


Transfer Learning mittels Bayes-Inferenz: Anwendung und Potenziale in der Degradationsprognose

Bauer, R.; Inkermann, D.

Transfer Learning ist ein vielversprechendes Werkzeug für die Degradationsmodellierung unter Datenmangel in frühen Entwicklungsphasen, da Informationen aus Referenzsystemen in die Modellierung einbezogen werden. In diesem Beitrag soll die Bayes-Inferenz als Verfahren des Transfer Learning am Beispiel von Lithium-Ionen-Batterien angewendet und hinsichtlich Prognosegenauigkeit und Verbesserungspotenzialen untersucht werden.



Transfer Learning is a promising tool for degradation modelling under a lack of data in early stages of the development process, as information from reference systems be included for modelling. In this article, transfer learning using Bayesian inference will be applied to lithium-ion batteries and its prognostic accuracy and improvement potentials will be examined.

Einleitung









Die Degradationsmodellierung (DM) ermöglicht in frühen Entwicklungsphasen eine optimale Anpassung der Produktarchitekturen und die Auswahl geeigneter Lebenszyklusstrategien für Komponenten /1/. Allerdings fehlen häufig Daten, um die DM frühzeitig durchführen zu können. Daher müssen Informationen aus Referenzsystemen verwendet werden /2/. Anwendungsfälle und Systemeigenschaften unterscheiden sich dabei meistens zwischen den Referenz- und Zieldaten, was zu einer unsicheren Degradationsprognose führt.

Transfer Learning

Ein vielversprechender Ansatz zur Übertragung vorhandener Informationen auf ähnliche, aber nicht identische Probleme ist das Transfer Learning (TL). Dabei kommen Methoden des Maschinellen Lernens (ML) zum Einsatz, welche Referenzmodelle und deren zugrundeliegende Daten verwenden /3/. TL erkennt gemeinsame Eigenschaften oder Muster in Daten, um neue Modelle zu erstellen, die präzise Ergebnisse für ein breiteres Spektrum spezifischer Probleme liefern als Modelle, die ohne TL erstellt wurden. Dies erfordert eine ausreichende Ähnlichkeit der Eigenschaften der Domänen, die für die TL-basierte Modellierung verwendet

werden /4/. Für die DM werden Domänen aus den betrachteten Systemen und Anwendungsfällen abgeleitet, wie schematisch in Tabelle 1 dargestellt.

Tabelle 1: Bildung von Domänen für ML-basierte Degradationsprognosen

Domäne	System	Use Case
Domäne 1		
Domäne 2		
Domäne 3		
Domäne 4		

Vorteile von TL gegenüber anderen ML-Methoden sind der deutlich geringere Datenbedarf und die Möglichkeit, Modelle auf ähnliche Domänen zu übertragen /3/.

Degradation von Lithium-Ionen-Batterien

Mit Eigenschaften wie hoher Energiedichte und langer Lebensdauer sind Lithium-Ionen-Batterien (LIBs) zum bedeutenden Energiespeicher u. a. in elektronischen Geräten, Elektrofahrzeugen und der Luftfahrt geworden /5/. Batteriedegradation entsteht durch Schadensmechanismen wie chemische Reaktionen, Ioneninterkationen und externe Belastungen. Diese Mechanismen führen zu einem Kapazitätsverlust C_{loss} , der die Leistungsfähigkeit der LIB beeinträchtigt. Ein Hauptschädigungsmechanismen ist das Wachstum einer Passivierungsschicht auf der Oberfläche der negativen Elektrode. Diese wird in der Regel als Festelektrolyt-Interphasen-Schicht (SEI-Schicht) bezeichnet /6/. In /7/ wurde ermittelt, wie häufig Einflussfaktoren der Batteriedegradation als Variablen in empirischen Modellen auftreten und wie diese in berücksichtigt werden (multiplikativ, exponentiell usw.). Die Ergebnisse sind in Abbildung 1 dargestellt. Die Häufigkeit der Variablen und ihre mathematische Darstellung in empirischen Modellen wird durch den Radius der Kreise und die Pfeilstärken angezeigt. α und β sind meist aus Messwerten bestimmte Konstanten, x_i ist der jeweilige Einflussfaktor als Variable.




Abbildung 1: Einflussfaktoren der Batteriedegradation /7/

Die Degradationsmodellierung von LIBs unter Verwendung von TL anstelle etablierter empirischer Methoden hat den Vorteil, dass keine neuen Messdaten für neue Anwendungen oder für Variationen der Batterieeigenschaften generiert werden müssen, sondern stattdessen öffentlich zugängliche Daten von Referenzdomänen verwendet werden können.

