

Beschreibung

[0001] Die Erfindung betrifft ein Verfahren zum Testen eines Spurhalteassistenzsystems für ein Fahrzeug.

[0002] Aus dem Stand der Technik sind Spurhalteassistenzsysteme für Fahrzeuge allgemein bekannt. Ebenso ist es allgemein bekannt, derartige Spurhalteassistenzsysteme, insbesondere in einer Entwicklungsphase, zu testen.

[0003] Der Erfindung liegt die Aufgabe zu Grunde, ein gegenüber dem Stand der Technik verbessertes Verfahren zum Testen eines Spurhalteassistenzsystems für ein Fahrzeug anzugeben.

[0004] Die Aufgabe wird erfindungsgemäß gelöst durch ein Verfahren zum Testen eines Spurhalteassistenzsystems für ein Fahrzeug mit den Merkmalen des Anspruchs 1.

[0005] Vorteilhafte Ausgestaltungen der Erfindung sind Gegenstand der Unteransprüche.

[0006] In einem erfindungsgemäßen Verfahren zum Testen eines Spurhalteassistenzsystems für ein Fahrzeug, insbesondere für einen Lastkraftwagen, wird ontologiebasiert eine Kategorie adäquater und relevanter Szenarien für existierende Feldtests extrahiert, wobei vorteilhafterweise kritische Szenarien, insbesondere ungünstigster-Fall-Szenarien, d. h. so genannte worst-case-Szenarien, mittels Data-Mining extrahiert und in Anforderungen für eine Testabdeckung transformiert werden.

[0007] Das erfindungsgemäße Verfahren und eine entsprechende Vorrichtung zur Durchführung des Verfahrens ermöglichen eine adaptive Testabdeckung für das Spurhalteassistenzsystem. Das Verfahren ermöglicht es, eine Kluft zwischen wissensbasierten und datenbasierten Ansätzen zu schließen, um eine kontinuierliche Erweiterung des Wissens in der adaptiven Testabdeckung zu ermöglichen.

[0008] Im Verfahren werden als obligatorische Verfahrensschritte beispielsweise folgende Schritte durchgeführt, wobei deren Reihenfolge veränderbar ist:

- I. Ereignisbasiertes Data-Mining
- II. Clustering, d. h. Gruppierung, von naturalistischen Fahrscenarien basierend auf Spurverlassenswarnereignissen des Spurhalteassistenzsystems
- III. Training eines Klassifikators mit markierten Clusterdaten
- IV. Anwendung des Klassifikators mit naturalistischen Fahrdaten

V. Nutzung der klassifizierten Clusterdaten zur Ermittlung der charakteristischen Verläufe der Systemeingangsgrößen für die jeweilige Gruppierung

VI. Identifikation eines zu den charakteristischen Verläufen zugehörigen Szenarios

VII. Bestimmen der jeweiligen Gruppe durch eine Parameter- und Signalschätzung von der Zeitreihenanalyse

VIII: Ableitung von worst-case-Szenarien, d. h. von ungünstigster-Fall-Szenarien

IX. zeitliche Kombination unterschiedlichen Charakterisierungen eines charakteristischen Signalverlaufs

X. Parsing von Felddaten in ein für die synthetische Umgebung geeignetes Format

XI. Kombination von Einzelergebnissen zu einem Testablauf

XII. Beschreiben des Testablaufs in einem Defacto-Standardformat

XIII. Testausführung auf einer so genannten auf Cluster-in-the-Loop-Plattform

XIV. Auswertung von Testfällen mittels Bestanden- und Durchgefallen-Kriterien

XV. Anwendung der adaptiven Testabdeckung

[0009] Eine weitere Vorgehensweise zur Berücksichtigung zusätzlicher Felddaten bei bereits ermittelten charakteristischen Verläufen der Systemeingangsgrößen sieht beispielsweise als optionale Verfahrensschritte vor:

XVI. Vergleich der zusätzlichen Felddaten mit charakteristischen Verläufen

XVII. Gegebenenfalls Erweiterung der Anzahl der Cluster für die Gruppierung

XVIII. Wiederholung und Anwendung der Schritte von II bis XV.

[0010] Ausführungsbeispiele der Erfindung werden im Folgenden anhand von Zeichnungen näher erläutert.

[0011] Dabei zeigen:

Fig. 1 schematisch eine Einbindung einer adaptiven Testabdeckung in einen Erprobungsprozess am Beispiel eines Spurhalteassistenzsystems,

Fig. 2 schematisch eine Unterscheidung in Anwendungsfall, verschiedene Szenarien, Situationen und Szenen sowie deren Bestandteile,

Fig. 3 schematisch eine Darstellung der Unterschiede zwischen Tests einzelner Einheiten

oder Komponenten, einem situationsbasierten open-loop-testing und einem szenarienbasierten closed-loop-testing,

Fig. 4 schematisch eine ontologiebasierte Test-szenariosynthese,

Fig. 5 schematisch eine Distanz bis zum Überfahren einer Fahrspurmarkierung bei einem Szenario mit gerader Straße,

Fig. 6 schematisch eine Distanz bis zum Überfahren einer Fahrspurmarkierung bei einem Szenario mit gekrümmter Straße,

Fig. 7 schematisch eine Identifizierung von Parametern, zum Beispiel der Time to Line Crossing, d. h. der Zeit bis zum Überfahren einer Fahrspurmarkierung, mit unterschiedlichen Quergeschwindigkeiten an einer Cluster-in-the-Loop Plattform,

Fig. 8 schematisch eine ereignisbasierte Analyse einer Distanz bis zum Überfahren einer Fahrspurmarkierung,

Fig. 9 schematisch ein Clustering einer ereignisbasierten Analyse,

Fig. 10 schematisch eine Anwendung des Clustering auf eine ereignisbasierte Analyse einer Distanz bis zum Überfahren einer Fahrspurmarkierung,

Fig. 11 schematisch charakteristische Verläufe der Systemeingangsgrößen für den jeweiligen Cluster, und

Fig. 12 schematisch ein Verfahren und eine Vorrichtung zum Testen eines Spurhalteassistenzsystems mittels Data-Mining von Fahrzeugdaten und adaptiver Testabdeckung.

[0012] Einander entsprechende Teile sind in allen Figuren mit den gleichen Bezugszeichen versehen.

[0013] Im Folgenden werden anhand der **Fig. 1** bis **Fig. 12** ein Verfahren zum Testen eines Spurhalteassistenzsystems **3** für ein Fahrzeug **2**, insbesondere für einen Lastkraftwagen, und eine Vorrichtung zur Durchführung des Verfahrens beschrieben. Damit wird eine adaptive Testabdeckung **9** für das Spurhalteassistenzsystem **3** ermöglicht.

[0014] Die digitale Transformation hat zu schnellen und tiefgreifenden Veränderungen in der Lastkraftwagenindustrie geführt und wird die Zukunft des Güterverkehrs verändern und zu einer Ära digitalisierter Lastkraftwagen führen. Aufgrund globaler Forschungs- und Entwicklungsaktivitäten nimmt die Technologiereife des automatisierten Fahrens ständig zu. In diesem Wachstumstrend sind Daten von besonderer Bedeutung, um diese Umwandlung zu fördern. Jedes Fahrzeug **2**, welches mit einer entsprechenden Datenerfassung ausgerüstet ist, produ-

ziert täglich ein großes Datenvolumen bezüglich öffentlicher Straßen und deren entsprechenden geographischen Variation. Dies erfordert höhere Kapazitäten zur Datenerfassung und -speicherung, hat aber den Vorteil, dass eine vollständige Re-Simulation mit modifizierten funktionalen Software-Versionen über alle Feldtests (Field Operational Test - FOT) ermöglicht wird.

[0015] Lastkraftwagen, insbesondere schwere Lastkraftwagen, und Personenkraftwagen unterscheiden sich in ihrer wirtschaftlichen Bedeutung und in ihrer Fahrzeugtechnik. Trotz rascher Fortschritte im Bereich der Umgebungserfassungssensortechnologie sind die Anforderungen an die Umgebungserfassungssensorik bei Lastkraftwagen, insbesondere bei schweren Lastkraftwagen, deutlich höher als bei Personenkraftwagen. Infolgedessen stellen Lastkraftwagen, insbesondere schwere Lastkraftwagen, eine große Herausforderung bei der Überprüfung und Validierung von automatisierten Fahrfunktionen dar. Zufallsfehler werden in der Regel durch stochastische Analysen von gefahrenen Kilometern ermittelt. Im Gegensatz dazu können systematische Fehler identifiziert und lokalisiert werden durch eine sorgfältige Analyse, eine geeignete Vorrichtungsausstattung zur Durchführung der Tests und eine entsprechende Systemdezentralisierung. Daher wird ein methodischer Ansatz benötigt, um das Test-Dilemma der automatisierten Fahrfunktionen zu überwinden und eine erfolgreiche Markteinführung zu ermöglichen.

[0016] Software-Produktlinien haben daten- und wissensbasierte Testmethoden etabliert, um die erforderliche Zuverlässigkeit ihrer Produkte sicherzustellen. Datenbasierte Ansätze analysieren empirische Daten, um automatische Fahrsysteme basierend auf ihren so genannten Key Performance Indicators (KPIs) d. h. basierend auf ihren Hauptleistungsindikatoren, zu validieren. Um im Laufe der Produktentwicklung eine effiziente Verifizierung zu ermöglichen, werden verschiedene so genannte X-in-the-Loop (XiL) Simulationen, reichend von makroskopischen bis nanoskopischen Verkehrssimulationen, eingesetzt. Diese synthetischen simulativen Ansätze werden häufig in einem so genannten closed-loop setting verwendet, d. h. in einer geschlossenen Schleife, um die Anforderungen der Testabdeckung sicherzustellen, welche definiert wird durch Fachwissen in Form von Aussagen in natürlicher Sprache. Implizite Informationen werden von Experten in Form von formalen Testanforderungen explizit gemacht. Trotz der einfachen Nachverfolgbarkeit dieses Ansatzes ist einer seiner Hauptnachteile die Annahme der Wissensvollständigkeit.

