίσταση (IR), εκφορτισθείσα χωρητικότητα (QD) και χρόνος εκφόρτισης (Discharge Time). Οι τιμές αυτών των μεταβλητών οργάνωθηκαν σε πίνακες με διαστάσεις $(T \times 3)$, όπου T είναι ο αριθμός κύκλων εντός κάθε παραθύρου. Οι τιμές κανονικοποιήθηκαν με βάση σταθερούς συντελεστές scaling, προερχόμενους από τα 95-εκατοστημόρια των αντίστοιχων κατανομών στο training set.

Για τη μορφολογική πληροφορία, χρησιμοποιήθηκε η συσχέτιση των μεταβλητών Q και T με την τάση. Για κάθε κύκλο εκφόρτισης, εφαρμόστηκε γραμμική παρεμβολή επί ενός κοινού voltage grid, αποτελούμενου από 1000 ισαπέχοντα σημεία εντός του εύρους λειτουργίας (2.0–3.5 V). Το αποτέλεσμα είναι δύο χρονοσειρές σταθερού μήκους: Qdlin και Tdlin, που συνδυάζονται σε tensor διαστάσεων $(T \times V \times 2)$, με T κύκλους, V σημεία τάσης και 2 κανάλια.

Η τελική αναπαράσταση κάθε δείγματος δημιουργήθηκε με χρήση τεχνικής sliding-window: κάθε είσοδος περιλαμβάνει 20 διαδοχικούς κύκλους, μετατοπιζόμενη ανά 5 κύκλους. Κάθε

παράθυρο συνοδεύεται από το αντίστοιχο target — τον τρέχοντα αριθμό κύκλου και την υπολειπόμενη διάρκεια ζωής — και αποθηκεύεται ως TFRecord. Αυτή η μέθοδος επιτρέπει την εκμετάλλευση πρώιμων δεδομένων (early-cycle inference), καθώς και την αναπαράσταση της πρόσφατης ιστορικής συμπεριφοράς της κυψέλης σε μορφή που είναι συμβατή με συνελκτικά νευρωνικά δίκτυα.



Εικόνα 21: Δημιουργία παραθύρων (sliding windows) από συνεχόμενους κύκλους για εκπαίδευση του μοντέλου.

4.5 Μοντέλο CNN

4.5.1 Αρχιτεκτονική Μοντέλου

Η αρχιτεκτονική του μοντέλου που χρησιμοποιείται στην παρούσα εργασία σχεδιάστηκε με γνώμονα την ικανότητα επεξεργασίας ετερογενών εισόδων: χρονοσειριακών και συνοπτικών για την πρόβλεψη της υπολειπόμενης διάρκειας ζωής (Remaining Useful Life – RUL) κυψελών ιόντων λιθίου. Για τον σκοπό αυτό, επιλέχθηκε μια συνελκτική αρχιτεκτονική δύο κλάδων (dual-branch CNN), η οποία διατηρεί διακριτές ροές πληροφορίας ανά τύπο εισόδου και καταλήγει σε κοινή προβλεπτική έξοδο. Η προσέγγιση αυτή συνδυάζει την ικανότητα μορφολογικής ανάλυσης της χωρητικότητας και θερμοκρασίας ανά κύκλο με την αξιοποίηση στατιστικών τάσεων σε μεταβλητές όπως η εσωτερική αντίσταση.

Η είσοδος του μοντέλου αποτελείται από δύο υποσυνιστώσες: 1. Ένα τανυστικό αντικείμενο διαστάσεων ($T \times V \times 2$), το οποίο περιλαμβάνει για κάθε δείγμα T διαδοχικούς κύκλους, V σημεία παρεμβολής τάσης, και 2 κανάλια (Q_{dlin} , T_{dlin}), 2. Ένα πίνακα διαστάσεων ($T \times 3$) που περιλαμβάνει τα summary χαρακτηριστικά: εσωτερική αντίσταση (IR), εκφορτισθείσα χωρητικότητα (QD) και χρόνο εκφόρτισης (Discharge Time) για τους αντίστοιχους κύκλους.

Ο πρώτος κλάδος (time-series branch) αποτελείται από διαδοχικά 2D συνελκτικά επίπεδα (Conv2D), τα οποία εφαρμόζονται στο input tensor. Κάθε επίπεδο εφαρμόζει φίλτρα μορφολογικής ανάλυσης σε τοπικές περιοχές τάσης και χρόνου, επιτρέποντας στο δίκτυο να εντοπίζει πρότυπα φθοράς, όπως αλλαγές κλίσης, τοπικές αποκλίσεις στη θερμοκρασία ή

σταθερές μετατοπίσεις της καμπύλης εκφόρτισης. Μεταξύ των συνελκτικών επιπέδων ενσωματώνονται ενεργοποιήσεις ReLU και MaxPooling για συμπίεση και αφαίρεση πληροφορίας χαμηλής σημασίας. Η τελική έξοδος ισοπεδώνεται (flatten) και οδηγεί σε ένα ενδιάμεσο διανυσματικό embedding.

Ο δεύτερος κλάδος (scalar branch) επεξεργάζεται τα summary χαρακτηριστικά μέσω 1D συνελκτικών στρωμάτων (Conv1D), τα οποία εφαρμόζονται διαδοχικά στο input ($T \times 3$). Τα φίλτρα επιτρέπουν την αναγνώριση τοπικών χρονικών μοτίβων (π.χ. πτώση IR ή αύξηση DT), ενώ το βάθος του δικτύου είναι περιορισμένο ώστε να διατηρείται η πληροφορία αμετάβλητη σε περιπτώσεις χαμηλής μεταβλητότητας. Η έξοδος του δεύτερου κλάδου περνά από πλήρως συνδεδεμένο επίπεδο (dense layer), και οδηγείται στο ίδιο επίπεδο embedding με τον πρώτο κλάδο.

