



カーナビゲーションシステムのための走行履歴と運転状況を用いた車両目的地予測手法

田中, 宏平
寺田, 努
岸野, 泰恵
西尾, 章治郎

(Citation)

情報処理学会論文誌, 51(1):141-151

(Issue Date)

2010-01-15

(Resource Type)

journal article

(Version)

Version of Record

(URL)

<https://hdl.handle.net/20.500.14094/90002103>



カーナビゲーションシステムのための 走行履歴と運転状況を用いた車両目的地予測手法

田 中 宏 平^{†1} 寺 田 努^{†2}
岸 野 泰 恵^{†3} 西 尾 章 治 郎^{†1}

現在のカーナビゲーションシステムは、入力された目的地をもとに経路案内を行う機能を主としているが、運転の大半を占める日常運転では経路案内は不要であるため、その機能はほとんど利用されていない。筆者らの研究グループでは日常運転に有効なカーナビゲーションシステムとして、目的地やその経路に関する情報を自動的に提示する目的予測型カーナビゲーションシステムを提案している。本研究では、目的予測型カーナビゲーションシステムにおけるユーザの目的地を過去の走行履歴や現在の運転状況を用いて予測する手法を提案する。提案手法では、走行状況に合わせて予測手法を選択的に用いることで、従来手法と比べて精度の高い予測を行う。提案手法を用いることで、日常運転における目的地入力の手間をかけずに目的地に関する情報を提示できるシステムが実現できる。

A Destination Prediction Method Using Driving Contexts for Car Navigation Systems

KOHEI TANAKA,^{†1} TSUTOMU TERADA,^{†2} YASUE KISHINO^{†3}
and SHOJIRO NISHIO^{†1}

Car navigation systems navigate drivers to their destinations that they have input previously. However, in daily driving, the navigation to a destination is not necessary since they are familiar with the route to the destination. Thus, our research group has proposed a new car navigation system that provides information related to the automatic estimated destinations. In this research, we discuss how to predict the destinations accurately. Our method predicts a destination using driving information selectively, such as driving trajectory, date, time, number of passengers, and weather. Using our method, the car navigation system knows the destination without any user input and provides the information related to the right destination on the early stage of driving.

1. はじめに

カーナビゲーションシステムの累積出荷台数は、2009年3月末現在3,480万台を超えており、自動車へのカーナビゲーションシステムの搭載は一般的になりつつある¹⁾。カーナビゲーションシステムの技術には、正確な位置取得のための自律航法や、自動車は道路を走行するという制約から自車位置を補正するマップマッチング⁹⁾、ユーザに目的地までの経路をナビゲーションするためのルート検索技術、3次元グラフィックスを用いて直観的な道案内を行う技術⁶⁾、音声を用いたインタラクション技術⁷⁾など、数多くの研究開発が行われ、実際に活用されている。これらの技術は主に、目的地への経路が未知である運転時に、経路案内を効率的に行うためのものであるが、実際の日常的な運転は通勤や買い物といった目的であることが多く、その場合ユーザは目的地までの経路を知っており、経路案内が不要である。さらに、目的地までの経路に関連した情報を得るために目的地をユーザが手で入力することは煩雑な作業である。これらの理由から、現在のカーナビゲーションシステムの技術の多くは日常的な運転において十分に活用されていない。

そこで筆者らの研究グループでは、ユーザの入力の手間を軽減し、日常運転においてもユーザが必要とする情報を提示するために、目的地や運転目的を過去の走行履歴から予測し、それらに関連した情報を提示する目的予測型カーナビゲーションシステムの研究開発を行っている⁵⁾。目的予測型カーナビゲーションシステムでは、たとえばユーザが友人を駅へ送迎するために運転していることを、過去の走行履歴と現在地情報、乗員数などから予測し、到着時刻付近の時刻表や経路上・駅周辺の渋滞情報などを提示するといった機能を持つ。

