

19



OFICINA ESPAÑOLA DE
PATENTES Y MARCAS

ESPAÑA



11 Número de publicación: **2 972 932**

51 Int. Cl.:

B60R 21/01 (2006.01)

B60R 21/0132 (2006.01)

B60R 21/017 (2006.01)

12

TRADUCCIÓN DE PATENTE EUROPEA

T3

96 Fecha de presentación y número de la solicitud europea: **17.08.2020 E 20191355 (5)**

97 Fecha y número de publicación de la concesión europea: **03.01.2024 EP 3782860**

54 Título: **Método y sistema para la estimación de la velocidad de un vehículo**

30 Prioridad:

16.08.2019 US 201962888182 P

14.08.2020 US 202016994232

45 Fecha de publicación y mención en BOPI de la traducción de la patente:

17.06.2024

73 Titular/es:

CAMBRIDGE MOBILE TELEMATICS INC. (100.0%)

314 Main Street, Suite 1200

Cambridge, MA 02142, US

72 Inventor/es:

KARNIK, SUSHRUT;

EREM, BURAK;

QI, YUTING;

SAHOO, SANUJIT y

KITCHEN, HARRISON

74 Agente/Representante:

VALLEJO LÓPEZ, Juan Pedro

ES 2 972 932 T3

Aviso: En el plazo de nueve meses a contar desde la fecha de publicación en el Boletín Europeo de Patentes, de la mención de concesión de la patente europea, cualquier persona podrá oponerse ante la Oficina Europea de Patentes a la patente concedida. La oposición deberá formularse por escrito y estar motivada; sólo se considerará como formulada una vez que se haya realizado el pago de la tasa de oposición (art. 99.1 del Convenio sobre Concesión de Patentes Europeas).

DESCRIPCIÓN

Método y sistema para la estimación de la velocidad de un vehículo

5 Antecedentes

El documento US 10 246 037 B1 divulga un método que comprende:

- 10 recibir, desde un dispositivo móvil dispuesto dentro de un vehículo, un conjunto de mediciones de sensor de un acelerómetro; convertir el conjunto de mediciones de sensor en un dominio de frecuencia; filtrar el conjunto de mediciones de sensor; definir un conjunto de ventanas contiguas basándose en unas mediciones de sensor restantes en el conjunto de mediciones de sensor, representando cada ventana contigua del conjunto de ventanas contiguas una porción contigua de las mediciones de sensor restantes en el conjunto de mediciones de sensor;
- 15 generar, para cada ventana contigua del conjunto de ventanas contiguas, un conjunto de características remuestreando las mediciones de sensor de la ventana contigua en una o más frecuencias predefinidas; generar una predicción de colisión de vehículo usando la predicción de velocidad; y transmitir, a un dispositivo remoto, la predicción de colisión de vehículo.
- 20 Los dispositivos móviles suelen incluir receptores de Sistema de Posicionamiento Global (GPS) así como Unidades de Medición Inercial (IMU) que incluyen sensores tales como un acelerómetro de tres ejes, un giroscopio de tres ejes y un magnetómetro de tres ejes para medir la velocidad angular, la fuerza y la intensidad del campo magnético. Las colisiones de vehículos pueden detectarse con una precisión razonable usando una combinación de datos de velocidad de GPS y mediciones de IMU. Sin embargo, un receptor de GPS consume una gran cantidad de energía
- 25 del dispositivo móvil y acorta el tiempo de funcionamiento del dispositivo móvil; por lo tanto, la confianza en los datos de GPS no es deseable.

Sumario

- 30 La deficiencia anterior puede superarse con las características de las reivindicaciones 1 y 15.
- De acuerdo con la invención, se proporciona un método para predecir eventos de colisión usando predicciones de velocidad de vehículo. el método incluye recibir desde un dispositivo móvil dispuesto dentro de un vehículo un conjunto de mediciones de sensor desde un acelerómetro; convertir el conjunto de mediciones de sensor en un dominio de frecuencia; filtrar con un filtro de paso de banda el conjunto de mediciones de sensor para eliminar mediciones de sensor de alta frecuencia del conjunto de mediciones de sensor; definir un conjunto de ventanas contiguas basándose en unas mediciones de sensor restantes en el conjunto de mediciones de sensor, representando cada ventana contigua del conjunto de ventanas contiguas una porción contigua de las mediciones de sensor restantes en el conjunto de mediciones de sensor; generar para cada ventana contigua del conjunto de ventanas contiguas un conjunto de características volviendo a muestrear las mediciones de sensor de la ventana contigua a una o más frecuencias predefinidas; generar una predicción de velocidad ejecutando una red neuronal entrenada usando el conjunto de características; generar una predicción de colisión de vehículo usando la predicción de velocidad; y transmitir a un dispositivo remoto la predicción de colisión de vehículo.
- 45 El método incluye recibir desde un dispositivo móvil dispuesto dentro de un vehículo un conjunto de mediciones de sensor desde un acelerómetro; generar un conjunto de ventanas contiguas usando el conjunto de mediciones de sensor, en donde cada ventana contigua del conjunto de ventanas contiguas representa un subconjunto del conjunto de mediciones de sensor; generar, para cada una de las ventanas contiguas del conjunto de ventanas contiguas una predicción de velocidad ejecutando una red neuronal entrenada usando el conjunto de ventanas contiguas; recibir una indicación de que el vehículo está involucrado en un evento de colisión; autenticar el evento de colisión usando la predicción de velocidad; determinar basándose en la autenticación del evento de colisión que no se produjo el evento de colisión; y purgar en respuesta a la determinación de que el evento de colisión no ocurrió el evento de colisión de la memoria.
- 50 Un ejemplo no cubierto por la presente invención incluye un sistema que comprende uno o más procesadores y un sistema no transitorio, instrucciones de almacenamiento en un medio legible por ordenador, que, cuando se ejecutan por uno o más procesadores, hacen que los uno o más procesadores realicen el primer método y/o el segundo método descritos anteriormente.
- 55 Un ejemplo no cubierto por la presente invención incluye instrucciones de almacenamiento en un medio legible por ordenador no transitorio, que, cuando se ejecutan por uno o más procesadores, hacen que uno o más procesadores realicen el primer método y/o el segundo método descritos anteriormente.
- 60 Se logran numerosos beneficios por medio de las diversas realizaciones sobre las técnicas convencionales. Por ejemplo, las diversas realizaciones proporcionan métodos y un dispositivo móvil que puede usarse para eludir el consumo de energía excesivo por los receptores de GPS que operan para la detección de accidentes de vehículos en
- 65

dispositivos móviles. En algunas realizaciones, las estimaciones de velocidad para la detección de colisiones se obtienen de mediciones de sensor de una unidad de medición inercial que consume significativamente menos energía de un dispositivo móvil que un receptor de GPS. Estas y otras realizaciones junto con muchas de sus ventajas y características se describen con más detalle junto con el texto a continuación y las figuras adjuntas.

- 5
- Breve descripción de los dibujos**
- Los aspectos y características de las diversas realizaciones serán más evidentes describiendo ejemplos con referencia a los dibujos adjuntos, en los que:
- 10
- La figura 1 es un diagrama simplificado de bloques que ilustra un ejemplo de un sistema para recopilar datos de conducción de acuerdo con algunos aspectos de la presente divulgación.
- 15
- La figura 2 es un diagrama de bloques simplificado que ilustra un ejemplo de otro sistema para recopilar datos de conducción de acuerdo con algunos aspectos de la presente divulgación.
- 20
- La figura 3 es un gráfico que ilustra un ejemplo de predicción de velocidad de vehículo por un clasificador que usa características extraídas de señales de IMU muestreadas a 9 Hz de acuerdo con diversos aspectos de la presente divulgación.
- Las figuras 4 y 5 son gráficos que ilustran ejemplos de predicción de velocidad de vehículo por un clasificador que usa características extraídas de señales de IMU muestreadas a 30 Hz de acuerdo con aspectos de la presente divulgación.
- 25
- La figura 6 es un diagrama de flujo que ilustra un ejemplo de un proceso para estimar la velocidad del vehículo de acuerdo con aspectos de la presente divulgación.
- Las figuras 7 y 8 son gráficos que ilustran ejemplos de predicción de velocidad de vehículo por un clasificador que usa características extraídas de señales de acelerómetro muestreadas a 30 Hz de acuerdo con aspectos de la presente divulgación.
- 30
- La figura 9 es un gráfico de agrupación que muestra la distancia estimada por el clasificador en comparación con la distancia medida por GPS de acuerdo con aspectos de la presente divulgación.
- 35
- La figura 10 es un diagrama de bloques que ilustra un ejemplo de un módulo de predicción de colisión de acuerdo con aspectos de la presente divulgación.
- Las figuras 11A-11D son gráficos que ilustran ejemplos de resultados de predicción de colisión de acuerdo con aspectos de la presente divulgación.
- 40
- La figura 12 es una representación ilustrativa de una estructura de datos de gráfico 1200 generada por unos datos de motor de detección de actividad de acuerdo con algunas realizaciones.
- La figura 13 es un diagrama de bloques ilustrativo del sistema 1300 para predecir la velocidad de un vehículo a partir de mediciones de sensor de dispositivo móvil de acuerdo con algunas realizaciones.
- 45
- La figura 14 es un conjunto ilustrativo de gráficos que ilustran la división de mediciones de sensor procesadas en ventanas contiguas de acuerdo con algunas realizaciones.
- 50
- La figura 15 es una representación ilustrativa de las capas de una red neuronal que puede generar una predicción de la velocidad de un vehículo de acuerdo con algunas realizaciones.
- La figura 16 es un diagrama de bloques ilustrativo de un sistema para predecir la velocidad de un vehículo que corresponde a etapas de tiempo usando mediciones de sensor de dispositivo móvil de acuerdo con algunas realizaciones.
- 55
- La figura 17 es un diagrama de flujo de ejemplo de un proceso para filtrar predicciones de velocidad de acuerdo con aspectos de la presente divulgación.
- 60
- La figura 18 incluye gráficos que ilustran un ejemplo en el que la "diferencia de ángulo de gravedad de ventana deslizante de suma" se usa para filtrar predicciones de velocidad de acuerdo con aspectos de la presente divulgación.
- 65
- La figura 19 es un gráfico ilustrativo que representa el uso de predicción de velocidad para derivar características para el modelo de aprendizaje automático para generar una predicción de colisión de acuerdo con algunas realizaciones.

La figura 20 es un diagrama de bloques de un proceso para predecir un accidente de vehículo de acuerdo con aspectos de la presente divulgación.

5 La figura 21 es un diagrama de flujo de ejemplo de un proceso para generar una predicción de colisión a una velocidad predicha de un vehículo de acuerdo con algunas realizaciones.

La figura 22 es un diagrama de bloques de un proceso para autenticar una predicción de colisión de vehículo usando predicciones de velocidad de acuerdo con aspectos de la presente divulgación.

10 La figura 23 es un gráfico de ejemplo de velocidad predicha a lo largo del tiempo que representa una predicción de colisión positiva verdadera de acuerdo con aspectos de la presente divulgación.

15 La figura 24 es un gráfico de ejemplo de velocidad predicha a lo largo del tiempo que representa una predicción de colisión falsamente positiva de acuerdo con aspectos de la presente divulgación.

Descripción detallada

20 Aunque se describen ciertas realizaciones, estas realizaciones se presentan únicamente a modo de ejemplo, y no pretenden limitar el alcance de protección como se define en las reivindicaciones adjuntas. Los aparatos, métodos y sistemas descritos en el presente documento pueden incorporarse en una variedad de otras formas. Asimismo, varias omisiones, sustituciones y cambios en la forma de los métodos y sistemas de ejemplo descritos en el presente documento pueden realizarse sin apartarse del alcance de protección como se define en las reivindicaciones adjuntas.

25 La figura 1 es un diagrama de sistema que ilustra un sistema 100 para medir la aceleración del dispositivo y detectar la interacción física de acuerdo con algunas realizaciones. El sistema 100 incluye un dispositivo móvil 104 que incluye una pluralidad de procesamiento, sensores y componentes de recursos de comunicación. El dispositivo móvil 104 puede incluir un bloque de datos de sensor 108, un bloque de procesamiento de datos 144, un bloque de transmisión de datos 164 y, opcionalmente, un bloque de notificación 160. El bloque de datos de sensor 108 incluye sensores de recopilación de datos, así como los datos recopilados de sensores que están disponibles para el dispositivo móvil 104. Esto puede incluir dispositivos externos conectados a través de Bluetooth, cable de USB, etc. El bloque de procesamiento de datos 144 puede incluir almacenamiento 156 que puede incluir datos de los sensores del bloque de datos de sensor 108 procesados por el procesador 122. Esto puede incluir, sin limitación, analizar, caracterizar, manipular, suavizar, submuestrear, filtrar, reformatear, etc. Los ejemplos de dispositivos móviles incluyen, pero sin limitación, teléfonos inteligentes, tabletas, ordenadores portátiles, circuitos integrados de aplicación específica (ASIC) y similares.

30 El bloque de transmisión de datos 164 puede procesar comunicaciones (por ejemplo, comunicaciones transmitidas y recibidas) tales como los datos de sensor procesados transmitidos a un dispositivo informático externo (por ejemplo, servidor 180). El dispositivo informático externo también puede almacenar y/o procesar los datos obtenidos del bloque de datos de sensor 108. El servidor 180 puede incluir su propio procesador 184 y almacenamiento 188.

35 El bloque de notificación 160 puede informar los resultados del análisis de datos de sensor realizados por el bloque de procesamiento de datos 144 a un usuario del dispositivo móvil 104 a través de una pantalla (no mostrada). Por ejemplo, el bloque de notificación 160 puede visualizar o presentar de otro modo una comunicación de advertencia a un usuario del dispositivo móvil 104 tras determinar que el usuario puede ser un conductor distraído. En algunos ejemplos, la determinación de interacción física puede ser un proceso ejecutado por el procesador 148 del dispositivo móvil 104. En otros ejemplos, la determinación de interacción física puede ser un proceso ejecutado por el procesador 184, como se describe adicionalmente en el presente documento con respecto a la figura 2.

40 Algunas realizaciones se describen usando ejemplos en los que se recopilan datos de conducción usando el dispositivo electrónico 104, y estos ejemplos no se limitan a ningún dispositivo electrónico particular. Por ejemplo, los dispositivos electrónicos pueden incluir una diversidad de dispositivos que se incluyen dentro o se conectan al dispositivo electrónico 104. Los ejemplos de dispositivos electrónicos incluyen, sin limitación, dispositivos con uno o más de sistemas de determinación de ubicación tales como receptores 112 de sistema de posicionamiento global (GPS), acelerómetros 116, magnetómetros 120, giroscopios 124, micrófonos 128, dispositivos externos (sensores) 132, brújulas 136, barómetros 140, capacidades de comunicación, y los dispositivos electrónicos ilustrativos incluyen relojes inteligentes, monitores de fitness, auriculares bluetooth, tabletas, ordenadores portátiles, teléfonos inteligentes, reproductores de música, dispositivos de análisis de movimiento y similares.

45 Uno o más sensores del dispositivo móvil 104 (por ejemplo, los sensores del bloque de datos de sensor 108) pueden operarse para recopilar mediciones para proporcionar una indicación en cuanto a la interacción física con el dispositivo móvil 104. En algunos ejemplos, las mediciones pueden recopilarse en el tiempo en que es probable que el dispositivo electrónico esté con el conductor cuando opera un vehículo, tal como cuando el dispositivo se mueve a una velocidad particular o cuando el dispositivo está ubicado en una carretera conocida (por ejemplo, una autopista). Los sensores usados para recopilar datos pueden ser componentes del dispositivo móvil 104 y usan recursos de energía disponibles

para los componentes del dispositivo móvil 104 (por ejemplo, energía de la batería del dispositivo móvil y/o una fuente de datos externa al dispositivo móvil 104).

5 En algunos ejemplos, la configuración de un dispositivo móvil puede usarse para habilitar diferentes funciones descritas en el presente documento. Por ejemplo, en Apple iOS, Android OS o los sistemas operativos de operación de dispositivos portátiles que tienen ciertos ajustes habilitados pueden habilitar ciertas funciones de las realizaciones. En algunos ejemplos, tener servicios de ubicación habilitados permite la recopilación de información de ubicación desde el dispositivo móvil (por ejemplo, recopilada por el receptor de sistema de posicionamiento global (GPS) 112), y habilitar la actualización de la aplicación en segundo plano permite que algunas realizaciones se ejecuten en segundo plano, 10 recopilar y analizar datos de conducción incluso cuando la aplicación no se está ejecutando. En algunos casos, la información de ubicación puede determinarse mediante otros sensores del dispositivo móvil, tal como rastreando el movimiento del dispositivo móvil (por ejemplo, usando un acelerómetro), recibiendo información de ubicación desde una fuente externa, triangulación de radio (por ejemplo, usando radios celulares, Bluetooth o Wi-Fi), mediante una dirección IP del dispositivo móvil, o mediante otros medios. En algunas implementaciones, las alertas se proporcionan o emergen usando el bloque de notificación 160 mientras la aplicación se ejecuta en segundo plano, ya que el examen físico se puede realizar en segundo plano. 15

La figura 2 es un diagrama de bloques simplificado que ilustra un ejemplo de otro sistema 200 para recopilar datos de conducción de acuerdo con algunos aspectos de la presente invención. El sistema 200 puede incluir el dispositivo electrónico 204, que puede incorporarse dentro del dispositivo móvil 104 (por ejemplo, como hardware o software especializado) o puede ser un dispositivo separado (o ejecutarse en un dispositivo separado) que se comunica con el dispositivo móvil 104. Por ejemplo, como un dispositivo separado el dispositivo electrónico 204 puede ser un dispositivo móvil (por ejemplo, tal como el dispositivo móvil 104 de la figura 1, un tipo similar de dispositivo móvil, un tipo diferente de dispositivo móvil, o similar), un servidor, un dispositivo informático tal como un ordenador de sobremesa o portátil, un dispositivo de procesamiento especializado (por ejemplo, tal como uno o más circuitos integrados específicos de la aplicación, matrices de puertas programables en campo, o similares), un sistema de procesamiento distribuido (por ejemplo, un entorno de nube de este tipo o similar), una combinación de los mismos (por ejemplo, como un proceso distribuido), o similares. En algunas realizaciones, el dispositivo electrónico 204 puede proporcionar funcionalidad usando componentes que incluyen, pero sin limitación: un analizador vectorial 208, un determinador vectorial 212, un receptor de información externo 216, un clasificador 220 (por ejemplo, un modelo de aprendizaje automático), un motor de frecuencia de recopilación de datos 224, un motor de detección de conductor 228 y un motor de detección de actividad 232. Cada componente puede incluir uno o más procesadores (no mostrados) y memoria (no mostrada). Las instrucciones almacenadas en la memoria de un componente pueden ejecutarse por los uno o más procesadores del componente que proporcionan la funcionalidad del componente. Como alternativa, uno o más procesadores del dispositivo electrónico 204 (no mostrado) pueden ejecutar instrucciones almacenadas en una memoria central del dispositivo electrónico 204 para proporcionar la funcionalidad de los componentes. El dispositivo electrónico 204 también puede incluir un almacenamiento de datos 236. En algunos casos, uno o más de los componentes 208-232 que operan en el dispositivo electrónico 204 pueden almacenarse en la memoria 152 o el almacenamiento 156 del dispositivo móvil 104, y/o ejecutarse por el procesador 148 del dispositivo móvil 104. 20

Uno o más sensores del dispositivo móvil 104 (por ejemplo, sensores del bloque de datos de sensor 108) se usan para medir características de un entorno en el que se coloca el dispositivo móvil. Por ejemplo, los uno o más sensores se usan para recopilar características de un vehículo mientras el dispositivo móvil se coloca en el vehículo y durante una conducción. En ese caso, los uno o más sensores pueden operarse mientras el dispositivo móvil se coloca cerca de un conductor durante un intervalo de tiempo que corresponde a cuando el conductor está operando el vehículo. Como se usa en el presente documento, los términos "conducir" y "viajar" se refieren a la operación de un vehículo durante un intervalo de tiempo. Las mediciones obtenidas de los uno o más sensores pueden analizarse para determinar los vectores de aceleración para el vehículo, así como diferentes características del accionamiento. En algunos casos, los datos externos (por ejemplo, clima, tráfico, información del vehículo, información del conductor) se pueden recuperar y correlacionar con los datos de conducción recopilados. 25

En algunas realizaciones, una pantalla de un dispositivo móvil (tal como el dispositivo móvil 104) puede mostrar representaciones de datos de conducción recopilados por los uno o más sensores o generados por cualquiera de los componentes 208-232. Por ejemplo, pueden generarse representaciones de datos de conducción transformando datos de sensor recopilados (por ejemplo, datos de conducción recopilados usando el bloque de datos de sensor 108) en diferentes resultados, incluyendo, pero sin limitación, estimaciones de una actividad de un usuario del dispositivo móvil 104 (por ejemplo, parado, caminando, corriendo, conduciendo), estimaciones de la ocurrencia de diferentes eventos de conducción durante una conducción para la que se recopilaron datos, una métrica descriptiva del comportamiento de conducción de un conductor durante la conducción, una métrica descriptiva del comportamiento de conducción general de un conductor para todas las unidades, una métrica descriptiva del comportamiento de un conductor en relación con la ocurrencia de ciertos eventos, y/o una combinación de datos de conducción transformados y datos geográficos. 30

En algunos casos, los datos de conducción recopilados se pueden analizar para asignar puntuaciones a una unidad, múltiples unidades, un conductor y/o un comportamiento de conducción basado en diferentes criterios. Un motor de puntuación (no mostrado) puede agregar datos recopilados por los uno o más sensores y aplicar una o más reglas 35

para generar puntuaciones para las realizaciones. Se puede encontrar una divulgación adicional con respecto a la puntuación en la solicitud de patente de EE. UU. N.º 15/615.579, titulada "SYSTEMS AND METHODS FOR SCORING DRIVING TRIPS" (la "solicitud '579"), presentada el 6 de junio de 2017, incorporada en el presente documento por referencia en su totalidad.

5 Los datos de sensor (por ejemplo, recopilados usando el bloque de datos de sensor 108) pueden usarse para analizar el movimiento del dispositivo móvil para detectar la ocurrencia de eventos de conducción. Los datos de sensor pueden agregarse por el dispositivo electrónico 204 y analizarse una vez que se recibe una cantidad predeterminada de los datos de sensor. Por ejemplo, una vez que el dispositivo electrónico 204 agrega 50 megabytes de datos de sensor, el
10 dispositivo electrónico 204 puede iniciar un análisis de los datos del sensor. En otro ejemplo, el dispositivo electrónico 204 puede iniciar un análisis de los datos de sensor una vez que el dispositivo electrónico 204 recibe datos de sensor recopilados durante un intervalo predeterminado (por ejemplo, media hora de datos de sensor, una hora de datos de sensor, etc.). En otro ejemplo más, el dispositivo electrónico 204 agrega datos de sensor asociados con un accionamiento y analiza los datos de sensor una vez que se reciben todos los datos de sensor asociados con el viaje.
15 Como alternativa, el dispositivo móvil 104 incluye uno o más de los componentes 208-232 y proporciona análisis de datos de sensor en tiempo real (por ejemplo, a medida que los uno o más sensores obtienen mediciones).

Un receptor de GPS puede proporcionar datos de ubicación y velocidad con indicación de tiempo que pueden usarse por diversas aplicaciones que se ejecutan en el dispositivo móvil. Los datos con indicación de tiempo pueden usarse
20 para determinar con precisión la ubicación y velocidad del vehículo. Un receptor de GPS puede detectar una colisión y determinar la distancia recorrida por el vehículo. Por ejemplo, el receptor de GPS puede detectar una colisión detectando cambios repentinos en la velocidad o ubicación. Sin embargo, dado que los dispositivos móviles funcionan con recursos limitados debido a las restricciones de potencia y procesamiento y debido al alto consumo de potencia de operar un receptor GPS, el dispositivo electrónico 204 puede usar los uno o más otros sensores del dispositivo
25 móvil 104 para detectar la ubicación y/o la velocidad del vehículo.

Por ejemplo, un dispositivo móvil colocado en un vehículo experimenta vibraciones mecánicas relacionadas con la actividad del vehículo. Estas vibraciones son medibles usando un subconjunto de los sensores en el bloque de datos de sensor 108 del dispositivo móvil 104 denominado unidad de medición inercial (IMU). Las mediciones de la vibración
30 mecánica pueden ocurrir en amplitudes y frecuencias variables, que pueden usarse para identificar la actividad del vehículo o, en algunos casos, la actividad del usuario. Por ejemplo, parte o todo el acelerómetro, las mediciones de giroscopio y magnetómetro pueden distinguir los patrones de caminata del usuario de los patrones de conducción del vehículo (por ejemplo, velocidad del vehículo de aproximadamente 5 m/s).