Οι δύο κλάδοι συνενώνονται μέσω συνένωσης των αντίστοιχων διανυσμάτων εξόδου (concatenation), και η κοινή αναπαράσταση οδηγείται σε ένα τελικό πλήρως συνδεδεμένο επίπεδο (Dense), το οποίο παράγει δύο συνεχείς προβλέψεις:

1. Τον αριθμό του τρέχοντος κύκλου (Current Cycle)
2. Την υπολειπόμενη διάρκεια ζωής (Remaining Useful Life – RUL)

Ως τελική συνάρτηση ενεργοποίησης εφαρμόζεται μία παραλλαγή της ReLU, περιορισμένη σε άνω φράγμα (Clipped ReLU), ώστε να αποφεύγονται μη ρεαλιστικές προβλέψεις (π.χ. αρνητικοί ή υπερβολικά μεγάλοι κύκλοι). Συγκεκριμένα, χρησιμοποιείται η σχέση:

$$\text{ClippedReLU}(x) = \min(\max(x, 0), M)$$

όπου M είναι ένας προκαθορισμένος αριθμός κύκλων ζωής (π.χ. 2500), βάσει των ορίων του dataset.

4.5.2 Βελτιστοποίηση Υπερπαραμέτρων (Hyperparameter Optimization)

Η αποτελεσματικότητα ενός συνελκτικού νευρωνικού δικτύου εξαρτάται σε μεγάλο βαθμό από την ορθή επιλογή των υπερπαραμέτρων που επιλέγονται. Παράγοντες όπως το μέγεθος των πυρήνων συνελίξεων (kernel size), ο αριθμός των φίλτρων (filters), ο ρυθμός εκμάθησης (learning rate) και το ποσοστό αποτροπής υπερπροσαρμογής μέσω dropout layers παίζουν κρίσιμο ρόλο στη σύγκλιση του δικτύου και στην τελική του απόδοση. Για τον λόγο αυτό, κρίθηκε αναγκαία η εφαρμογή μιας διαδικασίας Βελτιστοποίησης Υπερπαραμέτρων (Hyperparameter Optimization – HPO), με στόχο την εύρεση του συνδυασμού παραμέτρων που μεγιστοποιεί την ικανότητα γενίκευσης του μοντέλου στα δεδομένα δοκιμής.

Η διαδικασία HPO πραγματοποιήθηκε με τη μέθοδο της αναζήτησης πλέγματος (Grid Search). Στο πλαίσιο αυτής της προσέγγισης, ορίζεται ένα πεπερασμένο υποσύνολο πιθανών τιμών για κάθε υπερπαραμέτρο και δοκιμάζονται εξαντλητικά όλοι οι δυνατοί συνδυασμοί. Αν και στη βιβλιογραφία προτείνονται πιο εξελιγμένες τεχνικές όπως η Τυχαία Αναζήτηση (Random Search) ή η Βελτιστοποίηση μέσω Διαδοχικών Μοντέλων (Bayesian Optimization) [1][2], η χρήση Grid Search επιλέχθηκε λόγω της απλότητάς της, της δυνατότητας πλήρους ελέγχου του πειραματικού σχεδιασμού και της σαφούς ερμηνευσιμότητας των αποτελεσμάτων.

Για τη διατήρηση ενός ισορροπημένου χρόνου εκπαίδευσης και μιας εφικτής συνολικής πολυπλοκότητας, περιορίστηκε το πλήθος των συνδυασμών σε τέσσερις βασικές παραμετροποιήσεις. Το πεδίο αναζήτησης που ορίστηκε περιλάμβανε τις ακόλουθες παραμέτρους:

Υπερπαράμετρος	Τιμές
conv_filters	32, 64
conv_kernel_2d	(3,9), (5,5)
dropout_cnn	0.3, 0.4
learning_rate	0.0001, 0.0005

Το grid search εφαρμόστηκε συνδυάζοντας τις παραπάνω τιμές, με αποτέλεσμα 4 συνολικά συνδυασμούς. Κάθε συνδυασμός εκπαιδεύτηκε για έως 50 εποχές με χρήση early stopping, ώστε να αποφεύγεται η άσκοπη υπερπροσαρμογή σε περιπτώσεις σταθεροποίησης του validation loss.

Η επιλογή του βέλτιστου συνδυασμού βασίστηκε στην ελαχιστοποίηση του validation loss (MSE), στην ελαχιστοποίηση του validation MAE (ιδίως για τον αριθμό των υπολειπόμενων κύκλων ζωής), και στη γενικά σταθερή συμπεριφορά του μοντέλου στο validation set (χωρίς απότομες αυξομειώσεις ή φαινόμενα overfitting).

Με βάση τα αποτελέσματα που καταγράφηκαν στο αρχείο hpo_results.csv, ο βέλτιστος συνδυασμός υπερπαραμέτρων που αναδείχθηκε είναι:

Υπερπαράμετρος	Τιμές
conv_filters	64
conv_kernel_2d	(3,9)
dropout_cnn	0.3
learning_rate	0.0001

Αυτός ο συνδυασμός εμφάνισε τα χαμηλότερα validation loss και validation MAE, ενώ διατήρησε εξαιρετική σταθερότητα κατά τη διάρκεια της εκπαίδευσης. Το εύρημα αυτό συμφωνεί με τη γενικότερη τάση της βιβλιογραφίας που αναφέρει ότι μεγαλύτερος αριθμός φίλτρων και σχετικά ήπιο dropout ευνοούν την καλύτερη εξαγωγή χαρακτηριστικών σε προβλήματα μικρών έως μεσαίων datasets [3].