Bayes-Inferenz

Meistens werden für TL ML-basierte Methoden verwendet. Diese haben allerdings den Nachteil, dass die Ergebnisse nur schwer interpretierbar sind. Soll zum Beispiel die Degradationskurve eines Zielsystems prognostiziert werden, geben ML-Verfahren ohne spezifische Anpassungen nur Rohdaten einer solchen Degradationsprognose aus. Parameter eines Degradationsmodells werden nicht ermittelt. Auch wird keine Unsicherheit der Prognose angegeben. Für weiterführende Untersuchungen ist allerdings die Ausgabe von Degradationsfunktionen und Prognoseunsicherheiten erforderlich, da solche Ergebnisse als Grundlage verwendet werden können, um beispielsweise physikbasierte Ansatzfunktionen zur Verbesserung der Prognose zu implementieren.

In diesem Beitrag soll die Bayes-Inferenz als Methode des TL angewendet werden. Damit lassen sich sowohl Unsicherheiten als auch Parameter von Ansatzfunktionen zur Degradationsprognose auf Grundlage von Referenzdaten und initialen Degradationsdaten des Zielsystems berechnen. Im Allgemeinen basiert die Bayes-Inferenz auf dem Bayesschen Wahrscheinlichkeitssatz. Die Analyse der Modellparameter und die Vorhersagen bei den neuen, noch nicht getesteten Daten basieren auf der posterioren Verteilung der Referenzdaten. Details zur Durchführung der Bayes-Inferenz sollen hier nicht erläutert werden, sind aber in /8/ beschrieben.

Ziele des Beitrags

In diesem Beitrag sollen die Hypothesen überprüft werden, dass die Bayes-Inferenz als TL-Methode genutzt werden kann, um präzise Degradationsprognosen vorzunehmen und zudem eine gute Grundlage für die Entwicklung physikbasierter TL-Verfahren bietet. Solche Verfahren stellen eine Lücke im aktuellen Stand der Forschung dar. Um diese Hypothesen zu prüfen, sollen folgende Forschungsfragen beantwortet werden.

- Wie präzise sind mittels Bayes-Inferenz erstellte Degradationsmodelle?
- Wie unterscheiden sich die Ergebnisse, wenn sich einerseits nur die Anwendungsfälle unterscheiden und andererseits auch unterschiedliche LIBs berücksichtigt werden?
- Welche Verbesserungspotenziale und Möglichkeiten zur Integration physikbasierter Ansätze bieten TL-Prognosen mittels Bayes-Inferenz?

Datenbasis zur Batteriedegradation

Für die DM wurde zunächst eine MIT-Datenbank /9/ verwendet, die Degradationsdaten von 124 LIBs mit einer Nennkapazität von 1,1 Ah enthält. Die LIBs wurden bei einer Temperatur von 30 °C unter unterschiedlichen Lade-, aber identischen Entladebedingungen zyklisch betrieben. Insgesamt wurden 72 verschiedene Ladevarianten für jeweils zwei LIBs angewendet. Alle Zellen wurden mit einem konstanten Strom von 4,4 A entladen, bis die Batteriespannung 2,0 V erreichte, und dann unter konstanter Spannung weitergeladen, bis der Ladestrom unter 22 mA lag. Der Datensatz umfasst Messungen von Strom, Spannung, Kapazität, Innenwiderstand und Temperatur während des Ladezyklus. Dieser Datensatz eignet sich zur Bewertung von TL mittels Bayes-Inferenz für identische Systeme unter verschiedenen Anwendungsfällen.

Um die Bayes-Inferenz auch für verschiedene Systeme zu testen, wurde eine zusätzliche Datenbank der NASA /10/ verwendet, die Datensätze von 38 LIBs mit einer Nennkapazität von 2 Ah enthält. Die LIBs wurden bei verschiedenen Temperaturen (4 °C, 24 °C, 43 °C) betrieben. Das Laden erfolgte bei 1,5 A, bis die Batteriespannung 4,2 V erreichte, und wurde unter konstanter Spannung fortgesetzt, bis der Ladestrom auf 20 mA abfiel. Für die Entladung wurden insgesamt 10 unterschiedliche Profile für Entladung und Temperaturen getestet. Die Datensätze umfassen Messungen des Anschlussstroms, der Spannung und der Temperatur während eines Zyklus sowie Messungen der Entladekapazität und Impedanz von Zyklus zu Zyklus.