このシステムにおいて、単純に車載のGPSから求まる現在地と過去の道路通過履歴を用いて目的地を予測する場合、わき道の走行や抜け道の走行など通常と異なる道を通ったり、通勤や帰宅時に用いるなど使用頻度の高い幹線道路をそれ以外の用途で走行したりした際に、向かっている目的地の確率が急激に減少するなどの問題が発生する。

そこで本研究では、異なる2手法の予測結果から走行状況を分類し、走行状況ごとに適切

^{†1} 大阪大学大学院情報科学研究科

Graduate School of Information Science and Technology, Osaka University

^{†2} 神戸大学大学院工学研究科

Graduate School of Engineering, Kobe University

^{†3} NTTコミュニケーション科学基礎研究所

NTT Communication Science Laboratories, NTT Corporation

な目的地予測手法を選択的に利用することで、精度の高い予測を行う手法を提案する。

以下、2章で関連研究について述べ、3章で筆者らのグループで提案する目的予測型ナビゲーションシステムについて説明する。4章で走行履歴と運転状況を組み合わせた目的地予測手法を提案し、5章で評価を行い、6章で考察し、最後に7章で本研究をまとめる。

2. 関連研究

これまでに車両の向かう目的地を走行経路などを用いて予測する研究がいくつか行われている。過去に走行した経路と走行中の経路を格子状に区切った地図にプロットし、その一致度から目的地の予測を行う手法⁸⁾は、後述の筆者らの全出発地手法と同様の予測手法であるが、本論文で対象としている、抜け道を使用した際の急な予測結果の変化や、幹線道路などの複数の目的地に使用する経路を用いた際の目的地予測を考慮していないため精度が悪い。

また、交差点をノードとし、ノード遷移から移動先を予測する研究では、エントロピーと呼ぶ目的地予測の不確定さを用いて予測を行っている¹⁰⁾。この研究ではエントロピーを用いることで目的地予測の精度を示すことに成功しているが、目的地予測の精度を向上させることを目的としておらず、本論文の主旨とは異なる。また、文献10)でも文献8)と同様に、本研究で問題としている抜け道通過時の予測結果の変化に対応できない。

車両の目的地予測とは少し異なった研究として、車両の走行経路に関する情報が与えられたときのユーザが選択する経路を予測する研究がある⁴⁾。この研究では、ユーザが与えられた情報を見るタイミング、所要時間などを考慮し、ユーザが選ぶ経路を予測する。また、if-then ルールを利用して予測を行っており、天気が良かったら道を変更しやすい、道が混んでいたら変更しやすい、よく知っている道だと変更しやすいといったユーザの思考をルールで表現している。本研究では、目的地予測を目的としており、目的地を既知として考えているこの研究とは主旨が異なる。しかし、if-then ルールで用いられている項目のように、混んでいる道路はユーザは回避するなど、ユーザの思考を考慮し、目的地予測に利用することは可能である。

また、ユーザの交通手段を予測する手法^{2),3)}では、GPS データから求める位置と速度、および地図上のバス停や駐車場などの交通手段を切り替える可能性のある位置などの情報から、ペイジアンネットワークを用いてユーザの移動手段を予測する。この研究は、位置情報や地図情報からユーザの行為を予測する点では本研究に類似しているが、目的地を予測するわけではない。

3. 目的予測型カーナビゲーションシステム

筆者らの提案する目的予測型カーナビゲーションシステムは、図1に示すような構成で動作することを想定している。各要素の詳細を以下に示す。

● 行動履歴 DB

車両の走行経路、速度、乗員数、ガソリン残量、目的地など、運転から得られる情報を蓄積するデータベースである。本研究では、走行経路、目的地、乗員数、天気、時間帯、荷物重量を活用し、それ以外のデータは、提示情報や提示タイミングの調整に用いるため、取得することを想定している。

● 関連情報 DB

VICS やインターネットを通じて得られた目的地までの経路上の交通情報や店などの施設の情報や、目的地周辺や目的地に関する情報を格納したデータベースである。

● 目的地予測部

車載のセンサから現在の車両状況を取得し、行動履歴 DB と比較することで目的地を予測する。本研究で焦点を当てている部分であり次章以降で詳細に述べる。

● 目的予測部




図1 目的予測型カーナビゲーションシステムの構成

Fig.1 A structure of car navigation system that predicts user destination.