Είναι σημαντικό να σημειωθεί ότι, παρόλο που η περαιτέρω αύξηση του αριθμού των συνδυασμών ή η εισαγωγή επιπλέον υπερπαραμέτρων (όπως weight decay, learning rate scheduling ή batch normalization) θα μπορούσε θεωρητικά να βελτιώσει περαιτέρω την απόδοση του μοντέλου, στο πλαίσιο αυτής της εργασίας δόθηκε προτεραιότητα στην αναλογικότητα μεταξύ υπολογιστικής πολυπλοκότητας και τελικής ακρίβειας, ακολουθώντας καθιερωμένες πρακτικές πειραματικής αξιολόγησης.

4.5.3 Διαχείριση Εκπαίδευσης και Παρακολούθηση Μοντέλου

Για την εκπαίδευση του μοντέλου, εφαρμόστηκε ένα σύστημα διαχείρισης και παρακολούθησης με στόχο τη διασφάλιση της βέλτιστης απόδοσης και τη μείωση του κινδύνου υπερπροσαρμογής. Η υλοποίηση βασίστηκε σε δυνατότητες του TensorFlow και προσαρμοσμένα callbacks, τα οποία ενσωματώθηκαν στο training pipeline μέσω της συνάρτησης `model.fit(...)`. Αυτό επέτρεψε την αποτελεσματική εποπτεία του μοντέλου τόσο κατά την εκπαίδευση όσο και κατά την επιλογή του βέλτιστου checkpoint.

Early Stopping

Κατά την εκπαίδευση του μοντέλου, χρησιμοποιήθηκε ο μηχανισμός Early Stopping, με στόχο τη διακοπή της εκπαίδευσης όταν δεν παρατηρείται περαιτέρω βελτίωση στο validation loss μετά από συγκεκριμένο αριθμό εποχών (patience). Συγκεκριμένα, εφαρμόστηκε παρακολούθηση του validation loss με τιμή `patience = 10` και `restore_best_weights = True`, ώστε το μοντέλο να επανέλθει αυτόματα στα βάρη που πέτυχαν την καλύτερη απόδοση. Η επιλογή των παραμέτρων έγινε βάσει πρακτικών που συνιστώνται στη βιβλιογραφία για μεσαίου μεγέθους σύνολα δεδομένων, ενώ επιβεβαιώθηκε εμπειρικά από τα αποτελέσματα εκπαίδευσης.

Αυτή η στρατηγική συνέβαλε σημαντικά στην αποτροπή υπερπροσαρμογής, διασφαλίζοντας ότι η εκπαίδευση διακόπτεται όταν η απόδοση στο validation set παύει να βελτιώνεται, χωρίς να χάνεται η μέχρι τότε βέλτιστη εκδοχή του μοντέλου.

Custom Checkpoints και Αυτόματη Αποθήκευση


Παράλληλα, αναπτύχθηκε και ενσωματώθηκε προσαρμοσμένο callback με την ονομασία CustomCheckpoints, το οποίο βασίστηκε στο `tf.keras.callbacks.Callback`. Η κλάση αυτή επιτηρεί το validation loss ανά εποχή και αποθηκεύει το μοντέλο μόνο στην περίπτωση επίτευξης νέου τοπικού ελαχίστου. Η αποθήκευση πραγματοποιείται στη δομή `jobs/YYYYMMDD-HHMMSS/run_i/checkpoints/saved_model`, επιτρέποντας οργανωμένη καταγραφή πολλαπλών πειραμάτων. Επιπλέον, το callback δημιουργεί αυτόματα διαδραστικά γραφήματα με χρήση της βιβλιοθήκης Plotly, τα οποία περιλαμβάνουν προβλεπόμενες και πραγματικές τιμές για κάθε δείγμα του validation set καθώς και το αντίστοιχο σφάλμα. Τα γραφήματα αποθηκεύονται σε HTML μορφή, προσφέροντας άμεση οπτική εποπτεία ανά epoch, ακόμη και εκτός TensorFlow περιβάλλοντος.

Το μοντέλο κατέγραφε επίσης την πορεία εκπαίδευσης μέσω του TensorBoard, με ενεργοποιημένο το `tf.keras.callbacks.TensorBoard` και καταγραφή στο φάκελο `jobs/.../logs/`. Η παρακολούθηση των καμπυλών απώλειας και των μέσων σφαλμάτων (MAE) για τα σύνολα εκπαίδευσης και επαλήθευσης παρείχε ουσιαστική ένδειξη για τη σύγκλιση του μοντέλου.

Διαδραστική Αξιολόγηση με Plotly

Η αξιολόγηση του μοντέλου συνοδεύτηκε από τη δημιουργία διαδραστικών γραφημάτων μέσω της βιβλιοθήκης Plotly, τα οποία παράγονταν αυτόματα κατά τη διάρκεια της εκπαίδευσης. Τα γραφήματα αυτά περιλάμβαναν τόσο τις προβλεπόμενες όσο και τις πραγματικές τιμές για τις δύο εξόδους του μοντέλου δηλαδή τον τρέχοντα κύκλο (current cycle) και τους υπολειπόμενους κύκλους ζωής (remaining cycles). Επιπλέον, απεικονιζόταν το απόλυτο

σφάλμα πρόβλεψης για κάθε παράδειγμα του validation set, προσφέροντας ενδιαφέρουσα πληροφορία για την τοπική συμπεριφορά του μοντέλου.



