



(10) **DE 10 2021 207 467 A1** 2023.01.19

(12) **Offenlegungsschrift**

(21) Aktenzeichen: **10 2021 207 467.7**

(22) Anmeldetag: **14.07.2021**

(43) Offenlegungstag: **19.01.2023**

(51) Int Cl.: **G01R 31/392 (2019.01)**
G06N 20/00 (2019.01)

(71) Anmelder:
**Robert Bosch Gesellschaft mit beschränkter
Haftung, 70469 Stuttgart, DE**

(56) Ermittelter Stand der Technik:

AT	521 643	B1
US	8 332 342	B1

(72) Erfinder:
Simonis, Christian, 71229 Leonberg, DE


Rechercheantrag gemäß § 43 PatG ist gestellt.

Die folgenden Angaben sind den vom Anmelder eingereichten Unterlagen entnommen.

(54) Bezeichnung: **Verfahren und Vorrichtung zum Betreiben eines Systems zum Bereitstellen von prädierten Konfidenzintervallen von Alterungszuständen von elektrischen Energiespeichern für mindestens ein Gerät mithilfe von maschinellen Lernverfahren**

(57) Zusammenfassung: Die Erfindung betrifft ein computerimplementiertes Verfahren zur Prädiktion eines modellierten Alterungszustands (SOH) eines elektrischen Energiespeichers (41) mit mindestens einer elektrochemischen Einheit, insbesondere einer Batteriezelle, in einem technischen Gerät (4); mit folgenden Schritten:

- Bereitstellen eines datenbasierten Alterungszustandsmodells (9), das ausgebildet ist, um abhängig von einem Verlauf mindestens einer Betriebsgröße (F) des Energiespeichers (41) bis zu einem Zeitpunkt dem elektrochemischen Energiespeicher (41) einen entsprechenden Alterungszustand (SOH) für den Zeitpunkt zuzuordnen und eine entsprechende Modellierungsunsicherheit anzugeben,
- Präzisieren (S16) eines Verlaufs für die mindestens eine Betriebsgröße ausgehend von einem aktuellen Zeitpunkt in die Zukunft abhängig von einem Nutzungsmustermodell, das durch ein nutzer- oder nutzungsindividuelles Nutzungsmuster bestimmt ist,
- Präzisieren (S17) eines Verlaufs des Alterungszustands mithilfe des datenbasierten Alterungszustandsmodells (9) abhängig von dem modellbasiert generierten prädierten Verlauf der mindestens einen Betriebsgröße (F);
- Bestimmen (S18, S19) eines Konfidenzintervalls für den prädierten Verlauf des Alterungszustands abhängig von der Modellierungsunsicherheit des datenbasierten Alterungszustandsmodells (9) und einer Konfidenz des Nutzungsmustermodells (10);
- Signalisieren (S20) des prädierten Verlaufs des Alterungszustands und des entsprechenden Konfidenzintervalls.



Beschreibung

Technisches Gebiet

[0001] Die Erfindung betrifft netzunabhängig betriebene elektrische Geräte mit elektrischen Energiespeichern, insbesondere elektrisch antreibbare Kraftfahrzeuge, insbesondere Elektrofahrzeuge oder Hybridfahrzeuge, und weiterhin Maßnahmen zur Bestimmung eines Alterungszustands (SOH: State of Health) des elektrischen Energiespeichers. Weiterhin betrifft die Erfindung neben mobilen auch stationäre elektrische Energiespeicher.

Technischer Hintergrund

[0002] Die Energieversorgung von netzunabhängig betriebenen elektrischen Geräten und Maschinen, wie z.B. elektrisch antreibbaren Kraftfahrzeugen, erfolgt mithilfe von elektrischen Energiespeichern, in der Regel Gerätebatterien bzw. Fahrzeugbatterien. Diese liefern elektrische Energie zum Betrieb der Geräte. Als elektrischer Energiespeicher kommen jedoch auch Energiewandler, wie z.B. Brennstoffzellen-Systeme, inklusive Wasserstofftank, in Betracht.

[0003] Elektrische Energiespeicher bzw. Energiewandler degradieren über ihre Lebensdauer und abhängig von deren Belastung bzw. Nutzung. Diese sogenannte Alterung führt zu einer kontinuierlich abnehmenden maximalen Leistungs- bzw. Speicherkapazität. Der Alterungszustand entspricht einem Maß zur Angabe der Alterung von Energiespeichern. Gemäß der Konvention weist ein neuer Energiespeicher einen Alterungszustand von 100% auf, der im Laufe seiner Lebensdauer zusehends abnimmt. Ein Maß der Alterung des Energiespeichers (zeitliche Änderung des Alterungszustands) hängt von einer individuellen Belastung des Energiespeichers, d. h. bei Fahrzeugbatterien von Kraftfahrzeugen vom Nutzungsverhalten eines Fahrers, externen Umgebungsbedingungen und vom Fahrzeugbatterietyp ab.

[0004] Zwar kann mithilfe eines physikalischen Alterungszustandsmodells der momentane Alterungszustand des Energiespeichers basierend auf historischen Betriebszustandsverläufen bestimmt werden, jedoch ist dieses Modell in bestimmten Situationen ungenau. Diese Ungenauigkeit des herkömmlichen Alterungszustandsmodells erschwert eine Prädiktion des Alterungszustandsverlaufs. Jedoch ist die Prädiktion des Verlaufs des Alterungszustands der Energiespeicher eine wichtige technische Größe, da mit ihr eine wirtschaftliche Bewertung eines Restwerts des Energiespeichers möglich ist. Die Unsicherheit der Prädiktion spielt hierbei eine wichtige Größe, da sie das technische und wirtschaftliche Risiko quantifiziert, z.B. bei einer Spezifikation der Alterung bzw. einer Garantie-Verletzung.

Offenbarung der Erfindung

[0005] Erfindungsgemäß sind ein Verfahren zur Prädiktion eines Alterungszustands eines elektrischen Energiespeichers gemäß Anspruch 1 sowie eine Vorrichtung zur Prädiktion eines Alterungszustands eines elektrischen Energiespeichers in einem elektrisch betreibbaren Gerät gemäß dem nebengeordneten Anspruch vorgesehen.

[0006] Weitere Ausgestaltungen sind in den abhängigen Ansprüchen angegeben.

[0007] Gemäß einem ersten Aspekt ist ein computerimplementiertes Verfahren zur Prädiktion eines modellierten Alterungszustands eines elektrischen Energiespeichers mit mindestens einer elektrochemischen Einheit, insbesondere einer Batteriezelle, in einem technischen Gerät; mit folgenden Schritten:

- Bereitstellen eines datenbasierten Alterungszustandsmodells, das ausgebildet ist, um abhängig von einem Verlauf mindestens einer Betriebsgröße des Energiespeichers bis zu einem Zeitpunkt dem elektrochemischen Energiespeicher einen entsprechenden Alterungszustand für den Zeitpunkt zuzuordnen und eine entsprechende Modellierungsunsicherheit anzugeben,
- Prädizieren eines Verlaufs für die mindestens eine Betriebsgröße ausgehend von einem aktuellen Zeitpunkt in die Zukunft abhängig von einem Nutzungsmustermodell, das durch ein nutzer- oder nutzungsindividuelles Nutzungsmuster bestimmt ist,
- Prädizieren eines Verlaufs des Alterungszustands mithilfe des datenbasierten Alterungszustandsmodells abhängig von dem modellbasiert generierten prädizierten Verlauf der mindestens einen Betriebsgröße;

- Bestimmen eines Konfidenzintervalls für den prädizierten Verlauf des Alterungszustands abhängig von der Modellierungsunsicherheit des datenbasierten Alterungszustandsmodells und einer Konfidenz des Nutzungsmustermodells;
- Signalisieren des prädizierten Verlaufs des Alterungszustands und des entsprechenden Konfidenzintervalls.

[0008] Energiespeicher im Sinne dieser Beschreibung umfassen Gerätebatterien, Energiewandlersysteme mit einem elektrochemischen Energiewandler mit einem Energieträgervorrat, wie z.B. Brennstoffzellensysteme mit einer Brennstoffzelle und einem Energieträgervorrat.

[0009] Der Alterungszustand eines elektrischen Energiespeichers, insbesondere einer Gerätebatterie, wird üblicherweise nicht direkt gemessen. Dies würde eine Reihe von Sensoren in Inneren des Energiespeichers erfordern, die die Herstellung eines solchen Energiespeichers kostenintensiv sowie aufwendig machen und den Raumbedarf vergrößern würde. Zudem sind alltagstaugliche Messverfahren zur direkten Alterungszustandsbestimmung in den Energiespeichern noch nicht auf dem Markt verfügbar. Daher wird der aktuelle Alterungszustand eines elektrischen Energiespeichers in der Regel mithilfe eines physikalischen Alterungsmodells in einem von dem Energiespeicher separaten Steuergerät ermittelt. Dieses physikalische Alterungszustandsmodell ist in bestimmten Situationen ungenau und weist üblicherweise Modellabweichungen von bis zu mehr als 5 % auf.

[0010] Aufgrund der Ungenauigkeit des physikalischen Alterungsmodells kann dieses zudem lediglich den momentanen Alterungszustand des Energiespeichers einigermaßen genau angeben. Eine Prädiktion des Alterungszustands, die insbesondere von der Betriebsweise des Energiespeichers, wie z. B. von der Höhe und Menge des Ladungszuflusses und Ladungsabflusses bei einer Gerätebatterie, und damit von einem Nutzungsverhalten und von Nutzungsparametern abhängt, würde zu sehr ungenauen Vorhersagen führen und ist derzeit nicht vorgesehen.

[0011] Der Alterungszustand (SOH: State of Health) ist bei Gerätebatterien die Schlüsselgröße zur Angabe einer verbleibenden Batteriekapazität oder verbleibenden Batterieladung. Der Alterungszustand stellt ein Maß für die Alterung der Gerätebatterie dar. Im Falle einer Gerätebatterie oder eines Batterie-Moduls oder einer Batterie-Zelle kann der Alterungszustand als Kapazitätserhaltungsrate (Capacity Retention Rate, SOH-C) angegeben werden. Die Kapazitätserhaltungsrate SOH-C ist als Verhältnis der gemessenen momentanen Kapazität zu einer Anfangskapazität der vollständig aufgeladenen Batterie angegeben. Alternativ kann der Alterungszustand als Anstieg des Innenwiderstands (SOH-R) bezüglich eines Innenwiderstands zu einem Lebensdauerbeginn der Gerätebatterie angegeben werden. Die relative Änderung des Innenwiderstands SOH-R steigt mit zunehmender Alterung der Batterie an.

[0012] Vielversprechend sind Ansätze, eine nutzer- und nutzungsindividuelle Modellierung und Prädiktion eines Lastprofils und des einhergehenden Alterungszustands des elektrischen Energiespeichers basierend auf einem Alterungszustandsmodell vorzusehen, das die Verläufe von Betriebsgrößen vom Zeitpunkt der Inbetriebnahme nutzt, um den Alterungszustand jeweils Zeitschritt für Zeitschritt ausgehend von dem Alterungszustand zum Inbetriebnahmezeitpunkt anzupassen. Dieses Alterungszustandsmodell kann rein datenbasiert aber auch als hybrides datenbasiertes Alterungszustandsmodell implementiert werden. Ein solches Alterungszustandsmodell kann z. B. in einer Zentraleinheit (Cloud) implementiert sein und mithilfe von Betriebsgrößen einer Vielzahl von Energiespeichern verschiedener Geräte parametrisiert bzw. trainiert werden, die mit der Zentraleinheit in Kommunikationsverbindung stehen.

[0013] Alterungszustandsmodelle zur Ermittlung von Alterungszuständen für elektrische Energiespeicher können in Form eines hybriden Alterungszustandsmodells, also einer Kombination eines physikalischen Alterungsmodells mit einem datenbasierten Modell, bereitgestellt werden. Bei einem hybriden Modell kann ein physikalischer Alterungszustand mithilfe eines physikalischen bzw. elektrochemischen Alterungsmodells ermittelt werden und dieser mit einem Korrekturwert beaufschlagt werden, der sich aus einem datenbasierten Korrekturmodell ergibt, insbesondere durch Addition oder Multiplikation. Das physikalische Alterungsmodell basiert auf elektrochemischen Modellgleichungen, welche elektrochemische Zustände eines nichtlinearen Differentialgleichungssystems charakterisiert, fortlaufend berechnet und diese zur Ausgabe auf den physikalischen Alterungszustand abbildet, als SOH-C und/oder als SOH-R. Die Berechnungen können typischerweise in der Cloud z.B. einmal pro Woche ausgeführt werden.

[0014] Weiterhin kann das Korrekturmodell des hybriden datenbasierten Alterungszustandsmodells mit einem probabilistischen oder auf künstlicher Intelligenz basierendem Regressionsmodell, insbesondere

einem Gaußprozessmodell, ausgebildet sein und kann trainiert sein, um den durch das physikalische Alterungsmodell erhaltenen Alterungszustand zu korrigieren. Hierzu existieren folglich ein datenbasiertes Korrekturmodell des Alterungszustands zur Korrektur des SOH-C und/oder mindestens ein weiteres zur Korrektur des SOH-R. Mögliche Alternativen zum Gaußprozess stellen weitere Supervised Learning Verfahren, wie basierend auf einem Random-Forest-Modell, einem AdaBoost-Modell, einer Support-Vector-Machine oder einem Bayes'schen neuronalen Netzwerk dar.

