



(10) **DE 10 2021 211 158 A1** 2023.04.06

(12) **Offenlegungsschrift**

(21) Aktenzeichen: **10 2021 211 158.0**

(22) Anmeldetag: **04.10.2021**

(43) Offenlegungstag: **06.04.2023**

(51) Int Cl.: **G01R 31/36 (2020.01)**

(71) Anmelder:

**Robert Bosch Gesellschaft mit beschränkter
Haftung, 70469 Stuttgart, DE**

(56) Ermittelter Stand der Technik:

DE	10 2020 215 378	A1
JP	2021- 129 404	A

(72) Erfinder:

**Domokos, Csaba, 75397 Simmozheim, DE;
Simonis, Christian, 71229 Leonberg, DE; Woll,
Christoph, 70839 Gerlingen, 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 Frühwarn-Systems zum robusten Erkennen eines Fehlers eines elektrischen Energiespeichers für ein Gerät mithilfe von maschinellen Lernverfahren**

(57) Zusammenfassung: Die Erfindung betrifft ein computerimplementiertes Verfahren zur Ermittlung eines Fehlers des Verhaltens eines elektrischen Energiespeichers (41) in einem technischen Gerät (4); mit folgenden Schritten:


- Erfassen (S1) eines Betriebsgrößenverlaufs der mindestens einen Betriebsgröße des elektrischen Energiespeichers (41);

- Bestimmen (S2) von mindestens einem Betriebsmerkmal (M) aus dem Betriebsgrößenverlauf (F) der mindestens einen Betriebsgröße des elektrischen Energiespeichers (41);

- Auswerten (S3) eines Variational Autoencoders (50) mit einem zugeführten Eingangsgrößenvektor (x), der einen Betriebsmerkmalspunkt (M) aus dem mindestens einen Betriebsmerkmal (M) umfasst, um ein Abweichungsmaß aus einer Verteilung in einem latenten Zustandsraum oder einen Rekonstruktionsfehler zu bestimmen;

- Erkennen (S4, S5) eines Fehlers abhängig von dem Abweichungsmaß bzw. dem Rekonstruktionsfehler und weiterhin abhängig von einem vorgegebenen Fehlerschwellenwert;

- Signalisieren (S7) des Fehlers.



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 Erkennung einer Anomalie eines elektrischen Energiespeichers.

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, z.B. SOH-C, d.h. bezüglich seiner Kapazität von 100% auf, dessen Wert im Laufe seiner Lebensdauer zusehends abnimmt. Ein niedrigerer Wert des Alterungszustands gibt also ein höheres Maß einer Alterung an. Das 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.

Offenbarung der Erfindung

[0004] Erfindungsgemäß sind ein Verfahren zur Ermittlung einer Anomalie des Verhaltens eines elektrischen Energiespeichers gemäß Anspruch 1 sowie eine Vorrichtung zur Ermittlung einer Anomalie des Verhaltens eines elektrischen Energiespeichers in einem elektrisch betreibbaren Gerät gemäß dem nebengeordneten Anspruch vorgesehen.

[0005] Weitere Ausgestaltungen sind in den abhängigen Ansprüchen angegeben.

[0006] Gemäß einem ersten Aspekt ist ein computerimplementiertes Verfahren zur Ermittlung eines Fehlers des Verhaltens eines elektrischen Energiespeichers in einem technischen Gerät (4); mit folgenden Schritten:

- Erfassen eines Betriebsgrößenverlaufs der mindestens einen Betriebsgröße des elektrischen Energiespeichers;
- Bestimmen von mindestens einem Betriebsmerkmal aus dem Betriebsgrößenverlauf der mindestens einen Betriebsgröße des elektrischen Energiespeichers;
- Auswerten eines Variational Autoencoders mit einem zugeführten Eingangsgrößenvektor, der einen Betriebsmerkmalspunkt aus dem mindestens einen Betriebsmerkmal umfasst, um ein Abweichungsmaß aus einer Verteilung in einem latenten Zustandsraum oder einen Rekonstruktionsfehler zu bestimmen;
- Erkennen eines Fehlers abhängig von dem Abweichungsmaß bzw. dem Rekonstruktionsfehler und weiterhin abhängig von einem vorgegebenen Fehlerschwellenwert;
- Signalisieren des Fehlers.

[0007] 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.

[0008] Für die Ermittlung von Alterungszuständen werden Betriebsgrößen von Energiespeichern in einer Vielzahl von Geräten kontinuierlich erfasst und in einer Zentraleinheit ausgewertet werden. Die Betriebsgrößen können einen momentanen Energiespeicherstrom, eine momentane Energiespeicherspannung, eine momentane Energiespeichertemperatur und/oder einen momentanen Energiespeicherladezustand umfassen. Gemäß obigem Verfahren ist es weiterhin möglich, eine Anomalie der Energiespeicher durch zusätzliche

Auswertung basierend auf den Betriebsgrößenverläufen in einer geräteexternen Zentraleinheit oder in dem betreffenden Gerät zu erkennen.

[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 einer von dem Energiespeicher separaten Zentraleinheit ermittelt.

[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 datenbasierten 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 ein Random-Forest-Modell, AdaBoost-Modell, Support-Vector-Machine oder ein Bayes'schen neuronalen Netzwerk dar.

[0015] Das Korrekturmodell ist ausgebildet, die Korrekturgröße basierend auf Betriebsmerkmalen zu ermitteln, die durch Merkmalsextraktion basierend auf einer Signalverarbeitung aus den Verläufen der Betriebs-

größen einer oder mehrerer der Gerätebatterien ermittelt werden und auch einen oder mehrere der internen elektrochemischen Zustände des Differentialgleichungssystems des physikalischen Modells umfassen können. Insbesondere kann das mindestens eine Betriebsmerkmal aus dem Betriebsgrößenverlauf der mindestens einen Betriebsgröße des elektrischen Energiespeichers als aggregierte Größe bestimmt werden. Die Betriebsmerkmale können weiterhin auf den Auswertungszeitraum bezogene Merkmale und/oder akkumulierte Merkmale und/oder über die gesamte bisherige Lebensdauer ermittelte statistische Größen umfassen.

[0016] Die Berechnung des physikalischen/elektrochemischen Alterungsmodells nebst Korrekturmodell findet vorzugsweise geräteextern in einer Zentraleinheit (Cloud) 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 daraus Betriebsmerkmale zur Bestimmung des Alterungszustands z.B. gemäß dem elektrochemischen Modell sowie dem Korrekturmodell bestimmt. Die Betriebsmerkmale charakterisieren dadurch die Belastung des betreffenden Energiespeichers seit seiner Inbetriebnahme durch Kumulierung oder Aggregation der durch die Betriebsgrößenverläufe bestimmten Belastung.