35 La IMU puede incluir cualquiera del acelerómetro 116, el giroscopio 124 y el magnetómetro 120. La IMU y los sensores incluidos dentro pueden ser una unidad separada de un receptor de GPS. El acelerómetro 112 puede ser un acelerómetro de tres ejes operable para medir la aceleración longitudinal y lateral, así como la aceleración debida a la gravedad. El giroscopio 116 y el magnetómetro 114 también pueden ser dispositivos de tres ejes y pueden medir la rotación angular y el rumbo magnético, respectivamente, en tres dimensiones. La IMU puede combinar los datos de
40 acelerómetro tridimensionales con los datos giroscópicos tridimensionales para identificar el movimiento del dispositivo móvil con seis grados de libertad (6 GDL) (por ejemplo, traslación y rotación).

En algunos casos, los datos obtenidos de la IMU pueden filtrarse y usarse como entrada para entrenar un clasificador tal como el clasificador 220, para predecir la velocidad del vehículo. Un ejemplo de un clasificador de este tipo incluye,
45 sin limitación, un clasificador xgboost. El clasificador puede entrenarse usando características extraídas de datos de entrenamiento de un gran número de viajes de conducción. Las características de entrenamiento extraídas pueden incluir características estadísticas de los datos de conducción, por ejemplo, mediana, varianza y valores máximos de las señales de IMU (por ejemplo, acelerómetro, señales de giroscopio y magnetómetro). En algunos casos, la orientación del dispositivo móvil con respecto a la gravedad puede determinarse e introducirse en el clasificador para
50 su entrenamiento. Pueden usarse otras características estadísticas sin alejarse del alcance de la presente invención.

Durante una conducción con un dispositivo móvil colocado en un vehículo, la IMU del dispositivo móvil puede usarse para obtener mediciones de movimiento desde cualquiera del acelerómetro, el giroscopio y el magnetómetro, y las mediciones de movimiento para generar una entrada para que un clasificador prediga la velocidad del vehículo. En
55 algunos casos, las mediciones de aceleración usadas en la predicción de la velocidad del vehículo pueden ser mediciones de aceleración del usuario. Las mediciones de aceleración de usuario pueden ser mediciones de aceleración para las que se ha eliminado el componente de gravedad de la aceleración. En algunos casos, las mediciones de aceleración usadas en la predicción de la velocidad del vehículo pueden ser mediciones de aceleración sin procesar. Las mediciones de aceleración sin procesar pueden ser mediciones de aceleración que incluyen el
60 componente de gravedad.

Las señales de medición de movimiento de los sensores de IMU pueden muestrearse a una tasa de muestreo especificada para obtener señales digitales. En algunos casos, se puede usar una tasa de muestreo de 9 Hz para las señales de medición de movimiento. En otros casos, se puede usar una tasa de muestreo de 30 Hz para las señales
65 de medición de movimiento. Pueden usarse otras tasas de muestreo, por ejemplo, 50 Hz u otra tasa de muestreo. Las tasas de muestreo más altas pueden proporcionar una estimación de velocidad mejorada a costa de un mayor

consumo de recursos (por ejemplo, procesamiento y/o recursos de potencia). El dispositivo electrónico 204 y/o el dispositivo móvil 104 pueden modular el muestreo de sensor de IMU en tiempo real para optimizar el volumen de datos recopilados (por ejemplo, para la precisión del análisis de datos) y el consumo de recursos.

5 Por ejemplo, si el dispositivo móvil está conectado a una fuente de alimentación fiable (por ejemplo, como la fuente de alimentación del vehículo), las señales de medición de movimiento pueden muestrearse a una frecuencia más alta (por ejemplo, 50 Hz o una frecuencia más alta predeterminada). Si el dispositivo móvil no está conectado a una fuente de alimentación, las señales de medición de movimiento pueden muestrearse a una frecuencia más baja (por ejemplo, muestreo de 30 Hz o una frecuencia media predeterminada). Si la fuente de alimentación del dispositivo móvil está por debajo de un valor umbral (por ejemplo, 25 % de máximo), entonces el muestreo de las señales de medición de movimiento puede reducirse a una frecuencia más baja (por ejemplo, 9 Hz o una baja frecuencia predeterminada) para conservar la potencia restante del dispositivo móvil. En algunos casos, la tasa de muestreo de las señales de medición de movimiento puede modificarse para mejorar la estimación de velocidad. Por ejemplo, se puede usar una métrica de precisión para indicar una probabilidad de que una estimación de velocidad dada sea válida. Si la métrica de precisión no supera un umbral, la tasa de muestreo de las señales de medición de movimiento puede aumentarse temporal o permanentemente hasta que la métrica de precisión supere el umbral. El dispositivo móvil puede modular la tasa de muestreo en tiempo real basándose en las condiciones operativas (por ejemplo, consumo de recursos) del dispositivo móvil o la métrica.

20 Las señales de IMU filtradas pueden distinguir patrones de conducción, detención y marcha del usuario. Un filtro de paso de banda (por ejemplo, implementado en hardware o software), por ejemplo, un filtro de respuesta de impulso infinito (IIR), puede usarse para filtrar las señales de IMU para aislar frecuencias indicativas de diversas actividades del vehículo y para eliminar valores de magnitud de señal que superan un umbral especificado. Las porciones de las señales que tienen valores de magnitud que superan el umbral especificado pueden excluirse del filtrado de paso de banda adicional. Los filtros de paso de banda digitales pueden diseñarse para aislar la cantidad de vibración (es decir, frecuencias) que ocurren dentro de intervalos de frecuencia específicos de interés. Por ejemplo, la cantidad de vibraciones puede separarse en intervalos de frecuencia de 0,2 Hz a 1,1 Hz, de 1,1 Hz a 2,0 Hz, etc., dependiendo de la frecuencia de muestreo, filtrando paso banda las señales.

30 Los cambios en las bandas de frecuencia más bajas, por ejemplo, hasta aproximadamente 1 Hz, pueden contener información sobre la detención del vehículo, mientras que los cambios en las bandas de frecuencia más altas pueden corresponder a la conducción del vehículo a velocidades más altas. Las fuentes de las vibraciones detectadas por los sensores de la IMU son interacciones complejas entre las vibraciones del motor resultantes de los cambios de velocidad, vibraciones debidas a la interacción del vehículo con la superficie de la carretera a diferentes velocidades).
 35 Un modelo de aprendizaje automático (por ejemplo, el clasificador) puede aprender estas interacciones más complejas, que pueden ser una combinación de frecuencias altas y bajas, correspondientes al comportamiento de cada vehículo.

40 En algunos casos, las señales de sensor de IMU que tienen grandes magnitudes pueden ser perjudiciales para la predicción de velocidad del vehículo. En esos casos, el filtrado puede excluir las señales de gran magnitud. Por ejemplo, los valores de magnitud de señal de acelerómetro que superan un valor umbral de aproximadamente 10 m/s^2 u otro valor umbral, así como cualquier porción posterior de la señal, pueden excluirse. Las porciones de las señales de IMU hasta, pero sin incluir, los valores de magnitud de señal que superan el valor umbral pueden filtrarse en paso banda usando el filtro IIR.

45 El proceso de filtrado de IIR puede emplear un filtrado directo-inverso en el que las porciones de las señales de IMU se filtran normalmente (es decir, filtrado directo), y las señales filtradas directas se "invierten" en el tiempo y se filtran de nuevo con el filtro IIR (es decir, filtrado inverso) que produce una respuesta de amplitud al cuadrado. Los filtros IIR pueden aislar mejor las señales de interés y minimizar o eliminar la distorsión de fase no lineal de las señales. Los filtros IIR se aplican de forma recursiva, de modo que el resultado de la última etapa del algoritmo de filtro se aplica a la siguiente etapa. Los métodos de filtrado IIR pueden ser más eficientes computacionalmente que los métodos de filtrado que requieren el cálculo de todas las cantidades numéricas intermedias que conducen al resultado (por ejemplo, transformadas de Fourier). Los filtros IIR también son ventajosos porque pueden aislar intervalos de frecuencia de interés con mayor atenuación de amplitud de señal fuera de un intervalo de interés. En algunas implementaciones, un filtro de respuesta de impulso finito (FIR), en lugar de un filtro IIR, puede usarse para el filtrado de paso de banda de las señales de IMU.

60 El número de bandas de frecuencia usadas para el filtrado de paso de banda puede determinarse por la granularidad deseada y la frecuencia de muestreo de los datos de sensor. Por ejemplo, 14 bandas de paso pueden usarse en bandas de frecuencia de 0,3 Hz igualmente espaciadas desde 0,2 Hz a una frecuencia de muestreo de Nyquist de 4,5 Hz para datos obtenidos usando un muestreo de 9 Hz, y 28 bandas de paso pueden usarse desde 0,2 Hz a 15 Hz para datos obtenidos usando datos de 30 Hz. Pueden usarse bandas de frecuencia más granulares cuando las señales de IMU se muestrean a frecuencias de muestreo más altas. La selección del número y anchura de las bandas de frecuencia puede determinarse basándose en la calidad de señal deseada en cada banda y la granularidad de la información. Por ejemplo, demasiadas bandas de frecuencia pueden dar como resultado una calidad de señal degradada debido al ancho de banda estrecho, mientras que muy pocas bandas de frecuencia pueden dar como

resultado la pérdida de granularidad de la información capturada.

Las características, por ejemplo, características estadísticas, pueden extraerse de algunas o todas las señales filtradas. Las características utilizadas como entradas al clasificador 220 pueden ser estadísticas de resumen (por ejemplo, mediana, varianza y máximo) sobre las diversas señales, cubriendo diferentes lapsos de tiempo. Las características pueden extraerse de ventanas de tiempo de diferentes longitudes. En algunas implementaciones, cada una de las características estadísticas puede extraerse de las señales de IMU durante una ventana de tiempo de 5 segundos, una ventana de tiempo de 10 segundos y una ventana de tiempo de 20 segundos. Cada ventana puede estar centrada en el punto de tiempo bajo consideración. Sobre cada una de las ventanas, se pueden calcular estadísticas de resumen tales como la media, mediana, varianza, máximo y mínimo de las diversas versiones con paso de banda de las señales del sensor IMU (por ejemplo, acelerómetro, giroscopio) contenidas en estas ventanas.

Las diferentes ventanas de longitud pueden proporcionar niveles de estabilidad para los valores de característica, con tiempos de ventana más largos que producen valores de característica más estables. Se pueden usar otras longitudes de ventana o un número diferente de ventanas sin alejarse del alcance de la invención. Por ejemplo, en algunas implementaciones, se puede usar una sola ventana. Para una señal de acelerómetro filtrada de paso de banda entre 0,2 Hz y 1,1 Hz, se pueden extraer nueve características, por ejemplo, mediana, varianza y máximo, con cada característica extraída durante una ventana de tiempo de 5 segundos, una ventana de tiempo de 10 segundos y una ventana de tiempo de 20 segundos. La extracción de características produce una única lista de valores (por ejemplo, un vector de características) para cada punto de tiempo bajo consideración.

Las características extraídas (por ejemplo, los vectores de características) pueden introducirse en el clasificador. El modelo de aprendizaje automático (por ejemplo, el clasificador) puede hacer una predicción de velocidad basándose en las entradas de vector de características. La predicción de la velocidad del vehículo por el clasificador puede cuantificarse, por ejemplo, en incrementos de 5 m/s u otro incremento. En algunas implementaciones, la orientación del dispositivo móvil con respecto a la gravedad puede determinarse e introducirse en el clasificador.

El motor de detección de actividad 232 identifica una actividad que corresponde a mediciones de sensor recibidas desde los uno o más sensores del bloque de datos de sensor 108. Por ejemplo, el motor de detección de actividad 232 identifica: cuando el dispositivo móvil 104 está estacionario, con un usuario que está caminando, con un usuario que está corriendo, con un usuario que está montando en bicicleta, en un vehículo que está conduciendo, en un vehículo que está volando, y similares. En algunos casos, el motor de detección de actividad 232 emite una probabilidad de la actividad. En esos casos, el motor de detección de actividad 232 puede emitir más de una probabilidad, tal como una probabilidad del 45 % de que el dispositivo móvil esté caminando, un 33 % de probabilidad de que el dispositivo móvil esté conduciendo y un 22 % de probabilidad de alguna otra actividad. La probabilidad puede expresarse como un número entero o real, un porcentaje, un grado (tal como bajo, medio o alto), o de cualquier manera que represente la probabilidad de una actividad dada.

El motor de detección de actividad 232 puede usar la actividad para detectar accionamientos a partir de datos de sensor. Por ejemplo, el motor de detección de actividad 232 puede analizar los datos recibidos desde el dispositivo móvil 104 e identificar una primera vez cuando la actividad indica una alta probabilidad de que el dispositivo móvil 104 está en un coche que está conduciendo. El motor de detección de actividad 232 puede identificar una segunda vez después del primer tiempo en la que hay una alta probabilidad de otra actividad (por ejemplo, parado, caminando). El motor de detección de actividad 232 define a continuación una conducción producida desde el primer tiempo hasta el segundo tiempo. Otros componentes del dispositivo electrónico 204 pueden analizar adicionalmente los datos de sensor recibidos entre el primer tiempo y el segundo tiempo para identificar el comportamiento del conductor, una puntuación de conductor, detección de colisiones, estimación de velocidad, etc. En algunos casos, el motor de detección de actividad 232 o cualquiera de las operaciones descritas en conexión con el motor de detección de actividad 232 puede realizarse por un sistema operativo del dispositivo móvil para gestionar la recopilación de datos por el bloque de datos de sensor 108.

En algunos casos, el motor de detección de actividad 232 puede operar en el dispositivo móvil 104 para controlar la recopilación de mediciones del bloque de datos de sensor 108. El dispositivo móvil 104 puede ejecutar una aplicación de recopilación de datos que controla la operación de los uno o más sensores del dispositivo móvil 104 (por ejemplo, tales como tasas de muestreo y similares) y recopila mediciones de los uno o más sensores. La aplicación de recopilación de datos puede incluir uno o más de los componentes 208-232. Dado que el dispositivo móvil opera con recursos limitados, la aplicación de recopilación de datos puede ser suspendida o terminada por el usuario del dispositivo móvil, debido a la inactividad de la aplicación de recopilación de datos, cuando el dispositivo móvil está en reposo, o similar. El motor de detección de actividad 232 puede operar en un proceso en segundo plano para detectar si se está produciendo un accionamiento. Si se está produciendo un accionamiento, el motor de detección de actividad 232 puede hacer que se inicie la aplicación de recopilación de datos y comience la recopilación de datos de sensor asociados con el accionamiento.

En algunos casos, el motor de detección de actividad 232 puede generar una geovalla alrededor del dispositivo móvil 104, que, cuando se cruza, hará que el motor de detección de actividad 232 ejecute la aplicación de recopilación de datos o devuelva la aplicación de recopilación de datos a un estado activo desde un estado suspendido. Si el

dispositivo móvil 104 cruza la geovalla, entonces el motor de detección de actividad 232 puede hacer que se inicie la aplicación de recopilación de datos. Por ejemplo, la geovalla puede rodear el vehículo o la residencia de un usuario de tal manera que cuando se cruza la geovalla es probable que el usuario inicie una conducción. La geovalla puede generarse después de un periodo de inactividad tal como cuando el dispositivo móvil ha estado en reposo durante un intervalo de tiempo predeterminado. La geovalla puede generarse a una distancia predeterminada del móvil de manera que cuando el móvil cruza la geovalla es probable que se deba al comienzo de un recorrido en lugar de a través de otra actividad tal como caminar. El motor de detección de actividad 232 puede usar otros mecanismos para determinar si activar la aplicación de recopilación de datos que incluye, pero sin limitación, detectar una visita (por ejemplo, que el dispositivo móvil está en una ubicación particular), una notificación, un intervalo de tiempo, una o más mediciones de sensor que superan el umbral, o similares.

Dado que la aplicación de recopilación de datos del dispositivo móvil 104 no puede recopilar mediciones de sensor hasta que se ejecuta (o se devuelve a un estado de ejecución activa), algunas mediciones del sensor pueden perderse. Por ejemplo, la aplicación de recopilación de datos puede perder esas mediciones de sensor asociadas con la porción del recorrido que se produjo antes de cruzar la geovalla. Como resultado, la aplicación de recopilación de datos puede no recopilar mediciones de sensor para todo el accionamiento, perdiendo así información valiosa sobre la conducción, el comportamiento del conductor, posibles colisiones de vehículos, etc. En algunos casos, el dispositivo móvil 104 puede no detectar que se ha cruzado una geovalla en absoluto, y, por lo tanto, nunca activar la aplicación de recopilación de datos durante el viaje. En esos casos, el dispositivo móvil 104 puede perder la unidad de modo que la aplicación de recopilación de datos no recopila ninguna medición de sensor asociada con la unidad perdida. La aplicación de recopilación de datos puede obtener algunas mediciones de sensor recopiladas a lo largo de la unidad perdida de otros procesos que se ejecutan en el dispositivo móvil 104.

Por ejemplo, un sistema operativo del dispositivo móvil 104 puede recopilar y almacenar en caché algunas mediciones de sensor a lo largo de una ventana deslizante tal como un intervalo de tiempo inmediatamente anterior de una duración predeterminada. La ventana deslizante puede incluir lo anterior, veinticuatro horas, cuarenta y ocho horas, setenta y dos horas, noventa y seis horas, o cualquier intervalo de tiempo predeterminado. Las aplicaciones del dispositivo móvil 104 pueden solicitar y obtener mediciones de sensor para hasta la longitud de la ventana deslizante del sistema operativo.

El sistema operativo puede comenzar a recopilar y almacenar en caché mediciones de sensor a petición de una aplicación tal como la aplicación de recopilación de datos y retener las mediciones de sensor almacenadas en caché hasta la longitud de la ventana deslizante. En ese punto, el sistema operativo descarta la medición de sensor más antigua cada vez que se añade una nueva medición de sensor. Por ejemplo, el sistema operativo puede almacenar en caché hasta las 72 horas anteriores de mediciones de sensor (por ejemplo, 72 horas desde una hora actual tal como ahora), tiempo en el que, las mediciones de sensor más antiguas (por ejemplo, cualquier cosa anterior a 72 horas) pueden descartarse, de modo que la memoria caché retenga las mediciones de sensor recopiladas durante las 72 horas inmediatamente anteriores. En algunos casos, el sistema operativo solo puede permitir que una aplicación solicite la recopilación y el almacenamiento en caché de las mediciones del sensor para un intervalo de tiempo particular (por ejemplo, que puede ser menor o igual que la longitud de la ventana deslizante). La aplicación de recopilación de datos puede no ser capaz de solicitar al sistema operativo que almacene en caché mediciones de sensor a lo largo de toda la ventana deslizante si el intervalo de tiempo particular es menor que la ventana deslizante. En cambio, la aplicación de recopilación de datos puede generar una serie de solicitudes con cada solicitud posterior que se envía tras la terminación del intervalo particular de la solicitud anterior. Esto posibilita que la aplicación de recopilación de datos solicite almacenamiento en caché de mediciones de sensor por el sistema operativo para toda la ventana deslizante.

En el siguiente ejemplo, la ventana deslizante puede tener una duración de 72 horas y el intervalo de tiempo predeterminado puede ser de 12 horas. Cuando la aplicación de recopilación de datos se ejecuta (o vuelve de la suspensión), la aplicación de recopilación de datos puede generar una primera solicitud de que el sistema operativo recopile y almacene en caché mediciones de sensor para las siguientes 12 horas. En respuesta, el sistema operativo comenzará a recopilar y almacenar en caché las mediciones del sensor. La aplicación de recopilación de datos puede realizar a continuación cualquier operación predicha que fuera la razón de su ejecución (o retorno de suspensión) o terminación (o retorno a un estado suspendido). Al final del intervalo de tiempo de 12 horas, la aplicación de recopilación de datos puede ejecutar (o volver de la suspensión) y generar una segunda solicitud al sistema operativo para la recopilación y almacenamiento en caché de datos de sensor durante otras 12 horas. En algunos casos, la aplicación de recopilación de datos puede ejecutarse antes de la terminación del intervalo de tiempo de 12 horas. En ese caso, la aplicación puede generar la segunda solicitud al sistema operativo para la recopilación y almacenamiento en caché de datos de sensor para un intervalo de tiempo de 12 horas que comienza en el tiempo de la segunda solicitud (en lugar de en la terminación del intervalo de tiempo de 12 horas anterior). La aplicación de recopilación de datos también puede acceder a las mediciones de sensor de las 12 horas anteriores (desde la primera solicitud). Este proceso puede repetirse cada 12 horas de manera que el sistema operativo almacena en caché hasta 72 horas de mediciones de sensor.

La aplicación de recopilación de datos puede acceder a las mediciones de sensor almacenadas en caché durante las 72 horas completas (por ejemplo, basándose en cada solicitud de 12 horas combinada) aunque la aplicación de

recopilación de datos puede estar limitada a enviar solicitudes de recopilación de datos y almacenamiento en caché durante intervalos de tiempo más pequeños (por ejemplo, en este caso 12 horas). Si la aplicación de recopilación de datos envía una primera solicitud (en la marca de hora cero) para 12 horas de mediciones de sensor, cuando la aplicación de recopilación de datos se ejecuta (o vuelve de la suspensión) 12 horas más tarde, el sistema operativo
 5 habrá recopilado y almacenado en caché 12 horas de mediciones de sensor a las que puede acceder la aplicación de recopilación de datos. Cuando la aplicación de recopilación de datos envía una segunda solicitud al sistema operativo (en la marca de 12 horas) para otras 12 horas de almacenamiento en caché de medición de sensor, el sistema operativo continúa recopilando y almacenando en caché las mediciones del sensor durante las siguientes 12 horas. Cuando la aplicación de recopilación de datos se ejecuta 12 horas más tarde (por ejemplo, ahora en la marca de
 10 24 horas), la aplicación de recopilación de datos puede acceder ahora a 24 horas de datos de sensor incluso aunque la aplicación de recopilación de datos solo puede solicitar que el sistema operativo recopile y almacene en caché mediciones de sensor para las siguientes 12 horas.

La aplicación de recopilación de datos puede continuar realizando solicitudes de recopilación y almacenamiento en memoria caché de mediciones de sensor incluso cuando la memoria caché incluye mediciones de sensor durante el intervalo de tiempo de 72 horas (por ejemplo, la ventana corredera completa). Dado que la memoria caché solo puede almacenar mediciones de sensor a través de la ventana deslizante (por ejemplo, las 72 horas anteriores), las mediciones de sensor más antiguas (por ejemplo, mediciones de sensor de más de 72 horas) pueden descartarse a medida que se almacenan nuevas mediciones de sensor en la memoria caché. Las mediciones del sensor pueden
 15 descartarse continuamente a medida que las nuevas mediciones del sensor se almacenan en caché continuamente durante el siguiente intervalo de tiempo solicitado (por ejemplo, 12 horas). Con solicitudes consecutivas por la aplicación de recopilación de datos, la aplicación de recopilación de datos puede hacer que el sistema operativo almacene en caché perpetuamente las 72 horas anteriores de mediciones de sensor.

Las aplicaciones del dispositivo móvil 104 que incluyen los componentes 208-232 pueden solicitar la recopilación de datos por el sistema operativo mientras las aplicaciones del dispositivo móvil (tal como la aplicación de recopilación de datos) están suspendidas o no se están ejecutando. El sistema operativo puede recopilar mediciones de sensor a lo largo de un intervalo de tiempo predeterminado. Por ejemplo, una aplicación puede solicitar mediciones de sensor del sistema operativo hasta 12 horas después de que la aplicación se suspenda o finalice. Cuando la aplicación se
 25 ejecuta de nuevo, la aplicación puede solicitar acceso a las mediciones de sensor recopiladas por el sistema operativo mientras la aplicación estaba suspendida o terminada.

Como se ha descrito anteriormente, el motor de detección de actividad 232 puede obtener las mediciones de sensor que fueron recopiladas por el sistema operativo (u otra aplicación) del dispositivo móvil y generar una probabilidad de una actividad asociada con el dispositivo móvil. Como alternativa, esto puede ser realizado por el propio sistema operativo. Por ejemplo, el sistema operativo puede emitir una probabilidad de que el dispositivo móvil 104 esté estacionario, caminando, corriendo, conduciendo, volando, o similares. El motor de detección de actividad 232 puede usar los datos de actividad del sistema operativo para determinar un intervalo de tiempo durante el cual era probable que se hubiera producido un accionamiento mientras la aplicación de recopilación de datos estaba suspendida o
 35 terminada (por ejemplo, no se está ejecutando). El motor de detección de actividad 232 puede solicitar a continuación los datos de sensor recopilados por el sistema operativo durante el intervalo de tiempo. Los datos de sensor recopilados por el sistema operativo pueden añadirse a cualquier dato de sensor recopilado por la aplicación de recopilación de datos.