[0015] Eine Prädiktion des Alterungszustands ist hilfreich, z.B. wenn eine verbleibende Restlebensdauer des Energiespeichers ermittelt werden soll und diese z.B. gegen Garantiebedingungen oder CO₂-Flottenvorgaben bewertet werden. Weiterhin kann eine transparente fahrzeugübergreifende Bewertung des technischen Zustands des Energiespeichers zu einer höheren Transparenz bei der Bewertung von elektrischen Fahrzeugen beitragen, da die tatsächliche historische Batterielast, z.B. beeinflusst von bidirektionalem Laden, in der Regel unbekannt ist und nicht unmittelbar an einem Kilometerstand des Fahrzeugs erkannt werden kann.

[0016] Zur einhergehenden Charakterisierung und Alterungsbestimmung kann das datenbasierte Alterungszustandsmodell in Verbindung mit einem vorgegebenen Nutzungsmuster, das die Art der Nutzung und des Betriebs des elektrischen Energiespeichers angibt, kontinuierlich abgefragt werden. Dazu ist ausgehend von dem aktuellen Zeitpunkt eine laufende Generierung von „künstlichen“ (prädizierten) zeitlichen Verläufen von Betriebsgrößen notwendig, die von dem physikalischen Alterungsmodell aufgrund des Zeitintegrations-Verfahrens zur Lösung der Differentialgleichung benötigt werden, um einen prädizierten Alterungszustand zu modellieren. Insbesondere wird dadurch der prädizierte Verlauf des Alterungszustands ausgehend von dem aktuellen Zeitpunkt bestimmt. Die Betriebsgrößen werden dazu entweder direkt abhängig von dem erkannten Nutzungsmuster oder basierend auf von dem Nutzungsmuster abgeleiteten Verläufen von Belastungsgrößen, aus denen die Verläufe der benötigten Betriebsgrößen generiert werden, erzeugt.

[0017] Diese Möglichkeit der Prädiktion nutzt in vorteilhafter Weise das trainierte Alterungszustandsmodell und Nutzungsmuster, so dass eine genauere Prädiktion des Alterungszustands möglich ist als bei reinen extrapolierenden Verfahren.

[0018] Zur Modellierung eines Alterungszustands eines Energiespeichers mithilfe eines physikalischen bzw. elektrochemischen Alterungszustandsmodells und einer optionalen Präzisierung durch ein datenbasiertes Korrekturmodell (hybrides Alterungszustandsmodell) ist es notwendig, die Zeitverläufe von Betriebsgrößen relativ hochfrequent bereitzustellen. Diese Zeitverläufe der Betriebsgrößen müssen weiterhin für die erforderlichen Genauigkeitsanforderungen möglichst lückenlos bereitgestellt werden, d. h. für die Bestimmung des Alterungszustands zu dem aktuellen Zeitpunkt für eine Gerätebatterie ist es notwendig, die Zeitverläufe der Batterietemperatur, des Batteriestroms, der Batteriespannung und des Ladezustands, insbesondere auf Zellebene bereitzustellen.

[0019] Die Berechnung des physikalischen/elektrochemischen Modells nebst Korrekturmodell findet vorzugsweise geräteextern statt, da diese rechenaufwendig ist und häufig die geforderte Verarbeitungsleistung in den oder hardware-nah an den batteriebetriebenen Geräten nicht ausreicht oder aus Kostengründen nicht vorgehalten werden soll. Daher werden die Zeitverläufe der Betriebsgrößen kontinuierlich an eine geräteexterne Zentraleinheit übertragen und dort der Alterungszustand gemäß dem elektrochemischen Modell sowie ggfs. dem Korrekturmodell bestimmt. Weiterhin muss das Training für ein globales Alterungsmodell zentralisiert, also in einer Cloud-Umgebung, stattfinden.

[0020] Für die Prädiktion werden ausgehend von dem aktuellen Zeitpunkt bzw. aktuellen Auswertungszeitraum die mindestens eine Betriebsgröße (Belastungsgröße), also z.B. der zeitliche Verlauf einer Temperatur und/oder eines Stroms bei einer Batterie als Energiespeicher, in einem Nutzungsmustermodell generiert.

[0021] Weiterhin kann zur Bestimmung des prädizierten Verlaufs des Alterungszustands das datenbasierte Alterungszustandsmodell mit einem gesamten Verlauf der mindestens einer Betriebsgröße betrieben werden, der den bisherigen Verlauf der mindestens einen Betriebsgröße bis zu dem aktuellen Zeitpunkt und dem modellbasiert generierten Verlauf der mindestens einen Betriebsgröße ausgehend von dem aktuellen Zeitpunkt in die Zukunft umfasst.

[0022] Es kann vorgesehen sein, dass das Nutzungsmustermodell insbesondere als datenbasiertes Modell, insbesondere als Bayes'sches LSTM, ausgebildet ist, um abhängig von Nutzungsparametern eines nutzerindividuell oder nutzungsindividuell erlernten Nutzungsmusters kontinuierlich einen Verlauf der mindestens

einen Betriebsgröße oder einen Verlauf mindestens einer Belastungsgröße, aus der die mindestens eine Betriebsgröße generierbar ist, bereitzustellen.

[0023] Das Nutzungsmustermodell ist also ausgebildet, um abhängig von Nutzungsparametern des Nutzungsmusters kontinuierlich einen Verlauf der mindestens einen Betriebsgröße oder einen Verlauf mindestens einer Belastungsgröße, aus der die mindestens eine Betriebsgröße generierbar ist, zu erlernen und auszugeben. Somit ist das Nutzungsmustermodell ausgebildet, um abhängig von einem oder mehreren Nutzungsparametern, die das Nutzungsmuster explizit oder implizit, d.h. mithilfe eines datenbasierten Modells, vorgegeben, kontinuierliche Verläufe der mindestens einen Betriebsgröße auszugeben. Dies ermöglicht, ein durch das Nutzungsmuster parametrisiertes Nutzungsverhalten in Zeitreihen der mindestens einen Betriebsgröße umzusetzen. Dies kann durch ein direktes Generieren des Verlaufs der mindestens einen Betriebsgröße und/oder durch ein Generieren von mindestens einer Belastungsgröße, der selbst auch einem Verlauf der mindestens einen Betriebsgröße entsprechend kann, wobei aus dem Verlauf der mindestens einen Belastungsgröße ein Verlauf der mindestens einen Betriebsgröße mithilfe eines geeigneten Modells generiert wird. Das Nutzungsmuster kann somit Arten der Belastung des Energiespeichers mithilfe des Verlaufs der mindestens einen Belastungsgröße angeben. Die Belastungsgröße kann bei einer Gerätebatterie als Energiespeicher zumindest eine Strombelastung angeben. Eine weitere Belastungsgröße bei einer Gerätebatterie als Energiespeicher kann einer Temperatur der Gerätebatterie entsprechen.

[0024] Es kann vorgesehen sein, dass das nutzerindividuell der nutzungsindividuell vorgegebene Nutzungsmuster zur Erstellung von prädizierten Zeitreihen der mindestens einen Belastungsgröße verwendet wird, um insbesondere mithilfe des Alterungszustandsmodells einen Alterungszustand oder einen Verlauf des Alterungszustands zu prädizieren.

[0025] Das Nutzungsmuster ergibt sich aus den Modellparametern eines Nutzungsmustermodells, das vorzugsweise datenbasiert ausgebildet ist, insbesondere als rekurrentes neuronales Netz, wie z.B. ein Bayes'sches LSTM (LSTM: Long Short Term Memory). Dieses wird trainiert, indem eine kalendarische Zeitangabe den Belastungsgrößenverläufen bzw. den Betriebsgrößenverläufen zugeordnet wird. Das Nutzungsmustermodell ordnet dann einem zeitlichen Verlauf der kalendarischen Zeitangabe einen entsprechenden Verlauf der mindestens einen Belastungsgröße bzw. der mindestens einen Betriebsgröße zu bzw. generiert diese, vorzugsweise kontinuierlich als Zeitreihe, bei entsprechender Vorgabe der kalendarischen Zeitangabe. Die kalendarische Zeitangabe kann das Kalenderdatum und eine Uhrzeit angeben und daraus abzuleitende Informationen, wie Wochentag, Jahreszeit bzw. Monat und dergleichen.

[0026] Es wird also ausgehend von einem aktuellen Alterungszustand der betrachteten Gerätebatterie basierend auf aus dem aktuellen Nutzungsmuster erstellten künstlichen Verläufen mindestens einer Belastungsgröße und/oder mindestens einer Betriebsgröße der Alterungszustandsverlauf in die Zukunft fortgeschrieben. Es ergibt sich der prädizierte Alterungszustandsverlauf, aus dem beispielsweise eine voraussichtliche Lebensdauer bestimmt werden kann, insbesondere in Form eines Zeitpunkts, an dem der prädizierte Alterungszustand einen vorgegebenen Schwellenwert, der das Lebensdauerende angibt, unterschreitet.

[0027] Es kann vorgesehen sein, dass der elektrische Energiespeicher abhängig von dem Verlauf des prädizierten modellierten Alterungszustands betrieben wird, wobei insbesondere eine Restlebensdauer des elektrischen Energiespeichers abhängig von dem Verlauf des prädizierten modellierten Alterungszustand signalisiert wird. Weiterhin kann vorgesehen sein, dass je nach Restlebensdauer die Anzahl der verbleibenden Schnell-Lade-Zyklen erhöht oder verringert werden oder eine Anpassung der Betriebsgrenzen (Strom-Begrenzung) oder Betriebs-Strategie (De-Rating) erfolgt. Weiterhin kann eine alterungsabhängige bzw. eine von einem prädizierten Alterungszustandsverlauf abhängige Anpassung der Ladestrategie erfolgen. Dazu können Schnell-Lade-Zyklen zugelassen oder blockiert werden, je nachdem, ob die Anzahl der verbleibenden Schnell-Lade-Zyklen erreicht worden ist.

[0028] Insbesondere kann zur Bestimmung des prädizierten Verlaufs des Alterungszustands das Alterungszustandsmodell mit einem gesamten Verlauf der mindestens einer Betriebsgröße beaufschlagt werden, der den bisherigen Verlauf der mindestens einen Betriebsgröße bis zu dem aktuellen Auswertungszeitraum und den künstlichen Verlauf der mindestens einen Betriebsgröße ausgehend von dem aktuellen Auswertungszeitraum in die Zukunft umfasst.

[0029] Ein wesentliches Kriterium für die Qualität der Prädiktion des Alterungszustands besteht in der Genauigkeit und Zuverlässigkeit des durch das Nutzungsmustermodell bereitgestellten Verlaufs der mindestens einen Belastungsgröße und/oder der mindestens einen Betriebsgröße. Um diese basierend auf dem

Nutzungsmustermodell zu bewerten, wird die Übereinstimmung eines von dem Nutzungsmustermodell generierten Verlaufs der mindestens einen Betriebsgröße mit einem tatsächlichen Verlauf der mindestens einen Betriebsgröße vorgenommen, welche im Realbetrieb beobachtbar ist. Unter der Annahme, dass die Unsicherheit der Vorhersage vom Verlauf der mindestens einen Betriebsgröße bei einem individuellen Gerät unverändert bleibt, kann nun ein auf dem künstlich generierten Verlauf der mindestens einen Betriebsgröße durch das Nutzungsmustermodell bestimmter prädizierter Alterungszustandsverlauf hinsichtlich seiner Zuverlässigkeit bewertet werden. Dies ist insbesondere wichtig, um die Zuverlässigkeit einer Vorhersage einer Restlebensdauer des Energiespeichers vornehmen zu können. Insbesondere ermöglicht die Unsicherheit des prognostizierten Verlaufs der mindestens einen Betriebsgröße, einen Restlebensdauerbereich entsprechend der Unsicherheit anzugeben.

[0030] Gemäß einer Ausführungsform kann die Konfidenz des Nutzungsmustermodells durch Vergleich eines Zeitabschnitts eines tatsächlichen Verlaufs der mindestens einen Betriebsgröße mit dem einen oder den mehreren prädizierten Verläufen der mindestens einen Betriebsgröße für den entsprechenden Zeitabschnitt Zeitraum ermittelt werden, wobei insbesondere der eine oder die mehreren prädizierten Verläufe der mindestens einen Betriebsgröße für jeweils einen konstanten Prognosehorizont durchgeführt wird.

[0031] Insbesondere kann der eine oder die mehreren prädizierten Verläufe der mindestens einen Betriebsgröße jeweils durch Werte der mindestens einen Betriebsgröße zu Prognosezielzeitpunkten gebildet werden, die basierend auf einem Nutzungsmustermodell ermittelt werden, das mit einem tatsächlichen Verlauf der mindestens einen Betriebsgröße bis zu einem entsprechenden Prognosestartzeitpunkt trainiert ist, wobei die Prognosestartzeitpunkte um den entsprechenden konstanten Prognosehorizont vor den entsprechenden Prognosezielzeitpunkten liegen.

[0032] Weiterhin kann die Konfidenz der Ausgabe des Nutzungsmustermodells abhängig von einer Wahrscheinlichkeitsdichtefunktion der Abweichungen des tatsächlichen Verlaufs der mindestens einen Betriebsgröße, welche typischerweise eine Batterietemperatur und/oder einen Batteriestrom als Zeitreihe umfasst, und eines des einen oder der mehreren prädizierten Verläufe der mindestens einen Betriebsgröße für den gleichen Zeitraum bestimmt werden, insbesondere als Residuum bzw. der dazugehörigen Wahrscheinlichkeitsdichtefunktion, welche die Konfidenz charakterisiert..