Εικόνα 22: Πραγματικές και προβλεπόμενες τιμές (Current Cycle, Remaining Cycles) και απόλυτο σφάλμα (Absolute Error) για το validation set (output από την CustomCheckpoints).

Καταγραφή με TensorBoard

Η εξέλιξη της εκπαίδευσης καταγραφόταν σε πραγματικό χρόνο μέσω του TensorBoard, επιτρέποντας λεπτομερή και διαδραστική εποπτεία της διαδικασίας. Η ενεργοποίηση έγινε με χρήση του callback `tf.keras.callbacks.TensorBoard`, με τον φάκελο καταγραφής να ορίζεται ανά run στο path `jobs/.../logs/`. Μέσω του TensorBoard παρακολουθούνταν οι καμπύλες της συνάρτησης απώλειας (loss) και του μέσου απόλυτου σφάλματος (MAE), τόσο για το σύνολο εκπαίδευσης όσο και για το validation set. Η συνεχής παρατήρηση αυτών των μετρικών παρείχε κρίσιμη πληροφόρηση για τη σύγκλιση ή την εμφάνιση overfitting κατά την εκπαίδευση.


Πέρα από τις βασικές μετρικές, καταγράφονταν στατιστικά σχετικά με τις κλίσεις των βαρών (gradients), την κατανομή των ενεργοποιήσεων των επιπέδων και άλλες εσωτερικές μεταβλητές του μοντέλου, προσφέροντας έτσι εις βάθος κατανόηση της δυναμικής μάθησης. Επιπλέον, το εργαλείο επέτρεψε τη σύγκριση μεταξύ διαφορετικών runs, είτε αυτά προέκυψαν από μεταβολές στην αρχιτεκτονική είτε από διαφορετικές υπερπαραμέτρους, μέσω της δυνατότητας οπτικής αντιπαραβολής.

Αποτελέσματα Εκπαίδευσης και Απόδοση Checkpoint

Η τελική επιλογή του μοντέλου βασίστηκε στο checkpoint με το χαμηλότερο validation loss. Στο συγκεκριμένο βέλτιστο σημείο (epoch 56), καταγράφηκαν οι εξής τιμές:

- Validation MAE για τον τρέχοντα κύκλο (Current Cycle): ~182 κύκλοι.
- Validation MAE για τους υπολειπόμενους κύκλους ζωής (Remaining Cycles): ~158 κύκλοι.

Οι τιμές αυτές προκύπτουν από ανάλυση των καταγεγραμμένων metrics σε CSV μέσω TensorBoard και αποδεικνύουν την ικανότητα γενίκευσης του μοντέλου.



Εικόνα 23: Καμπύλες του Validation MAE (για current και remaining cycles) ανά epoch.

Όπως φαίνεται στην εικόνα 23, οι καμπύλες των MAE παρουσιάζουν σαφή μείωση κατά τις πρώτες 20–30 εποχές και σταθεροποίηση σε χαμηλά επίπεδα στη συνέχεια.

4.5.4 Αξιολόγηση Μοντέλου

Η αξιολόγηση του τελικού μοντέλου πραγματοποιήθηκε σε φιλτραρισμένο test set που περιλάμβανε 22 κυψέλες με διάρκεια ζωής μεταξύ 500 και 1000 κύκλων. Η επιλογή αυτού του εύρους είχε στόχο την απομάκρυνση ακραίων περιπτώσεων (outliers) και τη δημιουργία ενός πιο αντιπροσωπευτικού υποσυνόλου του πληθυσμού. Επιπλέον, η πρόβλεψη της υπολειπόμενης διάρκειας ζωής βασίστηκε αποκλειστικά στους 100 πρώτους κύκλους κάθε κυψέλης, προσομοιώνοντας ρεαλιστικά το σενάριο όπου είναι διαθέσιμα μόνο πρώιμα δεδομένα.

Καθώς οι τιμές εξόδου είχαν κανονικοποιηθεί κατά την προεπεξεργασία, οι προβλέψεις επαναφέρθηκαν στην αρχική τους κλίμακα (κύκλοι ζωής) μέσω αναστροφής της κανονικοποίησης, αξιοποιώντας τον συντελεστή κλίμακας που είχε εφαρμοστεί εξ αρχής στα δεδομένα. Μετά την αποκλιμάκωση υπολογίστηκαν τρεις βασικές μετρικές για κάθε έξοδο: **MAE**, **RMSE** και **R²**.

A. Υπολειπόμενη διάρκεια ζωής (Remaining Cycle Life)

Η έξοδος που συγκεντρώνει το κύριο ερευνητικό ενδιαφέρον είναι η πρόβλεψη της υπολειπόμενης διάρκειας ζωής.

- MAE = 102 κύκλοι
- RMSE = 136 κύκλοι
- $R^2 \approx 70\%$

Οι τιμές αυτές δείχνουν ότι το μοντέλο αποδίδει με συνέπεια και σταθερότητα, επιτυγχάνοντας μέση απόκλιση μικρότερη των 150 κύκλων και εξηγώντας περίπου το 70 % της μεταβλητότητας των πραγματικών τιμών. Το σφάλμα παραμένει περιορισμένο στις περισσότερες κυψέλες, ενώ η απόδοση είναι ιδιαίτερα ικανοποιητική στις περιοχές χαμηλού RUL, όπου η πρόβλεψη έχει τη μεγαλύτερη πρακτική αξία. Το αποτέλεσμα αυτό υποδηλώνει ότι το μοντέλο έχει μάθει ουσιώδη μοτίβα υποβάθμισης και μπορεί να γενικεύει αποτελεσματικά σε νέες κυψέλες.

