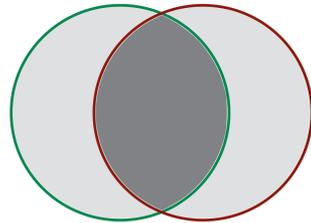


## Anwendung von Transfer Learning für die Degradationsprognose von Systemen

Bauer, R.; Inkermann, D.

*Transfer Learning (TL) nutzt Informationen und Modelle von Vergleichssystemen und ist ein vielversprechender Ansatz für die Degradationsmodellierung bei Datenmangel in frühen Entwicklungsphasen. Es wird ein Literaturreview durchgeführt, um eine Übersicht zu TL-Ansätzen und deren Anforderungen und Eigenschaften zu analysieren. Auf dieser Grundlage werden die TL-Ansätze anhand ihrer Datenanforderungen und Leistungsfähigkeit bewertet.*



*Transfer Learning (TL) uses information from comparative problems for modeling and is a promising method for degradation prognosis under a lack of data in early design stages. A literature review is conducted to provide an overview of existing TL methods and their requirements and properties. On this basis, collected TL methods will be assessed, considering their data requirements and performance.*

### Einleitung

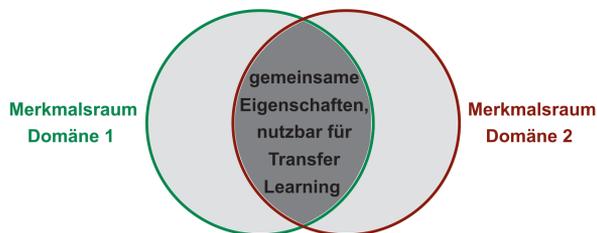
Um die Planung von Lebenszyklusoptionen, wie bspw. Wiederverwendung oder Wartung zu verbessern, sind Lebensdauermodelle von Systemkomponenten von zentraler Bedeutung /1/. Insbesondere in frühen Entwicklungsphasen können Produkte mittels präziser Degradationsprognosen grundlegend an die gestellten Anforderungen angepasst werden. In späteren Entwicklungsphasen sind häufig nur Anpassungen mit geringeren Optimierungspotenzial möglich /2/. Ein üblicher Ansatz zur Durchführung von Degradationsprognosen ist die empirische Modellbildung. Dabei werden Schädigungsgrößen unter definierten Betriebsbedingungen gemessen und daraus Modellfunktionen abgeleitet /3/. Allerdings sind Produkte in frühen Entwicklungsphasen physisch noch nicht existent, wodurch keine Versuchsdaten gesammelt werden können. Um Degradationsprognosen in frühen Entwicklungsphasen vorzunehmen, können Informationen und Lebensdauerdaten von Vergleichssystemen genutzt werden /4/. Eine Möglichkeit zur Übertragung solcher Informationen ist das Transfer Learning (TL). Dabei handelt es sich um Verfahren des Maschinellen Lernens (ML), die u.a. in der Bild- und Textklassifizierung sowie der Spracherkennung angewendet werden /5/. Für die Degradationsmodellierung neuer Produkte ist dabei wichtig, dass die Vergleichssysteme bzw. ihre Merkmalsräume hinreichend ähnlich sind. Gleiches gilt für den Anwendungsfall bzw. Betriebs- und Umfeldbedingungen /6/. Aus unterschiedlichen

Anwendungsfällen und Systemen werden Referenzdomänen gebildet, welche sich folgerichtig ebenfalls möglichst wenig unterscheiden sollten (siehe Tabelle 1).

**Tabelle 1:** Bildung von Domänen zur Durchführung von TL

Domäne	System	Anwendungsfall
Domäne 1	System A	Fall 1
Domäne 2	System B	Fall 1
Domäne 3	System A	Fall 2
Domäne 4	System B	Fall 2

Aus den Daten der Referenzdomänen werden mittels TL neue Modelle gebildet, welche sich aus gemeinsamen Eigenschaften ableiten /7/. Dies geschieht, indem Muster in den Daten der Domänen erkannt und für die Modellbildung verwendet werden. Eigenschaften, die sich nicht in mehreren Domänen wiederfinden, werden bei der Modellierung ignoriert oder haben einen geringeren Einfluss. Das Prinzip ist in Abbildung 1 verdeutlicht.