[0017] Während man anhand der Betriebsgrößenverläufe nur schwierig ein fehlerhaftes Verhalten des Energiespeichers oder funktionale Fehler frühzeitig erkennen kann, kann eine festgestellte ungewöhnliche Belastung anhand nicht zusammenpassender oder ungewöhnlicher Ausprägung von Betriebsmerkmalen, speziell in Bezug auf deren Kombination, frühzeitig als ein anomales Verhalten des Energiespeichers erkannt und signalisiert werden. Somit sollen gemäß obigem Verfahren die einer oder mehrere der Betriebsmerkmale genutzt werden, um eine Anomalie eines Energiespeichers festzustellen. Als das mindestens eine Merkmal zur Auswertung, um eine Anomalie festzustellen, kann mindestens ein aus dem Betriebsgrößenverlauf der mindestens einen Betriebsgröße des elektrischen Energiespeichers bestimmtes Betriebsmerkmal als aggregierte Größe bestimmt werden.

[0018] Diesbezüglich ist ein Variational Autoencoder vorgesehen, der insbesondere mithilfe von Betriebsmerkmalspunkten einer Vielzahl von Energiespeichern, die fehlerfrei arbeiten bzw. in der Vergangenheit (z.B. bis vor 3 Monaten) fehler- und ausfallfrei betrieben wurden, insbesondere unsupervised trainiert und regelmäßig oder kontinuierlich aktualisiert werden kann. So kann anhand einer Auswertung eines Abweichungsmaßes einer Verteilung im latenten Zustandsraum des Variational Autoencoders oder eines Rekonstruktionsfehlers eine Anomalie einer Gerätebatterie ermittelt werden kann. Dazu können beispielsweise zeitgleich mit der Bestimmung des aktuellen Alterungszustands mithilfe des hybriden Alterungszustandsmodells die Betriebsmerkmale der betreffenden Gerätebatterie zumindest teilweise genutzt werden, um die Anomalieerkennung durchzuführen.

[0019] Das Training des Variational Autoencoders erfolgt, so dass ein Encoder trainiert wird, um eine Verteilung der Trainingsdaten in einem latenten Zustandsraum zu bestimmen, basierend auf einer Loss-Funktion, die eine Kullback-Leibler Divergenz berücksichtigt. Dadurch wird ein overfitting des latenten Zustandsraum vermieden.

[0020] Bei einem Trainingsdatensatz x , wobei x aus einer latenten Variablen abgeleitet wird, kann der probabilistische Encoder durch $p(z|x)$ definiert sein und ein probabilistischer Decoder durch $\hat{x} \sim p(x|z)$ definiert sein.

[0021] Basierend auf dem Satz von Bayes erhält man

$$p(z|x) = \frac{p(x|z)p(z)}{p(x)} = \frac{p(x|z)p(z)}{\int p(x|z)p(z)dz} = \frac{p(x|z)p(z)}{\int p(x|z)p(z)dz}$$

Wobei $p(x)$ unlösbar ist. Daher wird $p(z|x)$ durch $q(z|x) \equiv N(\mu_x, \sigma_x)$ angenähert, was einer Gauß-Verteilung entspricht, wobei μ_x and σ_x den Mittelwert bzw. die Varianz abhängig von x angeben.

[0022] Weiterhin wird angenommen, dass $p(z) \equiv N(0, I)$ entspricht.

[0023] Es kann eine lösbare variationelle Inferenz durchgeführt werden, um μ_x and σ_x durch Minimierung der Kullback-Leibler Divergenz zu bestimmen:

$$\begin{aligned}
& (\mu_x, \sigma_x) \in \operatorname{argmin} KL(q(z|x)) \| p(z|x) \\
& = \operatorname{argmin} E_{z \sim q(z|x)} \left[\log q(z|x) - E_{z \sim q(z|x)} \left[\log \frac{p(x|z)p(z)}{p(x)} \right] \right] \\
& = \operatorname{argmin} E[\log q(z|x)] - E[\log p(x|z)] - E[\log p(z)] + E[\log p(x)] \\
& = \operatorname{argmin} E_{z \sim q(z|x)} [\log p(x|z)] - KL(q(z|x) \| p(z))
\end{aligned}$$

[0024] Der erste Term stellt dabei die Rekonstruktionswahrscheinlichkeit dar, die den Rekonstruktionsfehler bestraft und der zweite Term stellt sicher, dass die Verteilung $q(z|x)$ der wahren prior Verteilung von $p(z)$ ähnelt.

[0025] Die zu minimierende Loss-Funktion I ist für ein insbesondere vorgegebenes $c > 0$ wie folgt definiert:

$$I = c \|x - \hat{x}\|^2 + KL(N(\mu_x, \sigma_x) \| N(0, I))$$

[0026] Das Training erfolgt basierend auf Trainingsdatensätzen mit Betriebsmerkmalspunkten, bei denen die Loss-Funktion durch Training von Decoder und Encoder sukzessive mithilfe herkömmlicher Trainingsverfahren minimiert wird.

[0027] Eine Anomalie kann mit dem Variational Autoencoder erkannt werden, indem für einen auszuwertenden Betriebsmerkmalspunkt aus von Betriebsgrößenverläufen eines Energiespeichers ermittelten Betriebsmerkmalen ein Abweichungsmaß einer Verteilung im latenten Zustandsraum oder ein Rekonstruktionsfehler ausgewertet wird. Insbesondere kann eine Anomalie erkannt werden, wenn ein Rekonstruktionsfehler erkannt wird, der größer ist als ein vorgegebener Fehlerschwellenwert. Der Fehlerschwellenwert ergibt sich aus einer Auswertung der verfügbaren Trainingsdaten.

[0028] Vorteilhafterweise kann das Abweichungsmaß auch als Mahalanobis-Distanz zwischen einem Zentroiden der latenten Zustandsvektoren, die sich aus den Auswertungen der Eingangsgrößenvektoren der Trainingsdatensätze in dem trainierten Variational Autoencoder ergeben, und dem latenten Zustandsvektor für den auszuwertenden Eingangsgrößenvektor bestimmt werden. Alternativ kann das Abweichungsmaß auch z.B. als euklidische Distanz zwischen dem Zentroiden der latenten Zustandsvektoren, die sich aus den Auswertungen der Eingangsgrößenvektoren der Trainingsdatensätze in dem trainierten Variational Autoencoder ergeben, und dem latenten Zustandsvektor für den auszuwertenden Eingangsgrößenvektor bestimmt werden. Weiterhin kann zusätzlich oder alternativ auch der Rekonstruktionsfehler als euklidische Distanz zwischen einem Ausgangsgrößenvektor des Variational Autoencoders und dem auszuwertenden Eingangsgrößenvektor bestimmt werden.

[0029] Es kann vorgesehen sein, dass der vorgegebene Fehlerschwellenwert auf Basis einer zulässigen vorgegebenen False-positive-Wahrscheinlichkeit bestimmt wird, wobei die False-positive-Wahrscheinlichkeit einen relativen Grenzwert angibt, welcher Anteil der Auswertungen maximal zu einem fälschlich erkannten Fehler führen dürfen, wobei eine Häufigkeitsverteilung aus den Häufigkeiten des Auftretens eines bestimmten Werts (oder Wertebereichs) des Rekonstruktionsfehlers bei einer Auswertung von verfügbaren Trainingsdatensätzen bestimmt wird, wobei sich der Fehlerschwellenwert als derjenige Wert des Rekonstruktionsfehlers ergibt, der kleiner ist als die Rekonstruktionsfehler einer Anzahl von Trainingsdatensätzen, die einem Anteil an allen der verfügbaren Trainingsdatensätze entspricht, der der vorgegebenen False-positive-Wahrscheinlichkeit entspricht.