車両の目指す目的地や車載のセンサ情報から、行動履歴 DB と比較することでユーザーの運転目的を予測する。

- 情報検索部

目的・目的地の予測結果を用いて、ユーザーに提示する情報を検索・生成する。

- 情報提示部

情報検索部で生成された情報を、安全なタイミングで、より見やすく提示する。

3.1 想定サービス

目的予測型カーナビゲーションシステムでは、従来のカーナビゲーションシステムが対象としているような初めて訪問する目的地を対象としておらず、日常に頻繁に訪問する目的地への運転を想定している。これは、初めて訪問する目的地への運転は、そのユーザーが自動車に乗るほんの一部の運転であるため、ユーザーが目的地を入力しないような運転において、いかに有益な情報を提供できるかが重要であると考えたためである。目的予測型カーナビゲーションシステムは現在の走行の目的地を予測し、予測結果に応じて目的地やその目的地に至る経路に関連する情報を提示する。利用シナリオの例を以下に示す。

- ショッピングセンターに買い物へ行くことを予測し、ショッピングセンターの空き駐車場の情報を提示する。
- 遠方のゴルフ場へ行くことを予測し、目的地付近の気象情報を提示する。
- 駅に送迎に行くことを予測し、電車の時刻表を提示する。

目的予測型カーナビゲーションシステムでは、予測の上位 4 位に関する情報を検索し、その確率や目的地までの距離に応じて提示する。複数の情報を提示する理由は、正しい目的・目的地が必ずしも正確に予測されるとは限らないためである。画面表示の例を図 2 に示す。



図 2 目的地予測型カーナビゲーションシステムの表示例
Fig. 2 A snapshot of using our car navigation system.

また、システムの画面には地図や自車位置など重要な情報も表示されており、情報の表示量に限りがあるため、最大 4 つの情報のみを表示する。確率の高い結果に対して詳細な情報を大きく表示し、確率の低い目的地に対しては簡単な情報を小さく表示する。

4. 提案手法

本研究では、ユーザーの向かう目的地ができるだけ長い走行期間、目的地予測の上位に入る目的地予測手法の実現を目的とする。そのために、どのような状況で目的地予測の不適切な順位変動が発生するかを予備実験を通じて導出し、状況ごとに最も適した手法で適応的に予測手法を切り替える手法を提案する。

本研究では、関連研究であげた文献 8) と同等の、道路走行履歴と現在の走行経路の一致度から目的地を予測する**全出発地手法**を、基本手法として提案する。

4.1 全出発地手法

全出発地手法では、現在の走行経路と走行経路履歴を比較し、その一致度から目的地を推測する。具体的には図 3 に示すように、これまでに走行した経路を分岐ごとに道路リンクに分割し、目的地到着時に、走行したそれぞれの道路リンクに対して目的地の訪問回数を 1 加える。なお、道路リンクは方向を考慮したものとなっており、上り下りでは別の道路リンクとしている。このようにして記録した訪問回数をもとに以下の式を用いて予測する。

$$P_{ij} = (1 - \alpha) \frac{N_{ij}}{N_i} + \alpha P_{(i-1)j} \quad (1)$$

P_{ij} は、出発地から i 番目の道路リンクにさしかかったときの目的地 j に向かう確率であり、 N_i は今までに道路リンク i を通った回数、 N_{ij} は道路リンク i を通って目的地 j に行った回数である。また、 α は通過してきた経路をどの程度重視するかを表す係数であり、0 から




図 3 道路と道路リンク
Fig. 3 Examples of roads and road links.




図 4 全出発地手法を用いた目的地予測結果の一例 ($\alpha = 0.5$)

Fig. 4 An example of prediction result using passed roads.

