

5

10

15

**Überwachungssystem und Verfahren für die elektronische Überwachung von
Finanztransaktionen**

20

Beschreibung

Die vorgeschlagene Lösung betrifft insbesondere ein Überwachungssystem für die elektronische Überwachung von Finanztransaktionen.

25

Die elektronische Überwachung von Finanztransaktionen bedient sich verstärkt Mitteln des maschinellen Lernens, um beispielsweise Finanzinstitute bei der automatisierten Erkennung von Anomalien bei Finanztransaktionen zu unterstützen. Unter einer Anomalie wird hierbei eine Abweichung von einem vorbestimmten Regelsatz verstanden, die für eine betrügerische Finanztransaktion indikativ ist, insbesondere für mindestens eine zur Geldwäsche genutzte Finanztransaktion. Mit elektronischen Überwachungssystemen soll dabei automatisiert aus mehreren tausend Finanztransaktionen pro Tag derjenige Teil herausgefiltert werden, der als verdächtig eingestuft wird. Für eine als verdächtig eingestufte Finanztransaktionen soll dann ein Alarmereignis erzeugt werden, um die jeweiligen Finanztransaktionen weiter prüfen zu können und gegebenenfalls einer Aufsichts- und/oder Ermittlungsbehörde zu melden.

Gleichwohl in diesem Zusammenhang Elemente der künstlichen Intelligenz (KI) zunehmend an Bedeutung gewinnen, sind Lösungen für eine effiziente, kostengünstige und treffsichere Erkennung von Anomalien in Finanztransaktionen kaum bekannt. Hier setzt die vorgeschlagene Lösung an.

40

Insbesondere ist ein Überwachungssystem für die Überwachung von Finanztransaktionen vorgeschlagen, das elektronisch Finanztransaktionen zwischen mindestens einem Zahlungleistenden und mindestens einem Zahlungsempfangenden (respektive entsprechende Daten zu solchen Finanztransaktionen) auf das Auftreten wenigstens einer

5 Anomalie prüft. Hierbei wird unter einer Anomalie eine Abweichung von einem bestimmten Regelsatz verstanden, die für eine betrügerische Finanztransaktion indikativ ist, insbesondere für eine zur Geldwäsche genutzte Finanztransaktion und mithin aufgrund regulatorischer Vorgaben als verdächtig eingestuft werden muss. Das vorgeschlagene Überwachungssystem ist konfiguriert, bei der Detektion wenigstens einer solchen

10 Anomalie ein Alarmereignis und mithin ein zugehöriges elektronisches Alarmsignal zu erzeugen, das beispielsweise an einer (stationären oder mobilen) Computervorrichtung des Überwachungssystems und/oder an einer Computervorrichtung eines mit dem Überwachungssystem gekoppelten Nutzersystems eine Alarmmeldung auslöst. das vorgeschlagene Überwachungssystem umfasst einen Tokenizer und ein Sprachmodell für

15 die Überwachung der Finanztransaktionen. Der Tokenizer ist hierbei vorgesehen, aus einer für eine Finanztransaktionen repräsentativen Inputsequenz eine Tokensequenz zu generieren. Das Sprachmodell ist wiederum vorgesehen, auf Basis einer Tokensequenz oder mehrerer Tokensequenzen das Auftreten einer Anomalie in einer Finanztransaktion oder mehrerer Finanztransaktionen für die Erzeugung eines Alarmereignisses zu prüfen.

20 Die vorgeschlagene Lösung nutzt folglich ein Sprachmodell, das hier jedoch nicht für die Verarbeitung natürlicher Sprache, sondern für die Verarbeitung tokenisierter Inputsequenzen für Finanztransaktionen vorgesehen ist. Die vorgeschlagene Lösung macht sich somit ein Sprachmodell zunutze, dem anstelle eines Vokabulars für natürliche

25 Sprache ein Vokabular für Daten zu Finanztransaktionen zugrunde liegt, um auf dieser Basis zu detektieren, inwieweit bei überwachten Finanztransaktionen Anomalien vorliegen. Diese Anomalien stellen sich hier beispielweise als Abweichungen in einer für eine Finanztransaktion ausgewerteten Inputsequenz respektive einem hiermit korrespondierenden Datensatz gegenüber einem von dem Sprachmodell erwarteten

30 Aufbau für die jeweilige Finanztransaktionen dar.

Eine Importsequenz enthält hierbei für jede Finanztransaktion voneinander unterscheidbare Transaktionscharakteristika. Diese Transaktionscharakteristika werden in einem dem Tokenizer als Inputsequenz übergebenen String nach Art von Wörtern eines

35 Satzes behandelt, um hieraus Inputtokens für das Sprachmodell zu erzeugen. Eine Tokenisierung einer Inputsequenz erfolgt somit anhand der Transaktionscharakteristika, die im Vorfeld maschinell oder manuell eingelernt wurden. Ein

Transaktionscharakteristikum kann beispielsweise eine Kontonummer, eine Bankleitzahl (englisch „Business Identifier Code“, kurz BIC), ein Datum, eine Uhrzeit oder ein Indikator für eine Art der Transaktion (zum Beispiel Überweisung oder Abhebung) sein.

- 5 In einer Ausführungsvariante ist der Tokenizer dazu eingerichtet und vorgesehen, in einer Tokensequenz wenigstens einen Input der aus der Inputsequenz generierten Inputtoken zu maskieren, bevor die Tokensequenz an das Sprachmodell übergeben wird. Das Überwachungssystem ist hier dann weiter konfiguriert, mit dem Sprachmodell einen Outputtoken für den wenigstens einen maskierten Inputtoken vorherzusagen. In diesem
- 10 Zusammenhang kann dann beispielsweise weiter vorgesehen, dass das Überwachungssystem für die Detektion einer Anomalie prüft, inwieweit (insbesondere ob) der wenigstens eine vorhergesagte Outputtoken mit dem zugehörigen Inputtoken übereinstimmt. Über das Sprachmodell wird somit für die teilweise maskierte Tokensequenz einer Finanztransaktion eine Vorhersage des maskierten Teils getroffen.
- 15 Kann das Sprachmodell den oder die maskierten Inputtoken nicht vorhersagen, sodass der Outputtoken mit dem ursprünglichen Inputtoken, der zuvor maskiert wurde, nicht übereinstimmt, wird auf Basis des anhand zulässiger Finanztransaktionen trainierten Sprachmodells darauf geschlossen, dass eine Finanztransaktion respektive eine hiermit verbundene Geldbewegungen verdächtig ist und mithin eine Anomalie vorliegt, die –
- 20 gegebenenfalls unter Berücksichtigung weiterer Kriterien – zur Auslösung eines Alarmereignisses führt.

- In diesem Zusammenhang kann auch vorgesehen sein, dass stets ein vorgegebener, insbesondere prozentualer Anteil an Inputtoken maskiert wird, und das
- 25 Überwachungssystem konfiguriert ist, für die Detektion einer Anomalie zu prüfen, inwieweit vorhergesagte Outputtoken einer Outputsequenz für die Finanztransaktion zugehörigen (d.h., in Bezug auf Ihre Position in der Inputsequenz überstimmenden) Inputtoken entsprechen. Können durch das Sprachmodell die maskierten Inputtoken einer Finanztransaktion oder mehrere Finanztransaktionen nicht korrekt vorhergesagt werden,
- 30 spricht dies für eine verdächtige Finanztransaktion oder mehrere verdächtige Finanztransaktionen.