[0030] Weiterhin kann nach dem Vorliegen von Felddaten von Fehlern in Energiespeichern der vorgegebene Fehlerschwellenwert auf Basis einer sich aus den Trainingsdatensätzen von fehlerfreien Energiespeichern ergebende False-Positive-Häufigkeitsverteilung und einer False-Negative-Häufigkeitsverteilung bestimmt werden.

[0031] Somit wird insbesondere nach dem Trainingsprozess des Variational Autoencoders der Fehlerschwellenwert für die Erkennung einer Anomalie auf Basis einer vorgegebenen Wahrscheinlichkeit einer False-positive-Erkennung kalibriert. Z.B. kann bei einer maximalen False-Positive-Wahrscheinlichkeit von 1 % ein Grenzwert als Designparameter zur Auswertung einer Häufigkeitsverteilung bestimmt werden. Die Häufigkeitsverteilung ergibt sich aus den Häufigkeiten von Trainingsdatensätzen zu dem bestimmten Abweichungs-

maß, welches vorteilhafterweise der Mahalanobis-Distanz, ausgewertet im latenten Zustandsraum (Latent-Space), entspricht. Aus der Verteilung des Abweichungsmaßes bzw. des Rekonstruktionsfehlers ergibt sich als Fehlerschwellenwert derjenige Wert des Abweichungsmaßes bzw. des Rekonstruktionsfehlers, der kleiner ist als die Abweichungsmaße bzw. die Rekonstruktionsfehler einer Anzahl von Trainingsdatensätzen, die einem Anteil an allen Trainingsdatensätzen entspricht, der der vorgegebenen Wahrscheinlichkeit der False-positive-Erkennung entspricht. Die Wahrscheinlichkeit kann z.B. durch Integration über die Wahrscheinlichkeitsdichtefunktion der Häufigkeitsverteilung berechnet werden.

[0032] Der Fehlerschwellenwert wird nach jedem Neutraining des Variational Autoencoders basierend auf den entsprechenden Trainingsdatensätzen neu bestimmt.

[0033] Durch Vergleich des Rekonstruktionsfehlers mit dem vorgegeben Fehlerschwellenwert kann im Betrieb eine Anomalie erkannt werden. Ein Fehler kann erkannt werden, wenn der Rekonstruktionsfehler den Fehlerschwellenwert übersteigt.

[0034] Alternativ kann eine Anomalie bzw. ein Fehler mit dem Variational Autoencoder erkannt werden, indem für einen auszuwertenden Betriebsmerkmalspunkt aus von Betriebsgrößenverläufen eines Energiespeichers ermittelten Betriebsmerkmalen eine Verteilung im latenten Zustandsraum insbesondere mithilfe der Mahalanobis-Distanz ausgewertet wird. Insbesondere kann ein Fehler erkannt werden, wenn das Abweichungsmaß größer als ein vorgegebener Fehlerschwellenwert ist. Alternativ oder zusätzlich kann das Abweichungsmaß auf Basis der Rekonstruktionsfehler des Variational Autoencoder ausgewertet werden.

[0035] Es kann hierbei ebenfalls vorgesehen sein, dass der vorgegebene Fehlerschwellenwert auf Basis einer zulässigen vorgegebenen False-positive-Wahrscheinlichkeit bestimmt wird, wobei die False-positive-Wahrscheinlichkeit einen relativen Grenzwert angibt, welcher Anteil der Auswertungen maximal zu einem fälschlich erkannten Fehler führen darf. Dazu wird zwischen einem Zentroiden der latenten Zustandsvektoren, die sich aus den Auswertungen der Eingangsgrößenvektoren der Trainingsdatensätze in dem trainierten Variational Autoencoder ergeben, und dem latenten Zustandsvektor für jeden auszuwertenden Eingangsgrößenvektor der Trainingsdatensätze die Mahalanobis-Distanz im latenten Zustandsraum (des latenten Zustandsvektors) bestimmt. Der Fehlerschwellenwert ergibt sich als derjenige Wert der Mahalanobis-Distanz, der kleiner ist als die Mahalanobis-Distanzen einer Anzahl von Trainingsdatensätzen, die einem Anteil an allen der verfügbaren Trainingsdatensätze entspricht, der der vorgegebenen False-positive-Wahrscheinlichkeit entspricht.

[0036] Somit wird insbesondere nach dem Trainingsprozess des Variational Autoencoders der Fehlerschwellenwert für die Erkennung einer Anomalie auf Basis einer vorgegebenen Wahrscheinlichkeit der False-positive-Erkennung, von z.B. 1%, als Designparameter zur Auswertung eines Abweichungsmaßes, wie der Mahalanobis-Distanz, bestimmt.

[0037] Alternativ oder zusätzlich zur Abweichungs-Analyse im latenten Zustandsraum kann aus der Verteilung der Rekonstruktionsfehler als Fehlerschwellenwert derjenige Wert des Rekonstruktionsfehler berücksichtigt werden, der kleiner ist als die Rekonstruktionsfehler einer Anzahl von Trainingsdatensätzen, die einem Anteil an allen Trainingsdatensätzen entspricht, der der vorgegebenen Wahrscheinlichkeit der False-positive-Erkennung entspricht. Die Wahrscheinlichkeit kann z.B. durch Integration über die Häufigkeitsverteilung berechnet werden.

[0038] Das Verfahren zur Auswertung des Rekonstruktionsfehlers kann geräteintern oder geräteextern in der Zentraleinheit ausgeführt werden. Eine erkannte Anomalie in einem der Energiespeicher kann in geeigneter Weise durch das Gerät oder die Zentraleinheit signalisiert werden, z. B. durch ein Überwachungstool, durch ein Mobilgerät oder dergleichen. So kann beispielsweise eine Warnmitteilung an einen Benutzer des betreffenden mit dem Energiespeicher betriebenen Geräts ausgegeben werden.

[0039] Weiterhin kann vorgesehen sein, dass ein Fehler nur dann signalisiert wird, wenn eine Plausibilitätsbedingung für das Vorliegen des Fehlers erfüllt ist. Somit wird ein Fehler nur dann signalisiert, wenn der Fehler schädlich ist.

[0040] Zudem kann eine Ausführungshäufigkeit des Verfahrens zur Bestimmung des Fehlers abhängig von der Höhe des Rekonstruktionsfehlers oder von der Höhe des Abweichungsmaßes, wie z.B. der Mahalanobis-Distanz im latenten Zustandsraum, gewählt werden.

[0041] Es kann vorgesehen sein, dass das Verfahren in dem jeweiligen Gerät ausgeführt wird, wobei insbesondere der Variational Autoencoder regelmäßig geräteextern nachtrainiert wird und resultierende Modellparameter des Variational Autoencoders an das technische Gerät übertragen wird, wo die Interpretierung der Modellparameter und die Ausführung des Verfahrens zur Fehlererkennung und Anomalie-Prädiktion durchgeführt wird. insbesondere kann der vorgegebene Fehlerschwellenwert nach einer Aktualisierung geräteextern ermittelt und an das jeweilige Gerät übertragen werden, um dort zur Ermittlung eines Fehlers verwendet zu werden.