Por ejemplo, el motor de detección de actividad 232 puede detectar que el dispositivo móvil 104 cruzó una geovalla e iniciar la ejecución de una aplicación de recopilación de datos para comenzar la recopilación de mediciones de sensor tales como sensores de IMU. La aplicación de recopilación de datos a continuación solicita datos de sensor del sistema operativo durante un intervalo de tiempo antes de cuando el dispositivo móvil cruzó la geovalla. Esto posibilita que el dispositivo móvil 104 capture mediciones de sensor a lo largo de toda la duración del accionamiento a pesar de que la aplicación ejecuta y comienza la recopilación de mediciones de sensor unos pocos minutos en el accionamiento.
 45 50

En otro ejemplo, cuando se ejecuta la aplicación de recopilación de datos, la aplicación de recopilación de datos solicita datos de sensor del sistema operativo del dispositivo móvil 104 durante un intervalo de tiempo antes de la ejecución de la aplicación de recopilación de datos. La aplicación de recopilación de datos identifica a partir de los datos de actividad un primer intervalo de tiempo durante el cual el sistema operativo determina con una alta probabilidad que se ha producido un accionamiento. La aplicación de recopilación de datos solicita a continuación los datos de sensor recopilados por la operación del dispositivo móvil 104 durante el primer intervalo de tiempo. En algunos casos, puede haber un retraso entre el tiempo en que comienza la unidad y el sistema operativo detecta que se está produciendo una actividad de unidad. De manera similar, puede haber un retraso entre el tiempo en que finaliza la unidad y el sistema operativo detecta que la unidad finalizó. Para garantizar que se recopilen los datos del sensor para todo el viaje, la aplicación de recopilación de datos puede solicitar los datos del sensor durante un segundo intervalo de tiempo (más grande) que comienza antes del primer intervalo de tiempo (por ejemplo, un minuto, cinco minutos, diez minutos, o similar antes de que comience el primer intervalo de tiempo) y finaliza después del primer intervalo de tiempo (por ejemplo, un minuto, cinco minutos, diez minutos, o similar después de que finalice el primer intervalo de tiempo).
 55 60 65

La figura 3 es un gráfico 300 que ilustra un ejemplo de predicción de velocidad de vehículo por un clasificador que usa

características extraídas de señales de IMU muestreadas a 9 Hz de acuerdo con aspectos de la presente divulgación. La figura 3 muestra los datos del acelerómetro 310 usando la aceleración del usuario (es decir, con el componente de gravedad de la aceleración eliminado) y los datos de velocidad del vehículo GPS 320 para un viaje, así como la velocidad predicha del vehículo 330 generada por el clasificador. Las señales de la IMU, en particular, señales de acelerómetro y giroscopio (no mostradas), se muestrearon a una tasa de muestreo de 9 Hz, y se filtraron de paso de banda directo-inverso con un filtro IIR usando 14 bandas de frecuencia igualmente espaciadas de 0,2 Hz a 4,5 Hz. La característica estadística (por ejemplo, mediana, varianza y valores máximos) se extrajeron de las señales filtradas en tres tamaños de ventana (20 segundos 340, 10 segundos 350, 5 segundos 360) y se introdujeron en el clasificador. Como se puede observar en la figura 3, la velocidad de vehículo predicha 330 generada por el clasificador se aproxima a los datos de velocidad de vehículo de GPS 320.

Las figuras 4 y 5 son gráficos 400, 500 que ilustran ejemplos de predicción de velocidad de vehículo por un clasificador que usa características extraídas de señales de IMU muestreadas a 30 Hz de acuerdo con aspectos de la presente divulgación. La figura 4 muestra los datos del acelerómetro 410 usando la aceleración del usuario (es decir, con el componente de gravedad de la aceleración eliminado), datos de giroscopio 420 y datos de velocidad de vehículo de GPS 430 para un viaje, así como la velocidad predicha del vehículo 440 generada por el clasificador. La figura 5 muestra de manera similar los datos del acelerómetro 510 usando la aceleración del usuario (es decir, con el componente de gravedad de la aceleración eliminado), datos de giroscopio 520 y datos de velocidad de vehículo de GPS 530 para un viaje, así como la velocidad predicha del vehículo 540 generada por el clasificador.

Las señales de IMU, en particular, señales de acelerómetro y giroscopio, se muestrearon a una tasa de muestreo de 30 Hz, y se filtraron de paso de banda directo-inverso con un filtro IIR usando 28 bandas de frecuencia igualmente espaciadas de 0,2 Hz a 14,8 Hz. Las características estadísticas (por ejemplo, mediana, varianza y valores máximos) se extrajeron de las señales filtradas en tres tamaños de ventana (20 segundos 440, 10 segundos 450, 5 segundos 460) y se introducen en el clasificador. Las figuras 4 y 5 ilustran que puede obtenerse una predicción más cercana de la velocidad del vehículo cuando los datos de IMU se muestrean a una tasa de muestreo más alta. Es más, como se puede ver en la figura 4, la señal de acelerómetro 410 tiene un valor de magnitud que supera un valor umbral de aproximadamente 10 m/s². En consecuencia, el filtrado de las señales de sensor de IMU se puede realizar en las porciones de la señal de IMU hasta, por ejemplo, dentro de dos a cinco segundos u otro intervalo de tiempo, del valor de magnitud de señal que excede el valor umbral, pero sin incluir el valor de magnitud de señal que excede el valor umbral o valores posteriores de las señales.

De manera similar, la figura 5 ilustra la señal de acelerómetro 510 que tiene un valor de magnitud 550 que supera un valor umbral de aproximadamente 10 m/s². De este modo, en las figuras 4 y 5, solo las porciones de las señales de IMU hasta, pero sin incluir, los valores de magnitud de señal que superan el valor umbral, pueden filtrarse usando el filtro IIR.

La figura 6 es un diagrama de flujo que ilustra un ejemplo de un método 600 para estimar la velocidad del vehículo de acuerdo con aspectos de la presente divulgación. En el bloque 610, se determina que el dispositivo móvil está en un vehículo. Por ejemplo, se puede analizar una señal de acelerómetro para determinar un último patrón de señal consistente con un usuario caminando antes de un primer patrón de señal de acelerómetro consistente con el movimiento del vehículo. Se puede encontrar una divulgación adicional con respecto a la determinación de que un usuario ha entrado en el vehículo con el dispositivo móvil en el documento '093 incorporado.

En el bloque 620, los sensores del dispositivo móvil pueden operarse para obtener mediciones de movimiento. Por ejemplo, el dispositivo móvil puede incluir una IMU que tiene, entre otras cosas, un acelerómetro, un giroscopio y un magnetómetro. Los uno o más de los sensores de IMU (por ejemplo, el acelerómetro, el giroscopio y el magnetómetro) pueden operarse durante una conducción para obtener mediciones de movimiento mientras el receptor GPS está inactivo.

En el bloque 630, pueden recibirse señales de medición de movimiento. El procesador del dispositivo móvil puede recibir las señales correspondientes a la medición de movimiento desde uno o más del acelerómetro, el giroscopio y el magnetómetro de la IMU.

En el bloque 640, puede determinarse si el valor de una o más de las señales recibidas supera un valor umbral. En respuesta a la determinación de que una o más de las señales recibidas supera un valor umbral (640-Y), en el bloque 650, puede determinarse excluir esa porción de señales recibidas del filtrado posterior. El procesador del dispositivo móvil puede determinar excluir una porción de las señales recibidas dentro de un periodo de tiempo especificado alrededor de la porción de las señales recibidas que exceden el valor umbral del filtrado posterior. El procesador puede hacer que se filtre una porción de las señales recibidas hasta el tiempo especificado, de tal manera que la porción de las una o más de las señales recibidas que excede el valor umbral se excluye del filtrado posterior. Por ejemplo, el procesador puede determinar excluir porciones de las señales recibidas durante 0,5 segundos u otro periodo de tiempo antes y después del tiempo en que las una o más de las señales recibidas excede el valor umbral. El periodo de tiempo puede determinarse al menos en parte en la frecuencia de muestreo, aplicándose un periodo de tiempo más corto para una frecuencia de muestreo más alta.

5 En algunas implementaciones, únicamente puede filtrarse posteriormente la porción de las una o más señales que preceden al periodo de tiempo. En algunas implementaciones, tanto la porción de las una o más señales que preceden al periodo de tiempo como la porción de las una o más señales que siguen al periodo de tiempo pueden filtrarse posteriormente, excluyendo efectivamente la porción de las señales recibidas que exceden el valor umbral. El proceso puede continuar en el bloque 660.

En respuesta a la determinación de que una o más de las señales recibidas no superan un valor umbral (640-N) en el bloque 660, las señales pueden filtrarse.

10 En el bloque 660, las señales pueden filtrarse por paso de banda con un filtro IIR usando un proceso de filtrado directo-inverso. El filtrado de IIR directo-inverso filtra las señales de IMU normalmente (es decir, filtrado directo), y las señales filtradas directas se "invierten" entonces en el tiempo y se filtran de nuevo con el filtro IIR (es decir, filtrado inverso) que produce una respuesta de amplitud al cuadrado. Los filtros IIR pueden aislar mejor las señales de interés y minimizar o eliminar la distorsión de fase no lineal de las señales. Los filtros IIR se aplican de forma recursiva, lo que
15 significa que el resultado de la última etapa del algoritmo de filtro se aplica a la siguiente etapa. Los filtros IIR también son ventajosos porque pueden aislar intervalos de frecuencia de interés con mayor atenuación de amplitud de señal fuera de un intervalo de interés. Los filtros de paso de banda digitales pueden diseñarse para aislar la cantidad de vibración que se produce dentro de intervalos de frecuencia específicos de interés. En algunas implementaciones, un filtro de respuesta de impulso finito (FIR), en lugar de un filtro IIR, puede usarse para el filtrado de paso de banda de
20 las señales de IMU.

En el bloque 670, las características pueden extraerse de las señales filtradas. Las características, por ejemplo, características estadísticas, pueden extraerse de algunas o todas las señales filtradas. Las características pueden extraerse de ventanas de tiempo de diferentes longitudes. En algunas implementaciones, cada una de las
25 características estadísticas puede extraerse de las señales de IMU durante una ventana de tiempo de 5 segundos, una ventana de tiempo de 10 segundos y una ventana de tiempo de 20 segundos. Las diferentes ventanas de longitud pueden proporcionar niveles de estabilidad para los valores de característica, con tiempos de ventana más largos que producen valores de característica más estables. Se pueden usar otras longitudes de ventana o un número diferente de ventanas sin alejarse del alcance de la invención. Para una señal de acelerómetro filtrada de paso de banda entre
30 0,2 Hz y 1,1 Hz, se pueden extraer nueve características, por ejemplo, mediana, varianza y máximo, con cada característica extraída durante una ventana de tiempo de 5 segundos, una ventana de tiempo de 10 segundos y una ventana de tiempo de 20 segundos.

En el bloque 680, se puede ejecutar un clasificador para predecir la velocidad del vehículo. Las características
35 extraídas de las señales de IMU filtradas pueden introducirse en el clasificador, por ejemplo, un clasificador xgboost. Las características extraídas pueden ser, por ejemplo, mediana, varianza y valores máximos. Usando las características extraídas de las señales de IMU filtradas, el clasificador puede predecir la velocidad del vehículo. La predicción de la velocidad del vehículo por el clasificador puede cuantificarse, por ejemplo, en incrementos de 5 m/s u otro incremento. En algunas implementaciones, la orientación del dispositivo móvil con respecto a la gravedad también
40 puede determinarse e introducirse en el clasificador. Se puede encontrar una divulgación adicional con respecto a la determinación de la orientación del dispositivo móvil con respecto a la gravedad en las patentes '099, '157 y '446 incorporadas enumeradas anteriormente.

En algunas implementaciones, el método de la figura 6 puede usarse solo con la señal del acelerómetro. Por ejemplo,
45 mientras que el procesador puede recibir señales de los diversos sensores de IMU (por ejemplo, el acelerómetro, el giroscopio y el magnetómetro), solo las señales del acelerómetro pueden procesarse adicionalmente para predecir la velocidad del vehículo. Las señales de medición de movimiento del acelerómetro pueden muestrearse a una tasa de muestreo especificada para obtener señales digitales. Un filtro de paso de banda digital, por ejemplo, un filtro de
50 respuesta de impulso infinito (IIR), puede usarse para filtrar las señales del acelerómetro para aislar frecuencias indicativas de diversas actividades del vehículo y para eliminar valores de magnitud de señal que superan un umbral especificado. Las porciones de las señales de acelerómetro que tienen valores de magnitud que superan el umbral especificado pueden excluirse del filtrado de paso de banda adicional. Los filtros de paso de banda digitales pueden diseñarse para aislar la cantidad de vibración (es decir, frecuencias) que ocurren dentro de intervalos de frecuencia
55 específicos de interés.

El proceso de filtrado de IIR puede emplear filtrado directo-inverso en el que las porciones de las señales de
60 acelerómetro se filtran normalmente (es decir, filtrado directo), y las señales filtradas directas se "invierten" en el tiempo y se filtran de nuevo con el filtro IIR (es decir, filtrado inverso) que produce una respuesta de amplitud al cuadrado. Las características, por ejemplo, características estadísticas, pueden extraerse de las señales de acelerómetro filtradas y proporcionarse como entrada al clasificador para predecir la velocidad del vehículo.

En algunas implementaciones, las mediciones de aceleración usadas en la predicción de la velocidad del vehículo
65 pueden ser mediciones de aceleración del usuario. Las mediciones de aceleración de usuario se definen como mediciones de aceleración para las que se ha eliminado el componente de gravedad de la aceleración. En algunas implementaciones, las mediciones de aceleración usadas en la predicción de la velocidad del vehículo pueden ser mediciones de aceleración sin procesar. Las mediciones de aceleración sin procesar se definen como mediciones de

aceleración que incluyen el componente de gravedad.

5 Las figuras 7 y 8 son gráficos 700, 800 que ilustran ejemplos de predicción de velocidad de vehículo por un clasificador que usa características extraídas de señales de acelerómetro muestreadas a 30 Hz de acuerdo con aspectos de la presente divulgación. La figura 7 muestra los datos del acelerómetro 710 usando la aceleración del usuario (es decir, con el componente de gravedad de la aceleración eliminado), y los datos de velocidad del vehículo GPS 730 para un viaje, así como la velocidad predicha del vehículo 740 generada por el clasificador. De manera similar, la figura 8 muestra los datos del acelerómetro 810 usando la aceleración del usuario (es decir, con el componente de gravedad de la aceleración eliminado), y los datos de velocidad del vehículo GPS 830 para un viaje, así como la velocidad predicha del vehículo 840 generada por el clasificador.

15 Las señales del acelerómetro se muestrearon a una tasa de muestreo de 30 Hz y se filtraron paso banda directo-inverso con un filtro IIR. Las características estadísticas (por ejemplo, mediana, varianza y valores máximos) se extrajeron de las señales filtradas y se introdujeron en el clasificador. Como puede ser la figura 7, la señal de acelerómetro 710 tiene un valor de magnitud 750 que supera un valor umbral de aproximadamente 10 m/s². En consecuencia, el filtrado de la señal del acelerómetro se puede realizar en la porción de la señal del acelerómetro hasta, por ejemplo, dentro de una fracción de segundo del valor de magnitud de señal que excede el valor umbral, pero sin incluir el valor de magnitud de señal que excede el valor umbral o valores posteriores de las señales. De manera similar, la figura 8 ilustra la señal de acelerómetro 810 que tiene un valor de magnitud 850 que supera un valor umbral de aproximadamente 10 m/s². De este modo, en las figuras 7 y 8, solo las porciones de las señales del acelerómetro hasta, pero sin incluir, los valores de magnitud de señal que superan el valor umbral, pueden filtrarse usando el filtro IIR.

25 Debería apreciarse que las operaciones específicas ilustradas en la figura 6 proporcionan un método particular para estimar la velocidad del vehículo de acuerdo con una realización de la presente invención. También pueden realizarse otras secuencias de operaciones de acuerdo con realizaciones alternativas. Por ejemplo, las realizaciones alternativas pueden realizar las operaciones descritas anteriormente en un orden diferente. Además, las operaciones individuales ilustradas en la figura 6 puede incluir múltiples suboperaciones que pueden realizarse en diversas secuencias según sea apropiado para las operaciones individuales. Asimismo, se pueden añadir o eliminar operaciones adicionales dependiendo de las aplicaciones particulares. Un experto en la materia reconocería muchas variaciones, modificaciones y alternativas.

35 Los métodos de la figura 6 puede incorporarse en un medio legible por ordenador no transitorio conocido por los expertos en la materia, habiendo almacenado en el mismo un programa que incluye instrucciones ejecutables por ordenador para hacer que un procesador, ordenador u otro dispositivo programable ejecute las operaciones de los métodos.

40 En algunas implementaciones, el dispositivo móvil puede alinearse con el vehículo para predecir la aceleración longitudinal mediante métodos similares al método de la figura 6. Se puede encontrar una divulgación adicional con respecto a la alineación de un dispositivo móvil con un vehículo en la patente '099 incorporada. En algunas implementaciones, otras características, por ejemplo, la mediana, varianza y máximo del cambio de velocidad derivado mediante la integración de datos del acelerómetro y la mediana, varianza y máximo de la derivada de la aceleración (también conocida como sacudida), se pueden extraer de los datos del paso de banda filtrados e incluidos como entrada al clasificador para predecir la velocidad del vehículo, así como otras características de movimiento del vehículo. En algunas implementaciones, la distancia puede estimarse integrando la velocidad del vehículo predicha por el clasificador. La figura 9 es un gráfico de agrupación 900 que muestra la distancia estimada por el clasificador 910 en comparación con la distancia 920 medida por GPS de acuerdo con aspectos de la presente divulgación.

50 De acuerdo con algunos aspectos de la presente divulgación, el kilometraje del vehículo puede calcularse a partir de datos de sensor de IMU recopilados en segundo plano. Los datos del acelerómetro pueden recopilarse en segundo plano durante un viaje en el vehículo. Los datos del acelerómetro pueden muestrearse a una frecuencia inferior a la frecuencia de muestreo, por ejemplo, 9 Hz u otra frecuencia, y la magnitud de la señal muestreada hacia abajo calculada (por ejemplo, mediante el procesador del dispositivo móvil).

55 Las magnitudes de señal muestreadas hacia abajo pueden segmentarse en ventanas de tiempo de tamaño fijo e introducirse en un modelo de aprendizaje automático (por ejemplo, un clasificador) para predecir la distancia recorrida para cada segmento. La distancia predicha recorrida para cada segmento puede combinarse para determinar una distancia predicha recorrida para el viaje.

60 En algunas implementaciones, la distancia predicha recorrida (es decir, kilometraje) puede acumularse para todos los viajes del vehículo durante un periodo de tiempo específico, por ejemplo, un año u otro periodo de tiempo, para determinar el kilometraje total recorrido durante ese periodo de tiempo.

65 La estimación de la velocidad del vehículo basada en señales de IMU y señales de solo aceleración puede tener aplicaciones para áreas tales como la recopilación de datos de conducción, análisis de modo de transporte y predicción de accidentes, así como otras áreas.

En algunas realizaciones, los accidentes de vehículos pueden predecirse basándose únicamente en señales generadas por la IMU. La detección de colisiones basada únicamente en las señales de IMU proporciona una ventaja sobre la detección de colisiones basada en GPS al menos en que la IMU consume menos potencia de dispositivo móvil que un receptor de GPS. Por ejemplo, los datos de IMU se pueden recopilar en segundo plano en cualquier tiempo en el que el dispositivo móvil esté operativo. Adicionalmente, la frecuencia de muestreo para los sensores de IMU puede controlarse basándose en la actividad de sensor detectada. Por ejemplo, una frecuencia de muestreo baja utilizada durante condiciones de estado estable puede aumentarse cuando se detectan cambios repentinos de aceleración o cambios en la dirección. Obtener datos de GPS, por otro lado, requiere iniciar y ejecutar una aplicación de GPS en el dispositivo móvil que consume energía adicional.

De acuerdo con aspectos de la presente divulgación, la información normalmente obtenida a partir de datos de GPS puede inferirse a partir de datos de IMU. Por ejemplo, usando los datos de IMU, puede determinarse si un vehículo se ha detenido durante un periodo de tiempo especificado lo suficientemente largo como para calificar como un evento que una medición de GPS identificaría como el vehículo que se detuvo durante esa cantidad de tiempo.

La figura 10 es un diagrama de bloques que ilustra un ejemplo de un módulo de predicción de colisión 1000 de acuerdo con aspectos de la presente divulgación. Con referencia a la figura 10, el módulo de predicción de colisión 1000 puede incluir un filtro de tiempo de evento 1010 y un modelo de colisión de IMU 1020. Tanto el filtro de tiempo de evento 1010 como el modelo de colisión de IMU 1020 pueden ser modelos de aprendizaje automático. El filtro de tiempo de evento 1010 puede entrenarse usando datos de sensor de IMU para identificar tiempos de evento que pueden tener una mayor probabilidad (por ejemplo, según se determina a partir de datos históricos) que los tiempos vecinos de indicar una colisión.

Los datos de todos los tiempos registrados por los sensores de IMU pueden recibirse por el módulo de predicción de colisión 1000 como tiempos de evento 1005. Los tiempos de evento 1005 pueden incluir datos de sensor de IMU adquiridos durante ventanas de tiempo especificadas. El filtro de tiempo de evento 1010 puede identificar tiempos de evento candidatos. Por ejemplo, el filtro de tiempo de evento 1010 puede identificar tiempos de evento candidatos como ventanas de tiempo que incluyen datos de acelerómetro que superan una magnitud umbral (por ejemplo, 10 m/s² u otra magnitud). Estos tiempos de evento candidatos pueden tener una mayor probabilidad que los tiempos vecinos de indicar una colisión.

El filtro de tiempo de evento 1010 puede filtrar adicionalmente los tiempos de evento candidatos evaluando los datos de sensor de IMU en ventanas de tiempo alrededor de los tiempos de evento candidatos para determinar si se cumplen diversos criterios. Por ejemplo, usando los datos de IMU, el filtro de tiempo de evento 1010 puede proporcionar una indicación equivalente a una indicación de GPS de la velocidad del vehículo que supera una velocidad especificada (por ejemplo, 5 m/s u otra velocidad) durante una cantidad de tiempo especificada (por ejemplo, 2 minutos u otro tiempo). Como otro ejemplo, el filtro de tiempo de evento 1010 puede proporcionar una indicación equivalente a una indicación de GPS de que el vehículo viajó una distancia especificada (por ejemplo, 250 metros u otra distancia) en un tiempo especificado (por ejemplo, tres minutos u otro tiempo). Pueden proporcionarse otras indicaciones equivalentes a indicaciones de GPS sin apartarse del alcance de la presente divulgación. Los tiempos de evento candidatos y los datos asociados que cumplen los criterios especificados pueden filtrarse por el filtro de tiempo de evento 1010. Eliminar los tiempos de evento candidatos que es poco probable que sean indicaciones de colisión puede mejorar los resultados (por ejemplo, reducir los falsos positivos) del modelo de colisión de IMU.

El filtro de tiempo de evento 1010 puede emitir tiempos de evento filtrados 1015 que cumplen los criterios especificados como entrada al modelo de colisión de IMU 1020. Usando los tiempos de evento filtrados 1015, el modelo de colisión de IMU 1020 puede generar predicciones 1025 de si el vehículo estuvo involucrado en una colisión.

Las figuras 11A-11D son gráficos que ilustran ejemplos de resultados de predicción de colisión de acuerdo con aspectos de la presente divulgación. En las figuras 11A-11D, el eje horizontal indica predicciones positivas falsas por cada 19 312,13 km (12 000 millas) recorridos, y el eje vertical indica la fracción de accidentes que pueden detectarse en función de las predicciones positivas falsas. En los EE. UU., 19 312,13 km (12 000 millas) es el kilometraje anual promedio conducido; de este modo, los gráficos en las figuras 11A-11D también puede verse como una indicación de la fracción de accidentes que pueden detectarse en función de las predicciones de falsos positivos por año (por ejemplo, el número de predicciones falsas que se harían para un conductor-año).

En las figuras 11A-11D, los gráficos 1110A-1110D representan resultados de predicción de colisión generados por el modelo de colisión de IMU 1020 sin que los tiempos de evento se filtren por el filtro de tiempo de evento 1010. En otras palabras, todos los tiempos de evento generados por la IMU se usan como entrada al modelo de colisión de IMU 1020. Los gráficos 1120A-1120D representan resultados de predicción de colisión generados por el modelo de colisión de IMU 1020 teniendo el filtro de tiempo de evento 1010 conocimiento exacto de qué tiempos de evento candidatos deberían filtrarse. Los tiempos de evento filtrados alimentados al modelo de colisión de IMU 1020 se basan en datos de GPS conocidos para indicar tiempos de evento relacionados con eventos de colisión. De este modo, los gráficos 1120A-1120D indican predicciones por el modelo de colisión de IMU 1020 basándose únicamente en tiempos de evento que se sabe que están asociados con colisiones, resultando en las mejores predicciones de colisión posibles.