1 の値をとる。全出発地手法では、 $\alpha = 0.5$ を用いた。システムは、車両の移動とともに走行中の道路リンクが変更されるたびに、すべての目的地への確率を再計算する。なお、 P_{0j} はすべての目的地に行った総回数に対する目的地 j に行った総回数の割合を示す。

この手法を用いた予測の一例を図 4 に示す。図はある出発地から目的地 A に向かったときの主要な目的地の予測確率遷移である。グラフの右側、すなわち目的地周辺では、目的地 A の確率が高く、システムは情報を正しく提示できるといえる。一方、目的地までの距離 9,000 m 付近では他の目的地と比較して目的地 A の確率が低く、システムは正しく情報を提示できない。このように全出発地手法だけでは、正しい目的地を長い走行期間、目的地予測の上位に予測することが困難である。そこで、目的地予測の順位変動が発生している状況について、実際の走行ログを分析したところ、抜け道走行時や、幹線道路などの頻繁に利用する経路走行時に確率が大きく変動し、本来の目的地の予測結果が乱れることの多いことが分かった。そこで、そのような状況に対して有効と考えられる手法を検討する。




図 5 抜け道の走行の一例

Fig. 5 An example of using an alternative way.

4.2 抜け道の走行

4.2.1 抜け道走行の問題

全出発地手法では、通常利用する経路を一時的に離れて走行した際、その経路を他の目的地へ向かうときに利用していれば確率が大きく変動する。これは、全出発地手法がその道路リンクを用いて目的地に向かう回数の割合で目的地に向かう確率を算出しており、その通過回数が少なく信頼性が低い状態であっても確率計算が行われるためである。たとえば、図 5 に示す道路の場合、通常、目的地 A に向かう際には、道路リンク a, b, d と通過するのに対して、道路リンク b の代わりに抜け道である道路リンク c を通過した場合、以前に通過した道路リンク c の走行記録に大きく依存し、正しい目的地の確率が大きく低下する。道路リンク d に復帰することで再び正しい予測になることから、この確率変化は一時的なものであり、信頼性が低いといえる。この一時的な確率変化によって、システムがユーザーに提示する情報が、突然まったく別の目的地のものとなったり、正しい目的地に関する情報がユーザーに提示されなくなったりするなどの問題が発生する。このような状況は、日常の運転における以下のような状況で多発する。

- 目の前の信号が赤になったので、信号を回避するため別の道を利用した。
- 道路が渋滞しており、回避するために別の道を利用した。

4.2.2 抜け道走行の対処

抜け道走行では、走行回数が少なく信頼性が低いと考えられる経路を走行回数の多い道路

表 1 被験者
Table 1 Test subjects.

	被験者 1	被験者 2
職業	学生	主婦
走行回数	63 回	104 回
期間	4 カ月	4 カ月
目的地数	11 カ所	23 カ所
平均走行距離	6,400 m	3,180 m

と同等に扱っていることに問題があり、抜け道走行のデータ量が多くなれば、通常利用する道路の結果に近づくと考えられる。

そこで、全出発地手法で用いた α を変化させることで、道路の総走行回数に応じた予測の重みづけを行う。 α は次の式を用いて求めた。

$$\alpha = \frac{N_{i-1}}{N_{i-1} + N_i} \quad (2)$$

N_i は道路リンク i の総走行回数である。この式を用いることで、総走行回数と同じ走行回数の道路リンクをたどる場合には、 $N_i = N_{i-1}$ となるため $\alpha = 0.5$ となり、それまでに通過してきた経路の重みと等しい重みを現在の道路リンクでの確率にかけ合わせる。初めての道路を走行する場合は、 $N_i = 0$, $N_{i-1} \neq 0$, つまり $\alpha = 1$ となり、現在走行中の道路の値を用いず、それまでに通過してきた道路の値をそのまま利用して予測する。なお、 $N_i = 0$, $N_{i-1} = 0$ となる場合も、 $\alpha = 1$ として計算する。この α を用いた全出発地手法を、**抜け道考慮予測手法**と呼ぶ。