**Abbildung 1:** Konzept des TL in Anlehnung an /6/

Vorteile des TL gegenüber anderen Verfahren des ML sind der geringere Bedarf an Daten, die Möglichkeit, vorhandene Modelle durch ergänzende Daten von Vergleichsdomänen zu verbessern, eine schnellere und einfachere Modell-erstellung, sowie die Möglichkeit zur Übertragung von Modellen auf Vergleichsdomänen mit Datenmangel /5/. Damit erscheint das TL als eine vielversprechende Methode zur Degradationsprognose von Systemen in frühen Entwicklungsphasen.

### Problemstellung und Ziele

In diesem Beitrag wird die Eignung von TL-Ansätzen zur Degradationsmodellierung unter Datenmangel bewertet. Es wird die Hypothese verfolgt, dass mittels TL auf unterschiedliche Domänen übertragbare Degradationsmodelle erstellt werden können, wenn zugrundeliegende Schädigungsmechanismen und Merkmalsräume hinreichend ähnlich sind. Dazu wird ein Literaturreview durchgeführt, um eine Übersicht zu TL-Ansätzen und deren Anforderungen und Eigenschaften zu erstellen. Es sollen folgende Forschungsfragen beantwortet werden:

- Welche TL-Methoden gibt es, um Lebensdauermodelle zu erstellen?
- Welche Informationen und Datenmengen werden für TL benötigt?
- Wie hoch ist die Genauigkeit TL-basierter Degradationsprognosen?

## Review zu TL-Methoden für Lebensdauerprognosen

Um die Forschungsfragen zu beantworten, wird im Folgenden eine Übersicht zu existierenden TL-Verfahren erstellt. Dazu wurde ein strukturiertes Literaturreview durchgeführt.

### Forschungsmethodik

Mittels des Literaturreviews sollten TL-Methoden ermittelt werden, welche bereits zur Degradationsmodellierung angewendet wurden. Zur Ermittlung von Publikationen wurden die Bibliothek Google Scholar sowie das Suchwerkzeug Harzing's Publish or Perish verwendet /8/. Um viele Veröffentlichungen zu TL im Kontext der Lebensdauermodellierung zu erfassen, wurde der in Abbildung 2 dargestellte Suchstring verwendet.

Transfer Learning		Lifetime context
transfer learning OR tl	AND	life OR lifetime OR wear OR degradation OR failure OR aging OR ageing OR fatigue OR abrasion

**Abbildung 2:** Für das Review verwendeter Suchstring

Um relevante Beiträge zu extrahieren, wurden in einem ersten Schritt Titel und Abstracts anhand der in Tabelle 2 aufgeführten Ausschlusskriterien analysiert. Falls erforderlich, wurden die Volltexte quergelesen.

**Tabelle 2:** Ausschlusskriterien gefundener Beiträge

Nr.	Ausschlusskriterium
1.	Die Veröffentlichung befasst sich nicht mit TL zwecks Lebensdauermodellierung technischer Systeme gemäß Kapitel 1.1
2.	Die Veröffentlichung befasst sich nicht mit TL gemäß Kapitel 1.2
3.	Die Veröffentlichung wurde nicht fachlich geprüft / peer-reviewed
4.	Die Veröffentlichung kann nur kostenpflichtig über den Universitätszugang der TU Clausthal betrachtet werden
5.	TL wurde nicht tatsächlich angewendet, sondern es werden nur Konzepte oder theoretische Betrachtungen vorgestellt
6.	Das Paper wurde nicht in englischer Sprache verfasst
7.	Es handelt sich um ein Duplikat bzw. ein bereits betrachtetes Paper

Die auf diese Weise identifizierten Artikel wurden genauer untersucht und die gewonnenen Informationen zusammengefasst. Die Tabelle enthält Spalten zu Titel und Quelle der verbleibenden Publikationen, verwendeten TL-Methoden, betrachteten Anwendungsbeispielen, Datenanforderungen (besonders hinsichtlich Referenzsystemen) und zu vorgenommenen Leistungsbewertungen (insbesondere zur Genauigkeit der Prognose) der TL-Methoden. Um die Qualität der gefilterten Beiträge zu sichern, wurde ein Snowballing /9/ durchgeführt, um gegebene Annahmen und Informationen zu überprüfen.