- Alternativ oder ergänzend kann vorgesehen sein, dass das Überwachungssystem konfiguriert ist, für die Detektion einer Anomalie bei einer Finanztransaktion, die
- 35 Finanztransaktionen anhand wenigstens eines Referenz-Inputtokens der zu der Finanztransaktionen zugehörigen Tokensequenz mit mindestens einem Cluster zu vergleichen, das auf Basis von Tokensequenzen für Finanztransaktionen miteinander

- übereinstimmenden Referenz-Inputtoken gebildet ist. Bei dieser Ausführungsvariante werden folglich mithilfe des Sprachmodells und hierüber generierter Outputtoken Daten zu einer Finanztransaktion einem oder mehreren Clustern gegenübergestellt und geprüft, inwieweit die jeweilige Finanztransaktion einem Cluster als zugehörig eingestuft werden
- 5 kann. Hierbei wird sich zunutze gemacht, dass erkannt wurde, dass Finanztransaktionen bei einem spezifischen, übereinstimmenden Transaktionscharakteristikum und mithin einem hieraus sich ergebenden Referenz-Inputtoken durch ein Sprachmodell geclustert werden können. Liegt dann aber eine Finanztransaktion mit einem identischen Referenz-Inputtoken über ein zugelassenes Maß hinaus außerhalb eines derart gebildeten Clusters,
- 10 spricht dies für eine verdächtige Finanztransaktion. So lässt sich beispielsweise beobachten, dass mit Konten einer bestimmten Händlerkategorie stets vergleichbare Finanztransaktionen durchgeführt werden. Beispielsweise gibt es für das Konto einer Bäckerei typischerweise eine Vielzahl von Zahlungsflüssen mit vergleichsweise kleinen Beiträgen von einer Vielzahl unterschiedlicher Privatkonten während der Öffnungszeit der
- 15 Bäckerei. Eine Finanztransaktion, die für einen Zahlungsfluss mit einem gegenüber einem Durchschnittswert vielfach größeren Betrag außerhalb einer Öffnungszeit der Bäckerei steht, läge somit außerhalb eines für eine Bäckerei gebildeten Clusters und würde somit – gegebenenfalls unter Berücksichtigung weiterer Kriterien – als verdächtig eingestuft.
- 20 Unter Bezugnahme auf das vorstehend erläuterte Ausführungsbeispiel kann es sich bei dem Referenz-Inputtoken, der für das Clustering herangezogen wird, jeweils um einen Inputtoken einer Tokensequenz handeln, der für einen in der Inputsequenz enthaltenen Händlerkategorie-Code (englisch „Merchant Category Code“, MCC) repräsentativ ist.
- 25 Beispielsweise ist vorgesehen, dass das Überwachungssystem konfiguriert ist, für den Vergleich mit dem mindestens einen Cluster mit dem Sprachmodell anhand des wenigstens einen Referenz-Inputtokens für die Finanztransaktion einen Datenpunkt zu bestimmen und dessen Abstand zu einem Zentrum des mindestens einen Clusters zu ermitteln. Bei einem solchen Vorgehen werden beispielsweise mehrdimensionale,
- 30 insbesondere hochdimensionale Outputvektoren aus dem Sprachmodell einer Dimensionsreduzierung und anschließend einer Cluster-Funktion, mithin einem Clustering-Algorithmus, zugeführt, um für eine Inputsequenz zu einer Finanztransaktion einen Datenpunkt im zweidimensionalen oder dreidimensionalen Raum zu bilden, dessen Abstand zu einem Zentrum zu unterschiedlichen trainierten Clustern bestimmbar ist. Für
- 35 die Detektion einer Anomalie wird dieser ermittelte Abstand mit einem hinterlegten Schwellwert verglichen. Ist der Abstand letztlich zu einem bestimmten oder mehreren

Clustern zu groß, wird auf eine verdächtige Finanztransaktionen geschlossen und ein Alarmereignis erzeugt.

- In einer möglichen Weiterbildung kann auch vorgesehen sein, dass für unterschiedliche
- 5 Cluster unterschiedliche Schwellwerte hinterlegt sind. So kann für Cluster eines bestimmten ersten Referenz-Inputtoken eine größere Streuung der Datenpunkte für Finanztransaktionen zulässig sein als bei einem Cluster für Finanztransaktionen mit einem hierzu verschiedenen, zweiten Referenz-Inputtoken.
- 10 Für die Erzeugung eines Alarmereignisses können grundsätzlich auch beide vorstehend erläuterte Kriterien Berücksichtigung finden. So kann vorgesehen sein, dass für die Detektion einer Anomalie zum einen geprüft wird, inwieweit (ob) wenigstens ein vorhergesagter Outputtoken mit einem zugehörigen maskierten Inputtoken übereinstimmt, und zum anderen geprüft wird, inwieweit sich auf Basis einer Outputtoken-Sequenz eine
- 15 Finanztransaktion zu einem bestimmten Cluster von Finanztransaktionen zuordnen lässt. Kann das Sprachmodell beispielsweise die für eine Finanztransaktion maskierten Inputtoken nicht zutreffend vorhersagen und lässt sich auch die Finanztransaktion mit dem Sprachmodell nicht einem bestimmten Cluster sicher zuordnen, spricht dies für eine Anomalie und mithin für eine verdächtige Finanztransaktion, die zu einem
- 20 Alarmierungsereignis führt. Liegt gegebenenfalls lediglich bei einem der vorstehend genannten beiden Kriterien ein Hinweis auf eine Anomalie vor, können diese unterschiedlich gewichtet sein, um darüber zu entscheiden, ob bereits das Vorliegen eines der beiden Kriterien zur Erzeugung eines Alarmereignisses führt oder nicht.
- 25 Das sprachmodellbasierte Überwachungssystem kann beispielsweise ein Transformer-Maschine-Learning-Modell (mithin ein maschinelles Transformer-Lernmodell) sein. Insbesondere kann es sich hierbei um ein auf Basis von Inputsequenzen zu Finanztransaktionen trainiertes Transformer-Maschine-Learning-Modell und insbesondere ein bidirektional trainiertes Transformer-Maschine-Learning-Modell handeln.
- 30 Beispielsweise hat sich ein mit Bidirectional Encoder Representations from Transformers, kurz BERT, bidirektional trainiertes Transformer-Maschine-Learning-Modell oder ein anderer bidirektionaler Encoder Transformer als besonders vorteilhaft erwiesen, um hiermit zuverlässig und mit vergleichsweise überschaubarem Berechnungsaufwand auf Anomalien in überwachten Finanztransaktionen zu schließen.
- 35 Grundsätzlich kann das Alarmereignis zur Ausgabe an einer Computervorrichtung des Überwachungssystems und/oder an einer Computervorrichtung eines mit dem

Überwachungssystem verbundenen Nutzersystems vorgesehen sein. Das Überwachungssystem kann somit beispielsweise serverseitig, insbesondere in der Cloud implementiert sein. Die Ausgabe des erzeugten Alarmereignisses erfolgt wiederum an einem lokalen Nutzersystem, zum Beispiel eines Finanzinstituts. Alternativ kann ein On-
5 Premises-Überwachungssystem vorgesehen sein. Insbesondere eine Computervorrichtung eines Nutzersystems kann beispielsweise ein mobiles Endgerät, wie z.B. einen Laptop oder ein Mobiltelefon, umfassen.

Die vorgeschlagene Lösung betrifft ferner ein Verfahren zum elektronischen Überwachen
10 von Finanztransaktionen zwischen mindestens einem Zahlungleistenden und mindestens einem Zahlungsempfangenden auf das Auftreten wenigstens einer Anomalie. Hierbei ist vorgeschlagen, aus einer für eine Finanztransaktion repräsentativen Inputsequenz jeweils über einen Tokenizer eine Tokensequenz zu generieren und mit einem Sprachmodell auf Basis einer Tokensequenz oder mehrerer Tokensequenzen das Auftreten einer Anomalie
15 in einer oder mehreren Finanztransaktionen zu prüfen, um in Reaktion auf wenigstens eine bei der Prüfung detektierte Anomalie ein Alarmereignis zu erzeugen.

Eine Ausführungsvariante eines vorgeschlagenen Verfahrens ist dabei insbesondere mit einer Ausführungsvariante eines vorgeschlagenen Überwachungssystems umsetzbar.
20 Dementsprechend gelten vorstehend und nachstehend erläuterte Vorteile und Merkmale von Ausführungsvarianten eines vorgeschlagenen Überwachungssystems auch für Ausführungsvarianten eines vorgeschlagenen Verfahrens und umgekehrt.