[0033] Insbesondere kann die Konfidenz des Nutzungsmustermodells als Verlauf der Abweichungen abhängig vom tatsächlichen Verlauf der mindestens einen Betriebsgröße und den mehreren prädizierten Verläufen der mindestens einen Betriebsgröße für den gleichen Zeitraum für verschiedene konstante Prognosehorizonte bestimmt werden, wobei die Abweichungen zwischen den konstanten Prognosehorizonten interpoliert werden, um den Verlauf der Abweichung bzw. der Unsicherheit abhängig von dem Prognosezeitpunkt des zu prädizierenden Werts des Alterungszustands zu erhalten.

[0034] Es kann vorgesehen sein, dass das Konfidenzintervall basierend auf der erlernten Wahrscheinlichkeitsdichtefunktion, welche einem konstanten Prognosehorizont zugeordnet werden kann, für den prädizierten Verlauf des Alterungszustands durch Konfidenzintervallgrenzen angegeben wird, die sich aus Grenzalterungszustandsverläufen ergeben, wobei die Grenzalterungszustandsverläufe sich aus Alterungszustandsverläufen für die minimale und die maximale Belastung des Energiespeichers ergeben, die durch Beaufschlagen des prädizierten Verlaufs der mindestens einen Betriebsgröße mit den Verläufen der maximalen Abweichungen erhalten werden und die jeweils die von der nominalen Alterungszustandstrajektorie am weitesten beabstandet sind, wobei die so erhaltenen Alterungszustandsverläufe für die minimale und die maximale Belastung des Energiespeichers mit der Modellunsicherheit des datenbasierten Alterungszustandsmodells beaufschlagt werden, um die Grenzalterungszustandsverläufe zu erhalten. Alternativ kann ein stochastisches Sampling nach einem Monte-Carlo-Ansatz aus der erlernten statistischen Verteilung bzw. von definierten Quantilen erfolgen.

[0035] Durch Kombination mit dem hybriden Alterungsmodell ist es möglich, die Prädiktionskonfidenzen separat zu ermitteln. Dazu wird die Modellunsicherheit des Alterungszustandsmodell, die sich direkt aus dem Korrekturmodell (Gaußprozessmodell) ergibt, und weiterhin die fahrerindividuelle Konfidenz des Nutzungsmustermodells bestimmt, welche davon abhängig ist, wie deterministisch bzw. stochastisch sich die Fahrerin oder der Fahrer verhält. Die Konfidenz des Nutzungsmustermodells gibt die Zuverlässigkeit der aus dem Nutzungsmustermodell resultierenden prädizierten Verläufe der mindestens einen Belastungsgröße und/oder der mindestens einen Betriebsgröße an.

[0036] Es kann vorgesehen sein, dass das technische Gerät und insbesondere der elektrische Energiespeicher abhängig von dem Verlauf des prädierten modellierten Alterungszustands und abhängig von dem Konfidenzintervall betrieben wird, wobei insbesondere eine Restlebensdauer des elektrischen Energiespeichers abhängig von dem Verlauf des prädierten modellierten Alterungszustand signalisiert wird und/oder ein Bereich der möglichen Restlebensdauer abhängig von dem Verlauf des prädierten modellierten Alterungszustand und des Konfidenzintervalls signalisiert wird, wobei insbesondere abhängig von dem Bereich der möglichen Restlebensdauer der Energiespeicher die Anzahl der verbleibenden, zugelassenen Schnell-Lade-Zyklen erhöht oder verringert wird oder Strom- und De-Rating-Grenzen für den Betrieb des Energiespeichers optimiert werden.

[0037] Weiterhin können abhängig von der Konfidenz des Nutzungsmustermodells prädiktive Wartungsintervalle angepasst werden. Z.B. können bei einer Fahrzeugbatterie als Energiespeichers eines Fahrzeugs als technisches Gerät das Wartungsintervall auf z.B. 2 Jahre anstatt auf 1.5 Jahre festgelegt werden, wenn die Konfidenz des Nutzungsmustermodells gering ist und so ein gute Prädiktion des Alterungszustands ermöglicht.

[0038] Der Energiespeicher kann zum Betrieb eines Geräts, wie einem Kraftfahrzeug, einem Pedelec, einem Fluggerät, insbesondere einer Drohne, einer Werkzeugmaschine, einem Gerät der Unterhaltungselektronik, wie ein Mobiltelefon, einem autonomen Roboter und/oder einem Haushaltsgerät verwendet werden.

[0039] Gemäß einem weiteren Aspekt ist eine Vorrichtung zur Prädiktion eines modellierten Alterungszustands eines elektrischen Energiespeichers mit mindestens einer elektrochemischen Einheit, insbesondere einer Batteriezelle, in einem technischen Gerät vorgesehen; wobei die Vorrichtung ausgebildet ist zum:

- Bereitstellen eines datenbasierten Alterungszustandsmodells, das ausgebildet ist, um abhängig von einem Verlauf mindestens einer Betriebsgröße des Energiespeichers bis zu einem Zeitpunkt dem elektrochemischen Energiespeicher einen entsprechenden Alterungszustand für den Zeitpunkt zuzuordnen und eine entsprechende Modellierungsunsicherheit anzugeben,
- Prädiieren eines Verlaufs für die mindestens eine Betriebsgröße ausgehend von einem aktuellen Zeitpunkt in die Zukunft abhängig von einem Nutzungsmustermodell, das durch ein nutzer- oder nutzungsindividuelles Nutzungsmuster bestimmt ist,
- Prädiieren eines Verlaufs des Alterungszustands mithilfe des datenbasierten Alterungszustandsmodells abhängig von dem modellbasiert generierten prädierten Verlauf der mindestens einen Betriebsgröße;
- Bestimmen eines Konfidenzintervalls für den prädierten Verlauf des Alterungszustands abhängig von der Modellierungsunsicherheit des datenbasierten Alterungszustandsmodells und einer Konfidenz des Nutzungsmustermodells;
- Signalisieren des prädierten Verlaufs des Alterungszustands und des entsprechenden Konfidenzintervalls.

Figurenliste

[0040] Ausführungsformen werden nachfolgend anhand der beigefügten Zeichnungen näher erläutert. Es zeigen:

Fig. 1 eine schematische Darstellung eines Systems zur Bereitstellung von fahrer- und fahrzeugindividuellen Betriebsgrößen zur Bestimmung eines Alterungszustands einer Fahrzeugbatterie in einer Zentraleinheit;

Fig. 2 eine schematische Darstellung eines funktionalen Aufbaus eines hybriden Alterungszustandsmodells;

Fig. 3 ein Flussdiagramm zur Darstellung eines Verfahrens zum Trainieren eines datenbasierten Alterungszustandsmodells;

Fig. 4 eine schematische Darstellung eines funktionalen Aufbaus eines hybriden Alterungszustandsmodells mit nutzungsabhängiger Prädiktion des Alterungszustands;

Fig. 5 ein Flussdiagramm zur Veranschaulichung eines Verfahrens zum Ermitteln eines prädierten Verlaufs eines Alterungszustands einer Fahrzeugbatterie als Energiespeicher;

Fig. 6 eine Darstellung eines beispielhaften, schematischen Verlaufs der Batterietemperatur als eine betrachtete Betriebsgröße;

Fig. 7 ein Diagramm eines beispielhaften, schematischen Verlaufs der Batterietemperatur als die betrachtete Betriebsgröße für einen zurückliegenden Betrachtungszeitraum mit einem durch das Nutzungsmustermodell prädizierten Verlauf der Batterietemperatur und mit Zeitabschnitten eines tatsächlichen Verlaufs der Batterietemperatur;

Fig. 8 ein Diagramm von beispielhaften, prädizierten, schematischen Verläufen der betrachteten Betriebsgröße für zwei verschiedene Prognosehorizonte;

Fig. 9 ein Histogramm zur Darstellung eines Fehlerresiduums für einen konstanten 5-Tage-Prognosehorizont bezüglich der Batterietemperatur als betrachtete Betriebsgröße; und

Fig. 10 ein Diagramm zur Darstellung von prädizierten Verläufen des Grenzalterungszustands und der prädizierten Verläufe der Alterungszustände für die minimale und maximale Belastung der Fahrzeugbatterie zur Darstellung der Konfidenzintervalle.

Beschreibung von Ausführungsformen

[0041] Im Folgenden wird das erfindungsgemäße Verfahren anhand von Fahrzeugbatterien als elektrische Energiespeicher in einer Vielzahl von Kraftfahrzeugen als gleichartige Geräte beschrieben. In den Kraftfahrzeugen kann in einer Steuereinheit ein datenbasiertes Alterungszustandsmodell für die jeweilige Fahrzeugbatterie implementiert sein. Das Alterungszustandsmodell kann, wie nachfolgend beschrieben, in einer fahrzeugexternen Zentraleinheit kontinuierlich basierend auf Betriebsgrößen der Fahrzeugbatterien aus der Fahrzeugflotte aktualisiert bzw. nachtrainiert werden. Das Alterungszustandsmodell wird in der Zentraleinheit betrieben und zur Alterungsberechnung und Alterungsprädiktion eingesetzt.

[0042] Das obige Beispiel steht stellvertretend für eine Vielzahl von stationären oder mobilen Geräten mit netzunabhängiger Energieversorgung, wie beispielsweise Fahrzeuge (Elektrofahrzeuge, Pedelecs usw.), Anlagen, Werkzeugmaschinen, Haushaltsgeräte, IOT-Geräte und dergleichen, die über eine entsprechende Kommunikationsverbindung (z. B. LAN, Internet) mit einer geräteexternen Zentraleinheit (Cloud) in Verbindung stehen.

[0043] **Fig. 1** zeigt ein System 1 zum Sammeln von Flottendaten in einer Zentraleinheit 2 zur Erstellung und zum Betrieb sowie zur Auswertung eines Alterungszustandsmodells. Das Alterungszustandsmodell dient zur Bestimmung eines Alterungszustands eines elektrischen Energiespeichers, wie z. B. einer Fahrzeugbatterie oder einer Brennstoffzelle in einem Kraftfahrzeug. **Fig. 1** zeigt eine Fahrzeugflotte 3 mit mehreren Kraftfahrzeugen 4.

[0044] Eines der Kraftfahrzeuge 4 ist in **Fig. 1** detaillierter dargestellt. Die Kraftfahrzeuge 4 weisen jeweils eine Fahrzeugbatterie 41 als wiederaufladbaren elektrischen Energiespeicher, einen elektrischen Antriebsmotor 42 und eine Steuereinheit 43 auf. Die Steuereinheit 43 ist mit einem Kommunikationsmodul 44 verbunden, das geeignet ist, Daten zwischen dem jeweiligen Kraftfahrzeug 4 und einer Zentraleinheit 2 (einer sogenannten Cloud) zu übertragen.

[0045] Die Kraftfahrzeuge 4 senden an die Zentraleinheit 2 die Betriebsgrößen F, die zumindest Größen angeben, welche den Alterungszustand der Fahrzeugbatterie 41 beeinflussen. Die Betriebsgrößen F können im Falle einer Fahrzeugbatterie einen momentanen Batteriestrom, eine momentane Batteriespannung, eine momentane Batterietemperatur und einen momentanen Ladezustand (SOC: State of Charge) angeben, sowohl auf Pack-, Modul- und / oder Zellebene. Die Betriebsgrößen F werden in einem schnellen Zeitraster von 0,1 Hz bis 100 Hz erfasst und können in unkomprimierter und/oder komprimierter Form regelmäßig an die Zentraleinheit 2 übertragen werden. Beispielsweise können die Zeitreihen unter Ausnutzung von Kompressions-Algorithmen zwecks Minimierung des Datenverkehrs zur Zentraleinheit 2 im Abstand von 10 min bis zu mehreren Stunden blockweise an die Zentraleinheit 2 übertragen werden.

[0046] Die Zentraleinheit 2 weist eine Datenverarbeitungseinheit 21, in der das nachfolgend beschriebene Verfahren ausgeführt werden kann, und eine Datenbank 22 zum Speichern von Datenpunkten, Modellparametern, Zuständen und dergleichen auf.

[0047] In der Zentraleinheit 2 ist ein Alterungszustandsmodell implementiert, das als hybrides Modell teilweise datenbasiert ist. Das Alterungszustandsmodell kann regelmäßig, d. h. z.B. nach Ablauf der jeweiligen

Auswertungszeitdauer, verwendet werden, um basierend auf den zeitlichen Verläufen der Betriebsgrößen (jeweils seit Inbetriebnahme der jeweiligen Fahrzeugbatterie) und daraus ermittelten Betriebsmerkmalen eine Ermittlung des momentanen Alterungszustands der betreffenden Fahrzeugbatterie 41 der zugeordneten Fahrzeugflotte vorzunehmen. Mit anderen Worten ist es möglich, basierend auf den Verläufen der Betriebsgrößen von einer der Fahrzeugbatterien 41 der Kraftfahrzeuge 4 der zugeordneten Fahrzeugflotte 3 und den Betriebsmerkmalen, die sich aus diesen Verläufen der Betriebsgrößen ergeben, einen Alterungszustand der betreffenden Fahrzeugbatterie 41 zu ermitteln.

[0048] Der Alterungszustand (SOH: State of Health) ist die Schlüsselgröße zur Angabe einer verbleibenden Batteriekapazität oder verbleibenden Batterieladung. Der Alterungszustand stellt ein Maß für die Alterung der Fahrzeugbatterie oder eines Batterie-Moduls oder einer Batterie-Zelle dar und kann als Kapazitätserhaltungsrate (Capacity Retention Rate, SOH-C) oder als Anstieg des Innenwiderstands (SOH-R) angegeben werden. Die Kapazitätserhaltungsrate SOH-C ist als Verhältnis der gemessenen momentanen Kapazität zu einer Anfangskapazität der vollständig aufgeladenen Batterie angegeben. Die relative Änderung des Innenwiderstands SOH-R steigt mit zunehmender Alterung der Batterie an.

