

(19)日本国特許庁(JP)

(12)公開特許公報(A)

(11)公開番号

特開2022-16419

(P2022-16419A)

(43)公開日 令和4年1月21日(2022.1.21)

(51)国際特許分類	F I	テーマコード(参考)
G 0 8 G 1/16 (2006.01)	G 0 8 G 1/16 C	5 H 1 8 1
G 0 6 T 7/00 (2017.01)	G 0 6 T 7/00 3 5 0 C	5 H 3 0 1
G 0 5 D 1/02 (2020.01)	G 0 5 D 1/02 H	5 L 0 9 6

審査請求 未請求 請求項の数 15 O L 外国語出願 (全58頁)

(21)出願番号 特願2021-114281(P2021-114281)	(71)出願人 521295642 北京函森未来科技有限公司 中国北京市朝阳区亮馬橋路56号
(22)出願日 令和3年7月9日(2021.7.9)	
(31)優先権主張番号 202010658245.9	(74)代理人 100168583 弁理士 前井 宏之
(32)優先日 令和2年7月9日(2020.7.9)	(72)発明者 何 皓 中国北京市朝阳区亮馬橋路56号 北京 函森未来科技有限公司内
(33)優先権主張国・地域又は機関 中国(CN)	(72)発明者 王 乃岩 中国北京市朝阳区亮馬橋路56号 北京 函森未来科技有限公司内
	F ターム(参考) 5H181 AA01 AA27 BB20 CC03 CC04 CC11 CC12 CC14 FF04 FF10 FF14 FF22 FF27 LL04

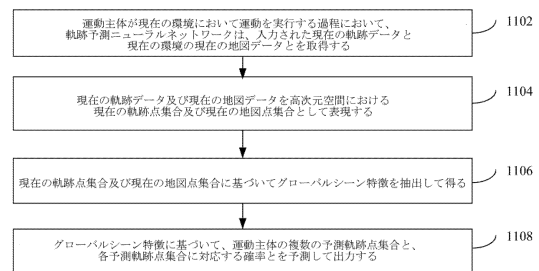
最終頁に続く

(54)【発明の名称】 軌跡予測方法及び装置

(57)【要約】 (修正有)【課題】特徴抽出の精度を著しく高めることができる軌跡予測方法を提供する。

【解決手段】運動主体が現在の環境において運動を実行する過程において、軌跡予測ニューラルネットワークは、入力された現在の軌跡データと現在の環境の現在の地図データとを取得して高次元空間における現在の軌跡点集合及び現在の地図点集合として表現し、現在の軌跡点集合及び現在の地図点集合に基づいて、現在の環境の地図特徴及び軌跡特徴を有するグローバルシーン特徴を抽出して得て、グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合と、各予測軌跡点集合に対応する確率とを予測して出力する。

【選択図】図1



## 【特許請求の範囲】

## 【請求項 1】

現在の軌跡データ及び現在の地図データを取得することと、  
現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現することと、  
現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を抽出して得ることと、  
グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合と、各予測軌跡点集合に対応する確率とを予測して出力することとを含み、  
現在の軌跡データは、運動主体と、現在の環境における他の1つ又は複数の運動物体との過去の所定時間帯での複数の軌跡点を含み、各軌跡点は1つの対応する時点における空間位置を含み、現在の地図データは該所定時間帯での現在の環境における道路要素の複数の地図点の空間位置を含む、軌跡予測方法。

10

## 【請求項 2】

現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現することは、  
所定の無順序の軌跡データのフォーマットで現在の軌跡点集合を表現し、無順序の現在の軌跡点集合を得ることと、  
所定の無順序の地図データのフォーマットで現在の地図点集合を表現し、無順序の現在の地図点集合を得ることと、  
を含む、請求項 1 に記載の軌跡予測方法。

20

## 【請求項 3】

現在の軌跡点集合は、現在の軌跡データの各軌跡点に対応する高次元軌跡点を含み、  
現在の地図点集合は、現在の地図データの各地図点に対応する高次元地図点を含む、  
請求項 1 又は 2 に記載の軌跡予測方法。

## 【請求項 4】

現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を抽出して得ることは、  
現在の軌跡点集合を所定の高次元空間に埋め込んで高次元軌跡点特徴を得て、現在の地図点集合を所定の高次元空間に埋め込んで高次元地図点特徴を得ることと、  
現在の軌跡点集合、現在の地図点集合、高次元軌跡点特徴及び高次元地図点特徴に基づいてローカルシーン特徴を取得して得ることと、  
ローカルシーン特徴及び高次元地図点特徴に対してそれぞれグローバル特徴抽出操作を実行して、グローバル軌跡特徴及びグローバル地図特徴を抽出して得ることと、  
グローバル軌跡特徴及びグローバル地図特徴に基づいてグローバルシーン特徴を決定して得ることと、  
を含む、請求項 1 から 3 のいずれか 1 項に記載の軌跡予測方法。

30

## 【請求項 5】

現在の軌跡点集合、現在の地図点集合、高次元軌跡点特徴及び高次元地図点特徴に基づいてローカルシーン特徴を取得して得ることは、  
現在の軌跡点集合及び現在の地図点集合に基づいて、各高次元軌跡点と該高次元軌跡点の周りの所定の複数の高次元地図点との間の複数の相対的な空間関係を決定して得ることと、  
1 つの高次元軌跡点に対応する各相対的な空間関係を高次元空間にそれぞれ埋め込んで高次元地図空間関係を得て、各高次元地図空間関係と、対応する高次元地図点特徴とのドット積を行って 1 つの加重地図特徴を得て、該高次元軌跡点の複数の加重地図特徴に対して最大化処理を行って最大加重地図特徴を選択して得ることと、  
最大加重地図特徴と、該高次元軌跡点に対応する高次元軌跡点特徴とを加算してローカルシーン特徴を得ることと、  
を含む、請求項 4 に記載の軌跡予測方法。

40

50

## 【請求項 6】

現在の軌跡点集合及び現在の地図点集合に基づいて、各高次元軌跡点と該高次元軌跡点の周りの所定の複数の高次元地図点との間の複数の相対的な空間関係を決定して得ることは、

、  
1つの高次元軌跡点とのユークリッド距離が予め設定された距離閾値内にある所定数の複数の高次元地図点を決定して得ることと、

該高次元軌跡点と、該複数の高次元地図点のうちの各高次元地図点との間の相対的な空間関係をそれぞれ決定することと、を含み、

1つの相対的な空間関係は、該高次元軌跡点及び1つの高次元地図点の絶対位置及び相対位置と、該軌跡点と該地図点との間の相対距離及び相対方向とを含む、

請求項 5 に記載の軌跡予測方法。

10

## 【請求項 7】

ローカルシーン特徴及び高次元地図点特徴に対してそれぞれグローバル特徴抽出操作を実行して、グローバル軌跡特徴及びグローバル地図特徴を抽出して得ることは、

複数回のグローバル特徴抽出操作を実行することを含み、各グローバル特徴抽出操作は、ローカルシーン特徴から抽出したグローバル軌跡特徴を高次元軌跡点特徴に連結してから、

連結された高次元軌跡点特徴を次のグローバル特徴抽出操作に出力することと、

高次元地図点特徴から抽出したグローバル地図特徴を高次元地図点特徴に連結してから、連結された高次元地図点特徴を次のグローバル特徴抽出操作に出力することと、を含む

20

請求項 4 に記載の軌跡予測方法。

## 【請求項 8】

現在の軌跡データは、

運動主体及び他の1つ又は複数の運動物体の各軌跡点における速度、または、

運動主体及び各運動物体の物体種別データを含む、運動主体及び各運動物体の属性データ

、  
をさらに含む、請求項 1 から 7 のいずれか 1 項に記載の軌跡予測方法。

## 【請求項 9】

現在の地図データは、

各地図点とそれが存在する同じ道路要素における他の隣り合う地図点との位置の差、または、

30

各地図点の属性データをさらに含み、

属性データは、該地図点が属する道路要素の種別、属する道路要素が該所定時間帯で含んだ複数の地図点における該地図点のシーケンス番号を含む、

請求項 1 から 8 のいずれか 1 項に記載の軌跡予測方法。

## 【請求項 10】

予測ニューラルネットワークによって実行される軌跡予測方法であって、前記軌跡予測方法は、トレーニングによって軌跡予測ニューラルネットワークを得ることをさらに含み、

トレーニングによって軌跡予測ニューラルネットワークを得ることは、

履歴の第 1 の軌跡データ、第 2 の軌跡データ及び履歴の地図データに基づいて、予め設定されたニューラルネットワークに対して、複数回の反復トレーニングを行うこと、を含み

40

、  
第 1 の軌跡データ及び第 2 の軌跡データは時間的に前後に隣り合うデータ集合であり、いずれも、運動主体及び周りの1つ又は複数の運動物体の所定時間帯での複数の軌跡点を含み、各軌跡点は1つの対応する時点における空間位置を含み、履歴の地図データは第 1 の軌跡データに対応する時間帯での運動主体が存在する環境における道路要素の複数の地図点の空間位置を含み、予め設定されたニューラルネットワークは初期パラメータ集合を有する、

請求項 1 から 9 のいずれか 1 項に記載の軌跡予測方法。

## 【請求項 11】

50

1回の反復トレーニングは、  
 第1の軌跡データと履歴の地図データを入力としてニューラルネットワークに提供することと、  
 ニューラルネットワークは、第1の軌跡データ及び履歴の地図データを高次元空間における第1の軌跡点集合と履歴の地図点集合として表現することと、  
 第1の軌跡点集合及び履歴の地図点集合に基づいて、運動主体が存在する環境の地図特徴及び軌跡特徴を有するグローバルシーン特徴を抽出して得ることと、  
 グローバルシーン特徴に基づいて、運動主体の複数の軌跡点集合と、いずれも運動主体の将来の所定時間帯での複数の時点の空間位置を含む各軌跡点集合に対応する確率とを予測して出力することと、  
 出力された各軌跡点集合及び対応する確率と、第2の軌跡データとを入力として1つの対応する損失関数に提供し、該損失関数の出力を得ることと、  
 すべての損失関数の出力が予め設定された収束の条件を満たすか否かを判断することと、  
 収束の条件を満たすと判断した場合、トレーニングの完了を決定し、トレーニング後のニューラルネットワークのパラメータ集合を取得することと、  
 収束の条件を満たさないと判断した場合、ニューラルネットワークのパラメータを調整し、  
 次の反復トレーニングを実行することと、  
 を含む、請求項10に記載の軌跡予測方法。

10

【請求項12】

予測ニューラルネットワークによって実行される軌跡予測方法であって、前記軌跡予測ニューラルネットワークは、  
 現在の軌跡データ及び現在の地図データを取得して高次元空間における現在の軌跡点集合及び現在の地図点集合として表現し、現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を抽出して得るために使用されるエンコーダと、  
 グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合と、各予測軌跡点集合に対応する確率とを予測して出力するために使用されるデコーダと、  
 を含む、請求項1から11のいずれか1項に記載の軌跡予測方法。

20

【請求項13】

デコーダは、  
 複数の長短期記憶ネットワーク又はゲート付き回帰型ユニットを含む循環ニューラルネットワーク、又は多層パーセプトロンを含み、グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合を予測して出力するために使用されるマルチヘッド型デコーダと、  
 各予測軌跡点集合に対応する確率を決定して得るために使用される確率決定層と、  
 を含む、請求項12に記載の軌跡予測方法。

30

【請求項14】

少なくとも1つのプロセッサと、少なくとも1つのメモリとを含み、  
 少なくとも1つのメモリには、少なくとも1つの機器実行可能な命令が記憶されており、  
 プロセッサは、少なくとも1つの機器実行可能な命令を実行して請求項1から13のいずれか1項に記載の軌跡予測方法を実現する、  
 軌跡予測装置。

40

【請求項15】

プロセッサに実行されて請求項1から13のいずれか1項に記載の軌跡予測方法を実現する少なくとも1つの機器実行可能な命令が記憶されている、  
 不揮発性記憶媒体。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は、コンピュータ技術の分野に関し、特に軌跡予測方法、装置、記憶媒体、及びコンピュータプログラムに関する。

50

## 【背景技術】

## 【0002】

人工知能の研究及び発展の上で、人工知能と結び付けて多くの技術分野、例えばロボット技術及び無人運転技術がより広く適用され、発展している。

## 【0003】

ロボット及び無人運転の分野で、軌跡予測は、重要な一環である。軌跡予測は、無人運転システムの安全性能を大きく左右する。無人運転を例にとると、車両の走行中に、軌跡予測技術によって周りの車両の将来の所定期間における走行軌跡をリアルタイムで予測する必要があり、無人運転システムがこの予測の結果に基づいて安全な経路計画を作成し、衝突を避ける。

10

## 【発明の概要】

## 【発明が解決しようとする課題】

## 【0004】

本発明の実施例は、従来技術における軌跡予測方法が有する予測結果の精確性や信頼性が低いという問題を解決するための軌跡予測方法、装置、記憶媒体、及びコンピュータプログラムを提供する。

## 【課題を解決するための手段】

## 【0005】

本発明の実施例の一態様によれば、

運動主体が現在の環境において運動を実行する過程において、軌跡予測ニューラルネットワークは、入力された現在の軌跡データと現在の環境の現在の地図データとを取得することと、

20

現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現することと、

現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を抽出して得ることと、

グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合と、各予測軌跡点集合に対応する確率とを予測して出力することと、を含み、

現在の軌跡データは、運動主体と、現在の環境における他の1つ又は複数の運動物体との過去の所定時間帯での複数の軌跡点を含み、各軌跡点は1つの対応する時点における空間位置を含み、現在の地図データは該所定時間帯での現在の環境における道路要素の複数の地図点の空間位置を含み、現在の軌跡点集合は、現在の軌跡データの各軌跡点に対応する高次元軌跡点を含み、現在の地図点集合は、現在の地図データの各地図点に対応する高次元地図点を含み、グローバルシーン特徴は、現在の環境の地図特徴及び軌跡特徴を有し、各予測軌跡点集合は、いずれも運動主体の将来の所定時間帯での複数の時点の空間位置を含む、

30

軌跡予測方法が提供される。

## 【0006】

本発明の実施例の他の態様によれば、

運動主体が現在の環境において運動を実行する過程において、入力された現在の軌跡データと現在の環境の現在の地図データとを取得することと、

40

現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現することと、

現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を抽出して得ることと、のために使用されるエンコードと、

グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合と、各予測軌跡点集合に対応する確率とを予測して出力するために使用されるデコードとを含み、

現在の軌跡データは、運動主体と、現在の環境における他の1つ又は複数の運動物体との過去の所定時間帯での複数の軌跡点を含み、各軌跡点は1つの対応する時点における空間位置を含み、現在の地図データは該所定時間帯での現在の環境における道路要素の複数の

50

地図点の空間位置を含み、グローバルシーン特徴は、現在の環境の地図特徴及び軌跡特徴を有し、各予測軌跡点集合は、いずれも運動主体の将来の所定時間帯での複数の時点の空間位置を含む、  
軌跡予測方法が提供される。

【0007】

本発明の実施例の他の態様によれば、  
少なくとも1つのプロセッサと、少なくとも1つのメモリとを含み、  
少なくとも1つのメモリには、少なくとも1つの機器実行可能な命令が記憶されており、  
少なくとも1つのプロセッサは、少なくとも1つの機器実行可能な命令を実行して上記のような軌跡予測方法を実行する、  
軌跡予測装置が提供される。

10

【0008】

本発明の実施例の他の態様によれば、  
上記のような軌跡予測方法を含む軌跡予測処理を実行するために使用されるように構成されたコードセグメント、  
を有するコンピュータプログラムが提供される。

【0009】

本発明の実施例の他の態様によれば、  
上記のような軌跡予測方法を含む軌跡予測処理のためのコンピュータプログラムが記憶されている、  
不揮発性記憶媒体が提供される。

20

【発明の効果】

【0010】

本発明の実施例に係る軌跡予測方法によれば、運動主体が運動を実行するリアルタイム過程において、リアルタイムで取得された現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現し、現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を取得して得て、グローバルシーン特徴は現在の環境の地図特徴及び軌跡特徴を有し、グローバルシーン特徴に基づいて運動主体の将来の所定時間帯での軌跡を予測することができる。ここで、現在の軌跡データ及び現在の地図データを高次元空間におけるデータの点集合として表現し、時間特徴と空間特徴とを同時に有するデータの点集合を取得することができ、グローバルシーン特徴が現在の環境の地図特徴と軌跡特徴を融合し、特徴抽出の精度を著しく高めることができ、さらに、効率で高精度な特徴抽出に基づいて、軌跡予測の結果の精度と正確性を著しく高めることができる。

30

【図面の簡単な説明】

【0011】

図面は、本発明のさらなる理解を提供するために使用され、且つ明細書の一部を構成し、本発明の実施例と共に、本発明を説明するために使用され、本発明を限定するものではない。

【0012】

40

【図1】本発明の実施例に係る軌跡予測ニューラルネットワークのトレーニング方法の1つの処理のフローチャートである。

【図2a】本発明の実施例に係る軌跡予測ニューラルネットワークの1つの構造の模式図である。

【図2b】本発明の実施例に係る軌跡予測ニューラルネットワークのトレーニング方法の他の処理のフローチャートである。

【図3】本発明の実施例に係る軌跡予測ニューラルネットワークの他の構造の模式図である。

【図4】図2bに示すステップ104aにおける処理手順のフローチャートである。

【図5a】1つのシーンにおける動的物体の模式図である。

50

【図 5 b】図 5 a に示すシーンにおいて、従来の方法を用いて動的物体の軌跡を表現する模式図である。

【図 5 c】図 5 a に示すシーンにおいて、本発明の実施例に係る方法を用いて動的物体の軌跡を表現する模式図である。

【図 6】図 2 b のステップ 1 0 6 a の処理手順のフローチャートである。

【図 7 a】図 6 のステップ 1 0 6 2 a の処理手順のフローチャートである。

【図 7 b】図 7 a のステップ 6 2 1 の処理手順のフローチャートである。

【図 8】一例における 1 つの高次元軌跡点と隣接する高次元地図点を決定する模式図である。

【図 9】一例における地図の関係学習を行う伝播の模式図である。

10

【図 1 0】図 6 のステップ 1 0 6 3 a の処理手順のフローチャートである。

【図 1 1】本発明の実施例に係るリアルタイム処理段階における軌跡予測方法の一処理のフローチャートである。

【図 1 2】図 1 1 のステップ 1 1 0 6 の処理手順のフローチャートである。

【図 1 3】図 1 2 のステップ 1 0 6 2 ' の処理手順のフローチャートである。

【図 1 4】図 1 2 のステップ 1 0 6 3 ' の処理手順のフローチャートである。

【図 1 5】本発明の実施例に係る軌跡予測ニューラルネットワークの他の構造の模式図である。

【図 1 6 a】本発明の実施例に係る軌跡予測ニューラルネットワークの他の構造の模式図である。

20

【図 1 6 b】本発明の実施例に係る軌跡予測ニューラルネットワークの他の構造の模式図である。

【図 1 7】本発明の実施例に係る 1 回のグローバル特徴抽出操作のフローチャートである。

【図 1 8】本発明の実施例に係る軌跡予測装置の構造模式図である。

【発明を実施するための形態】

【0 0 1 3】

以下、当業者が本発明の技術態様をよりよく理解できるように、本発明の実施例における図面を参照しながら、本発明の実施例における技術態様を明確且つ完全に説明する。説明される実施例は、本発明の一部の実施例にすぎず、すべての実施例ではないことは明らかである。本発明の実施例に基づいて、当業者が創造的な労働を行わない前提で得られるすべての他の実施例は、本発明の保護範囲に属すべきである。

30

【0 0 1 4】

ロボット技術や無人運転技術の中で、非常に重要な技術の一つは、ロボットや無人運転車両のために、安全かつ信頼性のある経路計画を如何に行うかである。経路計画はまた、ロボットや無人運転車両が位置する環境における他の動的物体の運動の軌跡を精確で有効に予測することに依存する。動的物体の運動の軌跡に対する精確で有効な予測に基づいてこそ、ロボットや無人運転車両に対して、安全かつ信頼性のある経路計画の作成が可能となる。

【0 0 1 5】

40

従来技術では、複数の方法によって物体の運動の軌跡を予測することができる。

【0 0 1 6】

1 つの履歴の軌跡データに基づく予測方法は、ニューラルネットワークを作成し、履歴の軌跡データを使用してニューラルネットワークをトレーニングし、軌跡を予測可能なニューラルネットワークを得る。この方法では、ニューラルネットワークによって実行される操作が通常、特徴抽出操作と予測操作を含み、特徴抽出操作によって動的物体（例えば車両、バイク、自転車又は歩行者）の過去の所定期間における走行軌跡の時間 - 空間特徴（即ち、時空間特徴）を取得し、予測操作によって抽出された時空間特徴に基づいて車両の将来の所定期間における軌跡を予測するようになっている。特徴抽出操作は、通常、先に複数の時点（時間特徴とも呼ぶ）を抽出してから、それぞれの時点における各動的物体の

50

空間特徴を抽出し、空間特徴と時間特徴を融合させる。

【0017】

上記の特徴抽出操作において、空間特徴の抽出は非常に時間の掛かる操作であり、このような処理手順はリアルタイムの処理環境に適用することができない。加えて、異なる時点間の動的物体間の空間の繋がりや空間の影響が捨てられ、特徴抽出操作は複数の時点間の空間特徴の複雑な繋がり及び影響を模擬できなくなってしまう。このような予測手順は、信頼性のない予測結果しかもたらすことができない。さらに、この方法は、ノイズのある入力データを処理することができない。ノイズのある入力データとは通常、ある動的物体の不完全な軌跡データをいう。不完全な軌跡データに対して、通常、この方法の処理は、この動的物体の全ての軌跡データを削除することと、不完全な軌跡データを充填することの二種類がある。このような制限は、明らかに予測結果の精確性と精度に影響を与え、上記の方法をリアルタイムの応用環境に適用できないようにしている。

10

【0018】

他の履歴の軌跡と道路情報に基づく方法では、通常、環境における高精度地図の情報及び異なる車両の走行軌跡を、平面視で見たラスターライズ画像で示し、ラスターライズ画像における画素RGB値をニューラルネットワークに入力し、ニューラルネットワークが、入力データに基づいて特徴を抽出し、抽出された特徴に基づいて軌跡予測を行う。この方法は、軌跡の情報及び道路構造の情報を保持することができるが、示される必要のあるシーンの面積が広く、画像で示すと、過量な冗長情報が記憶されてしまい（例えば、多くの車両のない場所が画像における画素点に対応してしまう）、さらにニューラルネットワークの演算効率が低いという問題をもたらしてしまう。

20

【0019】

従来技術による軌跡予測方法においては、予測操作に時間が掛かり、効率が低く、リアルタイム処理の環境に適用することができないという問題、及び予測結果の精確性が低く、信頼性及び効率が低いという問題があることが分かる。

【0020】

そこで、本発明の実施例は、上記の問題の一部又は全部を解決するために、軌跡予測態様を提供する。

【0021】

本発明は、無人運転技術を例として本発明に係る軌跡予測態様について説明する。当業者にとっては、本発明に係る軌跡予測態様が他の技術分野、例えばロボットの分野にも適用できることが理解できる。