Insbesondere kann folglich in einer Ausführungsvariante des vorgeschlagenen Verfahrens
25 vorgesehen sein, dass der Tokenizer in einer Tokensequenz wenigstens einen Inputtoken der aus der Inputsequenz generierten Inputtoken maskiert, bevor die Tokensequenz an das Sprachmodell übergeben wird, um im Anschluss mit dem Sprachmodell den wenigstens einen maskierten Inputtoken vorherzusagen und einen hierfür aus dem Sprachmodell generierten Outputtoken zu prüfen, inwieweit dieser mit dem unmaskierten
30 Inputtoken übereinstimmt.

Ebenso kann alternativ oder ergänzend für die Detektion einer Anomalie vorgesehen sein, dass anhand wenigstens eines Referenz-Inputtokens für eine Finanztransaktion geprüft wird, inwieweit sich diese Finanztransaktion unter Nutzung des Sprachmodells zu einem
35 Cluster vergleichbarer Finanztransaktionen zuordnen lässt.

Des Weiteren betrifft die vorgeschlagene Lösung ein Computerprogrammprodukt, umfassend Befehle, die bei einer Ausführung durch mindestens einen Prozessor, den mindestens einen Prozessor veranlassen, eine Ausführungsvariante eines vorgeschlagenen Verfahrens auszuführen.

5

Darüber hinaus betrifft die vorgeschlagene Lösung auch ein Verfahren zum Trainieren eines Sprachmodells für die Überwachung von Finanztransaktionen. Die vorgeschlagene Lösung betrifft folglich nicht nur die Verwendung des bereits trainierten Sprachmodells für die Detektion von Anomalien in Finanztransaktionen. Vielmehr steht auch im Fokus, wie
10 ein entsprechendes Sprachmodell trainiert werden kann. In diesem Zusammenhang ist vorgeschlagen, dass ein entsprechendes Trainingsverfahren wenigstens die folgenden Schritte umfasst:

- Bereitstellen von Daten zu einzelnen Finanztransaktionen, typischerweise jeweils in Form eines Strings,
- 15 – Erzeugung wenigstens einer Menge von Inputsequenzen für die Finanztransaktionen, wobei jede Inputsequenz voneinander unterscheidbare (typischerweise vordefinierte und dem Sprachmodell als Input zur Verfügung gestellte) Transaktionscharakteristika enthält;
- Tokenisierung der Inputsequenzen anhand der Transaktionscharakteristika mit
20 einem Tokenizer zu Erzeugung von Inputtoken für jede Inputsequenz;
- Trainieren des Sprachmodells auf Basis der Inputtoken und der Inputsequenzen, indem zumindest ein Teil der Inputtoken maskiert wird, um ein auf Daten zu Finanztransaktionen trainiertes Sprachmodell bereitzustellen, mit dem auf Basis einer Tokensequenz oder mehrerer Tokensequenzen das Auftreten einer Anomalie
25 in einer oder mehreren Finanztransaktionen detektierbar ist.

Bei dem vorgeschlagenen Verfahren ist somit das Trainieren des Sprachmodells mit dem Ziel vorgesehen, dass das Sprachmodell aus dem zur Verfügung gestellten Kontext die maskierten Inputtoken zutreffend bestimmt und mithin prüft, inwieweit mithilfe des
30 Sprachmodells generierte Outputtoken mit Inputtoken übereinstimmen, die dem Sprachmodell zuvor nur maskiert zur Verfügung gestellt wurden. Gemäß diesem Aspekt der vorgeschlagene Lösung wird mithin ein (gegebenenfalls vortrainiertes) Sprachmodell genutzt, um ein „Vokabular“ auf Basis von tokenisierten Inputsequenzen zu Finanztransaktionen zu lernen.

35

Grundsätzlich kann in diesem Zusammenhang vorgesehen sein, dass die Inputtoken jeweils mittels Wordembedding (englisch „embedding“) Vektoren reeller Zahlen zugeordnet

- werden. Zuvor kann der Tokenizer hierbei die Transaktionscharakteristika in numerische Inputtoken umsetzen. Lässt sich aus Sicht des Sprachmodells beispielsweise ein Datensatz und mithin String, der eine Finanztransaktionen charakterisiert, als Wort begreifen, beschreibt eine Menge von Inputsequenzen für ein bestimmtes Konto und/oder
- 5 eine bestimmte Händlerkategorie einen Text mit hierfür charakteristischen Worten. Wie vorstehend bereits erläutert können somit beispielsweise die für die wenigstens eine Menge von Inputsequenzen zugrunde gelegten Finanztransaktionen beim Training des Sprachmodells einem Konto eines bestimmten Händlerkategorie-Codes zugeordnet sein. Eine Menge von Inputsequenzen bildet dann beispielsweise ein „Textbeispiel“ für einen
- 10 bestimmten Typ von Konto, der anhand eines (typischerweise einer Inputsequenz vorangestellten) Referenz-Inputtokens identifizierbar ist. Zwischen einzelnen tokenisierten Inputsequenzen für das jeweilige Konto können beispielsweise jeweils Separations- oder Trenntoken vorgesehen.
- 15 So können beispielsweise zwei Inputsequenzen für ein bestimmtes Konto wie folgt aufgebaut sein:

(1)

20 Trx1 Hp1 Cp019 2023-10-27:00:00:00 300EUR CASH DEBIT
ATM_WITHDRAWAL DE MCC5892

(2)

25 Trx2 Hp1 Cp670 2023-10-30:01:10:08 600EUR ACH CREDIT ACH_TRANSFER
US MCC5892

Anhand vordefinierter Transaktionscharakteristika lassen sich diese Inputsequenzen wie folgt darstellen:

(3)

30 0D 0H 0M 0S AMOUNT2 CASH DEBIT ATM_WITHDRAWAL DE

(4)

3D 1H 10M 8S AMOUNT3 ACH CREDIT ACH_TRANSFER US

- 35 Hierbei wird beispielsweise der Zeitpunkt („2023-10-27:00:00:00“) der frühesten Finanztransaktion (1) als Nullpunkt gesetzt und für die Datumsbindung und Zeitangabe zu der zweite Finanztransaktionen lediglich die Differenz („3D 1H 10M 8S“) verwendet.

Im Anschluss werden die Inputsequenzen für die Finanztransaktionen (1) und (2) auf Basis der Formate (3) und (4) in eine numerische Darstellung wie folgt überführt:

5 (5)
 0 31 54 67 120 129 141 143 286

 (6)
 3 32 65 74 121 132 140 148 232

10

Angenommen, das entsprechende Konto betrifft einen Händlerkategorie-Code MCC mit dem Wert „523“, dann lässt sich hiermit eine Inputtoken-Sequenz durch den Tokenizer für dieses Konto wie folgt darstellen:

15 [CLS] 523 [SEP] 3 32 65 74 121 132 140 148 232 [SEP] 0 31 54 67 120 129 141
 143 286 [SEP] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD]
 [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD]
 [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD]
 [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD]
20 [PAD]

Hierbei bildet der Token [CLS] einen üblichen Klassifikationstoken. Mit [SEP] wird ein Separations- oder Trenntoken bezeichnet, der zwei Inputsequenzen voneinander trennt. Mit [PAD] wird ein Fülltoken (englisch „padding token“) bezeichnet, um eine Menge an
25 Inputtoken-Sequenzen für ein Konto auf eine für alle Trainingsdaten einheitliche Größe zu bringen.