Los gráficos 1130A-1130D representan resultados de predicción de colisión generados por el modelo de colisión de IMU 1020 con el filtro de tiempo de evento 1010 filtrando los tiempos de evento registrados por los sensores de IMU y proporcionando los tiempos de evento filtrados al modelo de colisión de IMU 1020. Para las figuras 11A y 11B, el umbral de tiempo de evento candidato para las gráficas 1130A y 1130B se estableció en un pico de aceleración de más de 10 m/s². Para las figuras 11C y 11D, el umbral de tiempo de evento candidato para las gráficas 1130C y 1130D se estableció como un pico de aceleración de más de 5 m/s².

Las figuras 11A-11D ilustran que el efecto de incluir el filtro de tiempo de evento 1010 para filtrar los tiempos de evento introducidos en el modelo de colisión de IMU 1020 es aumentar la precisión de predicción de colisión del modelo de colisión de IMU 1020. Como se muestra en los gráficos 1130A-1130D, que incluye el filtro de tiempo de evento 1010 mueve la precisión de predicción de colisión del modelo de colisión de IMU 1020 solo (por ejemplo, los gráficos 1110A-1110D) más cerca de la mejor precisión de predicción de colisión posible (es decir, las parcelas 1120A-1120D). Obsérvese que las escalas del eje x expandidas en las figuras 11B y 11D ilustran predicciones falsas positivas por cada 19 312,13 (12 000) conducidos es mucho menor que uno y se acerca a las mejores predicciones de colisión posibles (es decir, los gráficos 1120A-1120D) cuando el filtro de tiempo de evento 1010 se usa para filtrar los tiempos de evento (es decir, las parcelas 1130A-1130D).

La figura 12 es una representación ilustrativa de una estructura de datos de gráfico 1200 generada por unos datos de motor de detección de actividad de acuerdo con algunas realizaciones. Una aplicación de recopilación de datos que se ejecuta en el dispositivo móvil recopila mediciones de uno o más sensores (por ejemplo, tal como el sensor del bloque de datos de sensor 108 de la figura 1). Mientras se ejecuta, la aplicación de recopilación de datos puede consumir recursos (por ejemplo, procesar, el ancho de banda de red, la potencia y similares) del dispositivo móvil. En algunos casos, la aplicación de recopilación de datos solo puede pretender capturar datos de sensor que corresponden a un tipo de actividad predeterminado (por ejemplo, tal como una conducción o similar). Capturar datos de sensor de otras actividades (por ejemplo, cuando el dispositivo móvil está estacionario) puede desperdiciar los recursos del dispositivo móvil. Para reducir el consumo de recursos de las aplicaciones del dispositivo móvil, el sistema operativo del dispositivo móvil puede capturar y almacenar en caché datos de sensor de algunos o todos los sensores del dispositivo móvil durante un intervalo de tiempo predeterminado (por ejemplo, 12 horas). Cuando una aplicación tal como la aplicación de recopilación de datos se ejecuta (o regresa de un estado suspendido), la aplicación puede solicitar los datos de sensor recopilados por el sistema operativo durante el intervalo de tiempo predeterminado anterior (por ejemplo, hasta las 12 horas anteriores) mientras la aplicación de recopilación de datos no se estaba ejecutando.

El sistema operativo del dispositivo móvil también puede generar una probabilidad de una actividad contemporánea del dispositivo móvil a lo largo del intervalo de tiempo predeterminado. El sistema operativo puede generar una probabilidad de que el dispositivo móvil esté estacionario, con un usuario que está caminando, con un usuario que está corriendo, con un usuario que está montando una bicicleta, con un usuario que está conduciendo, con un usuario que está volando, o similar). El motor de detección de actividad puede acceder a los datos de actividad generados por el sistema operativo durante el intervalo de tiempo predeterminado y usar los datos de actividad para identificar posibles unidades perdidas (por ejemplo, unidades en las que la aplicación de recopilación de datos no obtuvo datos de sensor). Por ejemplo, si la aplicación de recopilación de datos se suspende o no se ejecuta de otra manera y el dispositivo móvil no detecta que se cruzó una geovalla (si se generó una), la aplicación de recopilación de datos puede no recopilar o analizar los datos de sensor del accionamiento. En cambio, el motor de detección de actividad puede identificar la unidad perdida a partir de los datos de actividad generados por el sistema operativo y recopilar la porción de los datos de sensor recopilados por el sistema operativo mientras la aplicación de recopilación de datos estaba suspendida o no se estaba ejecutando.

En algunos casos, la aplicación de recopilación de datos puede solicitar que el sistema operativo recopile datos de sensor. El motor de detección de actividad puede indicar un intervalo de tiempo durante el cual se solicitan las mediciones de sensor (por ejemplo, hasta un máximo permitido por el sistema operativo tal como 12 horas o similar). El sistema operativo puede a continuación almacenar en caché datos de sensor a lo largo del intervalo de tiempo mientras la aplicación de datos no se está ejecutando (o está suspendida). Cuando la aplicación de recopilación de datos se ejecuta (o vuelve de la suspensión), el motor de detección de actividad accede a los datos de actividad recopilados por el sistema operativo (por ejemplo, a través de una interfaz de programación de aplicaciones expuesta por el sistema operativo). La aplicación de recopilación de datos también puede generar una nueva solicitud al sistema operativo para recopilar datos de sensor durante un intervalo de tiempo posterior de modo que los datos de sensor siempre se recopilan o bien por la aplicación de recopilación de datos (cuando se ejecuta) o bien por el sistema operativo, (cuando la aplicación de recopilación de datos no se está ejecutando).

El motor de detección de actividad puede generar una estructura de datos de gráfico usando los datos de actividad recibidos del sistema operativo. Como se ha descrito anteriormente, los datos de actividad incluyen, sin limitación, una probabilidad de que el dispositivo móvil esté: estacionario, caminando (por ejemplo, el dispositivo móvil está con un usuario que está caminando), conduciendo en grado bajo (por ejemplo, baja probabilidad de que el dispositivo móvil esté con un usuario que está conduciendo), conduciendo en grado medio (por ejemplo, probabilidad media de que el dispositivo móvil esté con un usuario que está conduciendo), conduciendo en grado alto (por ejemplo, alta probabilidad de que el dispositivo móvil esté con un usuario que está conduciendo), montando en bicicleta (por ejemplo, el

dispositivo móvil está con un usuario que va en bicicleta), y similares. Cualquier actividad también puede representarse por la estructura de datos de gráfico, como las enumeradas por un usuario (por ejemplo, a través de la entrada del usuario o similar), las detectadas por otra aplicación del dispositivo móvil, o cualquier otra actividad que pueda detectarse a través del análisis de las mediciones del sensor. El motor de detección de actividad puede recibir identificación de cualquier cantidad de actividades durante el intervalo de tiempo precedente. El motor de detección de actividad puede obtener una indicación de una actividad en intervalos regulares (por ejemplo, sondeando el sistema operativo) tal como cada media hora, cada hora, etc. Como alternativa, el motor de detección de actividad puede recibir una indicación de una actividad cada vez que el sistema operativo detecta una nueva actividad (por ejemplo, notificación de avance desde el sistema operativo).

En algunos casos, el motor de detección de actividad puede recibir una probabilidad (por ejemplo, una fiabilidad de que la actividad está ocurriendo) para cada una de las múltiples actividades. En esos casos, el motor de detección de actividad representa, en la estructura de datos del gráfico, la actividad con la probabilidad más alta. Como alternativa, el motor de detección de actividad puede representar únicamente aquellas actividades con una probabilidad que supera un umbral. Por ejemplo, el motor de detección de actividad solo puede representar actividades con una probabilidad que supera el 40 % en la estructura de datos de gráfico. Si ninguna actividad supera el umbral del 40 %, la estructura de datos del gráfico puede no incluir actividades en ese tiempo (por ejemplo, la actividad puede representarse como un valor nulo). Como alternativa, el motor de recopilación de datos puede representar todas las actividades en la estructura de datos de gráfico con la probabilidad correspondiente de cada actividad.

La estructura de datos de gráfico 1200 incluye un intervalo de tiempo anterior de 12 horas desde un evento de reactivación (por ejemplo, un tiempo en el que la aplicación de recopilación de datos se ejecuta o se reactiva desde la suspensión). Un evento de reactivación puede ser cualquier evento predeterminado tal como, pero sin limitación, cruzar el móvil una geovalla (o cualquier límite particular), una notificación de visita, una notificación de un servicio de notificación (por ejemplo, conocida como "notificación de avance"), una hora programada, detectar datos de sensor indicativos de movimiento, o similares). Una visita puede ser una notificación desde el sistema operativo del dispositivo móvil que indica que el dispositivo móvil está ubicado en una ubicación durante el tiempo suficiente para que el sistema operativo determine que el dispositivo móvil está "visitando" la ubicación. La visita puede corresponder a cualquier ubicación en la que se coloca el dispositivo móvil durante más tiempo que un intervalo de tiempo umbral. Por ejemplo, una ubicación puede corresponder a un establecimiento (por ejemplo, un negocio, una institución pública, una residencia, o similares). El motor de detección de actividad recibió datos de actividad para cada hora del intervalo de tiempo de 12 horas anterior y representó, en la estructura de datos del gráfico, teniendo la actividad la probabilidad más alta (si se recibió más de una actividad). Por ejemplo, a menos 12 horas (por ejemplo, 12 horas antes de la ejecución de la aplicación de recopilación de datos) la actividad 1204 corresponde a estacionaria, a menos 11 horas la actividad 1208 corresponde a caminar, a menos tres horas, la actividad 1212 corresponde a una conducción en grado medio, y a menos nueve horas, la actividad 1216 corresponde a una conducción en grado alto.

El motor de detección de actividad puede identificar una unidad perdida usando los datos de actividad de la estructura de datos de gráfico 1200. Por ejemplo, el motor de detección de actividad identifica un primer tiempo 1220, que es un tiempo más temprano en el que se detecta un impulso de actividad alto. El motor de detección de actividad identifica la actividad 1216 como la actividad que corresponde al primer tiempo 1220. En algunos casos, el motor de detección de actividad identifica el tiempo más temprano de cualquier actividad de conducción (por ejemplo, grado medio o alto). En la estructura de datos de gráfico 1200, el primer tiempo que 1220 se detectó a las menos nueve horas (por ejemplo, nueve horas antes de la ejecución de la aplicación de recopilación de datos). El motor de detección de actividad identifica a continuación un segundo tiempo 1224, que es el tiempo más temprano después del primer tiempo en el que se detecta una actividad diferente. Por ejemplo, el motor de detección de actividad identifica la actividad 1228 como la siguiente actividad que no es una actividad de accionamiento. La actividad diferente puede ser cualquier actividad distinta de una actividad de conducción, tal como caminar o estacionario en el ejemplo descrito por la estructura de datos de gráfico 1200. En algunos casos, el motor de detección de actividad identifica un segundo tiempo que corresponde a una actividad que es cualquier otra cosa que una conducción en grado alto (por ejemplo, conducir en grado medio, caminar, montar en bicicleta o estar estacionario). Por ejemplo, el segundo tiempo puede corresponder a una actividad de accionamiento incluso si la probabilidad de que se produzca una actividad de conducción es media, baja o nula. El motor de detección de actividad a continuación identifica una conducción perdida que se produjo durante un intervalo de tiempo que incluye menos nueve horas a menos seis horas.

El motor de detección de actividad puede entonces identificar si se produjo otro viaje perdido identificando un tercer tiempo, que es un tiempo más temprano después del segundo tiempo en el que se detecta una actividad de conducción y un cuarto tiempo, que es un tiempo más temprano después del tercer tiempo en el que se detectó una actividad distinta de una unidad. El proceso puede continuar hasta que se identifiquen todas las unidades perdidas. Aunque el proceso de identificación de viajes perdidos comienza analizando desde un tiempo más temprano (por ejemplo, menos 12 horas) a un evento de reactivación, el proceso puede operar analizando datos de actividad desde el evento de reactivación hacia el tiempo más temprano.

La aplicación de recopilación de datos puede recibir los datos de sensor del sistema operativo durante los intervalos de tiempo en los que se produjo una unidad perdida (por ejemplo, de menos nueve horas a menos seis horas como se representa en la estructura de datos de gráfico 1200). Esto evita que la aplicación de recopilación de datos tenga

que analizar datos de sensor que corresponden a intervalos de tiempo que probablemente no corresponden a un accionamiento.

5 La figura 13 es un diagrama de bloques ilustrativo del sistema 1300 para predecir la velocidad de un vehículo a partir de mediciones de sensor de dispositivo móvil de acuerdo con algunas realizaciones. El sistema 1300 genera una o más predicciones de una velocidad de un vehículo a partir de mediciones de sensor recibidas por un dispositivo móvil colocado dentro del vehículo. En algunos casos, los procesos descritos en la figura 13 se ejecutan en tiempo real por el dispositivo móvil a medida que el dispositivo móvil recibe mediciones de sensor desde sensores del dispositivo móvil. En otros casos, el proceso puede ejecutarse parcialmente por el dispositivo móvil y parcialmente por uno o más otros dispositivos (por ejemplo, como servidores, dispositivos móviles, sistemas informáticos o similares) o en su totalidad por los uno o más otros dispositivos.

15 El sistema 1300 recibe mediciones de sensor sin procesar 1304 desde uno o más sensores del dispositivo móvil (por ejemplo, como un acelerómetro, magnetómetro o similares). Las mediciones de sensor sin procesar pueden incluir mediciones de sensor en uno o más ejes (por ejemplo, eje x, eje y y/o eje z). El sistema 1300 también recibe datos de actividad 1308 que incluyen una predicción de una actividad que tiene lugar aproximadamente al mismo tiempo en el que se reciben mediciones de sensor sin procesar 1304. Por ejemplo, el sistema operativo (o motor de detección de actividad) puede determinar una probabilidad de que el dispositivo móvil esté posicionado dentro del vehículo que está conduciendo actualmente. Las mediciones de sensor sin procesar 1304 y los datos de actividad 1308 se introducen en el sistema de procesamiento 1312. El sistema de procesamiento 1312 incluye cuatro etapas: filtrado de frecuencia 1316, normalizar las mediciones filtradas 1320, definir ventanas contiguas 1324 y remuestrear 1328. La salida del sistema de procesamiento 1312 puede introducirse en una red neuronal (u otro modelo de aprendizaje automático), que generará una predicción de una velocidad del vehículo.

25 El filtrado de frecuencia 1316 incluye filtrar una porción de los valores de datos que se producen en frecuencias particulares. Por ejemplo, las mediciones de sensor sin procesar pueden convertirse a un dominio de frecuencia usando una transformada (por ejemplo, Fourier o similares). Una vez en el dominio de la frecuencia, las mediciones de sensor sin procesar pueden filtrarse para eliminar ruido o valores de datos que son menos precisos en las predicciones de velocidad del vehículo. El filtrado de frecuencia 1316 filtra las frecuencias que son mayores que una frecuencia umbral. En algunos casos, el umbral puede ser, por ejemplo, una frecuencia de 9-50 Hz. El umbral de frecuencia puede seleccionarse mediante un proceso del sistema 1300, un usuario, una comunicación recibida desde un dispositivo remoto o similar. El sistema de procesamiento 1312 luego pasa las mediciones de sensor sin procesar restantes y normaliza las mediciones filtradas 1320, donde las mediciones de sensor sin procesar restantes se normalizan a una escala predeterminada.

35 El sistema de procesamiento 1312 define a continuación ventanas contiguas 1324 que cada una incluye una porción de las mediciones de sensor normalizadas. Las ventanas contiguas incluyen una porción de las mediciones de sensor normalizadas (en el dominio del tiempo) que se recibieron durante un intervalo de tiempo. La duración del intervalo de tiempo puede determinarse dinámicamente basándose en las mediciones de sensor normalizadas. Por ejemplo, una delta media puede definirse como la diferencia media en tiempo entre dos valores consecutivos de las mediciones de sensor normalizadas. Puede definirse una ventana contagiosa cada vez que el intervalo de tiempo entre dos valores consecutivos es mayor que un umbral que se basa en la delta mediana. En algunos casos, el umbral puede ser un múltiplo de la desviación estándar de la delta media, tal como una desviación estándar, dos desviaciones estándar, tres desviaciones estándar, etc. En otros casos, el umbral puede seleccionarse por un usuario o a partir de una entrada recibida desde otro dispositivo. Puede definirse cualquier número de ventanas contiguas para los valores de sensor normalizados, incluido uno (por ejemplo, tal como cuando una diferencia de tiempo entre cada uno de los valores consecutivos de las mediciones de sensor normalizadas no es mayor que el umbral 1412) o cualquier número mayor que uno.

50 Como alternativa, definir ventanas contiguas 1324 puede generar ventanas uniformes. Por ejemplo, cada ventana contigua puede tener una duración de intervalo de tiempo predeterminada tal como, pero limitada a, cinco segundos, 10 segundos, 30 segundos, un minuto, etc. La duración del intervalo de tiempo predeterminado puede estar predeterminada (por ejemplo, antes del tiempo de ejecución), seleccionada dinámicamente (en cualquier tiempo después del tiempo de ejecución), seleccionada basándose en la entrada del usuario, seleccionada basándose en un valor recibido desde un dispositivo informático remoto, o similar.

60 La última etapa del sistema de procesamiento 1312 incluye el remuestreo 1328 en el que las ventanas contiguas se remuestran a una frecuencia predeterminada. La frecuencia predeterminada puede ser una frecuencia seleccionada por el sistema de procesamiento 1312, el sistema 1300, el dispositivo móvil, un usuario, un dispositivo remoto, o similar. En algunos casos, la frecuencia predeterminada puede ser una frecuencia de 9-50 Hz.

65 La salida del sistema de procesamiento 1312 pueden ser las mediciones de sensor procesadas que corresponden a cada ventana contigua. Las mediciones de sensor procesadas que corresponden a una ventana contigua se pasan a la red neuronal 1332 que genera la velocidad predicha 1336 para cada unidad de tiempo (por ejemplo, definida basándose en la delta media, mediante una entrada de usuario, o como alguna división del intervalo de tiempo total de la ventana contigua) incluida en la ventana contigua. Por ejemplo, si la ventana contigua incluye 10 segundos de

mediciones de sensor procesadas y la unidad de tiempo es un segundo, entonces la ventana contigua incluiría 10 unidades de tiempo y la red neuronal 1332 puede emitir 10 valores de velocidad predichos. Si las ventanas contiguas no tienen una longitud uniforme (por ejemplo, sino que se basan en una diferencia de tiempo entre dos valores que son mayores que un múltiplo de la desviación estándar del delta de tiempo), entonces la red neuronal 1332 puede generar una cantidad diferente de predicciones para cada ventana contigua.

La figura 14 es un conjunto ilustrativo de gráficos que ilustran la división de mediciones de sensor procesadas en ventanas contiguas de acuerdo con algunas realizaciones. El gráfico 1404 incluye un gráfico de valores de aceleración normalizados con el eje x que representa el tiempo. El gráfico 1408 incluye un gráfico de la diferencia media entre dos valores consecutivos de los valores de aceleración normalizados frente al tiempo. Como resultado, cada conjunto de valores consecutivos representados en el gráfico 1404 tiene un valor correspondiente representado en el gráfico 1408. El gráfico 1404 incluye una primera ventana contigua que puede definirse antes del comienzo del gráfico (por ejemplo, en algún tiempo antes del tiempo 7800). La primera ventana contigua se extiende hasta que la diferencia de tiempo entre valores consecutivos de los valores de aceleración normalizados supera el umbral 1412. Por ejemplo, en 1416, hay una diferencia de tiempo entre valores consecutivos que es significativamente mayor que el umbral 1412 en el tiempo 8050, lo que significa el final de la primera ventana contigua y el comienzo de la segunda ventana contigua 1420. En 1424, hay otra diferencia de tiempo entre valores consecutivos que es significativamente mayor que el umbral 1412 en el tiempo 8150, lo que significa el final de la segunda ventana contigua 1420 y el comienzo de una tercera ventana contigua. En algunos casos, los gráficos 1404 y 1408 pueden representarse o visualizarse. En otros casos, los gráficos 1404 y 1408 pueden no representarse o visualizarse. En otros casos más, los gráficos 1404 y 1408 pueden representarse como metadatos, datos, una estructura de datos o similar. Además, mientras que los gráficos 1404 y 1408 ilustran la segmentación de valores de aceleración normalizados en el eje x en ventanas contiguas, se pueden usar otras entradas además de o en lugar de valores de aceleración normalizados en el eje x, tales como, pero sin limitación, valores de aceleración normalizados en el eje y, valores de aceleración normalizados en el eje z, magnitud de aceleración normalizada, datos de actividad, o similares.

La figura 15 es una representación ilustrativa de las capas de una red neuronal que puede generar una predicción de la velocidad de un vehículo de acuerdo con algunas realizaciones. Las redes neuronales incluyen la capa de entrada 1504 (por ejemplo, donde las características se introducen en la red neuronal), la capa de salida 1508, y una o más capas ocultas posicionadas entre la capa de entrada y la capa de salida. Cada capa incluye una o más neuronas que están conectadas cada una a una o más neuronas de una capa anterior (excepto para la capa de entrada) y una o más neuronas de la capa posterior (excepto para la capa de salida). Cada neurona de cada capa oculta proporciona una transformación no lineal de las características recibidas desde una capa anterior. Pueden asignarse pesos a las conexiones entre neuronas para dirigir la transformación que se aplica a las características.

La red neuronal 1500 puede ser una red neuronal convolucional, que incluye una o más capas de convolución, además de, o en lugar de, las capas ocultas. Cada neurona de una capa de convolución incluye un núcleo definido por hiperparámetros que se convolucionan a través de las características recibidas desde una capa anterior. En algunos casos, las capas de convolución pueden ser convoluciones dilatadas en las que el núcleo se aplica sobre un área más grande (de características de entrada de la capa anterior) que su longitud (por ejemplo, la distancia de la capa desde la capa de entrada). Cada capa posterior puede incluir dilataciones adicionales. Por ejemplo, una primera capa de convolución puede incluir una dilatación de una en la que el núcleo de la neurona 1520 se aplica sobre un área de uno (por ejemplo, una neurona de la neurona adyacente a la neurona 1520). El núcleo de la neurona 1520 puede aplicarse a las neuronas 1512 y 1516. La segunda capa de convolución puede incluir una dilatación de dos en la que el núcleo de la neurona 1524 se aplica sobre un área de dos desde la neurona adyacente 1520 de la capa anterior. El núcleo de la neurona 1524 puede aplicarse a las neuronas 1520 a la neurona 1528.

Continuando con el ejemplo, la siguiente capa incluye una dilatación de cuatro y el núcleo de la neurona 1532 se aplica un área de cuatro desde la neurona adyacente 1524 de la capa anterior. El núcleo de la neurona 1532 se aplica de 1524 a 1536. La última capa representada tiene una dilatación de ocho. El núcleo de la neurona 1540 se aplica desde la neurona 1532 a la neurona 1544 (por ejemplo, ocho neuronas de la neurona 1532). La red neuronal 1500 puede incluir cualquier número de neuronas (por ejemplo, 64, 128, 256, etc.), estando cada una configurada para aplicar un núcleo. La red neuronal 1500 puede incluir cualquier número de dilataciones. Por ejemplo, además de las dilataciones 1, 2, 4 y 8, mostradas, la red neuronal puede incluir 16, 32, 64, etc. siendo cada dilatación posterior el doble de la dilatación de la capa anterior.

Las características de entrada 1512 y 1516 corresponden a mediciones de sensor recibidas a lo largo del tiempo (por ejemplo, de derecha a izquierda siendo desde el tiempo (T) $T=0$ hasta el tiempo $T=\infty$). Por ejemplo, la característica de entrada 1512 puede corresponder a mediciones de acelerómetro recopiladas en el tiempo $T=0$ y la característica de entrada 1516 puede corresponder a mediciones de acelerómetro recopiladas en el siguiente intervalo de tiempo posterior $T=1$ (donde el tiempo entre $T=0$ y $T=1$ puede ser de cualquier cantidad de tiempo tal como un segundo, un milisegundo, etc.). Las convoluciones dilatadas permiten que la red neuronal incluya un campo receptivo más grande de características de entrada, lo que permite el uso selectivo de mediciones de sensor a lo largo de un intervalo de tiempo más grande. Por ejemplo, una red neuronal, tal como la red neuronal 1500, que incluye 128 núcleos y dilataciones de 1, 2, 4, 8, 16 y 32, incluiría un campo receptivo de 96. Esto significa que la red neuronal tendría 96 entradas (por ejemplo, 96 mediciones de sensor discretas o la medición de sensor recopilada durante 10,6 segundos).

Esto mejora la eficiencia de la red neuronal mejorando tanto la velocidad como la precisión de las predicciones generadas por la red neuronal (por ejemplo, predicción de velocidad, predicción de accidentes, etc.).