30

【0022】

本発明では、用語「車両」が本発明で任意の移動物体を含むものとして広く解釈され、例えば航空機、船、宇宙船、自動車、トラック、バン、セミトレーラー、バイク、ゴルフカート、オフローダー、倉庫の輸送車両又は農業用トラック、及び例えば電車又は自動車及び他の鉄道車両などの軌道上を走行する輸送手段を含む。本発明に係る「車両」は通常、動力システム、センサシステム、制御システム、周辺機器及びコンピュータシステムを含んでもよい。他の実施例において、車両は、より多い又はより少ない数のシステム、又は、異なるシステムを含んでもよい。

40

【0023】

ただし、動力システムは、車両に動力を提供して運動させるものであり、エンジン/モータ、トランスミッションとホイール/タイヤ、エネルギーユニットを含む。

【0024】

制御システムは、車両及びそのコンポーネントを制御する装置の組合せ、例えば、ステアリングユニット、スロットル、制動ユニットなどの部品を含んでもよい。

【0025】

周辺機器は、車両と外部センサ、他の車両、外部のコンピューティングデバイス及び/又はユーザとのインタラクトを可能にする設備、例えば、無線通信システム、タッチスクリーン、マイクロフォン及び/又はスピーカであってもよい。

50

## 【 0 0 2 6 】

上記説明した車両に基づいて、無人運転車両にはセンサシステムと無人運転制御装置も配置されている。

## 【 0 0 2 7 】

センサシステムは、車両が位置する環境の情報を検知するための複数のセンサ、及びセンサの位置及び/又は方向を変更する1つ又は複数のアクチュエータを含んでもよい。センサシステムは、全地球測位システムセンサ、慣性計測ユニット、無線検出及び測距 ( R A D A R ) ユニット、カメラ、レーザー距離計、光検出及び測距 ( L I D A R ) ユニット及び/又は音響センサ等のセンサの任意の組合せを含んでよく、センサシステムは、車両内部のシステムを監視するセンサ ( 例えば O 2 モニタ、燃料計、エンジン温度計等 ) を含んでもよい。

10

## 【 0 0 2 8 】

無人運転制御装置は、少なくとも1つのプロセッサと少なくとも1つのメモリを含んでもよい。プロセッサは、中央処理装置 ( C P U : C e n t r a l P r o c e s s i n g U n i t ) 及び/又は画像処理装置 ( G P U : G r a p h i c s P r o c e s s i n g U n i t ) を含んでもよい。メモリには、少なくとも1つの機器実行可能な命令が記憶されているが、該少なくとも1つの機器実行可能な命令を含むプログラムプロダクトを無人運転制御システムと呼ぶことができる。無人運転制御システムは、地図エンジン、測位モジュール、感知モジュール、ナビゲーション又は経路モジュール、及び自動制御モジュール等の複数のモジュールを含んでもよく、それに応じて、プロセッサが少なくとも1つの機器実行可能な命令を実行して、地図構築、測位、感知、ナビゲーション又は経路計画、及び車両制御等の機能を含む複数の対応する機能を実現することができる。地図エンジンと測位モジュールは、地図及び測位の情報を提供するために使用される。感知モジュールは、センサシステムによって取得された情報及び地図エンジンによって提供された地図情報に基づいて、車両が位置する環境の環境情報を感知するために使用される。ナビゲーション又は経路モジュールは、地図エンジン、測位モジュール及び感知モジュールの処理結果に基づいて、車両に走行経路を計画するために使用される。自動制御モジュールは、ナビゲーション又は経路モジュール等のモジュールの意思決定情報を、入力して解析し、車両制御システムに対する制御命令に変換して出力し、車載ネットワークによって ( 例えば、C A N バス、ローカルインターコネクトネットワーク ( L I N : L o c a l I n t e r c o n n e c t N e t w o r k ) 、マルチメディア指向性システム伝送 ( M O S T : M e d i a O r i e n t e d S y s t e m s T r a n s p o r t ) 等の方法による車両内部の電子ネットワークシステムによって ) 車両制御システムにおける対応する部品に制御命令を送信して車両に対する自動制御を実現する。自動制御モジュールは、車載ネットワークによって車両における各部品の情報を取得することもできる。

20

30

## 【 0 0 2 9 】

車両に経路を計画する過程において、軌跡予測技術によって周りの動的物体 ( 例えば車両、バイク、自転車又は歩行者 ) の将来の所定期間における走行軌跡をリアルタイムで予測する必要があり、この予測の結果に基づいて安全かつ信頼性のある経路計画を作成する。

## 【 0 0 3 0 】

本発明の実施例に係る学習に基づく軌跡予測態様は、トレーニング段階とリアルタイム処理段階という2つの段階を含む。

40

## 【 0 0 3 1 】

トレーニング段階において、特定のネットワーク構造と初期のパラメータ集合を有するニューラルネットワークを設置する。教師あり学習方法を使用して、履歴の実際のデータに基づいて学習を行うようにニューラルネットワークをトレーニングして、トレーニングの結果が収束の条件を満たす場合、ニューラルネットワークのパラメータ集合が得られる。該特定のネットワーク構造及びトレーニングによるパラメータ集合を有するニューラルネットワークは、即ち、軌跡予測を実現するニューラルネットワークであり、又は、軌跡予測ニューラルネットワークとも呼ばれる。

50

## 【 0 0 3 2 】

リアルタイム処理段階において、1つの動的主体に対して軌跡予測を行う場合、動的主体及び周りの動的物体の現在の軌跡点集合データと現在の環境における現在の地図点集合データを軌跡予測ニューラルネットワークに提供し、該ニューラルネットワークは、運動データの処理を行って、該動的主体の将来の複数の軌跡点集合及びそれぞれの軌跡点集合の対応する確率を予測する。

## 【 0 0 3 3 】

以下、複数の実施例によって、本発明の技術態様について説明する。

## 【 0 0 3 4 】

軌跡予測ニューラルネットワークを得るためのトレーニング

10

トレーニング段階において、複数のネットワーク層を含むことができるニューラルネットワークを構築し、該ニューラルネットワークに初期パラメータ集合を設定する。ニューラルネットワークにおけるネットワーク層の層数及び初期パラメータ集合が、ユースシーンのニーズに応じて、具体的に設定されてもよい。

## 【 0 0 3 5 】

本発明の実施例は、履歴の実際の第1の軌跡データ及び第2の軌跡データと、履歴の地図データとによって、構築されたニューラルネットワークをトレーニングする。

## 【 0 0 3 6 】

本発明の実施例において、第1の軌跡データ及び第2の軌跡データには運動主体及び周りの1つ又は複数の運動物体の複数の軌跡点が含まれ、各軌跡点は1つの対応する時点における空間位置を含む。該空間位置は、二次元位置、三次元位置又は高次元位置であってもよい。例えば、車両が比較的平坦な路面を走行する過程において、路面の高さの変化の幅が小さければ、高さ情報を無視してもよく、軌跡データには運動主体及び運動物体の二次元位置のみが含まれてもよい。他の分野では、例えば、特殊用途のロボットにおいては、運動過程中に高さが大幅に変化する可能性があるため、軌跡データには運動主体及び運動物体の三次元位置が含まれてもよい。他のユースシーンにおいて、他の次元の位置情報がある、又は、他の次元の位置情報を考える必要がある場合、軌跡データには、高次元位置のデータが含まれてもよい。簡潔及び便宜のために、本発明では、すべて二次元位置を例として解釈して説明する。当業者は、空間位置が三次元位置又は高次元位置である場合、三次元位置又は高次元位置に対して、対応する位置変換や座標変換等の処理を行う、又は、具体的なユースシーンのニーズに応じて、対応する位置処理と座標処理を行うことができることを理解すべきである。

20

30

## 【 0 0 3 7 】

本発明の実施例において、第1及び第2の軌跡データは、時間的に前後に隣り合うデータ集合であり、例えば第1の軌跡データは*i*番目の時間帯のデータ集合であり、第2の軌跡データは*i*+1番目の時間帯のデータ集合である。*i*番目の時間帯の時間の長さは*m*であり、*i*+1番目の時間帯の時間の長さは*n*であり、いくつかの実施例において、*m*と*n*は等しくてもよく、例えば、すべて3秒の時間の長さを含み、他のいくつかの実施例において、*m*と*n*は、等しくなくてもよく、例えば、*i*番目の時間帯の時間の長さは3秒であり、*i*+1番目の時間帯の時間の長さは2秒数である。*i*番目の時間帯で頻度*u*によって複数の時点が得られ、*i*+1番目の時間帯で頻度*v*によって複数の時点が得られるが、*u*と*v*は、等しくてもよいし、等しくなくてもよい。

40

## 【 0 0 3 8 】

履歴の地図データは、第1の軌跡データに対応する時間帯で（例えば、*i*番目の時間帯）の運動主体が位置する環境における道路要素の複数の地図点の空間位置を含む。履歴の地図データは、車両の走行過程中的高精度地図からのものであってもよい。道路要素は、車線、歩道、路肩、ランプウェイ、交差点、ロータリー等の要素であってもよい。本発明は、車線等の道路要素に対して所定距離ごとにサンプリングを行い、一連の地図点を得て、各地図点には該点の空間位置が記録されている。上記の軌跡点の空間位置に対応して、地図点の空間位置は、二次元位置、三次元位置又は高次元位置であってもよい。

50

## 【 0 0 3 9 】

図 1 は、本発明の実施例に係る軌跡予測ニューラルネットワークのトレーニング方法の処理手順を示しており、該トレーニング処理は複数回の反復トレーニングを含み、1回の反復トレーニングは、

履歴の第 1 の軌跡データと履歴の地図データを入力としてニューラルネットワークに提供するステップ 1 0 2 と、

ニューラルネットワークは、第 1 の軌跡データ及び履歴の地図データを高次元空間における第 1 の軌跡点集合と履歴の地図点集合として表現するステップ 1 0 4 と、

第 1 の軌跡点集合、履歴の地図点集合に基づいて現在の環境の地図特徴と軌跡特徴を有するグローバルシーン特徴を抽出して得るステップ 1 0 6 と、

グローバルシーン特徴に基づいて運動主体の複数の軌跡点集合と、いずれも運動主体の将来の所定時間帯での複数の時点の空間位置を含む各軌跡点集合に対応する確率とを予測して出力するステップ 1 0 8 と、

出力された各軌跡点集合について、該出力された軌跡点集合及び第 2 の軌跡データを損失関数の入力とし、1つの対応する損失関数の出力を得るステップ 1 1 0 と、

すべての損失関数の出力が予め設定された収束の条件を満たすか否かを判断し、収束の条件を満たすと判断した場合、処理がステップ 1 1 6 に進み、収束の条件を満たさない場合、処理がステップ 1 1 4 に戻るステップ 1 1 2 と、

ニューラルネットワークのパラメータを調整し、処理がステップ 1 0 2 に戻るステップ 1 1 4 と、

トレーニングの完了を決定し、トレーニングを完了したニューラルネットワークのパラメータ集合を取得するステップ 1 1 6 と、

の処理を含む。

## 【 0 0 4 0 】

以下、例示的な実施例によって、図 1 に示す処理手順について説明する。

## 【 0 0 4 1 】

運動主体と運動物体の数を  $N$  と仮定すると、第 1 の軌跡データには  $T$  個の時点が含まれ、

## 【 数 1 】

$$\mathbf{x}_n^t \in \mathbb{R}^2$$

30

は、運動主体又は運動物体  $n$  の時点  $t$  における二次元位置を示し、

## 【 数 2 】

$$t \in \{1, \dots, T\}$$

## 【 数 3 】

$$\mathbb{R}^2$$

40

が二次元空間の表示である。運動主体又は 1 つの運動物体  $n$  の軌跡データは、

## 【 数 4 】

$$\mathbf{X}_n = \{\mathbf{H}_n, \mathbf{F}_n\}$$

50

として表すことができ、そのうち、  
【数 5】

$$\mathbf{H}_n = \{\mathbf{x}_n^1, \mathbf{x}_n^2, \dots, \mathbf{x}_n^T\}$$

は、該物体の過去の時点 1 から観察時点 T までの履歴の位置を示し、  
【数 6】

$$\mathbf{F}_n = \{\mathbf{x}_n^{T+1}, \mathbf{x}_n^{T+2}, \dots, \mathbf{x}_n^{T+s}\}$$

10

は、該物体の将来の時点 T + 1 から時点 T + s までの将来位置を示す。  
【数 7】

$$\mathbf{H}_n$$

は、第 1 の軌跡点集合と見なすことができ、  
【数 8】

20

$$\mathbf{F}_n$$

は、第 2 の軌跡点集合と見なすことができる。  
【0 0 4 2】

履歴の地図点集合には  
【数 9】

$$\hat{\mathbf{N}}$$

30

段の車線が含まれると仮定し、第 1 の軌跡データに対応する時間帯は時点 1 から観察時点 T までであり、この期間における  
【数 10】

$$\hat{\mathbf{n}}$$

段目の車線の地図データは  
【数 11】

40

$$\mathbf{C}_{\hat{\mathbf{n}}} = \{\mathbf{c}_{\hat{\mathbf{n}}}^0, \dots, \mathbf{c}_{\hat{\mathbf{n}}}^T\}$$

であり、  
【数 12】

$$\mathbf{C}_{\hat{\mathbf{n}}}$$

50

は、

【数 1 3】

$$\hat{n}$$

段目の車線に含まれる

【数 1 4】

$$\hat{T}$$

10

個のサンプル地図点の地図位置を示し、

【数 1 5】

$$C_{\hat{n}}^t \in \mathbb{R}^2$$

は、

【数 1 6】

20

$$\hat{n}$$

段目の車線におけるサンプル地図点

【数 1 7】

$$\hat{t}$$

30

の地図位置を示す。

【0 0 4 3】

軌跡予測の目的は、

【数 1 8】

$$\{H_n\}_{n=1}^N$$

及び地図データ

【数 1 9】

40

$$\{C_{\hat{n}}\}_{\hat{n}=1}^{\hat{N}}$$

によって、

【数 2 0】

$$\{F_n\}_{n=1}^N$$

50

と最適なマッチングを形成することができるマルチモーダル分布の予測軌跡点集合を予測して得ることである。

【0044】

該例示的な実施例において、図2aに示すように、ニューラルネットワークの構造は、実現する機能によってエンコーダ1とデコーダ2を含んでもよい。該例示的な実施例において、ニューラルネットワークに対するトレーニング処理は、

履歴の第1の軌跡データと履歴の地図データを入力としてエンコーダ1に提供するステップ102aと、

エンコーダ1は、第1の軌跡データ及び履歴の地図データを高次元空間における第1の軌跡点集合と履歴の地図点集合として表現するステップ104aと、

エンコーダ1は、第1の軌跡点集合と履歴の地図点集合に基づいて運動主体が位置する環境の地図特徴と軌跡特徴を有するグローバルシーン特徴を抽出して得るステップ106aと、

デコーダ2は、グローバルシーン特徴に基づいて運動主体の複数の軌跡点集合と、いずれも運動主体の将来の所定時間帯での複数の時点の空間位置を含む各軌跡点集合に対応する確率とを予測して出力するステップ108aと、

出力された各軌跡点集合について、該出力された軌跡点集合及び第2の軌跡点集合を損失関数の入力とし、1つの対応する損失関数の出力を得るステップ110と、

すべての損失関数の出力が予め設定された収束の条件を満たすか否かを判断し、収束の条件を満たすと判断した場合、処理がステップ116に進み、収束の条件を満たさない場合、

処理がステップ114に戻るステップ112と、ニューラルネットワークのパラメータを調整し、処理がステップ102aに戻るステップ114と、

トレーニングの完了を決定し、トレーニングを完了したニューラルネットワークのパラメータ集合を取得するステップ116と、

【0045】

以下、いくつかの実施例におけるニューラルネットワークの構造設定によって、上記のステップ104a～108aの処理手順について説明する。

【0046】

いくつかの実施例において、図3に示すように、エンコーダ1に入力表示層11を設置することによって、ステップ104aを実施することができる。図4に示すように、ステップ104aは、

入力表示層11は、所定の無順序の軌跡データのフォーマットで第1の軌跡データを表現し、無順序な第1の軌跡点集合を得るステップ1041aと、

所定の無順序の地図データのフォーマットで履歴の地図データを表現し、無順序な履歴の地図点集合を得るステップ1042aと、

の処理手順として実施されることができる。

【0047】

ステップ1041aにおいて、予め設定された軌跡データのフォーマットは、具体的なコースシーンのニーズに応じて、具体的に設定されてもよい。一例では、簡潔と拡張性から考えると、下記の式(1)に示す軌跡データのフォーマットで第1の軌跡データを表すことができる。

【数21】

$$P_n^t = \{x_n^t, t\}, P = \{p_n^t | \forall t \in \{1, \dots, T\}, \forall n \in \{1, \dots, N\}\} \quad (1)$$

ここで、

【数22】

10

20

30

40

50

$$n \in \{1, \dots, N\}$$

は運動主体及び1つ又は複数の運動物体であり、  
【数23】

$$t \in \{1, \dots, T\}$$

は複数の時点であり、  
【数24】

$$x_n^t$$

は物体  $n$  の時間  $t$  における二次元位置（即ち、1つの軌跡点）である。  
【数25】

$$p_n^t$$

は、物体  $n$  の時間  $t$  における空間位置  
【数26】

$$x_n^t$$

が高次元空間にマッピングされた1つの対応点であり、 $P$  は高次元空間にマッピングされた第1の軌跡点集合である。

【0048】

ステップ1042aにおいて、下記の式(2)に示す地図データのフォーマットで履歴の地図点集合を表す。

【数27】

$$m_{\hat{n}}^{\hat{t}} = \{c_{\hat{n}}^{\hat{t}}, \hat{t}\}, M = \{m_{\hat{n}}^{\hat{t}} \mid \forall \hat{t} \in \{1, \dots, \hat{T}\}, \forall \hat{n} \in \{1, \dots, \hat{N}\}\} \quad \dots (2)$$

ここで、  
【数28】

$$c_{\hat{n}}^{\hat{t}}$$

は、  
【数29】

$$\hat{n}$$

段目の車線におけるサンプル地図点

【数 3 0】

$$\hat{t}$$

の地図位置であり、

【数 3 1】

$$\hat{n}$$

10

段目の車線に

【数 3 2】

$$\hat{T}$$

個のサンプル地図点が含まれ、該履歴の地図点集合に

【数 3 3】

20

$$\hat{N}$$

段の車線が含まれる。

【数 3 4】

$$m_{\hat{n}}^{\hat{t}}$$

30

は、1つのサンプル地図点

【数 3 5】

$$c_{\hat{n}}^{\hat{t}}$$

が高次元空間にマッピングされた1つの対応点であり、Mは、高次元空間にマッピングされた履歴の地図点集合である。

【0049】

例示的なシーンにおいて、入力表示層11は、式(1)で第1の軌跡データにおけるデータを高次元空間(例えば、時空間座標系)にマッピングする。該シーンにおいて、図5aに示すように、動的物体には、2台の車、1台の自転車及び1人の歩行者が含まれる。図5bは、伝統的な表示方法で該シーンにおける動的物体の軌跡を表現する場合を示しており、即ち、二次元空間座標系において物体の二次元位置を表現する。該二次元空間座標系において、各データ点は空間特徴のみを有する。図5cは、本発明の実施例に係るデータ表現方法で該シーンにおける第1の軌跡点集合を、時空間座標系に表現する場合を示している。該座標系において、x軸とy軸は二次元空間の座標軸を示しており、z軸は時間軸であり、該座標系における各データ点は同時に時間特徴と空間特徴を有する。

40

【0050】

所定の無順序で拡張可能なデータのフォーマットで第1の軌跡データを表現することによ

50

って、運動主体と運動物体の時系列順に発生する位置データを、時空間座標系にマッピングすることができ、即ち、順序あるデータを離散で無順序な点集合にマッピングすることができる。時空間座標系に表現された高次元第1の軌跡点集合は、第1の軌跡データの表現方式又は表現順序の変更に伴って変更されず、1つの物体に欠損データがあることによって、該物体のデータが表現できなくなることはない。第1の軌跡データを高次元空間にマッピングすることによって、従来技術において、入力データにノイズがある際に余分な処理が必要となるという問題を克服し、欠損のある入力データの処理のロバスト性を向上させることができることがわかる。

【0051】

さらに、所定のデータのフォーマットによって、第1の軌跡データにおけるすべてのデータを同じ高次元空間（例えば、時空間座標系）に統一して表現することができ、時間特徴と空間特徴を同じ表現に統一することで、後続の特徴抽出処理は、統一で融合された時間特徴と空間特徴を抽出することができる。

10

【0052】

入力表示層11は、所定の無順序なデータのフォーマットで、即ち、式(2)で履歴の地図データを表現することによって、道路要素を高次元空間（例えば時空間座標系）における離散で無順序な点集合として表現することができる。時空間座標系に表現された地図点集合は、道路データの表現方式又は表現順序の変更に伴って変更されず、道路要素にデータが欠損することによって、道路要素が表現できなくなることはない。

【0053】

一方、運動主体と運動物体の軌跡データ、及び道路要素の地図データを高次元空間における離散で無順序な高次元データの点集合として表現することによって、従来技術において、ラスタライズ画像で高精度地図の情報及び異なる車両の走行軌跡を示し、ラスタライズ画像における画素RGB値をニューラルネットワークに入力して特徴を抽出するよりも、ニューラルネットワークの処理のデータ量を著しく減らし、ニューラルネットワークの処理速度と処理効率を向上させることができる。

20

【0054】

いくつかの実施例において、図3に示すように、エンコーダ1に埋め込み層12、関係学習層13、グローバル特徴抽出層14及び特徴出力層15を設置することによって、ステップ106aを実施することができる。図6に示すように、ステップ106aは、以下の処理手順で実施されることができる。

30

【0055】

ステップ1061aにおいて、埋め込み層12は、第1の軌跡点集合を所定の高次元空間に埋め込んで高次元軌跡点特徴を得て、履歴の地図点集合を所定の高次元空間に埋め込んで高次元地図点特徴を得る。

【0056】

埋め込み操作の目的は、高次元空間の高次元軌跡点

【数36】

$$p_n^t$$

40

を、データの時間特徴と空間特徴を統一することが可能な隠れた軌跡特徴

【数37】

$$\bar{p}_n^t$$

にマッピングすることである。いくつかの実施例において、埋め込み層12は多層パーセプトロン(Multilayer Perceptron、MLP)によって実現される

50

ことができる。MLPは、フルメッシュ型ネットワークを含んでもよく、ネットワークにおけるニューロンの活性化関数はReLU活性化関数であってもよい。さらに、埋め込み層の各層の後には、1つのバッチ正規化層 (Batch Normalization、BN) が設置されてもよい。

【0057】

説明の便宜上、下記の式(3)で第1の軌跡点集合を高次元空間に埋め込み(又はマッピング)操作を表すことができる。ここで、

【数38】

$$\mathbf{MLP}_p$$

10

は多層パーセプトロンである。

【数39】

$$\bar{p}_n^t = \mathbf{MLP}_p (p_n^t) \quad \dots (3)$$

【0058】

同様に、履歴の地図点集合に対する埋め込みの原理は似ていて、下記の式(4)で高次元地図点

20

【数40】

$$m_n^t$$

を地図特徴

【数41】

$$\bar{m}_n^t$$

30

にマッピングすることができる。ここで、

【数42】

$$\mathbf{MLP}_m$$

は多層パーセプトロンである。

【数43】

$$\bar{m}_n^t = \mathbf{MLP}_m (m_n^t) \quad \dots (4)$$

40

【0059】

埋め込み操作は、高次元第1の軌跡点集合と高次元履歴の地図点集合を複数の次元からなる高次元空間に埋め込むが、各次元におけるデータは、いずれも時間特徴と空間特徴を含む。