Implementierung von Transfer Learning mittels Bayes-Inferenz

Für die Degradationsmodellierung wurde eine Kombination aus Convolutional Neural Network (CNN) und Bayesscher Inferenz gewählt. Das Verfahren ist analog zu /8/ aufgebaut und dort detailliert beschrieben. Mittels zu definierender Referenzdaten aus den Datensätzen /9, 10/ wird zunächst das CNN trainiert und damit Referenzmodelle für die Zykluslebensdauer erstellt. Diese Referenzmodelle, die Referenzdaten und initiale Degradationsdaten des ausgewählten Zielsystems werden anschließend als Eingabe der Bayes-Inferenz genutzt. Die DM wurde unter Verwendung der ersten 30 % der Degradationszyklen der Ziel-LIBs durchgeführt. Für die Bayessche Inferenz wurde dabei anstelle der Exponentialfunktion aus /8/ eine Polynomfunktion 4. Ordnung als Ansatzfunktion verwendet. Dies führte zu besseren Ergebnissen für den MIT-Datensatz.

Die in /8/ vorgeschlagene Kombination aus CNN und Bayesscher Inferenz wurde in Python implementiert. Da in /8/ kein Code bereitgestellt ist, wurde die Implementierung unabhängig entwickelt, folgt jedoch eng der dort skizzierten Struktur, um den Entwicklungsaufwand zu reduzieren. Einige Parameter, wie die Anzahl der CNN-Trainingsepochen und die verwendeten Datensätze, unterscheiden sich (diese Arbeit verwendet zusätzlich Daten aus /10/ neben /9/), was zu geringfügigen Code-Abweichungen führt. PyTorch wurde für das CNN und die

quantitative Ähnlichkeitsanalyse der Degradationsdaten verwendet, scikit-learn für die Datenaufbereitung, SciPy und NumPy für die Bayessche Inferenz und weitere Schritte zur Datenaufbereitung. Die Gesamtprogrammstruktur folgt /8/ und wird daher nicht im Detail erläutert.

Ergebnisse für verschiedene Anwendungsfälle

Um die implementierte TL-Methode zu trainieren, wurden 45 LIBs aus der MIT-Datenbank ausgewählt und in 14 Ziel- und 31 Trainingsdatensätze unterteilt. Ähnlich wie in /8/ wurden nur die ersten 30% der Degradationszyklen der Referenzdaten zum Trainieren des CNN-Modells verwendet. Das CNN wurde zur Vorhersage der Zykluslebensdauer der 14 Ziel-LIBs verwendet. Um die Genauigkeit des CNN-Modells zu bewerten und mit anderen Veröffentlichungen zu vergleichen, wurden der mittlere absolute Fehler (MAE), der mittlere quadratische Fehler (RMSE), der mittlere absolute prozentuale Fehler (MAPE) und das Bestimmtheitsmaß (R^2) zwischen den Prognosen und den tatsächlichen Werten ermittelt. Einzelheiten zur Berechnung sind in /8/ zu finden. Abbildung 2 zeigt die Prognoseergebnisse (Testdaten) im Vergleich zur tatsächlichen Lebensdauer der Zieldaten (Ideal Fit).




Abbildung 2: Prognoseergebnisse des CNN-Modells für die MIT-Daten

Die DM mittels Bayes-Inferenz wurde unter Verwendung der ersten 30% der Degradationszyklen der Ziel-LIBs durchgeführt. Für die meisten LIBs wurden genaue Ergebnisse erzielt. Beispielsweise wurden die in Tabelle 2 zusammengefassten Genauigkeitsparameter für den in Abbildung 3 vorhergesagten Degradationsverlauf berechnet.