Η βελτιωμένη απόδοση της συγκεκριμένης εξόδου δικαιολογείται και από το σχεδιασμό της εκπαίδευσης: η συνάρτηση κόστους είχε σταθμιστεί ώστε να αποδίδει μεγαλύτερη βαρύτητα στο Remaining Cycle Life, δεδομένου ότι αυτή η ποσότητα αποτελεί τον σημαντικότερο δείκτη για συστήματα προγνωστικής συντήρησης και Battery Management Systems (BMS). Η χαμηλή τιμή validation loss και η υψηλή σταθερότητα κατά την εκπαίδευση επιβεβαιώνουν την επιτυχία αυτής της στρατηγικής.

B. Τρέχων κύκλος (Current Cycle)

Η δεύτερη έξοδος αφορά την πρόβλεψη του τρέχοντος κύκλου λειτουργίας.


- $MAE = 146$ κύκλοι
- $RMSE = 194$ κύκλοι
- $R^2 \approx 32\%$

Οι προβλέψεις εμφανίζουν μεγαλύτερη διασπορά και αστάθεια γύρω από τη γραμμή ταύτισης. Το μοντέλο αποτυπώνει σε ικανοποιητικό βαθμό τη γενική συσχέτιση, ωστόσο η πληροφορία του τρέχοντος κύκλου είναι πιο δύσκολα προβλέψιμη με βάση τα διαθέσιμα πρώιμα δεδομένα. Παρατηρούνται μεμονωμένες περιπτώσεις με σημαντικές αποκλίσεις από την ιδανική γραμμή, γεγονός που υποδηλώνει περιορισμένη ικανότητα γενίκευσης και αυξημένη ευαισθησία σε ιδιαιτερότητες μεμονωμένων κυψελών. Παρ' όλα αυτά, η συμπεριφορά της εξόδου παραμένει συνεπής με τον σχεδιασμό του μοντέλου, το οποίο επικεντρώνεται στη βελτιστοποίηση της πρόβλεψης του Remaining Cycle Life.

4.6 Πειραματικά αποτελέσματα – Προβλέψεις

Στην ενότητα αυτή παρουσιάζονται και αναλύονται οι προβλέψεις του τελικού συνελικτικού μοντέλου επί του συνόλου δοκιμής, με στόχο την αποτίμηση της γενίκευσης και της πρακτικής του χρησιμότητας. Η αξιολόγηση αυτή έρχεται ως φυσική κατάληξη της όλης πειραματικής διαδικασίας και αντικατοπτρίζει την ικανότητα του μοντέλου να παράγει αξιόπιστες και ρεαλιστικές εκτιμήσεις διάρκειας ζωής για νέες, μη ορατές κυψέλες. Οι προβλέψεις εστιάζουν στις δύο εξόδους του μοντέλου: τον τρέχοντα κύκλο (current cycle) και τους υπολειπόμενους κύκλους ζωής (remaining cycles).


Γραφήματα Προβλέψεων



Εικόνα 24: Σύγκριση πραγματικών (μπλε) και προβλεπόμενων (πορτοκαλί) τιμών για τον τρέχοντα κύκλο (αριστερά) και την υπολειπόμενη διάρκεια ζωής (δεξιά) των κυψέλων στο test set.

Το παραπάνω γράφημα απεικονίζει την πορεία των πραγματικών (μπλε) και προβλεπόμενων (πορτοκαλί) τιμών τόσο για τον τρέχοντα κύκλο όσο και για τους υπολειπόμενους κύκλους ζωής των κυψέλων στο test set. Κάθε πριονωτή καμπύλη αντιστοιχεί σε διαδοχικούς κύκλους μιας κυψέλης, με τη χαρακτηριστική καθοδική κλίση να αντανακλά τη σταδιακή φθορά και μείωση της διάρκειας ζωής.

Για την έξοδο της υπολειπόμενης διάρκειας ζωής (Remaining Cycles), το μοντέλο καταφέρνει να συλλάβει με επιτυχία τη γενική φθίνουσα τάση της γήρανσης. Οι καμπύλες των προβλέψεων παραμένουν κοντά στις πραγματικές τιμές σε αρκετές κυψέλες. Η συνολική επίδοση ($R^2 \approx 0.7$) υποδηλώνει ότι το μοντέλο εξηγεί ένα σημαντικό μέρος της μεταβλητότητας, αν και παρατηρούνται αποκλίσεις σε μεμονωμένες περιπτώσεις, ειδικά προς το τέλος ζωής όπου η αβεβαιότητα αυξάνεται. Αυτό συνάδει με ευρήματα της βιβλιογραφίας, που αναφέρουν ότι η πρόβλεψη του RUL καθίσταται δυσκολότερη στα τελικά στάδια γήρανσης.



Εικόνα 25: Scatter plots πραγματικών έναντι προβλεπόμενων τιμών.