[0017] Trotz der Vielfalt der repräsentativen Situationen im Straßenverkehr mit einem streckenbasierten Testansatz ist eine drastische Reduzierung der

erforderlichen Fahrstrecke erforderlich. Ein Ausweg aus diesem Dilemma besteht darin, eine Initialroute zu bestimmen, die eine Vielfalt möglicher Variationen im Straßenverkehr ermöglicht. Darüber hinaus muss ein Testkatalog identifiziert werden, um einen Parameterbereich relevanter Szenarien und Systemumgebungen adäquat abzudecken. Anschließend ist eine Korrelation zwischen realen und simulierten Daten notwendig, um abzuleiten, ob mehr Testkilometer erforderlich sind oder mehr Simulationen durchgeführt werden müssen. Der im Folgenden näher beschriebene Ansatz zielt darauf ab, die Kluft zwischen wissensbasierten und datenbasierten Ansätzen zu überbrücken und eine kontinuierliche Erweiterung des Wissens in einer adaptiven Testabdeckung **9** zu ermöglichen.

[0018] Die Erfindung, welche im Folgenden anhand von Ausführungsbeispielen beschrieben wird, betrifft ein Verfahren und eine Vorrichtung zum Testen eines Spurhalteassistenzsystems **3** für ein Fahrzeug **2**, insbesondere für einen Lastkraftwagen, insbesondere zum Testen eines Spurhaltewarnprozesses. Es ist eine ontologiebasierte Methode identifiziert, um eine Kategorie von adäquaten und relevanten Szenarien für bestehende Feldtests, auch als Field Operational Tests (FOT) bezeichnet, zu extrahieren. Es stellt ein Konzept für eine semantische Repräsentation von worst-case-Szenarien dar. Diese sind mittels Data-Mining-Techniken zu extrahieren und systematisch in Anforderungen für eine Testabdeckung umzuwandeln. Das vorgeschlagene Konzept zielt darauf ab, die Lücke zwischen wissens- und datenbasierten Ansätzen zu schließen, um eine kontinuierliche Erweiterbarkeit des Wissens in einer adaptiven Testabdeckung **9** zu ermöglichen, wie in **Fig. 1** dargestellt.

[0019] **Fig. 1** zeigt eine adaptive Testabdeckung **9** am Beispiel des Spurhalteassistenzsystems **3**, wobei die funktionale Spezifikation **30** aus Spitzenanforderung **32** und Anwendungsfällen **13** erstellt und in natürlicher Sprache formuliert ist. Diese bilden die Basis für das wissensbasierte Testen **40**, welches das zu testende Spurhalteassistenzsystem **3** mit konkreten Szenarien **16** beaufschlägt. Die Adaption besteht nun in der Erweiterung der mit Hilfe des wissensbasierten Testens erzeugten konkreten Szenarien **16** durch weitere logische Szenarien **15**, welche ontologiebasiert, d. h. mittels einer ontologiebasierten Szenariosynthese **27**, aus funktionalen Szenarien **14** synthetisiert werden. Dabei werden die funktionalen Szenarien **14** aus dem datenbasierten Testen, insbesondere aus einem ereignisbasierten Data-Mining **26**, abgeleitet. Dabei kennzeichnet Bezugszeichen **1** ein natürliches Fahrscenario, welches mit dem Fahrzeug **2** mit dem Spurhalteassistenzsystem **3** in einer realen Testfahrt befahren wird, d. h. ein reales Fahrscenario. Mit Bezugszeichen **4** ist ein synthetisches Fahrscenario gekennzeichnet, welches mit Kamera-Box **5** für das Spurhalteassistenzsystem **3** er-

fasst oder in dieser oder mittels dieser für das Spurhalteassistenzsystem **3** simuliert wird. Jeweilige Ereignisse **6, 7** des Spurhalteassistenzsystems **3** werden einer mit dem Bezugszeichen **8** gekennzeichneten Kritikalitätsanalyse, insbesondere auf Basis einer so genannten Time to Line Crossing, d. h. einer Zeit bis zum Überfahren einer Fahrspurmarkierung, zugeführt. Das Bezugszeichen **9** kennzeichnet die adaptive Testabdeckung **9**, welche aus der Kritikalitätsanalyse **8** resultiert. Bezugszeichen **10** kennzeichnet ein so genanntes Parsing, d. h. eine Konvertierung in eine de-facto Standard Beschreibungssprache, von worst-case-Szenarien auf Basis der Kritikalitätsanalyse **8**. Zwischen der adaptiven Testabdeckung **9** und einer Testautomation **11** besteht eine Wechselbeziehung. Die Testautomation **11** und das Parsing von worst-case-Szenarien **10** beeinflussen das synthetische Fahrscenario **4** und/oder die Kamera-Box **5**. Des Weiteren beeinflusst eine Fahrzeugdynamik **12** das synthetische Fahrscenario **4**.

[0020] Die Vision des unfallfreien Verkehrs beschleunigt die Weiterentwicklung von intelligenten, verbundenen und komplexen Fahrfunktionen in Fahrzeugen **2**. Deswegen müssen Testverfahren mit diesen steigenden Anforderungen umgehen. Datenbasierte Ansätze analysieren empirische Daten, um neues Wissen zu gewinnen zu explizieren. Neben der Statistik der Ursachen von Unfällen als empirische Daten werden zunehmend naturalistische Fahrdaten als Quelle des Wissens angenommen. Gleichwohl ist eine statistische Validierung mittels Feldtests, dem so genannten Field Operational Testing (FOT) sehr zeitaufwändig und ressourcenaufwändig und umfasst Milliarden von Kilometern realer Fahrttests für eine erfolgreiche Markteinführung eines vollautomatischen Fahrzeugs **2**. Trotz dieser Nachteile ist dies wichtig, um die Funktionssicherheit und Zuverlässigkeit sicherzustellen.

[0021] Eine Re-Simulation aufgezeichneter Fahrsequenzen erleichtert situationsbezogene Regressionstests im Open-Loop-Setting. Um im Laufe der Produktentwicklung eine effiziente Verifizierung zu ermöglichen, werden verschiedene so genannte X-in-the-Loop (XiL) Simulationen, reichend von makroskopischen bis nanoskopischen Verkehrssimulationen, eingesetzt. Diese synthetischen simulativen Ansätze werden häufig in einem so genannten closed-loop setting verwendet, d. h. in einer geschlossenen Schleife, um die Anforderungen der Testabdeckung sicherzustellen, welche definiert wird durch Fachwissen in Form von Aussagen in natürlicher Sprache. Implizite Informationen werden von Experten in Form von formalen Testanforderungen explizit gemacht. Trotz der einfachen Nachverfolgbarkeit dieses Ansatzes ist einer seiner Hauptnachteile die Annahme der Wissensvollständigkeit.

[0022] Aktuelle Forschungsanstrengungen nutzen Data-Mining Techniken im Rahmen der Fahrerhaltensbewertung oder Fallstudienanalyse. Aufgrund der Interaktion von Fahrerassistenzsystemfunktionen mit der Umgebung wird das Testen hochkomplex und eine Validierung kann nicht mit einem einzigen Testansatz realisiert werden, wie in den **Fig. 2** und **Fig. 3** dargestellt.

[0023] **Fig. 2** zeigt eine Darstellung der Unterschiede zwischen Tests einzelner Einheiten oder Komponenten, dem so genannten Unit Testing **UT**, einem situationsbasierten open-loop-testing, d. h. einem situationsbasierten Test mit offener Schleife, und einem szenarienbasierten closed-loop-testing **CLT**, d. h. einem szenarienbasierten Test mit geschlossener Schleife. Dabei ist mit dem Bezugszeichen **13** ein Anwendungsfall, d. h. ein Use Case, gekennzeichnet. Bezugszeichen **14** kennzeichnet ein jeweiliges funktionales Szenario. Bezugszeichen **15** kennzeichnet ein jeweiliges logisches Szenario. Bezugszeichen **16** kennzeichnet ein jeweiliges konkretes Szenario. Bezugszeichen **17** kennzeichnet eine jeweilige Situation. Bezugszeichen **18** kennzeichnet eine Szene.

[0024] Bezugszeichen **19** kennzeichnet einen Fahrer des Fahrzeugs **2**. Bezugszeichen **20** kennzeichnet eine Aktion. Bezugszeichen **12** kennzeichnet die Fahrzeugdynamik. Bezugszeichen **21** kennzeichnet Sensoren des Fahrzeugs **2**. Bezugszeichen **22** kennzeichnet eine Fahrfunktion. Bezugszeichen **23** kennzeichnet Aktoren des Fahrzeugs **2** und Bezugszeichen **24** statische und dynamische Elemente. Der Fahrer **19** und die Aktoren **23** beeinflussen eine Aktion **20**, welche zu einer entsprechenden Fahrzeugdynamik **12** führt. Die Fahrzeugdynamik **12** und die statischen und dynamischen Elemente **24**, insbesondere in der Umgebung des Fahrzeugs **2**, werden von den Sensoren **21** des Fahrzeugs **2** erfasst. Entsprechende Sensorergebnisse werden der Fahrfunktion **22** zugeführt und führen zu einer entsprechenden Ansteuerung der Aktoren **23**.