Tabelle 2: Genauigkeitsmaße der DM für die MIT-Daten

MAE	RMSE	MAPE	R ²
0.0134 Ah	0.0196 Ah	1.502%	0.9587

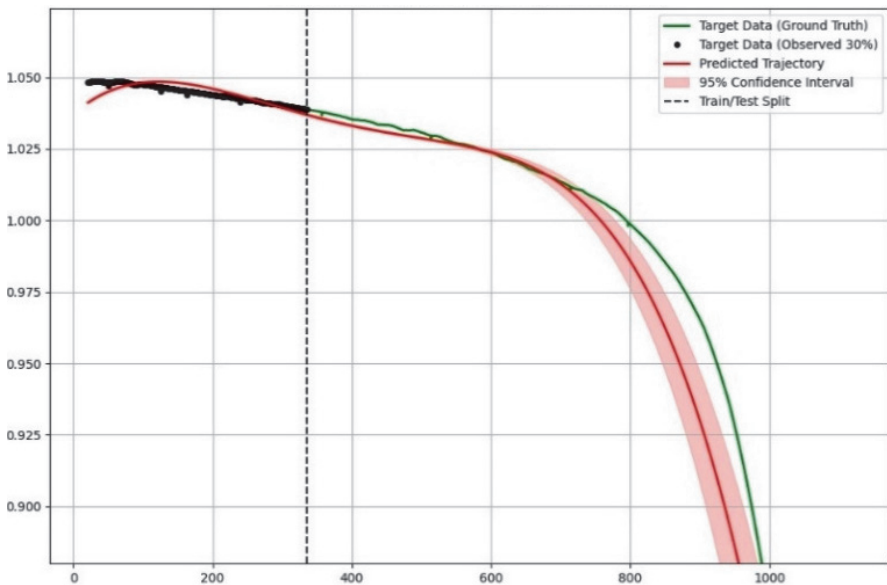


Abbildung 3: Degradationsprognose mittels Bayes-Inferenz für die MIT-Daten

Bei einigen anderen Ziel-LIBs wurden jedoch niedrigere Genauigkeitswerte von etwa $R^2=0,8$ erreicht. Wenn die initialen Zieldaten weniger Ähnlichkeit mit den Referenzdaten aufweisen, kann dies zu ungenaueren Ergebnissen führen.

Ergebnisse für verschiedene Batterien und Anwendungsfälle

Um zu testen, ob das implementierte Degradationsmodell für verschiedene Systeme und Anwendungsfälle geeignet ist, wurde es auf den Datensatz der NASA angewendet. Das CNN Basismodell wurde zusätzlich mit NASA-Daten aus 12 LIBs (Few-Shot) trainiert, indem das CNN mit einer 100-mal niedrigeren Lernrate als beim Vortraining mit MIT-Daten feinabgestimmt wurde. Dadurch werden die Modellpara-

meter des CNN nur in seinen letzten Schichten optimiert und nicht grundlegend an die zusätzlichen Daten angepasst. Basierend auf dem feinabgestimmten Modell wurde die Lebensdauer von 6 Ziel-LIBs vorhergesagt. Abbildung 4 zeigt die Vorhersage im Vergleich zur realen Lebensdauer der Zieldaten. Es gab erhebliche Abweichungen, aber es wurden auch präzise Vorhersageergebnisse erzielt.




Abbildung 4: Prognoseergebnisse des CNN-Modells für die NASA-Daten

Um den Degradationsverlauf vorherzusagen, wurde erneut TL unter Verwendung der ersten 30 % der Degradationszyklen der Ziel-LIBs durchgeführt. Für den vorhergesagten Degradationsverlauf einer Ziel-LIB in Abbildung 5 wurden $R^2=0,7765$ und $MAPE=3,879\%$ erreicht.

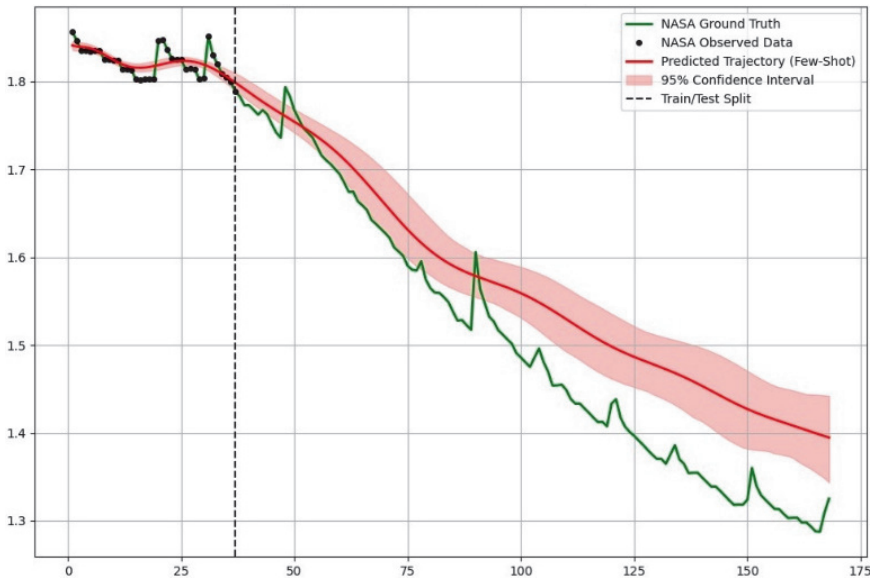


Abbildung 5: Degradationsprognose mittels Bayes-Inferenz für die NASA-Daten

Der Degradationsverlauf in Abbildung 5 zeigt im Vergleich zu Abbildung 3 die erheblichen Unterschiede zwischen den Daten des MIT und denen der NASA. Daher führt die Feinabstimmung des implementierten Degradationsmodells für die LIBs der NASA zu weniger genauen Ergebnissen als für die Daten des MIT.

