



(12) **Offenlegungsschrift**

(21) Aktenzeichen: **10 2019 209 797.9**

(22) Anmeldetag: **03.07.2019**

(43) Offenlegungstag: **07.01.2021**

(51) Int Cl.: **G07C 5/00 (2006.01)**

(71) Anmelder:
thyssenkrupp AG, 45143 Essen, DE

(72) Erfinder:
**Schön, Nico, 45127 Essen, DE; Wei, Sophie
Ruoshan, 80469 München, DE**

(56) Ermittelter Stand der Technik:

DE	10 2006 057 342	A1
DE	10 2015 212 923	A1
DE	10 2016 208 048	A1
DE	11 2016 006 448	T5
US	2015 / 0 363 925	A1
US	2019 / 0 102 840	A1
EP	2 905 665	A2

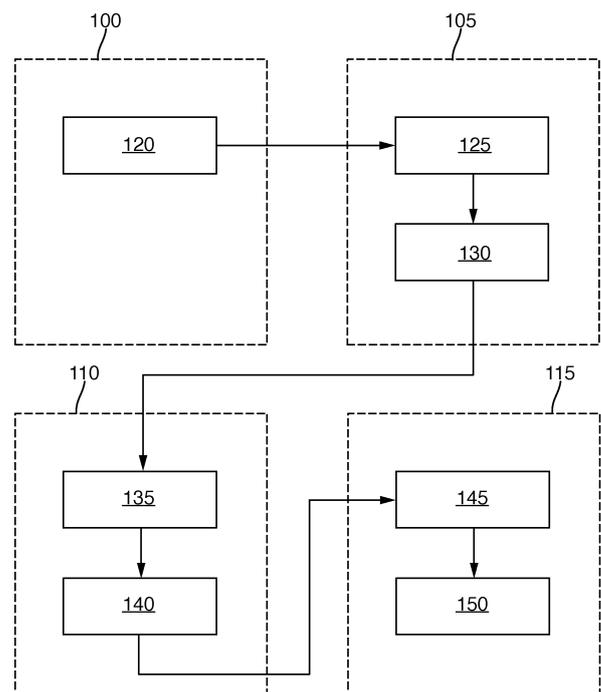
Prüfungsantrag gemäß § 44 PatG ist gestellt.

Die folgenden Angaben sind den vom Anmelder eingereichten Unterlagen entnommen.

(54) Bezeichnung: **Verfahren und Einrichtung zur Ermittlung des fahrbetriebsbedingten Zustandes von Karosseriekomponenten eines Fahrzeugs sowie eines entsprechenden Fahrerverhaltens**

(57) Zusammenfassung: Das beschriebene Verfahren zur Ermittlung des Zustandes wenigstens einer mechanischen Komponente eines Fahrzeugs, wobei in dem Fahrzeug wenigstens ein Sensor zur Erfassung mindestens einer mechanischen Größe angeordnet ist, sieht insbesondere die folgenden Schritte vor:

- Fensterung (100) der von dem wenigstens einen Sensor erfassten Sensordaten in eine empirisch vorgebbare Fensterlänge,
- Merkmalsextraktion (105) zur Bereitstellung charakteristischer Merkmale in den Sensordaten anhand von zu erzeugenden Merkmalsvektoren,
- Segmentierung (110) der erzeugten Fenster in Segmente unterschiedlicher Länge,
- Klassifizierung (115) der Sensordaten anhand der erzeugten Merkmalsvektoren.



Beschreibung

[0001] Die Erfindung betrifft ein Verfahren und eine Einrichtung zum Ermitteln bzw. Überwachen des fahrbetriebsbedingten Zustandes von Fahrgestell- bzw. Karosseriekomponenten eines Fahrzeugs sowie eines entsprechend zugrundeliegenden Fahrer- verhaltens.

Stand der Technik

[0002] Über die individuelle Nutzungshistorie von Fahrzeugen gibt es heutzutage wenig bis gar keine Transparenz. Daher kann der resultierende Fahrzeugzustand und der Grad des Verschleißes insbesondere von Fahrgestell- und Karosseriebauteilen nicht automatisch auf einer regelmäßigen, z.B. täglichen Basis ermittelt werden, da die zugrundeliegende Nutzungshistorie bezüglich mechanischer Belastungen, Stöße oder anderer Ereignisse bzw. Vorfälle aufgrund des individuellen Fahrverhaltens oder der Straßenbedingungen nicht bekannt ist.

[0003] Darüber hinaus haben Fahrzeughersteller sehr heterogene und proprietäre Sensorsysteme an Bord, die dem Fahrzeugbesitzer oder -betreiber nur sehr begrenzten Zugang gewähren, um solche Sensordaten für ihre eigenen Fahrzeug- oder Flottendiagnosezwecke zu verwenden. In der Industrie besteht daher eine zunehmende Nachfrage nach leicht nachrüstbaren und fahrzeugunabhängigen Sensorsystemen zur kontinuierlichen Überwachung und Analyse von Fahrzeugdaten, und zwar unter besonderer Berücksichtigung von Erfassung und Quantifizierung von mechanischen Belastungen wie z.B. Stößen oder anderen Schadensfällen sowie von Missbrauchsfällen aufgrund eines individuellen Fahrverhaltens des jeweiligen Fahrers oder der im Fahrbetrieb vorgelegenen Straßenbedingungen.

[0004] Aus DE 10 2009 025 278 A1 gehen ein Verfahren und ein Gerät zur Bewertung der Fahrzeugabnutzung zur Abrechnung von zur Nutzung überlassenen Kraffahrzeugen hervor. Das Verfahren nutzt dabei das Gerät zur Ermittlung von Kennziffern, die im Wesentlichen Verschleiß verursachende und auf die Räder wirkende Kräfte repräsentieren. Das Gerät kann unabhängig vom Fahrzeug und ausschließlich mit geräteinternen Einrichtungen betrieben werden. Während der Fahrt des Fahrzeugs registriert das Gerät die zurückgelegte Wegstrecke und Verschleiß verursachende und auf die Räder wirkende Kräfte. Anhand dieser Informationen wird eine den momentanen Fahrstil repräsentierende Kennziffer ermittelt, mittels der Mietvorgänge des Fahrzeugs so optimiert werden können, dass der Vermieter im Mittel einen nutzungsabhängig kalkulierten Mietpreis erzielt. Das Gerät kann dem Fahrer über eine Anzeigeeinheit die Kennziffer zum Beispiel grafisch anzeigen. Diese Kennziffer repräsentiert die momentane

Verschleißsituation des Fahrzeugs. Durch Integration der Kennziffer über die Zeit oder den Weg kann daraus die Verschleißsituation des Fahrzeugs für eine Dauer und/oder Strecke ermittelt werden. Damit kann eine Bewertung der Fahrzeugabnutzung zur Abrechnung von zur Nutzung überlassenen Kraffahrzeugen erfolgen.

Offenbarung der Erfindung

[0005] Die Erfindung schlägt ein Verfahren und eine Einrichtung zum Ermitteln bzw. Überwachen des fahrbetriebsbedingten mechanischen Zustandes eines Fahrzeugs anhand von realen, physikalischen Messgrößen. Der Fahrzeugzustand betrifft dabei wenigstens eine mechanische Komponente des Fahrzeugs, z.B. eine Komponente des Fahrzeugchassis', des Fahrwerks oder dergleichen.

[0006] Mit dem vorgeschlagenen Verfahren soll auch ermöglicht werden, ein insbesondere im Fahrbetrieb eines Fahrzeugs vorliegendes Fahrerverhalten eines jeweiligen Fahrzeugführers zu ermitteln.

[0007] Das vorgeschlagene Verfahren setzt voraus, dass in dem Fahrzeug wenigstens ein Sensor zur Erfassung mindestens einer dynamischen, mechanischen Messgröße, und zwar sowohl im Fahrzeugbetrieb als auch im Ruhezustand des Fahrzeugs, vorhanden ist.

[0008] Das vorgeschlagene Verfahren sieht insbesondere vor, dass an den von dem wenigstens einen Sensor erfassten Sensordaten wenigstens eine Fensterung der Sensordaten in eine empirisch vorgebbare Fensterlänge, eine Merkmalsextraktion zur Bereitstellung charakteristischer Merkmale in den Sensordaten anhand von zu erzeugenden Merkmalsvektoren, eine Segmentierung der erzeugten Fenster in Segmente unterschiedlicher Länge sowie eine Klassifizierung der Sensordaten anhand der erzeugten Merkmalsvektoren durchgeführt werden. Dabei ergeben sich wiederum Ergebnisdaten für die genannten realen, physikalischen Messgrößen. Diese Messgrößen können mit genauen Positions- und Zeitdaten versehen werden. Bei den Positionsdaten kann es sich um mittels eines GPS-Sensors gewonnene Ortsdaten, d.h. entsprechende Werte der geografischen Länge und Breite, handeln.

[0009] Bei dem ersten Verfahrensschritt der Fensterung kann vorgesehen sein, dass mittels eines Beschleunigungssensors erfasste Beschleunigungsdaten sowie mittels eines Rotationssensors bzw. Gyrometers erfasste Rotationsdaten zunächst in kurze, leicht überlappende Fenster mit einer empirisch vorgebbaren, festen Zeitlänge unterteilt werden. Bevorzugt wird dabei eine Fensterlänge Δt von 0.2 bis 60 s mit einer Fensterüberlappung von 0 bis 0.5 der gesamten Fensterlänge verwendet. Bei relativ kurzzei-

tigen Ereignissen wird bevorzugt eine Fensterlänge von 250 bis 1000 ms mit einer Überlappung von bis zu 1/8 der gesamten Fensterlänge verwendet.

[0010] Bei dem zweiten Verfahrensschritt der Merkmalsextraktion kann vorgesehen sein, dass für jedes erzeugte Fenster verschiedene charakteristische Merkmale abgeleitet bzw. extrahiert werden. Aus den zeitabhängigen Rohdaten bzw. Rohzeitreihen extrahierte Merkmale können dabei entweder Zeitdomänenmerkmale wie z.B. Mittelwerte, Mediane, Standardabweichungen, mittlere Ableitungen, Standardabweichungsableitungen und Nulldurchgangsraten, oder Frequenzdomänenmerkmale wie z.B. Hochfrequenzanteile, Dominantfrequenzen oder Spektraldifferenzen sein. Mit solchen Merkmalen lässt sich jedes der erzeugten Fenster in jeder Achse der jeweiligen Rohzeitreihe durch einen hochdimensionalen Merkmalsvektor kennzeichnen.

[0011] Bei dem dritten Verfahrensschritt der Segmentierung kann vorgesehen sein, dass Übergangspunkte in der Abfolge genannter Merkmalsvektoren identifiziert werden, an denen abrupte Änderungen auftreten. Dabei kann ein multivarianter Algorithmus zur Wechsellpunkterfassung angewendet werden. Diese Übergangspunkte ermöglichen es, ähnliche aufeinanderfolgende Fenster zu Segmenten unterschiedlicher Länge zu gruppieren, wobei jedes Segment einer anderen Art von mechanischer Belastung des Fahrzeugs entspricht. Wenn die Zeitreihendaten segmentiert sind, werden genannte Merkmalsvektoren von Fenstern innerhalb jedes Segments aggregiert, was einen aggregierten Merkmalsvektor pro Segment ergibt.

[0012] Bei dem vierten Verfahrensschritt der Klassifizierung der Sensordaten können auf Basis der Merkmalsvektoren Informationen über den momentanen Betriebszustand des Fahrzeugs (z.B. Fahrzeug ruht oder im Fahrbetrieb, Betriebszustand des Motors), über die Straßenoberflächenbeschaffenheit sowie über den jeweils vorliegenden Missbrauchs- bzw. Aufpralltyp abgeleitet werden. Hierfür kommen an sich bekannte Clustering- und Klassifikationsalgorithmen, z.B. die Methode des „Gaussian-Mixture“-Clustering oder die „Random-Forest“-Klassifikation, zum Einsatz. Dabei wird jedes Fenster oder Segment anhand seines mehrdimensionalen Merkmalvektors einer Gruppe (Cluster oder Klasse) zugeordnet. Jede Gruppe enthält somit Segmente bzw. Fenster mit ähnlicher Merkmalskombination und entspricht daher einer jeweils anderen Art von mechanischer Belastung des Fahrzeugs. Besonders rechenintensive Berechnungsschritte bei den genannten vier Verfahrensschritten können auf einem außerhalb des Fahrzeugs angeordneten (externen) Rechner, z.B. mittels Cloud-Computing, ausgeführt bzw. durchgeführt werden. Weniger rechenintensive Berechnungsschritte können dagegen bereits in dem Fahrzeug durchge-

führt werden und nur entsprechend vorprozessierte Daten an den externen Rechner übertragen werden, um insbesondere das Datenvolumen der zu übertragenden Daten zu reduzieren bzw. zu minimieren.

[0013] Darüber hinaus können Parameter und Hyperparameter der genannten Klassifizierungsalgorithmen aus dem vierten Verfahrensschritt anhand von Trainingsdaten mittels an sich bekannter maschineller Lernalgorithmen („machine learning algorithms“) angelernt bzw. trainiert werden, wobei entsprechende Trainingsdaten bevorzugt für ein individuelles Fahrzeug oder einen Fahrzeugtyp spezifisch an einem jeweiligen Teststand erzeugt werden können. Alternativ oder zusätzlich können die Trainingsdaten, ebenfalls fahrzeugspezifisch, bei Fahrten auf einer geeignet präparierten Teststrecke erzeugt werden, wobei z.B. vorab definierte Fahrzeug-Missbrauchs- bzw. Schadeneinwirkungsszenarien auf das jeweilige Fahrzeug im Standbetrieb und/oder im Fahrbetrieb reproduzierbar nachgestellt und sensorisch erfasst werden.

[0014] Für Segmente, die als kurzzeitige transiente Schock- oder Stoßereignisse klassifiziert werden, kann eine zusätzliche Wavelet-Analyse an genannten Fenstern durchgeführt werden. In Kombination mit den Zeit- und Frequenzmerkmalen ermöglicht diese Vorgehensweise eine Analyse des Ortes (d.h. genaue Position der Einwirkung am Fahrzeug), der Richtung und der Art der jeweiligen Ein- bzw. Auswirkungen auf das Fahrzeug.