5 La figura 16 es un diagrama de bloques ilustrativo de un sistema para predecir la velocidad de un vehículo que
 10 corresponde a etapas de tiempo usando mediciones de sensor de dispositivo móvil de acuerdo con algunas realizaciones. Un conjunto de mediciones de sensor 1604 puede recibirse como entrada. Por ejemplo, un dispositivo móvil, tal como el dispositivo móvil 104, recopila el conjunto de mediciones de sensor de los sensores del dispositivo móvil mientras el dispositivo móvil está dispuesto dentro del vehículo. El conjunto de mediciones de sensor incluye una o más mediciones de sensor recopiladas durante un intervalo de tiempo (por ejemplo, de T_0 a T_n) donde cada
 15 medición de sensor está asociada con el tiempo, T , en el que se recopiló la medición. El conjunto de mediciones de sensor puede incluir una o más mediciones de aceleración en el eje x, una o más mediciones de aceleración en el eje y, una o más mediciones de aceleración en el eje z, una o más mediciones de magnitud de aceleración, una identificación de una actividad actual a partir de datos de actividad para cada tiempo en el que hay una medición de aceleración, combinaciones de los mismos y similares. En algunos casos, además de las mediciones de aceleración, las mediciones del sensor pueden incluir mediciones giroscópicas, mediciones de magnetómetro, mediciones de GPS, combinaciones de los mismos, o similares.

20 El sistema de preprocesamiento 1312 puede recibir mediciones de sensor 1604 y generar una serie de fragmentos contiguos 1608 de mediciones de sensor procesadas. Cada fragmento contiguo 1608 puede corresponder a mediciones de sensor procesadas que corresponden a una ventana contigua (por ejemplo, como se describe en relación con la figura 13 y 14). Por ejemplo, el fragmento contiguo 1 1608-1 puede incluir las mediciones de sensor procesadas de mediciones de sensor recopiladas a lo largo de una primera ventana contigua. Estas mediciones de sensor procesadas pueden incluir uno o más valores para cada tipo de sensor de entrada (por ejemplo, mediciones de aceleración en el eje x, mediciones de aceleración en el eje y, mediciones de aceleración en el eje z, magnitud de aceleración y datos de actividad). Cualquier número de fragmentos contiguos puede generarse mediante el sistema de preprocesamiento 1312. Dado que cada fragmento contiguo incluye mediciones de sensor procesadas de mediciones de sensor recopiladas durante una ventana contigua y dado que las ventanas contiguas pueden tener longitudes variables, la cantidad de mediciones de sensor de cada fragmento contiguo 1608-1 - 1608-n puede ser diferente (por ejemplo, desde un único valor para cada tipo de sensor hasta cualquier cantidad particular de valores para cada tipo de sensor).
 30

35 La red neuronal recibe los fragmentos contiguos como entrada y genera, para cada tiempo para el que hay mediciones de sensor, una velocidad predicha del vehículo 1612-1 - 1612-n. Por ejemplo, dado que el fragmento contiguo 1 1608-1 incluye mediciones de sensor para tiempos T_0 - T_5 , la red neuronal 1332 puede generar una velocidad predicha 1612-1 del vehículo para cada uno de T_0 - T_5 . La red neuronal 1332 puede recibir a continuación el siguiente fragmento contiguo 1608-2 (no mostrado) y generar predicciones 1612-2 para cada unidad de tiempo en ese fragmento contiguo. Este proceso puede continuar generando predicciones 1612-n hasta que no haya más fragmentos contiguos para la red neuronal.

40 La figura 17 es un diagrama de flujo de ejemplo de un proceso para filtrar predicciones de velocidad de acuerdo con aspectos de la presente divulgación. El proceso incluye generar un conjunto de vectores de gravedad a partir de mediciones de acelerómetro sin procesar, correspondiendo cada vector de gravedad del conjunto de vectores de gravedad a un intervalo de tiempo (bloque 1704). Cada vector de gravedad del conjunto de vectores de gravedad puede ser unidimensional (por ejemplo, incorporar mediciones de acelerómetro sin procesar desde un único eje, como el eje x, eje y o eje z), bidimensional (por ejemplo, incorporan mediciones de acelerómetro sin procesar de dos ejes), o tridimensionales (por ejemplo, incorporar mediciones de acelerómetro sin procesar desde el eje x, eje y y eje z). Cada vector de gravedad puede estar asociado con el tiempo en el que se recopilaron las correspondientes mediciones de aceleración sin procesar. Los vectores de gravedad pueden generarse en intervalos regulares predeterminados (por ejemplo, denominados en el presente documento etapas de tiempo) que pueden determinarse basándose en la tasa de muestreo del acelerómetro o por un usuario. Por ejemplo, se puede generar un vector de gravedad cada medio segundo, cada segundo, o similares.
 45
 50

55 En algunos casos, cada vector de gravedad puede derivarse de una mediana de un conjunto de señales de aceleración sin procesar. Esto puede evitar que el ruido de señal del acelerómetro se propague al vector de gravedad derivado. Por ejemplo, se puede definir una ventana móvil con un intervalo de tiempo de longitud fija. Las mediciones de acelerómetro mediana recopiladas durante el intervalo de tiempo pueden usarse para derivar un vector de gravedad. Por ejemplo, la ventana deslizante puede incluir 22 segundos (por ejemplo, $T=0$ -22) de mediciones de acelerómetro sin procesar y derivar un primer vector de gravedad a partir de las mediciones de acelerómetro medianas recopiladas durante la ventana deslizante de 22 segundos. La ventana deslizante puede incrementarse de tal manera que la ventana deslizante incluya una medición de acelerómetro sin procesar más nueva y descarte una medición de acelerómetro sin procesar más antigua (por ejemplo, $T=1$ -23, donde la ventana ya no incluye la medición del acelerómetro recopilada en $T=0$, sino que incluye una medición de acelerómetro recopilada en $T=23$). Un segundo vector de gravedad puede derivarse de las mediciones de acelerómetro sin procesar que están dentro de la ventana deslizante. La ventana deslizante puede incrementarse en tiempo real, cuando se recibe una nueva medición de acelerómetro, a intervalos de tiempo predeterminados (por ejemplo, cada 0,5 segundos, cada 1 segundo, etc.) o similares.
 60
 65

El proceso continúa calculando un ángulo entre un vector de gravedad actual y un vector de gravedad anterior (por ejemplo, calcular la "diferencia de ángulo de gravedad") (bloque 1708). El proceso puede comenzar en un primer vector de gravedad en el que existe un vector de gravedad previo para calcular el ángulo entre y continuar para cada vector de gravedad sucesivo en el conjunto de vectores de gravedad hasta que no haya más vectores de gravedad. En algunos casos, el vector de gravedad anterior puede ser el vector de gravedad inmediatamente anterior al vector de gravedad actual. En este caso, el proceso puede comenzar en el segundo vector de gravedad (como el vector de gravedad actual) ya que existe un vector de gravedad inmediatamente anterior a partir del cual calcular el ángulo. En otros casos, el vector de gravedad anterior puede estar a una distancia predeterminada del vector de gravedad actual, tal como cinco vectores de gravedad anteriores al vector de gravedad actual, 10 vectores de gravedad anteriores al vector de gravedad actual, etc.

El proceso continúa determinando si hay más vectores de gravedad (por ejemplo, hay un vector de gravedad que se derivó después del vector de gravedad actual en el conjunto de vectores de gravedad) (bloque 1712). Si es así, el proceso continúa estableciendo el vector de gravedad actual al siguiente vector de gravedad en el conjunto de vectores de gravedad (bloque 1716) y volviendo al bloque 1708. Los bloques 1708-1716 forman un bucle sobre el conjunto de vectores de gravedad. El vector de gravedad actual (en el bloque 1708) se establece inicialmente en el primer (y más antiguo) vector de gravedad en el conjunto de vectores de gravedad y se itera a través del conjunto de vectores de gravedad calculando la diferencia de ángulo de gravedad entre el vector de gravedad actual y el vector de gravedad anterior hasta que no haya más vectores de gravedad en el conjunto de vectores de gravedad. Una vez que el bucle ha concluido, estará disponible un valor de diferencia de ángulo de gravedad para cada paso de tiempo (por ejemplo, la cantidad de valores de diferencia de ángulo de gravedad puede ser aproximadamente igual o menor que la cantidad de vectores de gravedad en el conjunto de vectores de gravedad).

El proceso continúa calculando una suma móvil sobre una diferencia de ángulo de gravedad dentro de una ventana de tiempo deslizante de una longitud predeterminada (bloque 1720). Por ejemplo, la ventana deslizante puede ser 10 segundos, 15 segundos, 20 segundos, o similar. El proceso calcula la suma de los valores de diferencia de ángulo de gravedad que están dentro de la ventana deslizante (por ejemplo, $T=5$ a $T=20$). La ventana deslizante se incrementa a continuación en un paso de tiempo y se calcula otra suma usando los valores de ángulo de gravedad que están dentro de la ventana deslizante incrementada (por ejemplo, $T=6$ a $T=21$). La suma móvil sobre una diferencia de ángulo de gravedad dentro de una ventana de tiempo deslizante puede denominarse como la "diferencia de ángulo de gravedad de ventana deslizante de suma". En algunos casos, se puede calcular una "diferencia de ángulo de gravedad de ventana deslizante de suma" para cada paso de tiempo en el que hay un valor de diferencia de ángulo de gravedad. En otros casos, se puede calcular una "diferencia de ángulo de gravedad de ventana deslizante de suma" para cada ventana deslizante completa. Por ejemplo, para una ventana deslizante de longitud x , la ventana deslizante no estaría completa hasta $T=x$. En esos casos, se puede calcular una "diferencia de ángulo de gravedad de ventana deslizante de suma" para todos los valores que existen en T mayores que o iguales a x .

El proceso continúa a continuación identificando una o más predicciones de velocidad a partir de un conjunto de predicciones de velocidad que corresponde a un mismo intervalo de tiempo en el que la suma móvil supera un umbral (bloque 1724). El conjunto de predicciones de velocidad incluye una velocidad predicha del vehículo para cada paso de tiempo en el que hay una "diferencia de ángulo de gravedad de ventana deslizante de suma". El proceso identifica cada "diferencia de ángulo de gravedad de ventana deslizante de suma" que excede un valor umbral. En algunos casos, el umbral puede ser dinámico. Por ejemplo, el umbral puede ser más o menos sensible basándose en eventos detectados. Si se detecta una colisión de vehículo, por ejemplo, el umbral puede ser sensible con respecto al intervalo de tiempo inmediatamente después del accidente de vehículo detectado. El proceso a continuación identifica las una o más predicciones de velocidad que corresponden a un mismo paso de tiempo como las "diferencias de ángulo de gravedad de ventana deslizante de suma" que exceden el valor umbral.

El proceso continúa filtrando a partir del conjunto de predicciones de velocidad las una o más predicciones de velocidad (bloque 1728). En algunos casos, las mediciones de aceleración pueden incluir valores no deseados y pueden ser en parte el resultado de que un usuario manipule el dispositivo móvil en lugar del vehículo, ruido o similares. El uso de estos valores de aceleración para generar predicciones de velocidad puede producir resultados inexactos. La "diferencia de ángulo de gravedad de ventana deslizante de suma", que representa la volatilidad de las mediciones de aceleración, puede usarse como un filtro para eliminar predicciones de velocidad que corresponden a mediciones de aceleraciones con un alto grado de variabilidad (por ejemplo, probablemente sea el resultado de fuerzas no vehiculares o ruido). Cuando la "diferencia de ángulo de gravedad de ventana deslizante de suma" supera el valor umbral en un paso de tiempo (por ejemplo, las mediciones de aceleración en ese paso de tiempo tienen un alto grado de volatilidad), la predicción de velocidad que corresponde a ese paso de tiempo puede filtrarse del conjunto de predicciones de velocidad.

En algún caso, el proceso puede continuar indefinidamente siempre que haya mediciones de aceleración para procesar. Por ejemplo, los bloques 1704-1728 pueden ejecutarse continuamente mientras el dispositivo móvil está posicionado en el vehículo en un viaje (por ejemplo, el vehículo se está moviendo desde una ubicación de inicio a una ubicación de destino). El proceso puede derivar predicciones de velocidad y filtrar esas predicciones de velocidad en tiempo real. En otros casos, los bloques 1704-1728 pueden ejecutarse una vez que ha concluido el viaje. Por ejemplo,

durante el viaje, el dispositivo móvil puede recopilar mediciones de sensor a lo largo de la unidad. Una vez que la unidad concluye, las mediciones de sensor pueden procesarse en un proceso por lotes para generar un conjunto de predicciones de velocidad durante el viaje y filtrar esas predicciones de velocidad.

- 5 En otros casos más, el proceso de 1704-1728 puede ejecutarse como un proceso semi-por lotes en el que los bloques 1704-1728 pueden ejecutarse cada vez que se recopila una cantidad predeterminada de mediciones de sensor (por ejemplo, basándose en una cantidad umbral de memoria, suficiente para generar una cantidad predeterminada de vectores de gravedad, el intervalo de tiempo entre el tiempo en que el vehículo comienza a moverse y el tiempo en que el vehículo deja de moverse, o similar) y/o tras la finalización del viaje (por ejemplo, en el caso en el que se
10 recopilaron menos de una cantidad umbral de mediciones de sensor, pero el viaje concluyó).

La figura 18 incluye gráficos que ilustran un ejemplo en el que la "diferencia de ángulo de gravedad de ventana deslizante de suma" se usa para filtrar predicciones de velocidad de acuerdo con aspectos de la presente divulgación. El gráfico 1804 es un gráfico de la "diferencia de ángulo de gravedad de ventana deslizante de suma" a lo largo del
15 tiempo. El gráfico 1808 es un gráfico de la velocidad real de un vehículo y la velocidad predicha del vehículo durante el mismo intervalo de tiempo que el gráfico 1804. Los gráficos 1804 y 1808 proporcionan una ilustración de un ejemplo en el que las predicciones de velocidad se filtran de acuerdo con el proceso de la figura 17. En el gráfico 1804, cuando la "diferencia de ángulo de gravedad de ventana deslizante de suma" supera el umbral 1812, como lo hace a aproximadamente 210 segundos, el sistema comienza a filtrar los correspondientes valores de predicción de velocidad
20 1816. Los gráficos 1804 y 1808 proporcionan una representación gráfica del filtrado de valores de predicción de velocidad. Durante el proceso de filtrado de predicciones de velocidad (por ejemplo, el proceso de la figura 17), los valores derivados (por ejemplo, velocidad predicha, la "diferencia de ángulo de gravedad de ventana deslizante de suma") puede no representarse gráficamente (como se muestra en la figura 18), sino que, en su lugar, se representan como datos, como estructura de datos, o similares.

25 La figura 19 es un gráfico ilustrativo que representa el uso de predicción de velocidad para derivar características para el modelo de aprendizaje automático para generar una predicción de colisión de acuerdo con algunas realizaciones. Un modelo de aprendizaje automático puede generar predicciones de colisión para un vehículo que está en funcionamiento. En algunos casos, el ruido de señal u otras fuerzas no vehiculares (por ejemplo, como un usuario que
30 opera el dispositivo móvil) pueden causar un falso positivo donde se detecta la colisión, pero no se ha producido ningún accidente. Pueden usarse características adicionales que caracterizan el entorno del vehículo después de que se produzca la colisión para mejorar la precisión de las colisiones predichas (por ejemplo, eliminando falsos positivos) y como entrada al modelo de aprendizaje automático para refinar el modelo o reentrenamiento.

35 Por ejemplo, después de una colisión, un conductor de un vehículo debe detener el vehículo por completo en una ubicación segura. El conductor puede inspeccionar entonces el daño al vehículo (por ejemplo, para determinar si el vehículo es seguro para operar), evaluar lesiones, intercambiar información con otros conductores, etc. La predicción de velocidad puede usarse para determinar si/cuándo el vehículo se detiene después de una colisión detectada. Si el
40 vehículo se detiene dentro de un intervalo de tiempo o distancia predeterminados después de una colisión detectada, entonces es más probable que la predicción de colisión haya sido precisa. Por otro lado, si el vehículo continúa conduciendo después de la colisión detectada, entonces la colisión detectada puede ser un falso positivo. La detección del vehículo que se detiene (basándose en la predicción de velocidad) y la distancia después de la colisión detectada en el que el vehículo se detuvo pueden ser características adicionales que se pueden usar para determinar la precisión de la predicción de colisión (por ejemplo, filtrar falsos positivos/negativos) y mejorar aún más la precisión del modelo
45 de aprendizaje automático en la generación de predicciones de colisión (por ejemplo, etiquetando los datos del sensor utilizados para entrenar el modelo de aprendizaje automático).

La distancia desde una ubicación de una posible colisión puede determinarse calculando la velocidad media predicha a lo largo de una o más ventanas después del tiempo en el que se detectó la colisión. La ventana puede tener una
50 duración fija y predeterminada, tal como 30 segundos, 60 segundos, 120 segundos, 180 segundos, 300 segundos, o de cualquier duración establecida por la velocidad media predicha (por ejemplo, con una velocidad media predicha más alta que tiene una ventana más grande) un usuario. Las distancias se pueden calcular multiplicando la velocidad media por la duración de cada ventana. Las distancias pueden calcularse para cada ventana usando la velocidad predicha (por ejemplo, como se describe en la figura 13) y de nuevo usando velocidad filtrada (por ejemplo, como se describe en la figura 17-18). Para las cinco ventanas representadas en la figura 19 (por ejemplo, 30 segundos,
55 60 segundos, 120 segundos, 180 segundos, 300 segundos), se derivarían 10 características de distancia: una característica de distancia para cada ventana usando velocidad predicha sin filtrar, y una característica de distancia para cada ventana usando velocidad predicha filtrada. Pueden generarse características de distancia adicionales si se seleccionan ventanas adicionales.

60 Las características de distancia pueden usarse para determinar que se ha producido realmente una colisión predicha. Por ejemplo, si el vehículo se detiene dentro de una distancia predicha después de que se detecte una colisión, entonces puede ser más probable que se haya producido la colisión. Por otro lado, si el vehículo no se detiene dentro de una distancia predicha, entonces puede ser más probable que la colisión predicha fuera un falso positivo. En tal
65 caso, la colisión detectada puede descartarse y la recopilación de datos por el dispositivo móvil puede continuar hasta que la unidad haya concluido.

5 Como alternativa o adicionalmente, las características de distancia pueden usarse como entradas adicionales para un modelo de aprendizaje automático configurado para generar las predicciones de colisión (por ejemplo, ya sea el mismo modelo de aprendizaje automático que generó la predicción de colisión original o un modelo de aprendizaje automático diferente). Generar una nueva predicción de colisión usando las características de distancia como entrada adicional puede producir una predicción de colisión que es más precisa que la predicción de colisión inicial.

10 En algunos casos, la información adicional puede usarse para proporcionar etiquetas para entrenamiento futuro. Por ejemplo, si el conductor no se detuvo después de que se pronosticara una colisión, entonces los datos de sensor que se introdujeron en el modelo de aprendizaje automático pueden etiquetarse con "no colisión". De manera similar, si el vehículo se detuvo después de la colisión predicho, entonces los datos de sensor que se introdujeron en el modelo de aprendizaje automático pueden etiquetarse con "colisión". Las etiquetas asignadas a los datos de sensor pueden usarse por el modelo de aprendizaje automático para refinar cómo el modelo de aprendizaje automático genera predicciones futuras, pueden mejorar la precisión del modelo de aprendizaje automático en la generación de futuras predicciones de accidentes.

20 La figura 20 es un diagrama de bloques de un proceso para predecir un accidente de vehículo de acuerdo con aspectos de la presente divulgación. En el bloque 2004, se detecta un evento de colisión asociado con un vehículo. Un dispositivo móvil dispuesto dentro del vehículo puede recopilar mediciones de sensor usando sensores del dispositivo móvil. Estas mediciones de sensor pueden procesarse y pasarse como entrada en un modelo de aprendizaje automático de predicción de colisión para generar una predicción de colisión. El modelo de aprendizaje automático de predicción de accidentes puede entrenarse para generar predicciones de accidentes usando mediciones de sensores (por ejemplo, mediciones de sensor sin procesar o mediciones de sensor procesadas tales como las descritas por el sistema de preprocesamiento 1312 de la figura 13). El modelo de aprendizaje automático de predicción de accidentes puede entrenarse usando aprendizaje supervisado, aprendizaje no supervisado o aprendizaje semisupervisado. El modelo de aprendizaje automático de predicción de colisión puede generar predicciones de colisión continuamente (tal como en intervalos regulares mientras el vehículo está en funcionamiento). En otros casos, se puede generar una predicción de colisión al detectar mediciones de sensor anómalas (por ejemplo, mediciones de sensor que superan un umbral o similares).

30 En el bloque 2008, se determina si el vehículo se ha detenido. Por ejemplo, el dispositivo móvil puede usar mediciones de sensor para predecir una velocidad del vehículo (en tiempo real, continuamente, en intervalos regulares, al detectar un evento tal como un evento de colisión o similar). Después de que se detecta el accidente, el dispositivo móvil puede determinar, después de un intervalo de tiempo predeterminado o distancia desde el evento de colisión, si la velocidad del vehículo es mayor que cero.

40 Si el vehículo aún está en movimiento, el proceso se mueve al bloque 2012 en el que se determina que no se produjo ninguna colisión (por ejemplo, el accidente de vehículo fue un falso positivo) y el proceso de la FIG. 20 vuelve al bloque 2004 y espera hasta que se detecta otra colisión o el vehículo ya no está en funcionamiento (por ejemplo, el viaje actual ha concluido).

45 Si el vehículo se detuviera, a continuación, el proceso se mueve al bloque 2016 en el que pueden generarse características a partir de las mediciones del sensor. Las características pueden incluir las características usadas por el modelo de aprendizaje automático para determinar el evento de colisión original en el bloque 2004. Las características también pueden incluir mediciones de sensor recopiladas o derivadas después del evento de colisión. Por ejemplo, las características pueden incluir una o más características de distancia correspondientes a la distancia que el coche recorrió después de que se produjera la colisión antes de detenerse como se describe en conexión con la figura 19. Las una o más características de distancia pueden derivarse multiplicando la velocidad media predicha en cada una de una o más ventanas de tiempo (por ejemplo, 30 segundos, 60 segundos, 120 segundos, 180 segundos y/o 300 segundos). Como alternativa o adicionalmente, se pueden derivar una o más características de distancia multiplicando la velocidad media predicha filtrada (por ejemplo, como se describe en la figura 17) a lo largo de cada una de una o más ventanas de tiempo (por ejemplo, 30 segundos, 60 segundos, 120 segundos, 180 segundos y/o 300 segundos).

55 Las características de distancia pueden proporcionar información adicional después del evento de colisión que puede proporcionar una indicación en cuanto a la gravedad de la colisión y si el movimiento del vehículo después de la colisión fue el resultado de un evento de colisión u otras actividades de conducción (por ejemplo, llegar a un destino, una señal de alto o un semáforo, tráfico, etc.). Por ejemplo, si el vehículo quedara inutilizado por la colisión, entonces el vehículo se detendría casi inmediatamente después de la colisión. Esto puede proporcionar una indicación de que el evento de colisión fue lo suficientemente grave como para inutilizar el vehículo (por ejemplo, no un mero "raspón"). Si el vehículo continúa conduciendo durante un breve periodo de tiempo antes de detenerse, entonces puede indicar que el evento de colisión no fue grave ya que el vehículo pudo continuar las operaciones. En otro ejemplo, las características de distancia (con otra información) pueden proporcionar una indicación de que la parada del vehículo se debió a un semáforo u otras operaciones de conducción de rutina, lo que puede proporcionar una indicación de que el evento de accidente en 2004 fue un falso positivo.