【0060】

ステップ1062aにおいて、関係学習層13は、第1の軌跡点集合、履歴の地図点集合

50

、高次元軌跡点特徴、及び高次元地図点特徴に基づいて、ローカル地図情報を有する高次元軌跡点特徴であるローカルシーン特徴を取得して得る。

【0061】

一例では、図7aに示すように、ステップ1062aは、以下の処理手順で実施されることができる。

【0062】

ステップ621において、関係学習層13は、第1の軌跡点集合と履歴の地図点集合に基づいて、各高次元軌跡点と、該高次元軌跡点の周りにおける所定の複数の高次元地図点との間の複数の地図空間関係を決定して得る。

【0063】

一例では、関係学習層13に、計算処理を行うネットワークを設置することによってステップ621を実施することができ、図7bに示すように、ステップ621の実施過程は、以下を含む。

【0064】

ステップS1において、1つの高次元軌跡点とのユークリッド距離が予め設定された距離閾値内にある所定数の複数の高次元地図点を決定して得る。

【0065】

一例では、図8に示すように、(a)部分は、第1の軌跡データにおける軌跡点、及び履歴の地図データにおける地図点を示し、入力表示層11によって第1の軌跡データと履歴の地図データが表示されると、(b)部分に示す高次元軌跡点と高次元地図点が得られ、(c)部分に示すように、ステップS1によって1つの高次元軌跡点と隣接する複数の高次元地図点を決定して得る。

【0066】

図9は、直観的な表現によってこの関連を示している。1つの高次元軌跡点

【数44】

$$p_n^t$$

の予め設定された距離内には、4つ近接した高次元地図点

【数45】

$$m_{\hat{n}}^{\hat{t}-1}$$

、  
【数46】

$$m_{\hat{n}}^{\hat{t}}$$

、  
【数47】

$$m_{\hat{n}+1}^{\hat{t}}$$

及び

【数48】

10

20

30

40

50

$$\widehat{m}_{\hat{n}+1}^{t-1}$$

がある。高次元地図点から高次元軌跡点に指している矢印は、関係学習を利用してローカル地図特徴を軌跡特徴に伝播し、相対的な空間関係を得る過程、即ち下記のステップ S 2 を示す。

【 0 0 6 7 】

ステップ S 2 において、該高次元軌跡点と、該複数の高次元地図点のうちの各高次元地図点との間の相対的な空間関係をそれぞれ決定し、1つの相対的な空間関係は、該高次元軌跡点及び1つの高次元地図点の絶対位置及び相対位置と、該軌跡点と該地図点との間の相対距離及び相対方向とを含む。

10

【 0 0 6 8 】

ここで、

【 数 4 9 】

$$\mathbf{x}_n^t$$

は高次元軌跡点の絶対位置であり、

20

【 数 5 0 】

$$\hat{c}_{\hat{n}}^t$$

は高次元地図点の絶対位置であり、

【 数 5 1 】

$$(\mathbf{x}_n^t - \hat{c}_{\hat{n}}^t)$$

30

は高次元軌跡点と高次元地図点との間の相対位置であり、 d i s t

【 数 5 2 】

$$(\mathbf{x}_n^t, \hat{c}_{\hat{n}}^t)$$

は高次元軌跡点と高次元地図点との間の相対距離であり、

c o s

【 数 5 3 】

40

$$(\mathbf{v}_n^t, \mathbf{u}_{\hat{n}}^t)$$

は高次元軌跡点と高次元地図点との間の相対方向であり、

【 数 5 4 】

$$\mathbf{u}_{\hat{n}}^t = \hat{c}_{\hat{n}}^t - \hat{c}_{\hat{n}}^{t-1}, \quad \mathbf{v}_n^t = \mathbf{v}_n^t - \mathbf{v}_n^{t-1}, \quad \mathbf{v}_n^t$$

50

は運動主体又は運動物体  $n$  の時点  $t$  における速度である。

1 つの高次元軌跡点と 1 つの高次元地図点との間の相対的な空間関係

【数 5 5】

$$e_{n\hat{n}}^{tt}$$

は、下記の式 (5) として表すことができる。

【数 5 6】

$$e_{n\hat{n}}^{tt} = \{ \mathbf{x}_n^t, \mathbf{c}_{\hat{n}}^t, \mathbf{x}_n^t - \mathbf{c}_{\hat{n}}^t, \text{dist}(\mathbf{x}_n^t, \mathbf{c}_{\hat{n}}^t), \cos(\mathbf{v}_n^t, \mathbf{u}_{\hat{n}}^t) \} \dots (5)$$

10

【0069】

ステップ 6 2 3 において、1 つの高次元軌跡点に対応する各相対的な空間関係を高次元空間にそれぞれ埋め込んで高次元地図空間関係を得て、各高次元地図空間関係と、対応する高次元地図点特徴とのドット積を行って 1 つの加重地図特徴を得て、該高次元軌跡点の複数の加重地図特徴に対して最大化処理を行って最大加重地図特徴を選択して得る。

【0070】

ここで、1 つの高次元軌跡点に対応する複数の相対的な空間関係をいずれも高次元空間に埋め込むという操作は、上記の式 (3) 又は (4) の埋め込み操作を参照することができる。関係学習層 1 3 に埋め込み層 (例えば、多層パーセプトロン MLP) を設置することによって該埋め込み操作を実行することができる。埋め込み操作の後に複数の高次元地図空間関係を得ることができ、複数の高次元地図空間関係を該高次元軌跡点とそれぞれドット積を行ってから、複数のドット積の結果、つまり、複数の加重地図特徴を得るが、関係学習層 1 3 にドット積の計算を実現するネットワーク層を設置することによってドット積操作を実行することができる。これらの複数のドット積の結果に対して最大化処理を行ってから、最大加重地図特徴を得ることができるが、関係学習層 1 3 にプーリング層 (例えば、最大プーリング層又は平均プーリング層) を設置することによって最大化処理を実現することができる。

20

30

【0071】

ステップ 6 2 5 において、最大加重地図特徴と、該高次元軌跡点に対応する高次元軌跡点特徴とを加算して 1 つのローカルシーン特徴を得る。

【0072】

式 (6) でステップ 6 2 3 及び 6 2 5 の処理手順を表すことができる。

【数 5 7】

$$\tilde{\mathbf{p}}_n^t = \bar{\mathbf{p}}_n^t + A (\{ \text{MLP}_e(e_{n\hat{n}}^{tt}) \cdot \bar{\mathbf{m}}_{\hat{n}}^t, \forall \bar{\mathbf{m}}_{\hat{n}}^t \in \text{top } k \}) \dots (6)$$

40

ここで、

【数 5 8】

$$\tilde{\mathbf{p}}_n^t$$

はローカルシーン特徴であり、符号

【数 5 9】

50

## A

は最大化処理を表し、

【数 6 0】

$$MLP_e$$

は相対的な空間関係に対して埋め込み処理を行うことであり、

【数 6 1】

$$\vec{m}_{\hat{n}}^t$$

は高次元地図点特徴であり、 $k$  は、1つの軌跡点とのユークリッド距離が予め設定された距離の閾値内にある地図点の所定数である。

【0 0 7 3】

図 7 a に示す処理によって、1つの高次元軌跡点の周りにおける複数の高次元地図点の地図情報を該高次元軌跡点に伝播し、即ち、1つの高次元軌跡点の周りにおけるローカル地図情報を該高次元軌跡点に伝播し、ローカルの地図情報及び軌跡点の時空間情報を有するローカルシーン特徴を得ることができる。ローカルシーン特徴は、後から精確さがより高い予測軌跡点集合を得るためのデータの基礎を提供する。

10

20

【0 0 7 4】

ステップ 1 0 6 3 a において、グローバル特徴抽出層 1 4 は、ローカルシーン特徴及び高次元地図点特徴に対してそれぞれグローバル特徴抽出操作を実行して、グローバル軌跡特徴及びグローバル地図特徴を抽出して得る。

【0 0 7 5】

1つの実施例において、図 1 0 に示すように、ステップ 1 0 6 3 a は、ローカルシーン特徴における各特徴に対して特徴を抽出し、抽出された特徴に対して最大化処理を行って、選択された最大の特徴をグローバル軌跡特徴とするステップ 6 3 1 と、高次元地図点特徴における各特徴に対して特徴を抽出し、抽出された特徴に対して最大化処理を行って、選択された最大の特徴をグローバル地図特徴とするステップ 6 3 3 との処理手順で実施されることができる。

30

【0 0 7 6】

ローカルシーン特徴と高次元地図点特徴を得た後、データの異なる配列に対して不変性を保持する必要がある。特徴抽出層は、高次元空間に含まれる各次元におけるデータに対して特徴を抽出し、時間特徴と空間特徴を融合したグローバル地図特徴、及びローカル地図特徴を融合したグローバル軌跡特徴を含むグローバル特徴を得る。グローバル特徴は、多次元の特徴を含むが、各次元が特徴空間の一部に対応し、つまり、時空間特徴における一部を表現する。

40

【0 0 7 7】

いくつかの実施例において、グローバル特徴抽出層 1 4 は、順番にグローバル軌跡特徴とグローバル地図特徴を抽出するために使用される1つのプーリング層を含んでよく、グローバル軌跡特徴とグローバル地図特徴をそれぞれ抽出するために使用される2つの並列するプーリング層を含んでもよい。

【0 0 7 8】

ステップ 1 0 6 4 a において、特徴出力層 1 5 は、グローバル軌跡特徴とグローバル地図特徴に基づいてグローバルシーン特徴を決定して得る。

50

## 【 0 0 7 9 】

ここで、特徴出力層 1 5 は、グローバル軌跡特徴をグローバル地図特徴に加算してグローバルシーン特徴を得る。該グローバルシーン特徴にはグローバル地図特徴とグローバル軌跡特徴が含まれ、後から精確さがより高い予測軌跡点集合を得るためのデータの基礎を提供する。

## 【 0 0 8 0 】

デコーダ 1 はグローバルシーン特徴を決定した後、デコーダ 2 はグローバルシーン特徴に基づいて予測処理を行うことができる。

## 【 0 0 8 1 】

いくつかの実施例において、図 3 に示すように、デコーダ 2 にマルチヘッド型デコーダ 2 1 と確率決定層 2 2 を設置することができる。 10

## 【 0 0 8 2 】

マルチヘッド型デコーダ 2 1 は、複数のサブデコーダを含んでもよく、サブデコーダは、循環ニューラルネットワーク又は多層パーセプトロンであってもよい。循環ニューラルネットワークは、長短期記憶ネットワーク (Long - Short Term Memory、LSTM) 又はゲート付き回帰型ユニット (GRU: Gated recurrent unit) を含む。他のいくつかの実施例において、確率論的デコーダ (Stochastic Decoder) を選択してもよい。

## 【 0 0 8 3 】

特定する初期パラメータ集合を有する各サブデコーダは、グローバルシーン特徴に基づいて 1 つの予測軌跡点集合を予測して得ると、マルチヘッド型デコーダ 2 1 は複数の予測軌跡点集合を出力する。 20

## 【 0 0 8 4 】

確率決定層 2 2 は各予測軌跡点集合に対して 1 つの対応する確率を決定して得る。確率決定層 2 2 は 1 つのソータであってもよい。

## 【 0 0 8 5 】

上記のステップ 1 1 0 において、出力された各軌跡点集合について、該出力された軌跡点集合及び第 2 の軌跡点集合を損失関数の入力とし、1 つの対応する損失関数の出力を得る。

## 【 0 0 8 6 】

損失関数は、ガウス分布の負の対数尤度 (Negative Log likelihood、NLL) 関数であってもよい。 30

## 【 0 0 8 7 】

上記のトレーニングによってニューラルネットワークのパラメータ集合を得ることができ、該トレーニングによって得られたパラメータ集合を有し、かつ特定の構造を有するニューラルネットワークは、軌跡予測ニューラルネットワークである。該軌跡予測ニューラルネットワークによって、リアルタイム処理段階において、入力された現在の軌跡点集合及び現在の地図点集合に対して処理を行い、将来の時間帯の複数の予測軌跡点集合及び各予測軌跡点集合に対応する確率を予測して得ることができる。

## 【 0 0 8 8 】

上記のトレーニング過程によって、履歴の第 1 の軌跡データを高次元空間における第 1 の軌跡点集合にマッピングし、履歴の地図データを高次元空間における履歴の地図点集合にマッピングし、順序ある軌跡データを無順序なデータ点に変換することで、データのノイズによる後続の影響を克服し、データの処理のロバスト性を向上させることができる。エンドツーエンドの学習方式によって軌跡データと地図データに対する特徴抽出を実現することで、特徴抽出操作の速度と効率を著しく向上させ、ユースシーンのリアルタイム性へのニーズをよりよく満たすことができる。抽出されたグローバルシーン特徴はグローバル軌跡特徴とグローバル地図特徴を有し、グローバル軌跡特徴はローカル地図特徴と軌跡特徴を融合し、軌跡特徴は時間特徴と空間特徴とを同時に有する。グローバルシーン特徴に基づいて予測して得た予測軌跡点集合は、軌跡予測の結果の精度と精確性を著しく高める 40 50

ことができる。

【0089】

リアルタイム処理段階における軌跡予測

図1に示す処理と対応し、図11は、リアルタイム処理段階において、軌跡予測ニューラルネットワークによって物体の運動軌跡を予測する処理手順を示している。

【0090】

ステップ1102において、運動主体が現在の環境において運動を実行する過程において、軌跡予測ニューラルネットワークは、入力された現在の軌跡データと現在の環境の現在の地図データとを取得し、現在の軌跡データは、運動主体と、現在の環境における他の1つ又は複数の運動物体との過去の所定時間帯での複数の軌跡点を含み、各軌跡点は1つの対応する時点における空間位置を含み、現在の地図データは該所定時間帯での現在の環境における道路要素の複数の地図点の空間位置を含む。

10

【0091】

ステップ1104において、現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現し、現在の軌跡点集合は、現在の軌跡データの各軌跡点に対応する高次元軌跡点を含み、現在の地図点集合は、現在の地図データの各地図点に対応する高次元地図点を含む。

【0092】

ステップ1106において、現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を抽出して得て、グローバルシーン特徴は、現在の環境の地図特徴及び軌跡特徴を有する。

20

【0093】

ステップ1108において、グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合と、各予測軌跡点集合に対応する確率とを予測して出力し、各予測軌跡点集合は、いずれも運動主体の将来の所定時間帯での複数の時点の空間位置を含む。

【0094】

以下、例示的な実施例によって、図11に示す処理について説明し、該例では、ニューラルネットワークは図3に示すニューラルネットワークであってもよい。該ニューラルネットワークにはエンコーダ1とデコーダ2が含まれる。エンコーダ1には入力表示層11、埋め込み層12、関係学習層13、グローバル特徴抽出層14及び特徴出力層15が含まれる。デコーダ2にはマルチヘッド型デコーダ21と確率決定層22が含まれる。

30

【0095】

上記のステップ1102において、軌跡予測ニューラルネットワークに入力される現在の軌跡データは、上流のモジュール、例えば感知モジュールからのものであってもよい。感知モジュールは、感知データの中から現在の軌跡データを選択して、現在の軌跡データを軌跡予測ニューラルネットワークのエンコーダ1に提供する。軌跡予測ニューラルネットワークに入力される現在の地図データは、上流の地図モジュールからの高精度地図データであってもよい。

【0096】

現在の軌跡データは、上記の第1の軌跡データと同じ設定を有してもよく、現在の地図データは、上記の現在の地図データと同じ設定を有してもよい。

40

【0097】

上記のステップ1104において、図3に示す入力表示層11によってステップ1104を実行することができる。

【0098】

該例では、入力表示層11は、所定の無順序の軌跡データのフォーマットで現在の軌跡データを表現し、高次元空間にマッピングされた無順序の現在の軌跡点集合を得て、軌跡データのフォーマットは上記の式(1)に示すフォーマットであってもよく、現在の軌跡点集合は現在の軌跡データの各軌跡点に対応する高次元軌跡点を含む。所定の無順序の地図データのフォーマットで現在の地図データを表現し、高次元空間にマッピングされた無順

50

序の現在の地図点集合を得て、地図データのフォーマットは上記の式(2)に示すフォーマットであってもよく、現在の地図点集合は現在の地図データの各地図点に対応する高次元地図点を含む。

【0099】

ステップ1104の具体的な処理手順は、上記のステップ104aの式(1)及び(2)と図4の処理を参照してもよい。

【0100】

該例では、上記のステップ1106が、図3に示す埋め込み層12、関係学習層13、グローバル特徴抽出層14及び特徴出力層15、及び図6に示す処理を参照することによって実行されることができる。図12に示すように、ステップ1106は、以下を含んでもよい。

10

【0101】

ステップ1061'において、埋め込み層12は、現在の軌跡点集合を所定の高次元空間に埋め込んで高次元軌跡点特徴を得て、現在の地図点集合を所定の高次元空間に埋め込んで高次元地図点特徴を得る。埋め込み層12の具体的な操作は上記の式(3)及び(4)を使用し、上記のステップ1061aの処理を参照して実現できる。

【0102】

ステップ1062'において、関係学習層13は、現在の軌跡点集合、現在の地図点集合、高次元軌跡点特徴及び高次元地図点特徴に基づいて、ローカル地図情報を有する高次元軌跡点特徴であるローカルシーン特徴を取得する。関係学習層13の具体的な操作は上記のステップ1062aの処理を参照して実現できる。

20

【0103】

ステップ1063'において、グローバル特徴抽出層14は、ローカルシーン特徴及び高次元地図点特徴に対してそれぞれグローバル特徴抽出操作を実行して、グローバル軌跡特徴及びグローバル地図特徴を抽出して得る。グローバル特徴抽出層14の具体的な操作は上記のステップ1063aを参照して実現できる。

【0104】

ステップ1064'において、特徴出力層15は、グローバル軌跡特徴とグローバル地図特徴に基づいてグローバルシーン特徴を決定して得る。特徴出力層15の具体的な操作は上記のステップ1064aを参照して実現できる。

30

【0105】

例示的に、図7aと上記のステップ1062aを参照し、図13に示すように、ステップ1062'において、関係学習層13の処理は、以下を含んでもよい。

【0106】

ステップ621'において、現在の軌跡点集合及び現在の地図点集合に基づいて、各高次元軌跡点と該高次元軌跡点の周りの所定の複数の高次元地図点との間の複数の相対的な空間関係を決定して得る。該処理は、図7b及び上記のステップ621の処理を参照してもよく、1つの高次元軌跡点とのユークリッド距離が予め設定された距離閾値内にある所定の複数の高次元地図点を決定して得ることと、該高次元軌跡点と、該複数の高次元地図点のうちの各高次元地図点との間の相対的な空間関係をそれぞれ決定することと、を含み、1つの相対的な空間関係は、該高次元軌跡点及び1つの高次元地図点の絶対位置及び相対位置と、該軌跡点と該地図点との間の相対距離及び相対方向とを含む。相対的な空間関係の表現は上記の式(5)を参照することができる。

40

【0107】

ステップ623'において、1つの高次元軌跡点に対応する各地図空間関係を高次元空間にそれぞれ埋め込んで高次元地図空間関係を得て、各高次元地図空間関係と、対応する高次元地図点特徴とのドット積を行って1つの加重地図特徴を得て、該高次元軌跡点の複数の加重地図特徴に対して最大化処理を行って最大加重地図特徴を選択して得る。

【0108】

ステップ625'において、最大加重地図特徴と、該高次元軌跡点に対応する高次元軌跡

50

点特徴とを加算して1つのローカルシーン特徴を得る。

【0109】

ステップ623'及び625'の操作は上記のステップ623及び625を参照して実現できる。

【0110】

1つの高次元軌跡点に対応するローカルシーン特徴は上記の式(6)で表現することができる。現在の軌跡点集合における複数の高次元軌跡点から、対応する複数のローカルシーン特徴を得ることができる。

【0111】

例示的に、図10及び上記のステップ1063aを参照し、図14に示すように、ステップ1063'において、グローバル特徴抽出層14の処理は、ローカルシーン特徴における各特徴に対して特徴を抽出し、抽出された特徴に対して最大化処理を行って、選択された最大の特徴をグローバル軌跡特徴とするステップ631'と、高次元地図点特徴における各特徴に対して特徴を抽出し、抽出された特徴に対して最大化処理を行って、選択された最大の特徴をグローバル地図特徴とするステップ633'を含む。

【0112】

例示的に、上記のステップ1064aを参照し、特徴出力層15の処理は、グローバル軌跡特徴をグローバル地図特徴に加算してグローバルシーン特徴を得ることを含むことができる。

【0113】

上記の処理によって、現在の軌跡データを高次元空間における現在の軌跡点集合にマッピングし、現在の地図データを高次元空間における現在の地図点集合にマッピングし、順序ある軌跡データを無順序なデータ点に変換することで、データのノイズによる後続の影響を克服し、データの処理のロバスト性を向上させることができる。エンドツーエンドの処理方式によって軌跡データと地図データに対する特徴抽出を実現することで、特徴抽出操作の速度と効率を著しく向上させ、ユースシーンのリアルタイム性へのニーズをよりよく満たすことができる。抽出されたグローバルシーン特徴はグローバル軌跡特徴とグローバル地図特徴を有し、グローバル軌跡特徴はローカル地図特徴と軌跡特徴を融合し、軌跡特徴は時間特徴と空間特徴とを同時に有する。グローバルシーン特徴は、軌跡予測に精確で有効なデータの基礎を提供することができる。

【0114】

該例では、ステップ1108の処理において、デコーダ21におけるマルチヘッド型デコーダ21が複数の予測軌跡点集合を出力して、確率決定層22が各予測軌跡点集合に対して1つの対応する確率を決定する。

【0115】

デコーダ2は、より精確で有効なグローバルシーン特徴に基づいて、精度と精確率がより高い軌跡点集合を予測することができる。

【0116】

他のいくつかの実施例において、上記のいずれかの実施例に基づいて、第1の軌跡データ、第2の軌跡データ、現在の軌跡データにおけるデータ項目に対して、区分けと拡張を行って、データを軌跡データと属性データに区分けしてもよい。これに対応し、入力表示層11が使用する軌跡データのフォーマットに対して、対応して拡張する。

【0117】

一例では、軌跡データには、物体の1つの所定時間帯での複数の時点の空間位置と速度とが含まれてもよい。このような場合、所定データのフォーマットの拡張性に基づいて、式(7)で軌跡データのフォーマットを定義することができる。

【数62】

10

20

30

40

50

$$P_n^t = \{x_n^t, v_n^t, t\}, P = \{p_n^t | \forall t \in \{1, \dots, T\}, \forall n \in \{1, \dots, N\}\} \dots (7)$$

ここで、

【数 6 3】

$$v_n^t$$

は物体の時間  $t$  における速度である。

【0 1 1 8】

実験及びテストの結果によって、軌跡データに速度データを追加することで、軌跡予測の結果の精度をさらに高められることが判明した。

【0 1 1 9】

他の例示的な実施例において、軌跡点集合には、軌跡データと属性データが含まれてもよい。属性データは、例えば歩行者、自転車又は車両である物体種別データを含んでもよい。具体的なユースシーンにおいて、物体種別データは、他の属性、例えばバン、レッカー車、セミトレーラー等の状況を含んでいる車両の属性であってもよく、また、車両のライトの属性項目、例えば車両のライトが点灯されているか否かを識別する車両のヘッドライトの属性データ又は車両のテールライトの属性データを追加してもよい。このような場合に、式(8)で軌跡データのフォーマットを定義することができる。