Το διάγραμμα διασποράς παρουσιάζει τη συσχέτιση μεταξύ πραγματικών και προβλεπόμενων τιμών τόσο για τον τρέχοντα κύκλο όσο και για τους υπολειπόμενους κύκλους ζωής σε όλα τα δείγματα του test set. Στον άξονα x αποτυπώνεται η πραγματική τιμή, ενώ στον άξονα y η


αντίστοιχη πρόβλεψη του μοντέλου. Η διακεκομμένη κόκκινη γραμμή αναπαριστά την ιδανική γραμμή ταύτισης ($y=x$), όπου οι προβλέψεις θα συνέπιπταν πλήρως με τις πραγματικές τιμές. Η κατανομή των σημείων αναδεικνύει διαφορετική συμπεριφορά για τις δύο εξόδους:

- Remaining Cycles:

Παρατηρείται σαφής θετική συσχέτιση, γεγονός που καταδεικνύει ότι το μοντέλο μαθαίνει ουσιώδη μοτίβα σχετιζόμενα με τη φθορά των κυψέλων. Παρόλα αυτά, σημαντικό ποσοστό των σημείων βρίσκεται κάτω από τη γραμμή ταύτισης, υποδεικνύοντας ότι το μοντέλο τείνει να υποτιμά την πραγματική διάρκεια ζωής, ιδιαίτερα σε κυψέλες με υψηλό συνολικό κύκλο ζωής. Το φαινόμενο αυτό συνοδεύεται από μια «συμπίεση» των προβλέψεων σε περιοχές γύρω στους 800–1000 κύκλους, ακόμη και όταν οι πραγματικές τιμές ξεπερνούν το εύρος αυτό. Η απόδοση είναι βελτιωμένη σε κυψέλες με χαμηλότερο RUL (<300 κύκλοι), όπου οι προβλέψεις ευθυγραμμίζονται περισσότερο με την κόκκινη γραμμή.

- Current Cycles:


Οι προβλέψεις παρουσιάζουν μεγαλύτερη διασπορά και αστάθεια γύρω από τη γραμμή ταύτισης. Το μοντέλο αποτυπώνει σε ικανοποιητικό βαθμό τη γενική συσχέτιση, ωστόσο η πληροφορία του τρέχοντος κύκλου αποδεικνύεται πιο δύσκολα προβλέψιμη με βάση τα διαθέσιμα δεδομένα. Παρατηρούνται μεμονωμένες περιπτώσεις με σημαντικές αποκλίσεις από την ιδανική γραμμή, γεγονός που υποδηλώνει περιορισμένη ικανότητα γενίκευσης και αυξημένη ευαισθησία του μοντέλου σε συγκεκριμένες κυψέλες ή πρότυπα φθοράς.



Εικόνα 26: Histograms πραγματικών έναντι προβλεπόμενων τιμών.

Η εικόνα συμπληρώνεται με την ανάλυση της κατανομής των σφαλμάτων πρόβλεψης, όπως φαίνεται στα ιστογράμματα των δύο εξόδων. Για το Remaining Cycle Life, τα σφάλματα συγκεντρώνονται κυρίως γύρω από το μηδέν, με τη μεγαλύτερη πυκνότητα στο εύρος ± 200 κύκλων. Η συμμετρική αυτή κατανομή υποδηλώνει ότι οι περισσότερες προβλέψεις παραμένουν κοντά στις πραγματικές τιμές, με σχετικά λίγες αποκλίσεις μεγάλης κλίμακας.

Αντίθετα, για τον Current Cycle παρατηρείται μεγαλύτερη διασπορά και παρουσία μεμονωμένων ακραίων αποκλίσεων, γεγονός που συνάδει με τις προηγούμενες παρατηρήσεις.



Εικόνα 27: Residual Plots πραγματικών έναντι προβλεπόμενων τιμών.

Η παραπάνω κατανομή δείχνει ότι σε χαμηλές τιμές RUL τα σφάλματα παραμένουν κοντά στο μηδέν, γεγονός που υποδηλώνει αυξημένη ακρίβεια του μοντέλου στις κυψέλες που πλησιάζουν στο τέλος ζωής τους. Αντίθετα, σε μεγαλύτερες τιμές RUL τα σφάλματα αποκλίνουν περισσότερο και εμφανίζεται τάση αρνητικής απόκλισης, δηλαδή το μοντέλο υποτιμά την πραγματική διάρκεια ζωής. Το φαινόμενο αυτό εντείνεται όσο αυξάνεται ο πραγματικός αριθμός κύκλων, αντανακλώντας αφενός την περιορισμένη εκπροσώπηση τέτοιων κυψελών στο training set και αφετέρου τη μεγαλύτερη πολυπλοκότητα του φαινομένου γήρανσης σε μακρόβιες κυψέλες. Συνολικά, το διάγραμμα αναδεικνύει ότι το μοντέλο αποδίδει καλύτερα σε χαμηλότερες τιμές RUL, ενώ τείνει να υποτιμά τις κυψέλες μεγάλης διάρκειας ζωής.

5. Συμπεράσματα

5.1 Σύνοψη και συμπεράσματα

Η παρούσα εργασία υλοποίησε ένα ολοκληρωμένο pipeline πρόβλεψης διάρκειας ζωής κυψελών Li-ion, από την προεπεξεργασία των δεδομένων και τη δημιουργία παραθύρων (sliding windows) έως την εκπαίδευση και αξιολόγηση ενός σύνθετου CNN. Η αρχιτεκτονική που σχεδιάστηκε συνδύασε δύο κλάδους: (α) ένα 2D-CNN για την επεξεργασία «λεπτομερών» χαρακτηριστικών, τα οποία αποτυπώνουν τη μορφολογία των καμπυλών εκφόρτισης σε παράθυρα κύκλων, και (β) ένα 1D-CNN για συνοπτικά χαρακτηριστικά, όπως η εσωτερική αντίσταση, η εκφορτισθείσα χωρητικότητα και ο χρόνος εκφόρτισης. Η έξοδος του μοντέλου παρήγαγε ταυτόχρονα δύο εκτιμήσεις: τον τρέχοντα κύκλο και τους υπολειπόμενους κύκλους ζωής έως το τέλος λειτουργικότητας της κυψέλης.