[0042] Es kann ein Alterungszustandsmodell vorgesehen sein, das das mindestens eine Betriebsmerkmal weiterhin zur Ermittlung eines Alterungszustands in einem datenbasierten Modell verwendet.

[0043] Gemäß einer Ausführungsform kann das Signalisieren des Fehlers eine automatisierte Stilllegung des Geräts oder das Überführen des Energiespeichers in einen sicheren Zustand, insbesondere über Schnell-Entladen, oder eine Planung eines Werkstattaufenthalts zur Inspektion umfassen.

[0044] 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.

[0045] Gemäß einem weiteren Aspekt ist eine Vorrichtung zur Ermittlung einer Anomalie des Verhaltens eines elektrischen Energiespeichers in einem technischen Gerät; wobei die Vorrichtung ausgebildet ist zum:

- Erfassen eines Betriebsgrößenverlaufs der mindestens einen Betriebsgröße des elektrischen Energiespeichers;
- Bestimmen von mindestens einem Betriebsmerkmal aus dem Betriebsgrößenverlauf der mindestens einen Betriebsgröße des elektrischen Energiespeichers;
- Auswerten eines Variational Autoencoders mit einem zugeführten Eingangsgrößenvektor, der einen Betriebsmerkmalspunkt aus dem mindestens einen Betriebsmerkmal umfasst, um ein Abweichungsmaß aus einer Verteilung in einem latenten Zustandsraum oder einen Rekonstruktionsfehler zu bestimmen;
- Erkennen eines Fehlers abhängig von dem Abweichungsmaß bzw. dem Rekonstruktionsfehler und weiterhin abhängig von einem vorgegebenen Fehlerschwellenwert;
- Signalisieren des Fehlers.

Figurenliste

[0046] 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 und zur Durchführung einer Anomalieerkennung einer Fahrzeugbatterie in einer Zentraleinheit;

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

Fig. 3 eine schematische Darstellung eines Variational Autoencoders;

Fig. 4 ein Flussdiagramm zur Veranschaulichung eines Verfahrens zur Ermittlung einer Anomalie des Verhaltens eines elektrischen Energiespeichers;

Fig. 5 ein Diagramm zur Darstellung der Verteilung der Häufigkeit eines Werts eines Abweichungsmaßes, wie der Mahalanobis-Distanz;

Fig. 6 ein Diagramm zur Darstellung der Verteilung der Häufigkeiten eines Werts eines Abweichungsmaßes für Trainingsdatensätze für ordnungsgemäße Fahrzeugbatterien und fehlerbehaftete Fahrzeugbatterien; und

Fig. 7 ein ROC-Diagramm zu den Häufigkeiten eines Abstandsmaßes bzw. Rekonstruktionsfehlers von ordnungsgemäßen und fehlerhaften Fahrzeugbatterien.

Beschreibung von Ausführungsformen

[0047] 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, in dessen Rahmen Betriebsmerkmale für den Betrieb der Fahrzeugbatterie bestimmt werden. Diese Betriebsmerkmale eignen sich in vorteilhafter Weise zur Durchführung einer Anomalieerkennung.

[0048] Das hierin beschriebene 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.

[0049] Für das hierin beschriebene Verfahren ist die Ermittlung des Alterungszustands nicht wesentlich, bietet aber die Möglichkeit, die darin verwendeten Betriebsmerkmale für das Verfahren zur Anomalieerkennung zu nutzen.

[0050] **Fig. 1** zeigt ein System 1 zum Sammeln von Flottendaten in einer Zentraleinheit 2 zur Erstellung und zum Betrieb sowie zur Auswertung eines Alterungszustandsmodells und zur Durchführung einer Anomalieerkennung. 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.

[0051] 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.

[0052] Die Kraftfahrzeuge 4 senden an die Zentraleinheit 2 die Betriebsgrößen F, die zumindest Größen angeben, aus welchen der Belastungszustand der Fahrzeugbatterie 41 abgeleitet werden kann. 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.

[0053] 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.

[0054] In der Zentraleinheit 2 sind Modelle implementiert, wie ein Anomalieerkennungsmodell und ein Alterungszustandsmodell, das als hybrides Modell teilweise datenbasiert sein kann. Weiterhin ist eine vollautomatisierte Pipeline zum Training und zum Deployment der Modelle in die jeweiligen Geräte implementiert, welches zur regelmäßigen und wiederkehrenden Parametrisierung, Validierung und Aktualisierung von Modellen oder Modellparametern eingesetzt wird. 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.

[0055] 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.

[0056] Fig. 2 zeigt beispielhaft schematisch den funktionalen Aufbau einer Ausführungsform eines beispielhaften datenbasierten Alterungszustandsmodells 9, das in einer hybriden Weise aufgebaut ist. Das Alterungszustandsmodell 9 umfasst ein physikalisches Alterungsmodell 5 und ein datengetriebenes, vorzugsweise probabilistisches Korrekturmodell 6.

[0057] 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.

[0058] 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.

[0059] 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.

[0060] 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.

[0061] Das Korrekturmodell 6 erhält eingangsseitig Betriebsmerkmale M, die durch feature engineering 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 des elektrochemischen physikalischen Alterungsmodells sowie vorteilhafterweise der physikalische Alterungszustand SOH_{ph}.

[0062] 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.

[0063] Die Betriebsmerkmale M können beispielsweise auf den Auswertungszeitraum bezogene Merkmale und/oder akkumulierte Merkmale und/oder über die gesamte bisherige Lebensdauer ermittelte statistische Größen bzw. aggregierte Größen umfassen. Insbesondere können die Betriebsmerkmale beispielsweise umfassen: Elektrochemische Zustände, wie z.B. SEI-Schichtdicke, Masse oder Mengen-Änderung von zyklisierbarem Lithium aufgrund von Anoden/Kathoden-Nebenreaktionen, schnelle Aufnahme von Elektrolytlösungsmitteln, 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 Histogrammdaten 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.

[0064] 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.

[0065] Es kann zur Anomalieerkennung ein Variational Autoencoder als Anomalieerkennungsmodell 11 vorgesehen sein, dem der Betriebsmerkmalspunkt M zugeführt wird. Das Anomalieerkennungsmodell 11 kann mit einem Variational Autoencoder ausgeführt sein. Der Variational Autoencoder wird vorzugsweise in der Zentraleinheit trainiert und - nach Übertragen der Modellparameter an das bzw. die betreffenden Fahrzeuge im Fahrzeug in Echtzeit ausgewertet, indem ein Abstandsmaß, wie die Mahalanobis-Distanz, in dem latenten Zustandsraum des Variational Autoencoders oder alternativ ein Rekonstruktionsfehler ausgewertet wird, insbesondere durch einen Schwellenwertvergleich. Als Ergebnis des Schwellenwertvergleichs wird ein Fehler-signal S ausgegeben.