【数 6 4】

$$P_n^t = \{x_n^t, v_n^t, \phi_n, t\}, P = \{p_n^t | \forall t \in \{1, \dots, T\}, \forall n \in \{1, \dots, N\}\} \dots (8)$$

ここで、

【数 6 5】

$$\phi_n$$

は物体種別を表し、該種別の値は、例えば車両が1、歩行者が2、自転車が3であると予め設定されてもよい。式(8)では、1つの項目の属性データを例示的に拡張しているが、具体的なユースシーンのニーズに応じて、複数の項目の属性データを拡張してもよい。

【0 1 2 0】

属性データには、例えば運動主体又は周りにおける運動物体である物体の識別データが含まれてもよい。このような場合に、式(9)で軌跡データのフォーマットを定義することができる。

【数 6 6】

$$P_n^t = \{x_n^t, v_n^t, \phi_n, t, id\}, P = \{p_n^t | \forall t \in \{1, \dots, T\}, \forall n \in \{1, \dots, N\}\} \dots (9)$$

ここで、 $id$  は物体が運動主体又は周りにおける運動物体であることを識別し、例えば該データの値が1であると、物体  $n$  が運動主体であることを示し、値が0であると、物体  $n$  が周りにおける運動物体であることを示す。

【0 1 2 1】

所定の拡張可能なデータのフォーマットは、ユースシーンのニーズに応じて、複数のデー

10

20

30

40

50

タを含むことが可能であるため、データのフォーマットの長さが可変である。従来の技術では、入力データに対してデータ項目を増減させる必要があるれば、開発者がデータに手動での編集と微調整を行う必要があり、仕事量が多い。本発明の実施例は、可変長のデータのフォーマットを提供し、データのフォーマットにデータ項目を増減させるだけで、データに後続の処理を行うことができ、手動での編集による余計な仕事を避けることができる。

【0122】

さらに、軌跡データに属性データを追加することによって、軌跡予測ネットワークが物体の属性について学習及び理解するようトレーニングすることができ、軌跡予測の精度と正確性を高めることができる。

10

【0123】

他のいくつかの実施例において、上記のいずれかの実施例に基づいて、履歴の地図データ及び現在の地図データにおけるデータ項目に対して、区分けと拡張を行うこともできる。これに対応し、入力表示層11の使用する地図データのフォーマットに対して、対応して拡張する。

【0124】

一例では、地図データには各地図点とその点が位置する同じ道路要素における他の隣の地図点との位置の差が含まれてもよい。このような場合に、所定のデータのフォーマットの拡張性に基づいて、式(10)で地図データのフォーマットを定義することができる。

【数67】

20

$$m_n^i = \{c_n^i, u_n^i, \hat{t}\}, \quad M = \{m_n^i | \forall i \in \{1, \dots, \hat{T}\}, \forall n \in \{1, \dots, \hat{N}\}\} \quad (10)$$

【数68】

$$u_n^{\hat{t}}$$

は、地図点

30

【数69】

$$\hat{t}$$

と隣の1つ前の地図点

【数70】

$$\hat{t}-1$$

40

との位置の差、例えば二次元座標における位置の差又は三次元座標における位置の差である。

【0125】

隣の2つの地図点間の位置の差を設定することで、軌跡予測ニューラルネットワークの後続の処理において道路要素の複数の地図点間の方向性及び接続性を取得することができる。

【0126】

該例では、埋め込み層12の処理が高次元地図点特徴を得てから、即ち、上記のステップ1061aと上記のステップ1061'の後に、高次元地図点特徴に対して方向性と接続

50

性の強化処理を行うことができる。これに対応し、図 15 に示すように、図 3 に示すニューラルネットワークに基づいて、埋め込み層 12 の後に強化層 12' を設置することができる。強化層 12' は、自己注意ニューラルネットワークであってもよい。

【0127】

他の例では、地図データには各地図点の属性データをさらに含んでもよく、属性データは、該地図点が属する道路要素の種別、属する道路要素が該所定時間帯で含んだ複数の地図点における該地図点のシーケンス番号を含む

【0128】

他のいくつかの実施例において、上記のいずれかの実施例に基づいて、より精確で有効なグローバル軌跡特徴とグローバル地図特徴を抽出するために、複数回のグローバル特徴抽出操作を行うこと、即ち、上記のステップ 1063 a 及びステップ 1063' において複数回のグローバル特徴抽出操作を実行することができる。これに対応し、図 16 a 又は図 16 b に示すように、図 3 又は図 15 に示すニューラルネットワークに基づいて、グローバル特徴抽出層 14 に複数の積み重ねられたサブグローバル特徴抽出層 141 を設置する。

10

【0129】

グローバル特徴抽出層 14 は、複数回のグローバル特徴抽出操作を実行し、各グローバル特徴抽出操作は、

隣の 1 つ前のサブグローバル特徴抽出層 141 は、ローカルシーン特徴から抽出したグローバル軌跡特徴を高次元軌跡点特徴に連結してから、連結された高次元軌跡点特徴を隣の

20

次のサブグローバル特徴抽出層 141 に出力することと、隣の 1 つ前のサブグローバル特徴抽出層 141 は、高次元地図点特徴から抽出したグローバル地図特徴を高次元地図点特徴に連結してから、連結された高次元地図点特徴を隣の次のサブグローバル特徴抽出層 141 に出力することと、を含む。

【0130】

図 17 は、1 回のグローバル特徴抽出操作の模式図を示しており、ポイントレベルの特徴（即ち、ローカルシーン特徴又は高次元地図点特徴）に対してグローバル特徴抽出を行い、集約した特徴（つまり、1 回の抽出で得たグローバル軌跡特徴又はグローバル地図特徴）を得て、該グローバル特徴を抽出して該グローバル特徴抽出操作に入力されたポイントレベルの特徴の後に連結して、連結されたローカルシーン特徴と連結された高次元地図点

30

特徴を得る。連結されたローカルシーン特徴と連結された高次元地図点特徴を次のサブグローバル特徴抽出層 141 に入力して、次のグローバル特徴抽出操作を実行する。

【0131】

エンコーダ 1 には 1 つのグローバル特徴抽出層 14 が含まれると、該グローバル特徴抽出層 14 は、運動主体が位置する環境の第 1 のシーケンス情報、即ち、グローバルの時空間特徴を抽出することができ、複数のグローバル特徴抽出層 14 によって該環境における第 2 のシーケンス情報、例えば異なる物体間の互いの影響を学習して抽出することができる。積層のグローバル特徴抽出層 14 によって、個体物体とグローバルの時空間環境の状態及び関係をより深く理解し、これにより積層の特徴層が複数の物体間の互いの作用及び影響を捉えることができる。

40

【0132】

積層の特徴層によって、例えば、現在の車が減速すると後の車に影響を与えて、それに応じて、後の車も減速するという作用と影響を捉えることができる。

【0133】

エンコーダ 1 に積層のグローバル特徴抽出層 14 を設置することによって、複数の物体間の互いの作用と影響を抽出し、ニューラルネットワークの環境への学習と理解の能力を高めることができ、これにより軌跡予測の精確性と精度をさらに高めることができる。

【0134】

本発明の実施例は軌跡予測装置をさらに提供し、該装置は上記の図 2 a、図 3、図 15、図 16 a 又は図 16 b に示す構造であってもよく、対応するネットワーク構造は上記の説

50

明を参照し、上記の軌跡予測の処理を対応して完了する。

【0135】

図18は、1つのプロセッサ81と1つのメモリ82を例示的に含む軌跡予測装置の一例の構造を示している。リアルタイム処理手順において、プロセッサ81は、メモリ82に記憶された少なくとも1つの機器実行可能な命令を実行して、図11～図14に示す処理を実行する。トレーニング過程において、プロセッサ81は、メモリ82に記憶された少なくとも1つの機器実行可能な命令を実行して、図1、図2b、図4、図6、図7a、図7b、図10に示す処理を実行する。

【0136】

本発明の実施例は、図11～図14に示す処理に加えて、図1、図2b、図4、図6、図7a、図7b、図10に示す処理をさらに含むことができる軌跡予測処理を実行するために使用されるように配置されるコードセグメントを有するコンピュータプログラムをさらに提供する。

10

【0137】

本発明の実施例は、図11～図14に示す処理に加えて、図1、図2b、図4、図6、図7a、図7b、図10に示す処理をさらに含むことができる軌跡予測処理のためのコンピュータプログラムを記憶している記憶媒体をさらに提供する。

【0138】

本開示のいくつかの例は、以下を含む。

【0139】

20

例1、

運動主体が現在の環境において運動を実行する過程において、軌跡予測ニューラルネットワーク、入力された現在の軌跡データと現在の環境の現在の地図データとを取得することと、

現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現することと、

現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を抽出して得ることと、

グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合と、各予測軌跡点集合に対応する確率とを予測して出力することと、を含み、

30

現在の軌跡データは、運動主体と、現在の環境における他の1つ又は複数の運動物体との過去の所定時間帯での複数の軌跡点を含み、各軌跡点は1つの対応する時点における空間位置を含み、現在の地図データは該所定時間帯での現在の環境における道路要素の複数の地図点の空間位置を含み、現在の軌跡点集合は、現在の軌跡データの各軌跡点に対応する高次元軌跡点を含み、現在の地図点集合は、現在の地図データの各地図点に対応する高次元地図点を含み、グローバルシーン特徴は、現在の環境の地図特徴及び軌跡特徴を有し、各予測軌跡点集合は、いずれも運動主体の将来の所定時間帯での複数の時点の空間位置を含む、

ことを特徴とする、軌跡予測方法。

【0140】

40

例2、軌跡予測ニューラルネットワークは、現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現することは、

所定の無順序の軌跡データのフォーマットで現在の軌跡点集合を表現し、無順序の現在の軌跡点集合を得ることと、

所定の無順序の地図データのフォーマットで現在の地図点集合を表現し、無順序の現在の地図点集合を得ることと、を含む、

ことを特徴とする、例1に記載の方法。

【0141】

例3、軌跡予測ニューラルネットワークは、現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を抽出して得ることは、

50

現在の軌跡点集合を所定の高次元空間に埋め込んで高次元軌跡点特徴を得て、現在の地図点集合を所定の高次元空間に埋め込んで高次元地図点特徴を得ることと、

現在の軌跡点集合、現在の地図点集合、高次元軌跡点特徴及び高次元地図点特徴に基づいて、ローカル地図情報を有する高次元軌跡点特徴であるローカルシーン特徴を取得して得ることと、

ローカルシーン特徴及び高次元地図点特徴に対してそれぞれグローバル特徴抽出操作を実行して、グローバル軌跡特徴及びグローバル地図特徴を抽出して得ることと、

グローバル軌跡特徴及びグローバル地図特徴に基づいてグローバルシーン特徴を決定して得ることと、を含む、

ことを特徴とする、例 1 に記載の方法。

10

【 0 1 4 2 】

例 4、軌跡予測ニューラルネットワークは、高次元軌跡点特徴と高次元地図点特徴に対して方向性と接続性の強化処理をさらに行う、

ことを特徴とする、例 3 に記載の方法。

【 0 1 4 3 】

例 5、現在の軌跡点集合、現在の地図点集合、高次元軌跡点特徴及び高次元地図点特徴に基づいてローカルシーン特徴を取得して得ることは、

現在の軌跡点集合及び現在の地図点集合に基づいて、各高次元軌跡点と該高次元軌跡点の周りの所定の複数の高次元地図点との間の複数の相対的な空間関係を決定して得ることと

20

、  
1つの高次元軌跡点に対応する各地図空間関係を高次元空間にそれぞれ埋め込んで高次元地図空間関係を得て、各高次元地図空間関係と、対応する高次元地図点特徴とのドット積を行って1つの加重地図特徴を得て、該高次元軌跡点の複数の加重地図特徴に対して最大化処理を行って最大加重地図特徴を選択して得ることと、

最大加重地図特徴と、該高次元軌跡点に対応する高次元軌跡点特徴とを加算して1つのローカルシーン特徴を得ることと、を含む、

ことを特徴とする、例 3 に記載の方法。

【 0 1 4 4 】

例 6、現在の軌跡点集合及び現在の地図点集合に基づいて、各高次元軌跡点と該高次元軌跡点の周りの所定の複数の高次元地図点との間の複数の相対的な空間関係を決定して得ることは、

30

1つの高次元軌跡点とのユークリッド距離が予め設定された距離閾値内にある所定数の複数の高次元地図点を決定して得ることと、

該高次元軌跡点と、該複数の高次元地図点のうちの高次元地図点との間の相対的な空間関係をそれぞれ決定することと、を含み、

1つの相対的な空間関係は、該高次元軌跡点及び1つの高次元地図点の絶対位置及び相対位置と、該軌跡点と該地図点との間の相対距離及び相対方向とを含む、

ことを特徴とする、例 5 に記載の方法。

【 0 1 4 5 】

例 7、ローカルシーン特徴及び高次元地図点特徴に対して、グローバル軌跡特徴及びグローバル地図特徴をそれぞれ抽出することは、

40

ローカルシーン特徴における各特徴に対して特徴を抽出し、抽出された特徴に対して最大化処理を行って、選択された最大の特徴をグローバル軌跡特徴とすることと、

高次元地図点特徴における各特徴に対して特徴を抽出し、抽出された特徴に対して最大化処理を行って、選択された最大の特徴をグローバル地図特徴とすることと、を含む、

ことを特徴とする、例 3 に記載の方法。

【 0 1 4 6 】

例 8、軌跡予測ニューラルネットワークは、ローカルシーン特徴及び高次元地図点特徴に対して、グローバル軌跡特徴及びグローバル地図特徴をそれぞれ抽出することは、

軌跡予測ニューラルネットワークは、

50

複数回のグローバル特徴抽出操作を実行することを含み、各グローバル特徴抽出操作は、ローカルシーン特徴から抽出したグローバル軌跡特徴を高次元軌跡点特徴に連結してから、連結された高次元軌跡点特徴を次回のグローバル特徴抽出操作に出力することと、高次元地図点特徴から抽出したグローバル地図特徴を高次元地図点特徴に連結してから、連結された高次元地図点特徴を次回のグローバル特徴抽出操作に出力することと、を含む、  
ことを特徴とする、例 3 又は 7 に記載の方法。

【 0 1 4 7 】

例 9、グローバル軌跡特徴及びグローバル地図特徴に基づいてグローバルシーン特徴を決定して得ることは、  
グローバル軌跡特徴をグローバル地図特徴に加算してグローバルシーン特徴を得ることを含む、  
ことを特徴とする、例 3 に記載の方法。

10

【 0 1 4 8 】

例 10、現在の軌跡データは、運動主体及び他の 1 つ又は複数の運動物体の各軌跡点における速度をさらに含む、  
ことを特徴とする、例 1 に記載の方法。

【 0 1 4 9 】

例 11、現在の軌跡データは、運動主体及び各運動物体の物体種別データを含む、運動主体及び各運動物体の属性データをさらに含む、  
ことを特徴とする、例 1 に記載の方法。

20

【 0 1 5 0 】

例 12、運動主体又は運動物体が車両である場合、属性データは、ヘッドライトの属性データとテールライトの属性データとのうちの 1 つ又は複数をさらに含む、  
ことを特徴とする、例 11 に記載の方法。

【 0 1 5 1 】

例 13、現在の地図データは、各地図点とそれが存在する同じ道路要素における他の隣り合う地図点との位置の差をさらに含む、  
ことを特徴とする、例 1 に記載の方法。

【 0 1 5 2 】

例 14、現在の地図データは、各地図点の属性データをさらに含み、  
属性データは、該地図点が属する道路要素の種別、属する道路要素が該所定時間帯で含んだ複数の地図点における該地図点のシーケンス番号を含む、  
ことを特徴とする、例 13 に記載の方法。

30

【 0 1 5 3 】

例 15、軌跡予測ニューラルネットワークは、入力された現在の軌跡データ及び現在の地図データを取得することは、  
上流モジュールから、入力された現在の軌跡データ及び現在の地図データを取得することを含む、  
ことを特徴とする、例 1 に記載の方法。

40

【 0 1 5 4 】

例 16、トレーニングによって軌跡予測ニューラルネットワークを得る処理は、  
履歴の第 1 の軌跡データ、第 2 の軌跡データ及び履歴の地図データに基づいて、予め設定されたニューラルネットワークに対して、複数回の反復トレーニングを行うこと、を含み、  
第 1 の軌跡データ及び第 2 の軌跡データは時間的に前後に隣り合うデータ集合であり、いずれも、運動主体及び周りの 1 つ又は複数の運動物体の所定時間帯での複数の軌跡点を含み、各軌跡点は 1 つの対応する時点における空間位置を含み、履歴の地図データは第 1 の軌跡データに対応する時間帯での運動主体が存在する環境における道路要素の複数の地図点の空間位置を含み、予め設定されたニューラルネットワークは初期パラメータ集合を有

50

し、

1回の反復トレーニングは、

第1の軌跡データと履歴の地図データを入力としてニューラルネットワークに提供することと、

ニューラルネットワークは、第1の軌跡データ及び履歴の地図データを高次元空間における第1の軌跡点集合と履歴の地図点集合として表現することと、

第1の軌跡点集合及び履歴の地図点集合に基づいて、運動主体が存在する環境の地図特徴及び軌跡特徴を有するグローバルシーン特徴を抽出して得ることと、

グローバルシーン特徴に基づいて、運動主体の複数の軌跡点集合と、いずれも運動主体の将来の所定時間帯での複数の時点の空間位置を含む各軌跡点集合に対応する確率とを予測して出力することと、

10

出力された各軌跡点集合及び対応する確率と、第2の軌跡データとを入力として1つの対応する損失関数に提供し、該損失関数の出力を得ることと、

すべての損失関数の出力が予め設定された収束の条件を満たすか否かを判断することと、

収束の条件を満たすと判断した場合、トレーニングの完了を決定し、トレーニング後のニューラルネットワークのパラメータ集合を取得することと、

収束の条件を満たさないと判断した場合、ニューラルネットワークのパラメータを調整し、次回の反復トレーニングを実行することと、を含む、

ことを特徴とする、例1に記載の方法。

【0155】

20

例17では、

運動主体が現在の環境において運動を実行する過程において、入力された現在の軌跡データと現在の環境の現在の地図データとを取得することと、

現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現することと、

現在の軌跡点集合及び現在の地図点集合に基づいてグローバルシーン特徴を抽出して得ることと、のために使用されるエンコーダと、

グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合と、各予測軌跡点集合に対応する確率とを予測して出力するために使用されるデコーダとを含み、

現在の軌跡データは、運動主体と、現在の環境における他の1つ又は複数の運動物体との過去の所定時間帯での複数の軌跡点を含み、各軌跡点は1つの対応する時点における空間位置を含み、現在の地図データは該所定時間帯での現在の環境における道路要素の複数の地図点の空間位置を含み、グローバルシーン特徴は、現在の環境の地図特徴及び軌跡特徴を有し、各予測軌跡点集合は、いずれも運動主体の将来の所定時間帯での複数の時点の空間位置を含む、

30

ことを特徴とする、軌跡予測装置。

【0156】

例18、

エンコーダは、入力表示層を含み、

エンコーダは、現在の軌跡データ及び現在の地図データを高次元空間における現在の軌跡点集合及び現在の地図点集合として表現することは、

40

入力表示層は、所定の無順序の軌跡データのフォーマットで現在の軌跡点集合を表現し、無順序の高次元の現在の軌跡点集合を得ることと、所定の無順序の地図データのフォーマットで現在の地図点集合を表現し、無順序の現在の地図点集合を得ることとを含む、

ことを特徴とする、例17に記載の装置。

【0157】

例19、

現在の軌跡点集合及び現在の地図点集合に基づいて、グローバルシーン特徴を抽出して得るエンコーダは、

現在の軌跡点集合を所定の高次元空間に埋め込んで高次元軌跡点特徴を得て、現在の地図

50

点集合を所定の高次元空間に埋め込んで高次元地図点特徴を得ることに使用される埋め込み層と、現在の軌跡点集合、現在の地図点集合、高次元軌跡点特徴及び高次元地図点特徴に基づいて、ローカル地図情報を有する高次元軌跡点特徴であるローカルシーン特徴を取得して得ることに使用される地図関係学習層と、ローカルシーン特徴及び高次元地図点特徴に対してそれぞれグローバル特徴抽出操作を実行して、グローバル軌跡特徴及びグローバル地図特徴を抽出して得ることに使用されるグローバル特徴抽出層と、グローバル軌跡特徴及びグローバル地図特徴に基づいてグローバルシーン特徴を決定して得ることに使用される特徴出力層とを含む、

ことを特徴とする、例 17 に記載の装置。

【0158】

例 20、エンコーダは、強化層をさらに含み、

強化層は高次元軌跡点特徴及び高次元地図点特徴に対して方向性と接続性の強化処理を行うために使用され、強化層は自己注意ニューラルネットワークを含む、

ことを特徴とする、例 19 に記載の装置。

【0159】

例 21、地図関係学習層は、現在の軌跡点集合、現在の地図点集合、高次元軌跡点特徴及び高次元地図点特徴に基づいてローカルシーン特徴を取得して得ることは、

現在の軌跡点集合及び現在の地図点集合に基づいて、各高次元軌跡点と該高次元軌跡点の周りの所定の複数の高次元地図点との間の複数の相対的な空間関係を決定して得ることと

、  
1つの高次元軌跡点に対応する各地図空間関係を高次元空間にそれぞれ埋め込んで高次元地図空間関係を得て、各高次元地図空間関係と、対応する高次元地図点特徴とのドット積を行って1つの加重地図特徴を得て、該高次元軌跡点の複数の加重地図特徴に対して最大化処理を行って最大加重地図特徴を選択して得ることと、

最大加重地図特徴と、該高次元軌跡点に対応する高次元軌跡点特徴とを加算して1つのローカルシーン特徴を得ることと、を含む、

ことを特徴とする、例 19 に記載の装置。

【0160】

例 22、地図関係学習層は、現在の軌跡点集合及び現在の地図点集合に基づいて、各高次元軌跡点と該軌跡点の周りの所定の複数の高次元地図点との間の複数の相対的な空間関係を決定して得ることは、

1つの高次元軌跡点とのユークリッド距離が予め設定された距離閾値内にある所定数の複数の高次元地図点を決定して得ることと、

該高次元軌跡点と、該複数の高次元地図点のうちの高次元地図点との間の相対的な空間関係をそれぞれ決定することと、を含む、

1つの相対的な空間関係は、該高次元軌跡点及び1つの高次元地図点の絶対位置及び相対位置と、該軌跡点と該地図点との間の相対距離及び相対方向とを含む、

ことを特徴とする、例 21 に記載の装置。

【0161】

例 23、グローバル特徴抽出層は、ローカルシーン特徴及び高次元地図点特徴に対して、  
グローバル軌跡特徴及びグローバル地図特徴をそれぞれ抽出することは、

ローカルシーン特徴における各特徴に対して特徴を抽出し、抽出された特徴に対して最大化処理を行って、選択された最大の特徴をグローバル軌跡特徴とすることと、

高次元地図点特徴における各特徴に対して特徴を抽出し、抽出された特徴に対して最大化処理を行って、選択された最大の特徴をグローバル地図特徴とすることと、を含む、

ことを特徴とする、例 19 に記載の装置。

【0162】

例 24、グローバル特徴抽出層は、複数の積み重ねられたサブグローバル特徴抽出層を含み、

隣の1つ前のサブグローバル特徴抽出層は、ローカルシーン特徴から抽出したグローバル

10

20

30

40

50

軌跡特徴を高次元軌跡点特徴に連結してから、連結された高次元軌跡点特徴を隣の次のサブグローバル特徴抽出層に出力し、隣の1つ前のサブグローバル特徴抽出層は、高次元地図点特徴から抽出したグローバル地図特徴を高次元地図点特徴に連結してから、連結された高次元地図点特徴を隣の次のサブグローバル特徴抽出層に出力することを特徴とする、例19又は23に記載の装置。