[0015] Die genannten Verfahrensschritte des vorgeschlagenen Analyseverfahrens können auch gleichzeitig mit der Datenübertragung in eine Cloud-Plattform durchgeführt werden. Sobald das Verfahren trainiert wurde, ist daher eine kontinuierliche Echtzeitanalyse möglich.

[0016] Zusammenfassend umfasst das vorgeschlagene Verfahren die folgenden drei Hauptziele:

(1) Verfolgen von Fahrzeugstatistiken: Ermittlung der Anzahl an Vibrationen und/oder Beschleunigungsspitzen oberhalb empirisch vorgegebener Schwellenwerte, welche einen erheblichen Fahrzeugverschleiß verursachen und damit zu einer erheblichen Wertminderung des jeweiligen Fahrzeugs führen können.

(2) Klassifizierung der Beanspruchungsarten: Erkennung verschiedener Straßenzustände, plötzlicher Einwirkungen („impacts“) auf das Fahrzeug und kritischer Ereignisse z.B. aufgrund von Fahrzeugmissbrauch, aufgrund von Unfällen oder durch eine individuelle Fahrweise verursacht.

(3) Charakterisierung kritischer Auswirkungen wie Richtung, Größe und Position von externen Lasten oder Stößen am Fahrzeug.

[0017] Diese Arten von kritischen Ereignissen werden identifiziert, klassifiziert und der daraus resultierende Schaden und Grad der Abnutzung an bestimmten, mechanischen Fahrzeugkomponenten abgeleitet. Auf diese Weise kann auch der Chassis- und Karosseriezustand eines gesamten Fahrzeugs ermittelt werden. Weiterhin können charakteristische Bewegungsereignisse am Fahrzeug identifiziert werden, die auf den Gebrauch des Fahrzeugs schließen lassen, z.B. das Zusteigen von Personen in das Fahrzeug, das Zuschlagen von einzelnen Türen oder das Anlassen und Ausschalten des Motors.

[0018] Anhand der vorliegenden Sensordaten kann auch eine Fahrverhaltensanalyse zur Erkennung eines Fahrzeugmissbrauchs durchgeführt werden, und zwar durch eine anhand der Sensordaten durchgeführte Richtungserkennung und Schweregradindikation. Eine genaue Lokalisierung bzw. Richtungserkennung von Schadensereignissen kann dabei anhand der Sensordaten, insbesondere anhand der von einem genannten Rotations- bzw. Gyrosensor bereitgestellten Daten, erfolgen. Dadurch kann ein charakteristisches Missbrauchs-Muster erkannt und zusätzlich z.B. bezüglich des Schweregrads qualifiziert bzw. quantifiziert werden. Ein jeweils erkanntes Missbrauchs-Muster kann auch zu Plausibilisierungszwecken z.B. mit öffentlich zugänglichen Straßendaten oder Verkehrsdaten abgeglichen werden.

[0019] Bei dem vorgeschlagenen Verfahren kann hierzu vorgesehen sein, dass die Richtungserkennung einer mechanischen Einwirkung auf das Fahrzeug mittels Klassifizierung der Sensordaten erfolgt. Die Klassifizierung der Sensordaten kann mittels einer Wavelet-Analyse erfolgen, wobei die Sensordaten bezüglich der Position und der Richtung der mechanischen Einwirkung auf das Fahrzeug eingruppiert werden. Die Klassifizierung kann zudem auf einem Ensemble einer Vielzahl von Entscheidungsbäumen beruhen, wobei für jeden Entscheidungsbaum anhand von erzeugten Wavelet-Merkmalen und deren Korrelation mit Zeit- und Frequenzdomänen-Merkmalen eine Zuordnung eines jeweiligen Ereignisses zu einer dominanten Einwirkungsrichtung erstellt wird.

[0020] Durch das Trainieren des Klassifikators mit zusätzlichen Straßen- und Verkehrsdaten ist es weiterhin möglich, mit Hilfe der vorliegenden Sensordaten bestimmte Straßentypen (z.B. Autobahn, Landstraße, Stadtstraßen) oder Fahrbahnoberflächen (z.B. Asphalt, Kopfsteinpflaster, unbefestigter Weg) zu erkennen.

[0021] Um weitere Indikatoren für möglichen Nutzungsmissbrauch eines Fahrzeugs zu erhalten, können auch zu diesem Zweck maschinelle Lernalgorithmen zur Datenanalyse eingesetzt werden. Diese Algorithmen können auf Trainingsdaten zugreifen, wel-

che z.B. an einer Teststrecke oder anhand von Feldtests in realen Betriebs- bzw. Fahrsituationen erzeugt werden. Dadurch ist eine zuverlässige Klassifizierung von relevanten Ereignissen möglich.

[0022] Das vorgeschlagene Verfahren ermöglicht somit eine genaue und insbesondere zeitlich umfassende Analyse von hier betroffenen Sensordaten. Dadurch kann für ein bestimmtes Fahrzeug sogar eine vollständige Gebrauchs- bzw. mechanische Belastungshistorie angelegt werden, welche unterschiedlichste Ereignisse des Produktlebenszyklus umfassen kann. Diese Ereignisse können hinsichtlich ihrer Bedeutung für den Wert des Fahrzeugs, den mechanischen Zustand bestimmter, tatsächlich lokalisierter Fahrzeugkomponenten sowie die Rückverfolgbarkeit und den Schweregrad von durch Fahrzeugmissbrauch oder Fahrzeugunfälle hervorgerufenen mechanischen, aber nicht notwendigerweise sofort sichtbaren, Schädigungen am Fahrzeug umfassen.

[0023] Die Erzeugung einer lückenlosen digitalen Fahrzeughistorie erlaubt es dem Besitzer eines Fahrzeugs, jeden in der Fahrzeughistorie gefahrenen Kilometer hinsichtlich der dabei erfahrenen Ereignisse, z.B. Schadensfälle, Fahrstile und/oder jeweils überfahrene Fahrbahnoberflächen, nachzuverfolgen. Für diese Ereignisse können die jeweils zugehörigen Positionsdaten mit ausgewertet werden und so nachträglich eine mögliche Korrelation mit vor Ort vorliegenden Verhältnissen, z.B. Straßenverhältnissen, durchgeführt werden. Anhand der sich dabei ergebenden Informationen kann sogar eine relative Fahrzeugabnutzung ermittelt werden. Bei Fahrzeugflotten können diese Informationen z.B. relativ zu einem repräsentativen Fahrzeugtyp oder einer repräsentativen Nutzergruppe statistisch ausgewertet werden.

[0024] Mit dem vorgeschlagenen Verfahren können zudem auch relativ geringfügige bzw. leichte Fahrzeugschäden, die optisch nicht erkennbar sind, aber zu einem vorzeitigen Verschleiß oder Versagen von Komponenten führen können, erkannt werden. Dadurch kann auch Fahrzeugmissbrauch transparent für z.B. einen Autovermieter oder ein Leasingunternehmen oder eine Versicherung qualifiziert und quantifiziert werden, noch bevor das Fahrzeug begutachtet wird.

[0025] Das vorgeschlagene Verfahren ermöglicht zudem eine verbesserte Unterstützung von Fahrzeugführern bzw. Fahrzeugbesitzern in einem Schadensfall, um dabei genauere Informationen z.B. über einen Unfallhergang oder eine verbesserte Erstellung eines Schadengutachtens auf der Grundlage der Sensorinformationen bereitzustellen. Darüber hinaus können dabei gezieltere Hinweise auf wahrscheinlich zu reparierende Komponenten gegeben werden.

[0026] Es ist anzumerken, dass das vorgeschlagene Verfahren modular implementiert werden kann, so dass das Verfahren entweder insgesamt in dem Fahrzeug oder auf einem externen Rechner (Cloud) durchgeführt werden kann oder dass z.B. ein erster Teil des Verfahrens in dem Fahrzeug und der jeweils zweite Teil auf dem externen Rechner durchgeführt wird.

[0027] Die ebenfalls vorgeschlagene Einrichtung zum Ermitteln bzw. Überwachen des fahrbetriebsbedingten mechanischen Zustandes eines Fahrzeugs weist Rechenmittel auf, mittels derer die vorgenannten Verfahrensschritte automatisiert ausgeführt werden können. Bei der Anordnung bzw. Implementierung der Einrichtung in einem Fahrzeug weist die Einrichtung zusätzlich eine genannte Sensorik zur Erfassung mindestens einer dynamischen, mechanischen Messgröße auf.

[0028] Es ist allerdings hervorzuheben, dass die Einrichtung auch in einem externen Rechner, z.B. in einem Cloud-Computing-System bzw. einer Cloud-Computing-Plattform, eingerichtet werden kann. In dieser Ausgestaltung werden die von der in einem Fahrzeug angeordneten Sensorik bereitgestellten Sensordaten der Einrichtung zugeführt und von dieser gemäß den vorgenannten Verfahrensschritten ausgewertet.

[0029] Die Erfindung kann insbesondere bei einem Kraftfahrzeug, prinzipiell aber auch bei Nutzfahrzeugen, Wasserfahrzeugen, Unterwasserfahrzeugen, Luft-/Raumfahrzeugen oder dergleichen, welche einer nutzungsabhängigen, mechanischen Abnutzung unterliegen, entsprechend zum Einsatz kommen.

[0030] Das Computerprogramm ist eingerichtet, jeden Schritt des Verfahrens durchzuführen, insbesondere wenn es auf einem Rechengertät oder in einem an dem jeweiligen Fahrzeug angeordneten Steuergerät abläuft. Es ermöglicht die Implementierung des Verfahrens auch in einem bereits vorliegenden Steuergerät des Fahrzeugs, ohne an dem Steuergerät bauliche Veränderungen vornehmen zu müssen. Hierzu ist der maschinenlesbare Datenträger vorgesehen, auf welchem das Computerprogramm gespeichert ist. Durch Aufspielen des Computerprogramms auf einen Mikroprozessor bzw. Mikrocontroller eines solchen Steuergerätes ist dieses eingerichtet, um das Verfahren auszuführen.

[0031] Weitere Vorteile und Ausgestaltungen der Erfindung ergeben sich aus der Beschreibung und den beiliegenden Zeichnungen.

[0032] Es versteht sich, dass die voranstehend genannten und die nachstehend noch zu erläuternden Merkmale nicht nur in der jeweiligen angegebenen Kombination, sondern auch in anderen Kombinati-

onen oder in Alleinstellung verwendbar sind, ohne den Rahmen der vorliegenden Erfindung zu verlassen.

Figurenliste

Fig. 1 zeigt ein erstes Ausführungsbeispiel des erfindungsgemäßen Auswerteverfahrens anhand eines Flussdiagramms.

Fig. 2 zeigt einen beispielhaften Auswertalgorithmus zur Implementierung des in **Fig. 1** gezeigten Ausführungsbeispiels des erfindungsgemäßen Auswerteverfahrens anhand eines Flussdiagramms.

Fig. 3 zeigt ein zweites Ausführungsbeispiel des erfindungsgemäßen Auswerteverfahrens anhand eines Flussdiagramms, zur Illustration der Ermittlung der Richtungsabhängigkeit eines Ereignisses aus erfassten, transienten Signalen.

Fig. 4 zeigt einen beispielhaften Auswertalgorithmus zur Implementierung des in **Fig. 3** gezeigten Ausführungsbeispiels des erfindungsgemäßen Auswerteverfahrens anhand eines Flussdiagramms, insbesondere zur Illustration der Ableitung von Schadensereignissen mittels Aggregation von extrahierten Merkmalen zu segmentierten Merkmalen.

Fig. 5 zeigt eine Übersicht über eine erfindungsgemäße Auswertung von an einem Kraftfahrzeug im Fahrbetrieb über einen kurzen Zeitraum gemessenen Sensordaten.

Fig. 6a - Fig. d zeigen beispielhafte Auswerteschritte von an einem vorliegend stehenden Kraftfahrzeug über einen längeren Zeitraum gemessenen Sensordaten, zur Ermittlung von richtungsabhängigen Stoßeinwirkungen auf das Kraftfahrzeug.

Fig. 7a - Fig. d zeigen beispielhafte Auswerteschritte von an einem über einen längeren Zeitraum gefahrenen Kraftfahrzeug gemessenen Sensordaten, zur Ermittlung eines Fahrerhaltens bzw. Fahrstils.

Beschreibung von Ausführungsbeispielen

[0033] Die in **Fig. 1** gezeigte Auswertungsroutine setzt sich aus vier jeweils durch gestrichelte Linien abgegrenzten Prozessabschnitten zusammen, nämlich eine Fensterung **100**, Merkmalsextraktion **105**, Segmentierung **110** und eine Klassifizierung **115** die jeweils erfassten Sensordaten betreffend.

[0034] Gemäß dem ersten Prozessabschnitt **100** werden zunächst in dem vorliegenden Ausführungsbeispiel erfasste Beschleunigungs- und Gyrationzeitreihendaten in kurze, leicht überlappende Fenster mit einer empirisch vorgebbaren, festen Zeitlänge unterteilt **120**. Bevorzugt wird dabei eine Fens-

terlänge von 250 - 1000 ms mit einer Überlappung von bis zu 1/8 der gesamten Fensterlänge verwendet. Für jedes so erzeugte Fenster werden verschiedene charakteristische Merkmale abgeleitet bzw. extrahiert **125**. Solche extrahierten Merkmale können Zeitdomänenmerkmale, z.B. ein Mittelwert, ein Median, eine Standardabweichung, eine mittlere Ableitung, eine Standardabweichungsableitung oder eine Nulldurchgangsrate sein (zu weiteren Details, siehe auch **Fig. 4**).

[0035] Alternativ oder zusätzlich können solche extrahierten Merkmale Frequenzdomänenmerkmale, z.B. ein Hochfrequenzanteil, eine Dominantfrequenz oder eine Spektraldifferenz sein. Mit diesen extrahierten Merkmalen wird dann jedes der erzeugten Fenster in jeder Achse der Rohzeitreihe durch einen hochdimensionalen Merkmalsvektor gekennzeichnet **130** (siehe **Fig. 4**).