[0066] Neben einem oder mehreren der Betriebsmerkmale M, die sich bereit aus der Implementierung des hybriden Alterungszustandsmodells ergeben können, ist es ein Kern des hierin beschriebenen Verfahrens, eine Anomalieerkennung mithilfe eines zentral-trainierten Anomalieerkennungsmodells durchzuführen, insbesondere einem Variational Autoencoder basierend auf diversen domänenbasierten Betriebsmerkmalen, die sich aus dem Betrieb des Energiespeichers und ggfs der Implementierung des oben beschriebenen Alterungszustandsmodells ergeben. Zu den Betriebsmerkmalen kann auch der modellierte Alterungszustand gehören.

[0067] Der Variational Autoencoder des Anomalieerkennungsmodells 11 kann basierend auf Betriebsgrößenverläufen der Vielzahl von Fahrzeugbatterien 41 der Fahrzeugflotte 3, insbesondere zu unterschiedlichen zyklischen und / oder kalendarischen Alterungszuständen bestimmt werden. Die Betriebsmerkmale können weiterhin umfassen: Statistische Momente der Verteilungen von Spannung, Strom oder Temperatur (wie Erwartungswert, Varianz, Schiefe, ...) sowie modell-endogene Parameter und / oder modell-exogene Parameter elektrochemischer Modelle, wie Porositäten, SEI-Dicken, verfügbares Lithium, Diffusionskoeffizienten, Kontaktwiderstände, verfügbares Aktivmaterial, Elektrolytkonzentrationen, sowie histogramm-basierte Merkmale, wie z.B. SOC-Temperatur-Histogramme, bewertet mit Penalty-Funktionen zur Einarbeitung von Domänenwissen.

[0068] Fig. 3 zeigt schematisch einen Variational Autoencoder 50 mit einem Encoder 51 und einem Decoder 52. Encoder 51 und Decoder 52 sind über einen latenten Zustandsraum verbunden. Encoder 51 und Decoder 52 können als tiefes neuronales Netz oder mit einem anderen datenbasierten Regressionsmodell ausgebildet sein. Der Variational Autoencoder 50 ist trainiert, um einen Eingangsgrößenvektor x einem identischen Ausgangsgrößenvektor $\hat{x}$ zuzuordnen, wobei eine Verteilung von resultierenden latenten Zustandsvektoren in dem latenten Zustandsraum einer vorgegebenen Verteilung, insbesondere einer Gaußverteilung folgt.

[0069] Das Training des Variational Autoencoders 50 erfolgt zum einen zur Abbildung des Eingangsgrößenvektors auf einen Ausgangsgrößenvektor und so, dass der Encoder 51 trainiert wird, um eine vorgegebene Verteilung des latenten Zustandsvektors in einem latenten Zustandsraum zu erhalten. Das Training erfolgt basierend auf einer Loss-Funktion, die sowohl den Rekonstruktionsfehler als auch eine Kullbeck-Leibler Divergenz berücksichtigt. Dadurch wird ein Overfitting des latenten Zustandsraum vermieden bzw. unterdrückt.

[0070] Wie eingangs beschrieben kann eine lösbar variationelle Inferenz durchgeführt werden, um μ_x and σ_x durch Minimierung der Kullback-Leibler Divergenz zu bestimmen:

$$\operatorname{argmin}_{z \sim q(z|x)} [\log p(x|z)] - KL(q(z|x) || p(z))$$

[0071] Der erste Term $\log p(x|z)$ stellt dabei die Rekonstruktionswahrscheinlichkeit dar, die den Rekonstruktionsfehler bestraft und der zweite Term $KL(q(z|x) || p(z))$ stellt sicher, dass die Verteilung $q(z|x)$ der wahren prior Verteilung von $p(z)$ ähnelt.

[0072] Die zu minimierende Loss-Funktion I ist für $c > 0$ wie folgt definiert:

$$I = c \|x - \hat{x}\|^2 + KL(N(\mu_x, \sigma_x) || N(0, I))$$

[0073] Das Training erfolgt basierend auf Trainingsdatensätzen mit Betriebsmerkmalspunkten, bei denen die Loss-Funktion durch Training von Decoder und Encoder sukzessive mithilfe herkömmlicher Trainingsverfahren minimiert wird.

[0074] Eine Anomalie bzw. ein Fehlverdacht kann mit dem Variational Autoencoder erkannt werden, indem für einen auszuwertenden Betriebsmerkmalspunkt aus von Betriebsgrößenverläufen eines Energiespeichers ermittelten Betriebsmerkmalen ein Abstandsmaß bezüglich der Verteilung im latenten Zustandsraum oder der Rekonstruktionsfehler ausgewertet wird. insbesondere kann eine Anomalie erkannt werden, wenn eine Abweichung zwischen der aktuellen Auswertung und dem Abstandsmaß oder dem Rekonstruktionsfehler erkannt wird, die größer ist als ein vorgegebener Fehlerschwellenwert. Der Fehlerschwellenwert ergibt sich aus einer Auswertung der verfügbaren Trainingsdaten.

[0075] Fig. 4 zeigt ein Flussdiagramm zur Veranschaulichung eines Verfahrens zur Anomalieerkennung des Verhaltens von Fahrzeugbatterien 41 als Beispiel für Energiespeicher von Fahrzeugen 4 einer Fahrzeugflotte 3 (entsprechend den Geräten der Vielzahl von Geräten). Das Verfahren wird in der Zentraleinheit 2 ausgeführt. Die übliche Ausführungsfrequenz des Verfahrens ist batterieindividuell und kann einer wöchentlichen Ausführung als Standard-Fall bei keinem akuten Anomalie-Verdacht entsprechen.

[0076] In Schritt S1 findet ein herkömmlicher Betrieb des hybriden Alterungsmodells 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. Das wie oben beschrieben ermittelte Fehlermerkmal kann sowohl in dem Fahrzeug 4 als auch in der Zentraleinheit 2 bestimmt werden.

[0077] In Schritt S2 werden zu vorgegebenen Zeitpunkten die Betriebsgrößenverläufe ausgewertet, um Betriebsmerkmale M für jede der betreffenden Gerätebatterien 41 zu ermitteln. Dies kann im Rahmen der Auswertung des Alterungszustandsmodells erfolgen. Dazu wird aus den Betriebsgrößenverläufen direkt durch das physikalische Alterungsmodell 5 ein physikalischer Alterungszustand SOH_{ph} ermittelt und Betriebsmerkmale M , wie oben beschrieben, aktualisiert bzw. ermittelt.

[0078] Das eine oder die mehreren Betriebsmerkmale M können als Eingangsgrößenvektor x für den Variational Autoencoder 50 dienen. Das eine oder die mehreren Betriebsmerkmale M werden in Schritt S3 dem Variational Autoencoder 50 als Anomalieerkennungsmodell 11 zugeführt und ausgewertet, der zuvor mit Betriebsmerkmalspunkten einer Vielzahl von ordnungsgemäß arbeitenden Fahrzeugbatterien 41 trainiert worden ist.