【0163】

例25、特徴出力層は、グローバル軌跡特徴及びグローバル地図特徴に基づいてグローバルシーン特徴を決定して得ることは、特徴出力層が、グローバル軌跡特徴をグローバル地図特徴に加算してグローバルシーン特徴を得ることを含む、ことを特徴とする、例19に記載の装置。

10

【0164】

例26、デコーダは、複数の長短期記憶ネットワーク又はゲート付き回帰型ユニットを含む循環ニューラルネットワーク、又は多層パーセプトロンを含み、グローバルシーン特徴に基づいて、運動主体の複数の予測軌跡点集合を予測して出力するために使用されるマルチヘッド型デコーダと、各予測軌跡点集合に対応する確率を決定して得るために使用される確率決定層と、を含む、ことを特徴とする、例17に記載の装置。

20

【0165】

例27、1つのプロセッサと、少なくとも1つのメモリとを含み、少なくとも1つのメモリには、少なくとも1つの機器実行可能な命令が記憶されており、プロセッサは、少なくとも1つの機器実行可能な命令を実行して例1から16のいずれか1項に記載の方法を実現する、ことを特徴とする、軌跡予測装置。

【0166】

例28、例1から16のいずれか1項に記載の方法を含む軌跡予測処理を実行するために使用されるように構成されたコードセグメントを有することを特徴とする、コンピュータプログラム。

30

【0167】

例29、プロセッサに実行されて例1～16のいずれか1項に記載の方法を実現する少なくとも1つの機器実行可能な命令が記憶されている、ことを特徴とする、不揮発性記憶媒体。

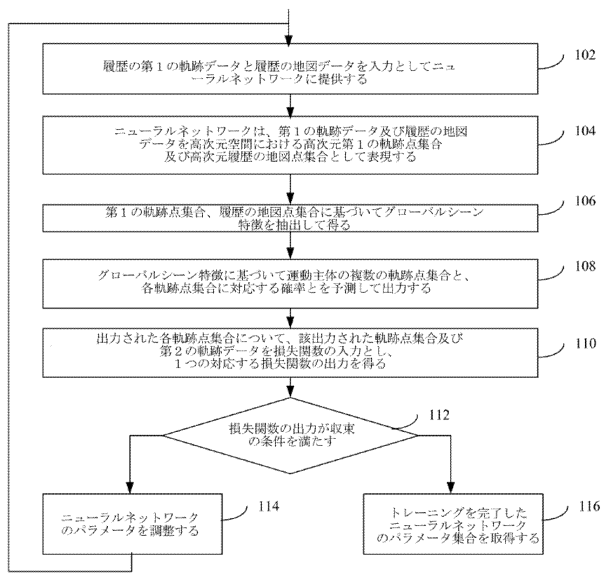
【0168】

当業者にとって、本発明の範囲および精神から逸脱することなく、本発明に対して様々な変更及び変形を行うことができることは、明らかである。このように、本発明に対するこれらの修正及び変形が本発明の請求項及びその均等技術の範囲に属すれば、本発明が、これらの変更及び変形を含むことも意図している。


40

【 図 面 】

【 図 1 】



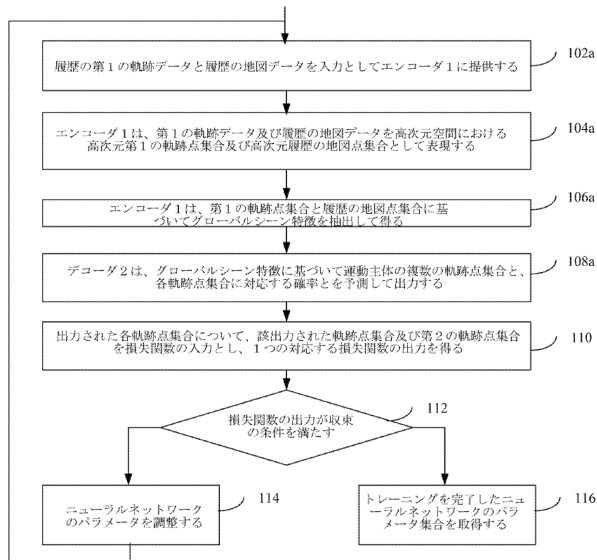
【 図 2 a 】



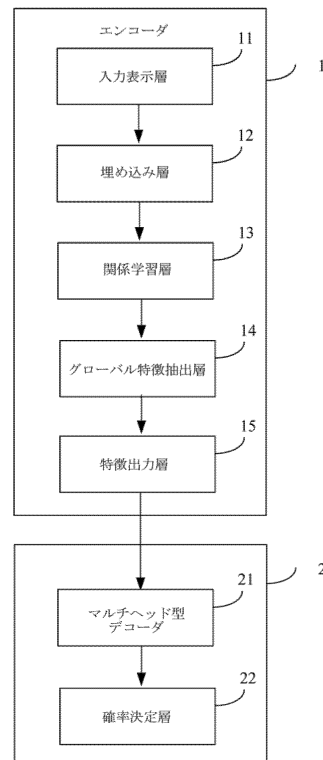
10

20

【 図 2 b 】



【 図 3 】




30


40

50

【 図 4 】




【 図 5 a 】




10

【 図 5 b 】



【 図 5 c 】



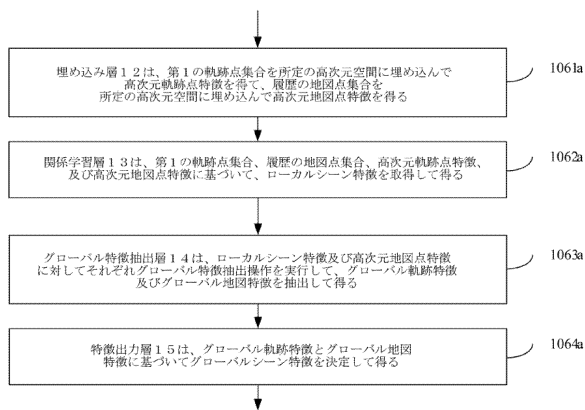
20

30

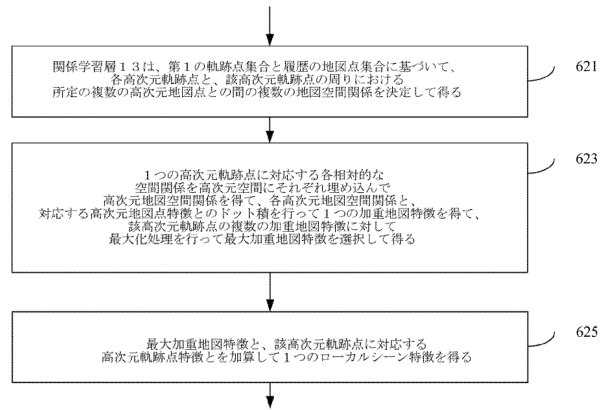
40

50

【 図 6 】



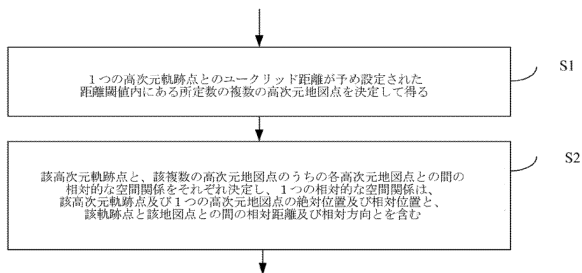
【 図 7 a 】




10

20

【 図 7 b 】



【 図 8 】




30


40

50

【 図 9 】

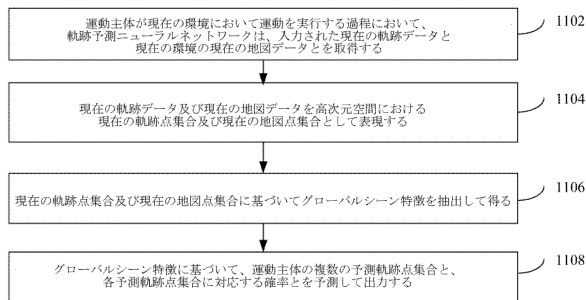


【 図 1 0 】

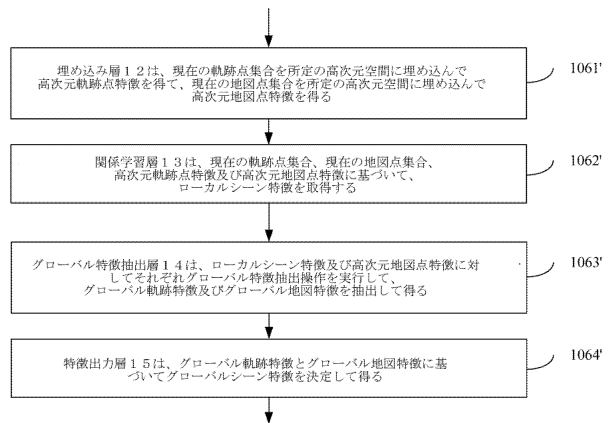


10

【 図 1 1 】



【 図 1 2 】



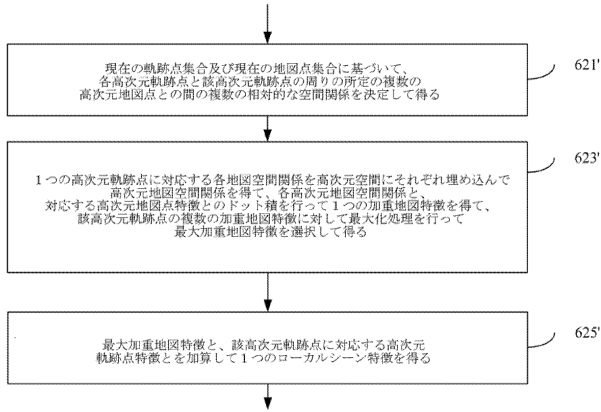
20

30


40

50

【 図 1 3 】

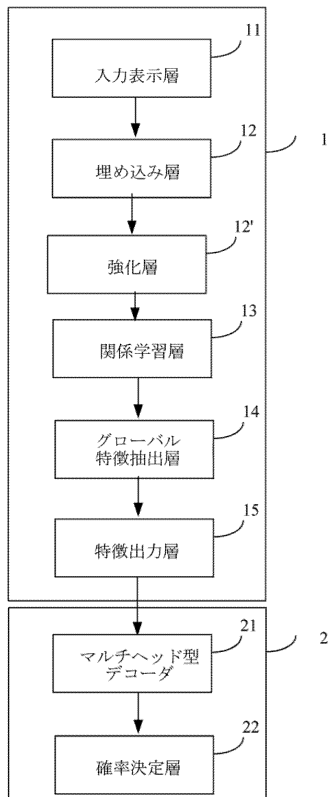


【 図 1 4 】




10

【 図 1 5 】



【 図 1 6 a 】




20

30


40

50

【 図 1 6 b 】




【 図 1 7 】



10

20

【 図 1 8 】



30

【 外国語明細書 】

40

50

说明书

一种轨迹预测方法和装置

技术领域

本申请涉及计算机技术领域，特别涉及一种轨迹预测方法和装置、存储介质和计算机程序。

背景技术

在人工智能得到研究和发展的基础上，很多技术领域结合人工智能得到了更广泛的应用和发展，例如机器人技术和无人驾驶技术。

在机器人领域和无人驾驶领域中，一个重要的环节就是轨迹预测。轨迹预测在很大程度上决定了无人驾驶系统的安全性能。以无人驾驶为例，在车辆行驶过程中，需要通过轨迹预测技术来实时地预测周围车辆在未来一段时间内的行驶轨迹，以便无人驾驶系统基于此预测结果做出安全的路径规划，从而避免碰撞发生。

发明内容

本申请实施例提供了一种轨迹预测方法和装置、存储介质和计算机程序，以解决已有技术中的轨迹预测方法存在的预测结果准确性低、可靠性低的问题。

根据本申请实施例的一个方面，提供了一种轨迹预测方法，包括：在运动主体在当前环境中执行运动的过程中，轨迹预测神经网络获取输入的当前轨迹数据、和当前环境的当前地图数据；其中，当前轨迹数据包括运动主体和当前环境中其它一个或多个运动物体在过去预定时间段内的多个轨迹点，每个轨迹点包括在一个对应时间点上的空间位置，当前地图数据包括在该预定时间段内当前环境中道路要素的多个地图点的空间位置；

将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集，当前轨迹点集包括当前轨迹数据中每个轨迹点对应的高维轨迹点，

当前地图点集包括当前地图数据中每个地图点对应的高维地图点；

根据当前轨迹点集和当前地图点集提取得到全局场景特征，其中，全局场景特征具有当前环境的地图特征和轨迹特征；

根据全局场景特征预测输出运动主体的多个预测轨迹点集以及每个预测轨迹点集对应的概率，每个预测轨迹点集均包括运动主体在未来预定时间段内多个时间点的空间位置。

根据本申请实施例的另一个方面，提供了一种轨迹预测装置，包括编码器和解码器；

编码器用于在运动主体在当前环境中执行运动的过程中，获取输入的当前轨迹数据、和当前环境的当前地图数据；其中，当前轨迹数据包括运动主体和当前环境中其它一个或多个运动物体在过去预定时间段内的多个轨迹点，每个轨迹点包括在一个对应时间点上的空间位置，当前地图数据包括在该预定时间段内当前环境中道路要素的多个地图点的空间位置；将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集；根据当前轨迹点集和当前地图点集提取得到全局场景特征，其中，全局场景特征具有当前环境的地图特征和轨迹特征；

解码器用于根据全局场景特征预测输出运动主体的多个预测轨迹点集以及每个预测轨迹点集对应的概率，每个预测轨迹点集均包括运动主体在未来预定时间段内多个时间点的空间位置。

根据本申请实施例的另一个方面，提供了一种轨迹预测装置，包括至少一个处理器和至少一个存储器，至少一个存储器中存储有至少一条机器可执行指令，至少一个处理器执行至少一条机器可执行指令后执行如上所述的轨迹预测方法。

根据本申请实施例的另一个方面，提供了一种计算机程序，该计算机程序具有被配置用于执行以下轨迹预测处理的代码段，该处理包括如上所述的轨迹预测方法。

根据本申请实施例的另一个方面，提供了一种非易失性存储介质，该存储介质中存储有用于轨迹预测处理的计算机程序，该处理包括如上所述的轨迹预

测方法。

根据本申请实施例提供的轨迹预测方法，能够在运动主体执行运动的实时过程中，将实时获取的当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集，根据当前轨迹点集和当前地图点集获取得到全局场景特征，全局场景特征具有当前环境的地图特征和轨迹特征，根据全局场景特征对运动主体在未来预定时间段内的轨迹进行预测。其中，将当前轨迹数据和当前地图数据表达为高维空间中的数据点集，能够获得同时具有时间特征和空间特征的数据点集，全局场景特征融合了当前环境的地图特征和轨迹特征，能够显著提高特征提取的精度，进一步，基于高效和高精度的特征提取，能够显著提高轨迹预测结果的精度和准确性。

附图说明

附图用来提供对本申请的进一步理解，并且构成说明书的一部分，与本申请的实施例一起用于解释本申请，并不构成对本申请的限制。

图1为本申请实施例提供的轨迹预测神经网络的训练方法的一种处理流程图；

图2a为本申请实施例提供的轨迹预测神经网络的一种结构示意图；

图2b为本申请实施例提供的轨迹预测神经网络的训练方法的另一种处理流程图；

图3为本申请实施例提供的轨迹预测神经网络的另一种结构示意图；

图4为图2b中步骤104a的处理过程流程图；

图5a为一个场景中的动态物体的示意图；

图5b为图5a所示场景中使用传统方法对动态物体的轨迹进行表达的示意图；

图5c为图5a所示场景中使用本申请实施例提供的方法对动态物体的轨迹进行表达的示意图；

图6为图2b中步骤106a的处理过程流程图；

图7a为图6中步骤1062a的处理过程流程图；

10

20

30

40

50

- 图 7b 为图 7a 中步骤 621 的处理过程流程图;
- 图 8 为一个示例中确定一个高维轨迹点的相邻高维地图点的示意图;
- 图 9 为一个示例中进行地图关系学习的传播示意图;
- 图 10 为图 6 中步骤 1063a 的处理过程流程图;
- 图 11 为本申请实施例提供的实时处理阶段中轨迹预测方法的一种处理流程图;
- 图 12 为图 11 中步骤 1106 的处理过程流程图;
- 图 13 为图 12 中步骤 1062' 的处理过程流程图;
- 图 14 为图 12 中步骤 1063' 的处理过程流程图;
- 图 15 为本申请实施例提供的轨迹预测神经网络的另一种结构示意图;
- 图 16a 为本申请实施例提供的轨迹预测神经网络的另一种结构示意图;
- 图 16b 为本申请实施例提供的轨迹预测神经网络的另一种结构示意图;
- 图 17 为本申请实施例提供的一次全局特征提取操作的一种流程图;
- 图 18 为本申请实施例提取的轨迹预测装置的结构示意图。

具体实施方式

为了使本技术领域的人员更好地理解本申请中的技术方案，下面将结合本申请实施例中的附图，对本申请实施例中的技术方案进行清楚、完整地描述，显然，所描述的实施例仅仅是本申请一部分实施例，而不是全部的实施例。基于本申请中的实施例，本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施例，都应当属于本申请保护的范围。

在机器人技术或者无人驾驶技术中，一个非常重要的技术就是，如何为机器人或者无人驾驶车辆做出安全可靠的路径规划。路径规划又依赖于准确有效地预测机器人或无人驾驶车辆所处环境中其它动态物体的运动轨迹。基于对动态物体运动轨迹准确有效的预测，才能对机器人或无人驾驶车辆做出安全可靠的路径规划。

在已有技术中，可以通过多种方法对物体的运动轨迹进行预测。

4

的上述问题。

本申请以无人驾驶技术为例，对本申请提供的轨迹预测方案进行说明。本领域技术人员可以理解的是，本申请提供的轨迹预测方案还可以应用在其他技术领域，例如机器人领域。

在本申请中，术语“车辆”在本申请中广泛地解释为包括任何移动物体，包括例如飞行器、船只、航天器、汽车、卡车、厢式货车、半挂车、摩托车、高尔夫球车、越野车辆、仓库运输车辆或农用车以及行驶在轨道上的运输工具，例如电车或火车以及其它有轨车辆。本申请中的“车辆”通常可以包括：动力系统、传感器系统、控制系统、外围设备和计算机系统。在其它实施例中，车辆可以包括更多、更少或者不同的系统。

其中，动力系统是为车辆提供动力运动的系统，包括：引擎/马达、变速器和车轮/轮胎、能源单元。

控制系统可以包括控制车辆及其组件的装置的组合，例如转向单元、节气门、制动单元等部件。

外围设备可以是允许车辆与外部传感器、其它车辆、外部计算设备和/或用户进行交互的设备，例如无线通信系统、触摸屏、麦克风和/或扬声器。

基于上述描述的车辆，无人驾驶车辆中还配置有传感器系统和无人驾驶控制装置。

传感器系统可以包括用于感测车辆所处环境的信息的多个传感器，以及改变传感器的位置和/或方向的一个或多个致动器。传感器系统可以包括全球定位系统传感器、惯性测量单元、无线电检测和测距 (RADAR) 单元、相机、激光测距仪、光检测和测距 (LIDAR) 单元和/或声学传感器等传感器的任何组合；传感器系统还可以包括监视车辆内部系统的传感器 (例如 O2 监视器、燃油表、引擎温度计等)。

无人驾驶控制装置可以包括至少一个处理器和至少一个存储器。处理器可以包括中央处理器 (CPU) 和/或图像处理器 (GPU)。存储器中存储有至少一条机器可执行指令，包括该至少一条机器可执行指令的程序产品可称为无人驾驶控制系统。无人驾驶控制系统可包括地图引擎、定位模块、感

6

在一种基于历史轨迹数据的预测方法中，通过搭建神经网络，使用历史的轨迹数据对神经网络进行训练，得到可进行轨迹预测的神经网络。在这种方法中，神经网络执行的操作通常包括特征提取操作和预测操作，通过特征提取操作获得动态物体 (例如车辆、摩托车、自行车或者行人) 在过去一段时间内行驶轨迹的时间-空间特征 (也即时空特征)，并通过预测操作基于已提取的时空特征预测车辆未来一段时间内的轨迹。特征提取操作通常先提取出多个时间点 (或称为时间特征)，然后提取出每个时间点下各动态物体的空间特征，并将空间特征与时间特征相融合。

在上述特征提取操作中，空间特征提取是非常耗时的操作，这样的处理过程无法应用在实时的处理环境中。并且，不同时间点之间动态物体之间的空间联系或空间影响被抛弃了，导致特征提取操作无法模拟多个时间点之间的空间特征的复杂联系和影响。这样的预测过程只能带来不可靠的预测结果。进一步，该方法无法处理有噪声的输入数据。有噪声的输入数据通常是指某个动态物体的不完整的轨迹数据。该方法对于不完整的轨迹数据通常有两种处理，一种是删除该动态物体的全部轨迹数据，另一种是对不完整轨迹数据进行填充。这样的限制显然对预测结果的准确性和精度造成影响，并且使得上述方法无法应用在实时的应用环境中。

在另一种基于历史轨迹和道路信息的方法中，通常将环境中的高精度地图信息和不同的车辆的行驶轨迹用俯视角的栅格化图像进行表示，将栅格化图像中的像素 RGB 值输入给神经网络，神经网络基于输入数据提取特征，并根据提取的特征进行轨迹预测。这种方法虽然能够保留轨迹信息和道路结构的信息，但是需要进行表示的场景面积较大，用图像表示会导致存储过量的冗余信息 (例如，大量不存在车辆的地方都会对应到图像中的像素点)，进而导致后续神经网络的运算效率低的问题。

可见，已有技术中的轨迹预测方法存在预测操作耗时长、效率低、无法应用在实时处理环境中的问题，以及存在预测结果准确性低、可靠性低、效率低的问题。

有鉴于此，本申请实施例提供了一种轨迹预测方案，以解决部分或全部

5

知模块、导航或路径模块、以及自动控制模块等多个模块，相应地处理器执行至少一条机器可执行指令可实现多种对应的功能，包括地图构建、定位、感知、导航或路径规划、以及车辆控制等功能。地图引擎和定位模块用于提供地图信息和定位信息。感知模块用于根据传感器系统获取到的信息和地图引擎提供的地图信息感知车辆所处环境的环境信息。导航或路径模块用于根据地图引擎、定位模块和感知模块的处理结果，为车辆规划行驶路径。自动控制模块将导航或路径规划模块的决策信息输入解耦转换成对车辆控制系统的控制命令输出，并通过车联网 (例如通过 CAN 总线、局域互联网络、多媒体定向系统传输等方式实现的车辆内部电子网络系统) 将控制命令发送给车辆控制系统中的对应部件，实现对车辆的自动控制；自动控制模块还可以通过车联网来获取车辆中各部件的信息。