[0036] Um Übergangspunkte in der Abfolge solcher Merkmalsvektoren zu identifizieren, an denen abrupte Änderungen auftreten, wird in dem vorliegenden Ausführungsbeispiel ein multivarianter Algorithmus zur Wechsellpunkterfassung angewendet **135**. Diese Übergangspunkte ermöglichen es, ähnliche aufeinanderfolgende Fenster zu Segmenten unterschiedlicher Länge zu gruppieren **140**, wobei jedes Segment einer anderen Art von mechanischer Belastung des Fahrzeugs entspricht (siehe **Fig. 4**).

[0037] Wenn die Zeitreihendaten in der genannten Weise segmentiert sind, werden die Merkmalsvektoren von Fenstern innerhalb jedes Segments aggregiert **145**, was einen aggregierten Merkmalsvektor pro Segment ergibt. Diese Merkmalsvektoren werden schließlich zur Klassifizierung **150** des Betriebszustandes des Fahrzeugs, z.B. Fahrzeug im Fahrbetrieb oder ruhend, Betriebszustand des Motors, Straßenoberflächenbeschaffenheit sowie der Missbrauchs- bzw. Aufpralltyp durch ein multivariates Clusterverfahren verwendet (siehe **Fig. 4**).

[0038] Für Segmente, die als kurzzeitige, transiente Schock- oder Stoßereignisse klassifiziert werden, kann eine zusätzliche Wavelet-Analyse an dem genannten Segment durchgeführt werden. In Kombination mit den Zeit- und Frequenzmerkmalen ermöglicht diese Vorgehensweise eine Analyse der räumlichen Position und der Richtung der jeweiligen Ein- bzw. Auswirkungen auf das Fahrzeug (siehe **Fig. 4**).

[0039] Anhand der vorliegenden Sensordaten kann auch eine Fahrverhaltensanalyse des jeweiligen Fahrzeugführers, z.B. zur Erkennung eines Fahrzeugmissbrauchs, durchgeführt werden. Diese Analyse kann durch eine anhand der Sensordaten durchgeführte Richtungserkennung und Schweregradindikation erfolgen (siehe auch **Fig. 4**).

[0040] In der **Fig. 2** ist ein Ausführungsbeispiel von Prozessschritten zur Ausführung eines Auswertalgorithmus' insbesondere zur Ermittlung eines genannten für die Beurteilung des Fahrzeugzustandes relevanten Wechsellpunktes durch ein Erkennen von Änderungen des Mittelwerts oder der Varianz von in dem Zeitintervall Δt enthaltenen Sensordaten.

[0041] Bei dem gezeigten Auswerteprozess wird zunächst eine Sequenz von n Zufallsvariablen $\{X_1, \dots, X_n\}$ vorgegeben **200**. Dabei wird angenommen, dass bereits eine geeignete Klassifizierung für die möglichen bzw. verschiedenen Änderungen vorliegt. Die Zufallsvariablen dienen sozusagen als Platzhalter für die vorliegend auszuwertenden Sensordaten, d.h. bevorzugt von Beschleunigungsdaten und gyroskopischen Daten. Im Schritt **205** wird aus einer Anzahl möglicher Teststatistiken eine bestimmte Teststatistik ausgewählt, welche für eine vorgegebene Änderungsklasse eine geeignete oder die optimale Teststatistik darstellt. Bei den genannten Teststatistiken kann es sich z.B. um die an sich bekannte Methode des „Generalized Likelihood Ratio“ (GLR) Tests, um eine anhand von Testpersonen ermittelte Teststatistik oder um die ebenfalls an sich bekannte Methode der sogenannten „Fishers Exact Test“ (FET) Statistik handeln, welche üblicherweise zur Erkennung von Parameteränderungen in einer Bernoulli-Sequenz eingesetzt wird, handeln.

[0042] In dem folgenden Schritt **210** wird festgelegt, wie groß die durchschnittliche Anzahl von erkannten Änderungen sein muss, damit überhaupt einer Fehlererkennung erfolgt bzw. ein Fehler erkannt wird. Dabei werden Werte für eine Falschalarmrate und eine durchschnittliche Lauflänge („Average Run Length“ = ARL0) empirisch vorgegeben. Gemäß Schritt **215** wird eine zwei Stichproben („two-sample“) umfassende Teststatistik $D_{k,n}$ an jedem möglichen Splitpunkt („split point“) X_k des zu untersuchenden Datensatzes ausgewertet bzw. bewertet. In Schritt **220** wird mittels einer genannten Teststatistik und der ARL0 ein Schwellenwert h_n berechnet. Dabei wird auf der Grundlage des Schwellenwertes h_n , und zwar bei Erfüllung der Bedingung $\max D_{k,n} > h_n$, ein Zeitpunkt T , zu dem eine jeweils erkannte Änderung stattgefunden hat, gemäß der Beziehung $T = \arg(k) \max D_{k,n}$ berechnet.

[0043] Bei der in **Fig. 3** gezeigten Auswerterroutine werden wiederum von einer genannten Sensorik gelieferte Beschleunigungsdaten **300** und Winkel- bzw. entsprechende gyroskopische Daten **305** ausgewertet. Diese Daten werden zunächst in der Zeitdomäne analysiert **310**, um anhand der Ergebnisse der Analyse **310** Zeitbereiche mit auffälligen Beschleunigungs- bzw. Rotationsdaten zu erkennen und zu selektieren **315**. Die in den so selektierten Zeitbereichen verfügbaren Daten werden in die Frequenzdomäne umgewandelt **320**. Denn dem vorliegenden Auswertever-

fahren liegt die Erkenntnis zugrunde, dass erst im Frequenzraum für die hier betroffenen Fahrzeugereignisse charakteristische, relativ kurze transiente Signale deutlich präziser erfasst werden können. Daher werden im nachfolgenden Schritt **325** solche Zeitbereiche mit auffällig kurzen Schockereignissen in dem vorliegenden Ausführungsbeispiel selektiert.

[0044] Die genannten Selektionen **315** und **325** werden durch Clustering-Algorithmen realisiert. Dabei werden die vorliegenden Daten in ein erstes Cluster mit auffälligen und ein zweites Cluster mit unauffälligen Zeitdomänen-Merkmalvektoren eingeordnet bzw. eingruppiert **315**. Zusätzlich werden noch die Frequenzdomänen-Merkmale verwendet **325**, um die Daten-Zeitbereiche aus dem auffälligen Cluster aus **315** in ein Cluster mit starken transienten Signalen und einen mit langsam veränderliche Signale einzuteilen.

[0045] Das Clustering erfolgt hierbei durch das sog. „Gaussian-Mixture“-Modell, bei dem eine probabilistische Clusterzugehörigkeit als gewichtete Überlagerung von mehrdimensionalen Normalverteilungen modelliert wird (siehe auch **Fig. 5**). Die zugrundeliegenden Ereignisse werden dabei meist als Punktwolken dargestellt. In der nachfolgend beschriebenen **Fig. 5** sind entsprechende Punktwolken für höhere bzw. multiple Dimensionen gezeigt. Die Parameter und Hyperparameter der Clustering-Modelle (Erwartungs- und Kovarianzmatrix, Clusteranzahl, Normalisierung, Kovarianztyp) werden initial aus Trainingsdaten **370** angelernt, und zwar unter Verwendung eines sog. „Expectation Maximization“(EM)-Algorithmus'. Bei dem EM-Algorithmus handelt es sich bekanntermaßen um einen Algorithmus der mathematischen Statistik, bei dem mit einem zufällig gewählten Modell gestartet wird und abwechselnd die Zuordnung der Daten zu den einzelnen Teilen des Modells (sog. „Expectation“-Schritt) und die Parameter des Modells an die jeweils neueste Zuordnung (sog. „Maximization“-Schritt) die Qualität des Ergebnisses verbessert wird. Im Expectation-Schritt werden dabei die Punkte einer genannten Punktwolke besser zugeordnet und im Maximization-Schritt das Modell so verändert, dass es besser zu den Daten passt. Findet keine wesentliche Verbesserung mehr statt, beendet man das Verfahren. Das Verfahren findet typischerweise nur „lokale“ Optima. Dadurch ist es oft notwendig, das Verfahren mehrfach aufzurufen, um das beste so gefundene Ergebnis auswählen zu können.

[0046] Der dabei zugrunde gelegte Trainingsdatensatz **370** kann aus Sensordaten eines beliebigen Fahrzeugtyps bestehen und sollte definierte Zeitabschnitte von einigen Minuten im ruhenden Zustand und im Fahrzustand des Fahrzeugs sowie abrupte Betriebsereignisse, z.B. Vollbremsungen oder Türenschließen, umfassen. Es ist anzumerken, dass in der **Fig. 5** jeder Punkt der dort gezeigten Punktwolken

(siehe dortige Bezugszeichen **560**, **565**) einem genannten Zeitfenster entspricht, innerhalb dessen ein möglicherweise relevantes Ereignis vorgelegen hat.

[0047] Alternativ kann die Analyse der genannten Daten in der Zeit- und der Frequenzdomäne stets für den vollständigen Zeitbereich der jeweils vorliegenden Messdaten durchgeführt werden. In diesem Fall entfällt der Selektionsschritt **315**. Zudem wird dabei mittels eines einzigen Clustering-Algorithmus' der Datenzeitraum auf der Basis von Zeit- **310** und Frequenzmerkmalen **320** klassifiziert **325**, und zwar in unauffällige Zeitbereiche (z.B. bei einem ruhenden Fahrzeug), auffällige Segmente z.B. bei Fahrten, Erschütterungen oder Fahrbahnunebenheiten, sowie kurze transiente Signalbereiche, z.B. bei Schock- oder Stoßereignissen.

[0048] Die dabei aufgefundenen Cluster können danach hierarchisch weiter in feinere Sub-Cluster aufgeteilt werden, und zwar nach dem gleichen Verfahren, wie beschrieben. Dadurch können z.B. Sub-Cluster eines Clusters „Fahrten“ nun Fahrten über unterschiedliche Fahrbahnoberflächen entsprechen. Der hier verwendete, probabilistische Clustering-Ansatz ermöglicht die Ableitung einer Plausibilitätsfunktion (sog. „Log-Likelihood“-Funktion). Durch eine kombinierte Betrachtung eines entsprechenden „Likelihood-Scores“ in den jeweiligen Clustern mit den Merkmalen **310**, **320** ist zusätzlich eine Anomalie-Erkennung möglich, um ungewöhnliche Segmente detektieren und beschreiben zu können.

[0049] Die durch den Schritt **325** selektierten Kurzzeitereignisse werden anhand von, für jeweils vorliegende relevante Fahrzeugereignisse empirisch vorgebbaren Wavelets **330** analysiert, um dadurch zusätzliche Wavelet-Merkmale **335** zu erzeugen. Anhand dieser Merkmale aus der Wavelet-Analyse können die Messsignale ggf. weiter klassifiziert werden **340** und danach entsprechend der Position und der Richtung der Ein- und Auswirkung auf das Fahrzeug eingruppiert werden **345**.

[0050] Bei dem Klassifizierungsschritt **340** kommt ein im Vorfeld antrainierter Klassifikationsalgorithmus zum Einsatz. Dieser Klassifizierungsalgorithmus basiert auf einem Ensemble von vielen einzelnen Entscheidungsbäumen, wobei jeder Entscheidungsbaum anhand der erzeugten Wavelet-Merkmale **335** und deren Korrelation mit den Zeit- und Frequenzdomänen-Merkmalen **310**, **320** eine Zuordnung eines jeweiligen Ereignisses zu einer dominanten Einwirkungsrichtung erstellt. Anschließend werden die Zuordnungsergebnisse aller Bäume gewichtet kombiniert und als Endresultat ausgegeben **345**. Die geeigneten Entscheidungsparameter und Hyperparameter des Klassifikators, d.h. die Baumanzahl und die Baumtiefe sowie die Split- und Stoppkriterien, werden in einem Trainingsprozess ermittelt. Für das An-

trainieren des Klassifikationsalgorithmus' wird ein Datensatz **380** verwendet, der Sensordaten von Stoß- und Schockereignissen an einem Fahrzeug beliebigen Fahrzeugtyps, deren Position und Richtung bereits bekannt sind, beinhaltet.

[0051] Der genannte mechanische Zustand kann sich auf den Zustand von Stoßdämpfern, Radlagern, Lenksäulen, Reifen, Bremsen, der Außenhaut des Fahrzeugs, einschließlich Fahrzeugtüren, Fahrzeugfenstern und Fahrzeugspiegeln beziehen. Bei dem Fahrverhalten können ein außergewöhnlich starkes Beschleunigen, Abbremsen oder Lenkverhalten des Fahrzeugs, mögliche Berührungen von Reifen mit Bordsteinen, heftiges Schließen von Fahrzeugtüren, das häufige Befahren von unebenen Fahrbahnen wie z.B. relativ unebenes Kopfsteinpflaster, oder das Auftreten von Parkremplern erkannt werden.

[0052] Fig. 4a zeigt einen Auswertalgorithmus zur Implementierung des anhand von Fig. 3 beschriebenen Auswertverfahrens. Dabei werden in dem vorliegenden Ausführungsbeispiel die erfassten Beschleunigungs- und Gyrationdaten **400** zunächst in Zeitfenster mit einer vorgegebenen Zeitlänge von 250 - 1000 ms und mit einer Überlappung von bis zu 1/8 der gesamten Fensterlänge unterteilt **405**. Es ist dabei hervorzuheben, dass anhand von Testläufen festgestellt wurde, dass für die Zeitlänge Werte im Bereich von bevorzugt 0.2 bis 60 s und für den Überlappungsgrad Werte im Bereich von bevorzugt Null bis 0.5, und zwar bezogen auf die gesamte Fensterlänge, möglich sind.

[0053] Dabei ist allerdings hervorzuheben, dass es bei dieser Fensterbildung hauptsächlich darum geht, solche Zeitfenster zu ermitteln, in denen überhaupt genannte Merkmale extrahiert bzw. für die weitere Auswertung erstellt werden können. Dabei wird die Fensterlänge in Abhängigkeit von der Ereignislänge gewählt, so dass sich bei relativ kurzzeitigen Ereignissen, z.B. Parkrempler, Türschließen, oder dergleichen, meist Fensterlängen im Bereich von 0.2 bis 2 s ergeben und bei relativ langzeitigen Ereignissen sogar Fensterlängen bis zu 1 h möglich sind. Solche langzeitigen Ereignisse können z.B. längere Park- bzw. Standzeiten des Fahrzeugs oder längere Fahrten des Fahrzeugs auf einer Strecke mit z.B. starken Bodenunebenheiten sein, welche zu einer besonders hohen mechanischen Belastung von Fahrgestellkomponenten des Fahrzeugs führen können.