Η εκπαίδευση πραγματοποιήθηκε στο πλήρες εύρος των διαθέσιμων κύκλων, ενώ στο στάδιο πρόβλεψης το μοντέλο τροφοδοτήθηκε με πρώιμους κύκλους νέων κυψελών, προκειμένου να εξεταστεί αν τα πρώιμα ίχνη φθοράς επαρκούν για την εκτίμηση του RUL. Τα πειραματικά αποτελέσματα έδειξαν ότι πράγματι τα πρώιμα δεδομένα εμπεριέχουν κρίσιμη πληροφορία για την πρόβλεψη της διάρκειας ζωής, σε συμφωνία με προηγούμενες μελέτες της διεθνούς βιβλιογραφίας [5], [17].

Σε επίπεδο ισχυρών σημείων, η υλοποίηση αξιοποιεί σήματα που είναι ήδη διαθέσιμα στα περισσότερα συστήματα διαχείρισης μπαταριών (τάση, θερμοκρασία, χωρητικότητα), χωρίς να απαιτεί ειδικά διαγνωστικά πρωτόκολλα ή ακριβές μετρήσεις. Επίσης, ο διαχωρισμός σε δύο κλάδους (2D/1D) επιτρέπει τη διαφοροποιημένη επεξεργασία λεπτομερών και συνοπτικών χαρακτηριστικών, διευκολύνοντας την αποτίμηση της συνεισφοράς τους.

Ωστόσο, αναδείχθηκαν και ορισμένες αδυναμίες:

- Η πρόβλεψη του Current Cycle παρουσίασε χαμηλή συσχέτιση με τις πραγματικές τιμές, γεγονός που υποδεικνύει ότι το μοντέλο δυσκολεύεται να αποτυπώσει επαρκώς τη δυναμική αυτής της εξόδου. Η απόδοση θα μπορούσε να βελτιωθεί με καλύτερη κανονικοποίηση ή διαφορετική στάθμιση στη συνάρτηση κόστους.
- Για την έξοδο του Remaining Cycle Life, αν και επιτεύχθηκε σημαντικά καλύτερη επίδοση, παρατηρήθηκε τάση συστηματικής υποτίμησης σε κυψέλες μεγάλης διάρκειας ζωής. Το φαινόμενο αυτό πιθανότατα συνδέεται με την άνιση κατανομή του training set, όπου οι κυψέλες μεγάλης διάρκειας είχαν περιορισμένη εκπροσώπηση. Στο μέλλον, θα μπορούσε να αντιμετωπιστεί με τεχνικές εξισορρόπησης δεδομένων ή με κατάλληλη δειγματοληψία.
- Τα σφάλματα του μοντέλου αυξάνονται προς το τέλος ζωής των κυψέλων, στοιχείο που αντανακλά την αυξημένη αβεβαιότητα σε αυτά τα στάδια. Η ενσωμάτωση μηχανισμών εκτίμησης αβεβαιότητας (π.χ. διαστήματα εμπιστοσύνης) θα μπορούσε να καταστήσει τις προβλέψεις πιο χρήσιμες σε πρακτικά σενάρια.

Συνοψίζοντας, η υλοποίηση απέδειξε ότι ένα CNN με κατάλληλη σχεδίαση μπορεί να αξιοποιήσει πρώιμα δεδομένα για να προβλέψει τη διάρκεια ζωής κυψελών Li-ion με ικανοποιητική ακρίβεια. Η βελτίωση της ποιότητας των δεδομένων εκπαίδευσης, η καλύτερη στάθμιση των εξόδων και η ενσωμάτωση πρόσθετων χαρακτηριστικών συνιστούν σημαντικά επόμενα βήματα για την ενίσχυση της αξιοπιστίας και της πρακτικής εφαρμογής του μοντέλου.

5.2 Μελλοντικές επεκτάσεις

Η παρούσα εργασία ανέδειξε ότι τα πρώιμα δεδομένα μπορούν να αξιοποιηθούν αποτελεσματικά για την πρόβλεψη της διάρκειας ζωής κυψελών Li-ion. Ωστόσο, υπάρχουν κατευθύνσεις που θα μπορούσαν να βελτιώσουν περαιτέρω την ακρίβεια και την αξιοπιστία των αποτελεσμάτων:

- Φυσικο-ενημερωμένα και υβριδικά μοντέλα: Η ενσωμάτωση φυσικών περιορισμών ή surrogate μοντέλων (π.χ. P2D, SEI-informed losses) σε νευρωνικά δίκτυα θα μπορούσε να οδηγήσει σε υβριδικές αρχιτεκτονικές που συνδυάζουν τις αρχές της ηλεκτροχημείας με την ευελιξία των data-driven μεθόδων, μειώνοντας το overfitting και βελτιώνοντας τη γενίκευση [20].
- Transformers και μηχανισμοί προσοχής: Η χρήση μηχανισμών attention δίνει τη δυνατότητα σύλληψης μακροπρόθεσμων εξαρτήσεων, τις οποίες τα CNNs αδυνατούν να καταγράψουν αποτελεσματικά. Υβριδικές αρχιτεκτονικές CNN–Transformer έχουν ήδη δείξει βελτιώσεις στην πρόβλεψη διάρκειας ζωής, ειδικά σε περιπτώσεις περιορισμένων πρώιμων δεδομένων [14], [21].
- Αβεβαιότητα και Conformal Prediction: Για πρακτικές εφαρμογές, η παροχή μόνο μίας σημειακής εκτίμησης δεν επαρκεί. Οι μέθοδοι Conformal Prediction προσφέρουν διαστήματα εμπιστοσύνης με προκαθορισμένο επίπεδο κάλυψης, ανεξάρτητα από την κατανομή των δεδομένων, καθιστώντας τις προβλέψεις πιο αξιόπιστες για χρήση σε συστήματα πραγματικού χρόνου [16], [21].