### Ergebnisse des Reviews

Mithilfe des Suchstrings wurden zunächst 297 Artikel identifiziert und anhand der Ausschlusskriterien gefiltert. Schließlich wurden 37 Artikel genauer analysiert und hinsichtlich verwendeter TL-Methoden, Anwendungsbeispielen, Anforderungen und der erzielten Prognoseergebnisse analysiert. Mithilfe der in einer Tabelle gesammelten Informationen wurde eine Übersicht zu vorhandenen TL-Methoden erstellt, wobei auch zwei Reviews /10, 11/ zur Lebensdauerprognose mittels TL berücksichtigt wurden. Abbildung 3 zeigt die aus /10 – 48/ ermittelte Architektur von TL Modellen zur Degradationsprognose, sowie eine Übersicht der in den reviewten Beiträgen genutzten Methoden zur Umsetzung einzelner Modellierungsabschnitte.

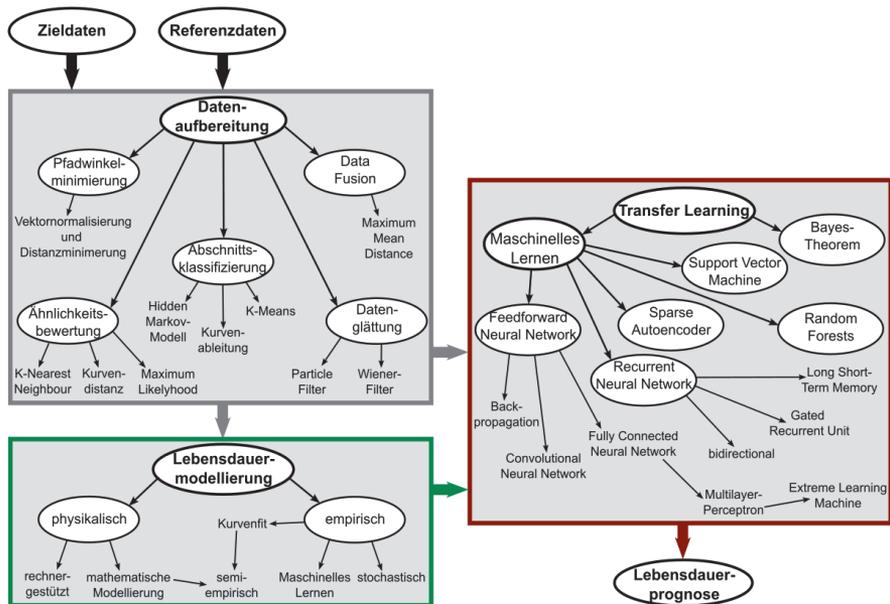


Abbildung 3: Ablauf und Verfahren TL-basierter Lebensdauermodelle /10 – 48/

TL-basierte Degradationsmodellierung wird dabei meistens anhand folgender Schritte ausgeführt:

1. Aufbereitung verfügbarer Referenzdaten, bspw. Glätten bzw. Filtern von Störsignalen oder statistischen Abweichungen. Teilweise erfolgt eine Auswahl möglichst ähnlicher Referenzdatensätze. Häufig wird eine weitere Anpassung der Daten derart vorgenommen, dass gemeinsame Eigenschaften mittels Algorithmen besser ermittelt werden können (z.B. Aufteilung von Daten in Abschnitte durch Klassifikation, Überlappung von Datensätzen/Data Fusion).
2. Erstellung von Degradations- und Lebensdauermodellen anhand der aufbereiteten Referenzdaten. Hierbei werden unterschiedliche Verfahren genutzt. Eine Beschreibung möglicher Verfahren ist in /3/ zu finden. In den gefundenen Beiträgen wurden häufig Verfahren des ML genutzt.
3. Anpassung erstellter Degradations- und Lebensdauermodelle mittels des in Kapitel 1 erläuterten TL-Konzeptes an das betrachtete Zielsystem. Dazu werden teilweise zusätzliche Referenzdaten genutzt. In den vorliegenden Beiträgen werden zudem in allen Fällen Lebensdauerinformationen des Zielsystems benötigt, diese können aber unvollständig sein und bspw. nur frühe Degradationsphasen umfassen.

Die in /10 – 48/ erfassten TL-Verfahren sind in Abbildung 3 in klassifizierter Form dargestellt. Es wurden fünf unterschiedliche Verfahren des ML angewendet, nämlich Feedforward Neural Networks (FFNN), Recurrent Neural Networks (RNN), Sparse Autoencoder (SAE), Support Vector Machines (SVM) und Random Forests. Dabei wurden RNN in verschiedenen Varianten angewendet, nämlich mit Long-Short Term Memory (LSTM RNN) oder als Gated Recurrent Unit (GRU), häufig mit bidirektionalem Informationsfluss. FFNN wurden zumeist mit Backpropagation von Informationen ausgeführt. Basierend auf FFNN wurden zudem Convolutional Neural Networks (CNN) und Fully Connected Neural Networks (FCNN) erstellt und erprobt. Außerdem fanden Sonderformen des FCNN, das Multilayer Perceptron (MLP) und daraus abgeleitete Extreme Learning Maschinen (ELM), Anwendung. Neben Verfahren des ML wurde zudem das Bayes Theorem als Grundlage von TL genutzt. Auch Hybridvarianten unterschiedlicher TL Verfahren wurden angewendet.

Weiterhin sind zwei Arten von Datengrundlagen zur Degradationsmodellierung zu unterscheiden, welche in betrachteten Beiträgen verwendet wurden:

- **Direkte Lebensdauerdaten:** Daten zu Referenz- und Zielsystemen enthalten Messwerte der Modellierungsgröße des Lebensdauermodells oder Größen, mit welchen diese berechnet werden kann (z.B. Restkapazität bei Batterien)
- **Indirekte Lebensdauerdaten:** Daten zu Referenz- und Zielsystemen enthalten Messwerte, mit denen lediglich auf die Modellierungsgröße des Degradations- oder Lebensdauermodells geschlossen wird (z.B. Schwingungsverhalten bei Kugellagerung)

Bei einer Modellierung anhand indirekter Lebensdauerdaten ist die Unsicherheit einer Degradationsprognose erhöht und die Erstellung präziser Modelle damit erschwert.

In Tabelle 3 sind die in den reviewten Beiträgen verwendeten TL Verfahren einschließlich Art der Datengrundlage und zugehöriger Quellen zusammengefasst. Weiterhin erfolgte eine Analyse und Bewertung der benötigten Menge an Referenzdaten und der Präzision der Degradationsvorhersage des angewendeten TL Verfahrens und der zugrundeliegenden Degradationsmodelle der Referenzsysteme.