[0054] Für diese Fenster werden vorliegend als charakteristische Zeitdomänenmerkmale ein Mittelwert, eine Standardabweichung, ein Maximum sowie eine Mediandurchgangsrate extrahiert **410**. Zusätzlich werden aus den Daten in dem vorliegenden Ausführungsbeispiel ein Hochfrequenzanteil, ein Niederfrequenzanteil, die jeweiligen Spektraldifferenzen, d.h. der Anteil der spektralen Informationen, welche seit

dem jeweils voranliegenden Zeitintervall neu hinzukommen, sowie die komplexe Phaseninformation extrahiert **412**. Mit diesen extrahierten **410**, **412** Merkmalen wird jedes der erzeugten Fenster durch einen genannten, hochdimensionalen Merkmalsvektor gekennzeichnet **415**.

[0055] Anhand der zeitlichen Abfolge der so gekennzeichneten **415** Merkmalsvektoren werden anschließend Übergangspunkte identifiziert **420**, an denen abrupte, d.h. z.B. einen empirisch vorgebbaren Schwellenwert **425** übersteigende Änderungen auftreten. Zur Identifizierung **420** der Übergangspunkte wird in dem vorliegenden Ausführungsbeispiel ein multivarianter Algorithmus zur Wechselpunkterfassung angewendet.

[0056] Anhand der so identifizierten **420** Übergangspunkte werden ähnliche, zeitlich aufeinander folgende Fenster zu Segmenten unterschiedlicher Länge gruppiert **430**. Dabei entspricht jedes Segment einer anderen Art von mechanischer Belastung des Fahrzeugs. Für Segmente, die als vorübergehende Schock- oder Stoßereignisse klassifiziert werden sollen, wird in dem vorliegenden Ausführungsbeispiel optional (wie durch die Strichelung angedeutet) eine zusätzliche Wavelet-Analyse an genannten Fenstern durchgeführt **435**, um auch den Ort und die Richtung der jeweiligen Ein- bzw. Auswirkungen auf das Fahrzeug zu erfassen bzw. zu ermitteln.

[0057] Die Merkmalsvektoren von Fenstern innerhalb jedes Segments können optional, wie durch die Strichelung angedeutet, vor der Klassifizierung **450** zusätzlich aggregiert werden **440**. Die Klassifizierung **450** der Merkmalsvektoren erfolgt in dem Ausführungsbeispiel durch ein anhand der Fig. 3 beschriebenes Clustering-Verfahren **325**, wobei vorliegend zu Vereinfachungszwecken nur der Straßenoberflächentyp sowie der Missbrauchs- bzw. Aufpralltyp klassifiziert werden.

[0058] Diese Arten von kritischen Ereignissen werden identifiziert, klassifiziert und der daraus resultierende Schaden und Grad der Abnutzung an bestimmten, mechanischen Fahrzeugkomponenten abgeleitet. Die aufgrund der genannten Eingruppierung sich ergebenden Positions- bzw. Richtungsinformationen **345**, **435** und die mittels der Klassifizierung **450** gewonnenen Merkmalsvektoren werden mit den Zeit- und Frequenz-Merkmalen **310**, **410** und **320**, **412** in Beziehung gesetzt bzw. mit diesen korreliert.

[0059] Zusätzlich wird in dem vorliegenden Ausführungsbeispiel eine Vergleichsanalyse mit ähnlichen Ereignissen durchgeführt. Die sich dabei ergebenden Vergleichsergebnisse ermöglichen die Einordnung **350**, **455** dieser Ereignisse nach Schwere und Ausprägungsgrad sowie einen Hinweis auf den Grad einer jeweiligen Anomalie. Eine Betrachtung der Er-

gebnisse **350, 455** über die gesamte Fahrzeughistorie ermöglichen präzise Aussagen über den mechanischen Fahrzeugzustand **355, 460**, insbesondere Änderungen des Fahrzeugzustandes aufgrund eines besonderen Fahrerverhaltens oder Ereignisses. Mögliche Fahrzeugzustände und/oder Fahrverhaltensmuster können zudem mit realen Messdaten **390, 465**, z.B. mit bei einer Fahrzeuginspektion in einer Werkstatt gewonnenen Messdaten, korreliert werden. Dabei können die durch die gestrichelte Linie **470** eingegrenzten Verfahrensschritte entsprechend wiederholt bzw. rekursiv ausgeführt werden.

Bei einem genannten Fahrzeugzustand kann es sich um den mechanischen Zustand von Stoßdämpfern, Radlagern, Lenksäulen, Reifen, Bremsen, sowie der Außenhaut des Fahrzeugs, einschließlich Fahrzeugtüren, Fahrzeugfenster und Fahrzeugsiegeln, handeln. Bei einem genannten Fahrverhalten bzw. Fahrerverhalten kann es sich um ein außergewöhnlich starkes Beschleunigen, Abbremsen oder Lenkverhalten des Fahrzeugs, mögliche Berührungen von Reifen mit Bordsteinen, ein heftiges Schließen von Fahrzeugtüren, ein häufiges Befahren von unebenen Fahrbahnen wie z.B. von relativ unebenem Kopfsteinpflaster, oder das Auftreten von Parkremplern handeln. Auf diese Weise kann auch der Chassis- und Karosseriezustand eines gesamten Fahrzeugs zuverlässig ermittelt werden.

[0060] Zur genannten Erkennung eines Fahrzeugmissbrauchs wird in dem vorliegenden Ausführungsbeispiel eine Analyse der Sensordaten anhand einer Richtungserkennung und Schweregradindikation durchgeführt. Dabei wird ein charakteristisches Missbrauchs-Muster, z.B. die Beschädigung einer Frontverkleidung des Fahrzeugs aufgrund des Anfahrens eines Pollers auf einem Parkplatz, erkannt. Das erkannte Ereignis wird vorliegend zusätzlich dahingehend qualifiziert, ob nur ein „Parkrempler“ oder sogar ein schwerwiegender Zusammenstoß mit einem stationären oder beweglichen Gegenstand oder mit einem anderen Fahrzeug erfolgt ist. Dabei wird der Schweregrad z.B. eines Parkremplers als z.B. „gering“, „mittel“ oder „hoch“ quantifiziert. Anhand der Sensordaten, insbesondere anhand der von einem Gyrosensor bereitgestellten Daten, kann zusätzlich eine genaue Lokalisierung bzw. Richtungserkennung von Schadensereignissen erfolgen, z.B. „Stoßeinwirkung vorne rechts, im Bereich von 30 bis 45°, bezogen auf die Fahrzeuglängsachse“.

[0061] Anhand von mittels GPS erzeugten Positionsinformationen eines jeweiligen Ereignisses, z.B. Parkvorgang an einem „Parkplatz Str. XY“, kann ein jeweils erkanntes Missbrauchsmuster zu Plausibilisierungszwecken z.B. mit öffentlich zugänglichen Straßendaten oder Verkehrsdaten abgeglichen werden. Die GPS-Daten können dabei z.B. mit detektierten Ereignissen kombiniert werden. So können das Auftreten sowie die Häufung von Ereignissen be-

stimmten Typs mit den GPS-Daten kombiniert werden. Dabei kann z.B. eine zeit- und ortsabhängige Häufung von bestimmten Schadensereignissen erkannt werden und ggf. sogar entsprechende Gegenmaßnahmen ergriffen werden. Auch können bestimmte Ereignismuster bestimmten Orten zugeordnet werden, z.B. das Öffnen und Schließen der Motorhaube an bekannten Orten wie z.B. in einer Werkstatt oder einer Wartungsstation, in der das Fahrzeug durch einen Techniker begutachtet und ggf. instandgesetzt wird. Auch können dabei ortsabhängige Verkehrsinformationen, z.B. eine Häufung von Verkehrs- bzw. Unfallgefährdungen an bestimmten Örtlichkeiten, z.B. an bestimmten Straßenkreuzungen.

[0062] Es ist anzumerken, dass z.B. die Verfahrensschritte **400, 410, 420** lokal, d.h. in dem Fahrzeug, durchgeführt werden und die übrigen Schritte auf einem externen Rechner bzw. in einer Cloud. Alternativ können sämtliche Verfahrensschritte auf einem externen Rechner (Cloud) durchgeführt werden.

[0063] Die in **Fig. 5** gezeigte, datenanalytische Auswertung beruht auf rohen, d.h. nicht vorverarbeiteten und in den drei Raumrichtungen erfassten Sensordaten (Rohdaten) **500** für die Fahrzeugbeschleunigung **505** (a_x, a_y, a_z in der Einheit $[m/s^2]$) und das Gyrationverhalten **510** (g_x, g_y, g_z in der Einheit $[Grad/s]$) des Fahrzeugs. In dem dargestellten Beispielszenario mit einer Dauer von sechs Minuten treten einige deutlich sichtbare Messsignale auf, von denen drei Zeitbereiche durch Strichelungen **506, 507, 508** in den Beschleunigungsdaten a_x, a_y, a_z sowie Gyrationdaten g_x, g_y, g_z hervorgehoben sind.

[0064] Die so erfassten Sensordaten **500** werden einer ersten Datenverarbeitungseinheit **520** zugeführt **515**, mittels der eine Merkmalsextraktion aus diesen Daten **500** durchgeführt wird. Dabei werden die Daten **500** zunächst in der den Messdaten zugrundeliegenden Zeitdomäne **525** bearbeitet, wobei aus den jeweils drei bzw. insgesamt sechs räumlichen Dimensionen der Messsignale a_x, a_y, a_z und g_x, g_y, g_z jeweils K zeitabhängige Zeitdomänen-Merkmale (mit $K = 4$ in dem vorliegenden Ausführungsbeispiel) extrahiert werden. Die aus den Rohdaten **500** bereits erkennbaren Ereignisse bzw. möglichen Schadensereignisse **506, 507** und **508** entsprechen in der Zeitdomäne den jeweils durch Stricheln hervorgehobenen Zeitbereichen **526, 527, 528**. Aus den in der Zeitdomäne verarbeiteten Sensordaten werden in einem ersten Verarbeitungsschritt **540** Zeitbereiche mit anomalen Signalverläufen für die weitere Frequenzanalyse **530** vorselektiert. Alternativ kann die Frequenzanalyse, wie in dem vorliegenden Ausführungsbeispiel gezeigt, auch direkt in dem gesamten Zeitbereich durchgeführt werden.

[0065] Bei der Frequenzanalyse werden die Rohdaten **500** mittels einer Kurzzeit-Fourier-Transformati-

on zeitabschnittsweise in die Frequenzdomäne **530** transformiert und dort weiterverarbeitet. Dabei werden aus dem bei der Transformation sich ergebenden Spektrogramm insgesamt L Frequenzdomänen-Merkmale für jede der sechs Rohdaten-Dimensionen extrahiert (mit $L = 6$ in dem vorliegenden Ausführungsbeispiel). Auf der Basis der damit insgesamt vorliegenden $K \times L$ Merkmale klassifiziert der Clustering-Algorithmus **545** die Zeitbereiche, die besonders dynamische, transiente Signale enthalten.

[0066] Die so selektierten 545 transienten Signale werden danach einer Wavelet-Analyse unterzogen **535**. Gemäß Schritt **548** erfolgt eine kontinuierliche Wavelet-Dekomposition anhand eines „Morlet“-Wavelets von dem transienten Ereignis **508**. Daraus lassen sich W Wavelet-Merkmale auf verschiedenen Approximations- und Detailstufen extrahieren.

[0067] Die sich insgesamt ergebenden Analyseergebnisse, d.h. die Zeit-, Frequenz-, und Wavelet-Merkmale **525**, **530**, **535**, werden danach einer zweiten Datenverarbeitungseinheit **555** zugeführt **550**, in der die Analyseergebnisse mittels „Maschine Learning“-Algorithmen weiter ausgewertet werden, um in den Datensätzen verborgene Informationen über mögliche Schadensereignisse zu extrahieren. Dabei werden die insgesamt $6 \times K \times L \times W$ Zeit-, Frequenz-, und Wavelet-Merkmale zunächst mittels multidimensionaler Clusteranalyse in zweckmäßige Teilmengen bzw. Klassen untergliedert bzw. segmentiert **560**.

[0068] Die Clusteranalyse beruht auf einem „Gaussian-Mixture“-Modell, bei dem die probabilistische Clusterzugehörigkeit als gewichtete Überlagerung von mehrdimensionalen Normalverteilungen modelliert wird. Gemäß Schritt **560** erfolgt dabei eine zweidimensionale Visualisierung der Wahrscheinlichkeitsverteilungen eines solchen Cluster-Modells, welches verschiedene Fahrzeugzustände bzw. Ereignisse klassifiziert. Dabei werden die wichtigsten fünf Dimensionen paarweise als Matrix dargestellt, wobei jede Farbe der „Likelihood“-Kontur der Verteilungsfunktion eines Clusters entspricht. Das Clustering-Modell **560** wurde im Vorfeld durch Trainingsdaten aus einem Fahrzeug beliebigen Typs angelern. Anschließend können mit Hilfe des trainierten Clustering-Modells **560** neue Daten aus dem Fahrbetrieb entsprechend klassifiziert werden **565**.

[0069] Der gesamte Zeitbereich des hier vorliegenden Ausführungsbeispiels wird so einem Cluster zugeordnet, wobei die Cluster jeweils verschiedenen Ereignis- bzw. Schädigungsgruppen entsprechen. Die Einteilung der Ereignisgruppen ist in für die in **570** dargestellte, obere Messkurve **572** in zeitlicher Abfolge als farbliche Hinterlegung zusammen mit den entsprechenden Rohdaten **500** gezeigt. Jede der Farben entspricht einem Cluster bzw. einer Ereignisgruppe.