[0025] In **Fig. 3** sind das situationsbasierte open-loop-testing **OLT** mit dem Unit Testing **UT** und das szenarienbasierte closed-loop-testing **CLT** im Zeitverlauf **ZV** dargestellt, wobei das Bezugszeichen **25** Ziele und Werte kennzeichnet. Zweckmäßigerweise werden das situationsbasierte open-loop-testing **OLT** mit dem Unit Testing **UT** und das szenarienbasierte closed-loop-testing **CLT** nacheinander durchgeführt, beispielsweise auch ein- oder mehrfach wiederholt nacheinander.

[0026] **Fig. 4** zeigt eine ontologiebasierte Testszenariosynthese. Es wird zunächst ein ereignisbasiertes Data-Mining **26** mit einer ontologiebasierten Szenariosynthese **27** durchgeführt.

[0027] Die ontologiebasierte Szenariosynthese **27** umfasst:

1. Szenariofilterung mittels einer Kritikalitätsmatrix
2. Ermittlung einer Szenariozugehörigkeit
3. Clusterbildung, d. h. Gruppierung, von Fahrscenarien, insbesondere basierend auf Spurverlassenswarnereignissen des Spurhalteassistenzsystems **3**
4. Identifizieren von Parametern, zum Beispiel der Time to Line Crossing, d. h. der Zeit bis zum Überfahren einer Fahrspurmarkierung

[0028] Aus dem ereignisbasierten Data-Mining **26** resultieren die logischen Szenarien **15**, welche in eine systematische Testfallgenerierung **28** mit einem generischen Modell für eine Szenariobeschreibung **29** einfließen.

[0029] Dieses generische Modell für die Szenariobeschreibung **29** umfasst:

1. eine Straßengeometrie, zum Beispiel Krümmung und/oder andere Parameter
2. statische Objekte, zum Beispiel Verkehrszeichen und/oder andere statische Objekte
3. dynamische Objekte, zum Beispiel andere Fahrzeuge und/oder andere dynamische Objekte
4. Wetterverhältnisse, zum Beispiel Regen und/oder andere Wetterverhältnisse

[0030] Aus der systematischen Testfallgenerierung **28** resultieren die konkreten Szenarien **16** und daraus Testfälle **31**. In die Testfälle **31** fließt des Weiteren eine funktionale Spezifikation **30** ein, welche aus Spitzenanforderungen **32** und den Anwendungsfällen **13** resultiert, wobei die Spitzenanforderungen **32** auch in die Anwendungsfälle **13** einfließen.

[0031] Die Testfälle **31** werden in einer Testausführung **33** mit einer so genannten Cluster-in-the-Loop Plattform **34** verwendet. Cluster-in-the-Loop steht für Subsystem-in-the-Loop. Ein Subsystem kann ein Komponenten-Cluster oder eine Komponente sein. Eine daraus resultierende Änderung ausgewählter Parameter **35** fließt in die systematische Testfallgenerierung **28** ein.

[0032] Testresultate **36** der Testausführung **33** fließen in eine Testevaluierung, d. h. in eine Testauswertung **37**, ein. Es erfolgt eine Auswertung **38** der Testfälle **31** mittels Bestanden- und Durchgefallen-Kriterien. Basierend auf dieser Auswertung sind gegebenenfalls Änderungen am zu testenden System vorzunehmen. Beispielsweise muss das Produkt nachge-

bessert werden, falls es die gewünschte Spezifikation nicht erfüllt.

[0033] Im Folgenden wird die Ermittlung der so genannten Time to Line Crossing, d. h. der Zeit bis zum Überfahren der Fahrspurmarkierung, näher beschrieben. Hierzu wird zunächst eine trigonometrische Berechnung beschrieben.

[0034] Eine mathematische Beschreibung der Time to Line Crossing t_{LC} ist wie folgt:

$$t_{LC} = \frac{d_{LC}}{v_{ego}}, \forall v_{ego} > 0 \quad (1)$$

[0035] Dabei ist d_{LC} [m] eine Distanz bis zum Überfahren der Fahrspurmarkierung entlang eines Fahrwegs des Fahrzeugs **2** und v_{ego} [m/s] ist eine Geschwindigkeit des Fahrzeugs **2**, welche beispielsweise eine Längsgeschwindigkeit $v_{längs}$ [m/s] und/oder eine Lateralgeschwindigkeit v_{lat} [m/s] des Fahrzeugs **2** umfasst (Die jeweilige Angabe in eckigen Klammern gibt die Dimension des jeweiligen Parameters an). Der Parameter d_{LC} [m] ist direkt berechenbar mittels der Kosinusregel:

$$d_{LC} = \alpha * r_{ego} \quad (2)$$

wobei der Radius r_{ego} des Fahrwegs des Fahrzeugs **2** berechnet wird als

$$r_{ego} = \frac{v_{längs}}{\varphi} \quad (3)$$

mit φ [rad/s] als Gierrate des Fahrzeugs **2**. α ist der Winkel zwischen einer Linie von einem Zentrumspunkt $(x,y)_{ego}$ einer Trajektorie des Fahrzeugs **2** zu einem Fahrspurverlassenspunkt \mathbf{p} und einer Linie von einem Vorderrad des Fahrzeugs **2** zum Zentrumspunkt $(x,y)_{ego}$, wie in der **Fig. 5** dargestellt, welche die Distanz d_{LC} [m] bis zum Überfahren der Fahrspurmarkierung bei einem Szenario mit gerader Straße zeigt.

[0036] Im Fall eines solchen Szenarios mit gerader Straße wird der Winkel α mittels der Kosinusregel berechnet:

$$\alpha = \arccos\left(\left(\frac{b^2 + r_{ego}^2 - c^2}{2 * b * c}\right)\right) \quad (4)$$

wobei

$$b = r_{ego} - \frac{f}{\cos(\gamma)} \quad (5)$$

[0037] Dabei ist f die Distanz zwischen dem Vorderrad des Fahrzeugs **2** und einer Fahrspurgrenze entlang einer rechtwinkligen Linie zum Straßenverlauf, γ der Winkel zwischen dieser rechtwinkligen Linie f und einer Linie zwischen dem Vorderrad des Fahrzeugs **2** und dem Zentrumspunkt $(x,y)_{ego}$, b der Abstand zwischen dem Zentrumspunkt $(x,y)_{ego}$ und der Fahrspurgrenze auf der Linie zwischen dem Zentrumspunkt $(x,y)_{ego}$ und dem Vorderrad des Fahrzeugs **2** und c der Abstand zwischen dem Fahrspurverlassenspunkt \mathbf{p} und dem Schnittpunkt zwischen Fahrspurgrenze und der Linie zwischen dem Zentrumspunkt $(x,y)_{ego}$ und dem Vorderrad des Fahrzeugs **2**. β ist ein Winkel zwischen der Fahrspurgrenze und der Linie zwischen dem Zentrumspunkt $(x,y)_{ego}$ und dem Vorderrad des Fahrzeugs **2** und d ist ein Abstand zwischen dem Vorderrad des Fahrzeugs **2** und der Fahrspurgrenze auf der Linie zwischen dem Zentrumspunkt $(x,y)_{ego}$ und dem Vorderrad des Fahrzeugs **2**.

$$c = \frac{2 * b * \cos(\beta) + \sqrt{(2 * b * \cos(\beta))^2 - 4(b^2 - r_{ego}^2)}}{2} \quad (6)$$

[0038] Im Gegensatz dazu zeigt **Fig. 6** das Szenario mit gekrümmter Straße. In diesem Fall wird der Winkel α berechnet als

$$\alpha = \delta - \varepsilon \quad (7)$$

[0039] Der Parameter δ ist ein Winkel zwischen einer Linie vom Zentrumspunkt $(x,y)_{ego}$ zu einem Straßenkurvenzentrumspunkt $(x,y)_{road}$ und einer Linie vom Zentrumspunkt $(x,y)_{ego}$ zum linken Vorderrad des Fahrzeugs **2** und ε ist der Winkel zwischen der Linie vom Fahrspurverlassenspunkt \mathbf{p} zum Zentrumspunkt $(x,y)_{ego}$ und der Linie zwischen dem Zentrumspunkt $(x,y)_{ego}$ und dem Straßenkurvenzentrumspunkt $(x,y)_{road}$.

$$\varepsilon = \frac{\arccos\left(e^2 + r_{ego}^2 - r_{road}^2\right)}{2 * e * r_{ego}} \quad (8)$$

[0040] Dabei ist e der Abstand zwischen dem Zentrumspunkt $(x,y)_{ego}$ und dem Straßenkurvenzentrumspunkt $(x,y)_{road}$ und r_{road} ist der Radius des gekrümmten Straßensegments.

[0041] Im Folgenden wird das ereignisbasierte Data-Mining **26** für die Ermittlung der so genannten Time to Line Crossing beschrieben.

[0042] Zunächst erfolgt eine Extraktion von Parametern, zum Beispiel die Time to Line Crossing, zum semantischen Beschreiben von Fahrscenarien, wie in **Fig. 7** gezeigt. **Fig. 7** zeigt eine ereignisbasierte Analyse der Distanz d_{LC} bis zum Überfahren der Fahrspurmarkierung aus synthetischen Fahrdaten im

Koordinatensystem der Videokamera basierend auf dem optischen Fluss des Videostroms der Videokamera, welche an der Cluster-in-Loop-Plattform angewendet werden, für drei unterschiedliche Lateralgeschwindigkeiten v_{lat} . Auf der Abszissenachse ist die Zeit t abgetragen und auf der Ordinatenachse die Distanz f zwischen Fahrzeug **2** und Fahrspurmarkierung.