在为车辆规划路径的过程中，需要通过轨迹预测技术来实时地预测周围的动态物体 (例如车辆、摩托车、自行车或者行人) 在未来一段时间内的行驶轨迹，以便无人驾驶系统基于此预测结果做出安全可靠的路径规划。

本申请实施例提供的一种基于学习的轨迹预测方案，该方案包括两个阶段，训练阶段和实时处理阶段。

在训练阶段，设置一个神经网络，该神经网络具有特定的网络结构，并具有初始的参数集。使用有监督的学习方法，训练神经网络根据历史的真实数据进行学习，在训练结果满足收敛条件的情况下，得到神经网络的参数集。该具有特定网络结构以及训练得到的参数集的神经网络，即为实现轨迹预测的神经网络，或称为轨迹预测神经网络。

在实时处理阶段，要对一个动态主体进行轨迹预测时，将动态主体和周围的动态物体的当前轨迹点集数据和当前环境的当前地图点集数据提供给轨迹预测神经网络，该神经网络对运动数据进行处理，并预测得出该动态主体的未来的多个轨迹点集。以及每个轨迹点集对应的概率。

下面通过多个实施例对本申请的技术方案进行说明。

训练得到轨迹预测神经网络

7

10

20

30

40

50

在训练阶段，构建一个神经网络，该神经网络可以包括多个网络层，并对该神经网络设置初始参数集。神经网络中的网络层的层数以及初始参数集可以根据应用场景的需要来进行具体设置。

本申请实施例中通过历史真实的第一轨迹数据和第二轨迹数据、以及历史地图数据对构建的神经网络进行训练。

在本申请的实施例中，第一轨迹数据和第二轨迹数据中包括运动主体以及周围一个或多个运动物体的多个轨迹点，每个轨迹点包括在一个对应时间点上的空间位置。该空间位置可以是二维位置、三维位置或者高维位置。例如，车辆在较为平坦的路面行驶的过程中，路面高程变化的幅度很小，高程信息可以被忽略，轨迹数据中可以只包括运动主体和运动物体的二维位置。在其他领域中，例如对于特殊用途的机器人，在运动过程中，可能存在较大幅度的高程变化，轨迹数据中可以包括运动主体和运动物体的三维位置。在其它的应用场景中，当存在或需要考虑其它维度的位置信息时，轨迹数据中还可以包括高维位置数据。为了简洁和方便起见，在本申请中均以二维位置为例进行解释和说明。本领域技术人员可以理解的是，当空间位置为三维位置或高维位置时，可以对三维位置或者高维位置进行相应的位置转换、坐标转换等处理，或者根据具体应用场景的需求进行相应的位置处理和坐标处理。

在本申请的实施例中，第一轨迹数据和第二轨迹数据是时间前后相邻的数据集，例如第一轨迹数据是第 i 个时间段的数据集，第二轨迹数据是第 i+1 个时间段的数据集。第 i 个时间段的时长为 m，第 i+1 个时间段的时长为 n，在一些实施例中，m 与 n 可以是相等的，例如均包括 3 秒时长。在另一些实施例中，m 与 n 也可以是不相等的，例如第 i 个时间段的时长为 3 秒，第 i+1 个时间段的时长为 2 秒。在第 i 个时间段中根据频率 u 得到多个时间点，在第 i+1 个时间段中根据频率 v 得到多个时间点，u 和 v 可以是相等的，也可以是不相等的。

历史地图数据包括第一轨迹数据对应的时间段内（例如第 i 个时间段）运动主体所在环境中道路要素的多个地图点的空间位置。历史地图数据可

以来自于车辆行驶过程中的高精度地图。道路要素可以是车道线、人行道、道路边缘、匝道、交叉路口、转盘等要素。本申请中对车道线等道路要素按照预定距离进行抽样，得到一系列的地图点，每个地图点记录有该点的空间位置。与上述轨迹点的空间位置相对应，地图点的空间位置也可以是二维位置、三维位置或者高维位置。

图 1 中示出了本申请实施例提供的轨迹预测神经网络的训练方法的处理流程，该训练处理包括多次迭代训练，一次迭代训练包括下列处理。

步骤 102、将历史的第一轨迹数据和历史地图数据作为输入提供给神经网络。

步骤 104、神经网络将第一轨迹数据和历史地图数据表达为高维空间中的第一轨迹点集和历史地图点集；

步骤 106、根据第一轨迹点集、历史地图点集提取得到全局场景特征；其中，全局场景特征具有当前环境的地图特征和轨迹特征；

步骤 108、根据全局场景特征预测输出运动主体的多个轨迹点集以及每个轨迹点集对应的概率，每个轨迹点集均包括运动主体在未来预定时间段内多个时间点的空间位置；

步骤 110、对于输出的每一个轨迹点集，将该输出的轨迹点集和第二轨迹数据作为损失函数的输入，得到一个对应的损失函数的输出；

步骤 112、判断全部损失函数的输出是否满足预设的收敛条件，在判断满足收敛条件的情况下，处理进行到步骤 116，在判断不满足收敛条件的情况下，处理返回到步骤 114；

步骤 114、调整神经网络的参数，处理返回步骤 102；

步骤 116、确定训练完成、并获得训练完成的神经网络的参数集。

下面通过一个示范性实施例对图 1 所示的处理过程进行说明。

假设运动主体与运动物体的数量为 N，第一轨迹数据中包括 T 个时间点， $x_n^t \in R^2$  表示运动主体或者运动物体 n 在时间点 t 的二维位置， $t \in \{1, \dots, T\}$ ， $R^2$  为二维空间的表示。运动主体或者一个运动物体 n 的轨迹数据可表示为  $X_n = \{H_n, F_n\}$ ，其中  $H_n = \{x_n^1, x_n^2, \dots, x_n^T\}$  表示该物体在过去时间

10

20

点 t 到观察时间点 T 的历史位置， $F_n = \{x_n^{T+1}, x_n^{T+2}, \dots, x_n^{T+s}\}$  表示该物体在未来的时间点 T+1 到时间点 T+s 的未来位置。 $H_n$  可以看作是第一轨迹点集， $F_n$  可以看作是第二轨迹点集。

假设历史地图点集中包括 N 段车道线，第一轨迹数据对应的时间段为时间点 t 到观察时间点 T，该段时间中第 n 段车道线的地图数据为  $C_n = \{c_n^1, \dots, c_n^T\}$ ， $C_n$  表示第 n 段车道线包括的 T 个抽样地图点的地图位置， $c_n^t \in R^2$  表示第 n 段车道线中抽样地图点 t 的地图位置。

轨迹预测的目的是通过  $\{H_n\}_{n=1}^N$  和地图数据  $\{C_n\}_{n=1}^N$  预测得到多模态分布的预测轨迹点集，该多模态分布的预测轨迹点集能够与  $\{F_n\}_{n=1}^N$  形成最佳匹配。

在该示范性实施例中，如图 2a 所示，神经网络的结构根据实现的功能可以包括编码器 1 和解码器 2。在该示范性实施例中对神经网络的训练处理包括如图 2b 所示的过程：

步骤 102a、将历史的第一轨迹数据和历史地图数据作为输入提供给编码器 1。

步骤 104a、编码器 1 将第一轨迹数据和历史地图数据表达为高维空间中的第一轨迹点集和历史地图点集；

步骤 106a、编码器 1 根据第一轨迹点集和历史地图点集提取得到全局场景特征；其中，全局场景特征具有运动主体所在环境的地图特征和轨迹特征。

步骤 108a、解码器 2 根据全局场景特征预测输出运动主体的多个轨迹点集以及每个轨迹点集对应的概率，每个轨迹点集均包括运动主体在未来预定时间段内多个时间点的空间位置。

步骤 110、对于输出的每一个轨迹点集，将该输出的轨迹点集和第二轨迹点集作为损失函数的输入，得到一个对应的损失函数的输出；

步骤 112、判断全部损失函数的输出是否满足预设的收敛条件，在判断满足收敛条件的情况下，处理进行到步骤 116，在判断不满足收敛条件的情况下，处理返回到步骤 114；

步骤 114、调整神经网络的参数，处理返回步骤 102a；

步骤 116、确定训练完成、并获得训练完成的神经网络的参数集。

下面通过一些实施例中神经网络的结构设置，来说明上述步骤 104a-108a 的处理过程。

在一些实施例中，如图 3 所示，可以在编码器 1 中设置输入表示层 11 来实施步骤 104a。如图 4 所示，步骤 104a 可以实施为如下的处理过程：

步骤 1041a、输入表示层 11 用预定的无序的轨迹数据格式对第一轨迹数据进行表达，得到无序的第一轨迹点集；

步骤 1042a、用预定的无序的地图数据格式对历史地图数据进行表达，得到无序的历史地图点集。

在步骤 1041a 中，预设的轨迹数据格式可以根据具体应用场景的需要而进行具体设置。在一个示例中，出于简洁和可扩展性考虑，可以使用如下公式 (1) 所示的轨迹数据格式对第一轨迹数据进行表示。

$$P_n^t = \{x_n^t, t\}, \quad P = \{p_n^t | \forall t \in \{1, \dots, T\}, \forall n \in \{1, \dots, N\}\} \quad (1)$$

其中， $n \in \{1, \dots, N\}$  为运动主体以及一个或多个运动物体， $t \in \{1, \dots, T\}$  为多个时间点， $x_n^t$  为物体 n 在时间 t 的二维位置（也即一个轨迹点）， $p_n^t$  为物体 n 在时间 t 的空间位置  $x_n^t$  映射在高维空间中的一个对应点，P 为映射在高维空间中的第一轨迹点集。

在步骤 1042a 中，使用如下的公式 (2) 所示的地图数据格式对历史地图点集进行表示。

$$M_n^t = \{c_n^t, t\}, \quad M = \{m_n^t | \forall t \in \{1, \dots, T\}, \forall n \in \{1, \dots, N\}\} \quad (2)$$

其中， $c_n^t$  为第 n 段车道线中抽样地图点 t 的地图位置，第 n 段车道线中包括 T 个抽样地图点，该历史地图点集中包括 N 段车道线， $m_n^t$  为一个抽样地图点  $c_n^t$  映射在高维空间中的一个对应点，M 为映射在高维空间中的历史地图点集。

在一个示范性场景中，输入表示层 11 使用公式 (1) 将第一轨迹数据中

30

40

50

的数据映射到高维空间（例如时空坐标系）。在该场景中，如图 5a 所示，其中动态物体包括两个车辆、一个自行车和一个行人。图 5b 示出了用传统的表示方法对该场景中的动态物体的轨迹进行表达的情况，也即在二维空间坐标系中表达出物体的二维位置。在该二维空间坐标系中，每个数据点只具有空间特征。图 5c 示出了用本申请实施例提供的数据表达方法将该场景的第一轨迹集表达在时空坐标系中的情况。在该坐标系中，x 轴和 y 轴表示二维空间坐标轴，z 轴是时间轴，该坐标系中的每个数据点同时具有时间特征和空间特征。

通过使用预定的无序的可扩展的数据格式对第一轨迹数据进行表达，可以将运动主体和运动物体的按时间顺序发生的位置数据映射到时空坐标系中，也即将有序的数据映射为离散的无序的点集。表达在时空坐标系中的高维第一轨迹点集不随第一轨迹数据的表达方式或表达顺序的改变而改变，并且不会由于一个物体存在缺失数据而导致该物体的数据无法表达。可见，通过将第一轨迹数据映射到高维空间中，可以克服已有技术中当输入数据存在噪声时需要额外处理的问题，能够提高处理存在缺失的输入数据的鲁棒性。

并且，通过预定的数据格式能够将第一轨迹数据中的全部数据统一表达在同一个高维空间（例如时空坐标系）中，将时间特征和空间特征统一到同一个表达中，使得后续的特征抽取处理能够抽取得到统一的、融合的时间特征和空间特征。

输入表示层 11 通过使用预定的无序的数据格式也即公式 (2) 对历史地图数据进行表达，能够将道路要素表达为高维空间（例如时空坐标系）中的离散的无序的点集。表达在时空坐标系中的地图点集不随道路数据的表达方式或者表达顺序的改变而改变，也不会由于道路要素中缺失数据而导致道路要素无法表达。

另一方面，通过将运动主体和运动物体的轨迹数据、以及道路要素的地图数据表达为高维空间中离散、无序的高维数据点集，相比于已有技术中通过栅格化图像表示高精度地图信息和不同的车辆的行驶轨迹，并将栅格化

图像中的像素 RGB 值输入给神经网络提取特征，能够显著地减少神经网络处理的数据量，提高神经网络的处理速度和处理效率。

在一些实施例中，如图 3 所示，可以在编码器 1 中设置嵌入层 12、关系学习层 13、全局特征提取层 14 和特征输出层 15 来实施步骤 106a。如图 6 所示，步骤 106a 可以实施为如下的处理过程：

步骤 1061a、嵌入层 12 将第一轨迹点集嵌入到预定的高维空间中得到高维轨迹点特征；将历史地图点集嵌入到预定的高维空间中得到高维地图点特征。

嵌入操作的目的是将高维空间的高维轨迹点 $p_n^t$ 映射为隐藏的轨迹特征 $\bar{p}_n^t$ ，该轨迹特征能够统一数据的时间特征和空间特征。在一些实施例中，嵌入层 12 可以通过多层感知机 (Multilayer Perceptron, MLP) 来实现。MLP 可以包括全连接的多层网络，网络中神经元的激活函数可以是 ReLU 激活函数。进一步，还可以在嵌入层的每一层之后设置一个批量归一化层 (Batch Normalization, BN)。

为了方便说明，可通过下列公式 (3) 来表示将第一轨迹点集嵌入（或映射）到高维空间的操作。其中， $MLP_p$  为多层感知机。

$$\bar{p}_n^t = MLP_p(p_n^t) \quad (3)$$

同理，对历史地图点集的嵌入原理类似，可以通过下列公式 (4) 来将高维地图点 $m_n^t$ 映射为地图特征 $\bar{m}_n^t$ 。其中， $MLP_m$  为多层感知机。

$$\bar{m}_n^t = MLP_m(m_n^t) \quad (4)$$

嵌入操作将高维的第一轨迹点集和高维的历史地图点集嵌入到由多维度构成的高维空间，每一维度中的数据均包括时间特征和空间特征。

步骤 1062a、关系学习层 13 根据第一轨迹点集、历史地图点集、高维轨迹点特征和高维地图点特征获取得到局部场景特征；该局部场景特征是具有局部地图信息的高维轨迹点特征；

在一个示例中，如图 7a 所示，步骤 1062a 可以实施为如下的处理过程：

步骤 621、关系学习层 13 根据第一轨迹点集和历史地图点集确定得到每个高维轨迹点与该高维地图点周围预定多个高维地图点之间的多个地图

10

20

空间关系；

在一个示例中，关系学习层 13 中可以设置进行计算处理的网络来实施步骤 621，如图 7b 所示，步骤 621 的实施过程可以包括：

步骤 S1、确定得到与一个高维轨迹点的欧式距离在预设的距离阈值内的预定数量的多个高维地图点。

在一个示例中，图 8 所示，(a) 部分表示第一轨迹数据中的轨迹点、以及历史地图数据中的地图点，通过输入表示层 11 对第一轨迹数据和历史地图数据进行表示后，得到如 (b) 部分所示的高维轨迹点和高维地图点，通过步骤 S1 确定得到与一个高维轨迹点相邻的多个高维地图点，如 (c) 部分所示。

图 9 通过一个直观的表达来表示这种关联。在一个高维轨迹点 $p_n^t$ 的预设距离内，具有四个邻近的高维地图点： $m_{n-1}^t, m_n^t, m_{n+1}^t, m_{n+2}^t$ 。高维地图点指向高维轨迹点的箭头表示使用关系学习传播局部地图特征到轨迹特征、得到相对空间关系的过程，也即如下的步骤 S2。

步骤 S2、分别确定该高维轨迹点与该多个高维地图点中每个高维地图点之间的相对空间关系，一个相对空间关系包括该高维轨迹点和一个高维地图点的绝对位置和相对位置、以及该轨迹点和该地图点之间的相对距离和相对方向。

其中， $x_n^t$  是高维轨迹点的绝对位置， $c_n^t$  是高维地图点的绝对位置， $(x_n^t - c_n^t)$  是高维轨迹点和高维地图点之间的相对位置， $dist(x_n^t, c_n^t)$  是高维轨迹点与高维地图点之间的相对距离， $\cos(v_n^t, u_n^t)$  是高维轨迹点与高维地图点之间的相对方向， $u_n^t = c_n^t - x_n^t$ ， $v_n^t = p_n^t - x_n^t$ ， $v_n^t$  是运动主体或运动物体 n 在时间点 t 上的速度。

一个高维轨迹点与一个高维地图点之间的相对空间关系 $e_{nn}^t$ 可以表示为如下的公式 (5)：

$$e_{nn}^t = \{x_n^t, c_n^t, x_n^t - c_n^t, dist(x_n^t, c_n^t), \cos(v_n^t, u_n^t)\} \quad (5)$$

步骤 623、将一个高维轨迹点对应的每个相对空间关系分别嵌入到高维空间中得到高维地图空间关系，将每个高维地图空间关系与对应的高维地

图点特征进行点乘得到一个加权地图特征；对该高维轨迹点的多个加权地图特征进行最大化处理、选取得到最大加权地图特征；

其中，将一个高维轨迹点对应的多个相对空间关系均嵌入到高维空间中，该操作可以参考上述公式 (3) 或 (4) 的嵌入操作，可以在关系学习层 13 中设置嵌入层（例如多层感知机 MLP）来执行该嵌入操作。嵌入操作后可以得到多个高维地图空间关系，将多个高维地图空间关系分别与该高维轨迹点进行点乘之后得到多个点乘结果，也即多个加权地图特征，可以在关系学习层 13 中设置实现点乘计算的神经网络来执行点乘操作。对这多个点乘结果进行最大化处理后可以得到最大加权地图特征，可以在关系学习层 13 中设置池化层（例如最大池化层或者平均池化层）来实现最大化处理。

步骤 625、将最大加权地图特征与该高维轨迹点对应的高维轨迹点特征相加得到一个局部场景特征。

步骤 623 和步骤 625 的处理过程可以通过公式 (6) 来表示。

$$\bar{p}_n^t = \bar{p}_n^t + A(\{MLP_p(e_{nn}^t) \cdot \bar{m}_n^t, \forall \bar{m}_n^t \in \text{top } k\}) \quad (6)$$

其中， $\bar{p}_n^t$  为局部场景特征，符号 A 表示最大化处理， $MLP_p$  为对相对空间关系进行嵌入处理， $\bar{m}_n^t$  为高维地图点特征，k 为与一个轨迹点的欧式距离在预设的距离阈值内的地图点的预定个数。

通过如图 7a 的处理，可以将一个高维轨迹点周围多个高维地图点的地图信息传播到该高维轨迹点上，也即将一个高维轨迹点周围的局部地图信息传播到该高维轨迹点上，得到具有局部地图信息以及轨迹点的时空信息的局部场景特征。局部场景特征为后续得到精度更高的预测轨迹点集提供数据基础。

步骤 1063a、全局特征提取层 14 对局部场景特征和高维地图点特征分别执行全局特征提取操作，提取得到全局轨迹特征和全局地图特征。

在一个实施例中，如图 10 所示，步骤 1063a 可以实施为如下处理过程：

步骤 631、对局部场景特征中的每个特征提取特征，并对提取的特征进行最大化处理、将选取得到的最大特征作为全局轨迹特征；

步骤 633、对高维地图点特征中的每个特征提取特征，对提取的特征进

30

40

行最大化处理、将选取得到的最大特征作为全局地图特征。

在得到了局部场景特征和高维地图点特征后，需要对数据的不同排列保持不变性。特征提取层对高维空间包括的各个维度的数据进行特征提取，得到包括融合了时间特征和空间特征的全局地图特征，以及融合了局部地图特征的全局轨迹特征；全局特征包括多维特征，每一维对应特征空间的一部分也即表达时空特征中的一部分。

在一些实施例中，全局特征提取层 14 可以包括一个池化层，通过一个池化层依次提取全局轨迹特征和全局地图特征，也可以包括两个并列的池化层，通过这两个池化层分别提取全局轨迹特征和全局地图特征。

步骤 1064a、特征输出层 15 根据全局轨迹特征和全局地图特征确定得到全局场景特征。

其中，特征输出层 15 将全局轨迹特征和全局地图特征相加得到全局场景特征。该全局场景特征中包括全局地图特征和全局轨迹特征，为后续得到精确度更高的预测轨迹点集提供数据基础。

在解码器 1 确定得到全局场景特征之后，解码器 2 可以根据全局场景特征进行预测处理。

在一些实施例中，如 3 所示，可以在解码器 2 中设置多头解码器 21 和概率确定层 22。

多头解码器 21 可以包括多个子解码器，子解码器可以是循环神经网络或者多层感知机。循环神经网络包括长短期记忆网络 (Long-Short Term Memory, LSTM) 或者门控循环单元 GRU。在其他的一些实施例中，还可以选择随机解码器 (Stochastic Decoder)。

每个子解码器具有特定的初始参数集，根据全局场景特征预测得到一个预测轨迹点集，则多头解码器 21 输出多个预测轨迹点集。

概率确定层 22 针对每个预测轨迹点集确定得到一个对应的概率。概率确定层 22 可以是一个分类器。

在上述步骤 110 中，对于输出的每一个轨迹点集，将该输出的轨迹点集和第二轨迹点集作为损失函数的输入，得到一个对应的损失函数的输出。

16

轨迹点集和当前地图点集，当前轨迹点集包括当前轨迹数据中每个轨迹点对应的高维轨迹点，当前地图点集包括当前地图数据中每个地图点对应的高维地图点；

步骤 1106、根据当前轨迹点集和当前地图点集提取得到全局场景特征，其中，全局场景特征具有当前环境的地图特征和轨迹特征；

步骤 1108、根据全局场景特征预测输出运动主体的多个预测轨迹点集以及每个预测轨迹点集对应的概率，每个预测轨迹点集均包括运动主体在未来预定时间段内多个时间点的空间位置。

下面通过一个示例性实施例对图 11 所示处理进行说明，在该示例中神经网络可以是如图 3 所示的神经网络。该神经网络中包括编码器 1 和解码器 2。编码器 1 中包括输入表示层 11、嵌入层 12、关系学习层 13、全局特征提取层 14 和特征输出层 15。解码器 2 中包括多头解码器 21 和概率确定层 22。

在上述步骤 1102 中，输入给轨迹预测神经网络的当前轨迹数据可以来自于上游模块，例如感知模块。感知模块从感知数据中选择出当前轨迹数据，并将当前轨迹数据提供给轨迹预测神经网络的编码器 1。输入该轨迹预测神经网络的当前地图数据，可以是来自上游地图模块的高精度地图数据。当前轨迹数据的设置可以具有与上述第一轨迹数据相同的设置，当前地图数据的设置可以具有与上述当前地图数据相同的设置。