**Tabelle 3: Bewertung der Leistungsfähigkeit betrachteter TL-Methoden**

Verwendete TL-Verfahren	Direkt/indirekt	Referenzdatenbedarf	Genauigkeit	Quellen
FFNN oder MLP	indirekt	mittel	niedrig bis mittel	/12 – 16/
ELM	direkt	mittel	mittel	/17/
CNN	indirekt	niedrig bis mittel	niedrig bis mittel	/18 – 22/
CNN und FCNN	indirekt	mittel	niedrig bis mittel	/23/
CNN und FCNN	direkt	hoch	niedrig bis mittel	/24, 25/
LSTM RNN	indirekt	mittel	niedrig bis mittel	/26, 27/
LSTM RNN	direkt	mittel bis hoch	hoch bis sehr hoch	/28 – 36/
GRU	indirekt	mittel	niedrig bis mittel	/37/
GRU	direkt	mittel	hoch bis sehr hoch	/38/
LSTM RNN und FCNN oder CNN	mittel	mittel	niedrig bis mittel	/39/
LSTM RNN und FCNN oder CNN	direkt	mittel	hoch bis sehr hoch	/40, 41/
GRU und FFNN	indirekt	mittel	niedrig bis mittel	/42/
CNN und LSTM	indirekt	niedrig	niedrig bis mittel	/43/
SAE	indirekt	hoch	niedrig bis mittel	/44/
SAE und LSTM RNN	indirekt	mittel	mittel?	/45/
RF	indirekt	mittel	mittel?	/46/
SVM	indirekt	mittel	mittel?	/47/
BT	direkt	mittel	hoch bis sehr hoch	/48/

Als Bewertungsgrundlage für die Datenanforderungen wurde definiert, dass ein Bedarf an Lebensdauerinformationen von maximal 20 Referenzsystemen als

„niedrig“ bewertet wird. Werden über 100 Referenzsysteme benötigt, ist der Datenbedarf „hoch“, ansonsten wird er als „mittel“ eingestuft. Befindet sich der Datenbedarf nahe den definierten Grenzwerten, wurde zudem keine eindeutige Bewertung vorgenommen und bspw. „niedrig bis mittel“ gewählt. Die Präzision der TL-Verfahren wurde daran bemessen, ob mit dem erstellten Degradationsmodell eine zuverlässige Prognose für das Zielsystem möglich ist. Verfehlen die in den Beiträgen dargestellten Ergebnisse die realen Lebensdauerdaten des Zielsystems mindestens zeitweise um über 30%, so ist die Genauigkeit „niedrig“, da dann nur eine unsichere Prognose möglich ist. Sind die Ergebnisse sehr nahe an den realen Daten und weichen selten um mehr als 5% ab, ist die Genauigkeit „hoch“ oder sogar „sehr hoch“, ansonsten „mittel“. Bei vielen Beiträgen variierte die Genauigkeit der TL Verfahren bei variablen Einflussgrößen der Lebensdauer jedoch deutlich, sodass auch hier teils keine eindeutige Bewertung vorgenommen werden konnte. Zudem wurde in einigen Beiträgen die Genauigkeit der entwickelten TL-Verfahren nicht hinreichenden mit Ergebnissen belegt, sodass nur eine Bewertung unter Vorbehalt erfolgte, siehe /45 – 47/.

## Zusammenfassung und Ausblick

Mittels des Reviews konnte eine umfangreiche Übersicht zu TL Verfahren für die Lebensdauermodellierung erstellt werden. Dabei wurden signifikante Unterschiede hinsichtlich der Genauigkeit betrachteter Verfahren erkannt, wenn direkte oder indirekte Lebensdauerdaten als Grundlage genutzt wurden, siehe Tabelle 3. Der Bedarf an Referenzdaten verschiedener TL Verfahren konnte ermittelt und bewertet werden, wobei zumeist weniger als 100 Datensätze benötigt wurden. Dennoch konnten Effizienzunterschiede bei den Verfahren festgestellt werden, wobei LSTM RNN, GRU und BT hier besonders vielversprechend erscheinen.

In weiterführenden Untersuchungen sollen TL Methoden ohne Nutzung von Zieldaten entwickelt und geprüft werden, da hier eine Forschungslücke gefunden wurde. Insbesondere die Integration einer geeigneten Ähnlichkeitsbewertung muss dabei betrachtet werden. Weiterhin sollen Modelverbesserungen durch die Integration in Digitale Zwillinge untersucht werden.