[0043] Fig. 8 zeigt die Distanz f zwischen Fahrzeug **2** und Fahrspurmarkierung ohne Gruppierung.

[0044] Dann erfolgt eine Plausibilisierung durch Erarbeitung von Kriterien aus synthetischen Fahrdaten.

[0045] Dann erfolgt eine Erfassung ausgewählter Parameter basierend auf einer prinzipiellen Komponentenanalyse **K1**, **K2**.

[0046] Dann erfolgt ein Clustering, d. h. eine Gruppierung, von natürlichen Fahrscenarien **1** basierend auf Spurverlassenswarnereignissen des Spurhalteassistentensystems **3**, wie in Fig. 9 gezeigt. Fig. 9 zeigt ein Clustering einer ereignisbasierten Analyse. Auf der Abszissenachse ist eine erste prinzipielle Komponentenanalyse **K1** abgetragen und auf der Ordinatenachse eine zweite prinzipielle Komponentenanalyse **K2**. Dargestellt sind die Cluster **C0**, **C1**, **C2**.

[0047] Dann erfolgt ein Klassifikatortraining mit markierten Clusterdaten, wie in Fig. 10 gezeigt. Fig. 10 zeigt beispielsweise die Zeitreihenanalyse für die jeweilige Gruppierung nach dem Klassifikatortraining.

[0048] Dann erfolgt eine Anwendung des Klassifikators mit naturalistischen Fahrdaten, wie in Fig. 11 gezeigt. Fig. 11 zeigt die Anwendung des Clustering auf die ereignisbasierte Analyse einer Distanz bis zum Überfahren einer Fahrspurmarkierung zu einem Referenzmodell des charakteristischen Verlaufes der Systemeingangsgrößen für den jeweiligen Cluster **C0**, **C1**, **C2**, wobei ein jeweiliger Signalprototyp **S0**, **S1**, **S2** dargestellt ist.

[0049] Dann erfolgt eine Identifizierung der jeweiligen Gruppe durch eine Parameter- und Signalschätzung von der Zeitreihenanalyse.

[0050] Dann erfolgt ein Parsing von Felddaten in ein für die synthetische Umgebung geeignetes Format.

[0051] Abschließend erfolgt ein Beschreiben von Szenarien in einem De-facto-Standardformat.

[0052] Fig. 12 zeigt eine schematische Darstellung des Verfahrens und der Vorrichtung zur Evaluierung des Spurhalteassistentensystems **3** mittels Data-Mining von Fahrzeugdaten.

[0053] Bezugszeichen 1 kennzeichnet auch hier das natürliche Fahrscenario und somit eine reale Testfahrt.

[0054] Bezugszeichen 2 kennzeichnet auch hier das Fahrzeug **2**, beispielsweise ein realer Lastkraftwagen.

[0055] Bezugszeichen 4 kennzeichnet auch hier das synthetische Fahrscenario und somit eine virtuelle Testfahrt, d. h. eine Simulation. Bezugszeichen 39 kennzeichnet ein datenbasiertes Ausdauer testen.

[0056] Bezugszeichen 40 kennzeichnet ein wissensbasiertes Testen des Fahrzeugs **2**.

[0057] Bezugszeichen 41 kennzeichnet ein datenbasiertes Clustertesten.

[0058] Bezugszeichen 42 kennzeichnet ein wissensbasiertes Clustertesten.

[0059] Bezugszeichen 43 kennzeichnet ein Fahrzeugdynamikmodell, insbesondere Lastkraftwagen- dynamikmodell, inklusive einer Fahrer kabine.

[0060] Bezugszeichen 44 kennzeichnet eine Steuer gerätplattform für automatische Fahrfunktionen.

[0061] Bezugszeichen 45 kennzeichnet ein Aktor- modell.

[0062] Bezugszeichen 46 kennzeichnet ausgelöste Ereignisse.

[0063] Bezugszeichen 47 kennzeichnet eine integrierte Datenbank.

[0064] Bezugszeichen 48 kennzeichnet Data-Mining und Analyse.

[0065] Bezugszeichen 49 kennzeichnet eine Auswahl von Fahrfällen.

[0066] Bezugszeichen 50 kennzeichnet eine semantikkbasierte Funktionalspezifikation.

[0067] Bezugszeichen 32 kennzeichnet auch hier die Spitzenanforderungen.

[0068] Bezugszeichen 51 kennzeichnet die Fahrfälle.

[0069] Bezugszeichen 52 kennzeichnet eine Funktionalspezifikation basierend auf natürlicher Sprache.

[0070] Bezugszeichen 53 kennzeichnet ein Verbinden von Fahrscenarien.

[0071] Bezugszeichen 54 kennzeichnet ein Fahrzeugverhalten, insbesondere Lastkraftwagenverhalten, in einer virtuellen Umgebung.
 Bezugszeichen 55 kennzeichnet Werte zum Beeinflussen der Fahrzeugdynamik **12**.

[0072] Bezugszeichen 16 kennzeichnet auch hier die konkreten Szenarien, insbesondere Fahrszenarien.

[0073] Bezugszeichen 14 kennzeichnet auch hier die funktionalen Szenarien, insbesondere Fahrszenarien.

[0074] Bezugszeichen 15 kennzeichnet auch hier die logischen Szenarien, insbesondere Fahrszenarien.

Bezugszeichenliste

1	natürliches Fahrszenario	27	ontologiebasierte Szenariosynthese
2	Fahrzeug	28	systematische Testfallgenerierung
3	Spurhalteassistenzsystem	29	generisches Modell für eine Szenariobeschreibung
4	synthetisches Fahrszenario	30	funktionale Spezifikation
5	Kamera-Box	31	Testfall
6, 7	Ereignis	32	Spitzenanforderung
8	Kritikalitätsanalyse	33	Testausführung
9	adaptive Testabdeckung	34	Cluster-in-the-Loop Plattform
10	Zergliedern von worst-case-Szenarien	35	Änderung ausgewählter Parameter
11	Testautomation	36	Testresultat
12	Fahrzeugdynamik	37	Testauswertung
13	Anwendungsfall	38	Auswertung der Testfälle
14	funktionales Szenario	39	datenbasiertes Ausdauerstesten
15	logisches Szenario	40	wissensbasiertes Testen
16	konkretes Szenario	41	datenbasiertes Clustertesten
17	Situation	42	wissensbasiertes Clustertesten
18	Szene	43	Fahrzeugdynamikmodell
19	Fahrer	44	Steuergerätplattform
20	Aktion	45	Aktormodell
21	Sensor	46	ausgelöstes Ereignis
22	Fahrfunktion	47	Datenbank
23	Aktor	48	Data-Mining und Analyse
24	statische und dynamische Elemente	49	Auswahl von Fahrfällen
25	Ziele und Werte	50	semantikbasierte Funktional-spezifikation
26	ereignisbasiertes Data-Mining	51	Fahrfall
		52	Funktionalspezifikation basierend auf natürlicher Sprache
		53	Verbinden von Fahrszenarien
		54	Fahrzeugverhalten in virtueller Umgebung
		55	Werte zum Beeinflussen der Fahrzeugdynamik
		b	Abstand
		c	Abstand
		C0	Cluster
		C1	Cluster
		C2	Cluster
		d	Abstand

e	Abstand	Mining extrahiert und in Anforderungen für eine Testabdeckung transformiert werden.
CLT	closed-loop-testing	
d_{LC}	Distanz bis zum Überfahren der Fahrspurmarkierung	Es folgen 11 Seiten Zeichnungen
f	Distanz zwischen Vorderrad und Fahrspurgrenze	
I	Index	
K1	erste prinzipielle Komponentenanalyse	
K2	zweite prinzipielle Komponentenanalyse	
ls	linke Seite	
OLT	open-loop-testing	
p	Fahrspurverlassenspunkt	
r_{ego}	Radius	
r_{road}	Radius	
rs	rechte Seite	
S0	Signalprototyp	
S1	Signalprototyp	
S2	Signalprototyp	
t	Zeit	
UT	Unit Testing	
v_{längs}	Längsgeschwindigkeit des Egofahrzeugs	
v_{lat}	Lateralgeschwindigkeit des Egofahrzeugs	
ZV	Zeitverlauf	
α	Winkel	
β	Winkel	
γ	Winkel	
δ	Winkel	
ε	Winkel	
(x,y)_{ego}	Zentrumspunkt	
(x,y)_{road}	Straßenkurvenzentrumspunkt	

Patentansprüche

1. Verfahren zum Testen eines Spurhalteassistenzsystems (3) für ein Fahrzeug (2), insbesondere für einen Lastkraftwagen, **dadurch gekennzeichnet**, dass ontologiebasiert eine Kategorie adäquater und relevanter Szenarien für existierende Feldtests extrahiert wird.