[0049] Fig. 2 zeigt beispielhaft schematisch den funktionalen Aufbau einer Ausführungsform eines datenbasierten Alterungszustandsmodells 9, das in einer hybriden Weise aufgebaut ist. Das Alterungszustandsmodell 9 umfasst ein physikalisches Alterungsmodell 5 und ein Korrekturmodell 6.

[0050] Bei dem physikalischen Alterungsmodell 5 handelt es sich um ein nichtlineares, mathematisches Modell, das auf Differenzialgleichungen basiert. Das Auswerten des physikalischen Alterungsmodells des Alterungszustandsmodells mit Betriebsgrößenverläufen, insbesondere seit Lebensdauerbeginn der Gerätebatterie, führt dazu, dass sich ein interner Zustand des Gleichungssystems der physikalischen Differenzialgleichungen einstellt, der einem physikalischen internen Zustand der Gerätebatterie entspricht. Da das physikalische Alterungsmodell auf physikalischen und elektrochemischen Gesetzmäßigkeiten basiert, sind die Modellparameter des physikalischen Alterungsmodells Größen, die physikalische Eigenschaften angeben.

[0051] Die Zeitreihen der Betriebsgrößen F gehen also direkt in das physikalische Alterungszustandsmodell 5 ein, welches vorzugsweise als elektrochemisches Modell ausgeführt ist und entsprechende interne elektrochemische Zustände, wie Schichtdicken (z.B. SEI-Dicke), Änderung des zyklisierbaren Lithiums aufgrund von Anode/Kathode-Nebenreaktionen, schneller Verbrauch von Elektrolyten, langsamer Verbrauch von Elektrolyten, Verlust des Aktivmaterials in Anode, Verlust des Aktivmaterials in Kathode, etc....), mithilfe von nichtlinearen Differentialgleichungen und einem mehrdimensionalen Zustandsvektor beschreibt.

[0052] Das physikalische Alterungsmodell 5 entspricht somit einem elektrochemischen Modell der Batteriezellen und der Zellchemie. Dieses Modell ermittelt abhängig von den Betriebsgrößen F interne physikalische Batteriezustände, um einen physikalisch basierten Alterungszustand SOH_{ph} der Dimension von mindestens eins in Form der oben genannten elektrochemischen Zustände, welche linear oder nichtlinear auf eine Kapazitätserhaltungsrate (SOH-C) und/oder eine Innenwiderstandsanstiegsrate (SOH-R) abgebildet werden, um diese als Alterungszustand (SOH-C und SOH-R) bereitzustellen.

[0053] Die durch das elektrochemische Modell bereitgestellten Modellwerte für den physikalischen Alterungszustand SOH_{ph} sind jedoch in bestimmten Situationen ungenau, und es ist daher vorgesehen, diese mit einer Korrekturgröße k zu korrigieren. Die Korrekturgröße k wird von dem datenbasierten Korrekturmodell 6 bereitgestellt, das mithilfe von Trainingsdatensätzen aus den Fahrzeugen 4 der Fahrzeugflotte 3 und / oder mithilfe von Labordaten trainiert wird.

[0054] Das Korrekturmodell 6 erhält eingangsseitig Betriebsmerkmale M, die aus den Verläufen der Betriebsgrößen F ermittelt und auch einen oder mehrere der internen elektrochemischen Zustände des Differentialgleichungssystems des physikalischen Modells umfassen können. Weiterhin kann das Korrekturmodell 6 eingangsseitig den aus dem physikalischen Alterungsmodell 5 erhaltenen physikalischen Alterungszustand SOH_{ph} erhalten. Die Betriebsmerkmale M des aktuellen Auswertungszeitraums werden in einem Merkmalsextraktionsblock 8 basierend auf den Zeitreihen der Betriebsgrößen F erzeugt. Zu den Betriebsmerkmalen M zählen weiterhin die inneren Zustände aus dem Zustandsvektor den elektrochemischen physikalischen Alterungsmodells sowie vorteilhafterweise der physikalische Alterungszustand SOH_{ph}.

[0055] Aus den Betriebsgrößen F können in der Zentraleinheit 2 für jede Fahrzeugflotte 3 oder in anderen Ausführungsformen auch bereits in den jeweiligen Kraftfahrzeugen 4 Betriebsmerkmale M generiert werden, die sich auf einen Auswertungszeitraum beziehen. Der Auswertungszeitraum kann für die Bestimmung des

Alterungszustands wenige Stunden (z. B. 6 Stunden) bis mehrere Wochen (z. B. einen Monat) betragen. Ein üblicher Wert für den Auswertungszeitraum beträgt eine Woche.

[0056] Die Betriebsmerkmale M können beispielsweise auf den Auswertungszeitraum bezogene Merkmale und/oder akkumulierte Merkmale und/oder über die gesamte bisherige Lebensdauer ermittelte statistische Größen umfassen. Insbesondere können die Betriebsmerkmale beispielsweise umfassen: Elektrochemische Zustände, wie z.B. SEI-Schichtdicke, Änderung von zyklisierbarem Lithium aufgrund von Anoden/Kathoden-Nebenreaktionen, schnelle Aufnahme von Elektrolytlösungsmittel, langsame Aufnahme von Elektrolytlösungsmitteln, Lithiumabscheidung, Verlust von aktivem Anodenmaterial und Verlust von aktivem Kathodenmaterial, Informationen zu Impedanzen bzw. den Innenwiderständen, Histogrammmerkmale, wie Temperatur über Ladezustand, Ladestrom über Temperatur und Entladestrom über Temperatur, insbesondere mehrdimensionale Histogramm Daten bezüglich der Batterietemperaturverteilung über dem Ladezustand, der Ladestromverteilung über der Temperatur und/oder der Entladestromverteilung über der Temperatur, den Stromdurchsatz in Amperestunden, die akkumulierte Gesamtladung (Ah), eine durchschnittliche Kapazitätzunahme bei einem Ladevorgang (insbesondere für Ladevorgänge, bei denen die Ladungszunahme über einem Schwellenanteil [z. B. 20 % Δ SOC] der gesamten Batteriekapazität liegt), die Ladekapazität sowie ein Extremwert (z.B. Maximum) der differentiellen Kapazität während eines gemessenen Ladevorgangs mit ausreichend großem Hub des Ladezustands (geglätteter Verlauf von dQ/dU : Ladungsänderung dividiert durch Änderung der Batteriespannung) oder die akkumulierte Fahrleistung. Diese Größen werden vorzugsweise so umgerechnet, dass sie das reale Nutzungsverhalten bestmöglich charakterisieren und im Merkmalsraum normiert. Die Betriebsmerkmale M können insgesamt oder nur teilweise für das nachfolgend beschriebene Verfahren verwendet werden.

[0057] Für die Bestimmung eines korrigierten auszugebenden Alterungszustands SOH werden die Ausgänge SOH_{ph}, k des physikalischen Alterungsmodells 5 und des datenbasierten Korrekturmodells 6, welches vorzugsweise als Gauß-Prozess-Modell ausgeführt ist, miteinander beaufschlagt. Insbesondere können diese in einem Summierblock 7 addiert oder ansonsten auch multipliziert (nicht gezeigt) werden, um den auszugebenden modellierten Alterungszustand SOH zu einem aktuellen Auswertungszeitraum zu erhalten. Die Konfidenz des Gaußprozesses kann im Additions-Fall weiterhin als Konfidenz des auszugebenden korrigierten Alterungswert SOH des hybriden Modells verwendet werden. Die Konfidenz des Gaußprozessmodells charakterisiert somit die Modellierungs-Unsicherheit der Abbildung von Betriebsmerkmalspunkten bzw. von Hauptkomponenten (bei Verwendung von PCA) auf einen Alterungszustand.

[0058] Für die Skalierung und die Dimensionsreduzierung der Betriebsmerkmale kann ggfs. eine PCA (Principal Components Analysis) verwendet werden, um redundante linear-abhängige Information im Merkmalsraum entsprechend vordem Trainieren des Korrekturmodells (unsupervised) zu reduzieren. Alternativ kann auch eine Kernel-PCA verwendet werden, um in der Komplexitätsreduktion der Daten auch nichtlineare Effekte abzubilden zu können. Sowohl vor der Dimensionsreduzierung und speziell danach findet eine Normalisierung des gesamten Betriebsmerkmalsraums (bzw. des Hauptkomponenten-Raums) statt, z.B. mit Min/Max-Scaling oder der Z-Transformation.

[0059] Die Berechnung des Alterungszustands und die Prädiktion des Alterungszustands sind daher möglich für Energiespeicher mit mindestens einer elektrochemischen Einheit, z.B. einer Batterie-Zelle. Das Verfahren ist durch regel- und / oder datenbasierte Abbildung auch auf das Gesamtsystem des Energiespeichers anwendbar. Am Beispiel der Batterie kann die Alterungsprädiktion neben Zellebene somit direkt auch auf Modulebene und Packebene angewandt werden. Weiterhin oder alternativ kann die schwächste Zelle in einem Energiespeicher-System auch als limitierende Komponente für das den Batterie-Pack angenommen werden.

[0060] Fig. 3 zeigt ein Flussdiagramm zur Veranschaulichung eines beispielhaften Verfahrens zum Trainieren des hybriden Alterungszustandsmodells in der Zentraleinheit 2. Dazu werden Trainingsdatensätze definiert, die Verläufe von Betriebsgrößen einem empirisch ermittelten Alterungszustand als Label zuordnen.

[0061] Die Ermittlung eines Alterungszustands als Label kann in an sich bekannter Weise durch Auswertung der Betriebsgrößenverläufe mit einem zusätzlichen Modell in dem Fahrzeug oder in der Zentraleinheit 2 unter definierten Last- und Umgebungsbedingungen einer Labelerzeugung erfolgen, wie z.B. in einer Werkstatt, auf einem Prüfstand oder einem Diagnose- oder Labelerzeugungsmodus, der ein Betriebsmodus darstellt und das Einhalten vorbestimmter Betriebsbedingungen der Fahrzeugbatterie, wie z.B. konstante Temperatur, konstanter Strom und der gleichen garantiert. Dazu kann können andere Modelle zur Ermittlung des Alter-

ungszustands genutzt werden, z.B. basierend auf der Analyse einer erkannten Lade- und / oder Entladephase der Batterienutzung.

[0062] Vorzugweise wird eine SOH-C-Messung durch Coulomb-Counting bzw. durch Bildung eines zeitlichen Stromintegrals während des Ladevorgangs vorgenommen, welches durch den Hub des Ladezustands zwischen Beginn und Ende der betreffenden Lade- und / oder Entladephase dividiert wird. Vorteilhafterweise erfolgt hierbei die Kalibrierung an der Leerlaufspannungskennlinie in Ruhephasen, um den Ladezustandsverlauf in der Zentraleinheit mitzuberechnen. Eine hinreichend zuverlässige Angabe über den Alterungszustand zur Nutzung als Label kann man beispielsweise erhalten, wenn die Fahrzeugbatterie während eines Ladevorgangs aus einem definierten relaxierten Zustand unter reproduzierbaren Last- und Umgebungsbedingungen von einem vollständig entladenen Lade-Zustand in einen vollständig geladenen Zustand gebracht wird. Die dadurch erfasste maximale Ladung kann zu einer initialen maximalen Ladekapazität der Fahrzeugbatterie in Beziehung gesetzt werden. Widerstandsbezogene Alterungszustände (SOH-R-Werte) können auch durch Spannungsänderungen bezogen auf eine Stromänderung errechnet werden. Üblicherweise sind diese auf ein definiertes Zeitintervall sowie definierte Umgebungsbedingungen und die Energiefluss-Richtung des Systems bezogen.

[0063] Ein Trainingsdatensatz für eine Fahrzeugbatterie ergibt sich somit aus dem jeweils zu einem Zeitpunkt ermittelten Alterungszustand und den Betriebsgrößenverläufen für die betreffende Fahrzeugbatterie von dem Inbetriebnahmezeitpunkt der betreffenden Fahrzeugbatterie bis zu diesem Zeitpunkt. Für eine Fahrzeugbatterie können mehrere Trainingsdatensätze zu verschiedenen Zeitpunkten ermittelt werden, wobei die Zeitpunkte relativ zu dem Inbetriebnahmezeitpunkt (Lebensdauerbeginn) angegeben werden können. Die Trainingsdatensätze werden für die Vielzahl von Fahrzeugen gesammelt und bereitgestellt.

[0064] Das Alterungszustandsmodell kann in herkömmlicher Weise mit den Trainingsdatensätzen trainiert werden. Hierzu ist vorgesehen, dass das Training des Korrekturmodells 6 auf das Residuum des physikalischen Modells erfolgt, sodass der das Korrekturmodell entsprechend datengetriebene Korrekturen genau dort vornehmen kann, wo es die Datenlage mit hinreichender Konfidenz erlaubt. Die Trainingsdatensätze stellen dann die Trainingsmenge dar.

[0065] Das Training kann erfolgen, indem die Trainingsdatensätze in eine Trainingsmenge und eine Testmenge unterteilt werden. Die Trainingsmenge dient zum Trainieren des hybriden Alterungszustandsmodells, während die Testmenge zur Validierung des hybriden Alterungszustandsmodells mithilfe neuer, nicht für das Training verwendeter, unbekannter Daten der Testmenge dient. Vorzugsweise kann ein dritter Datensatz, der Validierungs-Datensatz verwendet werden, um die Hyperparameter des Korrekturmodells zu optimieren.