Teil der tokensierten Transaktionscharakteristika und damit der numerischen Inputtoken kann auch ein Kategorisierungsparameter für das Transaktionsvolumen der jeweiligen
30 Finanztransaktion sein. So ist eine IBAN einer Gegenpartei für jedes betrachtete Konto, zu dem eine Finanztransaktion betrachtet wird, in der Regel unterschiedlich. Würde damit eine IBAN als Transaktionscharakteristikum übergeben, würde dies die Übertragbarkeit gelernter Charakteristika von einem Konto auf ein anderes Konto erschweren, da mit jedem Konto und dessen betrachteten Transaktionscharakteristika eine andere Menge an IBANs
35 und damit Inputtokens zugeführt werden. Vor diesem Hintergrund ist in einer Ausführungsvariante eine Kategorisierung respektive Sortierung nach Transaktionsvolumen vorgesehen. Hierbei wird dem zu trainierenden Sprachmodell für

jedes Konto eine Menge von Inputsequenzen zur Verfügung gestellt werden, die einen Wert für einen Kategorisierungsparameter enthält. Die Werte für diesen Kategorisierungsparameter hängen dabei vom Transaktionsvolumen der jeweiligen Finanztransaktionen mit dem Konto der Gegenpartei ab. Ein erster Wert für diesen

5 Kategorisierungsparameter wird z.B. stets identisch für dasjenige Konto mit dem größten Transaktionsvolumen gesetzt. Beispielsweise kann in diesem Zusammenhang vorgesehen sein, dass für dasjenige Konto mit dem größten Transaktionsvolumen stets ein Inputtoken „0“ für den Kategorisierungsparameter vorgesehen ist und in Abhängigkeit von der Größe der vorkommenden Transaktionsvolumina weitere Inputtoken mit aufsteigenden Werten

10 gesetzt werden, z.B. ein Inputtoken „1“ für das zweitgrößte Transaktionsvolumen, etc. Das erlaubt dem zu Sprachmodell eine bessere Generalisierung von einem Konto zum nächsten Konto.

Für das Trainieren des Sprachmodells können eine Vielzahl an Mengen von

15 Inputsequenzen erzeugt werden, denen Konten mit identischen und unterschiedlichen Händlerkategorie-Codes zugrunde liegen. Auf dieser Basis lassen sich mit dem Sprachmodell als Output erzeugte Outputvektoren – nach einer optionalen Dimensionsreduzierung und mithilfe einer Clusterfunktion – Cluster erzeugen, die jeweils für Finanztransaktionen eines Händlerkategorie-Codes repräsentativ sind. Diese Cluster

20 können für einen späteren Vergleich genutzt werden, inwieweit mit dem trainierten Sprachmodell eine zu prüfende Finanztransaktion mit einem bestimmten Händlerkategorie-Code einem entsprechenden Cluster für diesen Händlerkategorie-Code zuordnenbar ist oder gegebenenfalls so stark hiervon abweicht, dass von einer Anomalie auszugehen ist.

25 Grundsätzlich kann das zu trainierende Sprachmodell ein Transformer-Maschine-Learning-Modell sein, insbesondere ein mit BERT bidirektional vortrainiertes Transformer-Maschine-Learning-Modell, ein auf BERT basierendes Encoder-Transformer-Modell oder ein anderes bidirektionales Encoder-Transformer-Modell.

30 Die beigefügten Figuren veranschaulichen exemplarisch mögliche Ausführungsvarianten der vorgeschlagenen Lösung

Hierbei zeigen:

35

Figur 1 eine schematische Darstellung des Überwachungssystems und dessen Überwachung von Finanztransaktionen;

- Figur 2 eine Menge von Inputsequenzen für verschiedene Finanztransaktionen unter Veranschaulichung unterschiedlicher Transaktionscharakteristika für einen einzelnen Transaktionsdatensatz;
- 5
- Figur 3A das Vorgehen beim Trainieren eines mit bidirektional vortrainierten Transformer-Maschine-Learning-Modells auf Basis von Inputsequenzen gemäß der Figur 2;
- 10
- Figur 3A das Vorgehen für das Prüfen von Finanztransaktionen auf etwaige Anomalien auf Basis des trainierten Sprachmodells;
- Figur 4A Visualisierung unterschiedlicher mit dem trainierten Sprachmodell ermittelter Cluster für Finanztransaktionen;
- 15
- Figur 4B eine Visualisierung für einen mit dem Sprachmodell ermittelten Datenpunkt zu einer verdächtigen Finanztransaktion unter Veranschaulichung von Abständen dieses Datenpunktes zu unterschiedlichen Clustern;
- 20
- Figur 5A eine schematische Darstellung für die Bewertung der Relevanz von Finanztransaktionen auf Basis von Transaktionscharakteristika respektive damit definierter Inputtoken;
- 25
- Figur 5B eine schematische Darstellung für die Aufbereitung der Relevanz unterschiedlicher Transaktionscharakteristiken einer Finanztransaktion bei Erzeugung eines Alarmereignisses.
- 30
- Die Figur 1 zeigt schematisch ein elektronisches Überwachungssystem 1, mit dem sich mithilfe eines Sprachmodells Finanztransaktionen elektronisch überwachen lassen. Dem Überwachungssystem 1 werden hierbei Daten zu einer Vielzahl von Finanztransaktionen, beispielsweise von einem Finanzinstitut oder mehreren Finanzinstituten, zur Verfügung gestellt oder das Überwachungssystem 1 ist bei einem Finanzinstitut im Einsatz. In der
- 35
- Figur 1 sind schematisch Finanztransaktionen T1 bis T4 für das Konto eines Zahlungsempfängenden E mithin einem Begünstigten dargestellt. Mit jeder Finanztransaktionen T1 bis T4 erhält der Zahlungsempfängende E Zahlungsflüsse in

unterschiedlicher Höhe von unterschiedlichen Zahlungleistenden S1, S2, S3. Mithilfe des Überwachungssystems 1 werden die Finanzströme auf Basis der Finanztransaktionen T1 bis T4 geprüft, um elektronisch und automatisiert Verdachtsfälle zu identifizieren, bei denen von einer Anomalie bei der jeweiligen Finanztransaktion und mithin beispielsweise von einem Verstoß gegen Regularien zur Geldwäsche verstoßen wird.

Wird bei einer der Finanztransaktionen eine Anomalie festgestellt, erzeugt das Überwachungssystem 1 automatisch ein Alarmereignis. Dieses Alarmereignis führt dann beispielsweise zur Ausgabe einer Alarmmeldung, um auf einen Verdachtsfall bei mindestens einer der Finanztransaktionen T1 bis T4 hinzuweisen. Die Ausgabe einer solchen Alarmmeldung erfolgt dann beispielsweise an einer Computervorrichtung eines mit Überwachungssystem 1 gekoppelten Nutzersystems 2 im Zuge einer Geldwäschebekämpfung (englisch „anti-money laundry“).

Bei einer Ausführungsvariante der vorgeschlagenen Lösung ist vorgesehen, Daten zu jeder Finanztransaktionen T1 bis T4 einem trainierten Sprachmodell des Überwachungssystems 1 als Inputsequenz SQ mit voneinander unterscheidbaren Transaktionscharakteristika TC1 bis TC5 zur Verfügung zu stellen. Eine Inputsequenz SQ entsprechend der Figur 2 weist beispielsweise einen Transaktionstext TT und mithin einen String auf, der sich aus den mehreren Transaktionscharakteristika TC1 bis TC5 zusammensetzt.

Über die Summe der Transaktionscharakteristika TC1 bis TC5 ist eine Finanztransaktionen T1 bis T4 eindeutig bestimmt. So beinhaltet beispielsweise ein erstes Transaktionscharakteristikum TC1 eine Angabe zum Konto des Zahlungsempfängenden E. Ein Wert für das Transaktionscharakteristikum TC2 steht wiederum beispielsweise für die Art der Finanztransaktion und gibt beispielsweise an, ob es sich um eine Abhebung an einem Geldautomat oder eine Überweisung handelt. Ein weiteres Transaktionscharakteristikum TC3 gibt beispielsweise die Kontonummer des Zahlungsempfängenden S1, S2 oder S3 an. Mit dem Transaktionscharakteristikum TC4 wird beispielsweise die Bankleitzahl des Kontos des Zahlungsempfängenden S1, S2, S3 identifiziert. Ein Transaktionscharakteristikum TC5 enthält wiederum eine Information zur Höhe des Geldbetrages. Weitere Transaktionscharakteristika geben wiederum Datum und Uhrzeit der Finanztransaktionen an.