2. Verfahren nach Anspruch 1, **dadurch gekennzeichnet**, dass worst-case-Szenarien mittels Data-

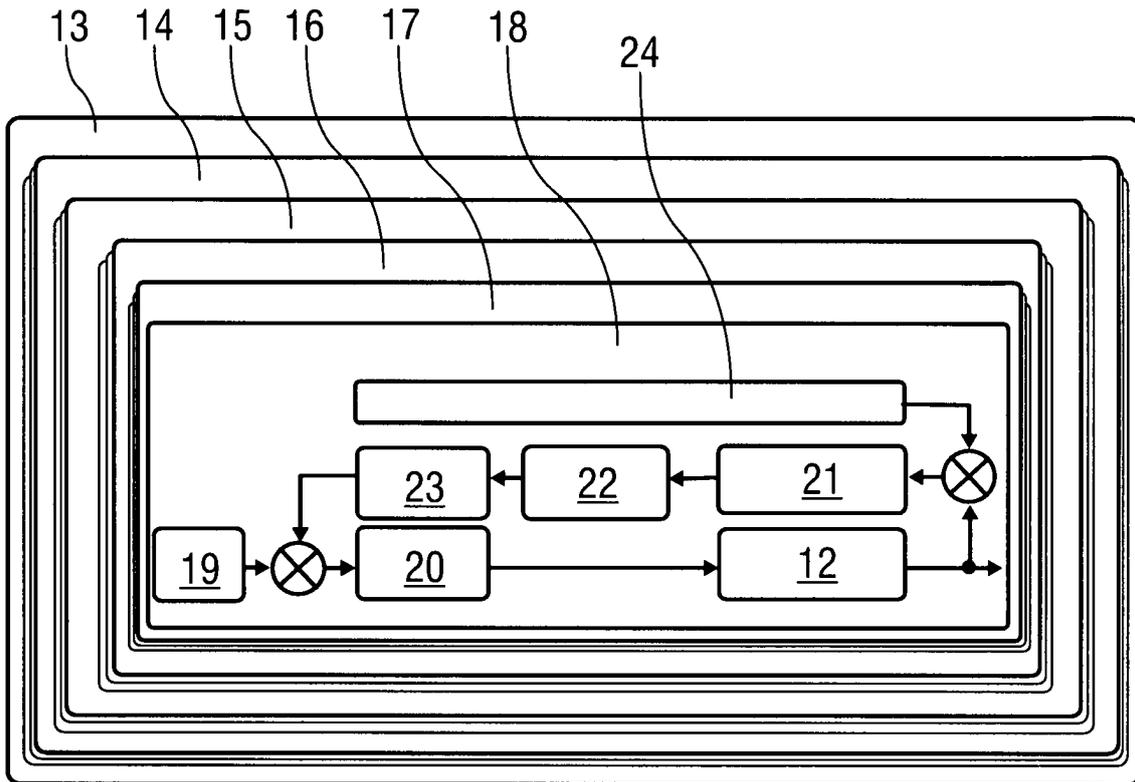


FIG 2