- En el bloque 2020, se puede ejecutar un modelo de aprendizaje automático de predicción de colisión usando las características de distancia generadas para generar una nueva predicción de colisión. En algunos casos, este modelo de aprendizaje automático de predicción de accidentes puede ser el mismo modelo de aprendizaje automático ejecutado en el bloque 2004. En otros casos, el modelo de aprendizaje automático de predicción de accidentes puede ser un segundo modelo de aprendizaje automático (diferente). En esos casos, el segundo modelo de aprendizaje automático puede entrenarse usando las mediciones de sensor con las características de distancia. El segundo modelo de aprendizaje automático puede entrenarse usando aprendizaje supervisado, aprendizaje no supervisado o aprendizaje semisupervisado.
- El modelo de aprendizaje automático de predicción de accidentes puede generar una nueva predicción de accidentes basándose en la información adicional de las características de distancia generadas. El modelo de aprendizaje automático de predicción de accidentes puede generar una probabilidad de que se haya producido un accidente en un tiempo particular. La probabilidad puede representarse por cualquier medio predeterminado (por ejemplo, un número entre 0 y 1, 1 y 100, un grado tal como A-F, etc.).
- En el bloque 2024, se determina si la nueva predicción de colisión es mayor que un umbral. En algunos casos, el umbral puede seleccionarse dinámicamente (en tiempo de ejecución). Las mediciones de sensor y/o la predicción de colisión original pueden usarse para establecer el umbral. El umbral puede ser diferente para cada evento de colisión. Por ejemplo, si el evento de colisión original indicaba una alta probabilidad (por ejemplo, 75-100 %) de que se produjo la colisión (aunque el automóvil continuó conduciendo), entonces el umbral puede establecerse a un valor más bajo. Como resultado, una nueva probabilidad de detección de colisión inferior satisfará el umbral e indicará que se ha producido la colisión. Esto permite que el sistema confíe parcialmente en los resultados de detección de colisión originales para determinar que se ha producido una colisión. Si la predicción de colisión original tenía una probabilidad más baja (por ejemplo, 50-75 %), entonces el umbral puede establecerse más alto para ser más sensible al potencial de un falso positivo. En otros casos, el umbral puede estar predeterminado. En esos casos, el umbral puede establecerse mediante un modelo de aprendizaje automático, tal como el modelo de aprendizaje automático de predicción de accidentes, el usuario, un comando desde un dispositivo remoto, o similares.
- En algunos casos, se pueden usar múltiples umbrales. Por ejemplo, si la predicción de colisión es mayor que un primer umbral, el proceso puede continuar hasta el bloque 2028. Si la predicción de colisión está entre un primer umbral y un segundo umbral, el proceso puede continuar preguntando en primer lugar a un usuario que confirme si se ha producido una colisión. Si el usuario confirma la colisión, entonces el proceso continúa hasta el bloque 2028. Si el usuario no confirma la colisión, entonces el proceso continúa hasta el bloque 2012. En algunos casos, si el usuario no responde dentro de un intervalo de tiempo predeterminado, se puede suponer una colisión. Por ejemplo, la colisión puede haber impedido que el usuario confirme debido a lesiones o daños en el dispositivo móvil. Como resultado, el proceso puede solicitar proactivamente servicios de emergencia o similares. Si la predicción de colisión es inferior al segundo umbral, entonces el proceso puede continuar hasta el bloque 2012. El primer umbral puede establecerse más alto que el segundo umbral. Por ejemplo, el primer umbral puede establecerse en 85 % y el segundo umbral puede establecerse en 65 %. El primer umbral y el segundo umbral pueden establecerse en cualquier valor predeterminado (o seleccionado dinámicamente) siempre que un umbral sea más alto que el otro umbral.
- Si, en el bloque 2024, se determina que la nueva predicción de colisión es mayor que el umbral, a continuación, el proceso cambia al bloque 2028 en el que se indica que se ha producido una colisión. En algunos casos, se pueden realizar una o más acciones como resultado de determinar que se ha producido la colisión, tal como, pero sin limitación, transmitir automáticamente una indicación de colisión al usuario del dispositivo móvil (por ejemplo, para iniciar un proceso de reclamaciones, determinar la seguridad de las personas involucradas en el accidente, recopilar información adicional sobre el accidente, para proporcionar información al usuario sobre qué hacer después de una colisión, para proporcionar información de seguridad, para proporcionar información de primeros auxilios, etc.), transmitir automáticamente una indicación de colisión a los servicios de emergencia, transmitir automáticamente una indicación de colisión al personal de seguros asociado con el vehículo o conductor, modificar un perfil de conducción del conductor para incluir la indicación de colisión y, opcionalmente, mediciones de sensor asociadas con la colisión, o similares.
- Si, en el bloque 2024, se determina que la nueva predicción de colisión no es mayor que el umbral, entonces el proceso continúa hasta el bloque 2012 en el que se indica que no se produjo una colisión. En algunos casos, las predicciones de colisión (por ejemplo, en 2004 y/o en 2020) pueden descartarse del sistema. En otros casos, tanto las predicciones de colisión como las mediciones de sensor que desencadenaron la predicción de colisión pueden descartarse o marcarse de otro modo para evitar el uso de las mediciones de sensor en otro análisis de datos. Dado que las mediciones del sensor provocaron al menos una predicción de colisión falsamente positiva, los datos pueden incluir mediciones de sensor anómalas que pueden no ser fiables incluso para otras operaciones de análisis (por ejemplo, determinar el comportamiento del conductor, tal como conducción distraída o similares). En otros casos más, la predicción de colisión puede conservarse y usarse adicionalmente para entrenar y/o refinar el modelo o modelos de aprendizaje automático de predicción de colisión.
- La figura 21 es un diagrama de flujo de ejemplo de un proceso para generar una predicción de colisión a una velocidad predicha de un vehículo de acuerdo con algunas realizaciones. El proceso comienza recibiendo, desde un dispositivo

móvil dispuesto dentro de un vehículo, un conjunto de mediciones de sensor (bloque 2104). El conjunto de mediciones de sensor puede incluir mediciones recibidas o derivadas de uno o más sensores del dispositivo móvil tales como, pero sin limitación, mediciones desde un acelerómetro, datos de actividad (por ejemplo, como se describe en la figura 12), mediciones desde un magnetómetro y/o mediciones desde uno o más sensores del dispositivo móvil. Las mediciones de sensor pueden recibirse a lo largo de un intervalo de tiempo o evento predeterminado. Por ejemplo, el conjunto de mediciones de sensor puede recibirse en tiempo real o en intervalos regulares tales como, pero sin limitación, cada medio segundo, cada segundo, cada cinco segundos, o cualquier intervalo predeterminado.

Como alternativa, el conjunto de mediciones de sensor puede recibirse (en tiempo real o en intervalos regulares) durante un viaje (por ejemplo, donde se está operando un vehículo para moverse desde una ubicación de inicio a una ubicación de destino). Por ejemplo, los datos de actividad pueden recopilarse desde el dispositivo móvil como se describe en conexión con la figura 12 anterior. Los datos de actividad pueden usarse para determinar cuándo comienza y finaliza una actividad tal como una conducción. Cuando el dispositivo móvil detecta que ha comenzado una conducción, el dispositivo móvil puede comenzar a recopilar el conjunto de mediciones de acelerómetro desde el acelerómetro del dispositivo móvil hasta que los datos de actividad (un usuario o comunicación remota), indiquen que la conducción ha terminado.

Alternativamente todavía, el conjunto de mediciones de sensor puede recibirse desde un dispositivo remoto tal como un acelerómetro remoto, un dispositivo móvil, un servidor o similar. El conjunto de mediciones de sensor puede incluir mediciones de sensor recopiladas durante la conducción. En algunos casos, el conjunto de mediciones de sensor puede recibirse después de que se haya terminado el accionamiento, tras la detección de un evento de colisión, tras la detección de otro evento, tras la expiración de un intervalo de tiempo, cuando las señales del sensor superan un umbral, o similares.

El proceso continúa convirtiendo el conjunto de mediciones de sensor en un dominio de frecuencia (bloque 2108). El conjunto de mediciones de sensor puede convertirse usando cualquier medio tal como una transformada de Fourier o similares. En algunos casos, esto puede realizarse por un modelo de aprendizaje automático entrenado para procesar señales de acelerómetro. El modelo de aprendizaje automático puede configurarse para realizar adicionalmente uno o más de los bloques 2112-2120.

El proceso continúa filtrando, con un filtro de paso de banda, el conjunto de mediciones de sensor para eliminar mediciones de sensor de alta frecuencia del conjunto de mediciones de sensor (bloque 2112). El filtro de paso de banda filtra una porción de las mediciones de sensor que se producen a frecuencias particulares. Por ejemplo, frecuencias asociadas con mediciones de sensor de ruido de señal que no corresponden al vehículo (por ejemplo, movimiento del dispositivo móvil independiente del movimiento del vehículo). En algunos casos, pueden filtrarse frecuencias que son mayores que una primera frecuencia umbral y menores que una segunda frecuencia umbral. El primer umbral puede ser, por ejemplo, aproximadamente 50 Hz y el segundo umbral puede ser, por ejemplo, aproximadamente 9 Hz. Los umbrales primero y segundo pueden seleccionarse mediante un proceso del dispositivo móvil (por ejemplo, tal como una aplicación de recopilación de datos, el sistema operativo, etc.), por un usuario, de una comunicación recibida desde un dispositivo remoto, o similares.

El proceso continúa definiendo una o más ventanas contiguas basándose en unas mediciones de sensor restantes en el conjunto de mediciones de sensor (bloque 2116). La definición de una o más ventanas contiguas del conjunto restante (filtrado) de mediciones de sensor puede realizarse como se describe por el bloque 1324 de la figura 13. Las ventanas contiguas pueden definirse para el intervalo de tiempo durante el cual se recibieron las señales de acelerómetro. Cada medición de acelerómetro puede corresponder a una ventana contigua basándose en el intervalo de tiempo representado por una ventana contigua y cuándo se generó la señal de acelerómetro por el acelerómetro.

Las una o más ventanas contiguas pueden definirse identificando una diferencia de tiempo entre cada par de señales de acelerómetro consecutivas (por ejemplo, cuando las señales fueron generadas por el acelerómetro). Se puede definir una ventana continua entre un primer par de mediciones de sensor consecutivas que es mayor que un umbral (por ejemplo, tres desviaciones estándar de la diferencia de tiempo media entre mediciones de acelerómetro consecutivas o similares) y el siguiente par de mediciones de sensor consecutivas que es mayor que el umbral. Dado que la diferencia de tiempo entre pares de mediciones de acelerómetro consecutivas varía, las ventanas contiguas pueden no tener la misma longitud. Cada ventana contigua incluye un intervalo de tiempo durante el cual se generó un subconjunto del conjunto restante de mediciones de sensor por el acelerómetro.

El proceso continúa generando, para cada ventana contigua, un conjunto de características remuestreando el subconjunto del conjunto restante de mediciones de sensor representadas por la ventana contigua a una o más frecuencias predefinidas (bloque 2116). El subconjunto del conjunto restante de mediciones de sensor puede volver a muestrearse como se describe por 1328 de la figura 13, que puede determinarse, por ejemplo, como una frecuencia de 9-50 Hz, por entrada de usuario, mediante una comunicación desde un dispositivo remoto, o similares.

El proceso continúa generando, para cada conjunto de características, una o más predicciones de velocidad ejecutando una red neuronal entrenada usando el conjunto de características. La red neuronal entrenada puede ser la red neuronal 1332 de la figura 13, la red neuronal 1500 de la figura 15 (por ejemplo, que puede ser lo mismo que la

red neuronal 1332), o una red neuronal diferente. La red neuronal puede entrenarse usando aprendizaje supervisado o no supervisado para generar una predicción de velocidad a partir de mediciones de sensor.

5 En algunos casos, las predicciones de velocidad pueden filtrarse para evitar que la confianza en el ruido de la señal o las señales del acelerómetro que no están asociadas con el vehículo produzcan predicciones de velocidad inexactas. Por ejemplo, las una o más predicciones de velocidad pueden filtrarse como se describe por el proceso de la figura 17.

10 El proceso continúa generando una predicción de colisión de vehículo usando las una o más predicciones de velocidad (bloque 2128). La generación de una predicción de colisión de vehículo a partir de una o más predicciones de velocidad puede realizarse como se describe por algunos o todos los bloques de la figura 20. Por ejemplo, una predicción de colisión de vehículo puede proporcionarse mediante un modelo de aprendizaje automático de predicción de colisión que indica que se ha producido un evento de colisión. La predicción de colisión de vehículo puede autenticarse usando la predicción de velocidad para determinar si el vehículo se detuvo después del evento de colisión. Si el vehículo no se detuvo, entonces la predicción de colisión puede definirse como falsa (por ejemplo, el evento de colisión no ocurrió). Si el vehículo se detuvo, entonces la predicción de colisión puede definirse como verdadera (por ejemplo, el evento de colisión ocurrió).

20 Para otro ejemplo, una predicción de colisión de vehículo puede proporcionarse mediante un modelo de aprendizaje automático de predicción de colisión que indica que se ha producido un evento de colisión. La predicción de colisión de vehículo puede autenticarse usando la predicción de velocidad para determinar si el vehículo se detuvo después del evento de colisión. La predicción de velocidad puede usarse para derivar características de distancia que indican si y/o cuándo el vehículo se detuvo después de una detección de colisión inicial. Las características de distancia pueden proporcionarse al modelo de aprendizaje automático de predicción de colisiones (por ejemplo, la red neuronal que proporcionó la predicción de velocidad, el mismo modelo de aprendizaje automático de predicción de colisiones que proporcionó la predicción de colisiones inicial, u otro modelo de aprendizaje automático de predicción de colisiones), que puede ejecutarse usando las características de distancia y (opcionalmente) las mediciones de sensor para proporcionar una detección de colisión final para generar una predicción de colisión final. La predicción de colisión final puede ser una probabilidad de que se haya producido una colisión (por ejemplo, entre 0-1, 0-100, un grado entre A-F, un booleano tal como verdadero o falso, o similares).

35 La probabilidad puede compararse con uno o más umbrales. Si la probabilidad es mayor que los uno o más umbrales, entonces se puede determinar que se produjo una colisión (por ejemplo, la predicción de colisión de vehículo puede definirse como verdadera). Si la probabilidad era menor que un primer umbral, pero mayor que un segundo umbral (si se utiliza), el dispositivo móvil puede desencadenar una notificación a un usuario u otro dispositivo (por ejemplo, tal como un servidor, un dispositivo informático a bordo del vehículo, otro dispositivo móvil, o similar) para solicitar información adicional y/o confirmación de si se produjo o no la colisión. El evento de colisión puede definirse basándose en la entrada del usuario como verdadero (por ejemplo, se produjo una colisión) o falso (por ejemplo, no se produjo la colisión). Si la probabilidad es menor que los uno o más umbrales, entonces se determina que no se produjo la colisión (por ejemplo, y la predicción de colisión de vehículo puede definirse como falsa).

El proceso continúa transmitiendo, a un dispositivo remoto, la predicción de colisión de vehículo (y/o predicción de colisión final) (bloque 2132).

45 En algunos casos, si se determina que se ha producido un accidente, el dispositivo móvil puede ejecutar una o más acciones. Los ejemplos de las una o más acciones incluyen, pero sin limitación, transmitir una notificación (por ejemplo, tal como una notificación de avance, un correo electrónico, una llamada automática, un mensaje de texto o similar) a los servicios de emergencia, iniciar un proceso de reclamaciones, transmitir una notificación al personal de seguros, transmitir una notificación a otro dispositivo móvil (por ejemplo, informar a un contacto de emergencia del conductor o pasajero, solicitar información adicional asociada con la colisión de otros ocupantes del vehículo u ocupantes de otros vehículos involucrados en la colisión, o similares), determinar la gravedad de la colisión, combinaciones de los mismos, o similares.

55 Si no se predice ningún accidente, el proceso puede volver al bloque 2104 en el que se puede recopilar un nuevo conjunto de mediciones de sensor. El nuevo conjunto de mediciones de sensor puede asociarse con otra porción del mismo viaje o de un viaje posterior.

60 La figura 22 es un diagrama de bloques de un proceso para autenticar una predicción de colisión de vehículo usando predicciones de velocidad de acuerdo con aspectos de la presente divulgación. El proceso comienza recibiendo, desde un dispositivo móvil dispuesto dentro de un vehículo, un conjunto de señales de sensor (bloque 2204). El conjunto de mediciones de sensor puede incluir mediciones recibidas o derivadas de uno o más sensores del dispositivo móvil tales como, pero sin limitación, mediciones desde un acelerómetro, datos de actividad (por ejemplo, como se describe en la figura 12), mediciones desde un magnetómetro y/o mediciones desde uno o más sensores del dispositivo móvil. Las mediciones de sensor pueden recibirse a lo largo de un intervalo de tiempo o evento predeterminado. Por ejemplo, 65 el conjunto de mediciones de sensor puede recibirse en tiempo real o a intervalos regulares.

Como alternativa, el conjunto de mediciones de sensor puede recibirse (en tiempo real o a intervalos regulares) durante un viaje (por ejemplo, donde se está operando un vehículo para moverse desde una ubicación de inicio a una ubicación de destino). Por ejemplo, los datos de actividad pueden recopilarse desde el dispositivo móvil como se describe en conexión con la figura 12 anterior. Los datos de actividad pueden usarse para determinar cuándo comienza y finaliza una actividad tal como una conducción. Cuando el dispositivo móvil detecta que ha comenzado una conducción, el dispositivo móvil puede comenzar a recopilar el conjunto de mediciones de acelerómetro desde el acelerómetro del dispositivo móvil hasta que los datos de actividad (un usuario o comunicación remota), indiquen que la conducción ha terminado.

5
10 Alternativamente todavía, el conjunto de mediciones de sensor puede recibirse desde un dispositivo remoto tal como un acelerómetro remoto, un dispositivo móvil, un servidor o similar. El conjunto de mediciones de sensor puede incluir mediciones de sensor recopiladas durante la conducción. En algunos casos, el conjunto de mediciones de sensor puede recibirse después de que se haya terminado el accionamiento, tras la detección de un evento de colisión, tras la detección de otro evento, tras la expiración de un intervalo de tiempo, cuando las señales del sensor superan un umbral, o similares.

15 El proceso continúa generando un conjunto de ventanas contiguas usando el conjunto de mediciones de sensor, en donde cada ventana contigua del conjunto de ventanas contiguas representa un subconjunto del conjunto de mediciones de sensor (bloque 2208). La definición de una o más ventanas contiguas a partir del conjunto de mediciones de sensor puede realizarse como se describe en el bloque 1312 de la figura 13. Las ventanas contiguas pueden definirse para el intervalo de tiempo durante el cual se recibieron las señales de acelerómetro. Cada ventana contigua puede representar un subconjunto del conjunto de mediciones de acelerómetro que se generaron por el acelerómetro durante un tiempo incluido en la ventana contigua.

20 Las una o más ventanas contiguas pueden definirse identificando una diferencia de tiempo entre cada par de señales de acelerómetro consecutivas (por ejemplo, cuando las señales fueron generadas por el acelerómetro). En algunos casos, las mediciones del sensor pueden procesarse antes de que se definan las ventanas contiguas, como el filtrado (por ejemplo, como se describe en 1316) y normalizar las mediciones de sensor restantes (por ejemplo, como se describe en 1320). Se puede definir una ventana contigua entre un primer par de mediciones de sensor consecutivas que es mayor que un umbral (por ejemplo, una o más desviaciones estándar de la diferencia de tiempo media entre mediciones de sensor consecutivas o similares) y el siguiente par de mediciones de sensor consecutivas que es mayor que el umbral. Dado que la diferencia de tiempo entre pares de señales de acelerómetro consecutivas varía, las ventanas contiguas pueden tener longitudes variables. Cada ventana contigua incluye un intervalo de tiempo durante el cual se generó un subconjunto del conjunto restante de mediciones de sensor por o derivado del sensor del dispositivo móvil.

25 El proceso continúa generando, para cada ventana contigua del conjunto de ventanas contiguas, una predicción de velocidad ejecutando una red neuronal entrenada usando el conjunto de ventanas contiguas (bloque 2212). Una o más características pueden derivarse de cada ventana contigua. Cada característica puede ser una entrada a la red neuronal entrenada. La red neuronal puede ser la red neuronal 1332 de la figura 13 o la red neuronal 1500 de la figura 15 o similares. La red neuronal entrenada puede ejecutarse usando el subconjunto del conjunto de mediciones de sensor que corresponde a cada ventana contigua para generar una o más predicciones de velocidad para la ventana contigua. Cada predicción de velocidad puede corresponder a un paso de tiempo (por ejemplo, un tiempo particular dentro de la ventana contigua). En algunos casos, la red neuronal puede generar un conjunto de predicciones de velocidad, una predicción de velocidad para cada paso de tiempo de la ventana contigua.

30 El proceso continúa recibiendo una indicación de que el vehículo está implicado en un evento de colisión (bloque 2216). La indicación del evento de colisión puede determinarse por el dispositivo móvil a partir de las mediciones de sensor. Por ejemplo, puede ejecutarse un modelo de aprendizaje automático de predicción de colisión para generar una predicción de colisión usando las mediciones de sensor. El modelo de aprendizaje automático de predicción de accidentes puede ser la red neuronal o un modelo separado. En algunos casos, la indicación del evento de colisión puede recibirse desde un dispositivo remoto. Por ejemplo, las mediciones del sensor pueden transmitirse a un dispositivo remoto. El dispositivo remoto puede ejecutar el modelo de aprendizaje automático de predicción de accidentes para generar una predicción de accidentes. El dispositivo remoto puede a continuación transmitir la indicación de un evento de colisión de vuelta al dispositivo móvil.

35 El proceso continúa autenticando el evento de colisión usando la predicción de velocidad (bloque 2220). La predicción de colisión puede autenticarse mediante uno o más de los procesos descritos en la figura 20. En algunos ejemplos, autenticar el evento de colisión puede incluir determinar, usando la predicción de velocidad, si el vehículo continuó conduciendo después del evento de colisión. El dispositivo móvil puede usar múltiples ventanas de tiempo (por ejemplo, 30 segundos, 60 segundos, 120 segundos, 180 segundos, 300 segundos, etc.) y determinar si y/o cuándo el vehículo se detuvo con cada ventana de tiempo. Si el vehículo no se detuvo, entonces se puede determinar que la indicación del evento de colisión fue un falso positivo (por ejemplo, no se produjo ningún evento de colisión).

65 En otros ejemplos, autenticar el evento de colisión puede incluir determinar, usando la predicción de velocidad, si el vehículo continuó conduciendo después del evento de colisión. Si se determinó que el vehículo se detuvo después del

evento de colisión, las características de distancia pueden derivarse de las predicciones de velocidad y las ventanas de tiempo. Las características de distancia pueden indicar si y/o cuándo el vehículo se detuvo después de una detección de colisión inicial y a qué distancia del evento de colisión. Las características de distancia pueden proporcionarse al modelo de aprendizaje automático de predicción de colisiones (por ejemplo, la red neuronal que proporcionó la predicción de velocidad, el mismo modelo de aprendizaje automático de predicción de colisiones que proporcionó la predicción de colisiones inicial, u otro modelo de aprendizaje automático de predicción de colisiones), que puede ejecutarse usando las características de distancia y (opcionalmente) las mediciones de sensor para generar una predicción de colisión actualizada. La predicción de colisión actualizada puede ser una probabilidad de que se haya producido una colisión (por ejemplo, entre 0-1, 0-100, un grado entre A-F, un booleano tal como verdadero o falso, o similares).

La probabilidad puede compararse con uno o más umbrales. Si la probabilidad es mayor que los uno o más umbrales, entonces se puede determinar que se produjo un evento de colisión. Si la probabilidad era menor que un primer umbral, pero mayor que un segundo umbral (si se utiliza), el dispositivo móvil puede desencadenar una notificación a un usuario u otro dispositivo (por ejemplo, tal como un servidor, un dispositivo informático a bordo del vehículo, otro dispositivo móvil, o similar) para solicitar información adicional y/o confirmación de si se produjo o no la colisión. El evento de colisión puede definirse basándose en la entrada del usuario como verdadero (por ejemplo, se produjo una colisión) o falso (por ejemplo, no se produjo la colisión). Si la probabilidad es menor que los uno o más umbrales, entonces se determina que no se produjo la colisión.

El proceso continúa determinando, basándose en la autenticación del evento de colisión de que no se produjo el evento de colisión (bloque 2228).

El proceso continúa purgando, en respuesta a la determinación de que no se produjo el evento de colisión, el evento de colisión de la memoria. En algún caso, purgar el evento de colisión de la memoria puede incluir purgar la memoria local del dispositivo móvil. En otros casos, el evento de colisión de la memoria puede incluir la depuración de la memoria de uno o más dispositivos remotos (por ejemplo, otros dispositivos móviles, servidores) que pueden configurarse para procesar mediciones de sensor del dispositivo móvil, proporcionar predicciones de velocidad usando mediciones de sensor del dispositivo móvil, proporcionar predicciones de colisión usando mediciones de sensor del dispositivo móvil, o similares.

Los procesos de los bloques 2204-2224 pueden continuar recibiendo mediciones de sensor y, al recibir otra indicación de un posible evento de colisión, autenticar el evento de colisión.

La figura 23 es un gráfico de ejemplo de velocidad predicha a lo largo del tiempo que representa una predicción de colisión positiva verdadera de acuerdo con aspectos de la presente divulgación. El gráfico 2300 representa la velocidad predicha de un vehículo durante un recorrido 2304 (en gris) y la velocidad real del vehículo 2308 (en negro). En 2312 (T=2840), una predicción de colisión indica la ocurrencia de un posible evento de colisión. Después de 2312, la velocidad predicha del vehículo (y la velocidad real) se reducen a aproximadamente cero, lo que indica que el vehículo se detuvo después del posible evento de colisión. Dado que el vehículo se detuvo después del evento de colisión, es más probable que el posible evento de colisión sea un verdadero positivo (por ejemplo, se produjo el accidente).