[0066] In Schritt S1 wird das physikalische Alterungsmodell 5 abhängig von einem ersten Teil der Trainingsmenge parametrisiert, insbesondere durch Parameteroptimierung mithilfe der Kleinste-Quadrate-Methode oder dergleichen. Der physikalische Alterungszustand SOH_{ph} als Ausgang des physikalischen Alterungsmodells 5 wird dabei als der Alterungszustand des jeweiligen Trainingsdatensatzes angenommen.

[0067] In Schritt S2 wird das physikalische Alterungsmodell auf die gesamte Trainingsmenge des hybriden Modells angewendet, d. h. eine Anzahl von Trainingsdatensätzen, die mindestens die Menge an Trainingsdatensätzen, mit der das physikalische Alterungsmodell parametrisiert worden ist, umfasst oder sogar über sie hinausgeht. Der Fehler des physikalischen Alterungsmodells 5 wird entsprechend in einem Gesamtfehler bzgl. des Residuums als Histogramm der Modellabweichung evaluiert. Dieses Residuum in enthält in Kombination mit den Betriebsmerkmalen M bzw. den Betriebsgrößen F alle relevanten Informationen bezüglich der systematischen Schwächen des physikalischen Alterungsmodells 5. Auch ergibt sich die Information, wie sich das physikalische Alterungsmodell 5 bezüglich neuer nicht für die Parametrisierung des physikalischen Alterungsmodells 5 genutzte Trainingsdatensätze verhält, d.h. wie es generalisiert.

[0068] In einem nächsten Schritt S3 wird das datenbasierte Korrekturmodell 6 auf die vollständige Trainingsmenge des hybriden Alterungszustandsmodells 9 trainiert. Diese Trainingsmenge des hybriden Modells umfasst mindestens die Trainingsmenge des physikalischen Modells entsprechend Schritt S1. Für das Training des Korrekturmodells 6 werden sowohl die Betriebsmerkmale M aus den Betriebsgrößen F extrahiert als auch die internen Zustände des physikalischen Alterungsmodells 5 als eine Teilmenge von M verwendet, um sämtliche Betriebsmerkmale auf einen Fehler zwischen der Modellvorhersage (physikalischen Alterungszustand) des physikalischen Alterungsmodells und dem gelabelten Alterungszustand entsprechend des Trainingsdatensatzes abzubilden. Weiterhin kann M auch den modellierten physikalischen Alterungszustand SOH_{ph} umfassen. Dadurch kann das Korrekturmodell 6 die Schwächen des physikalischen Alterungsmodells

5 lernen, um so in dem Korrekturblock eine Korrektur des physikalischen Alterungszustands vornehmen zu können.

[0069] Das Trainieren des datenbasierten Korrekturmodells 6 kann mit Cross-Validierung und sequenziellem Bagging (Bootstrap Aggregating) durchgeführt werden, um die Robustheit und Genauigkeit zu verbessern. Wenn das Korrekturmodell trainiert ist, kann das trainierte hybride Alterungszustandsmodell mithilfe der Testmenge in Schritt S4 validiert werden, so dass die Gesamt-Performance für die Alterungszustandsberechnung validiert werden kann.

[0070] Das trainierte hybride Alterungszustandsmodell kann nun für die Ermittlung des Alterungszustands basierend auf den zeitlichen Verläufen von Betriebsgrößen F einer Fahrzeugbatterie seit Lebensdauerbeginn genutzt werden.

[0071] Das Training des hybriden Alterungszustandsmodells kann immer dann angestoßen werden, wenn neue gelabelte Trainingsdatensätze verfügbar sind, speziell, wenn sie neue und relevante Informationen beinhalten. Beim Betrieb in einer Zentraleinheit 2 basierend auf Flottendaten ist somit ein ständiges Nachtrainieren des hybriden Alterungszustandsmodells zur Ermittlung des aktuellen Alterungszustands einer Fahrzeugbatterie und zur Verwendung bei einer Prädiktion des Alterungszustands möglich.

[0072] Das Ermitteln der Trainingsdaten kann mithilfe von „Representative Active Learning“ durchgeführt werden, wobei Trainingsdaten bezüglich Betriebsmerkmalspunkten (Kombination von Betriebsmerkmalen) ermittelt werden, für das Korrekturmodell eine hohe Unsicherheit aufweist. Insbesondere können die Geräte der Gerätegruppe ausgewählt werden, deren Betriebsmerkmalspunkte hohe Modellierungsunsicherheit und gleichzeitig eine hohe Relevanz für die bestehende Fahrzeugflotte 3 aufweisen, sodass von einer Label-Generierung und anschließendem Modell-Training eine möglichst hohe Anzahl von Fahrzeugen 4 der betreffenden Fahrzeugflotte 3 profitieren.

[0073] Fig. 4 beruht auf dem hybriden Alterungszustandsmodell der Fig. 2. Zur Prädiktion eines zukünftigen Alterungszustandsverlaufs wird ein Dynamikmodell 9 verwendet, um zeitliche Verläufe von Betriebsgrößen, wie der Batteriespannung U und dem Ladezustand SOC, auf Basis eines Verlaufs mindestens einer Belastungsgröße L , wie z.B. dem Verlauf des Batteriestroms I und der Batterietemperatur T , zu generieren und alle diese Betriebsgrößen insgesamt, nämlich die zeitlichen Verläufe der Batteriespannung U , des Ladezustands SOC, des Batteriestroms I und gegebenenfalls der Batterietemperatur T , als „künstliche“ Betriebsgrößenverläufe F dem hybriden Alterungszustandsmodell 9 bereitzustellen.

[0074] Für Batterien als Energiespeicher entsprechen somit die Verläufe der erzeugten Belastungsgrößen L einem Teil der oder auch allen „künstlichen“ Betriebsgrößenverläufe. Bei anderen Typen von Energiespeichern können sich die Belastungsgrößen L von den daraus generierten Betriebsgrößen unterscheiden. Auch können in anderen Ausführungsformen die Verläufe der Betriebsgrößen vollständig den Belastungsgrößen entsprechen und damit unmittelbar von einem Nutzungsmustermodell 10, wie nachfolgend beschrieben, generiert werden.

[0075] Das Dynamikmodell 9 hat also die Aufgabe, für das hybride Alterungszustandsmodell im Prädiktionsfall generierte (nicht reale, künstlich erzeugte) Zeitreihen bzw. Verläufe von Belastungsgrößen L für die Erstellung von Betriebsgrößen und/oder als zumindest einen Teil der Betriebsgrößen F bereitzustellen, mit denen eine Prädiktion des Verlaufs des Alterungszustands durch Fortschreiben des aktuellen Alterungszustands (basierend auf den seit Lebensdauerbeginn (Inbetriebnahme) erfassten Verläufen der Betriebsgrößen) durchgeführt werden kann.

[0076] Das Dynamikmodell 9 kann verschiedenartig ausgestaltet sein, wie beispielsweise ein Ersatzschaltungsmodell, ein elektrochemisches Modell, ein Einzelpartikelmodell von Batteriezellen oder dergleichen. Das Dynamikmodell 9 kann insbesondere einem elektrochemischen Batteriemodell entsprechen, das Gleichgewichtszustände modelliert und sich in Ruhephasen an Zell-Spannungen kalibriert um einen Batteriestrom und Ladezustand aus einer Batteriespannung zu generieren. Alternativ kann das Dynamikmodell als ein Batterie-Performance-Modell zur Charakterisierung der System-Übertragungsfunktion ausgeführt sein, wobei die Nichtlinearität der Stromstärke über ein Butler-Volmer Tuning herausgerechnet wird.

[0077] Die Generierung der Betriebsgrößenverläufe aus den Verläufen der Belastungsgrößen L geschieht in Abhängigkeit des resultierenden Alterungszustands SOH der Fahrzeugbatterie 41, welche eine Aktualisierung des Dynamikmodells 9, speziell bezüglich seiner Parameter oder alternativ seiner Zustände bewirkt.

Somit ändert sich das Übertragungsverhalten des Dynamikmodells 9 in Abhängigkeit des Alterungszustand der Fahrzeugbatterie 41. Typischerweise erfolgt dieser Parameter-Update einmal pro (simuliertem) Monat während einer Simulation bzw. Prädiktion.

[0078] Die Berücksichtigung des Alterungszustand SOH erfolgt, indem entweder Parameter und/oder Zustände des Dynamikmodells 9 auf Basis des berechneten modellierten Alterungszustands SOH aktualisiert werden.

[0079] Für das Beispiel des Batterie-Performance-Modells wird die Batteriespannung aus den Zellenspannungen U_{cell} wie folgt bestimmt:

$$U_{cell} = OCV(SOC) + R1(SOH) * (U_{ohmic} + U_{ct}) + R2(SOH) * U_{diff}$$

wobei OCV der Leerlaufspannung, U_{ohmic} dem Spannungsabfall über der Batteriezelle aufgrund des ohmschen Widerstands, U_{ct} dem Spannungsabfall basierend auf dem Ladungswechselwiderstand, U_{diff} dem Spannungsabfall basierend auf dem Diffusionswiderstand, $R1(SOH)$ und $R2(SOH)$ den zu optimierenden Parametern entsprechen. Dabei wird $R1 = R_{ohmic} + R_{ct}(T, I)$ für den Hochfrequenz-Anteil und $R2$ für den Niederfrequenz-Anteil parametrisiert. R_{ct} (CT = Charge Transfer) beschreibt den nichtlinearen Anteil der Übertragungsfunktion aufgrund der nichtlinearen Abhängigkeit von der Stromstärke.

$$R_{ct}(T, I_0, I) = R_{ct0}(T) \cdot f(I(T, I_0, I))$$

I_0 entspricht dem Strom im dynamischen Gleichgewichtszustand. In diesem Betriebspunkt ist der Widerstand gemäß der Butler-Volmer-Gleichung hinreichend genau linearisierbar.

[0080] Um die Verläufe der Belastungsgrößen L für die Prädiktion des Alterungszustands zu generieren, wird das Nutzungsmustermodell 10 vorgesehen. Das Nutzungsmustermodell 10 setzt vorgegebene Nutzungsmuster N in Verläufe von Belastungsgrößen L um, die die Belastung des Energiespeichers widerspiegeln, der der Energiespeicher bei der durch das Nutzungsmuster angegebenen Nutzungs- und Betriebsweise ausgesetzt ist. Die Nutzungsmuster N führen also zu der Ausgabe eines zeitlichen Verlaufs eines Batteriestroms I und einer Batterietemperatur T als Belastungsgrößen L durch das Nutzungsmustermodell 10, mit denen mithilfe des Dynamikmodells 9 der Satz von Betriebsgrößen (F) mit den Verläufen der Batteriespannung U und des Ladezustands SOC vervollständigt wird, um die künstlich generierten Verläufe der Betriebsgrößen zu generieren.

[0081] Die Nutzungsmuster werden durch Nutzungsparameter N definiert, welche fahrzeugindividuell durch das Nutzungsmustermodell 10, vorzugsweise unter Zuhilfenahme von datenbasierten Verfahren, erlernt werden, und dienen dazu, das typische Nutzungsverhalten eines individuellen Nutzers bzw. eines durch einen Nutzer betriebenen Antriebsstrangs bezüglich der betreffenden Fahrzeugbatterie 41 zu simulieren.

[0082] Das Nutzungsmustermodell 10 kann als ein rekurrentes neuronales Netz, wie z.B. ein LSTM oder GRU ausgebildet sein, insbesondere als ein Bayes'sches LSTM-Netz, ausgebildet sein und basierend auf Verläufen von Belastungsgrößen L bzw. Betriebsgrößen F , die eine typische und repräsentative Art der Nutzung des Energiespeichers angeben, trainiert sein. Die dabei zu berücksichtigenden Verläufe von Belastungsgrößen L bzw. Betriebsgrößen F sollten auf einem Zeitraum gleicher Nutzungsart und gleicher Betriebsart der Fahrzeugbatterie 41 basieren.

[0083] Die Nutzungsparameter, die das Nutzungsmuster angeben, entsprechen dann den Modellparametern des Nutzungsmustermodells 10 und charakterisieren folglich implizite und explizite Nutzungsmuster eines Fahrers oder Nutzungsarten des Fahrzeugs, d.h. im Falle eines künstlichen neuronalen Netzes z.B. den Gewichtungen und Bias-Werten der einzelnen Neuronen. Weiterhin können Prior und Posterior-Verteilungen sowie Wahrscheinlichkeiten, die gemäß Bayes-Theorem auf Beobachtungen konditioniert wurden, als relevante Parameter berücksichtigt werden.

[0084] Die Nutzungsmuster ergeben sich durch ein Training des Nutzungsmustermodells 10 basierend auf bekannten zeitlichen Verläufen der Belastungsgrößen L und/oder der Betriebsgrößen F bezüglich ihres kalendarischen Bezugs. D.h. das Nutzungsmustermodell 10 wird eingangsseitig mit einer kalendarischen Zeitangabe und ausgangsseitig mit den Belastungsgrößen (Strom, Temperatur vorzugsweise als Zeitreihe) und/oder den Betriebsgrößen in an sich für rekurrente neuronale Netze bekannter Weise trainiert.