Bewertung der Ergebnisse und Potenziale

TL-basierte Degradationsprognosen für LIBs aus /8, 11-13/ werden als Referenz für die Genauigkeitsbewertung der hier vorgestellten Ergebnisse verwendet. MAPE wurde als Bewertungsparameter für die Beurteilung der Genauigkeit der mit Bayes-Inferenz vorhergesagten Degradationspfade gewählt, da die anderen Genauigkeitsparameter in /8, 11-13/ nicht immer angegeben sind. Die Referenzmodelle wurden auf verschiedenen Anwendungsfälle angewendet, jedoch nur mit Daten aus gleichen Systemen trainiert. Die im vorherigen Abschnitt beschriebenen Trainingsmethoden für unterschiedliche Batterien wurden nicht durchgeführt. Die berechneten Werte für die Prognosegenauigkeit beziehen sich immer auf bestimmte LIBs aus den verwendeten Datensätzen. Da die eigene Beispiel-LIB zufällig ausgewählt wurde und nicht die LIB mit den bestmöglichen Ergebnissen, wurden die weniger genauen Ergebnisse der Vergleichsmodelle als Referenz verwendet. Diese sind in Tabelle 3 zusammengefasst.

Tabelle 3: Genauigkeitsparameter der Degradationsprognosen

TL-Verfahren	Use Case	System	MAPE
Erstelltes	variabel	gleich	1.50%
aus /11/	variabel	gleich	1.44%
aus /12/	variabel	gleich	1.55%
aus /13/	variabel	gleich	1.71%
aus /8/	variabel	gleich	0.79%
Erstelltes	variabel	variabel	3.88%

Ein Vergleich der Ergebnisse in Tabelle 3 zeigt, dass das implementierte Modell ähnlich genau ist wie andere präzise TL-basierte Degradationsmodelle. Das als Referenz verwendete Modell aus /8/ weist teilweise bessere Werte für die Genauigkeit auf (z. B. MAPE, RMSE, MAE), während einige Parameter ähnlich gut sind (z. B. R^2). Um die Ergebnisse aus /8/ zu erreichen, sind geringfügige Optimierungen des erstellten Modells erforderlich, z. B. hinsichtlich Parameter wie der Lernrate oder der Anzahl der Trainingsepochen. Das erstellte Degradationsmodell liefert teilweise gute, aber weniger präzise Ergebnisse für verschiedene Systeme und Anwendungsfälle. Für einige LIBs sind hier die Prognoseergebnisse ungenau.

Weitere Leistungsverbesserungen des vorgestellten TL-Ansatzes mittels Bayes-Inferenz sind möglich, beispielsweise durch Optimierung der Modellparameter (z. B. Lernrate) oder geringfügige strukturelle Anpassungen (z. B. Anzahl der CNN-Schichten). Weiterhin kann das CNN-Basismodell auch durch andere Verfahren ersetzt werden. So handelt es sich bei CNNs um ML-Methoden, bei denen wichtige Einflussgrößen und Muster der Degradation (Features) automatisch bestimmt werden und bei der anschließenden Degradationsprognose einen hohen Einfluss haben. Es gibt jedoch auch ML-Verfahren, z.B. Random Forests, bei welchen die Featureextraktion manuell vorzunehmen ist. In weiterführenden Forschungsarbeiten sollen Untersuchungen dazu vorgenommen werden, welche Vor- und Nachteile ein Basismodell mit manueller Featureextraktion bietet und welche zusätzlichen Anforderungen sich daraus ergeben. Weiterhin erfolgt die TL-basierte Degradationsprognose mittels Bayes-Inferenz auf Grundlage einer Ansatzfunktion samt zu ermittelnder Parameter. Hier bietet sich im Gegensatz zu ML-basierten TL-Verfahren eine unmittelbare Möglichkeit, ein physikbasiertes Modell zu implementieren. Hier soll zukünftig geprüft werden, ob und wie sich die Leistungsfähigkeit des vorgestellten TL-Verfahrens verbessern lässt, wenn die Ansatzfunktion der Bayes-Inferenz aus mathematischen Gleichungen zur Beschreibung der Degradationsmechanismen der Zielsysteme gebildet wird und damit auf physikalischen Zusammenhängen beruht. Dabei soll auch untersucht werden, in wie weit sich bei einer solchen physikbasierten Bayes-Inferenz der Bedarf an initialen Degradationsdaten des Zielsystems reduzieren lässt, ohne die Prognosegenauigkeit zu senken. Es soll erforscht werden, ob nur Informationen des Zielsystems zu den Einflussgrößen der Degradation ohne initiale Degradationsdaten genügen, um die physikbasierte Ansatzfunktion der Bayes-Inferenz anzupassen.