La figura 24 es un gráfico de ejemplo de velocidad predicha a lo largo del tiempo que representa una predicción de colisión falsamente positiva de acuerdo con aspectos de la presente divulgación. El gráfico 2400 representa la velocidad predicha de un vehículo durante un recorrido 2404 (en gris) y la velocidad real del vehículo 2408 (en negro). En 2412 (T=6200), la velocidad predicha del vehículo es de aproximadamente 36 mph cuando una predicción de colisión indica la ocurrencia de un posible evento de colisión. Después de 2412, la velocidad predicha del vehículo (y la velocidad real) no cambia, sino que continúa a 36 mph. Dado que el vehículo no se detuvo después del evento de colisión, es más probable que el posible evento de colisión sea un falso positivo (por ejemplo, no se produjo ningún evento de colisión). Como resultado, la predicción de colisión puede purgarse de la memoria local.

Se proporcionan detalles específicos en la siguiente descripción para proporcionar una comprensión completa de las realizaciones. Sin embargo, un experto en la materia entenderá que las realizaciones pueden ponerse en práctica sin estos detalles específicos. Por ejemplo, circuitos, sistemas, redes, procesos y otros componentes pueden mostrarse como componentes en forma de diagrama de bloques para no oscurecer las realizaciones con detalles innecesarios. En otros casos, los circuitos bien conocidos, los procesos, los algoritmos, las estructuras y las técnicas pueden mostrarse sin detalles innecesarios para evitar oscurecer las realizaciones.

También, se observa que las realizaciones individuales pueden describirse como un proceso que se representa como un diagrama esquemático, un diagrama de flujo, un diagrama de flujo de datos, un diagrama de estructura o un diagrama de bloques. Aunque un diagrama de flujo puede describir las operaciones como un proceso secuencial, muchas de las operaciones se pueden realizar en paralelo o simultáneamente. Adicionalmente, el orden de las operaciones puede reorganizarse. Un proceso se termina cuando se completan sus operaciones, pero podría tener etapas adicionales no incluidas en una figura. Un proceso puede corresponder a un método, una función, un procedimiento, una subrutina, un subprograma, etc. Cuando un proceso corresponde a una función, su terminación puede corresponder a un retorno de la función a la función de llamada o la función principal.

La implementación de las técnicas, bloques, etapas y medios descritos anteriormente se puede realizar de diversas maneras. Por ejemplo, estas técnicas, bloques, etapas y medios pueden implementarse en hardware, software, o una combinación de los mismos. Para una implementación de hardware, las unidades de procesamiento pueden implementarse dentro de uno o más circuitos integrados específicos de la aplicación (ASIC), procesadores de señales digitales (DSP), dispositivos de procesamiento de señales digitales (DSPD), dispositivos lógicos programables (LAD), matrices de puertas programables en campo (FPGA), matriz de puertas programables de máscara (MPGA), procesadores, controladores, microcontroladores, microprocesadores, otras unidades electrónicas diseñadas para realizar las funciones descritas anteriormente, y/o combinaciones de las mismas.

También, se observa que las realizaciones y/o ejemplos pueden describirse como un proceso que se representa como un diagrama de flujo, un diagrama de flujo, un diagrama de carril, un diagrama de flujo de datos, un diagrama de estructura o un diagrama de bloques. Aunque una representación puede describir las operaciones como un proceso secuencial, muchas de las operaciones se pueden realizar en paralelo o simultáneamente. Adicionalmente, una o más de las operaciones pueden realizarse fuera de orden del orden representado. Un proceso puede terminar cuando se completan sus operaciones o volver a una etapa o bloque anterior. Un proceso podría tener etapas o bloques adicionales no incluidos en la figura. Un proceso puede corresponder a un método, una función, un procedimiento, una subrutina, un subprograma, etc. Cuando un proceso corresponde a una función, su terminación corresponde a un retorno de la función a una función de llamada o una función principal.

Asimismo, los dispositivos y/o sistemas descritos en el presente documento pueden implementarse por hardware, software, lenguajes de cifrado, firmware, middleware, microcódigo, lenguajes de descripción de hardware y/o cualquier combinación de los mismos. Cuando se implementa en software, firmware, middleware, lenguaje de secuencias de comandos y/o microcódigo, el código o segmentos de código de programa para realizar las tareas necesarias pueden almacenarse en un medio legible por ordenador no transitorio tal como un medio de almacenamiento. Un segmento de código o una instrucción ejecutable por máquina puede representar un procedimiento, una función, un subprograma, un programa, una rutina, una subrutina, un módulo, un paquete de software, un cifrado, una clase, o cualquier combinación de instrucciones, estructuras de datos y/o sentencias de programa. Un segmento de código puede acoplarse a otro segmento de código o un circuito de hardware pasando y/o recibiendo información, datos, argumentos, parámetros y/o contenidos de memoria. Información, argumentos, parámetros, datos, etc. pueden pasarse, reenviarse o transmitirse a través de cualquier medio adecuado, incluido el uso compartido de memoria, paso de mensajes, paso de testigos, transmisión de red, etc.

Para una implementación de firmware y/o software, las metodologías pueden implementarse con módulos (por ejemplo, procedimientos, funciones, etc.) que realizan las funciones descritas en el presente documento. Cualquier medio legible por ordenador no transitorio que incorpore tangiblemente instrucciones puede usarse para implementar las metodologías descritas en el presente documento. Por ejemplo, los códigos de software pueden almacenarse en una memoria. La memoria puede implementarse dentro del procesador o externa al procesador. Tal como se utiliza en el presente documento, el término "memoria" se refiere a cualquier tipo de medio de almacenamiento volátil, no volátil u otro medio de almacenamiento y no debe limitarse a ningún tipo particular de memoria o número de memorias, o tipo de medio en el que se almacena la memoria.

Además, como se divulga en el presente documento, la expresión "medio de almacenamiento" puede representar una o más memorias para almacenar datos, incluyendo memoria de solo lectura (ROM), memoria de acceso aleatorio (RAM), RAM magnética, memoria caché, medios de almacenamiento de disco magnético, medios de almacenamiento óptico, dispositivos de memoria flash y/u otros medios legibles por máquina para almacenar información. La expresión "medio legible por ordenador" incluye, pero sin limitación, dispositivos de almacenamiento portátiles o fijos, dispositivos de almacenamiento óptico y/u otros diversos medios de almacenamiento capaces de almacenar que contienen o transportan instrucción(es) y/o datos.

Los ejemplos y realizaciones descritos en el presente documento son solo para fines ilustrativos. Diversas modificaciones o cambios a la luz de la misma serán evidentes para los expertos en la materia.

REIVINDICACIONES

1. Un método que comprende:

5 recibir, desde un dispositivo móvil dispuesto dentro de un vehículo, un conjunto de mediciones de sensor de un acelerómetro;
 convertir el conjunto de mediciones de sensor en un dominio de frecuencia;
 filtrar, con un filtro de paso de banda, el conjunto de mediciones de sensor para eliminar mediciones de sensor de alta frecuencia del conjunto de mediciones de sensor;
 10 definir un conjunto de ventanas contiguas basándose en unas mediciones de sensor restantes en el conjunto de mediciones de sensor, representando cada ventana contigua del conjunto de ventanas contiguas una porción contigua de las mediciones de sensor restantes en el conjunto de mediciones de sensor;
 generar, para cada ventana contigua del conjunto de ventanas contiguas, un conjunto de características remuestreando las mediciones de sensor de la ventana contigua en una o más frecuencias predefinidas;
 15 generar una predicción de velocidad ejecutando una red neuronal entrenada usando el conjunto de características;
 generar una predicción de colisión de vehículo usando la predicción de velocidad; y
 transmitir, a un dispositivo remoto, la predicción de colisión de vehículo.

20 2. El método de la reivindicación 1, en donde generar la predicción de colisión de vehículo usando la predicción de velocidad incluye:
 determinar, basándose en la predicción de velocidad, si el vehículo se detuvo después del evento de colisión.

3. El método de la reivindicación 1, en donde al menos dos ventanas contiguas del conjunto de ventanas contiguas representan una cantidad diferente de las mediciones de sensor restantes en el conjunto de mediciones de sensor.

25 4. El método de la reivindicación 1, en donde la red neuronal entrenada es una red neuronal convolucional con una o más convoluciones dilatadas.

30 5. El método de la reivindicación 1, en donde definir el conjunto de ventanas contiguas incluye:
 derivar, para cada señal de aceleración en el conjunto de mediciones de sensor, una diferencia de tiempo entre cuándo se recopiló cada par de mediciones de sensor consecutivas;
 definir una primera ventana contigua del conjunto de ventanas contiguas que comienza en un primer tiempo en el que una primera diferencia de tiempo entre un primer par de mediciones de sensor consecutivas supera un umbral
 35 y termina en un segundo tiempo después del cual una segunda diferencia de tiempo entre un segundo par de mediciones de sensor consecutivas supera el umbral, en donde el segundo tiempo se produce después del primer tiempo.

40 6. El método de la reivindicación 5, en donde el umbral es igual a una o más desviaciones estándar de una diferencia de tiempo media entre cada par de mediciones de sensor consecutivas.

7. El método de la reivindicación 1, en donde generar la predicción de colisión de vehículo usando la predicción de velocidad incluye:

45 ejecutar un modelo de aprendizaje automático de predicción de colisión usando el conjunto de mediciones de sensor para generar una primera predicción de colisión de vehículo, indicando la primera predicción de colisión de vehículo un evento de colisión ocurrido en un primer tiempo;
 determinar, en un tiempo posterior a la predicción de colisión de vehículo, que la predicción de velocidad es mayor que cero;
 50 determinar, basándose en la determinación de que una velocidad del vehículo es mayor que cero, que no se produjo el evento de colisión; y
 definir la predicción de colisión de vehículo para indicar que no se produjo el evento de colisión.

55 8. El método de la reivindicación 1, en donde generar la predicción de colisión de vehículo usando la predicción de velocidad incluye:

ejecutar un modelo de aprendizaje automático de predicción de colisión usando el conjunto de mediciones de sensor para generar una primera predicción de colisión de vehículo, indicando la primera predicción de colisión de vehículo un evento de colisión ocurrido en un primer tiempo;
 60 determinar, en un tiempo posterior a la primera predicción de colisión de vehículo, que el vehículo se detuvo después del primer tiempo;
 generar, usando la predicción de velocidad, un conjunto de características de distancia, correspondiendo cada característica de distancia del conjunto de características de distancia a una posición del vehículo en relación con el evento de colisión; y
 65 definir la predicción de colisión de vehículo para que sea una salida de una segunda ejecución del modelo de aprendizaje automático de predicción de colisión usando el conjunto de mediciones de sensor y el conjunto de

características de distancia.

9. Un método que comprende:

5 recibir, desde un dispositivo móvil dispuesto dentro de un vehículo, un conjunto de mediciones de sensor de un acelerómetro;
 generar un conjunto de ventanas contiguas usando el conjunto de mediciones de sensor, en donde cada ventana contigua del conjunto de ventanas contiguas representa un subconjunto del conjunto de mediciones de sensor;
 10 generar, para cada una de las ventanas contiguas del conjunto de ventanas contiguas, una predicción de velocidad ejecutando una red neuronal entrenada usando el conjunto de ventanas contiguas;
 recibir una indicación de que el vehículo está involucrado en un evento de colisión;
 autenticar el evento de colisión usando la predicción de velocidad;
 determinar, basándose en la autenticación del evento de colisión, que no se produjo el evento de colisión; y
 15 purgar, en respuesta a la determinación de que no se produjo el evento de colisión, el evento de colisión de la memoria.

10. El método de la reivindicación 9, en donde al menos dos ventanas contiguas del conjunto de ventanas contiguas representan una cantidad diferente de mediciones de sensor en el conjunto de mediciones de sensor.

20 11. El método de la reivindicación 9, en donde la red neuronal entrenada es una red neuronal convolucional con una o más convoluciones dilatadas.

12. El método de la reivindicación 9, en donde autenticar el evento de colisión usando la predicción de velocidad incluye:

25 determinar si el vehículo se detuvo después del evento de colisión, en donde se determina que el evento de colisión no se ha producido al determinar que el vehículo no se detuvo.

13. El método de la reivindicación 9, en donde autenticar el evento de colisión usando la predicción de velocidad incluye:

30 determinar que el vehículo se detuvo a una distancia del evento de colisión;
 generar una o más características de distancia que representan la distancia desde el evento de colisión.
 ejecutar un modelo de aprendizaje automático de predicción de colisión usando el conjunto de mediciones de sensor y las características de distancia para generar una predicción de colisión de vehículo; y
 35 determinar que la predicción de colisión de vehículo es menor que un umbral, en donde determinar que la predicción de colisión de vehículo es menor que el umbral indica que no se produjo el evento de colisión.

14. El método de la reivindicación 1 o 9, en donde el conjunto de mediciones de sensor incluye datos de actividad.

40 15. Un dispositivo móvil que comprende:

uno o más procesadores;
 un acelerómetro; y
 un medio legible por ordenador no transitorio que almacena instrucciones, que, cuando se ejecutan por los uno o
 45 más procesadores, hacen que los uno o más procesadores realicen el método de cualquiera de las reivindicaciones 1-14.