Für ein Training eines Sprachmodells des Überwachungssystems 1 können mehrere Inputsequenzen SQ für ein Konto nach Art von Wörtern zur Verfügung gestellt werden, die

Grundlage für ein zu erlernendes Vokabular sein sollen. Aus Finanztransaktionen für ein einzelnes Konto wird hierfür zufällig eine Menge von mehreren Finanztransaktionen ausgewählt, um einen Transaktionsdatensatz TS und mithin eine Menge von Inputsequenzen SQ für das Training zur Verfügung zu stellen.

5

Sowohl für das Training des Sprachmodells als auch für dessen spätere Verwendung wird eine Inputsequenz SQ jeweils tokenisiert. Die einzelnen Transaktionscharakteristika TC1 bis TC5 werden hierbei in numerische Inputtoken w_1 bis w_5 umgewandelt.

10 So können beispielsweise zwei Inputsequenzen für das eine Konto wie folgt aufgebaut sein:

(1)

15 Trx1 Hp1 Cp019 2023-10-27:00:00:00 300EUR CASH DEBIT
ATM_WITHDRAWAL DE MCC5892

(2)

Trx2 Hp1 Cp670 2023-10-30:01:10:08 600EUR ACH CREDIT ACH_TRANSFER
US MCC5892

20

Anhand der vordefinierten Transaktionscharakteristika TC1 bis TCn lassen sich diese Inputsequenzen wie folgt darstellen:

(3)

25 0D 0H 0M 0S AMOUNT2 CASH DEBIT ATM_WITHDRAWAL DE

(4)

3D 1H 10M 8S AMOUNT3 ACH CREDIT ACH_TRANSFER US

30 Hierbei wird beispielsweise der Zeitpunkt („2023-10-27:00:00:00“) der frühesten Finanztransaktion (1) als Nullpunkt gesetzt und für die Datumsbindung und Zeitangabe zu der zweite Finanztransaktionen lediglich die Differenz („3D 1H 10M 8S“) verwendet.

Im Anschluss werden die Inputsequenzen für die Finanztransaktionen (1) und (2) auf Basis
35 der Formate (3) und (4) in eine numerische Darstellung für Inputtoken w_1 bis w_n wie folgt überführt:

(5)

0 31 54 67 120 129 141 143 286

(6)

5 3 32 65 74 121 132 140 148 232

Angenommen, das entsprechende Konto betrifft einen Händlerkategorie-Code MCC mit dem Wert „523“, dann lässt sich hiermit eine Inputtoken-Sequenz durch den Tokenizer für dieses Konto wie folgt darstellen:

10

[CLS] 523 [SEP] 3 32 65 74 121 132 140 148 232 [SEP] 0 31 54 67 120 129 141
 143 286 [SEP] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD]
 [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD]
 [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD]
 15 [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD] [PAD]
 [PAD]

20

Hierbei bildet der Token [CLS] einen üblichen Klassifikationstoken. Mit [SEP] wird ein Separations- oder Trenntoken bezeichnet, der zwei Inputsequenzen voneinander trennt. Mit [PAD] wird ein Fülltoken (englisch „padding token“) bezeichnet, um eine Menge an Inputtoken-Sequenzen SQ für ein Konto auf eine für alle Trainingsdaten einheitliche Größe für einen Transaktionsdatensatz TS zu bringen.

25

Teil der tokenisierten Transaktionscharakteristika TC1 bis TCn und damit der numerischen Inputtoken kann auch ein Kategorisierungsparameter für das Transaktionsvolumen der jeweiligen Finanztransaktion T1 bis T4 sein. So ist eine IBAN eines Zahlungsempfängenden E für jedes betrachtete Konto, zu dem eine Finanztransaktion T1 bis T4 betrachtet wird, in der Regel unterschiedlich. Würde damit eine IBAN als Transaktionscharakteristikum übergeben, würde dies die Übertragbarkeit gelernter Charakteristika von einem Konto auf ein anderes Konto erschweren, da mit jedem Konto und dessen betrachteten Transaktionscharakteristika TC1 bis TCn eine andere Menge an IBANs und damit Inputtoken w_1 bis w_n zugeführt würden. Vor diesem Hintergrund ist in einer Ausführungsvariante eine Kategorisierung respektive Sortierung nach Transaktionsvolumen vorgesehen. Hierbei wird jedem Konto als Teil einer Menge von Inputsequenzen SQ, die im Beispiel der Figur 1 für einen Zahlungleistenden S1 bis S3, mithin einem Konto einer Gegenpartei, dem zu trainierenden Sprachmodell zur Verfügung gestellt werden, ein Wert für einen Kategorisierungsparameter zugeordnet. Die Werte für

30

35

diesen Kategorisierungsparameter hängen dabei vom Transaktionsvolumen der jeweiligen Finanztransaktionen T1 bis T4 mit dem jeweiligen Konto (der Gegenpartei) ab. Ein erster Wert für diesen Kategorisierungsparameter wird z.B. stets identisch für dasjenige Konto eines Zahlungleistenden S1 bis S3 mit dem größten Transaktionsvolumen gesetzt.

- 5 Beispielsweise kann in diesem Zusammenhang vorgesehen sein, dass für dasjenige Konto mit dem größten Transaktionsvolumen stets ein Inputtoken mit dem Wert „0“ für den Kategorisierungsparameter vorgesehen ist und in Abhängigkeit von der Größe der vorkommenden Transaktionsvolumina weitere Inputtoken mit aufsteigenden Werten gesetzt werden, z.B. ein Inputtoken „1“ für das zweitgrößte Transaktionsvolumen, etc. Das
- 10 erlaubt dem zu Sprachmodell eine bessere Generalisierung von einem Konto zum nächsten Konto.

- Das Training des in dem Überwachungssystem 1 zur Überwachung von Finanztransaktionen T1 bis T4 eingesetzten Sprachmodells ist anhand der Figur 3A näher
- 15 veranschaulicht. Hierbei ist ein Sprachmodell 31 mit bidirektionalem Transformer Encoder vorgesehen. Inputsequenzen SQ respektive eine Menge von Inputsequenzen SQ wird hierbei einem Tokenizer 10 zugeführt. Dieser Tokenizer 10 erzeugt auf Basis der Transaktionscharakteristika TC1 bis TC5 jeder Inputsequenz SQ für die Finanztransaktionen eine Tokensequenz mit den Inputtoken w_1 bis w_5 .

- 20 Für das Trainieren des Sprachmodells 31 wird nun ein bestimmter Anteil der Inputtoken w_1 bis w_5 maskiert, im Beispiel der Figur 3 exemplarisch dargestellt durch Ersetzen des Inputtoken w_4 durch eine maskierten Token [MASK]. Die Tokensequenz wird dann einer Worteinbettung 30 (englisch „embedding“) zugeführt, um die Tokensequenz für das
- 25 Sprachmodell 31 aufzubereiten. Diese Aufbereitung schließt hier die vorstehend erläuterte Hinzufügung des Klassifikationstoken [CLS], der Trenntoken [SEP] und der Fülltoken [PAD] ein.