Mittels solcher, antrainierter Clusteranalysen ist es möglich, durch einen Vergleich mit aktuell ermittelten Sensordaten zuverlässig auf bestimmte, genannte Ereignisse schließen zu können.

[0070] So entspricht die in dem vorliegenden Beispielszenario zu der oberen Messkurve gezeigte Gruppe ‚0‘ **573** einem Fahrzeug im Ruhezustand und die Gruppen ‚1‘, ‚2‘ und ‚3‘ **574**, **575**, **576** verschiedenen Fahrsituationen und die Gruppe ‚4‘ **577** den auffälligen, transienten Schockereignissen. So werden z.B. die beiden vorliegend als **506** und **508** markierten Ereignisse in die Gruppe ‚4‘ **577** (ein-)klassifiziert, während der Bereich **507** in die drei Fahrsituationsgruppen ‚1‘, ‚2‘ oder ‚3‘ **574**, **575**, **576** eingruppiert wird.

[0071] Aus den bei der Merkmalsextraktion **520** und bei dem ML-Verfahren **555** sich ergebenden Daten **585** können schließlich unterschiedliche Rückschlüsse **590** auf die Fahrzeughistorie gezogen werden. So kann der aktuelle Fahrzeugzustand **592** ermittelt werden, z.B. unter Angabe einer die jeweiligen Einwirkungen („impacts“) auf das Fahrzeug entsprechenden Punktzahl („score“). Diese Punktzahl kann zusätzlich mit der aktuell vorliegenden Laufleistung des Fahrzeugs korreliert werden. Alternativ oder zusätzlich kann aus den vorliegenden Daten für jede der ermittelten Einwirkungen die entsprechende Art der Beanspruchung **594**, z.B. eine schlag- oder stoßartige Beanspruchung, ermittelt werden. Alternativ oder zusätzlich kann für jede der ermittelten Einwirkungen auch die jeweilige Einwirkungsrichtung **596** ermittelt werden. Aus den Daten kann zusätzlich das im zu untersuchenden Fahrbetrieb des Fahrzeugs vorgelegene Fahrerverhalten **598** ermittelt werden. Dabei kann zwischen verschiedenen Fahrertypen, z.B. einem „konservativ“, „sportlich“ oder „aggressiv“ fahrenden Fahrer, unterschieden werden.

[0072] Anhand der **Fig. 6a - Fig. 6d** wird ein Ausführungsbeispiel des beschriebenen Verfahrens zur Ermittlung der genannten Einwirkungsrichtung **596** beschrieben. Wie in **Fig. 6a** schematisch gezeigt, kommen bei einem Personenkraftwagen im Wesentlichen die Einwirkungsrichtungen vorne (V), hinten (H), links-vorne (LV), links-hinten (LH), rechts-vorne (RV) und rechtshinten (RH) in Betracht, um transiente Schockeinwirkungen und in verschiedenen Richtungen erfolgende schwingungsförmige Einwirkungen zu erfassen.

[0073] In dem vorliegenden Beispiel wurde als Testfall das Schließen von Fahrzeugtüren eines angenommen viertürigen Fahrzeugs untersucht. Als Trainingsdatensätze für das ML-Verfahren wurden dabei für drei unterschiedliche Fahrzeugtypen jeweils 80 Mal wiederholte Türschließvorgänge der vier Türen durchgeführt. In der **Fig. 6b** sind die sich dabei ergebenden, in einem Zeitraum von etwa 300 s

erfassten Sensor-Rohdaten für die Beschleunigung **600** und die Gyration **605** dargestellt. Die Rohdaten stellen, wie für das Schließen von Türen typisch, relativ kurz andauernde bzw. gedämpft abklingende Schwingungssignale dar.

[0074] Wie aus den Rohdaten zu ersehen, ergeben sich bei den Beschleunigungskomponenten a_x und a_z sowie bei der Gyrationkomponente g_y die jeweils größten Signalamplituden. Die Gyrationkomponente g_z besitzt zudem die insgesamt geringste Amplitude, da die hier betroffenen Schließbewegungen der Türen zwar ein Nicken und/oder Rollen des Fahrzeugs in der x- und y-Richtung bewirken, nicht aber ein Gieren bzw. Schlingern des Fahrzeugs in der z-Richtung

[0075] In der **Fig. 6c** ist eine zeitliche Ausschnittvergrößerung **615** von am vorliegenden Messzeitende erfassten, sechs Schwingungssignalen **610** dargestellt. Wie daraus zu ersehen, unterscheiden sich die Amplituden und Phasen der drei durch Strichelungen **616**, **617**, **618** hervorgehobenen Signalverläufe deutlich. Die Ursache dafür ist der directionale Impuls (hier aus der negativen x-Richtung) sowie die nicht zentrale Anordnung des Beschleunigungs- und Gyrosensors in Bezug auf den Fahrzeugschwerpunkt, welcher an der Fahrzeugstruktur im Motorraum nahe der 12V-Fahrzeuggatterie installiert ist. Anhand solcher Signale **610**, **615** lässt sich die Art der jeweiligen Einwirkung auf das Fahrzeugchassis bzw. seine Komponenten, d.h. vorliegend durch ein z.B. heftiges Türschließen, erkennen und charakterisieren. Aufgrund der Unterschiede der in den verschiedenen Achsen gemessenen Signale kann auch die Richtung der jeweiligen Einwirkung erkannt werden.

[0076] In dem in **Fig. 6d** gezeigten Diagramm ist die Vorhersagegüte des beschriebenen Verfahrens für vorliegend 55 Testereignisse mit unterschiedlichen Einwirkungsrichtungen dargestellt. Dabei sind horizontal mittels des beschriebenen Verfahrens anhand von genannten Sensordaten vorhergesagte Einwirkungsrichtungen RV, RH, LH und LV sowie vertikal bei den Messungen tatsächlich vorliegende entsprechende Einwirkungsrichtungen aufgetragen. Die vier auf der Diagonalen angeordneten Felder **620**, **621**, **622**, **623** entsprechen dabei korrekten Vorhersagen der jeweiligen Einwirkungsrichtung, welche mittels des beschriebenen Verfahrens getroffen wurden, wobei die in diesen Feldern eingetragenen Zahlen die Anzahl der jeweiligen Ereignisse angeben. Nicht auf der Diagonalen liegende Felder entsprechen dagegen mit dem beschriebenen Verfahren getroffenen falschen Vorhersagen bezüglich der Einwirkungsrichtung. Die Anzahl solcher Ereignisse mit falschen Vorhersagen ist allerdings relativ gering und liegt in dem vorliegenden Beispiel bei insgesamt nur sechs Ereignissen (siehe 624, 625, 626 und 627). Das Verfahren

ermöglicht somit eine sehr präzise Vorhersage der jeweiligen Einwirkungsrichtung.

[0077] Das anhand der **Fig. 6a - Fig. 6d** beschriebene Verfahren ermöglicht eine mehr als 98%ige Genauigkeit bei der Erfassung von, den mechanischen Fahrzeugzustand beeinflussenden Einwirkungen sowie eine 85- bis 90-prozentige Genauigkeit bei der Erkennung der jeweiligen Einwirkungsrichtung. Zudem kann die relative Stärke der jeweiligen Einwirkung mittels einer Punktzahl präzise charakterisiert bzw. festgestellt werden.

[0078] In den **Fig. 7a - Fig. 7d** ist ein Ausführungsbeispiel des beschriebenen Verfahrens zur Ermittlung des Fahrerverhaltens **598** gezeigt. Die dabei zugrundeliegenden, bei einer von mehreren Testfahrten erfassten Rohdaten sind in **Fig. 7a** dargestellt, und zwar wiederum drei Messreihen **700** eines im Fahrzeug angeordneten Beschleunigungssensors sowie drei Messreihen **705** eines im Fahrzeug angeordneten Gyrosensors. Bei den Testfahrten auf einer vorliegend 20 km langen Teststrecke wurden die Messdaten bei Fahrten mit drei verschiedenen Fahrern erfasst.

[0079] Aus den in **Fig. 7a** gezeigten, bei der Testfahrt einer der drei Fahrer erfassten Rohdaten lassen sich noch keine qualitativen oder quantitativen Aussagen über das dabei zugrundeliegende Fahrerverhalten treffen. Erst die Auswertung der Sensordaten in der vorbeschriebenen Weise lässt solche Aussagen zu. Da die Sensorik im Wesentlichen Brems- und Beschleunigungseingriffe sowie Lenkeingriffe seitens des Fahrers anhand der vorliegenden Sensordaten mittelbar erfassen kann, kann mittels der beschriebenen Auswertung, ggf. einschließlich eines dabei durchgeführten KI-basierten Lernverfahrens, eine konservative Fahrweise von einer sportlichen oder sogar aggressiven Fahrweise der vorliegend drei Fahrer sicher unterschieden werden.

[0080] Eine Auswertung der in **Fig. 7a** gezeigten Rohdaten **700'**, **705'** ergibt die in **Fig. 7b** gezeigten Zeitintervalle bzw. Zeitfenster **710**, in denen für das Fahrerverhalten relevante Zeitbereiche erfasst wurden. Die Vorselektion dieser Zeitintervalle **710** erfolgt durch ein „Clustering“-Verfahren auf Basis der Zeitdomänen-Merkmale der erfassten Beschleunigungs- und Gyrationssignale bzw. Gyrationssignale.

[0081] Aus den in **Fig. 7b** gezeigten, vorselektierten Daten **710'** ergibt sich bei einer, wie vorbeschrieben, eingehenderen Datenauswertung der Beschleunigungsdaten **700''** und der Gyrationssignale **705''** die in **Fig. 7c** gezeigten Zwischenergebnisse. So kann aus der Richtungsabhängigkeit der Fahrereingriffe, welche sich in entsprechend ansteigenden bzw. abfallenden Flanken der Messsignale niederschlägt, z.B. auf die Richtung von Lenkeingriffen seitens des

Fahrers geschlossen werden. In dem vorliegenden Beispiel kann somit zwischen einem Linkseinschlagen **715** und einem Rechtseinschlagen **720** des Fahrzeuglenkrades unterschieden werden.

[0082] Wie aus der **Fig. 7c** somit zu ersehen, ermöglichen gemäß dem beschriebenen Verfahren ermittelte Amplituden, Trends und die Dauer verschiedener Fahrmanöver, z.B. Links- oder Rechtseinschläge, Beschleunigen oder Abbremsen, und deren zeitlicher Ablauf sowie die Kombination solcher Fahrmanöver, das individuelle Fahrverhalten oder den Fahrstil eines vorliegenden Fahrers zuverlässig zu ermitteln.

[0083] In dem in **Fig. 7d** gezeigten Diagramm ist die Vorhersagegüte einer beschriebenen gesamten Datenauswertung bezüglich des bei der Testfahrt zugrundeliegenden Fahrerverhaltens gezeigt. In dem Diagramm sind vertikal die drei tatsächlich vorliegenden Fahrstile (konservativ, sportlich und aggressiv) der an den Testfahrten beteiligten die sehr unterschiedlich agierenden Fahrer aufgetragen und in horizontal der mittels des beschriebenen Verfahrens jeweils vorhergesagte, entsprechende Fahrstil. Es ist zu ersehen, dass bei allen drei Fahrstilen eine hohe Vorhersagegüte **725**, **730**, **735** mit Einzelübereinstimmungen mit jeweiligen Werten „39“, „24“ und „38“ vorliegt. Die anderen sechs Felder weisen dagegen relativ geringe Werte von Null bis maximal „8“ auf.

ZITATE ENTHALTEN IN DER BESCHREIBUNG

Diese Liste der vom Anmelder aufgeführten Dokumente wurde automatisiert erzeugt und ist ausschließlich zur besseren Information des Lesers aufgenommen. Die Liste ist nicht Bestandteil der deutschen Patent- bzw. Gebrauchsmusteranmeldung. Das DPMA übernimmt keinerlei Haftung für etwaige Fehler oder Auslassungen.

Zitierte Patentliteratur

- DE 102009025278 A1 [0004]

Patentansprüche

1. Verfahren zum Ermitteln des Zustandes wenigstens einer mechanischen Komponente eines Fahrzeugs, wobei in dem Fahrzeug wenigstens ein Sensor zur Erfassung mindestens einer mechanischen Größe angeordnet ist, **gekennzeichnet durch** die Schritte:

- Merkmalsextraktion (105) zur Bereitstellung charakteristischer Merkmale in den Sensordaten anhand von zu erzeugenden Merkmalsvektoren;
- Klassifizierung (115) der Sensordaten anhand der erzeugten Merkmalsvektoren.

2. Verfahren nach Anspruch 1, **gekennzeichnet durch** die Schritte:

- Fensterung (100) der von dem wenigstens einen Sensor erfassten Sensordaten in eine empirisch vorgebbare Fensterlänge;
- Merkmalsextraktion (105) zur Bereitstellung charakteristischer Merkmale in den Sensordaten anhand von zu erzeugenden Merkmalsvektoren;
- Segmentierung (110) der erzeugten Fenster in Segmente unterschiedlicher Länge;
- Klassifizierung (115) der Sensordaten anhand der erzeugten Merkmalsvektoren.

3. Verfahren nach Anspruch 1 oder 2, **dadurch gekennzeichnet**, dass bei dem ersten Verfahrensabschnitt der Fensterung zunächst Beschleunigungs- und/oder Gyrationzeitreihendaten in zeitlich relativ kurze Fenster mit einer empirisch vorgebbaren festen Zeitlänge unterteilt werden.

4. Verfahren nach Anspruch 3, **dadurch gekennzeichnet**, dass eine Fensterlänge von 0.2 bis 60 s mit einer Überlappung von bis zur Hälfte der gesamten Fensterlänge

5. Verfahren nach Anspruch 4, **dadurch gekennzeichnet**, dass bei relativ kurzzeitigen Ereignissen eine Fensterlänge von 250 - 1000 ms mit einer Überlappung von bis zu 1/8 der gesamten Fensterlänge gebildet wird.

6. Verfahren nach einem der vorhergehenden Ansprüche, **dadurch gekennzeichnet**, dass bei dem zweiten Verfahrensabschnitt der Merkmalsextraktion für jedes erzeugte Fenster verschiedene charakteristische Merkmale extrahiert werden.