FIG. 1

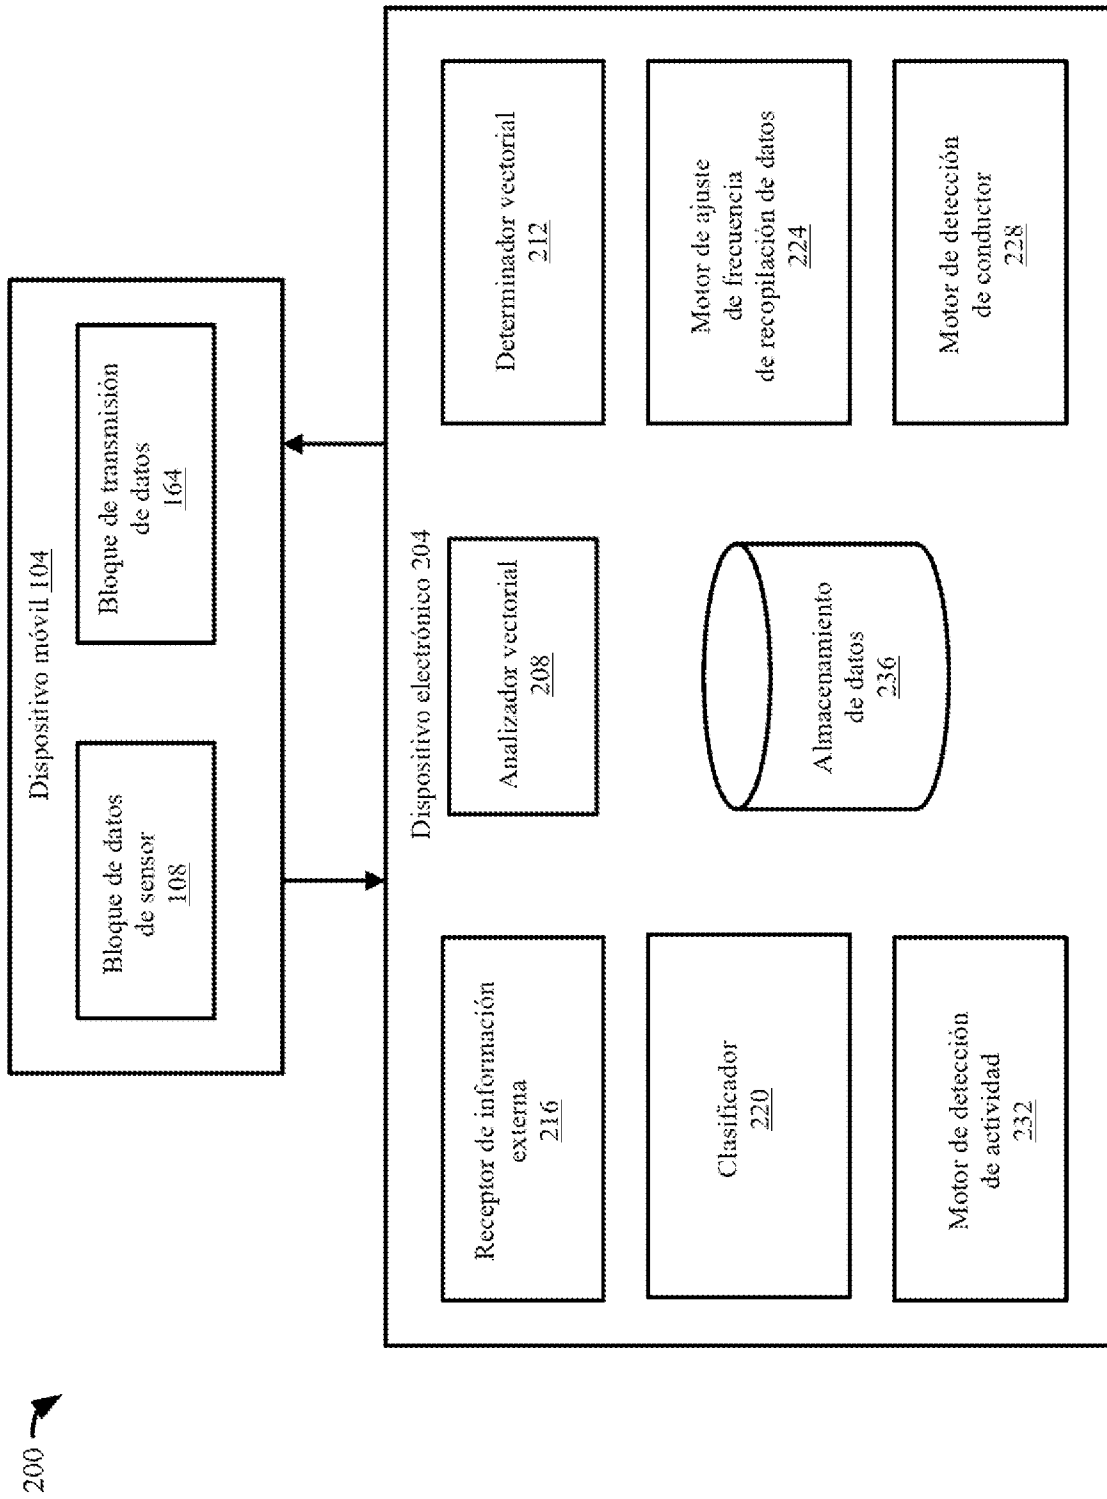


FIG. 2




FIG. 3




FIG. 4




FIG. 5

600 ↘

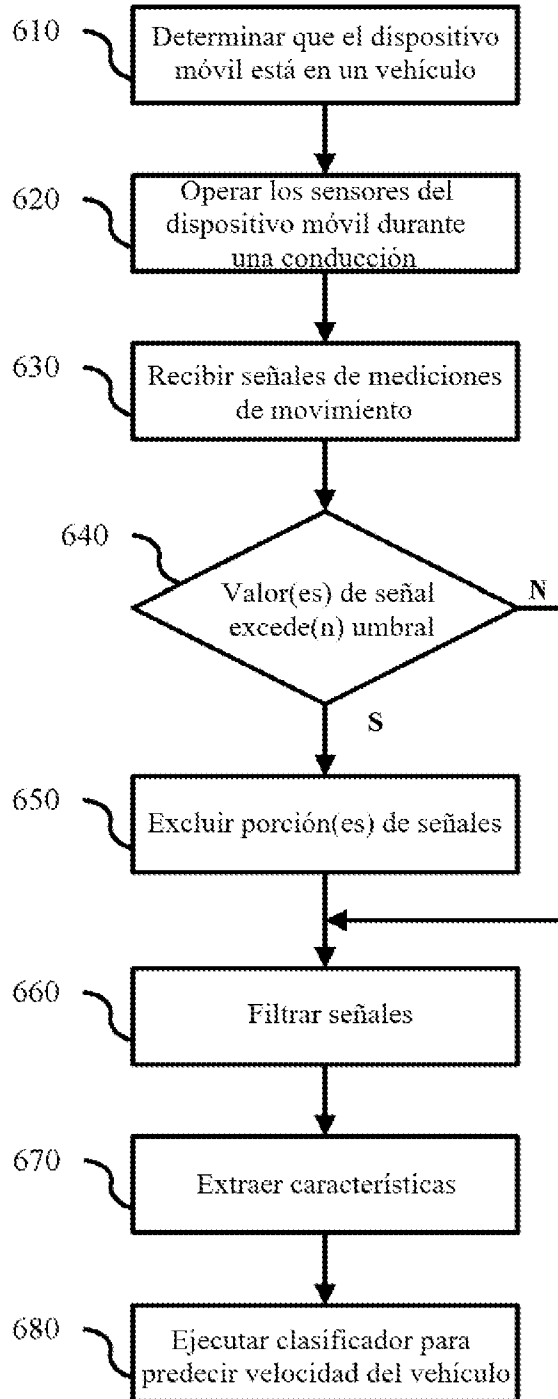


FIG. 6




FIG. 7




FIG. 8

900




FIG. 9




FIG. 10




FIG. 11A





FIG. 11B



Predicciones de falsos positivos por 19 312,13 km (12 000 millas) conducidos

FIG. 11C




FIG. 11D




FIG. 12

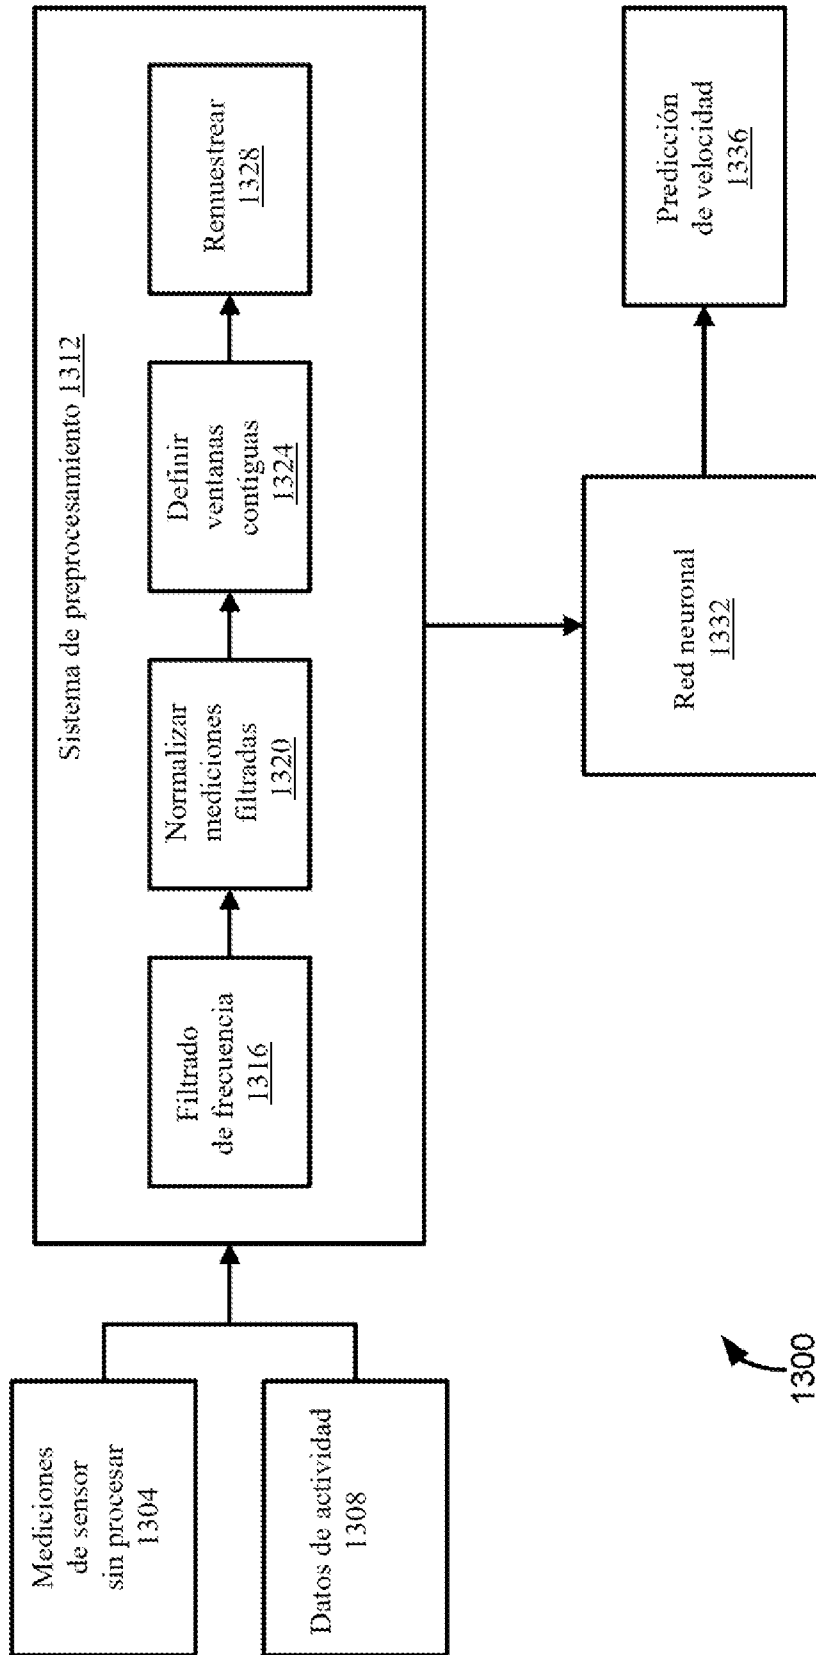


FIG. 13




FIG. 14




FIG. 15

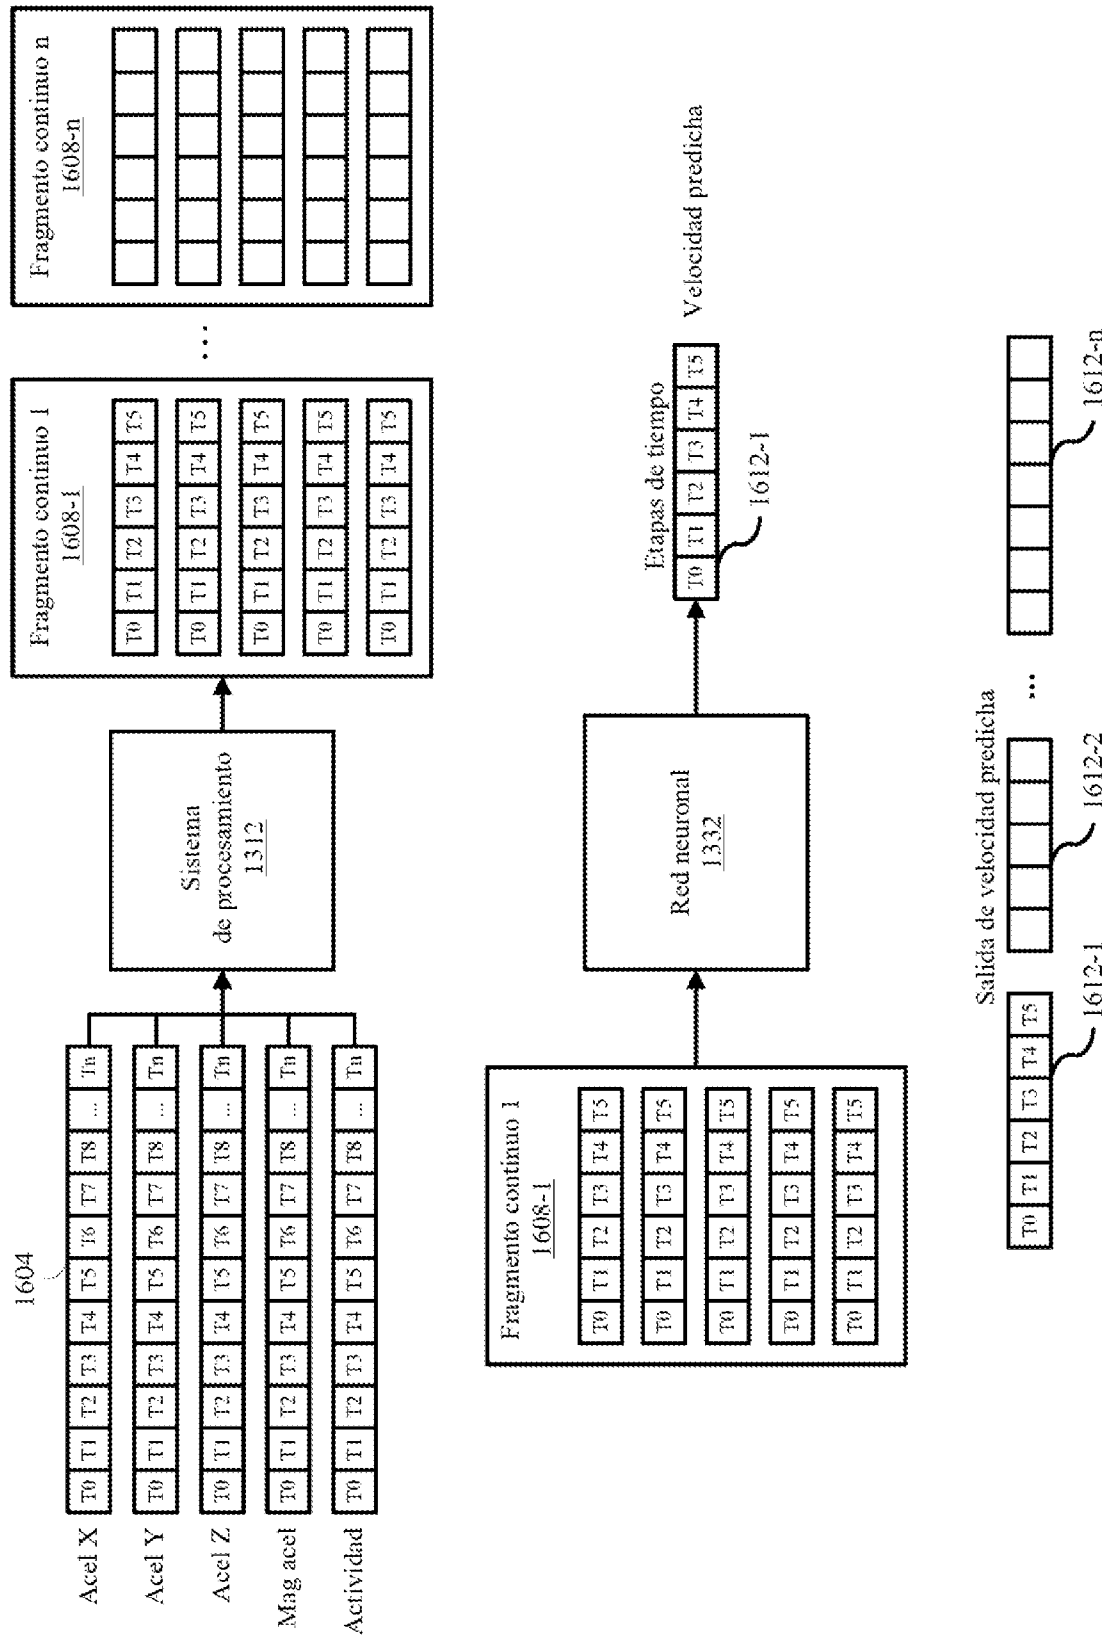


FIG. 16

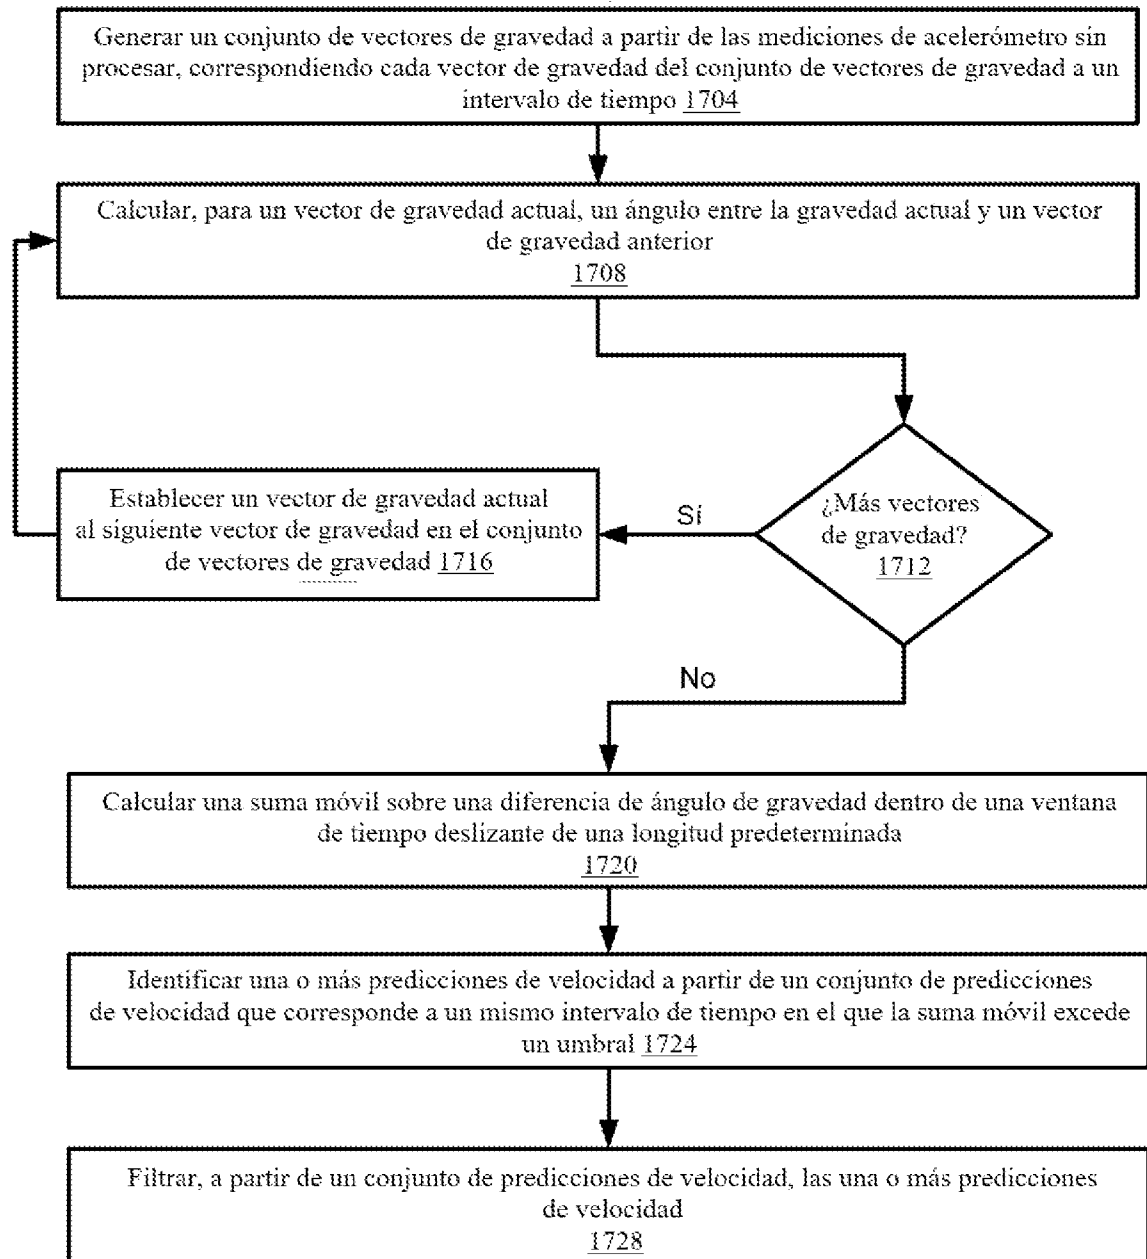


FIG. 17




FIG. 18




FIG. 19

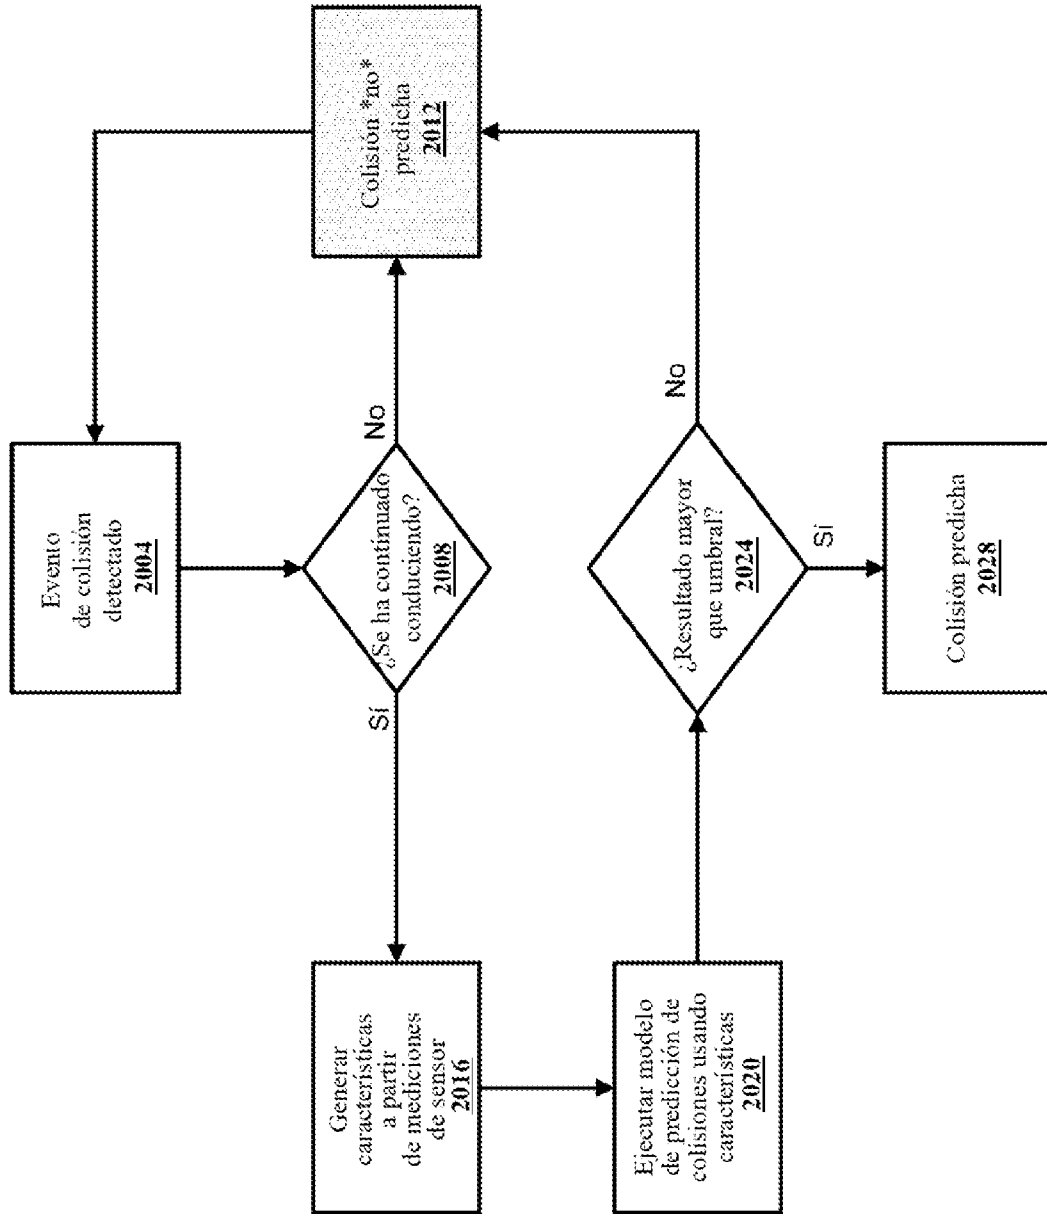


FIG. 20

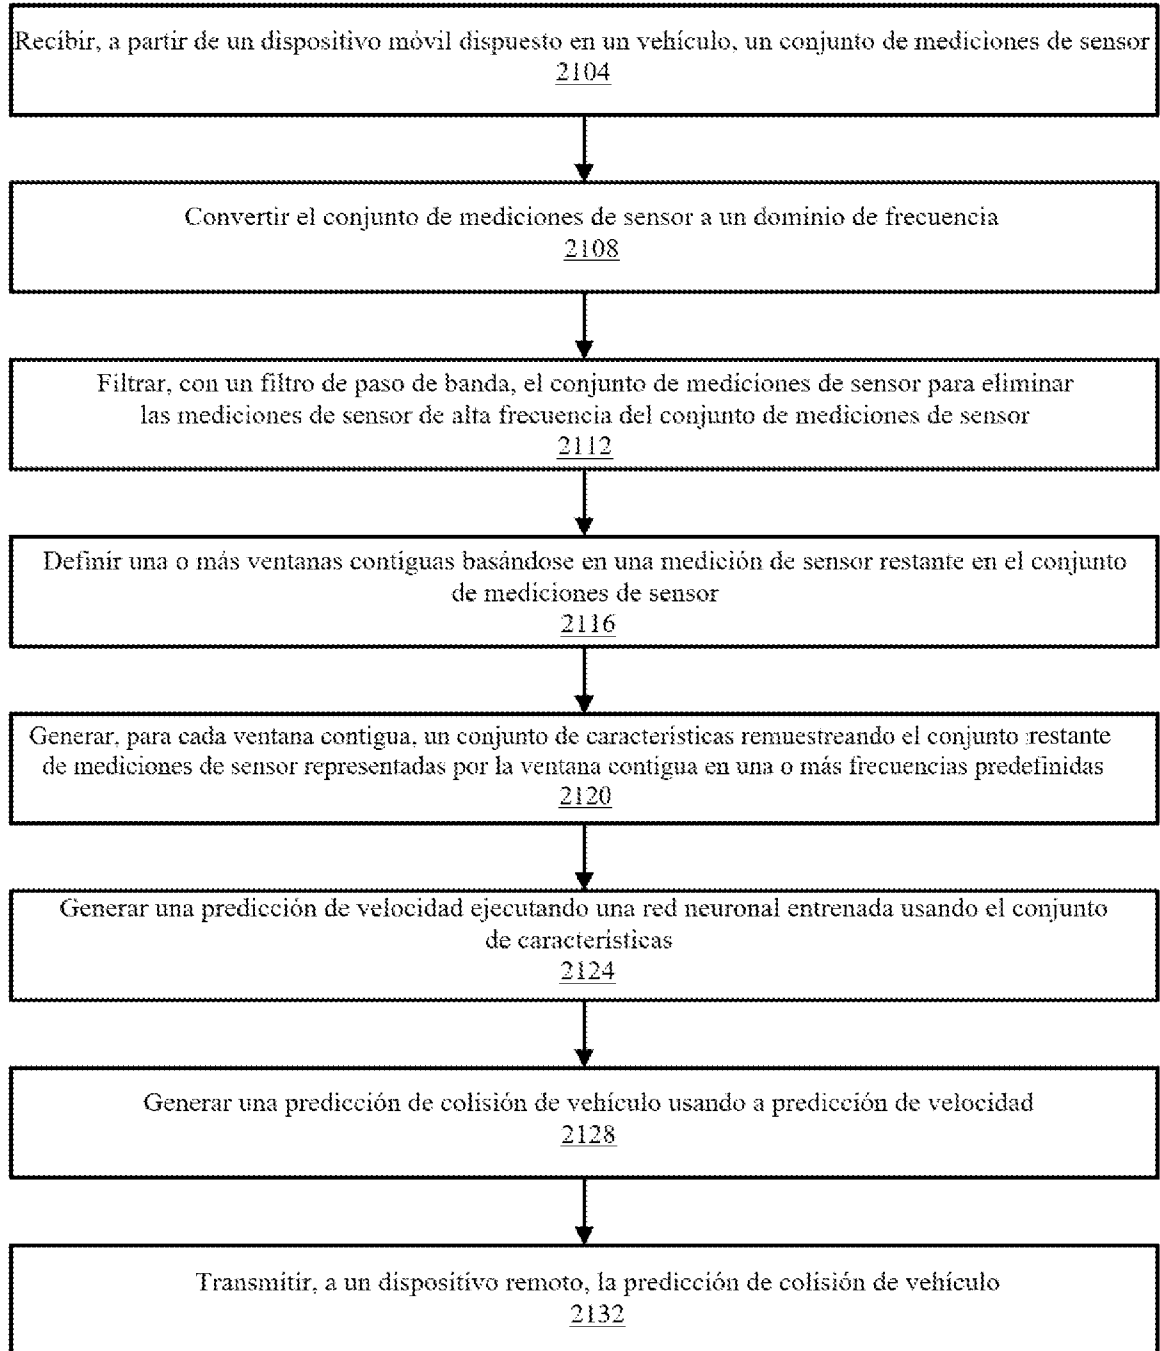


FIG. 21

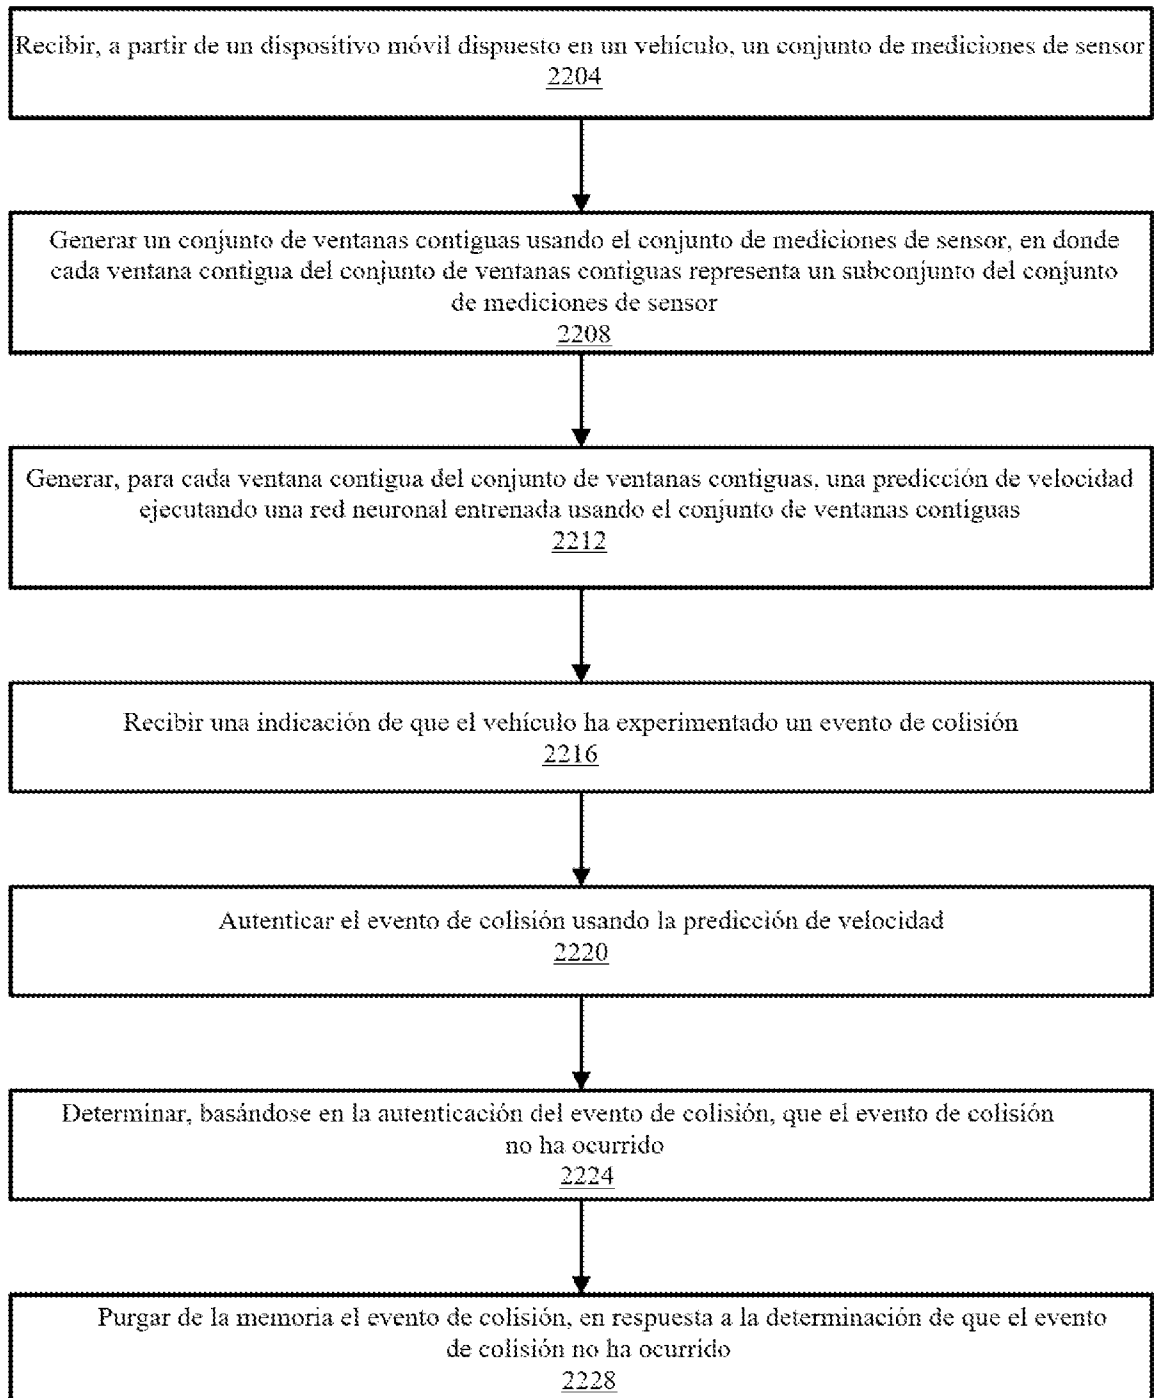




FIG. 22



2300

FIG. 23



2400

FIG. 24