[0085] Das Nutzungsmustermodell 10 kann als Gesamtmodell ausgebildet sein oder für jeden zu präzisierenden Verlauf einer Belastungsgröße L ein Teilmodell aufweisen. Hierbei wird ein Teilmodell des Nutzungsmustermodells 10 auf den fahrerindividuellen zeitlichen Temperaturverlauf und ein weiteres Teilmodell des Nutzungsmustermodells 10 auf den fahrerindividuellen Stromverlauf trainiert, um diese einer kalendarischen Bezugsgröße bzw. Zeitangabe simulativ zuzuordnen und bereitstellen zu können. So kann durch Vorgabe einer kalendarischen Zeitangabe, wie des Datums und einer Uhrzeit, ein künstlicher Verlauf der Belastungsgrößen und/oder der Betriebsgrößen generiert werden. Die kalendarische Zeitangabe kann ferner den Wochentag, den Monat und die Kenntnis über Feiertage enthalten und insbesondere durch Feature Engineering Saisonalitäten berücksichtigen.

[0086] Das Nutzungsmuster-Modell kann, solange kein Fahrerwechsel erkannt wurde, regelmäßig unter Berücksichtigung neuer Daten trainiert werden, z.B. einmal pro Monat. Der Trainingsdatensatz kann in diesem Fall typischerweise Verläufe von Betriebsgrößen bzw. Belastungsgrößen seit dem letzten identifizierten Fahrerwechsel bis hin zu den neusten erfassten Betriebsgrößen bzw. Belastungsgrößen umfassen. Typischerweise wird in der Mitte dieses Abschnitts ein Zeitabschnitt aus dem Trainingsdatensatz herausgelöst, der nicht zum Training sondern zur Validierung des Nutzungsmuster-Modells genutzt wird. Typischerweise wird ein Bayes'sches LSTM-Netz für die fahrerindividuelle Charakterisierung des Stromverlaufs eingesetzt. Weiterhin wird ein Bayes'sches LSTM-Netz für die fahrerindividuelle Charakterisierung des Temperaturverlaufs eingesetzt. Alternativen zum LSTM-Ansatz stellen ARIMAX-Modelle dar.

[0087] Das Nutzungsmustermodell 10 kann so direkt aus Rohdaten der Verläufe der Belastungsgrößen L und/oder der Betriebsgrößen F ausgebildet werden. Für die Fahrzeugbatterie 41 werden somit typische Muster des Stromprofils, z.B. wegen wiederkehrenden Pendler-Strecken & typische Stand- und Ruhezeiten und Lasten zu Temperaturbereichen erkannt und reproduzierbar gemacht.

[0088] Die Nutzungsmuster N können somit implizit Arten der Belastung der Fahrzeugbatterie 41 angeben, insbesondere periodische Belastungen.

[0089] Auch kann das Nutzungsmuster N insbesondere Umgebungsbedingungen und einen periodischen Belastungsverlauf angeben. Die Umgebungsbedingungen können z.B. aus einer Klimatable abgeleitet werden, einen Verlauf der Batterietemperatur innerhalb eines Tag-Nacht-Rhythmus, für die Jahreszeiten und dergleichen angeben, vorzugsweise unter Zuhilfenahme von GPS-abhängigen Wetterdaten aus der Zentraleinheit (Cloud). Dazu kann das Nutzungsmustermodell zusätzlich zu der kalendarischen Zeitangabe mit einer Temperaturverlaufsangabe trainiert und verwendet werden. Vorzugsweise können Vorhersagen von GPS-abhängigen Temperaturverläufen in die Prädiktion der Nutzmuster eingearbeitet werden.

[0090] Die Temperaturverlaufsangabe kann sich aus einer durchschnittlichen Temperatur in einem unmittelbar zurückliegenden Zeitraum, wie z.B. einem Monat, ergeben, die mithilfe von saisonalen Schwankungen, die sich aus einer Klimatable ergeben, präzisiert werden kann. Die Klimatable kann sich aus einer Ortsangabe (Geoposition) des Fahrzeugs (Fahrzeugort: Ortsangabe der häufigsten festgestellten Fahrzeugposition) abgeleitet werden. Somit sieht das Nutzungsmustermodell eine Abbildung der kalendarischen Zeitangabe und der Temperaturverlaufsangabe auf die Verläufe der Belastungsgrößen und/oder der Betriebsgrößen als Eingangsgröße vor und ist auch entsprechend trainiert.

[0091] Zudem kann das Nutzungsmustermodell 10 abhängig von dem modellierten Alterungszustand SOH betrieben werden. Damit kann beispielsweise im Falle eines mit der Fahrzeugbatterie betriebenen Fahrzeugs berücksichtigt werden, dass ein Fahrer bei gealterter Batterie eher dreimal pro Woche laden muss, anstatt wie anfänglich nur zweimal, um seine gewünschte Strecke zurückzulegen.

[0092] Die Nutzungsmuster N werden fahrzeugindividuell trainiert und vorgegeben und charakterisieren die Art der Nutzung und des Betriebs bzw. das Nutzungs- und Betriebsverhalten der jeweiligen Fahrzeugbatterien 41.

[0093] Das Nutzungsmuster N, das in Form der Nutzungsparameter (Modellparameter) des Nutzungsmustermodells 10 vorgegeben wird, kann in Form von Gradientenverläufen von kumulativen Betriebsmerkmalen plausibilisiert werden für kumulative Größen, von denen bei gleicher Nutzungsart oder Betriebsart ein lineares Wachstum erwartet ist, wie z.B. die km-Leistung oder der Wirkungsgradnormierte AH-Durchsatz, z.B. unter Berücksichtigung des SOHR.

[0094] Die Vorhersagequalität des Nutzungsmustermodells 10 hängt in erheblichem Maße von der Verfügbarkeit von ausreichenden Trainingsdaten ab. Insbesondere bei neu in Betrieb genommenen Fahrzeugen bzw. Fahrzeugbatterien 41 liegen in der Regel noch keine Daten über Verläufe von Betriebsgrößen und Belastungsgrößen für eine ausreichende Zeitdauer vor, um das Nutzungsmustermodell 10 mit einer hinreichenden Genauigkeit in dem oben beschriebenen Trainingsverfahren zu modellieren.

[0095] Nachfolgend beschriebenes Verfahren sieht daher vor, die Modellierungsunsicherheit der Prädiktion der Verläufe der Belastungsgrößen L und/oder der Betriebsgrößen F zu erlernen und zu bewerten, um die Gesamtkonfidenz der darauf basierenden Prädiktion des Alterungszustands bzw. Ermittlung der Restlebensdauer bewerten zu können. Das Verfahren nutzt dazu die Flottendaten der Vielzahl von Fahrzeugen, um die Qualität der Prognose (Konfidenz) von Belastungsgrößen L und/oder Betriebsgrößen F zu bestimmen. Aus der fahrzeugindividuellen Prognosequalität zum Nutzungsverhalten, d.h. der Prädiktion der Verläufe der mindestens einen Belastungsgröße und/oder der mindestens einen Betriebsgröße, lässt sich statistisch eine Unsicherheit der Prädiktion der fahrerindividuellen Belastungsgrößen, umfassend z.B. Temperatur und Strom, ableiten, die verwendet wird, um die resultierende Prädiktion, einschließlich der Modellierungsunsicherheit des Alterungszustandsmodells zu bewerten, unter Berücksichtigung der Modellierungskonfidenz des Nutzungsmustermodells 10. Insbesondere kann bewertet werden, wie gut die Prognose einen bestimmten Fahrertypus abbilden und präzisieren kann. Zudem ist es möglich, eine statistisch abgesicherte Konfidenzbewertung der Prädiktion des Alterungszustands durchzuführen.

[0096] Durch Kombination mit dem hybriden Alterungszustandsmodell ist es möglich, die Prädiktionskonfidenzen aufzuspalten zwischen Modellierungsunsicherheit des Alterungszustandsmodell, welche direkt aus dem Korrekturmodell (Gaußprozessmodell) bestimmt wird, und der Konfidenz des fahrerindividuellen Nutzungsmustermodells, welche davon abhängig ist, wie deterministisch bzw. stochastisch sich der Fahrer verhält.

[0097] Das Verfahren wird in der Zentraleinheit 2 ausgeführt und nachfolgend anhand des Flussdiagramms der **Fig. 5** näher beschrieben.

[0098] In Schritt S11 findet ein herkömmlicher Betrieb der Zentraleinheit 2 statt. Im laufenden Betrieb werden dabei kontinuierlich Verläufe von Betriebsgrößen, wie beispielsweise der Batteriestrom, die Batteriespannung, der Ladezustand und die Batterietemperatur, von jedem der Fahrzeuge 4 der Fahrzeugflotte 3 an die Zentraleinheit 2 übertragen.

[0099] In Schritt S12 wird überprüft, ob für eine Fahrzeugbatterie 41 eines bestimmten Fahrzeugs 4 eine Prädiktion des Alterungszustands vorgenommen werden soll.

[0100] Ist dies der Fall (Alternative: Ja), wird das Verfahren mit Schritt S13 fortgesetzt, anderenfalls (Alternative: Nein), wird zu Schritt S11 zurückgesprungen.

[0101] Zu vorbestimmten diskreten Zeitpunkten wird eine Prädiktion des Alterungszustands basierend auf den bis dahin empfangenen Verläufen von Betriebsgrößen entsprechend dem zuvor beschriebenen hybriden Alterungszustandsmodell 9 vorgenommen, um einen Alterungszustand für den aktuellen Auswertungszeitraum bzw. den aktuellen Zeitpunkt zu ermitteln bzw. zu präzisieren. Wenn ein Verlauf des Alterungszustands prädiert werden soll, wird basierend auf dem Nutzungsmustermodell 10 für ein bestimmtes Fahrzeug fahrzeugindividuell ein Verlauf mindestens einer Belastungsgröße bzw. mindestens einer Betriebsgröße bzw. der oben genannten Betriebsgrößen, wie zuvor beschrieben, bestimmt. Beispielsweise zeigt **Fig. 6** einen möglichen Verlauf der Batterietemperatur ausgehend von einem momentanen Auswertungszeitraum T0.

[0102] In einem nachfolgenden Schritt S13 werden nun vergangene Prädiktionen, die mithilfe des Nutzungsmustermodells 10 erstellt werden können, bewertet. Dazu wird überprüft, wie eine bezüglich eines zurückliegenden Auswertungszeitraums vorgenommene Prädiktion eines Verlaufs der Belastungsgrößen bzw. Betriebsgrößen mit den tatsächlich von dem betreffenden Fahrzeug 4 empfangenen Verläufen der Betriebsgrößen übereinstimmt.

[0103] Diese Analyse erfolgt vorzugsweise auf Basis eines konstanten Prognosehorizonts. Weiterhin wird angenommen, dass auch in Zukunft der Fahrer bzw. die Nutzungsart der Fahrzeugbatterie 41 mit einer ähnlichen Konfidenz auf dem identischen Prognosehorizont bzgl. seiner Nutzmuster, d.h. der Belastungs- und/oder Betriebsgrößen, z.B. umfassend Zeit und Temperatur, prädiert werden kann. Das Erlernen von historischen Nutzmuster-Konfidenzen erfolgt auf mindestens einem Prognosehorizont, vorzugsweise jedoch auf mehreren, z.B. zehn Prognosehorizonte, üblicherweise diskretisiert zwischen 1 Monat und 15 Jahren.

[0104] In **Fig. 7** ist beispielsweise anhand Betriebsgröße der Batterietemperatur für einen zurückliegenden Betrachtungszeitraum ein durch das Nutzungsmustermodell 10 prädizierten Verlauf VP der Batterietemperatur und Zeitabschnitte für einen tatsächlichen Verlauf VT der Batterietemperatur aufgetragen. Da das Fahrzeug bzw. die Fahrzeugbatterie 41 nicht kontinuierlich in Betrieb ist, steht der tatsächliche Verlauf der Batterietemperatur nicht kontinuierlich zur Verfügung. Immer, wenn eine Batterie-Temperatur oder eine Stromstärke im Betrieb gemessen bzw. beobachtet wurde, steht jedoch ein weiteres relevantes Label für das Nutzungsmustermodell zur Verfügung, welches weiterhin auch zur Bewertung des prädizierten Verlaufs der Belastungsgröße(n) und/oder Betriebsgröße(n) verwendet werden kann.

[0105] Es wird nun überprüft, inwieweit der prognostizierte (prädizierte) Verlauf mit dem tatsächlichen Verlauf der prädizierten Belastungsgrößen, umfassend z.B. Temperatur und Strom, übereinstimmt.

[0106] Es werden dazu für einen oder mehrere konstante Prognosehorizonte jeweils ein prädizierter Verlauf der betrachteten Betriebsgröße nach jeweils dem konstanten Prognosehorizont ermittelt. Das heißt, zur Ermittlung des prädizierten Verlaufs der betrachteten Belastungsgröße L bzw. Betriebsgröße F wird für zeitlich aufeinanderfolgende Prognosezielzeitpunkte, die einem Auswertungszeitraum bzw. einem gleichen Zeitschritt (z.B. 3 Jahren) in einem zurückliegenden Betrachtungszeitraum entsprechen und die den prädizierten Verlauf angeben, jeweils ein Wert der betrachteten Betriebsgröße ausgehend von einem Verlauf der betrachteten Betriebsgröße bis zu einem Prognosestartzeitpunkt mithilfe des Nutzungsmustermodells 10 prädiziert. Die Zeitdauer zwischen dem Prognosestartzeitpunkt und dem Prognosezielzeitpunkt entspricht dem konstanten Prognosehorizont. Der Prognosestartzeitpunkt entspricht somit einem Auswertungszeitraum/Zeitpunkt (Start der Prädiktion), der um den vorgegebenen konstanten Prognosehorizont bezüglich des betrachteten Auswertungszeitraums/Zeitpunkts zurückliegt.