Damit bietet das vorgestellte TL-Verfahren eine sehr gute Grundlage für umfassende weiterführende Untersuchungen und Verbesserungen.

Literatur

- /1/ van den Bogaard, J. A.: Product lifecycle optimization using dynamic degradation models. Eindhoven, Technische Universiteit Eindhoven, 2006. DOI 10.6100/IR600023
- /2/ Inkermann, D.: Lifecycle option selection in early design stages based on degradation model evaluation. In: Proceedings of the Design Society Vol. 2, 2022, S. 475-484. DOI 10.1017/pds.2022.49
- /3/ Weiss, K.; Khoshgoftaar, T. M.; Wang, D.: A survey of transfer learning. In: Journal of Big Data Vol. 3, 2016, Nr. 9. DOI 10.1186/s40537-016-0043-6
- /4/ Fernandes, K.; Cardoso, J. S.: Hypothesis transfer learning based on structural model similarity. In: Neural Computing and Applications Vol. 31, 2019, S. 3417-3430. DOI 10.1007/s00521-017-3281-4
- /5/ Wang, F., Zhai, Z., Zhao, Z. et al.: Physics-informed neural network for lithium-ion battery degradation stable modeling and prognosis. In: Nature Communication Vol. 15, 2024, Nr. 4332. DOI 10.1038/s41467-024-48779-z
- /6/ Rechkemmer, S.: Lifetime modeling and model-based lifetime optimization of Li-ion batteries for use in electric two-wheelers. Stuttgart, Universität Stuttgart, 2020. DOI 10.18419/opus-10979
- /7/ Bauer, R.; Inkermann, D.: Analysis of degradation models for modelling the lifetime heterogeneity of complex systems. In: Proceedings of the 33rd Symposium Design for X, 2022. DOI 10.35199/dfx2022.16
- /8/ Zhou, Z.; Liu, Y.; You, M.; Xiong, R.; Zhou, X.: Two-stage aging trajectory prediction of LFP lithium-ion battery based on transfer learning with the cycle life prediction. In: Green Energy and Intelligent Transportation Vol. 1(1), 2022, Nr. 100008. DOI 10.1016/j.geits.2022.100008
- /9/ Severson, K. A.; Attia, P. M.; Jin, N. et al.: Data-driven prediction of battery cycle life before capacity degradation. In: Nature Energy Vol. 4, 2019, S. 383–391. DOI 10.48550/arXiv.2110.09687
- /10/ Saha, B.; Goebel, K.: Battery Data Set. Moffet Field, NASA Ames Research Center, 2007. <https://phm-datasets.s3.amazonaws.com/NASA/5.+Battery+Data+Set.zip>
- /11/ Ji, S.; Zhang, Z.; Stein, H. S.; Zhu, J.: Flexible health prognosis of battery nonlinear aging using temporal transfer learning. In: Applied Energy Vol. 377(D), 2025, Nr. 124766. DOI 10.1016/j.apenergy.2024.124766
- /12/ Kim, J.; Han, D.; Lee, P.-Y.; Kim, J.: Transfer learning applying electrochemical degradation indicator combined with long short-term memory network for flexible battery state-of-health estimation. In: eTransportation Vol. 18, 2023, Nr. 100293. DOI 10.1016/j.etrans.2023.100293
- /13/ Zhang, C.; Du, J.; Li, S.; Zhang, L.; Zhang, W.: Cross-domain machine transfer learning for capacity aging trajectory prediction of lithium-ion batteries. In: Journal of Power Sources Vol. 624, 2024, Nr. 235534. DOI 10.1016/j.jpowsour.2024.235534