[0079] Durch Auswertung des Variational Autoencoders 50 mit dem Betriebsmerkmalspunkt M der betreffenden auszuwertenden Fahrzeugbatterie 41 kann eine resultierende Verteilung im latenten Zustandsraum in Form der Information eines Mittelwertvektors und der Varianzvektors mithilfe der Mahalanobis-Distanz zu einem Zentroiden der Verteilung im latenten Zustandsraum (des Normal-Clusters), der sich aus den Auswertungen der zur Verfügung stehenden Trainingsdatensätze für den Variational Autoencoder 50 ergeben hat, ermittelt und bewertet werden. Das resultierende Abweichungsmaß zwischen dem Zentroiden und dem aktuellen latenten Zustandsvektor der Fahrzeugbatterie 41 (durch Auswertung des Eingangsgrößenvektors des Betriebsmerkmalspunkts) kann mithilfe der Mahalanobis-Distanz bestimmt werden.

[0080] In Schritt S4 wird das Abweichungsmaß vorteilhafterweise die Mahalanobis-Distanz, mit einem Fehlerschwellenwert verglichen. Der Fehlerschwellenwert kann fest vorgegeben sein oder aus dem aktuellen Trainingszustand des Variational Autoencoders und den dafür verwendeten Trainingsdatensätzen bestimmt werden.

[0081] Der Fehlerschwellenwert für die Erkennung einer Anomalie wird auf Basis einer zulässigen vorgegebenen Wahrscheinlichkeit einer False-positive-Erkennung, von z.B. einem vorgegebenen Maximalwert, wie beispielsweise 1%, als Designparameter bestimmt. Diese False-positive-Wahrscheinlichkeit wird zur Auswertung und zum Abgleich einer Häufigkeitsverteilung genutzt, um den Fehlerschwellenwert zu dimensionieren. Die Häufigkeitsverteilung ergibt sich aus der Verteilung im latenten Zustandsraum des Normal-Clusters aller Trainingsdatensätze und kann über die sich ergebende Mahalanobis-Distanz charakterisiert werden.

[0082] Durch Integration über die Häufigkeitsverteilung kann die Wahrscheinlichkeit bestimmt werden. Durch Anpassung des Fehlerschwellenwertes kann der Fehlerschwellenwert genau so eingestellt werden, dass das gewünschte Kriterium, nämlich z.B. die 1 % (auch andere Vorgaben sind möglich) False-Positive-Wahrscheinlichkeit, auf Basis sämtlicher verfügbarer Trainingsdaten hinreichend genau erfüllt ist.

[0083] Die Bewertung der Verteilung bzw. der Abstände der resultierenden latenten Zustandsvektoren im latenten Zustandsraum erfolgt vorzugsweise mithilfe der Mahalanobis-Distanz.

[0084] Dies ist beispielhaft in **Fig. 5** dargestellt. Hier sind die relativen Häufigkeiten r_H des Auftretens von bestimmten Wertebereichen der Abweichungsmaße bzw. der Mahalanobis-Distanz MD dargestellt. Der schraffierte Bereich entspricht dem Bereich der False-Positive-Erkennungen. Der Fehlerschwellenwert Thr gibt die Grenze der Trainingsdatensätze an, die 1 % der höchsten Abweichungsmaße, z.B. auf Basis der Mahalanobis-Distanz, bzw. der Rekonstruktionsfehler aufweisen.

[0085] Wird in Schritt S5 festgestellt, dass der Fehlerschwellenwert durch das Abweichungsmaß der Verteilung im Zustandsraum oder durch den Rekonstruktionsfehler überschritten wird (Alternative: Ja), so wird das Verfahren mit Schritt S6 fortgesetzt, andernfalls (Alternative: Nein) wird zu Schritt S1 zurückgesprungen. Dieser Schwellwertabgleich erfolgt vorzugsweise im Fahrzeug. Da der Variational Autoencoder eine Verteilung im robusten latenten Zustandsraum erlernt hat, ist eine robuste Ausführung im Fahrzeug in Echtzeit möglich, auch wenn keine Cloud-Verbindung vorliegt.

[0086] In Schritt S6 wird basierend auf einem oder mehreren Domänenmodellen die Erkennung einer Anomalie bzw. des Fehlerverdachts plausibilisiert, indem überprüft wird, ob eine Plausibilitätsbedingung für das Vorliegen des Fehlers erfüllt ist. Diese Domänenmodelle umfassen vorteilhafterweise regelbasierte Schadensrichtungen mindestens eines Merkmals.

[0087] Dazu werden die Betriebsmerkmale des aktuellen Betriebsmerkmalspunkts für die Merkmalsverteilungen der berücksichtigten Betriebsmerkmale, zumindest Mittelwert und Standardabweichung, basierend auf der letzten Parametrisierung des Variational Autoencoders bewertet. Somit kann die Bewertung auf Basis der Kovarianz-Matrix erfolgen.

[0088] Hierbei wird auf eine Belastungs-Relevanz-Richtung modelliert. Wenn das aktuelle Betriebsmerkmal des Betriebsmerkmalspunkts einen Grenzwert überschreitet bzw. unterschreitet (je nach Richtung der höheren Belastung) z.B. einen Mittelwert, ist die Plausibilisierungsbedingung erfüllt und die Anomalie bzw. der Fehlerverdacht erfolgreich plausibilisiert.

[0089] Wenn beispielsweise der Mittelwert des AH-Durchsatzes bei 10.000 AH bei einer Standardabweichung von 200 AH liegt und der Mittelwert des Alterungszustands, ausgewertet auf Basis von umfassenden Flotten-Daten, z.B. mithilfe des beschriebenen Alterungsmodells, bei 10.000 AH bei einem SOH = 0.9 liegen, so kann trotz einer Erkennung einer Anomalie bei einem aktuellen AH-Durchsatz von 10.000 AH und einem Alterungszustand von SOH = 0.94 der erkannte Fehler verworfen werden, weil die Alterung besser als Flotten-Durchschnitt ist und folglich trotz datenbasierte Anomalie keine Schädlichkeit vorliegt.

[0090] Wenn das Betriebsmerkmal des AH-Durchsatzes 10.000 AH beträgt und der Alterungszustand 0.8, wird der Fehlerverdacht bestätigt und ein Fehler erkannt, da eine zu starke Alterung vorliegt, die nicht zum Nutzmuster passt. Die Auswertung findet generell in einem mehrdimensionalen Merkmalsraum statt, in welchem vorteilhafterweise redundante Information über eine PCA-Transformation eliminiert werden kann.

[0091] Die Auswertung kann anhand der Kovarianzmatrix bzw. des Mahalanobis-Abstandes im Merkmalsraum der Betriebsmerkmale, unter Berücksichtigung der Alterungszustände, wobei jedem Betriebsmerkmal und Alterungszustand eine Belastungs-Relevanzrichtung oder eine Richtung des Anomaliegrades zugeordnet ist.