- Eine Tokensequenz durchläuft dann eine Transformer Encoder Ebene des Sprachmodells
- 30 31. Zu einer teilweise maskierten Tokensequenz erzeugt das Sprachmodell 31 hierbei in an sich für BERT bekannter Weise mehrdimensionale Outputvektoren O1 bis O5, aus denen sich nach einer Klassifikation 32 und anschließender Vokabularisierung 33 Outputtoken w'_1 bis w'_5 ergeben. Die Outvektoren O1 bis O5 korrespondieren dementsprechend mit den jeweiligen Inputtoken w_1 bis w_5 . Die Outputvektoren O1 bis O5
- 35 enthalten folglich die Kontextinformationen des jeweiligen Inputtoken w_1 bis w_5 , sodass gelernt werden kann, in welchem Kontext ein bestimmtes Transaktionscharakteristikum auftritt. Bei der Klassifikation 32 werden eine oder mehrere Klassifikationsschichten

- durchlaufen, die Wahrscheinlichkeiten für verschiedene Klassen in einer Klassifizierungsaufgabe erzeugen, sodass nachfolgend auf Basis einer Wahrscheinlichkeitsverteilung und des bereits gelernten Kontextes auf Outputtoken für maskierte Inputtoken, wie z.B. einen Outputtoken w'_4 für den maskierten Inputtoken w_4 geschlossen wird. Das Sprachmodell 31 wird folglich mit einer Vielzahl von Mengen von Inputsequenzen SQ mit dem Ziel trainiert, auf Basis des Kontextes, mithin unmaskierter Inputtoken w_1, w_2, w_3, w_5 auf maskierte Inputtoken wie den Inputtoken w_4 zu schließen. Beispielsweise können für die Maskierung zufällig 15% der Inputtoken w_1 bis w_5 ausgewählt werden. Hiervon werden i) 80% durch einen maskierten Token [MASK] entsprechend der Figur 3A ersetzt, ii) 10% mit einem zufälligen Inputtoken ersetzt und iii) 10% unverändert gelassen. Durch Vergleich der erzeugten Outputtoken w'_1 bis w'_5 mit der Tokensequenz der Inputtoken w_1 bis w_5 wird das Sprachmodell 31 trainiert, Inputtoken korrekt vorherzusagen und damit auf Transaktionscharakteristika TC1 bis TC5 zu schließen.
- Ist das Sprachmodell mit entsprechenden Trainingsdaten trainiert, steht ein trainiertes Sprachmodell 34 entsprechend der Figur 3B für die effiziente Überwachung von Finanztransaktionen zur Verfügung. Hierbei wird für jede Finanztransaktion T1 bis T4 eine Inputsequenz SQ dem Tokenizer 10 einzeln oder als Teil einer Menge von mehreren Inputsequenzen SQ für ein Konto zur Verfügung gestellt. Ein bestimmter Anteil der Inputtoken w_1 bis w_5 wird auch hier maskiert. Mit dem durchlaufen der Transformer Encoder Ebene des trainierten Sprachmodells 34 werden hochdimensionale Outputvektoren O1 bis O5 erzeugt, mit denen für maskierte Inputtoken w_4 Outputvektoren vorhergesagt werden. Weichen vorhergesagte Outputtoken und damit eine Outputtoken-Ssequenz von der tatsächlichen Tokensequenz w_1 - w_5 ab, lässt dies auf eine Anomalie bei der jeweiligen Finanztransaktionen schließen. D. h., es wird mit anderen Worten geprüft, inwieweit auf Basis des trainierten Sprachmodells 34 zuvor maskierte Inputtoken für Transaktionscharakteristika korrekt vorhergesagt werden. Ist dies nicht der Fall, weichen die Transaktionscharakteristika TC1 bis TC5 einer Finanztransaktion auffällig stark von dem Regelfall ab. Damit erscheint die jeweilige Finanztransaktion verdächtig und löst ein Alarmereignis aus, um dieses näher durch einen Nutzer respektive eine Kontrollinstanz, beispielsweise bei einem Finanzinstitut, weiter zu prüfen. Eine entsprechende Anomaliedetektion 35 ist in der Figur 3B vorgesehen.
- Die Anomaliedetektion 35 kann gegebenenfalls ergänzend einschließen, dass nach einer Dimensionsreduzierung der hochdimensionalen Outputvektoren O1 bis O5 für eine

Finanztransaktion ein Datenpunkt bestimmt und mit über beim Training des Sprachmodells 31 generierten Clustern für die bisher betrachteten Finanztransaktionen verglichen wird.

So lässt sich entsprechend der Visualisierung der Figur 4 zeigen, dass
5 Finanztransaktionen, die für ein Konto mit einem bestimmten Händlerkategorie-Code MCC als eine Referenz-Inputtoken klassifiziert sind, mit dem Sprachmodell 31 verschiedenen, für Händlerkategorie-Codes spezifischen Clustern C1 bis C9 zuordnenbar sind. Liegt dann aber ein Datenpunkt A für eine Finanztransaktion entsprechend der Figur 4B nicht in der Nähe eines dieser Cluster C1 bis C9, spricht auch dies für eine Anomalie bei der
10 Finanztransaktion, die zu dem Datenpunkt A gehört. Beispielsweise ist bei dem visualisierten Beispiel der Figur 4B der Datenpunkt A mit einem Abstand d1 zu einem Zentrum M1 des einen Clusters C8 und mit einem Abstand d2 zu einem Zentrum M2 eines anderen Clusters C5 jeweils so weit beabstandet, dass der Abstand d1 über einem für das Cluster C8 vorgegebenen Schwellwert liegt und der Abstand d2 über einem für das Cluster
15 C5 vorgegebenen Schwellwert liegt.

Wird im Rahmen der Anomaliedetektion 35 der Figur 3B somit beispielsweise für eine Finanztransaktion mithilfe des trainierten Sprachmodells 34 festgestellt, dass das Sprachmodell 34 die Tokensequenz w_1 bis w_5 nicht vollständig zutreffend vorhersagt und
20 zudem ein hierfür ermittelter Datenpunkt A keinem zuvor ermittelten Cluster C5 oder C8 für ähnliche Finanztransaktionen zuordnen ist, spricht dies für eine Anomalie und mithin eine verdächtige Finanztransaktionen, die ein Alarmereignis auslöst.

Um eine entsprechend ausgelöstes Alarmereignis im Zuge der Bewertung einer weiteren
25 Prüfung durch einen menschlichen Benutzer leichter bewertbar zu machen, ist bei der Ausführungsvariante der Figur 3B nach der Anomaliedetektion 35 noch eine Relevanzbewertung 36 vorgesehen. Hierbei werden diejenigen Kriterien, die für die sprachmodellbasierte Bewertung einer Finanztransaktion als verdächtig maßgeblich waren, für einen menschlichen Benutzer bei der Ausgabe des Alarmereignisses aufbereitet
30 und nachvollziehbar visualisiert.

So lässt sich beispielsweise jede Finanztransaktionen T1 bis T4 als Summe von Transaktionscharakteristika respektive entsprechender Transaktionstoken 500, 501 darstellen, die unterschiedlichen Gruppen 50 und 51 zugeordnet sind. So stehen
35 beispielsweise die Transaktionstoken 500 gemeinsam für einen Zahlungstyp 50 und die Transaktionstoken 501 einem Ländercode 51. Indem beispielsweise bei der Finanztransaktionen T1 einer der Transaktionstoken 500 für den Zahlungstyp 50 – mit Blick

auf das Detektieren einer Anomalie – als hochrelevant eingestuft wird, wird die Finanztransaktionen mit einem Relevanzwert (englisch „importance score“) von 1 versehen. Demgegenüber enthält die Finanztransaktion T3 einen Relevanzwert von 2, während die beiden weiteren dargestellten Informationen T2 und T4 mit dem Relevanzwert 3 eingestuft werden. In einer Visualisierung der unterschiedlichen Finanztransaktionen T1 bis T4 wird somit auf einem Nutzersystem 2 die Finanztransaktionen T1 als möglicherweise relevanter für die genauere Betrachtung auf das Auftreten einer Anomalie hin hervorgehoben. Das trainierte Sprachmodell 34 ermöglicht somit eine tokenbasierte Erklärbarkeit für die Einstufung verschiedener Finanztransaktionen als potenziell verdächtig oder unverdächtig.

Diesem Grundsatz liegt auch eine Visualisierung entsprechend der Figur 5B zugrunde. Während für die Visualisierung im Rahmen der Relevanzbewertung 36 entsprechend der Figur 5A tokenbasiert Unterschiede über mehrere Finanztransaktionen T1 bis T4 visualisiert werden, ist bei einer Visualisierung entsprechend dem Vorgehen der Figur 5B vorgesehen, die unterschiedlichen Transaktionscharakteristika innerhalb einer Finanztransaktion T1 für einen Nutzer des Nutzersystems 2 zu visualisieren, die zu einer Bewertung dieser Finanztransaktion T1 als verdächtig und mithin als Detektion einer Anomalie geführt haben. Lässt sich Beispiel auf Basis der Transaktionstoken 500, 501 und damit für die entsprechenden Transaktionscharakteristika vorhergesagte Outputtoken des trainierten Sprachmodells 34 darauf schließen, dass es gegenüber als zulässig einzustufenden Finanztransaktionen gerade beim Zahlungstyp und Ländercode erhebliche Abweichungen gibt, lassen sich diese gewichten und dahingehend visualisieren.