[0107] Der prädizierte Verlauf der betrachteten Betriebsgröße wird für den zurückliegenden Betrachtungszeitraum ermittelt, der vorzugsweise zum aktuellen Auswertungszeitraum/Zeitpunkt endet. Im zurückliegenden Betrachtungszeitraum, der z.B. zum Zeitpunkt der Inbetriebnahme des Energiespeichers starten kann, werden nun sämtliche Prädiktionen mit dem konstanten Prognosehorizont (z.B. 3 Jahre) zu einem Last-Prädiktionsvektor mit konstantem Prognosehorizont zusammengefasst.

[0108] Durch Abgleich mit dem realen gemessenen oder beobachteten Verlauf der Belastungsgröße(n) und/oder Betriebsgröße(n), z.B. der Temperatur, kann das Residuum der Prädiktion der betreffenden Belastungsgröße(n) und/oder Betriebsgröße(n) genau bestimmt werden.

[0109] Das angewendete Nutzungsmustermodell 10 ist in der Regel datenbasiert und wird wie oben beschrieben fahrzeugindividuell für das betrachtete Fahrzeug mit bekannten Verläufen der betrachteten tatsächlichen Betriebsgröße trainiert. Insbesondere kann als Nutzungsmustermodell 10 für die Bestimmung des prädizierten Verlaufs der betrachteten Betriebsgröße stets ein Modell angenommen werden, für dessen Training nur Verläufe der betrachteten Betriebsgröße bis zu dem jeweils berücksichtigten Prognosestartzeitpunkt (Start der Prädiktion) berücksichtigt wird. D.h. zur Ermittlung des jeweiligen prädizierten Verlaufs der betrachteten Betriebsgröße werden eine Vielzahl von Nutzungsmustermodellen verwendet, die entsprechend dem Prognosestartzeitpunkt ausgewählt werden.

[0110] Die resultierenden prädizierten Verläufe der betrachteten Betriebsgröße sind beispielhaft in **Fig. 8** für zwei verschiedene Prognosehorizonte dargestellt. Man erkennt als gepunktete Kurve P2 die prädizierten Werte der betrachteten Betriebsgröße, die für einen längeren Prognosehorizont von z.B. 5 Tagen, vorhergesagt wurden, und anhand der gestrichelten Kurve die prädizierten Werte der betrachteten Betriebsgröße, die für einen kürzeren Prognosehorizont P1 prädiziert worden sind. Man erkennt im Vergleich mit den Abschnitten des tatsächlichen Verlaufs VT der betrachteten Betriebsgröße, dass das Nutzungsmustermodell 10 für einen kürzeren Prognosehorizont den Verlauf der Betriebsgröße besser vorhersagen kann, als dies für die Vorhersage bezüglich eines längeren Prognosehorizonts der Fall ist.

[0111] In Schritt S14 wird nun ausgewertet, bezüglich der Zeitabschnitte, für die ein tatsächlicher Verlauf von Betriebsgrößen vorliegt, wie gut die Prädiktion für unterschiedliche Prognosehorizonte vorgenommen wurde. So kann beispielsweise für jeden Prognosehorizont ein vollständiges Fehlerresiduum bzw. Fehlerhistogramm aus den jeweiligen prädizierten Werten der betrachteten Belastungsgröße(n) und/oder Betriebsgröße(n) für die Auswertungszeiträume bzw. Zeitschritte in einem definierten Auswertungsintervall erstellt werden. Die Fehlerresiduen ergeben sich beispielsweise für jeden Auswertungszeitraum bzw. Zeitschritt in einem definierten Auswertungsintervall als eine Abweichung zwischen dem entsprechenden Wert der betrachteten Betriebsgröße und dem tatsächlichen Wert der betrachteten Betriebsgröße. Das definierte Auswertungsintervall kann dem

Betrachtungszeitraum entsprechen. Üblicherweise ist der Auswertezeitraum seit Inbetriebnahme des Energiespeichers oder seit dem letzten Fahrerwechsel bis zur Gegenwart definiert.

[0112] Die Auswertung der Fehlerresiduen bezüglich der tatsächlich gemessenen Betriebsgrößen und der prädizierten Betriebsgrößen kann auf einem erst kürzlich zurückliegenden Zeitfenster erfolgen, wie beispielsweise die letzten sieben Tage, oder einen anderen Zeitraum zwischen einem Tag und einem Monat bis hin zu mehreren Jahren erfolgen. Es wird dabei über historische Daten erlernt und festgestellt, wie die Residuen für einen bestimmten konstanten Prognosehorizont innerhalb des definierten Zeitfensters für einen bestimmten Nutzer bzw. eine bestimmte Nutzungsart verteilt sind.

[0113] In einem nachfolgenden Schritt S15 wird basierend auf dem ermittelten Residuum welches einem Prognosehorizont zugeordnet ist, für einen zurückliegenden vorgegebenen Zeitraum, insbesondere bis zu Beginn der Inbetriebnahme der Fahrzeugbatterie oder seit dem letzten Fahrerwechsel, die Fehlerresiduen entsprechend einem Histogramm analytisch ausgewertet. Basierend auf dem Residuum wird eine Wahrscheinlichkeitsdichtefunktion gefittet, welche eindeutig einem Prognosehorizont zugeordnet werden kann und die Unsicherheit der Nutzmuster-Prädiktion fahrerindividuell charakterisiert. Die Wahrscheinlichkeitsdichtefunktion kann z.B. basierend auf einer Normalverteilung oder nichtparametrisch gefittet werden. Es ergibt sich ein vollständiges Fehlerresiduumbild für den Prädiktionshorizont von z.B. 3 Jahren, für den über das Residuen-Histogramm eine Wahrscheinlichkeitsdichtefunktion unter Annahme, z.B. einer Normalverteilung, gefittet werden kann. Die Wahrscheinlichkeitsdichtefunktion für die betrachtete Betriebsgröße und für den betrachteten konstanten Prognosehorizont erlaubt es nun, eine Bewertung durchzuführen, wie stochastisch bzw. wie deterministisch die Fahrzeugbatterie von vom Fahrer genutzt wird.

[0114] Beispielsweise ist in **Fig. 9** ein Histogramm (Häufigkeiten H) für ein Fehlerresiduum dargestellt für einen konstanten 5-Tage-Prognosehorizont bezüglich der Batterietemperatur als betrachtete Betriebsgröße. An dem Beispiel der **Fig. 9** erkennt man, dass das Residuum der Batterietemperatur in erster Näherung normal verteilt (gemäß der Wahrscheinlichkeitsverteilung W) ist und ca. zwischen -12°C und $+12^{\circ}\text{C}$ schwankt für einen konstanten Prognosehorizont von fünfzig Tagen. Es wird eine historische Unsicherheit der betrachteten Betriebsgröße in Form einer maximalen Abweichung bestimmt, welche mit Wahrscheinlichkeiten hinterlegt ist, wie z. B. $\pm 12^{\circ}\text{C}$ Abweichung bei einem konstantem Prognosehorizont von fünfzig Tagen bei einer Konfidenz von 99 %, $\pm 16^{\circ}\text{C}$ Abweichung bei einem konstanten Prognosehorizont von 100 Tagen bei 99 % Konfidenz, und $\pm 20^{\circ}\text{C}$ Abweichung bei einem konstanten Prognosehorizont von drei Jahren bei einer Konfidenz von 99 %.

[0115] Es soll weiterhin geprüft sichergestellt werden, dass das Residuum sich gerade nicht im Randbereich des globalen Flotten-Residuums aufhält. Wenn dies der Fall ist und speziell bei einer stark steigenden Unsicherheit auf gleichen Prognosehorizont (z.B. 3 Jahre), wird ein erneutes Training des fahrerindividuellen bzw. nutzungsindividuellen Nutzungsmustermodells 10 angestoßen, sodass im Anschluss die neusten Residuen nicht im Randbereich der historischen Residuen liegen. Alternativ zum Training kann auch ein systematischer Residuen-Offset erlernt und anschließend additiv kompensiert werden.

[0116] In einem nachfolgenden Schritt S16 wird nun ausgehend von dem aktuellen Auswertungszeitraum eine Prädiktion des Alterungszustands basierend auf dem aktuellsten Nutzungsmustermodells 10 durchgeführt. Es ergibt sich ein nomineller prädizierter Verlauf des Alterungszustands. Durch die Verwendung des hybriden Alterungszustandsmodells ergibt sich neben dem prädizierten Verlauf des Alterungszustands auch ein Konfidenzintervall bezüglich einer vorgegebenen, z.B. 99% Konfidenz der Modellschätzung des hybriden Alterungszustandsmodells, vorzugsweise direkt abgeleitet vom Gaußprozessmodell.

[0117] Mithilfe der zuvor bestimmten maximalen Abweichungen der Betriebsgrößen für verschiedene Prognosehorizonte können nun in einem Schritt S17 prädizierte Verläufe für den Alterungszustand ermittelt werden. Dabei sollen prädizierte Verläufe für die minimale und maximale Belastungen bzw. Stressfaktoren der Fahrzeugbatterie ermittelt werden. Dies wird durchgeführt, indem prädizierte Verläufe des Alterungszustands mit modifizierten Verläufen einer oder mehrerer der Betriebsgrößen berechnet werden. Dazu wird der ursprüngliche prädizierte Verlauf einer oder mehrerer der Betriebsgrößen mit den zuvor ermittelten Abweichungen, die sich für die betrachtete Betriebsgrößen für die Prognosehorizonte ergeben, beaufschlagt. Die maximalen Abweichungen der jeweils betrachteten Betriebsgrößen werden entsprechend dem prädizierten Verlauf der entsprechenden Betriebsgröße hinzuaddiert oder subtrahiert. Bei einer Abweichung von z.B. $\pm 12^{\circ}\text{C}$ wird der prädizierte Verlauf der Batterietemperatur also um $\pm 12^{\circ}\text{C}$ verschoben, um minimale und maximale Temperatur-bedingte Nutzungsmuster beschreiben zu können

[0118] Alternativ kann auch ein Sampling durch eine Monte-Carlo-Methode, z.B. mit einer Stichprobe von $n = 80$, erfolgen, um z.B. die Unsicherheit der Temperatur-Prädiktion mit der Unsicherheit der Stromprädiktion zu kombinieren und das hybride Alterungszustandsmodell eingangsseitig zu stimulieren. Hierbei kann aus der erlernten Verteilung gesampelt werden, entsprechend **Fig. 9**.

[0119] Weiterhin wird in Schritt S18 eine minimale Prädiktion des Verlaufs der betrachteten Betriebsgrößen und eine maximale Prädiktion des Verlaufs der betrachteten Betriebsgrößen durchgeführt. Dazu werden entsprechend dem Nutzungsmustermodell 10 der Verlauf der Betriebsgrößen, Batteriestrom und Batterietemperatur, ermittelt. Diesbezüglich werden bezüglich der mehreren betrachteten Prognosehorizonte die entsprechenden maximalen Abweichungen als Konfidenzintervall für die Prädiktion des Verlaufs des Alterungszustands berücksichtigt. Zwischen den Prognosehorizonten für die die maximalen Abweichungen vorliegen, kann die berücksichtigte maximale Abweichung interpoliert werden.

[0120] Das heißt, auf den Verlauf des modellbasiert prädizierten Batteriestroms und der Batterietemperatur werden für jeden betrachteten Prognosehorizont zumindest die negative maximalen Abweichung der Batterietemperatur und die negative maximale Abweichung des Batteriestroms, die positive maximale Abweichung der Batterietemperatur und die negative maximale Abweichung des Batteriestroms, die negative maximale Abweichung der Batterietemperatur und die positive maximale Abweichung des Batteriestroms und die positive maximale Abweichung der Batterietemperatur und die positive maximale Abweichung des Batteriestroms ermittelt. Es ergeben sich daraus mehrere Trajektorien für den Verlauf des Alterungszustands, wie beispielsweise aus **Fig. 10** mit den Kurven SOH_{nom} für den nominellen Alterungszustandsverlauf, SOH_{min} für den Alterungszustandsverlauf bei minimaler Belastung der Fahrzeugbatterie 41 und SOH_{max} für den Alterungszustandsverlauf bei maximaler Belastung der Fahrzeugbatterie 41. Ausgehend von der nominellen Alterungszustandsprädiktion bei den negativen und positiven maximalen Abweichungen der Betriebsgrößen werden also diejenige Alterungszustandstrajektorie, die eine minimale Belastung der Fahrzeugbatterie, und diejenige Alterungszustandstrajektorie, die eine maximale Belastung der Fahrzeugbatterie angibt, berücksichtigt.

[0121] Entsprechend dem datenbasierten hybriden Alterungszustandsmodell 9 können nun in Schritt S19 zusätzlich die Modellierungsunsicherheiten als Konfidenzintervall um den Alterungszustandsverlauf SOH_{nom} für den nominellen Alterungszustandsverlauf, den Alterungszustandsverlauf SOH_{min} bei minimaler Belastung der Fahrzeugbatterie 41 und den Alterungszustandsverlauf SOH_{max} bei maximaler Belastung der Fahrzeugbatterie 41 ermittelt werden. Diese sind als gepunktete Grenzalterungszustandsverläufe SOH_{maxges} , SOH_{minges} um die entsprechenden Alterungszustandsverläufe SOH_{max} , SOH_{min} für die maximale und minimale Belastung der Fahrzeugbatterie 41 dargestellt.