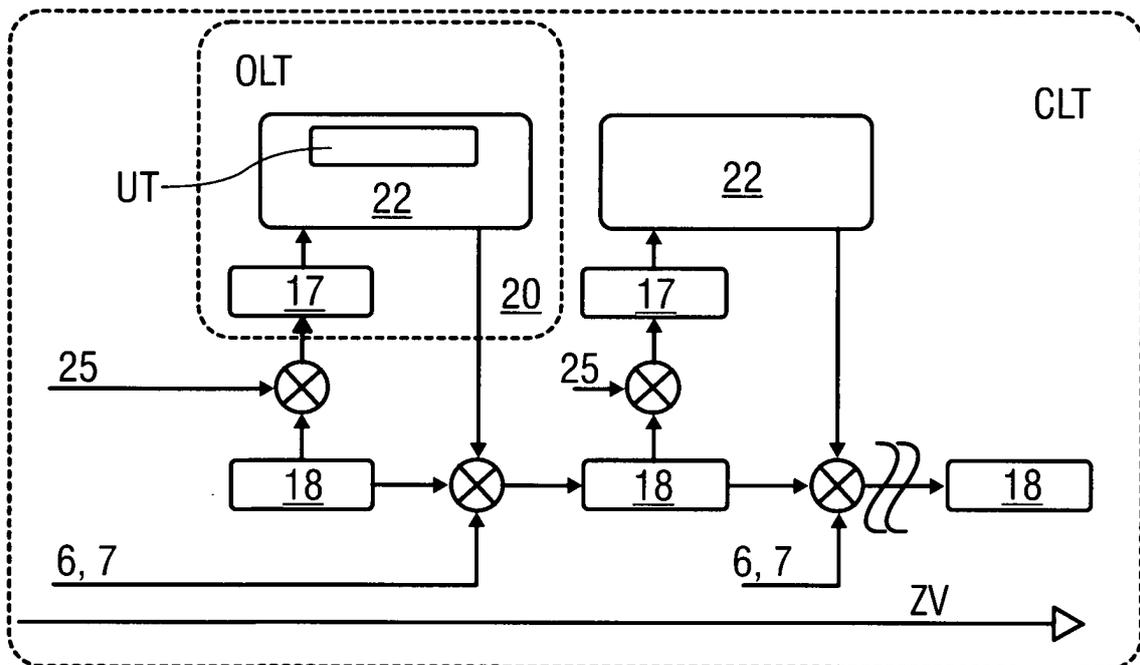


FIG 3

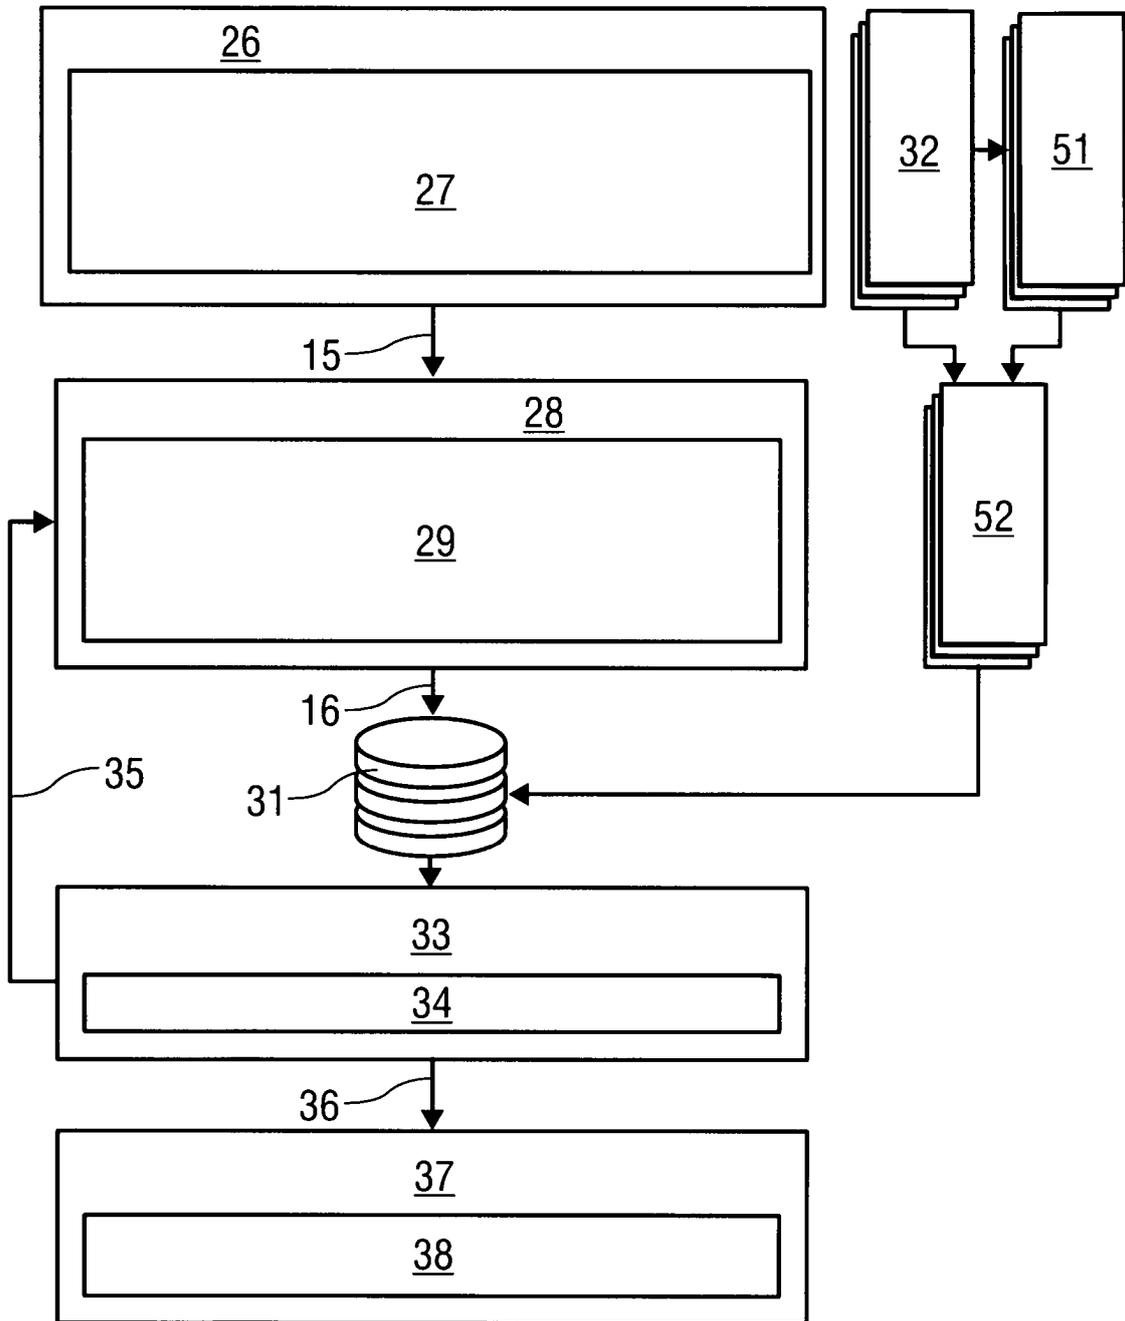


FIG 4

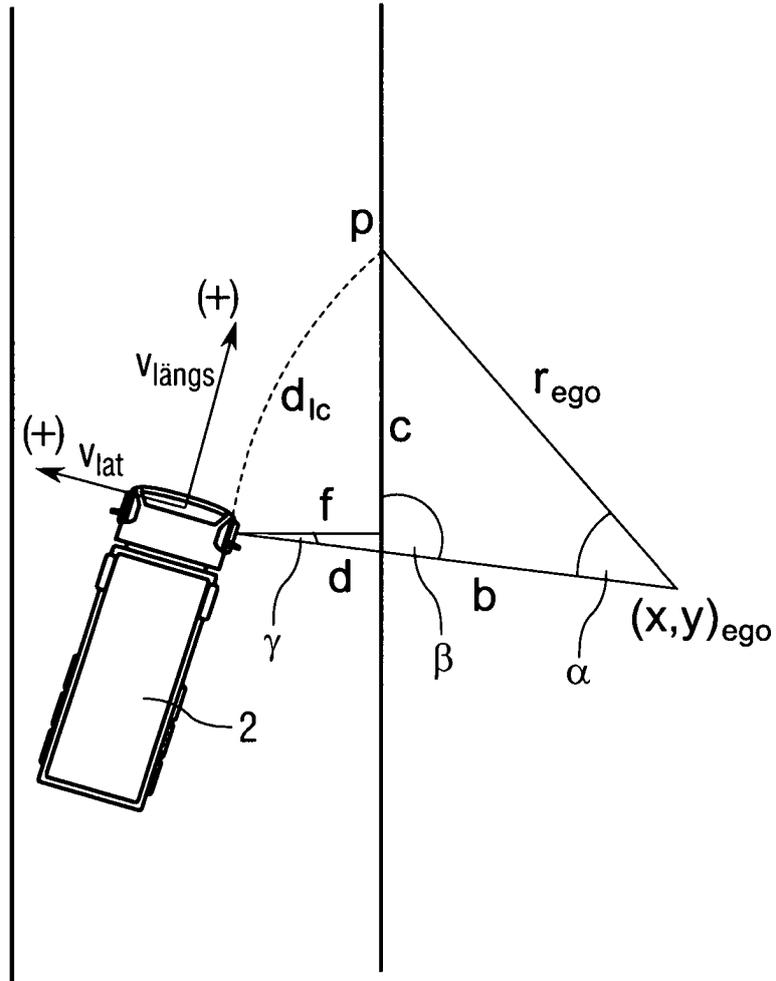


FIG 5

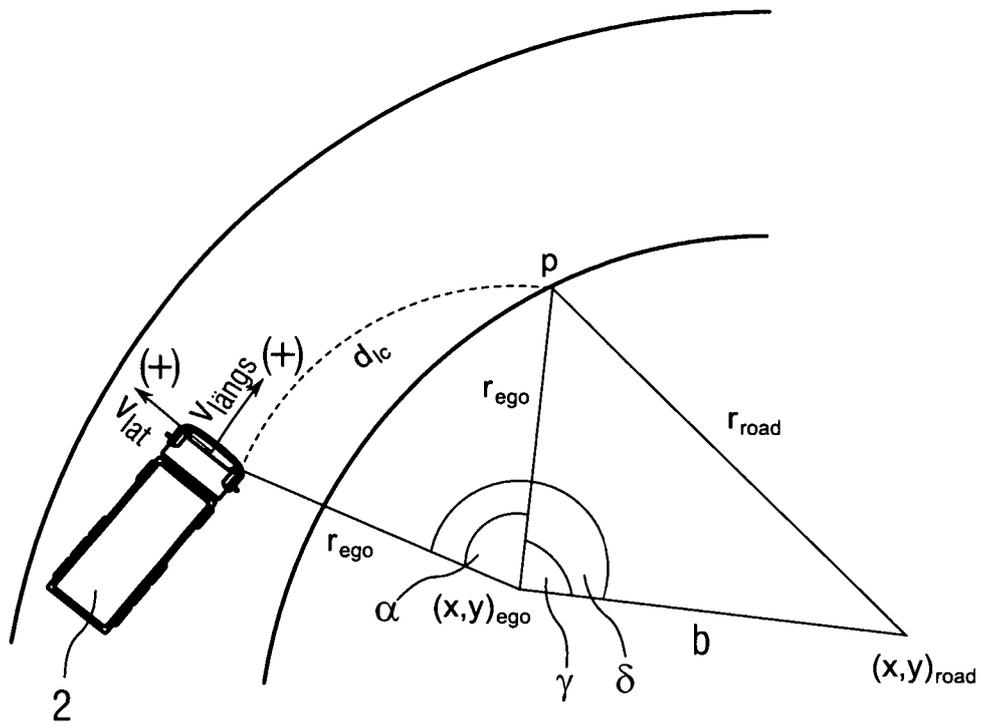