上述步骤 1104 可以通过如图 3 所示的输入表示层 11 来执行步骤 1104。

在该示例中，输入表示层 11 用预定的无序的轨迹数据格式对当前轨迹数据进行表达，得到映射在高维空间的无序的当前轨迹点集，轨迹数据格式可以是上述公式 (1) 所示的格式，当前轨迹点集包括当前轨迹数据中每个轨迹点对应的高维轨迹点；用预定的无序的地图数据格式对当前地图数据进行表达，得到映射在高维空间的无序的当前地图点集，地图数据格式可以是上述公式 (2) 所示的格式，当前地图点集包括当前地图数据中每个地图点对应的高维地图点。

步骤 1104 的具体处理过程可以参照上述步骤 104a、公式 (1) 和公式

18

损失函数可以是高斯分布的负对数似然 (Negative Log likelihood, NLL) 函数。

通过上述的训练，可以得到神经网络的参数集，该具有训练得到的参数集、且具有特定结构的神经网络即为轨迹预测神经网络。通过该轨迹预测神经网络，能够在实时处理阶段，对输入的当前轨迹点集和当前地图点集进行处理，预测得到未来时间段的多个预测轨迹点集以及每个预测轨迹点集对应的概率。

通过上述训练过程，通过将历史的第一轨迹数据映射为高维空间中的第一轨迹点集、将历史地图数据映射为高维空间中的历史地图点集，将有序的轨迹数据转变为无序的数据点，能够克服数据噪声带来的后续影响，提高数据处理的鲁棒性；通过端到端的学习方式实现对轨迹数据和地图数据的特征提取，能够显著地提高特征提取操作的速度和效率，更好地满足应用场景的实时性需求；提取得到的全局场景特征具有全局轨迹特征和全局地图特征，全局轨迹特征融合了局部地图特征和轨迹特征，轨迹特征同时具有时间特征和空间特征；基于全局场景特征预测得到的预测轨迹点集，能够显著提高轨迹预测结果的精度和准确性。

实时处理阶段的轨迹预测

与图 1 所示的处理相对应，图 11 示出了在实时处理阶段通过轨迹预测神经网络对物体的运动轨迹进行预测的处理过程。

步骤 1102、在运动主体在当前环境中执行运动的过程中，轨迹预测神经网络获取输入的当前轨迹数据和当前环境的当前地图数据；其中，当前轨迹数据包括运动主体和当前环境中其它一个或多个运动物体在过去预定时间段内的多个轨迹点，每个轨迹点包括在一个对应时间点的空间位置，当前地图数据包括在该预定时间段内当前环境中道路要素的多个地图点的空间位置；

步骤 1104、将当前轨迹数据和当前地图数据表达为高维空间中的当前

17

(2) 以及图 4 的处理。

在该示例中，上述步骤 1106 可以通过如图 3 所示的嵌入层 12、关系学习层 13、全局特征提取层 14 和特征输出层 15，以及参考图 6 所示的处理来执行。如图 12 所示，步骤 1106 可以包括：

步骤 1061'、嵌入层 12 将当前轨迹点集嵌入到预定的高维空间中得到高维轨迹点特征，将当前地图点集嵌入到预定的高维空间中得到高维地图点特征。嵌入层 12 的具体操作可以使用上述公式 (3) 和公式 (4)、参照上述的步骤 1061a 的处理来实现。

步骤 1062'、关系学习层 13 根据当前轨迹点集、当前地图点集、高维轨迹点特征和高维地图点特征获取得到局部场景特征，该局部场景特征是具有局部地图信息的高维轨迹点特征。关系学习层 13 的具体操作可以参考上述步骤 1062a 的处理来实现。

步骤 1063'、全局特征提取层 14 对局部场景特征和高维地图点特征分别执行全局特征提取操作，提取得到全局轨迹特征和全局地图特征。全局特征提取层 14 的具体操作可以参考上述步骤 1063a 来实现。

步骤 1064'、特征输出层 15 根据全局轨迹特征和全局地图特征确定得到全局场景特征。特征输出层 15 的具体操作可以参考上述步骤 1064a 来实现。

示例性地，参考图 7a 和上述的步骤 1062a，如图 13 所示，步骤 1062' 中关系学习层 13 的处理可以包括：

步骤 621'、根据当前轨迹点集和当前地图点集确定得到每个高维轨迹点与该高维轨迹点周围预定多个高维地图点之间的多个相对空间关系；该处理可以参考图 7b 和上述步骤 621 的处理，包括：确定得到与一个高维轨迹点的欧式距离在预设的距离阈值内的预定数量的多个高维地图点；分别确定该高维轨迹点与该多个高维地图点中每个高维地图点之间的相对空间关系，一个相对空间关系包括该高维轨迹点和一个高维地图点的绝对位置和相对位置、以及该轨迹点和该地图点之间的相对距离和相对方向。相对空间关系的表达可以参考上述公式 (5)。

19

10

20

30

40

50

步骤 623'、将一个高维轨迹点对应的每个地图空间关系分别嵌入到高维空间中得到高维地图空间关系，将每个高维地图空间关系与对应的高维地图点特征进行点乘得到一个加权地图特征；对该高维轨迹点的多个加权地图特征进行最大化处理、选取得到最大加权地图特征；

步骤 625'、将最大加权地图特征与该高维轨迹点对应的高维轨迹点特征相加得到一个局部场景特征。

步骤 623'和步骤 625'的操作可以参照上述步骤 623 和步骤 625 来实现。一个高维轨迹点对应的局部场景特征可以使用上述公式 (6) 来表示。当前轨迹点集中的多个高维轨迹点，可以得到对应的多个局部场景特征。

示例性地，参考图 10 和上述步骤 1063a，如图 14 所示，步骤 1063'中全局特征提取层 14 的处理包括：

步骤 631'、对局部场景特征中的每个特征提取特征，并对提取的特征进行最大化处理、将选取得到的最大特征作为全局轨迹特征；

步骤 633'、对高维地图点特征中的每个特征提取特征，对提取的特征进行最大化处理、将选取得到的最大特征作为全局地图特征。

示例性地，参考上述步骤 1064a，特征输出层 15 的处理可以包括：将全局轨迹特征和全局地图特征相加得到全局场景特征。

通过上述处理，将当前轨迹数据映射为高维空间中的当前轨迹点集、将当前地图数据映射为高维空间中的当前地图点集，将有序的轨迹数据转变为无序的数据点，能够克服数据噪声带来的后续影响，提高数据处理的鲁棒性；通过端到端的处理方式实现对轨迹数据和地图数据的特征提取，能够显著地提高特征提取操作的速度和效率，更好地满足应用场景的实时性需求；提取得到的全局场景特征具有全局轨迹特征和全局地图特征，全局轨迹特征融合了局部地图特征和轨迹特征，轨迹特征同时具有时间特征和空间特征，全局场景特征能够为轨迹预测提供准确有效的数据基础。

在该示例中，步骤 1108 的处理中，解码器 21 中的多头解码器 21 输出多个预测轨迹点集，概率确定层 22 针对每个预测轨迹点集确定一个对应的概率。

20

解码器 2 基于更为准确有效的全局场景特征能够预测得到精度更高、准确率更高的轨迹点集。

在其他的一些实施例中，基于上述任意一个实施例，还可以对第一轨迹数据、第二轨迹数据、当前轨迹数据中的数据项进行划分和扩展，将数据项划分为轨迹数据和属性数据。相应地，对输入表示层 11 使用的轨迹数据格式进行对应扩展。

在一个示例中，轨迹数据中可以包括物体在一个预定时间段中多个时间点的空间位置和速度。在这种情况下，基于预定数据格式的可扩展性，可以使用公式 (7) 对轨迹数据格式进行定义。

$$P_n^t = \{x_n^t, v_n^t, t\}, P = \{P_n^t | \forall t \in \{1, \dots, T\}, \forall n \in \{1, \dots, N\}\} \quad (7)$$

其中， $v_n^t$ 是物体在时间  $t$  的速度。

通过实验和测试结果表明，在轨迹数据中增加速度数据，能够进一步提高轨迹预测结果的精度。

在另一个示例性实施例中，轨迹点集中可以包括轨迹数据和属性数据。属性数据可以包括物体的类别数据，例如该物体是行人、自行车或车辆。在具体的应用场景中，物体的类别数据还可以是其它的属性，例如车辆的属性包括厢式货车、牵引车、半挂车等情形；还可以增加车灯的属性项，例如车前灯属性数据或车尾灯属性数据，通过车灯属性数据标识车灯是否开启；还可以增加。在这种情况下，可以用公式 (8) 进行轨迹数据格式定义。

$$P_n^t = \{x_n^t, v_n^t, \phi_n, t\}, P = \{P_n^t | \forall t \in \{1, \dots, T\}, \forall n \in \{1, \dots, N\}\} \quad (8)$$

其中， $\phi_n$ 表示物体的类别，该类别的值可以是预先设定的，例如车辆为

21

1、行人为 2、自行车为 3。公式 (8) 中示例性地扩展了一项属性数据，根据具体应用场景的需求，还可以扩展多项属性数据。

属性数据中还可以包括物体的标识数据，例如物体是运动主体或者是周围的运动物体。在这种情况下，可以用公式 (9) 进行轨迹数据格式定义。

$$P_n^t = \{x_n^t, v_n^t, \phi_n, t, id\}, P = \{P_n^t | \forall t \in \{1, \dots, T\}, \forall n \in \{1, \dots, N\}\} \quad (9)$$

其中， $id$  标识物体为运动主体或者周围的运动物体，例如该数据的值为 1 时表示物体  $n$  为运动主体，值为 0 时表示物体  $n$  为周围的运动物体。

由于预定的可扩展的数据格式可以根据应用场景的需要包括多个数据，从而数据格式的长度是可变的。在已有技术中，如果需要对输入数据增加或者减少数据项，需要研发人员对数据进行手工编排和微调，工作量巨大。本申请实施例提供可变动长度的数据格式，只需要在数据格式中增加或减少数据项，就可以对数据进行后续处理，避免了手工编排带来的额外工作。

进一步，在轨迹数据中增加属性数据，能够训练轨迹预测网络对物体的属性进行学习和理解，提高轨迹预测的精度和准确性。

在其他的一些实施例中，基于上述任意一个实施例，还可以对历史地图数据和当前地图数据中的数据项进行划分和扩展。相应地，对输入表示层 11 使用的地图数据格式进行对应扩展。

在一个示例中，地图数据中还可以包括每个地图点与其所在的同一个道路要素上其它相邻地图点之间的位置差值。在这种情况下，基于预定数据格式的扩展性，可以使用公式 (10) 对地图数据格式进行定义。

$$M_n^t = \{c_n^t, u_n^t, \hat{t}\}, M = \{M_n^t | \forall t \in \{1, \dots, \hat{T}\}, \forall n \in \{1, \dots, \hat{N}\}\} \quad (10)$$

$u_n^t$ 为地图点  $t$  与相邻前一个地图点  $t-1$  之间的位置差值，例如二维坐标的位置差值、或者三维坐标的位置差值。

通过设置相邻两个地图点之间的位置差值，能够在轨迹预测神经网络

22

后续的处理中获得道路要素的多个地图点之间的方向性和连通性。

在该示例中，可以在嵌入层 12 处理得到高维地图点特征之后，也即在上述步骤 1061a 和上述步骤 1061' 之后，对高维地图点特征进行方向性和连通性的增强处理。相对应地，如图 15 所示，可以在如图 3 所示神经网络的基础上，在嵌入层 12 之后设置增强层 12'。增强层 12' 可以是自注意力神经网络。

在另一个示例中，地图数据中还可以每个地图点的属性数据，属性数据包括该地图点所属的道路要素的类别，该地图点在所属道路要素在该预定时间段内包括的多个地图点中的序号。

在其它一些实施例中，在上述任一实施例的基础上，为了提取得到更为精确有效的全局轨迹特征和全局地图特征，可以进行多次的全局特征提取操作，也即在上述步骤 1063a 和上述步骤 1063' 中执行多次全局特征提取操作。相对应地，如图 16a 或图 16b 所示，在如图 3 或者如图 15 所示的神经网络的基础上，在全局特征提取层 14 中设置多个堆叠的子全局特征提取层 141。

全局特征提取层 14 执行多次全局特征提取操作，每次全局特征提取操作包括：

相邻的前一个子全局特征提取层 141 对局部场景特征提取到的全局轨迹特征并接到高维轨迹点特征之后，将拼接后的高维轨迹点特征输出给相邻的下一个子全局特征提取层 141；

相邻的前一个子全局特征提取层 141 将对高维地图点特征提取到的全局地图特征并接到高维地图点特征之后，将拼接后的高维地图点特征输出给相邻的下一个子全局特征提取层 141。

图 17 示出了一次全局特征提取操作的示意图，针对点级特征（也即局部场景特征或者高维地图点特征）进行全局特征提取，得到聚合的特征（也即一次提取得到的全局轨迹特征或者全局地图特征），将该全局特征提取并接到输入到该词全局特征提取操作的点级特征之后，得到拼接后的

23

10

20

30

40

50

局部场景特征和拼接后的高维地图点特征。将拼接后的局部场景特征和拼接后的高维地图点特征输入给下一个子全局特征提取层 141, 执行下一次全局特征提取操作。

编码器 1 中包括一个全局特征提取层 14 时, 该全局特征提取层 14 能够提取到运动主体所在环境的第一序列信息, 也即全局的时空特征, 通过多个全局特征提取层 14 能够学习和提取出该环境中的第二序列信息, 例如不同物体之间的相互影响。通过层叠的全局特征提取层 14 能够更深刻地理解个体物体和全局时空环境的状态及关系, 从而层叠的特征层能够捕捉到多个物体之间的相互作用和影响。

例如, 当前车减速后会影响到后车相应地进行减速, 通过层叠的特征层能够捕捉到这种作用和影响。

通过在编码器 1 中设置层叠的全局特征提取层 14, 能够提取出多个物体之间的相互作用和影响, 提高神经网络对环境的学习和理解能力, 从而能够进一步提高轨迹预测的准确性和精度。

本申请实施例还提供了一种轨迹预测装置, 该装置可以是上述图 2a、图 3、图 15、图 16a 或者图 16b 所示的结构, 相应的网络结构参考上述的描述, 并且相应地完成上述的轨迹预测的处理。

图 18 示出了一个示例的轨迹预测装置的结构, 示例性地, 该装置包括一个处理器 81 和一个存储器 82。在实时处理过程中, 处理器 81 执行存储器 82 中存储的至少一条机器可执行指令, 执行如图 11 至图 14 所示的处理。在训练过程中, 处理器 81 执行存储器 82 中存储的至少一条机器可执行指令, 执行如图 1、图 2b、图 4、图 6、图 7a、图 7b、图 10 所示的处理。

本申请实施例还提供了一种计算机程序, 该计算机程序具有被配置用于执行轨迹预测处理的代码段, 该处理包括如图 11 至图 14 所示的处理, 进一步还可以包括如图 1、图 2b、图 4、图 6、图 7a、图 7b、图 10 所示的处理。

24

前轨迹点集和当前地图点集提取得到全局场景特征, 包括:

将当前轨迹点集嵌入到预定的高维空间中得到高维轨迹点特征, 将当前地图点集嵌入到预定的高维空间中得到高维地图点特征;

根据当前轨迹点集、当前地图点集、高维轨迹点特征和高维地图点特征获取得到局部场景特征, 该局部场景特征是具有局部地图信息的高维轨迹点特征;

对局部场景特征和高维地图点特征分别执行全局特征提取操作, 提取得到全局轨迹特征和全局地图特征;

根据全局轨迹特征和全局地图特征确定得到全局场景特征。

示例 4、根据示例 3 所述的方法, 其特征在于, 轨迹预测神经网络还对高维轨迹点特征和高维地图点特征进行方向性和连通性的增强处理。

示例 5、根据示例 3 所述的方法, 其特征在于, 根据当前轨迹点集、当前地图点集、高维轨迹点特征和高维地图点特征获取得到局部场景特征, 包括:

根据当前轨迹点集和当前地图点集确定得到每个高维轨迹点与该高维轨迹点周围预定多个高维地图点之间的多个相对空间关系;

将一个高维轨迹点对应的每个地图空间关系分别嵌入到高维空间中得到高维地图空间关系, 将每个高维地图空间关系与对应的高维地图点特征进行点乘得到一个加权地图特征; 对该高维轨迹点的多个加权地图特征进行最大化处理、选取得到最大加权地图特征;

将最大加权地图特征与该高维轨迹点对应的高维轨迹点特征相加得到一个局部场景特征。

示例 6、根据示例 5 所述的方法, 其特征在于, 根据当前轨迹点集和当前地图点集确定得到每个高维轨迹点与该高维轨迹点周围预定多个高维地图点之间的多个相对空间关系, 包括:

确定得到与一个高维轨迹点的欧式距离在预设的距离阈值内的预定数量的多个高维地图点;

分别确定该高维轨迹点与该多个高维地图点中每个高维地图点之间的相对空间关系, 一个相对空间关系包括该高维轨迹点和一个高维地图点的绝对位置和相对位置、以及该轨迹点和该地图点之间的相对距离和相对方向。

26

本申请实施例还提供了一种存储介质, 该存储介质中存储有用于轨迹预测处理的计算机程序, 该处理包括如图 11 至图 14 所示的处理, 进一步还可以包括如图 1、图 2b、图 4、图 6、图 7a、图 7b、图 10 所示的处理。

本公开的一些示例包括:

示例 1、一种轨迹预测方法, 其特征在于, 包括:

在运动主体在当前环境中执行运动的过程中, 轨迹预测神经网络获取输入的当前轨迹数据、和当前环境的当前地图数据; 其中, 当前轨迹数据包括运动主体和当前环境中其它一个或多个运动物体在过去预定时间段内的多个轨迹点, 每个轨迹点包括在一个对应时间点上的空间位置, 当前地图数据包括在预定时间段内当前环境中道路要素的多个地图点的空间位置;

将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集, 当前轨迹点集包括当前轨迹数据中每个轨迹点对应的高维轨迹点, 当前地图点集包括当前地图数据中每个地图点对应的高维地图点;

根据当前轨迹点集和当前地图点集提取得到全局场景特征, 其中, 全局场景特征具有当前环境的地图特征和轨迹特征;

根据全局场景特征预测输出运动主体的多个预测轨迹点集以及每个预测轨迹点集对应的概率, 每个预测轨迹点集均包括运动主体在未来预定时间段内多个时间点的空间位置。

示例 2、根据示例 1 所述的方法, 其特征在于, 轨迹预测神经网络将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集, 包括:

用预定的无序的轨迹数据格式对当前轨迹点集进行表达, 得到无序的当前轨迹点集;

用预定的无序的地图数据格式对当前地图点集进行表达, 得到无序的当前地图点集。

示例 3、根据示例 1 所述的方法, 其特征在于, 轨迹预测神经网络根据当

25

示例 7、根据示例 3 所述的方法, 其特征在于, 对局部场景特征和高维地图点特征分别提取全局轨迹特征和全局地图特征, 包括:

对局部场景特征中的每个特征提取特征, 并对提取的特征进行最大化处理、将选取得到最大特征作为全局轨迹特征;

对高维地图点特征中的每个特征提取特征, 对提取的特征进行最大化处理、将选取得到的最大特征作为全局地图特征。

示例 8、根据示例 3 或 7 所述的方法, 其特征在于, 轨迹预测神经网络对局部场景特征和高维地图点特征分别提取全局轨迹特征和全局地图特征, 包括: 轨迹预测神经网络执行多次全局特征提取操作, 每一次全局特征提取操作包括:

将对局部场景特征提取到的全局轨迹特征并接入到高维轨迹点特征之后, 将拼接后的高维轨迹点特征输出给下一次全局特征提取操作;

对高维地图点特征提取到的全局地图特征并接入到高维地图点特征之后, 将拼接后的高维地图点特征输出给下一次全局特征提取操作。

示例 9、根据示例 3 所述的方法, 其特征在于, 根据全局轨迹特征和全局地图特征确定得到全局场景特征, 包括:

将全局轨迹特征和全局地图特征相加得到全局场景特征。

示例 10、根据示例 1 所述的方法, 其特征在于, 当前轨迹数据还包括运动主体以及其它一个或多个运动物体在每个轨迹点上的速度。

示例 11、根据示例 1 所述的方法, 其特征在于, 当前轨迹数据还包括: 运动主体以及每个运动物体的属性数据, 属性数据包括运动主体和每个运动物体的物体类别数据。

示例 12、根据示例 11 所述的方法, 其特征在于, 当运动主体或运动物体是车辆时, 属性数据还包括以下一个或多个: 前灯属性数据、尾灯属性数据。

示例 13、根据示例 1 所述的方法, 其特征在于, 当前地图数据还包括: 每个地图点与其所在的同一道路要素上其它相邻地图点之间的位置差值。

示例 14、根据示例 13 所述的方法, 其特征在于, 当前地图数据还包括: 每个地图点的属性数据, 属性数据包括该地图点所属的道路要素的类别, 该地

27

10

20

30

40

50

图点在该道路要素在该预定时间段内包括的多个地图点中的序号。

示例 15、根据示例 1 所述的方法，其特征在于，轨迹预测神经网络获取输入的当前轨迹数据和当前地图数据，包括：

从上游模块获取输入的当前轨迹数据和当前地图数据。

示例 16、根据示例 1 所述的方法，其特征在于，训练得到轨迹预测神经网络的处理包括：

在训练阶段，根据历史的第一轨迹数据、第二轨迹数据以及历史地图数据对预设的神经网络进行多次迭代训练；其中，第一轨迹数据和第二轨迹数据是时间前后相邻的数据集，并且均包括运动主体以及周围一个或多个运动物体在预定时间段内的多个轨迹点，每个轨迹点包括在一个对应时间点的空间位置；历史地图数据包括第一轨迹数据对应的时间段内运动主体所在环境中道路要素的多个地图点的空间位置；预设神经网络具有初始参数集；

一次迭代训练包括：

将第一轨迹数据和历史地图数据作为输入提供给神经网络；神经网络将第一轨迹数据和历史地图数据表达为高维空间中的第一轨迹点集和历史地图点集；根据第一轨迹点集和历史地图点集提取得到全局场景特征；其中，全局场景特征具有运动主体所在环境的地图特征和轨迹特征；根据全局场景特征预测输出运动主体的多个轨迹点集以及每个轨迹点集对应的概率，每个轨迹点集均包括运动主体在未来预定时间段内多个时间点的空间位置；

分别将输出的每个轨迹点集和对应的概率以及第二轨迹数据作为输入提供一个对应的损失函数，得到该损失函数的输出；判断全部损失函数的输出是否满足预设的收敛条件；在判断满足收敛条件的情况下，确定训练完成，并获得训练后的神经网络的参数集；在判断不满足收敛条件的情况下，调整神经网络的参数，并执行下一次迭代训练。

示例 17、一种轨迹预测装置，其特征在于，包括编码器和解码器；

编码器用于在运动主体在当前环境中执行运动的过程中，获取输入的当前轨迹数据、和当前环境的当前地图数据；其中，当前轨迹数据包括运动主体和当前环境中其它一个或多个运动物体在过去预定时间段内的多个轨迹点，每个

轨迹点包括在一个对应时间点的空间位置，当前地图数据包括在该预定时间段内当前环境中道路要素的多个地图点的空间位置；将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集；根据当前轨迹点集和当前地图点集提取得到全局场景特征，其中，全局场景特征具有当前环境的地图特征和轨迹特征；

解码器用于根据全局场景特征预测输出运动主体的多个预测轨迹点集以及每个预测轨迹点集对应的概率，每个预测轨迹点集均包括运动主体在未来预定时间段内多个时间点的空间位置。