[0092] Hierbei kann mindestens ein Betriebsmerkmal M ausgewertet werden. Vorzugsweise erfolgt die Bewertung auf Basis von mehreren Betriebsmerkmalen, zum Beispiel um den Fehlerverdacht bzw. die Anomalie bzgl. ihrer Schadensrelevanz zu bewerten, z.B. im Hinblick auf eine kalendarische Alterung, eine zyklische Alterung und spezielle Schadensfälle, wie Overheating durch z.B. durch Re-Rating Setpoint im Zuge von Temperatur-Lasten.

[0093] Insgesamt erfolgt die Bewertung anhand einer oder mehrerer Plausibilisierungsbedingungen, mit der beurteilt werden kann, ob die Anomalie bzw. der Fehlerverdacht kritisch ist. Dies kann vorteilhafterweise ebenfalls mit der Mahalanobis-Distanz oder alternativ über Mittelwert- und Varianz-Abgleich der einzelnen Betriebsmerkmale durchgeführt werden, wobei jeweils eine Schädlichkeits-Richtung vorgegeben ist. Die Plausibilisierungsbedingungen können als Expertenwissen vorgegeben sein.

[0094] Wird in Schritt S6 festgestellt, dass die erkannte Anomalie durch die Plausibilisierungsbedingung als tatsächliche Anomalie bestätigt wird (Alternative: Ja), so wird in Schritt S7 ein Fehler signalisiert. Andernfalls (Alternative: Nein) wird zu Schritt S1 zurückgesprungen.

[0095] Durch diesen Schritt sollen False-Positive-Ergebnisse ausgeschlossen oder deutlich reduziert werden. Wenn z.B. ein Fahrzeug längere Zeit, z.B. über mehrere Jahre hinweg stillsteht, könnte der Variational Autoencoder 50 aufgrund der Datenlage eine Anomalie feststellen. Da dies jedoch für die Fahrzeugbatterie 41 nicht kritisch sein dürfte, wenn der Alterungszustand der Batterie in einem erwartbaren Bereich liegt, wird die erkannte Anomalie nicht bestätigt.

[0096] Der Variational Autoencoder 50 kann bei Vorliegen neuer Betriebsmerkmalspunkte neu trainiert werden. Dies kann in Verbindung mit der Ermittlung eines aktualisierten Fehlerschwellenwert erfolgen.

[0097] Während das Training des Variational Autoencoders und die Ermittlung des Fehlerschwellenwerts in der Zentraleinheit 2 durchgeführt werden, kann das Verfahren zur Anomalieerkennung nach Übertragen von Modellparametern, die die Bedienung des Variational Autoencoders definieren, und des Fehlerschwellenwerts an das betreffende Fahrzeug fahrzeugintern erfolgen, sodass keine Abhängigkeit der Anomalie-Erkennungsfunktion von einer Kommunikationsverbindung zur Zentraleinheit 2 (Cloud) besteht.

[0098] Die Auswertung hinsichtlich einer Erkennung einer Anomalie kann regelmäßig und insbesondere gleichzeitig mit der Ermittlung des Alterungszustands mithilfe des hybriden Alterungszustandsmodells 9 durchgeführt werden, da zu diesem Zeitpunkt die für das Korrekturmodell 6 benötigten Betriebsmerkmalspunkte M aus den neu erfassten Betriebsgrößenverläufen ermittelt werden.

[0099] Der Variational Autoencoder wird regelmäßig in der Zentraleinheit 2 basierend auf sämtlichen neu erfassten Normaldaten neu trainiert und der Fehlerschwellenwert basierend auf der vorgegebenen False-Positive-Wahrscheinlichkeit neu parametrisiert. Ein automatisiertes Übertragen der Modellparameter des Variational Autoencoders zum Fahrzeug kann anschließend durchgeführt werden.

[0100] Mit Bezug zu **Fig. 6**, kann der Fehlerschwellenwert zusätzlich auch nach Erkennen von Fehlerfällen basierend auf einer sich aus den Trainingsdatensätzen von fehlerfreien Fahrzeugbatterien ergebende Häufigkeitsverteilungen H1 des Abweichungsmaßes bzw. des Rekonstruktionsfehlers für fehlerfreie Fahrzeugbatterien und einer Häufigkeitsverteilung H2 des Abweichungsmaßes bzw. des Rekonstruktionsfehlers für fehlerbehaftete Fahrzeugbatterien bestimmt werden. Der Fehlerschwellenwert kann dann beispielsweise als Schnittpunkt der Häufigkeitsverteilungen, als F-score oder allgemein aus den Verläufen der Häufigkeitsverteilungen H1, H2 bestimmt werden.

[0101] Weiterhin kann ein Klassifikationsmodell trainiert werden basierend auf den Betriebsmerkmalspunkten von ordnungsgemäßen und fehlerbehafteten Fahrzeugbatterien, vorzugsweise mit logistischer Regression, um False Positives und False-Negatives zu bewerten und eine ROC-Analyse abzuleiten. Vorteilhafterweise kann dieses Modell zusätzlich zum Variational Autoencoder oder alternativ im Fahrzeug ausgeführt werden. Der Fehlerschwellenwert kann nun auf Basis der False-Positive und der False-Negativ-Rate ausgelegt werden.

[0102] Wie in dem ROC-Diagramm (ROC: Receiver Operating Characteristics) der **Fig. 7** ersichtlich ist, kann dies durchgeführt werden, z.B. indem der minimale Abstand der ROC-Kurve zum Punkt ($FPR=0 \mid TPR = 1$) verwendet wird, um einen optimalen Fehlerschwellwert abzuleiten. Ein ROC-Diagramm ist ein Diagramm, in dem die True-Positive-Rate TPR gegen die False-Positive-Rate aufgetragen ist. Es ergeben sich Werte für FPR und TPR, denen entsprechend den Häufigkeitsverteilungen der **Fig. 6** ein Abstandsmaß oder ein Rekonstruktionsfehler als Fehlerschwellenwert zugeordnet werden kann. Hierbei wird wie beim Variational Autoencoder das Abstandsmaß, wie die Mahalanobis-Distanz als Merkmal zur Auslegung des Grenzwertes verwendet. Der Klassifikator kann ein logistisches Regressionsmodell umfassen.

[0103] Anschließend kann der Fehlerschwellwert im Fahrzeug entsprechend angepasst werden.

[0104] Die Anomalie-Erkennung kann weiterhin mithilfe des Variational Autoencoders erfolgen. Zusätzlich, ergänzend oder alternativ kann auch der Klassifikator zur Erkennung der Anomalie eingesetzt werden.

Patentansprüche

1. Computerimplementiertes Verfahren zur Ermittlung eines Fehlers des Verhaltens eines elektrischen Energiespeichers (41) in einem technischen Gerät (4); mit folgenden Schritten:

- Erfassen (S1) eines Betriebsgrößenverlaufs der mindestens einen Betriebsgröße des elektrischen Energiespeichers (41);
- Bestimmen (S2) von mindestens einem Betriebsmerkmal (M) aus dem Betriebsgrößenverlauf (F) der mindestens einen Betriebsgröße des elektrischen Energiespeichers (41);
- Auswerten (S3) eines Variational Autoencoders (50) mit einem zugeführten Eingangsgrößenvektor (x), der einen Betriebsmerkmalspunkt (M) aus dem mindestens einen Betriebsmerkmal (M) umfasst, um ein Abweichungsmaß aus einer Verteilung in einem latenten Zustandsraum oder einen Rekonstruktionsfehler zu bestimmen;
- Erkennen (S4, S5) eines Fehlers abhängig von dem Abweichungsmaß bzw. dem Rekonstruktionsfehler und weiterhin abhängig von einem vorgegebenen Fehlerschwellenwert;
- Signalisieren (S7) des Fehlers.