FIG 6

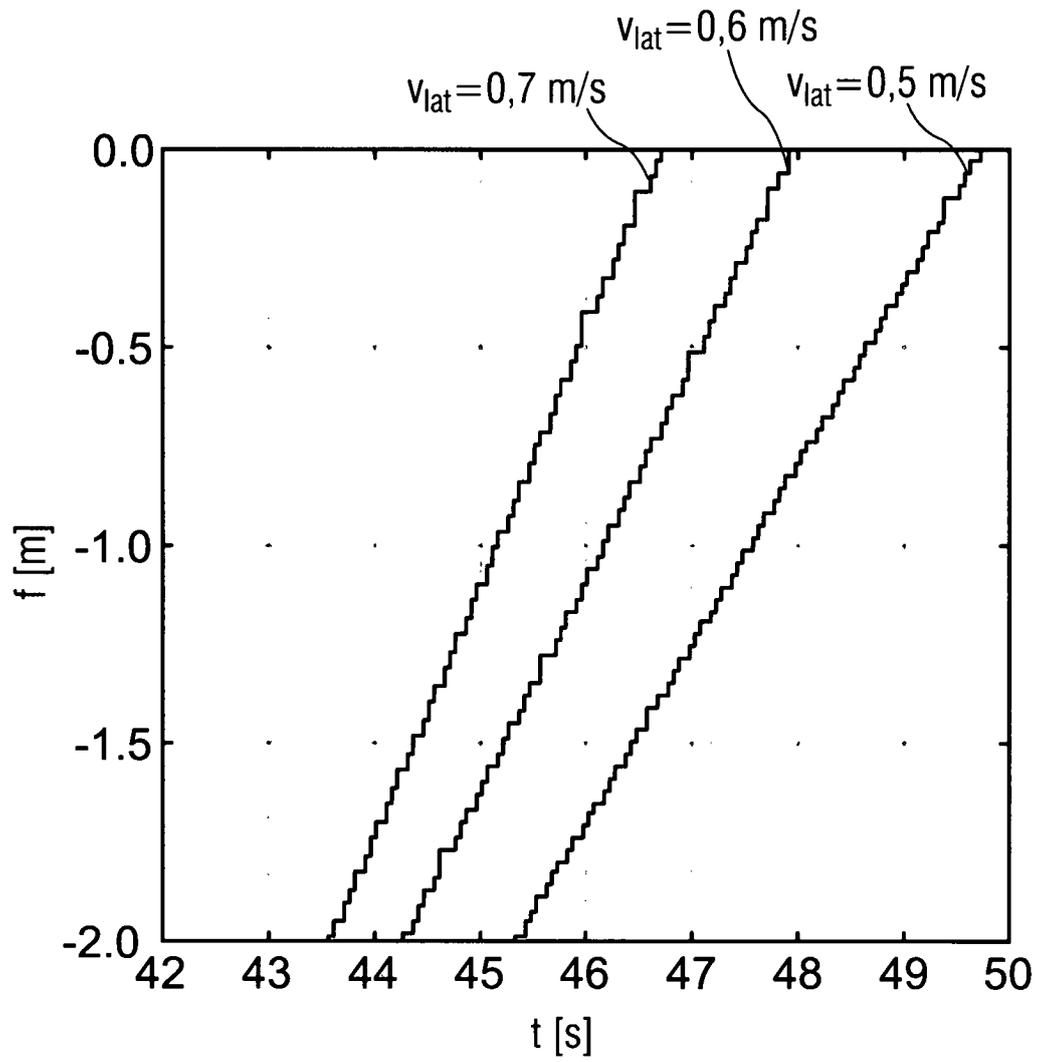


FIG 7

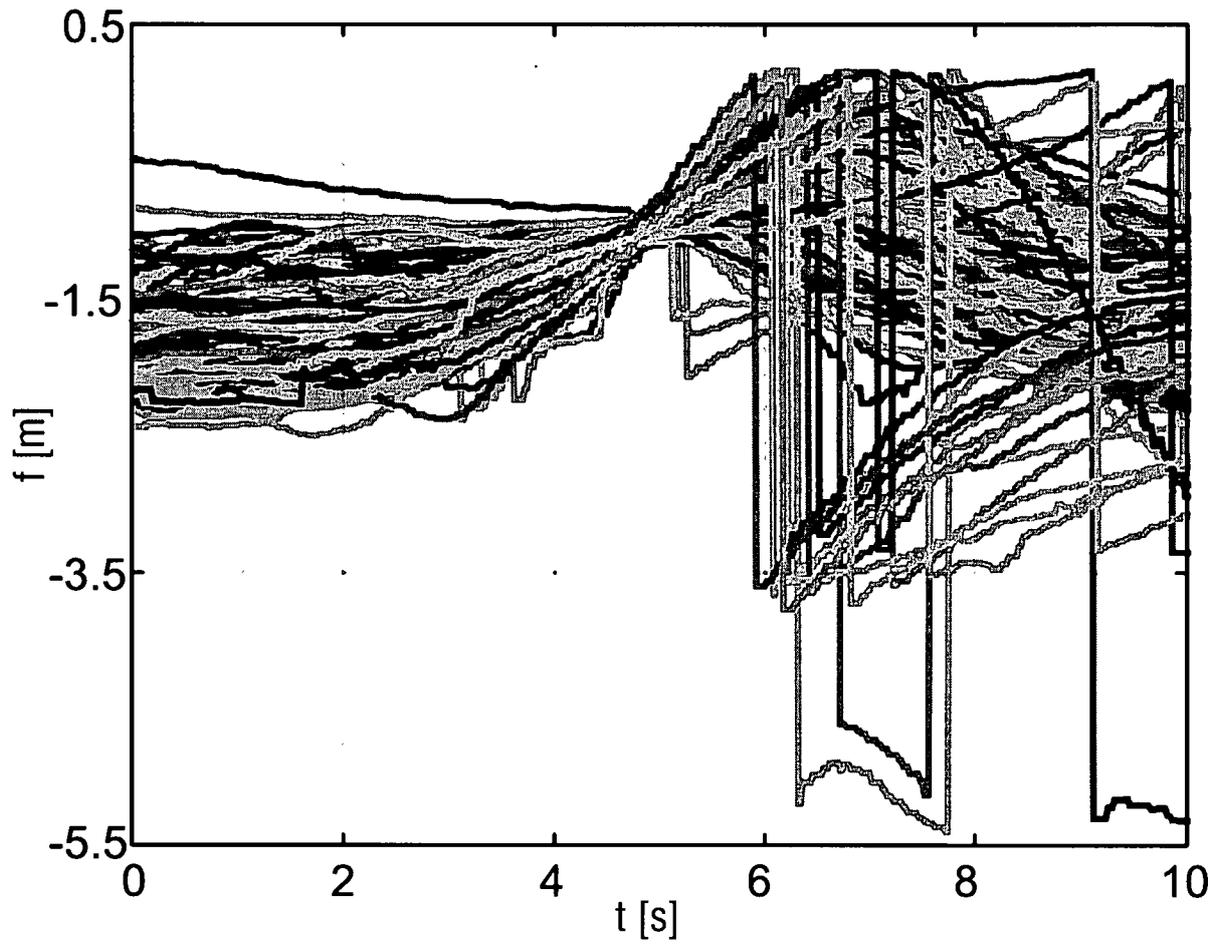


FIG 8

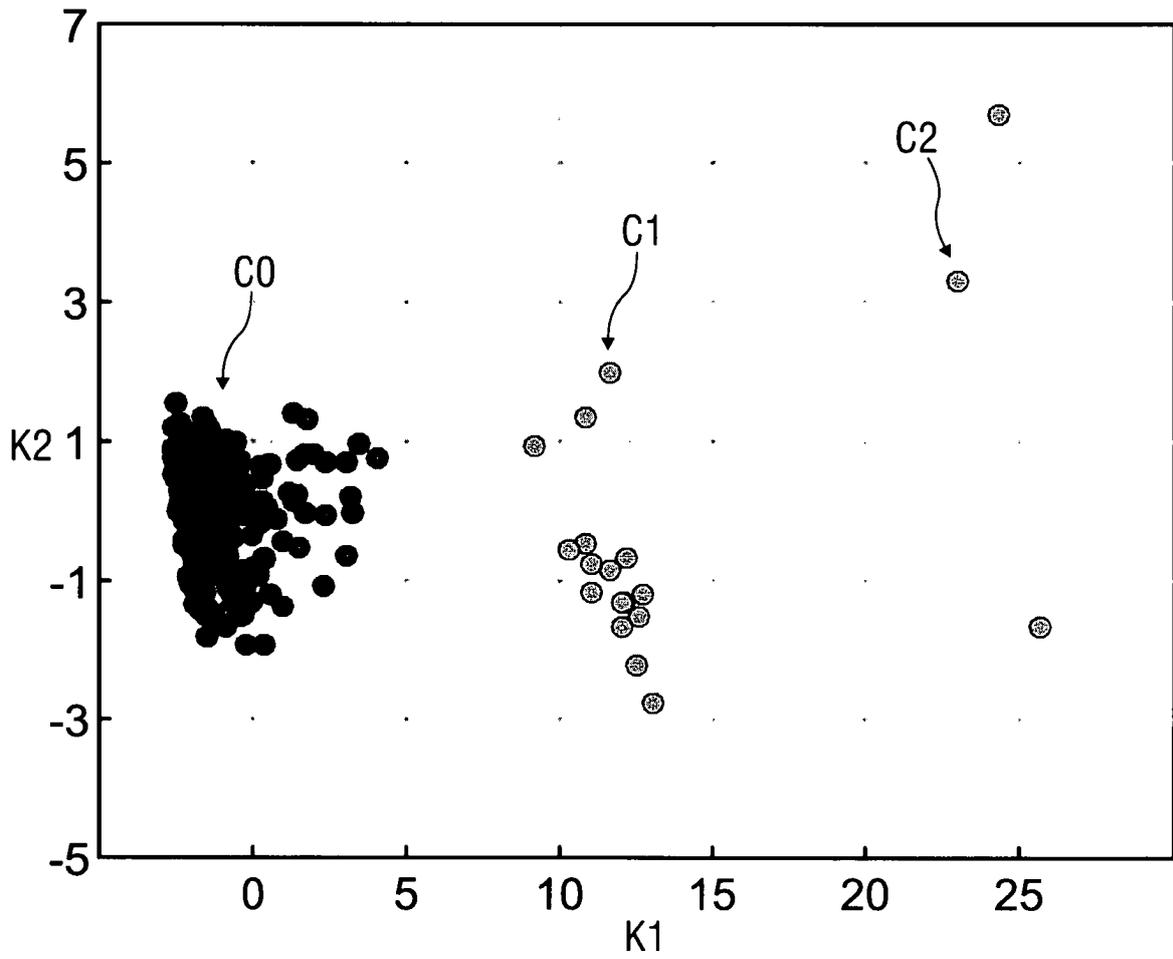