7. Verfahren nach Anspruch 6, **dadurch gekennzeichnet**, dass als extrahierte charakteristische Merkmale Zeitdomänenmerkmale oder Frequenzdomänenmerkmale zugrunde gelegt werden.

8. Verfahren nach Anspruch 6 oder 7, **dadurch gekennzeichnet**, dass anhand von extrahierten charakteristischen Merkmalen jedes erzeugte Fenster durch einen Merkmalsvektor gekennzeichnet wird.

9. Verfahren nach einem der vorhergehenden Ansprüche, **dadurch gekennzeichnet**, dass bei dem dritten Verfahrensabschnitt der Segmentierung Übergangspunkte in der Folge von Merkmalsvektoren identifiziert werden, an denen abrupte Änderungen auftreten.

10. Verfahren nach Anspruch 9, **dadurch gekennzeichnet**, dass bei der Identifizierung von Übergangspunkten ein multivarianter Wechselpunkterfassungsalgorithmus angewendet wird, wobei ähnliche aufeinanderfolgende Fenster zu Segmenten gruppiert werden, wobei jedes Segment einer vorgebbaren Art von mechanischer Belastung des Fahrzeugs entspricht.

11. Verfahren nach einem der Ansprüche 8 bis 10, **dadurch gekennzeichnet**, dass bei dem vierten Verfahrensabschnitt der Klassifizierung der Sensordaten die Merkmalsvektoren entsprechend möglicher Einflussfaktoren auf den Fahrzeugzustand (ein)klassifiziert werden.

12. Verfahren nach Anspruch 11, **dadurch gekennzeichnet**, dass die Merkmalsvektoren nach einem bzw. in einen Straßenoberflächentyp, Missbrauchs- bzw. Aufpralltyp und/oder Fahrer bzw. Fahrstil (ein-)klassifiziert werden.

13. Verfahren nach Anspruch 11 oder 12, **dadurch gekennzeichnet**, dass die Klassifizierung unter Verwendung eines multivariaten „Clustering“-Verfahrens, insbesondere unter Verwendung eines „Gaussian-Mixture-Clusterings“, erfolgt.

14. Verfahren nach Anspruch 13, **dadurch gekennzeichnet**, dass die Klassifizierung unter Verwendung eines Ensemble-Entscheidungsbaumes, insbesondere eines „Random Forest“-Klassifizierers, erfolgt.

15. Verfahren nach einem der Ansprüche 11 bis 14, **dadurch gekennzeichnet**, dass Parameter und Hyperparameter des Klassifizierers anhand von Trainingsdaten trainiert und/oder gelernt werden.

16. Verfahren nach einem der vorhergehenden Ansprüche, **dadurch gekennzeichnet**, dass eine Erkennung der Richtung einer mechanischen Einwirkung auf das Fahrzeug mittels Klassifizierung der Sensordaten durchgeführt wird.

17. Verfahren nach Anspruch 16, **dadurch gekennzeichnet**, dass die Klassifizierung der Sensordaten mittels einer Wavelet-Analyse (340) erfolgt, wobei die Sensordaten bezüglich der Position und der Richtung der mechanischen Einwirkung auf das Fahrzeug eingruppiert werden (345).

18. Verfahren nach Anspruch 17, **dadurch gekennzeichnet**, dass die Klassifizierung auf einem Ensemble einer Vielzahl von Entscheidungsbäumen beruht, wobei für jeden Entscheidungsbaum anhand von erzeugten Wavelet-Merkmalen (335) und deren Korrelation mit Zeit- und Frequenzdomänen-Merkmalen (310, 320) eine Zuordnung eines jeweiligen Ereignisses zu einer dominanten Einwirkungsrichtung erstellt wird.

19. Verfahren nach einem der vorhergehenden Ansprüche, zum Ermitteln des Fahrerverhaltens eines Fahrers im Fahrbetrieb eines wenigstens einen Sensor zur Erfassung mindestens einer mechanischen Größe aufweisenden Fahrzeugs, **gekennzeichnet durch** die Schritte:

- Fensterung (100) der von dem wenigstens einen Sensor erfassten Sensordaten in eine empirisch vorgebbare Fensterlänge,
- Merkmalsextraktion (105) zur Bereitstellung charakteristischer Merkmale (715, 720) in den Sensordaten, in Bezug auf Eingriffe des Fahrers, anhand von zu erzeugenden Merkmalsvektoren,
- Segmentierung (110, 710, 710') der erzeugten Fenster in Segmente unterschiedlicher Länge,
- Klassifizierung (115) der Sensordaten anhand der erzeugten Merkmalsvektoren zur Ermittlung wenigstens eines Fahrereingriffs.

20. Computerprogramm, welches eingerichtet ist, jeden Schritt eines Verfahrens gemäß einem der Ansprüche 1 bis 17 durchzuführen.

21. Steuergerät eines Fahrzeugs, welches eingerichtet ist, durch Aufspielen des Computerprogramms gemäß Anspruch 20 auf einen Mikroprozessor oder Mikrocontroller des Steuergeräts das Verfahren gemäß einem der Ansprüche 1 bis 19 auszuführen.