示例 18、根据示例 17 所述的装置，其特征在于，编码器包括输入表示层；

编码器将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集，包括：

输入表示层用预定的无序的轨迹数据格式对当前轨迹点集进行表达，得到无序的高维当前轨迹点集；用预定的无序的地图数据格式对当前地图点集进行表达，得到无序的当前地图点集。

示例 19、根据示例 17 所述的装置，其特征在于，编码器包括嵌入层、地图关系学习层、全局特征提取层和特征输出层；

编码器根据当前轨迹点集和当前地图点集提取得到全局场景特征，包括：嵌入层用于将当前轨迹点集嵌入到预定的高维空间中得到高维轨迹点特征；将当前地图点集嵌入到预定的高维空间中得到高维地图点特征；

地图关系学习层用于根据当前轨迹点集、当前地图点集、高维轨迹点特征和高维地图点特征获取得到局部场景特征，该局部场景特征是具有局部地图信息的高维轨迹点特征；

全局特征提取层用于对局部场景特征和高维地图点特征分别执行全局特征提取操作，提取得到全局轨迹特征和全局地图特征；

特征输出层用于根据全局轨迹特征和全局地图特征确定得到全局场景特征。

示例 20、根据示例 19 所述的装置，其特征在于，编码器还包括增强层；

增强层用于对高维轨迹点特征和高维地图点特征进行方向性和连通性的

29

10

20

增强处理；增强层包括自注意力神经网络。

示例 21、根据示例 19 所述的装置，其特征在于，地图关系学习层根据当前轨迹点集、当前地图点集、高维轨迹点特征和高维地图点特征获取得到局部场景特征，包括：

根据当前轨迹点集和当前地图点集确定得到每个高维轨迹点与该高维轨迹点周围预定多个高维地图点之间的多个相对空间关系；

将一个高维轨迹点对应的每个地图空间关系分别嵌入到高维空间中得到高维地图空间关系，将每个高维地图空间关系与对应的高维地图点特征进行点乘得到一个加权地图特征；对该高维轨迹点的多个加权地图特征进行最大化处理，选取得到最大加权地图特征；

将最大加权地图特征与该高维轨迹点对应的高维轨迹点特征相加得到一个局部场景特征。

示例 22、根据示例 21 所述的装置，其特征在于，地图关系学习层根据当前轨迹点集和当前地图点集确定得到每个高维轨迹点与该轨迹点周围预定多个高维地图点之间的多个相对空间关系，包括：

确定得到与一个高维轨迹点的欧式距离在预设的距离阈值内的预定数量的多个高维地图点；

分别确定该高维轨迹点与该多个高维地图点中每个高维地图点之间的相对空间关系，一个相对空间关系包括该高维轨迹点和一个高维地图点的绝对位置和相对位置、以及该轨迹点和该地图点之间的相对距离和相对方向。

示例 23、根据示例 19 所述的装置，其特征在于，全局特征提取层对局部场景特征和高维地图点特征分别提取全局轨迹特征和全局地图特征，包括：

对局部场景特征中的每个特征提取特征，并对提取的特征进行最大化处理，将选取得到最大特征作为全局轨迹特征；

对高维地图点特征中的每个特征提取特征，对提取的特征进行最大化处理，将选取得到的最大特征作为全局地图特征。

示例 24、根据示例 19 或 23 所述的装置，其特征在于，全局特征提取层包括多个堆叠的子全局特征提取层；

相邻的前一个子全局特征提取层对局部场景特征提取到的全局轨迹特征拼接到高维轨迹点特征之后，将拼接后的高维轨迹点特征输出给相邻的下一个子全局特征提取层；

相邻的前一个子全局特征提取层将对高维地图点特征提取到的全局地图特征拼接到高维地图点特征之后，将拼接后的高维地图点特征输出给相邻的下一个子全局特征提取层。

示例 25、根据示例 19 所述的装置，其特征在于，特征输出层根据全局轨迹特征和全局地图特征确定得到全局场景特征，包括：

特征输出层将全局轨迹特征和全局地图特征相加得到全局场景特征。

示例 26、根据示例 17 所述的装置，其特征在于，解码器包括多头解码器和概率确定层；

多头解码器用于根据全局场景特征预测输出运动主体的多个预测轨迹点集；多头解码器包括多个循环神经网络或多层感知机，循环神经网络包括长短期记忆网络或门控循环单元；

概率确定层用于确定得到每个预测轨迹点集对应的概率。

示例 27、一种轨迹预测装置，其特征在于，包括一个处理器和至少一个存储器，至少一个存储器中存储有至少一条机器可执行指令，处理器执行至少一条机器可执行指令实现如示例 1-16 中任一所述的方法。

示例 28、一种计算机程序，其特征在于，该计算机程序具有被配置用于执行以下轨迹预测处理的代码段，该处理包括如示例 1-16 中任一所述的方法。

示例 29、一种非易失性存储介质，其特征在于，存储有至少一条机器可执行指令，至少一条机器可执行指令被处理器执行后实现如示例 1-16 中任一所述的方法。

显然，本领域的技术人员可以对本申请进行各种改动和变形而不脱离本申请的精神和范围。这样，倘若本申请的这些修改和变形属于本申请权利要求及其等同技术的范围之内，则本申请也意图包含这些改动和变形在内。

31

30

40

28

30

50

权利要求书

1、一种轨迹预测方法，包括：  
 获取当前轨迹数据和当前地图数据；其中，当前轨迹数据包括运动主体和当前环境中其它一个或多个运动物体在过去预定时间段内的多个轨迹点，每个轨迹点包括在一个对应时间上的空间位置，当前地图数据包括在该预定时间段内当前环境中道路要素的多个地图点的空间位置；  
 将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集；  
 根据当前轨迹点集和当前地图点集提取得到全局场景特征；  
 根据全局场景特征预测输出运动主体的多个预测轨迹点集以及每个预测轨迹点集对应的概率。

2、根据权利要求 1 所述的方法，其中，将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集，包括：  
 用预定的无序的轨迹数据格式对当前轨迹点集进行表达，得到无序的当前轨迹点集；  
 用预定的无序的地图数据格式对当前地图点集进行表达，得到无序的当前地图点集。

3、根据权利要求 1 或 2 所述的方法，其中，当前轨迹点集包括当前轨迹数据中每个轨迹点对应的高维轨迹点，当前地图点集包括当前地图数据中每个地图点对应的高维地图点。

4、根据权利要求 1-3 中任一项所述的方法，其中，根据当前轨迹点集和当前地图点集提取得到全局场景特征，包括：  
 将当前轨迹点集嵌入到预定的高维空间中得到高维轨迹点特征，将当前地图点集嵌入到预定的高维空间中得到高维地图点特征；  
 根据当前轨迹点集、当前地图点集、高维轨迹点特征和高维地图点特征获取得到局部场景特征；  
 对局部场景特征和高维地图点特征分别执行全局特征提取操作，提取得到全局轨迹特征和全局地图特征；

运动主体以及每个运动物体的属性数据，属性数据包括运动主体和每个运动物体的物体类别数据。

9、根据权利要求 1-8 中任一项所述的方法，其中，当前地图数据还包括：  
 每个地图点与其所在的同一个道路要素上其它相邻地图点之间的位置差值，或  
 每个地图点的属性数据，属性数据包括该地图点所属的道路要素的类别，该地图点在所属道路要素在该预定时间段内包括的多个地图点中的序号。

10、根据权利要求 1-9 中任一项所述的方法，其中所述方法通过预测神经网络执行，所述方法还包括通过训练得到轨迹预测神经网络，  
 其中，通过训练得到轨迹预测神经网络包括：  
 根据历史的第一轨迹数据、第二轨迹数据以及历史地图数据对预设的神经网络进行多次迭代训练；其中，第一轨迹数据和第二轨迹数据是时间前后相邻的数据集，并且均包括运动主体以及周围一个或多个运动物体在预定时间段内的多个轨迹点，每个轨迹点包括在一个对应时间上的空间位置；历史地图数据包括第一轨迹数据对应的时间段内运动主体所在环境中道路要素的多个地图点的空间位置；预设神经网络具有初始参数集。

11、根据权利要求 10 所述的方法，其中，一次迭代训练包括：  
 将第一轨迹数据和历史地图数据作为输入提供给神经网络；神经网络将第一轨迹数据和历史地图数据表达为高维空间中的第一轨迹点集和历史地图点集；根据第一轨迹点集和历史地图点集提取得到全局场景特征；其中，全局场景特征具有运动主体所在环境的地图特征和轨迹特征；根据全局场景特征预测输出运动主体的多个预测轨迹点集以及每个预测轨迹点集对应的概率，每个预测点集均包括运动主体在未来预定时间段内多个时间点的空间位置；  
 分别将输出的每个预测轨迹点集和对应的概率以及第二轨迹数据作为输入提供给一个对应的损失函数，得到该损失函数的输出；判断全部损失函数的输出是否满足预设的收敛条件；在判断满足收敛条件的情况下，确定训练完成，并获得训练后的神经网络的参数集；在判断不满足收敛条件的情况下，调整神经网络的参数，并执行下一次迭代训练。

根据全局轨迹特征和全局地图特征确定得到全局场景特征。

5、根据权利要求 4 所述的方法，其中，根据当前轨迹点集、当前地图点集、高维轨迹点特征和高维地图点特征获取得到局部场景特征，包括：  
 根据当前轨迹点集和当前地图点集确定得到每个高维轨迹点与该高维轨迹点周围预定多个高维地图点之间的多个相对空间关系；  
 将一个高维轨迹点对应的每个相对空间关系分别嵌入到高维空间中得到高维地图空间关系，将每个高维地图空间关系与对应的高维地图点特征进行点乘得到一个加权地图特征；对该高维轨迹点的多个加权地图特征进行最大化处理、选取得到最大加权地图特征；  
 将最大加权地图特征与该高维轨迹点对应的高维轨迹点特征相加得到局部场景特征。

6、根据权利要求 5 所述的方法，其中，根据当前轨迹点集和当前地图点集确定得到每个高维轨迹点与该高维轨迹点周围预定多个高维地图点之间的多个相对空间关系，包括：  
 确定得到与一个高维轨迹点的欧式距离在预设的距离阈值内的预定数量的多个高维地图点；  
 分别确定该高维轨迹点与该多个高维地图点中每个高维地图点之间的相对空间关系，一个相对空间关系包括该高维轨迹点和一个高维地图点的绝对位置和相对位置、以及该轨迹点和该地图点之间的相对距离和相对方向。

7、根据权利要求 4 所述的方法，其中，对局部场景特征和高维地图点特征分别执行全局特征提取操作，提取得到全局轨迹特征和全局地图特征，包括：  
 执行多次全局特征提取操作，每一次全局特征提取操作包括：  
 将对局部场景特征提取到的全局轨迹特征并接到高维轨迹点特征之后，将拼接后的高维轨迹点特征输出给下一次全局特征提取操作；  
 对高维地图点特征提取到的全局地图特征并接到高维地图点特征之后，将拼接后的高维地图点特征输出给下一次全局特征提取操作。

8、根据权利要求 1-7 中任一项所述的方法，其中，当前轨迹数据还包括：  
 运动主体以及其它一个或多个运动物体在每个轨迹点上的速度，或

12、根据权利要求 1-11 中任一项所述的方法，其中所述方法通过预测神经网络执行，所述轨迹预测神经网络包括编码器和解码器；  
 编码器用于获取当前轨迹数据和当前地图数据；将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集；根据当前轨迹点集和当前地图点集提取得到全局场景特征；  
 解码器用于根据全局场景特征预测输出运动主体的多个预测轨迹点集以及每个预测轨迹点集对应的概率。

13、根据权利要求 12 所述的方法，其中，解码器包括多头解码器和概率确定层；  
 多头解码器用于根据全局场景特征预测输出运动主体的多个预测轨迹点集；多头解码器包括多个循环神经网络或多层感知机，循环神经网络包括长短期记忆网络或门控循环单元；  
 概率确定层用于确定得到每个预测轨迹点集对应的概率。

14、一种轨迹预测装置，包括至少一个处理器和至少一个存储器，至少一个存储器中存储有至少一条机器可执行指令，处理器执行至少一条机器可执行指令实现如权利要求 1-13 中任一项所述的方法。

15、一种非易失性存储介质，存储有至少一条机器可执行指令，至少一条机器可执行指令被处理器执行后实现如权利要求 1-13 中任一项所述的方法。

10

20

30

40

50

说明书摘要

本申请公开一种轨迹预测方法和装置、存储介质和计算机程序，以解决已有技术中的轨迹预测方法存在的预测结果准确性低、可靠性低的问题。在运动主体在当前环境中执行运动的过程中，轨迹预测神经网络获取输入的当前轨迹数据、和当前环境的当前地图数据；将当前轨迹数据和当前地图数据表达为高维空间中的当前轨迹点集和当前地图点集；根据当前轨迹点集和当前地图点集提取得到全局场景特征，其中，全局场景特征具有当前环境的地图特征和轨迹特征；根据全局场景特征预测输出运动主体的多个预测轨迹点集以及每个预测轨迹点集对应的概率。

10

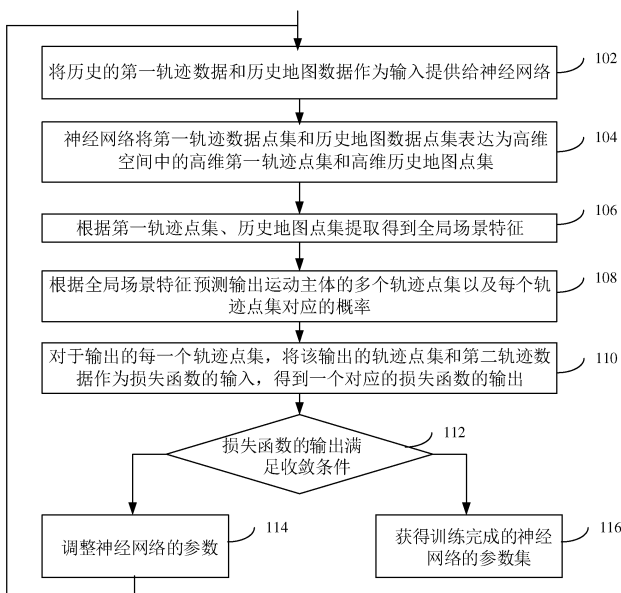
20

30


40

50

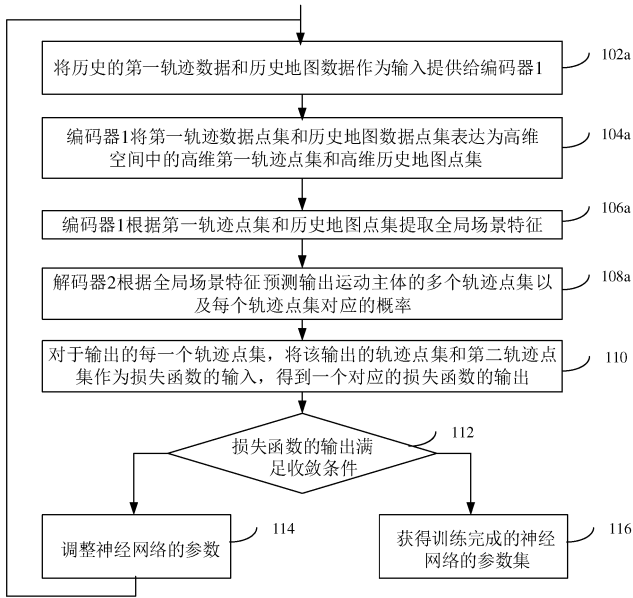
【图 1】



【图 2 a】



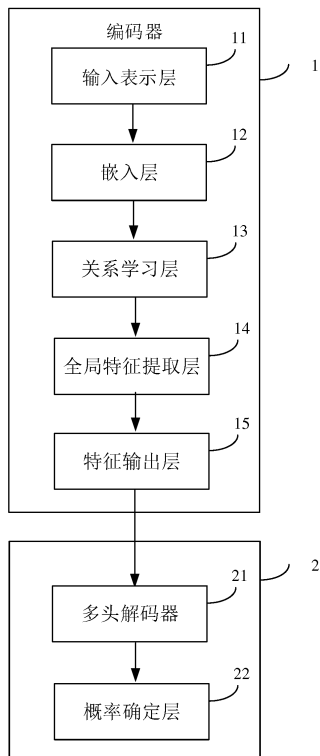
【图 2 b】



10

【图 3】


20



30


40

【图 4】




50

【图 5 a】




10

【图 5 b】



20


【图 5 c】



30

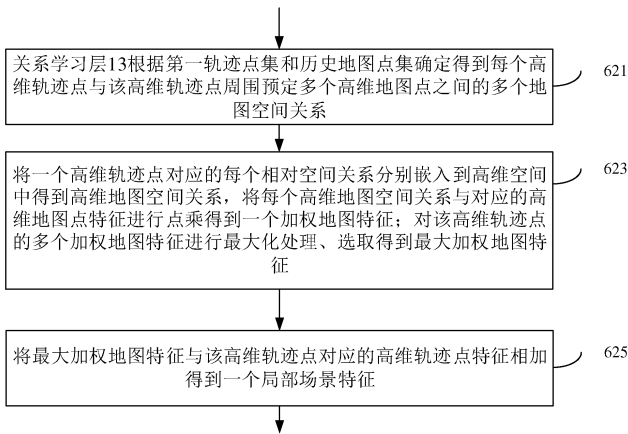
40

【图 6】



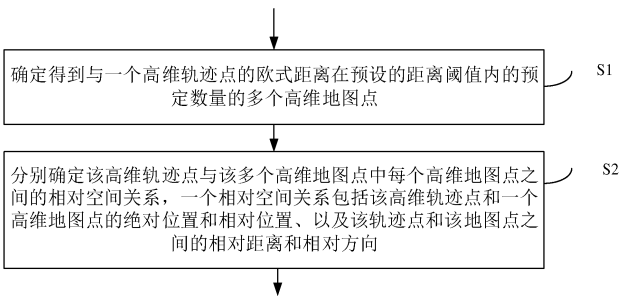
50

【图 7 a】




10

【图 7 b】




20

【图 8】




30

【图 9】



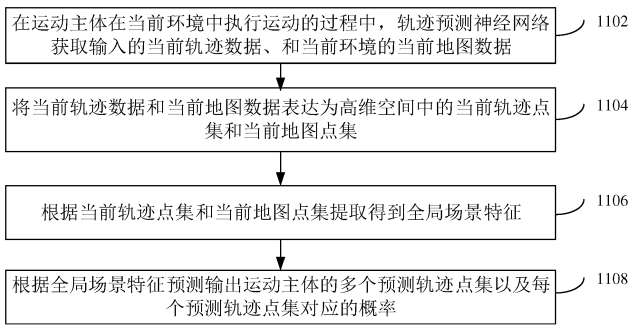
40

【图 1 0】



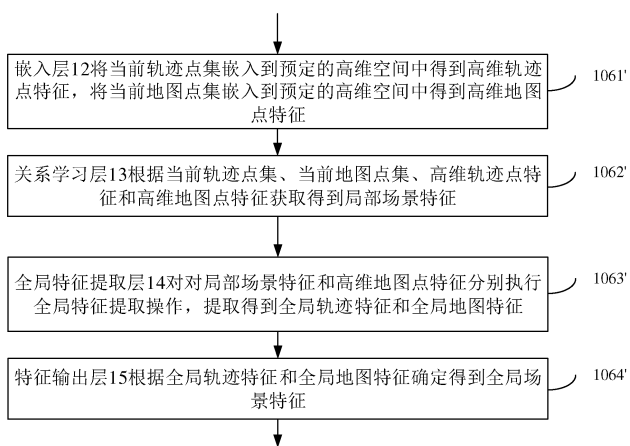
50

【图 1 1】



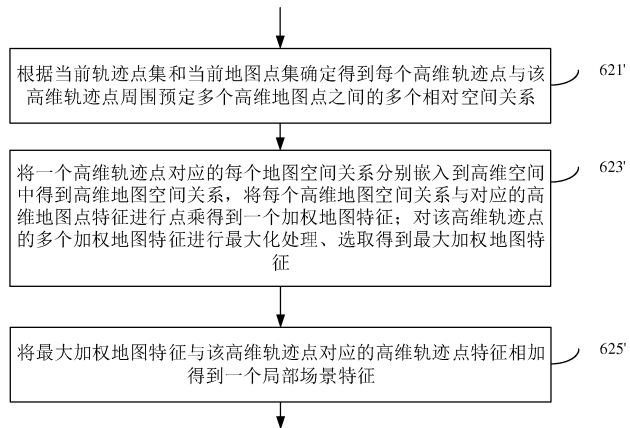
10

【图 1 2】



20

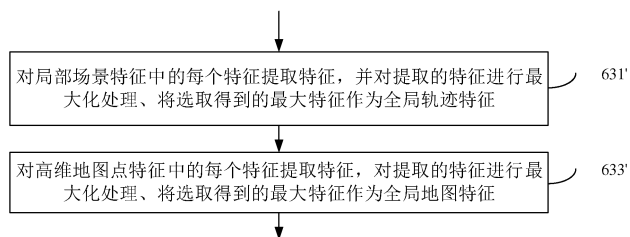
【图 1 3】



30

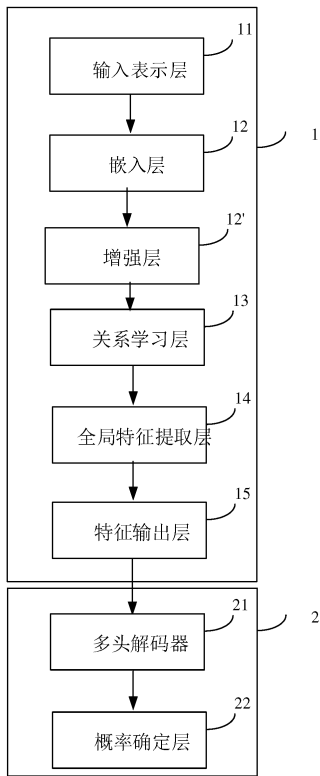
40

【图 1 4】



50

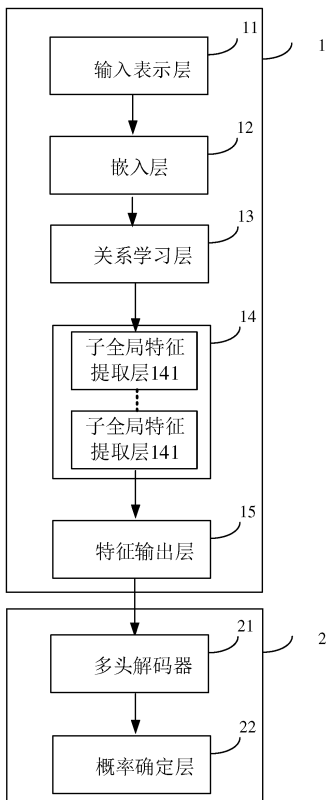
【图 15】



10

20


【图 16 a】



30


40

【图 16 b】



50


【图 17】



10

20

【图 18】



30

40

50

---

フロントページの続き

Fターム(参考) 5H301 AA01 AA06 AA07 AA10 BB01 BB05 BB14 CC10 DD01 DD07  
DD15 FF11 GG06 GG07 GG08 GG09 GG11 GG16 HH01 HH02 QQ06  
5L096 BA04 BA05 CA04 CA27 DA01 FA67 FA69 HA04 KA03 KA04  
KA15