So kann einem Nutzer beispielsweise nach Auftreten mehrerer ähnlich auffälliger Finanztransaktionen mitgeteilt werden, dass bei dem für ein Konto insbesondere auf Basis der Finanztransaktion T1 ausgelösten Alarmereignis beispielsweise jeweils anteilig entscheidend war, dass wiederholt in kurzer Folge kleinere Beträge auf ein bestimmtes Konto eines Zahlungsempfangenden E erfolgt sind, ein Großteil des Transaktionsvolumens jeweils Teil einer Round-Trip-Transaktion war und zumindest teilweise auf eine grenzüberschreitende Finanztransaktionen zurückging.

Durch eine damit ebenfalls tokenbasierte Visualisierung lässt sich Erklärbarkeit für einen Nutzer des Überwachungssystems 1 erheblich verbessern. Dies bietet einen zusätzlichen Vorteil bei der mit der vorgeschlagenen Lösung einhergehenden verbesserten Technik zur effizienten elektronischen, automatisierten Überwachung von Finanztransaktionen auf

Basis eines Sprachmodells, die mit vergleichsweise geringer Prozessorleistung und hoher Geschwindigkeit umsetzbar ist.

Bezugszeichenliste

1	Überwachungssystem
10	Tokenizer
2	Nutzersystem
30	Worteinbettung / Embedding
31	Vortrainiertes Sprachmodell / Transformationsencoder
32	Klassifikation
33	Vokabularisierung
34	Trainiertes Sprachmodell
35	Anomaliedetektion und Clustering
36	Relevanzbewertung
50	Zahlungstyp
500	Transaktionstoken für Zahlungstyp
501	Transaktionstoken für Ländercode
51	Ländercode
A	Datenpunkt für Anomalie
C1 – C9	Cluster
d1, d2	Abstand
E	Zahlungsempfänger
I	Relevanzwert
M1, M2	Clusterzentrum
O1, O2, O3, O4, O5	Outputvektor
S1, S2, S3	Zahlungsemitter
SQ	Inputsequenz
T1, T2, T3, T4	Finanztransaktion
TC1 – TC5	Transaktionscharakteristik
TS	Transaktionsdatensatz (Menge von Inputsequenzen)
TT	Transaktionstext
w' ₁ , w' ₂ , w' ₃ , w' ₄ , w' ₅	Outputtoken
w ₁ , w ₂ , w ₃ , w ₄ , w ₅	Inputtoken

Ansprüche

1. Überwachungssystem für die Überwachung von Finanztransaktionen (T1, T2, T3, T4),
wobei das Überwachungssystem (1) elektronisch Finanztransaktionen (T1, T2, T3, T4)
5 zwischen mindestens einem Zahlungleistenden (S1, S2, S3) und mindestens einem
Zahlungsempfangenden (E) auf das Auftreten wenigstens einer Anomalie prüft und das
Überwachungssystem (1) konfiguriert ist, bei Detektion wenigstens einer Anomalie ein
Alarmereignis zu erzeugen,
10 **dadurch gekennzeichnet**, dass

das Überwachungssystem (1) einen Tokenizer (10) und ein Sprachmodell (34) für die
Überwachung der Finanztransaktionen (T1, T2, T3, T4) umfasst, wobei der Tokenizer
(10) vorgesehen ist, aus einer für eine Finanztransaktion (T1, T2, T3, T4)
15 repräsentativen Inputsequenz (SQ) eine Tokensequenz (w_1 - w_5) zu generieren, und
das Sprachmodell (34) vorgesehen ist, auf Basis einer Tokensequenz (w_1 - w_5) oder
mehrerer Tokensequenzen (w_1 - w_5) das Auftreten einer Anomalie in einer oder
mehrerer Finanztransaktionen (T1, T2, T3, T4) für die Erzeugung eines Alarmereignis
zu prüfen.
20
2. Überwachungssystem nach Anspruch 1, **dadurch gekennzeichnet**, dass der
Tokenizer (10) dazu eingerichtet und vorgesehen ist, in einer Tokensequenz (w_1 - w_5)
wenigstens einen Inputtoken (w_4) der aus der Inputsequenz (SQ) generierten
Inputtoken (w_1, w_2, w_3, w_4, w_5) zu maskieren, bevor die Tokensequenz (w_1 - w_5) an das
25 Sprachmodell (34) übergeben wird, und das Überwachungssystem konfiguriert ist, mit
dem Sprachmodell (34) einen Outputtoken (w'_4) für den wenigstens einen maskierten
Inputtoken (w_4) vorherzusagen.
3. Überwachungssystem nach Anspruch 2, **dadurch gekennzeichnet**, dass das
30 Überwachungssystem konfiguriert ist, für die Detektion einer Anomalie zu prüfen,
inwieweit der wenigstens eine vorhergesagte Outputtoken (w'_4) mit dem zugehörigen
Inputtoken (w_4) übereinstimmt.
4. Überwachungssystem nach Anspruch 3, **dadurch gekennzeichnet**, dass der
35 Tokenizer (10) dazu eingerichtet und vorgesehen ist, in einer Tokensequenz (w_1 - w_5)
einen vorgegebenen Anteil der Inputtoken (w_1, w_2, w_3, w_4, w_5) zu maskieren, und das
Überwachungssystem konfiguriert ist, für die Detektion einer Anomalie zu prüfen,

inwieweit vorhergesagte Outputtoken ($w'_1, w'_2, w'_3, w'_4, w'_5$) mit zugehörigen Inputtoken (w_1, w_2, w_3, w_4, w_5) übereinstimmen.

5. Überwachungssystem nach einem der vorhergehenden Ansprüche, **dadurch gekennzeichnet**, dass das Überwachungssystem (1) konfiguriert ist, für die Detektion einer Anomalie eine Finanztransaktion (T1, T2, T3, T4) anhand wenigstens eines Referenz-Inputtokens (w_1) der zu der Finanztransaktion (T1, T2, T3, T4) zugehörigen Tokensequenz (w_1-w_5) mit mindestens einem Cluster (C1-C9) zu vergleichen das auf Basis von Tokensequenzen für Finanztransaktionen (T1, T2, T) mit zueinander übereinstimmenden Referenz-Inputtoken (w_1) gebildet ist.
5
10
6. Überwachungssystem nach Anspruch 5, **dadurch gekennzeichnet**, dass der Referenz-Inputtoken (w_1) jeweils ein Inputtoken einer Tokensequenz (w_1-w_5) ist, der für einen in der Inputsequenz (SQ) enthaltenen Händlerkategorie-Code repräsentativ ist.
15
7. Überwachungssystem nach Anspruch 5 oder 6, **dadurch gekennzeichnet**, dass das Überwachungssystem (1) konfiguriert ist, für die Detektion einer Anomalie zu prüfen, inwieweit die jeweilige Finanztransaktion (T1, T2, T3, T4) dem mindestens einen Cluster (C1-C9) zuordnenbar ist.
20
8. Überwachungssystem nach einem der Ansprüche 5 bis 7, **dadurch gekennzeichnet**, dass das Überwachungssystem (1) konfiguriert ist, für den Vergleich mit dem mindestens einen Cluster (C1-C9) mit dem Sprachmodell (34) anhand des wenigstens einen Referenz-Inputtokens (w_1) für die Finanztransaktion (T1, T2, T3, T4) einen Datenpunkt (A) zu bestimmen und dessen Abstand (d_1, d_2) zu einem Zentrum (M1, M2) des mindestens einen Clusters (C1-C9) zu ermitteln.
25
9. Überwachungssystem nach Anspruch 8, **dadurch gekennzeichnet**, dass das Überwachungssystem (1) konfiguriert ist, für die Detektion einer Anomalie den ermittelten Abstand (d_1, d_2) mit einem hinterlegten Schwellwert zu vergleichen.
30
10. Überwachungssystem nach Anspruch 9, **dadurch gekennzeichnet**, dass für unterschiedliche Cluster (C1-C9) unterschiedliche Schwellwerte vorgesehen sind.
35
11. Überwachungssystem nach einem der Ansprüche 8 bis 10, **dadurch gekennzeichnet**, dass das Überwachungssystem (1) zur Bestimmung des Datenpunkts (A) konfiguriert ist, für aus dem Sprachmodell (34) für Inputtokens (w_1, w_2, w_3, w_4, w_5) einer Finanztransaktion (T1, T2, T3, T4) erhaltene, mehrdimensionale Outputvektoren (O_1-O_5) eine Dimensionsreduktion durchzuführen.
40