Συνολικά, μια μελλοντική κατεύθυνση θα μπορούσε να είναι η ανάπτυξη υβριδικών μοντέλων που συνδυάζουν CNNs, Transformers και φυσικο-ενημερωμένους περιορισμούς,

εμπλουτισμένων με μεθόδους εκτίμησης αβεβαιότητας. Μια τέτοια προσέγγιση δύναται να ενισχύσει τόσο την ακρίβεια όσο και την αξιοπιστία των προβλέψεων σε πραγματικές συνθήκες λειτουργίας.

Βιβλιογραφία

- [1] S. Jin, et al., “Overview of Machine Learning Methods for Lithium-Ion Battery Remaining Useful Lifetime Prediction,” *Electronics*, vol. 10, no. 24, p. 3126, 2021.
- [2] J. N. C. Sekhar, et al., “Prediction of Battery Remaining Useful Life Using Machine Learning Algorithms,” *Sustainability*, vol. 15, no. 21, p. 15283, 2023.
- [3] P. Sharma and B. J. Bora, “A Review of Modern Machine Learning Techniques in the Prediction of Remaining Useful Life of Lithium-Ion Batteries,” *Batteries*, vol. 9, no. 1, p. 13, 2023.
- [4] M. Ahwiadi and W. Wang, “Battery Health Monitoring and Remaining Useful Life Prediction Techniques,” *Batteries*, vol. 11, no. 1, p. 31, 2025.
- [5] K. A. Severson, P. M. Attia, N. Jin, et al., “Data-driven prediction of battery cycle life before capacity degradation,” *Nature Energy*, vol. 4, pp. 383–391, 2019.
- [6] Y. Zhang, et al., “Machine Learning Approaches for Battery State of Health Estimation and Remaining Useful Life Prediction,” *Energies*, vol. 12, no. 6, 2021.
- [7] Y. Tang, et al., “Data-Driven Prognostics of Lithium-Ion Batteries: A Review of State of the Art,” *Energies*, vol. 15, no. 10, 2022.
- [8] H. Xie, et al., “Remaining Useful Life Prediction of Lithium-ion Batteries Using a Hybrid CNN-LSTM Model,” *IEEE Access*, vol. 9, pp. 91595–91603, 2021.
- [9] W. He, et al., “Remaining Useful Life Prediction of Lithium-ion Batteries Based on Data-Driven Methods,” *Energies*, vol. 13, no. 11, 2020.
- [10] Z. Song, et al., “Deep Learning-Based State of Health Estimation for Lithium-Ion Batteries Using Voltage Relaxation Signals,” *IEEE Transactions on Transportation Electrification*, vol. 6, no. 2, pp. 419–429, 2020.
- [11] T. F. Fuller, M. Doyle, and J. Newman, “Simulation and Optimization of the Dual Lithium Ion Insertion Cell,” *Journal of the Electrochemical Society*, vol. 141, no. 1, pp. 1–10, 1994.
- [12] S. S. Zhang, “A review on the separators of liquid electrolyte Li-ion batteries,” *Journal of Power Sources*, vol. 164, no. 1, pp. 351–364, 2007.
- [13] Y. Li, et al., “A Semi-Empirical Capacity Degradation Model for Lithium-Ion Batteries under Variable Loading Conditions,” *Energies*, vol. 13, no. 3, 2020.
- [14] Y. Wang, et al., “CNN-Based Methods for Remaining Useful Life Prediction of Lithium-Ion Batteries: A Review,” *IEEE Access*, vol. 8, pp. 168808–168819, 2020.
- [15] C. Zhang, et al., “A Review on Remaining Useful Life Estimation Methods for Lithium-Ion Batteries,” *Journal of Power Sources*, vol. 512, p. 230526, 2021.
- [16] C. Hu, et al., “Battery RUL Prediction with Lightweight Machine Learning Models for Real-Time Applications,” *IEEE Transactions on Transportation Electrification*, vol. 9, no. 2, pp. 1234–1243, 2023.
- [17] Y. Zhang, et al., “A Data-Driven Approach for Remaining Useful Life Prediction of Lithium-Ion Batteries Based on MAE and RMSE Evaluation,” *Applied Sciences*, vol. 10, no. 15, 2020.

- [18] J. Lu, et al., “Data-Driven Battery Health Prediction Using Deep Feature Extraction and Ensemble Learning,” *Applied Energy*, vol. 321, p. 119353, 2022.
- [19] Z. Yu and Z. Pan, “Joint Estimation of SOH and RUL for Lithium-ion Batteries using CNN-GRU Based on Artificial Lemming Algorithm,” in *Proc. IEEE 3rd Int. Conf. on Advanced Battery Diagnostics*, 2025.
- [20] J. N. C. Sekhar and D. Domathoti, “Prediction of Battery Remaining Useful Life Using Machine Learning Algorithms,” *International Journal of Recent Engineering Science (IJRES)*, vol. 10, no. 2, pp. 12–18, 2023.
- [21] V. Vovk, A. Gammerman, and G. Shafer, *Algorithmic Learning in a Random World*. Springer, 2005.