Es folgen 10 Seiten Zeichnungen

Anhängende Zeichnungen

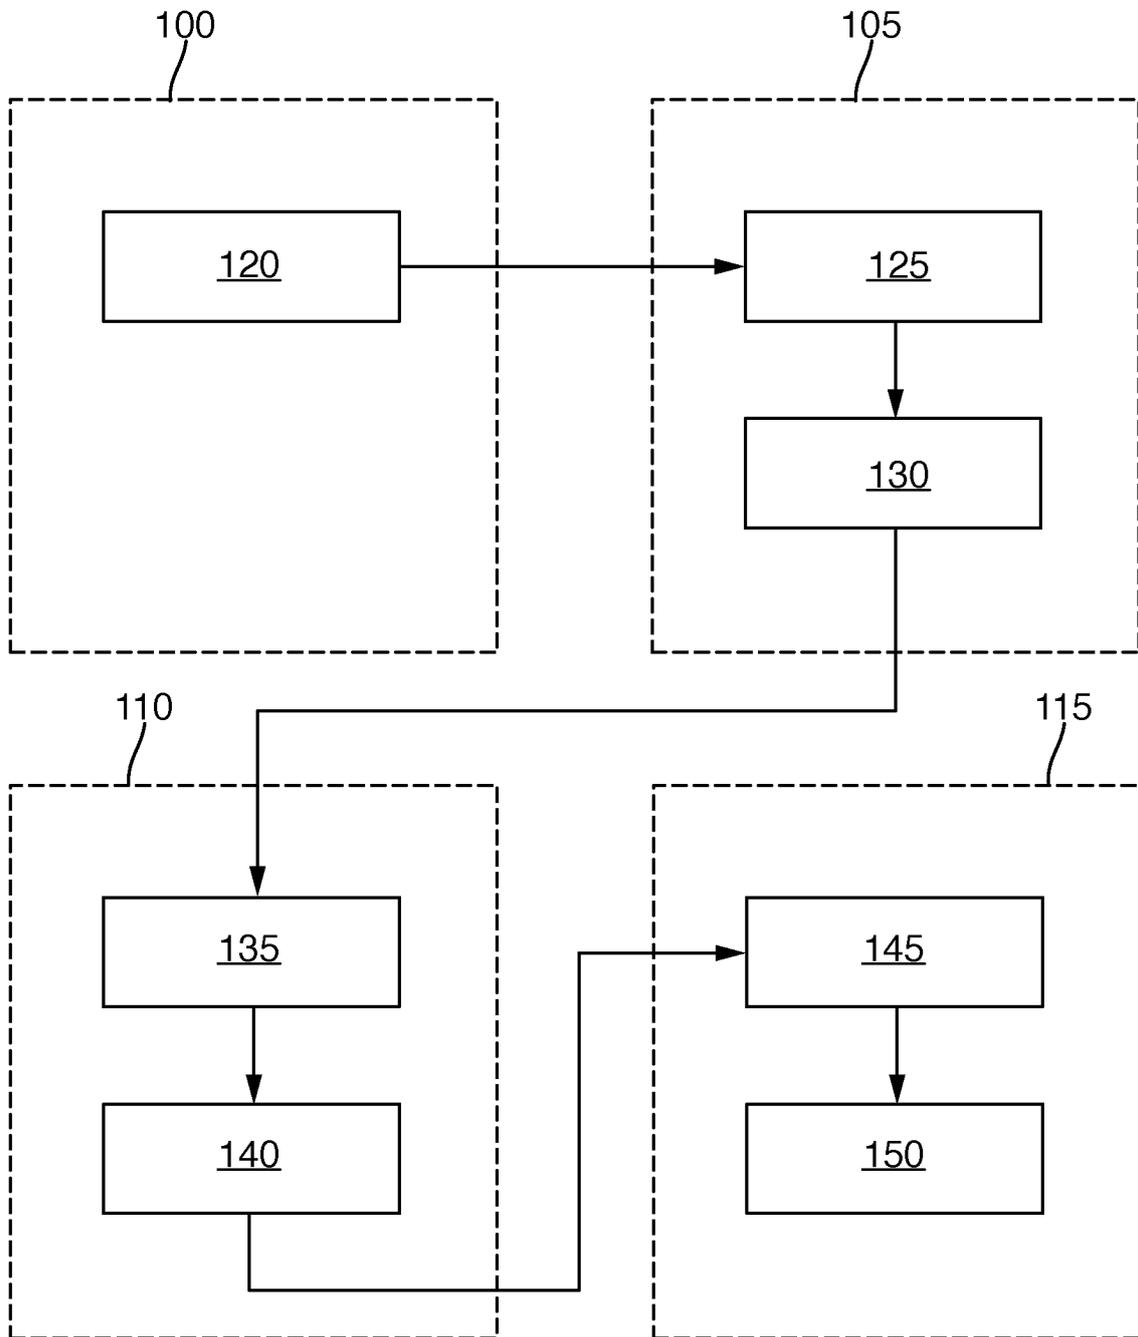


Fig. 1

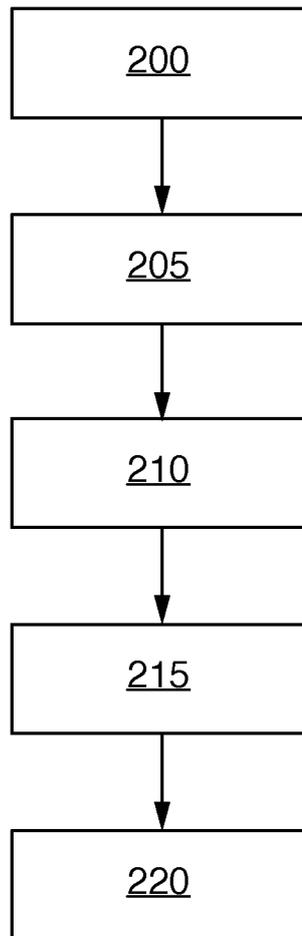


Fig. 2

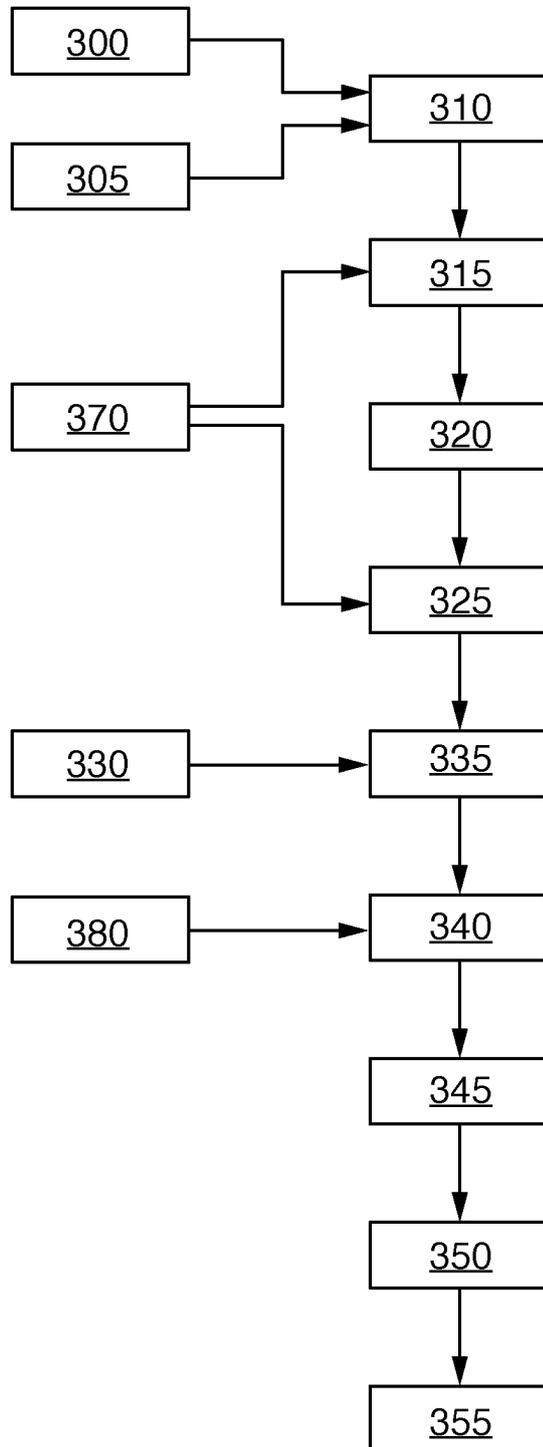


Fig. 3

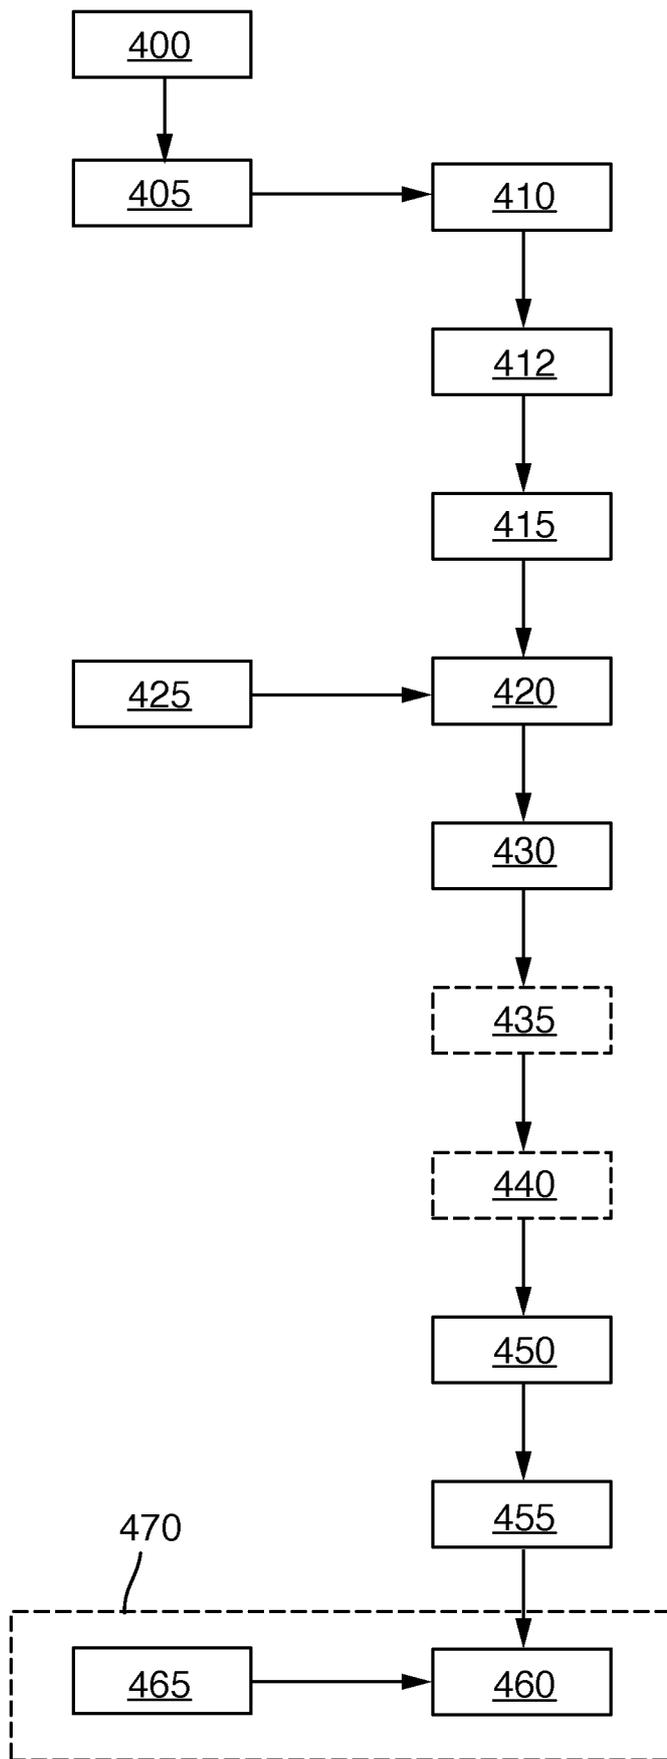


Fig. 4

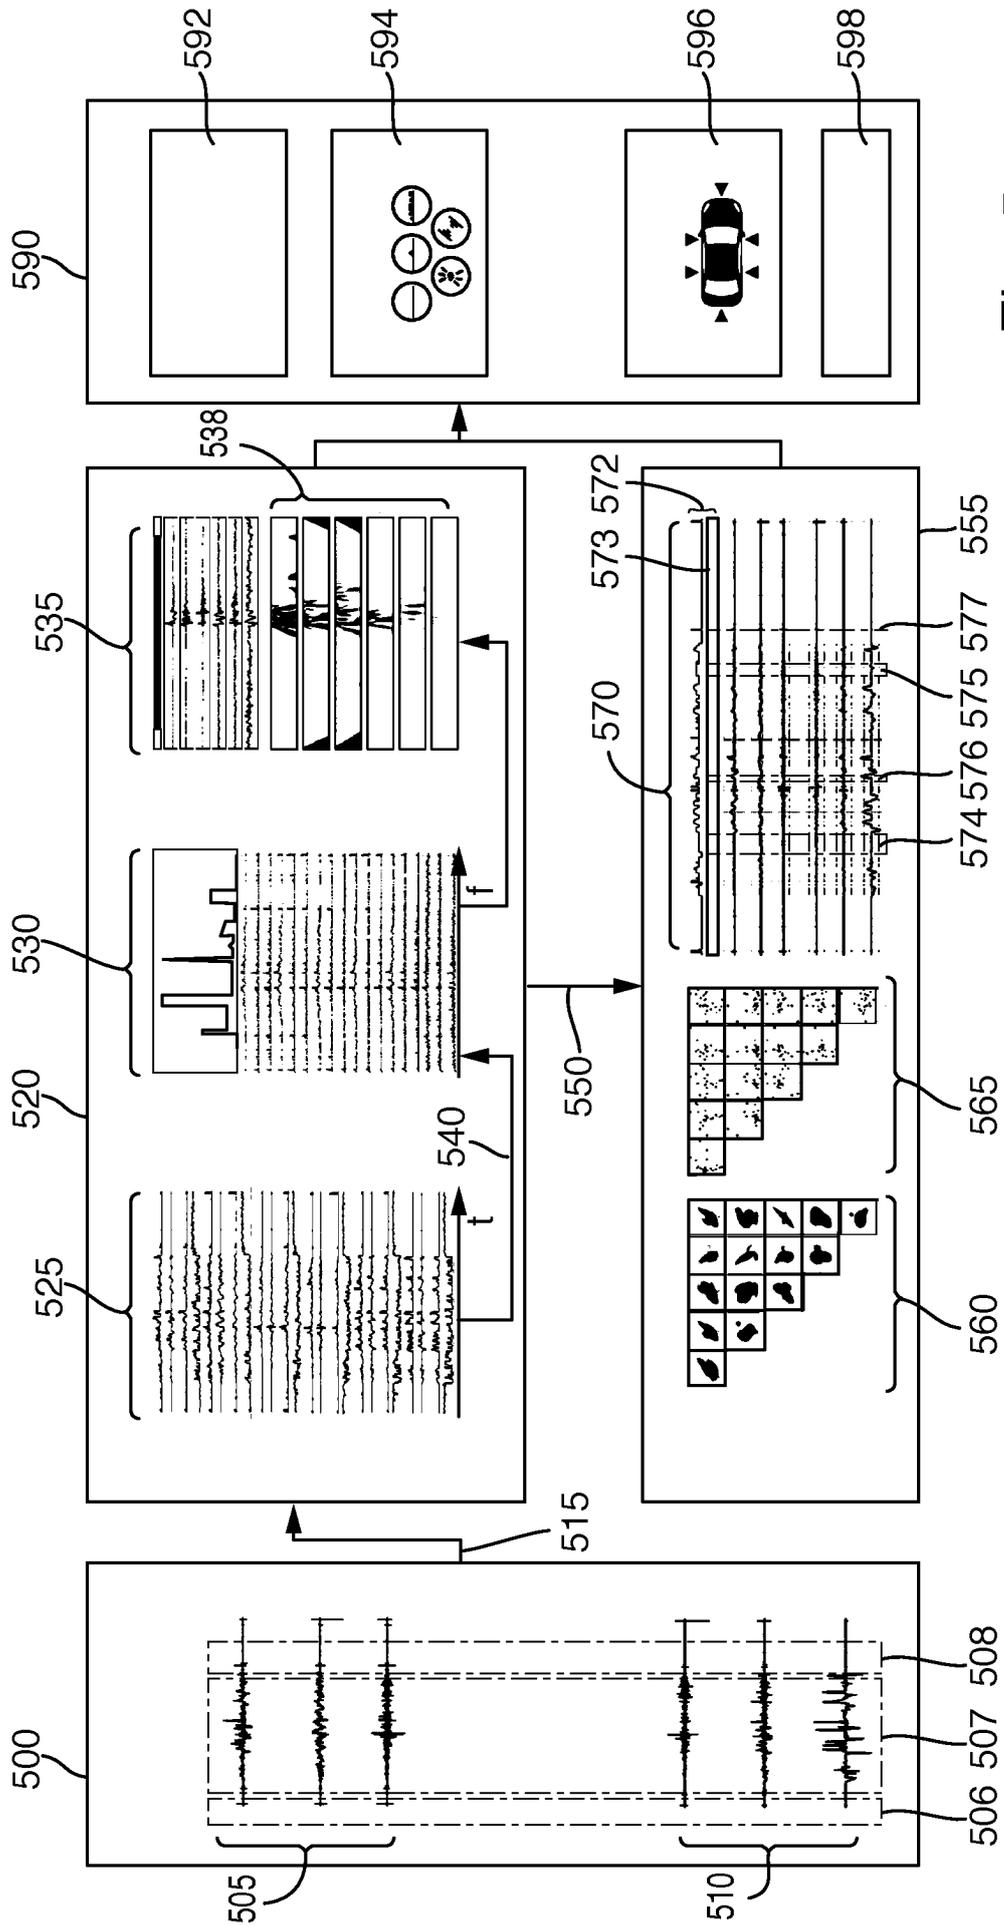


Fig. 5

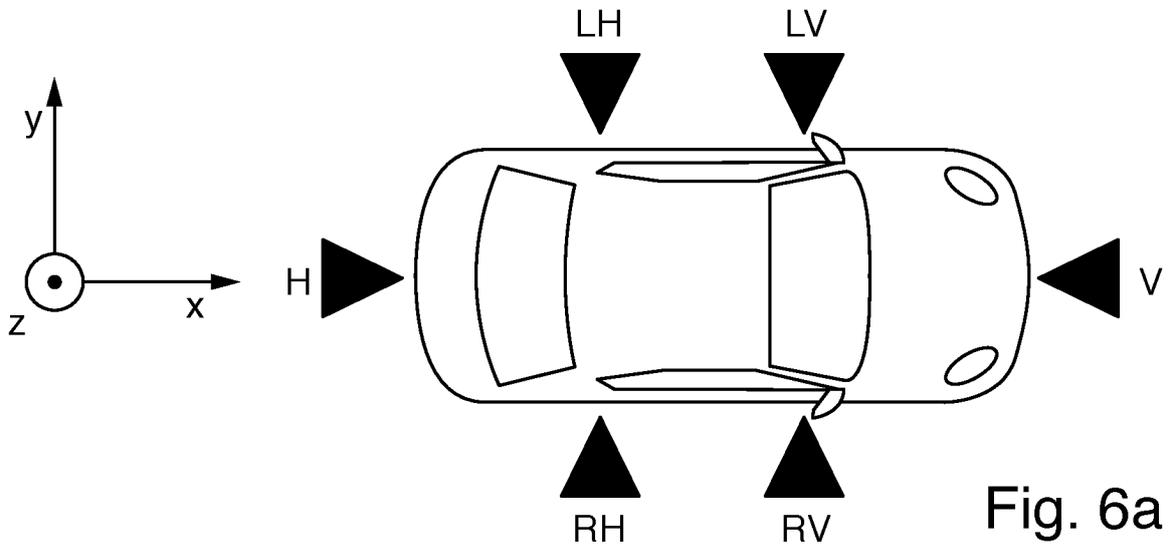


Fig. 6a