12. Überwachungssystem nach einem der Ansprüche 3 oder 4 und einem der Ansprüche 5 bis 11, **dadurch gekennzeichnet**, dass das Überwachungssystem (1) konfiguriert ist, für die Detektion einer Anomalie, zum einen zu prüfen, inwieweit der wenigstens eine vorhergesagte Outputtoken (w'_4) mit dem zugehörigen Inputtoken (w_4) übereinstimmt und zum anderen anhand des wenigstens einen Referenz-Inputtokens (w_1) einen Vergleich mit dem mindestens einen Cluster (C1-C9) durchzuführen.
13. Überwachungssystem nach einem der vorhergehenden Ansprüche, **dadurch gekennzeichnet**, dass das Sprachmodell (34) des Überwachungssystems (1) ein Transformer-Machine-Learning-Modell ist, insbesondere ein auf Basis von Inputsequenzen (SQ) zu Finanztransaktionen (T1, T2, T3, T4) trainiertes Transformer-Machine-Learning-Modell und insbesondere ein auf Basis von Inputsequenzen (SQ) zu Finanztransaktionen (T1, T2, T3, T4 bi-direktional trainiertes Transformer-Machine-Learning-Modell.
14. Überwachungssystem nach einem der vorhergehenden Ansprüche, **dadurch gekennzeichnet**, dass das Alarmereignis zur Ausgabe an einer Computervorrichtung des Überwachungssystems (1) und/oder an einer Computervorrichtung eines mit dem Überwachungssystem (1) verbundenen Nutzersystems (2) vorgesehen ist.
15. Verfahren zum elektronischen Überwachen von Finanztransaktionen (T1, T2, T3, T4) zwischen mindestens einem Zahlungleistenden (S1, S2, S3) und mindestens einem Zahlungsempfangenden (E) auf das Auftreten wenigstens einer Anomalie, wobei in Reaktion auf wenigstens eine bei der Prüfung detektierte Anomalie ein Alarmereignis erzeugt wird,
- dadurch gekennzeichnet**, dass
- aus einer für eine Finanztransaktion (T1, T2, T2) repräsentativen Inputsequenz (SQ) jeweils über einen Tokenizer (10) eine Tokensequenz (w_1 - w_5) generiert wird und mit einem Sprachmodell (34) auf Basis einer Tokensequenz (w_1 - w_5) oder mehrerer Tokensequenzen (w_1 - w_5) das Auftreten einer Anomalie in einer oder mehreren Finanztransaktionen (T1, T2, T) für die Erzeugung eines Alarmereignis geprüft wird.
16. Computerprogrammprodukt umfassend Befehle, die bei einer Ausführung durch mindestens einen Prozessor, den mindestens einen Prozessor veranlassen, das Verfahren nach Anspruch 15 auszuführen.

17. Verfahren zum Trainieren eines Sprachmodells (31) für die Überwachung von Finanztransaktionen, umfassend wenigstens die folgenden Schritte:
- Bereitstellen von Daten (TT) zu einzelnen Finanztransaktion (T1, T2, T3, T4);
 - Erzeugung wenigstens einer Menge von Inputsequenzen (SQ) für die Finanztransaktionen, wobei jede Inputsequenz (SQ) voneinander unterscheidbare Transaktionscharakteristika (TC1-TC5) enthält;
 - Tokenisierung der Inputsequenzen (SQ) anhand der Transaktionscharakteristika (TC1-TC5) mit einem Tokenizer (10) zur Erzeugung von Inputtokens (w_1 - w_5) für jede Inputsequenz (SQ);
 - Trainieren des Sprachmodells (31) auf Basis der Inputtokens (w_1, w_2, w_3, w_4, w_5) und der Inputsequenzen (SQ), indem zumindest ein Teil der Inputtokens (w_1, w_2, w_3, w_4, w_5) maskiert wird, um ein auf Daten zu Finanztransaktionen (T1, T2, T2) trainiertes Sprachmodell (34) bereitzustellen, mit dem auf Basis einer Tokensequenz (w_1 - w_5) oder mehrerer Tokensequenzen (w_1 - w_5) das Auftreten einer Anomalie in einer oder mehreren Finanztransaktionen (T1, T2, T) detektierbar ist.
18. Verfahren nach Anspruch 17, **dadurch gekennzeichnet**, dass die Inputtokens (w_1, w_2, w_3, w_4, w_5) mittels Wordembedding Vektoren reeller Zahlen zugeordnet werden.
19. Verfahren nach Anspruch 17 oder 18, **dadurch gekennzeichnet**, dass der Tokenizer (10) die Transaktionscharakteristika (TC1-TC5) in numerische Inputtokens (w_1, w_2, w_3, w_4, w_5) umsetzt.
20. Verfahren nach Anspruch 19, **dadurch gekennzeichnet**, dass die für die wenigstens eine Menge von Inputsequenzen (SQ) zugrunde gelegten Finanztransaktionen (T1, T2, T3, T4) einem Konto eines bestimmten Händlerkategorie-Codes zugeordnet sind.
21. Verfahren nach einem der Ansprüche 17 bis 20, **dadurch gekennzeichnet**, dass eine Vielzahl an Mengen von Inputsequenzen (SQ) erzeugt werden, wobei diesen Mengen von Inputsequenzen (SQ) Konten mit unterschiedlichen Händlerkategorie-Codes zugrunde liegen, und auf Basis von mehrdimensionalen, von dem Sprachmodell (31) als Output erzeugten Outputvektoren (O_1 - O_5), nach einer Dimensionsreduzierung, über eine Clusterfunktion Cluster (C1-C9) erzeugt werden, die jeweils für Finanztransaktionen (T1, T2, T3, T4) eines Händlerkategorie-Codes repräsentativ sind.

22. Verfahren nach einem der Ansprüche 17 bis 21, **dadurch gekennzeichnet**, dass wenigstens einer der tokenisierten Transaktionscharakteristika (TC1-TC5) einen Kategorisierungsparameter für ein Transaktionsvolumen der jeweiligen Finanztransaktion (T1, T2, T3, T4) betrifft.
- 5 23. Verfahren nach Anspruch 22, **dadurch gekennzeichnet**, dass Werte für den Kategorisierungsparameter in aufsteigender oder absteigender Reihenfolge beginnend mit einem Wert für dasjenige Konto einer Gegenpartei (S1-S3) vorgegeben werden, das angesichts der zur Verfügung gestellten Daten (TT) zu den
- 10 Finanztransaktionen (T1, T2, T3, T4) mit einem Konto das größte Transaktionsvolumen hat.
24. Verfahren nach einem der Ansprüche 17 bis 23, **dadurch gekennzeichnet**, dass das zu trainierende Sprachmodell (31) ein Transformer-Machine-Learning-Modell ist,
- 15 insbesondere ein bi-direktional vortrainiertes Transformer-Machine-Learning-Modell.
25. Verwendung eines Überwachungssystems nach einem der Ansprüche 1 bis 14 für die Überwachung von Finanztransaktionen.