## Literatur

- /1/ Umeda, Y.; Daimon, T.; Kondoh, S.: Life cycle option selection based on the difference of value and physical lifetimes for life cycle design. In: 16th International Conference on Engineering Design. 2007, Artikel-Nr. DS42\_P\_47. ISBN 1-904670-02-4
- /2/ Mcpherson, J.: Reliability Physics and Engineering. New York, Springer, 2010. DOI 10.1007/978-3-319-93683-3
- /3/ Bauer, R. S.; Inkermann, D.: Selection of model approaches and modelling methods for lifetime prognosis. In: Proceedings of the Design Society Vol. 3, 2023, S. 3125-3134. DOI 10.1017/pds.2023.313

- /4/ 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
- /5/ Weiss, K.; Khoshgoftaar, T. M.; Wang, D.: A survey of transfer learning. In: Journal of Big Data Vol. 3, 2016, Artikel-Nr. 9. DOI 10.1186/s40537-016-0043-6
- /6/ 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
- /7/ Li, Z.; Kristoffersen, E.; Li, J.: Deep transfer learning for failure prediction across failure types. In: Computers & Industrial Engineering Vol. 172, Issue A, 2022, Artikel-Nr. 108521. DOI 10.1016/j.cie.2022.108521
- /8/ Harzing, A. W.: Publish or perish. <https://harzing.com/resources/publish-or-perish>; 2007.
- /9/ Kitchenham, B.; Brereton, P.: A systematic review of systematic review process research in software engineering. In: Information and Software Technology Vol. 55, Issue 12, 2013, S. 2049–2075. DOI 10.1016/j.infsof.2013.07.010
- /10/ Lin, T. et al.: Investigating explainable transfer learning for battery lifetime prediction under state transitions. In: eScience Vol. 4, Issue 5, 2024, Artikel-Nr. 100280. DOI 10.1016/j.esci.2024.100280
- /11/ Liu, K. et al.: Transfer learning for battery smarter state estimation and ageing prognostics: Recent progress, challenges, and prospects. In: Advances in Applied Energy Vol. 9, 2023, Artikel-Nr. 100117. DOI 10.1016/j.adapen.2022.100117
- /12/ Zhu, J.; Chen, N.; Shen, C.: A new data-driven transferable remaining useful life prediction approach for bearing under different working conditions. In: Mechanical Systems and Signal Processing Vol. 139, 2020, Artikel-Nr. 106602. DOI 10.1016/j.ymssp.2019.106602
- /13/ Ding, Y.; Jia, M.; Miao, Q.; Huang, P.: Remaining useful life estimation using deep metric transfer learning for kernel regression. In: Reliability Engineering & System Safety Vol. 212, 2021, Artikel-Nr. 107583. DOI 10.1016/j.res.2021.107583
- /14/ Siahpour, S.; Li, X.; Lee, J.: A novel transfer learning approach in remaining useful life prediction for incomplete dataset. In: IEEE Transactions on Instrumentation and Measurement Vol. 71, 2022, S. 1-11. DOI 10.1109/TIM.2022.3162283
- /15/ Li, Y.; Wie, P.; Xiang, G.; Jia, C.; Liu, H.: Gear contact fatigue life prediction based on transfer learning. In: International Journal of Fatigue Vol. 173, 2023, Artikel-Nr. 107686. DOI 10.1016/j.ijfatigue.2023.107686
- /16/ Cheng, H. et al.: Remaining useful life prediction combined dynamic model with transfer learning under insufficient degradation data. In: Reliability Engineering & System Safety Vol. 236, 2023, Artikel-Nr. 109292. DOI 10.1016/j.res.2023.109292
- /17/ Gu, B.; Liu, Z.: Transfer learning-based remaining useful life prediction method for lithium-ion batteries considering individual differences. In: Applied Sciences Vol. 14, Issue 2, 2024, Artikel-Nr. 698. DOI 10.3390/app14020698
- /18/ Zhang, W.; Li, X.; Ma, H.; Luo, Z.; Li, X.: Transfer learning using deep representation regularization in remaining useful life prediction across operating conditions. In: Reliability Engineering & System Safety Vol. 211, 2021, Artikel-Nr. 107556. DOI 10.1016/j.res.2021.107556
- /19/ Cheng, H.; Kong, X.; Wang, Q.; Ma, H.; Yang, S.: The two-stage RUL prediction across operation conditions using deep transfer learning and insufficient degradation data. In: Reliability Engineering & System Safety Vol. 225, 2022, Artikel-Nr. 108581. DOI 10.1016/j.res.2022.108581