2. Verfahren nach Anspruch 1, wobei das mindestens eine Betriebsmerkmal (M) aus dem Betriebsgrößenverlauf der mindestens einen Betriebsgröße des elektrischen Energiespeichers (41) als aggregierte Größe bestimmt wird.

3. Verfahren nach Anspruch 1 oder 2, wobei der vorgegebene Fehlerschwellenwert auf Basis einer zulässigen vorgegebenen False-positive-Wahrscheinlichkeit bestimmt wird, wobei die False-positive-Wahrscheinlichkeit ein relativer Grenzwert angibt, welcher Anteil der Auswertungen maximal zu einem fälschlich erkannten Fehler führen dürfen, wobei eine Häufigkeitsverteilungsfunktion aus den Häufigkeiten des Auftretens eines bestimmten Werts (oder Wertebereichs) des Abweichungsmaßes der Verteilung im latenten Zustandsraum bzw. des Rekonstruktionsfehlers bei einer Auswertung von verfügbaren Trainingsdatensätzen bestimmt wird, wobei sich der Fehlerschwellenwert als derjenige Wert des Abweichungsmaßes der Verteilung im latenten Zustandsraum bzw. des Rekonstruktionsfehlers ergibt, der kleiner ist als die Abweichungsmaße bzw. Rekonstruktionsfehler einer Anzahl von Trainingsdatensätzen, die einem Anteil an allen der verfügbaren Trainingsdatensätze entspricht, der der vorgegebenen False-positive-Wahrscheinlichkeit entspricht.

4. Verfahren nach Anspruch 1 oder 2, wobei nach dem Vorliegen von Felddaten von Fehlern in Energiespeichern (41) der vorgegebene Fehlerschwellenwert auf Basis einer sich aus den Trainingsdatensätzen von fehlerfreien Energiespeichern (41) ergebende False-Positive-Häufigkeitsverteilung und einer False-Negative-Häufigkeitsverteilung bestimmt wird.

5. Verfahren nach einem der Ansprüche 1 bis 4, wobei ein Fehler erkannt wird, wenn das Abweichungsmaß der Verteilung im latenten Zustandsraum bzw. der Rekonstruktionsfehler den Fehlerschwellenwert übersteigt.

6. Verfahren nach einem der Ansprüche 1 bis 5, wobei ein Fehler nur dann signalisiert wird, wenn eine Plausibilitätsbedingung für das Vorliegen des Fehlers erfüllt ist.

7. Verfahren nach Anspruch 6, wobei die Plausibilitätsbedingung einen Vergleich eines oder mehrerer Betriebsmerkmale (M) des Betriebsmerkmalspunkts des Energiespeichers (41) mit einem jeweiligen Mittel-

wert des einen oder der mehreren Betriebsmerkmale umfasst und ein Fehler plausibilisiert wird, wenn mindestens einer des einen oder der mehreren Betriebsmerkmale (M) den jeweiligen Mittelwert überschreiten.

8. Verfahren nach einem der Ansprüche 1 bis 7, wobei das Verfahren in dem jeweiligen Gerät (4) ausgeführt wird, wobei insbesondere der Variational Autoencoder (50) regelmäßig geräteextern nachtrainiert wird und Modellparameter des Variational Autoencoders (50) an das technische Gerät (4) übertragen wird, wobei insbesondere der vorgegebene Fehlerschwellenwert geräteextern ermittelt wird und an das jeweilige Gerät (4) übertragen wird, um dort zur Ermittlung eines Fehlers verwendet zu werden.

9. Verfahren nach einem der Ansprüche 1 bis 8, wobei das Abweichungsmaß als euklidische Distanz zwischen einem Zentroiden der latenten Zustandsvektoren, die sich aus den Auswertungen der Eingangsgrößenvektoren der Trainingsdatensätze in dem trainierten Variational Autoencoder (50) ergeben, und dem latenten Zustandsvektor für den auszuwertenden Eingangsgrößenvektor (x) oder als Mahalanobis-Distanz zwischen dem Zentroiden der latenten Zustandsvektoren, die sich aus den Auswertungen der Eingangsgrößenvektoren (x) der Trainingsdatensätze in dem trainierten Variational Autoencoder (50) ergeben, und dem latenten Zustandsvektor für den auszuwertenden Eingangsgrößenvektor (x) bestimmt wird, bzw. wobei der Rekonstruktionsfehler als euklidische Distanz zwischen einem Ausgangsgrößenvektor ($\hat{x}$) des Variational Autoencoders (50) und dem auszuwertenden Eingangsgrößenvektor (x) bestimmt wird.

10. Verfahren nach einem der Ansprüche 1 bis 9, wobei ein Alterungszustandsmodell vorgesehen ist, das das mindestens eine Betriebsmerkmal (M) weiterhin zur Ermittlung eines Alterungszustands in einem datenbasierten Modell verwendet.

11. Verfahren nach einem der Ansprüche 1 bis 10, wobei das Signalisieren des Fehlers eine automatisierte Stilllegung des Geräts (4) oder das Überführen des Energiespeichers (41) in einen sicheren Zustand, insbesondere über Schnell-Entladen, oder eine Planung eines Werkstattaufenthalts zur Inspektion umfasst.

12. Verfahren nach einem der Ansprüche 1 bis 11, wobei der Energiespeicher (41) zum Betrieb eines Geräts (4), 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.

13. Vorrichtung zur Ermittlung einer Anomalie des Verhaltens eines elektrischen Energiespeichers (41) in einem technischen Gerät (4); wobei die Vorrichtung ausgebildet ist zum:


- Erfassen eines Betriebsgrößenverlaufs der mindestens einen Betriebsgröße des elektrischen Energiespeichers (41);
- Bestimmen von mindestens einem Betriebsmerkmal (M) aus dem Betriebsgrößenverlauf der mindestens einen Betriebsgröße des elektrischen Energiespeichers (41);
- Auswerten eines Variational Autoencoders (50) mit einem zugeführten Eingangsgrößenvektor (x), der einen Betriebsmerkmalspunkt aus dem mindestens einen Betriebsmerkmal (M) umfasst, um ein Abweichungsmaß aus einer Verteilung in einem latenten Zustandsraum oder einen Rekonstruktionsfehler zu bestimmen;
- Erkennen eines Fehlers abhängig von dem Abweichungsmaß bzw. dem Rekonstruktionsfehler und weiterhin abhängig von einem vorgegebenen Fehlerschwellenwert;
- Signalisieren des Fehlers.

14. 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.

15. 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 6 Seiten Zeichnungen

Anhängende Zeichnungen






FIG. 2




FIG. 3




FIG. 4





FIG. 5




FIG. 6




FIG. 7