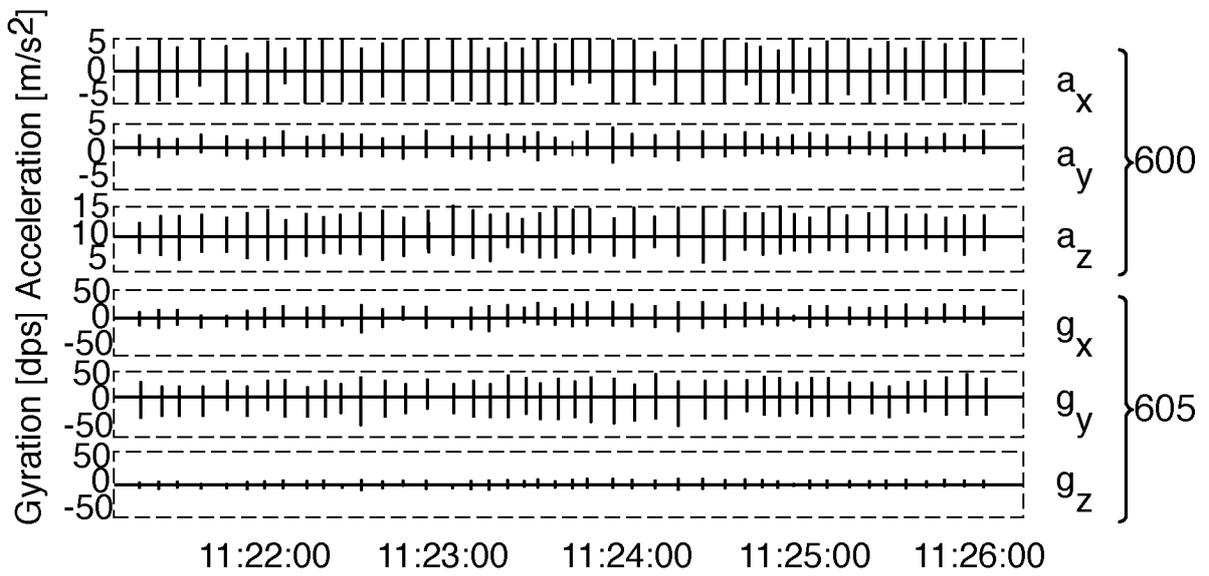


Fig. 6b

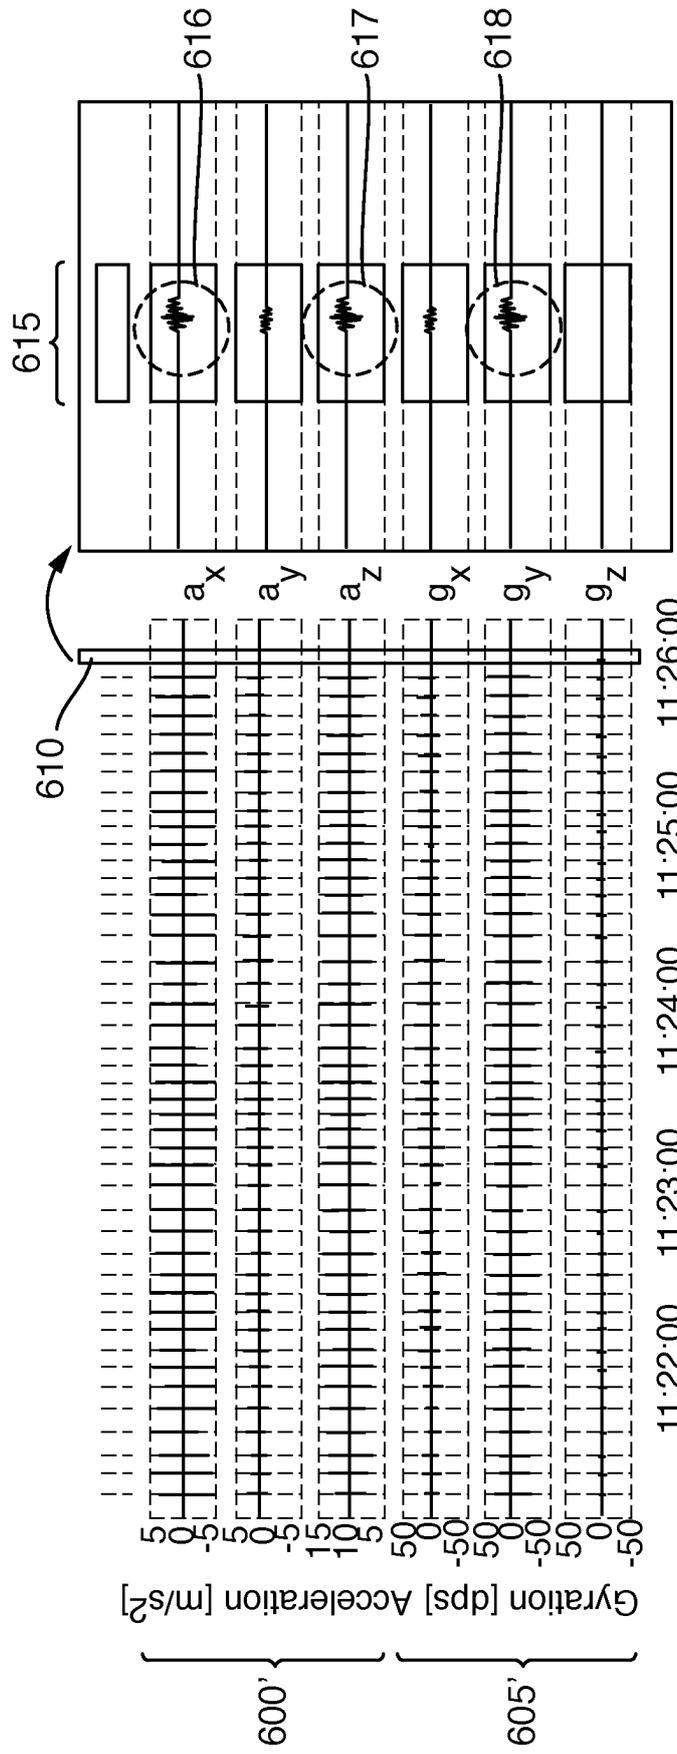


Fig. 6c

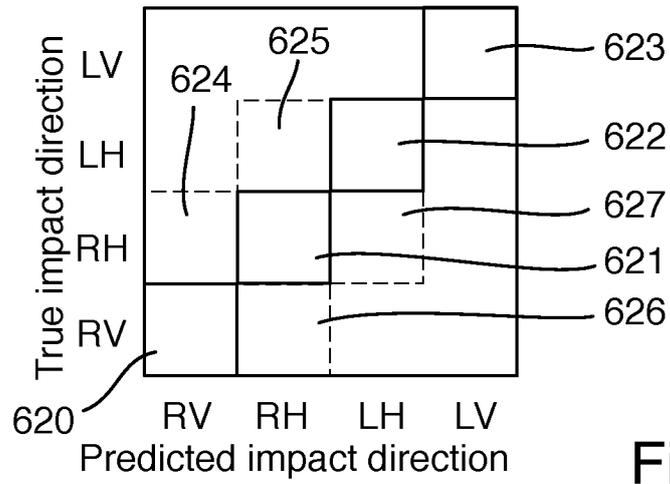


Fig. 6d

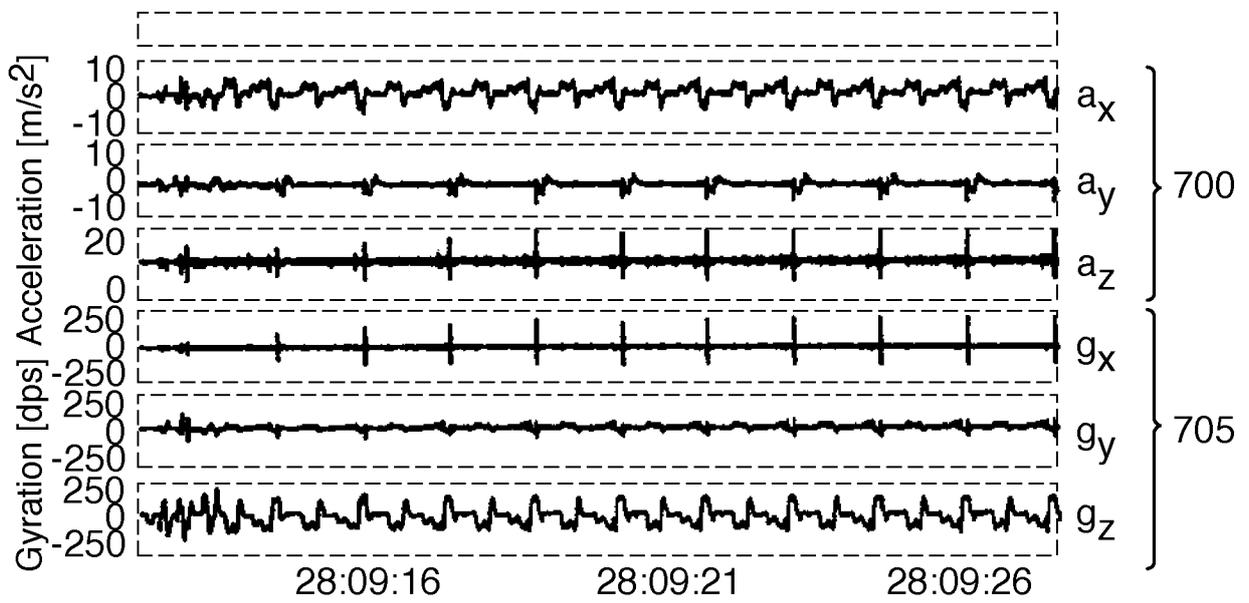


Fig. 7a

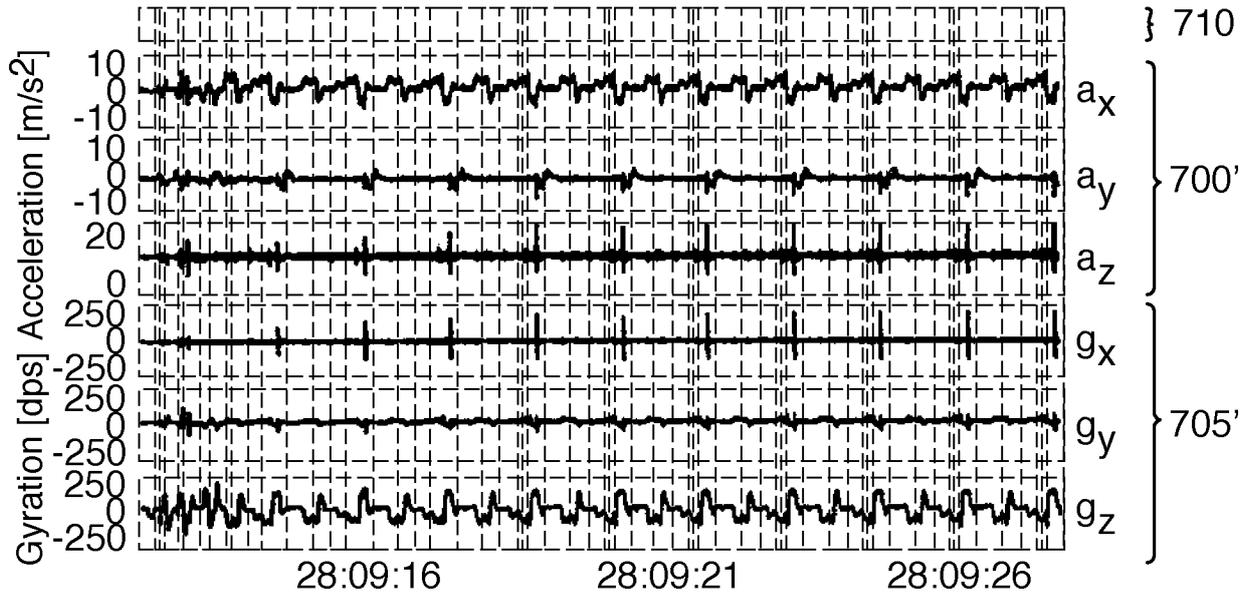


Fig. 7b

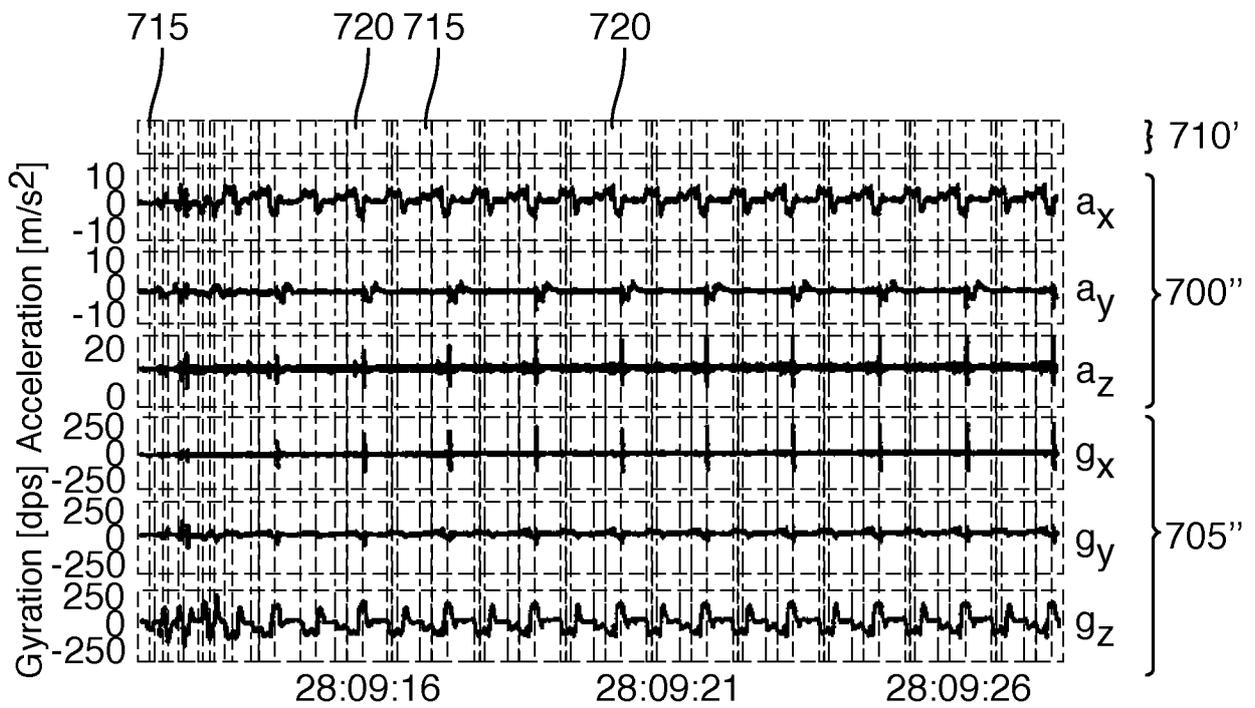


Fig. 7c

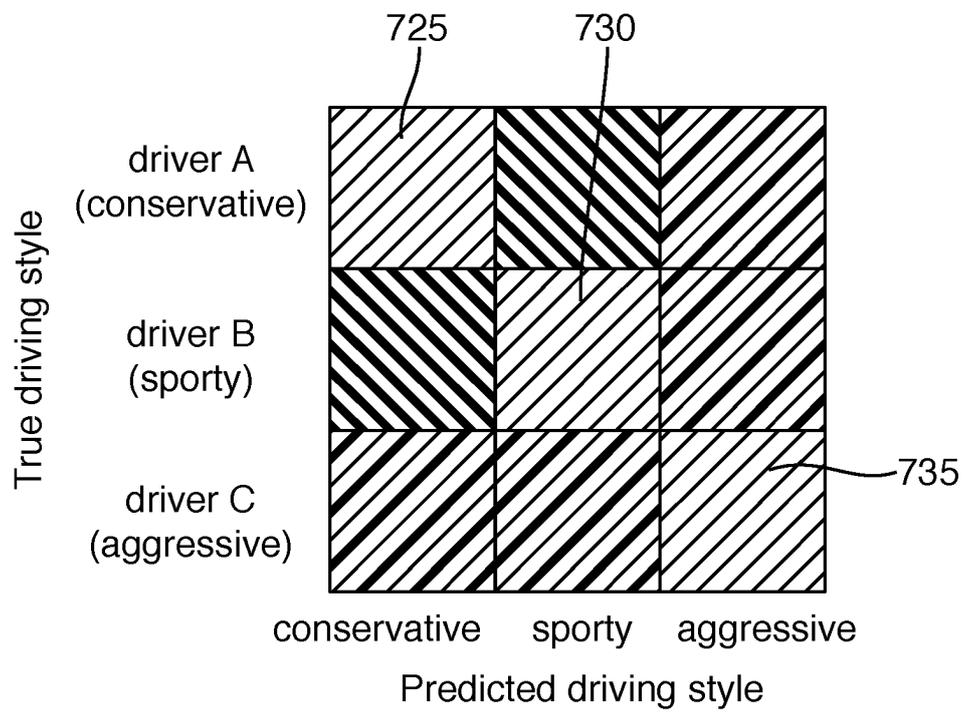


Fig. 7d