- /20/ Kamm, S. et al.: Simulation-to-reality based transfer learning for the failure analysis of SiC power transistors. In: IEEE 27th International Conference on Emerging Technologies and Factory Automation, 2022, S. 1-8. DOI 10.1109/ETFA52439.2022.9921681
- /21/ Schwendemann, S.; Sikora, A.: Transfer-learning-based estimation of the remaining useful life of heterogeneous bearing types using low-frequency accelerometers. In: Journal of Imaging Vol. 9, 2023, Artikel-Nr. 34. DOI 10.3390/jimaging9020034
- /22/ Gao, Z.; Chen, N.; Yang, Y.; Li, L.: An innovative multisource lightweight adaptive replayed online deep transfer learning algorithm for tool wear monitoring. In: Journal of Manufacturing Processes Vol. 124, 2024, S. 261-281. DOI 10.1016/j.jmapro.2024.05.050
- /23/ Zhu, Q.; Zu, X.: Fully convolutional neural network structure and its loss function for image classification. In: IEEE Access Vol. 10, 2022, S. 35541-35549. DOI 10.1109/ACCESS.2022.3163849
- /24/ Xiao, L. et al.: A transfer learning-based approach to fatigue life prediction of corroded bimetallic steel bars using small samples. In: Construction and Building Materials Vol. 400, 2023, Artikel-Nr. 132679. DOI 10.1016/j.conbuildmat.2023.132679
- /25/ Zhou, C. et al.: Creep rupture life prediction of high-temperature titanium alloy using cross-material transfer learning. In: Journal of Materials Science & Technology Vol. 178, 2024, S. 39-47. DOI 10.1016/j.jmst.2023.08.046
- /26/ Zhang, A. et al.: Transfer learning with deep recurrent neural networks for remaining useful life estimation. In: Applied Sciences Vol. 8, 2018, Artikel-Nr. 2416. DOI 10.3390/app8122416
- /27/ Berghout, T.; Mouss, L.-H.; Bentrucia, T.; Benbouzid, M.: A semi-supervised deep transfer learning approach for rolling-element bearing remaining useful life prediction. In: IEEE Transactions on Energy Conversion Vol. 37, Issue 2, 2022, S. 1200-1210. DOI 10.1109/TEC.2021.3116423
- /28/ Deng, Z.; Lin, X.; Cai, J.; Hu, X.: Battery health estimation with degradation pattern recognition and transfer learning. In: Journal of Power Sources Vol. 525, 2022, Artikel-Nr. 231027. DOI 10.1016/j.jpowsour.2022.231027
- /29/ Pan, D.; Li, H.; Wang, S.: Transfer learning-based hybrid remaining useful life prediction for lithium-ion batteries under different stresses. In: IEEE Transactions on Instrumentation and Measurement Vol. 71, 2022, S. 1-10. DOI 10.1109/TIM.2022.3142757
- /30/ Ma, J. et al.: A hybrid transfer learning scheme for remaining useful life prediction and cycle life test optimization of different formulation Li-ion power batteries. In: Applied Energy Vol. 282, Issue A, 2021, Artikel-Nr. 116167. DOI 10.1016/j.apenergy.2020.116167
- /31/ Chen, J.; Han, X.; Sun, T.; Zheng, Y.: Analysis and prediction of battery aging modes based on transfer learning. In: Applied Energy Vol. 356, 2024, Artikel-Nr. 122330. DOI 10.1016/j.apenergy.2023.122330
- /32/ Zhao, G.; Kang, Y.; Huang, P.; Duan, P.; Zhang, C.: Battery health prognostic using efficient and robust aging trajectory matching with ensemble deep transfer learning. In: Energy Vol. 282, 2023, Artikel-Nr. 128228. DOI 10.1016/j.energy.2023.128228
- /33/ Wang, Y.; Zhu, J.; Cao, L.; Gopaluni, B.; Cao, Y.: Long short-term memory network with transfer learning for lithium-ion battery capacity fade and cycle life prediction. In: Applied Energy Vol. 350, 2023, Artikel-Nr. 121660. DOI 10.1016/j.apenergy.2023.121660