[0122] Die jeweiligen Konfidenzintervallgrenzen, die sich aus den so ermittelten Gesamtalterungszustandsverläufen SOH_{maxges} , SOH_{minges} mit den kombinierten Unsicherheiten aus dem Nutzungsmustermodell 10 und dem hybriden Alterungszustandsmodell 9 ergeben, entsprechen denjenigen Trajektorien, die von der nominalen Alterungszustandstrajektorie am weitesten beabstandet sind. Diese definieren das Konfidenzintervall für die nominale Alterungszustandstrajektorie. Dieses berücksichtigt sowohl die Modellierungsunsicherheit des hybriden Alterungszustandsmodells 9 als auch die Modellierungsunsicherheit des Nutzungsmustermodells 10. Somit ist sichergestellt, dass deterministisch agierende Fahrer, wie z.B. Linienverkehr, hochpräzise bzgl. der Nutzungsmuster und Lasten prädiziert werden kann, was direkt für eine genaue Alterungszustandsprädiktion und Berechnung der Restlebensdauer genutzt werden kann. Dies bedeutet, dass für deterministisch genutzte Fahrzeugbatterien bei hinreichend schmaler Konfidenz prädiktive Wartungsintervalle effizient geplant und sehr effektiv durchgeführt werden können.

[0123] In Schritt S20 wird die nominale prädizierte Alterungszustandstrajektorie sowie das zugehörige Konfidenzintervall signalisiert.

[0124] Durch den Zeitpunkt, zu dem der Verlauf des prädizierten Alterungszustands einen vorgegebenen Alterungszustandsschwellenwert, wie z.B. 80% SOH, erreicht, wird die Restlebensdauer bestimmt. Das sich nach dem obigen Verfahren für die Prädiktion des Alterungszustandsverlaufs ergebende Konfidenzintervall ermöglicht es nun, ein entsprechendes Intervall für die voraussichtliche Restlebensdauer basierend auf den gemeinsamen Unsicherheiten des Nutzungsmustermodells und des hybriden Alterungszustandsmodells 9 anzugeben. Die Ermittlung des Unsicherheitsbereichs für die prädizierte Restlebensdauer erfolgt durch die Angabe derjenigen Zeitpunkte, zu dem die prädizierten Alterungszustandsverläufe SOH_{maxges} , SOH_{minges} für die maximale und minimale Belastung den vorgegebenen Alterungszustandsschwellenwert, wie beispielsweise 80 % SOH, unterschreitet.

Patentansprüche

1. Computerimplementiertes Verfahren zur Prädiktion eines modellierten Alterungszustands (SOH) eines elektrischen Energiespeichers (41) mit mindestens einer elektrochemischen Einheit, insbesondere einer Batteriezelle, in einem technischen Gerät (4); mit folgenden Schritten:

- Bereitstellen eines datenbasierten Alterungszustandsmodells (9), das ausgebildet ist, um abhängig von einem Verlauf mindestens einer Betriebsgröße (F) des Energiespeichers (41) bis zu einem Zeitpunkt dem elektrochemischen Energiespeicher (41) einen entsprechenden Alterungszustand (SOH) für den Zeitpunkt zuzuordnen und eine entsprechende Modellierungsunsicherheit anzugeben,
- Prädizieren (S16) eines Verlaufs für die mindestens eine Betriebsgröße ausgehend von einem aktuellen Zeitpunkt in die Zukunft abhängig von einem Nutzungsmustermodell, das durch ein nutzer- oder nutzungs-individuelles Nutzungsmuster bestimmt ist,
- Prädizieren (S17) eines Verlaufs des Alterungszustands mithilfe des datenbasierten Alterungszustandsmodells (9) abhängig von dem modellbasiert generierten prädizierten Verlauf der mindestens einen Betriebsgröße (F);
- Bestimmen (S18, S19) eines Konfidenzintervalls für den prädizierten Verlauf des Alterungszustands abhängig von der Modellierungsunsicherheit des datenbasierten Alterungszustandsmodells (9) und einer Konfidenz des Nutzungsmustermodells (10);
- Signalisieren (S20) des prädizierten Verlaufs des Alterungszustands und des entsprechenden Konfidenzintervalls.

2. Verfahren nach Anspruch 1, wobei zur Bestimmung des prädizierten Verlaufs des Alterungszustands (SOH) das datenbasierte Alterungszustandsmodell (9) mit einem gesamten Verlauf der mindestens einer Betriebsgröße (F) betrieben wird, der den bisherigen Verlauf der mindestens einen Betriebsgröße (F) bis zu dem aktuellen Zeitpunkt und dem modellbasiert generierten Verlauf der mindestens einen Betriebsgröße (F) ausgehend von dem aktuellen Zeitpunkt in die Zukunft umfasst.

3. Verfahren nach Anspruch 1 oder 2, wobei das Nutzungsmustermodell (10) insbesondere als datenbasiertes Modell, insbesondere als Bayes'sches LSTM, ausgebildet ist, um abhängig von Nutzungsparametern des Nutzungsmusters (N) kontinuierlich einen Verlauf der mindestens einen Betriebsgröße (F) oder einen Verlauf mindestens einer Belastungsgröße (L), aus der die mindestens eine Betriebsgröße (F) generierbar ist, bereitzustellen.

4. Verfahren nach einem der Ansprüche 1 bis 3, wobei die Konfidenz des Nutzungsmustermodells (10) abhängig von einer Unsicherheit der Prädiktion des modellbasiert generierten Verlaufs für die mindestens eine Betriebsgröße (F) bestimmt wird.

5. Verfahren nach einem der Ansprüche 1 bis 4, wobei die Konfidenz der Prädiktion der mindestens einen Betriebsgröße (F) auf Basis in der Vergangenheit erfasster Verläufe der mindestens einen Betriebsgröße (F) ermittelt wird, wobei insbesondere die Konfidenz des Nutzungsmustermodells (10) durch Vergleich eines Zeitabschnitts eines tatsächlichen Verlaufs der mindestens einen Betriebsgröße (F) mit dem einen oder den mehreren prädizierten Verläufen der mindestens einen Betriebsgröße (F) für den entsprechenden Zeitabschnitt Zeitraum ermittelt wird, wobei insbesondere der eine oder die mehreren prädizierten Verläufe der mindestens einen Betriebsgröße für jeweils einen konstanten Prognosehorizont durchgeführt wird.

6. Verfahren nach Anspruch 5, wobei der eine oder die mehreren prädizierten Verläufe der mindestens einen Betriebsgröße jeweils durch Werte der mindestens einen Betriebsgröße zu Prognosezielzeitpunkten gebildet werden, die basierend auf einem jeweiligen Nutzungsmustermodell (10) ermittelt werden, das mit einem tatsächlichen Verlauf der mindestens einen Betriebsgröße bis zu einem entsprechenden Prognosestartzeitpunkt trainiert ist, wobei die Prognosestartzeitpunkte um den entsprechenden konstanten Prognosehorizont vor den entsprechenden Prognosezielzeitpunkten liegen.

7. Verfahren nach einem der Ansprüche 5 bis 6, wobei die Konfidenz des Nutzungsmustermodells (10) abhängig von einer Wahrscheinlichkeitsdichtefunktion der Abweichungen des tatsächlichen Verlaufs der mindestens einen Betriebsgröße (F) mit einem der einen oder der mehreren prädizierten Verläufe der mindestens einen Betriebsgröße (F) für den gleichen Zeitraum bestimmt wird, insbesondere als Residuum bzw. der dazugehörigen Wahrscheinlichkeitsdichtefunktion.

8. Verfahren nach Anspruch 7, wobei die Konfidenz des Nutzungsmustermodells (10) als Verlauf der Abweichungen abhängig vom tatsächlichen Verlauf der mindestens einen Betriebsgröße (F) und den mehreren prädizierten Verläufen der mindestens einen Betriebsgröße für den gleichen Zeitraum für verschiedene konstante Prognosehorizonte bestimmt wird, wobei die Abweichungen zwischen den konstanten Prognosehorizonten interpoliert werden, um den Verlauf der Abweichung abhängig von dem Prognosezeitpunkt des zu prädizierenden Werts des Alterungszustands (SOH) zu erhalten.

9. Verfahren nach einem der Ansprüche 5 bis 8, wobei das Konfidenzintervall für den prädizierten Verlauf des Alterungszustands durch Konfidenzintervallgrenzen angegeben wird, die sich aus Grenzalterungszustandsverläufen ($SOH_{\max ges}$, $SOH_{\min ges}$) ergeben, wobei die Grenzalterungszustandsverläufe ($SOH_{\max ges}$, $SOH_{\min ges}$) sich aus Alterungszustandsverläufen ($SOH_{\max}$, $SOH_{\min}$) für die minimale und die maximale Belastung des Energiespeichers (41) ergeben, die durch Beaufschlagen des prädizierten Verlaufs der mindestens einen Betriebsgröße mit den Verläufen der maximalen Abweichungen erhalten werden und die jeweils die von der nominalen Alterungszustandstrajektorie am weitesten beabstandet sind, wobei die so erhaltenen Alterungszustandsverläufe für die minimale und die maximale Belastung des Energiespeichers (41) mit der Modellunsicherheit des datenbasierten Alterungszustandsmodells (9) beaufschlagt werden, um die Grenzalterungszustandsverläufe ($SOH_{\max ges}$, $SOH_{\min ges}$) zu erhalten.

10. Verfahren nach einem der Ansprüche 1 bis 9, wobei das Alterungszustandsmodell als ein hybrides Modell ausgebildet ist und ein physikalisches Alterungsmodell (5), das auf elektrochemischen Modellgleichungen basiert und zur Ausgabe eines physikalischen Alterungszustand (SOH_{ph}) ausgebildet ist, und ein trainierbares datenbasiertes Korrekturmodell (6), insbesondere in Form eines Regressionsmodells, vorzugsweise einen Gaußprozess, umfasst, wobei das Korrekturmodell (6) trainiert ist, um den physikalischen Alterungszustand (SOH_{ph}) zu korrigieren und den korrigierten physikalischen Alterungszustand als den modellierten Alterungszustand (SOH) und die entsprechende Modellunsicherheit, bereitzustellen.

11. Verfahren nach einem der Ansprüche 1 bis 10, wobei das technische Gerät und insbesondere der elektrische Energiespeicher (41) abhängig von dem Verlauf des prädizierten modellierten Alterungszustands (SOH) und abhängig von dem Konfidenzintervall betrieben wird, wobei insbesondere eine Restlebensdauer des elektrischen Energiespeichers (41) abhängig von dem Verlauf des prädizierten modellierten Alterungszustand (SOH) signalisiert wird und/oder ein Bereich der möglichen Restlebensdauer abhängig von dem Verlauf des prädizierten modellierten Alterungszustand (SOH) und des Konfidenzintervalls signalisiert wird, wobei insbesondere abhängig von dem Bereich der möglichen Restlebensdauer der Energiespeicher (41) die Anzahl der verbleibenden, zugelassenen Schnell-Lade-Zyklen erhöht oder verringert wird oder Strom- und De-Rating-Grenzen für den Betrieb des Energiespeichers optimiert werden.

12. Verfahren nach einem der Ansprüche 1 bis 11, wobei abhängig von der Konfidenz des Nutzungsmustermodells (10) prädiktive Wartungsintervalle des technischen Geräts angepasst werden.

13. Verfahren nach einem der Ansprüche 1 bis 11, wobei der Energiespeicher (41) zum Betrieb eines Geräts, wie einem Kraftfahrzeug, einem Pedelec, einem Fluggerät, insbesondere einer Drohne, einer Werkzeugmaschine, einem Gerät der Unterhaltungselektronik, wie ein Mobiltelefon, einem autonomen Roboter und/oder einem Haushaltsgerät verwendet wird.

14. Vorrichtung zur Prädiktion eines modellierten Alterungszustands (SOH) eines elektrischen Energiespeichers (41) mit mindestens einer elektrochemischen Einheit, insbesondere einer Batteriezelle, in einem technischen Gerät; wobei die Vorrichtung ausgebildet ist zum:

- Bereitstellen eines datenbasierten Alterungszustandsmodells (9), das ausgebildet ist, um abhängig von einem Verlauf mindestens einer Betriebsgröße (F) des Energiespeichers (41) bis zu einem Zeitpunkt dem elektrochemischen Energiespeicher (41) einen entsprechenden Alterungszustand (SOH) für den Zeitpunkt zuzuordnen und eine entsprechende Modellierungsunsicherheit anzugeben,
- Prädizieren eines Verlaufs für die mindestens eine Betriebsgröße ausgehend von einem aktuellen Zeitpunkt in die Zukunft abhängig von einem Nutzungsmustermodell (10), das durch ein nutzer- oder nutzungsindividuelles Nutzungsmuster bestimmt ist,
- Prädizieren eines Verlaufs des Alterungszustands mithilfe des datenbasierten Alterungszustandsmodells (9) abhängig von dem modellbasiert generierten prädizierten Verlauf der mindestens einen Betriebsgröße;
- Bestimmen eines Konfidenzintervalls für den prädizierten Verlauf des Alterungszustands (SOH) abhängig von der Modellierungsunsicherheit des datenbasierten Alterungszustandsmodells (9) und einer Konfidenz des Nutzungsmustermodells (10);


- Signalisieren des prädizierten Verlaufs des Alterungszustands und des entsprechenden Konfidenzintervalls.

15. Computerprogrammprodukt umfassend Befehle, die bei der Ausführung des Programms durch mindestens eine Datenverarbeitungseinrichtung diese veranlassen, die Schritte des Verfahrens nach einem der Ansprüche 1 bis 12 auszuführen.

16. Maschinenlesbares Speichermedium, umfassend Befehle, die bei der Ausführung durch mindestens eine Datenverarbeitungseinrichtung diese veranlassen, die Schritte des Verfahrens nach einem der Ansprüche 1 bis 12 auszuführen.

Es folgen 7 Seiten Zeichnungen

Anhängende Zeichnungen






FIG. 2




FIG. 3




FIG. 4




FIG. 5




FIG. 6




FIG. 7




FIG. 8




FIG. 9




FIG. 10