FIG 9

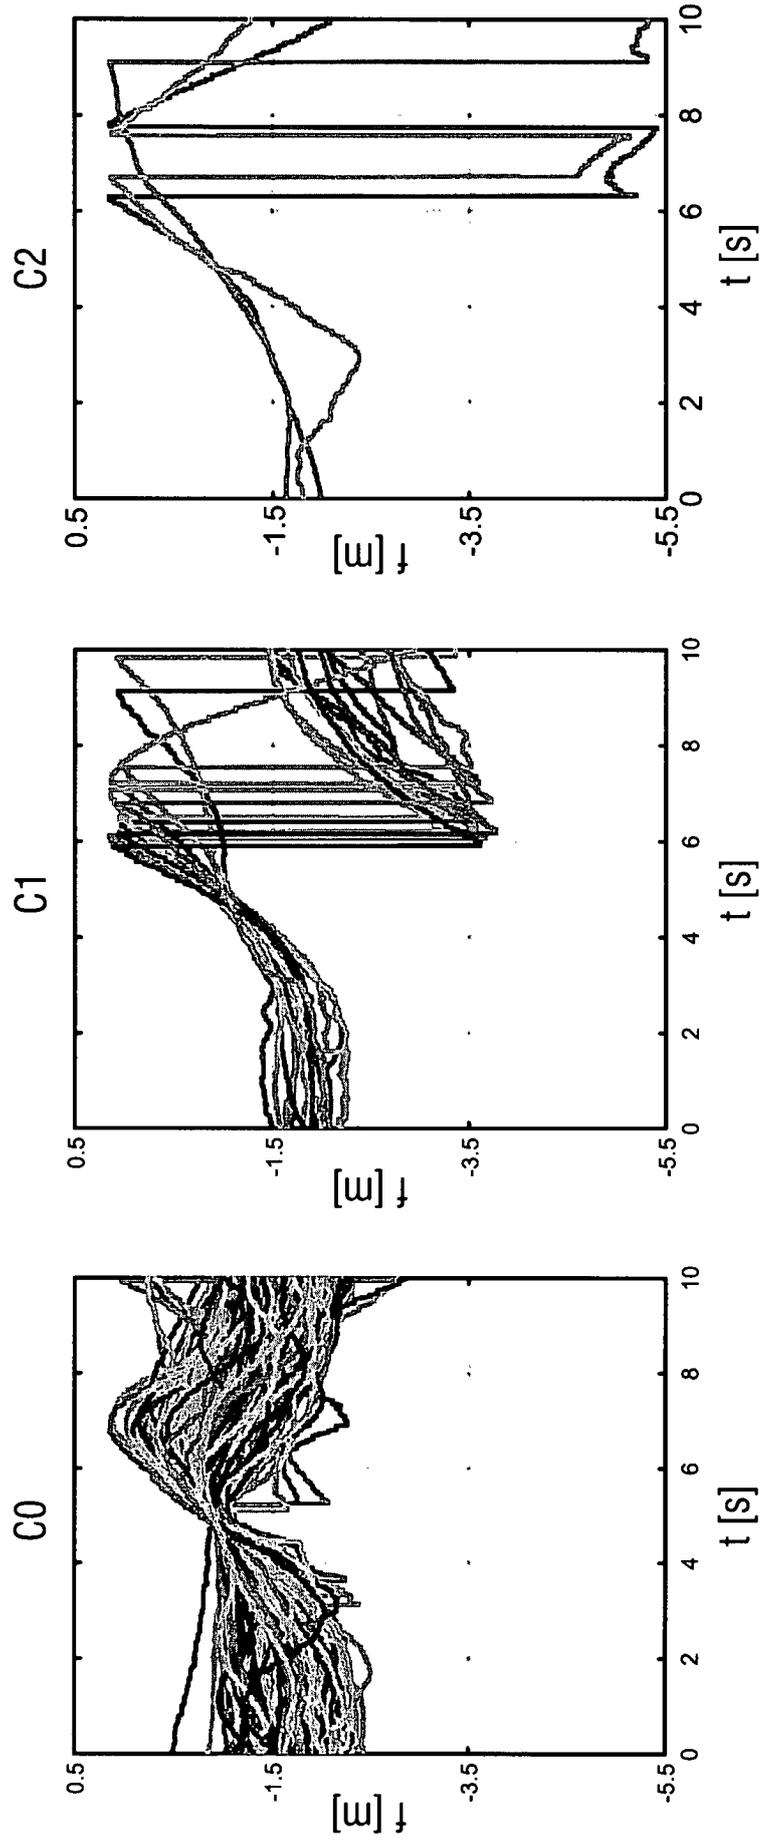


FIG 10

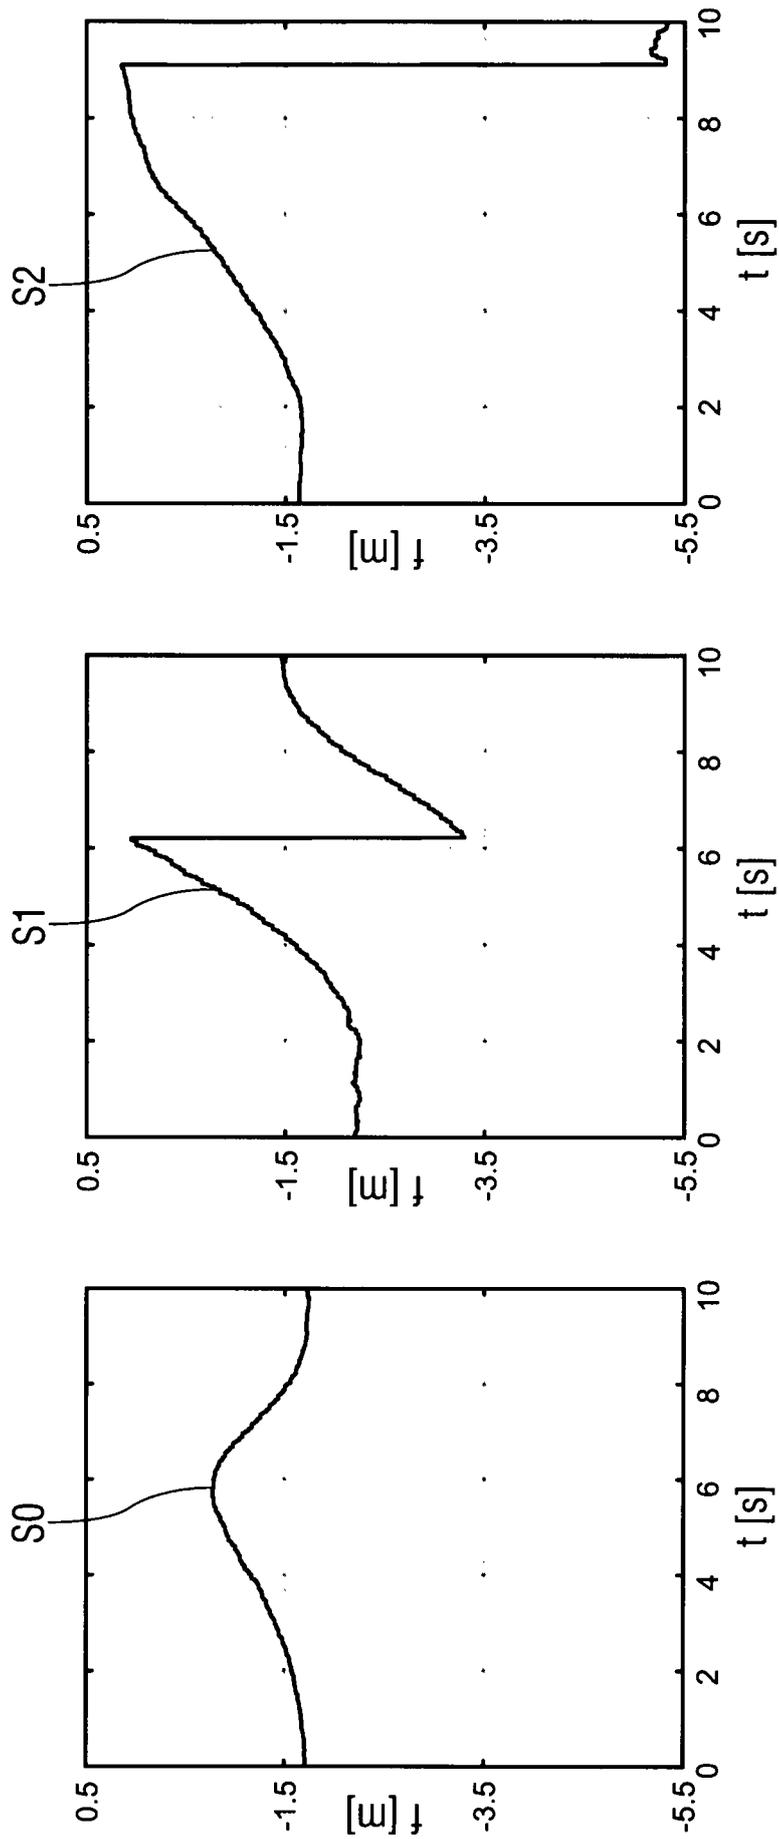


FIG 11

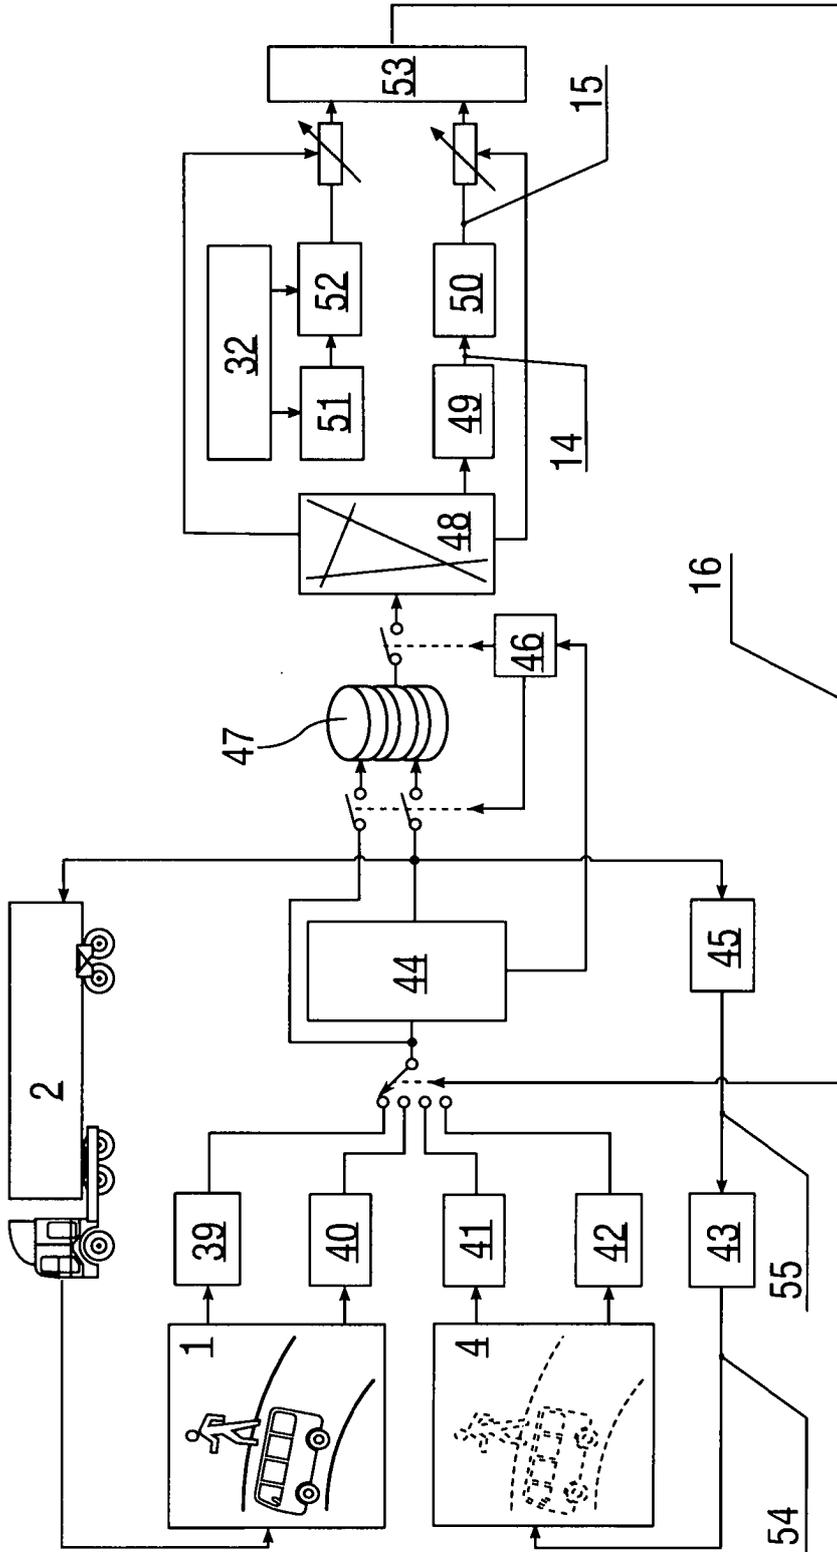


FIG 12