- /34/ Chen, X. et al.: Transfer learning based remaining useful life prediction of lithium-ion battery considering capacity regeneration phenomenon. In: Journal of Energy Storage Vol. 76, 2024, Artikel-Nr. 109798. DOI 10.1016/j.est.2023.109798
- /35/ Li, Z.; Bai, F.; Zuo, H.; Zhang, Y.: Remaining useful life prediction for lithium-ion batteries based on iterative transfer learning and mogrifier LSTM. In: Batteries Vol. 9, Issue 9, 2023, Artikel-Nr. 448. DOI 10.3390/batteries9090448
- /36/ Guo, Y.; Wang, Y.; Ding, P.; Huang, K.: Future degradation trajectory prediction of lithium-ion battery based on a three-step similarity evaluation criterion for battery selection and transfer learning. In: Journal of Energy Storage Vol. 72, Issue E, 2023, Artikel-Nr. 108763. DOI 10.1016/j.est.2023.108763
- /37/ Izadi, M. J.; Hassani, P.; Raeesi, M.; Ahmadi, P.: A novel WaveNet-GRU deep learning model for PEM fuel cells degradation prediction based on transfer learning. In: Energy Vol. 293, 2024, Artikel-Nr. 130602. DOI 10.1016/j.energy.2024.130602
- /38/ 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, Issue D, 2025, Artikel-Nr. 124766. DOI 10.1016/j.apenergy.2024.124766
- /39/ Park, S. H.; Park, K. S.: A pre-trained model selection for transfer learning of remaining useful life prediction of grinding wheel. Journal of Intelligent Manufacturing Vol. 35, S. 2295–2312. DOI 10.1007/s10845-023-02154-9
- /40/ 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, Artikel-Nr. 100293. DOI 10.1016/j.etrans.2023.100293
- /41/ 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, Artikel-Nr. 235534. DOI 10.1016/j.jpowsour.2024.235534
- /42/ Cao, Y.; Jia, M.; Ding, P.; Ding, Y.: Transfer learning for remaining useful life prediction of multi-conditions bearings based on bidirectional-GRU network. In: Measurement Vol. 178, 2021, Artikel-Nr. 109287. DOI 10.1016/j.measurement.2021.109287
- /43/ Yue, M.; Benagoune, K.; Meng, J.; Diallo, D.: Implementation of an early stage fuel cell degradation prediction digital twin based on transfer learning. In: IEEE Transactions on Transportation Electrification Vol. 9, Issue 2, S. 3308-3318. DOI 10.1109/TTE.2022.3229716
- /44/ Sun, C. et al.: Deep transfer learning based on sparse autoencoder for remaining useful life prediction of tool in manufacturing. In: IEEE Transactions on Industrial Informatics Vol. 15, Issue 4, S. 2416-2425. DOI 10.1109/TII.2018.2881543
- /45/ Ma, J. et al.: Degradation prognosis for proton exchange membrane fuel cell based on hybrid transfer learning and intercell differences. In: ISA Transactions Vol. 113, 2021, S. 149-165. DOI 10.1016/j.isatra.2020.06.005
- /46/ Fan, Y.; Nowaczyk, S.; Rognvaldsson, T.: Transfer learning for remaining useful life prediction based on consensus self-organizing models. In: Reliability Engineering & System Safety Vol. 203, 2020, Artikel-Nr. 107098. DOI 10.1016/j.res.2020.107098
- /47/ Han, X. et al.: Online transfer learning-based method for predicting remaining useful life of aero-engines. In: 7th International Conference on Intelligent Computing and Signal Processing, 2022, S. 865-870. DOI 10.1109/ICSP54964.2022.9778844
- /48/ 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, Issue 1, 2022, Artikel-Nr. 100008. DOI 10.1016/j.geits.2022.100008