4.2.3 抜け道走行の対処の評価

提案した抜け道考慮予測手法について、実際に正しい目的地が上位に予測できる距離について評価した。評価に参加した被験者の詳細を表 1 に示す。また、評価軸として、総走行距離において正しい目的地が上位 1 位 (Top1)、上位 4 位 (Top4) に入る距離の割合を用いた。評価に Top4 を用いた理由は、目的予測型ナビゲーションでは予測の上位 4 位の目的地候補に関する情報を提示するためである。なお、評価は全走行データを順に学習させながら目的地を予測するという実環境での利用と同様の条件で行った。

結果を図 6 に示す。結果から、Top4 においてはまったく同じ結果となったが、Top1 において約 2%、距離にして約 14km の間、従来の全出発地手法より長い距離で正しい目的地を予測できた。これは、従来の全出発地手法で抜け道通過時に正しい目的地が一時的に Top1 でなくなっていたものが、 α を変更することで Top1 のまま予測できているためである。




図 6 抜け道考慮予測手法の総走行距離に対する正しい目的地が Top1, Top4 に入る距離の割合
Fig. 6 The rate that the prediction includes correct destination in Top-1 and Top-4 about a method considering alternative ways.

表 2 正しい目的地の予測順位の変化回数

Table 2 The times of rank changes about the correct destination.

変化	全出発地手法	抜け道考慮予測手法
上昇	65 回	66 回
低下	46 回	42 回

さらに被験者 1 のデータを用いて、正しい目的地の順位変化についても評価した。表 2 に示す結果から、抜け道考慮予測手法は、正しい目的地の順位の低下を防いでおり、抜け道の通過により一時的に順位が下がるという問題を解決できていることが分かる。

4.3 幹線道路の走行

4.3.1 幹線道路の走行の問題点

複数の出発地から利用し、様々な目的地に向かうために利用する道路を幹線道路と定義すると、幹線道路の走行時には、本来の目的地の確率が大きく変化することがある。たとえば、図 7 において、ユーザが道路リンク a, b, d と走行し、目的地 A に向かう場合、道路 a を走行時には目的地 A が正しく予測できるが、道路リンク b にさしかかった際、道路リンク b は目的地 B へ向かう際に頻繁に利用される経路であるため、目的地 A に向かう確率は大きく変化することになる。

この確率変化は、幹線道路では別の出発地からのデータがノイズとなり正しい予測を困難としているために起こる。図 7 の例でも、出発地別で目的地を予測すれば、理想とする予測が行える。ただし、すべての場合で別の出発地からのデータがノイズとなるわけではなく、別の出発地からのデータが良い影響をもたらす可能性もある。

4.3.2 出発地を考慮した手法

全出発地手法と、出発地別に学習した予測手法の違いを検証するため、予備実験を行った。本研究では、出発地別に学習した全出発地手法を**出発地別予測手法**と呼ぶ。なお、出発地別




図 7 幹線道路の走行

Fig. 7 An example of using an arterial way.

表 3 正しい目的地に対する予測確率変化の割合

Table 3 The probability of predicting correct destination.

確率変化	全出発地手法	出発地別予測手法
増加	65.0% (316/486)	80.7% (167/207)
減少	35.0% (170/486)	19.3% (40/207)

ただし、括弧内は（目的地の確率変化回数/全確率変化回数）

予測手法で用いる α は、抜け道考慮手法と同様に算出する。

実験では、表 1 の被験者 1 のデータを用いて、2 つの手法の確率変化に違いがどの程度あるのかを、正しい目的地に対する予測確率変化回数の割合を比較することで調べた。学習は全走行データを順に学習させながら目的地を予測するという条件で行った。

結果を表 3 に示す。結果から、全出発地手法と比較して、出発地別予測手法の方が正しい目的地に対する予測確率が下がる割合が少なく、正しい目的地の確率変化が右肩上がりとなることが分かった。これは出発地別に学習を行うことで、その出発地を起点とした走行において、抜け道や別経路を用いない限り、次に走行する道路を利用して目的地に行った回数が、それまでに走行していた道路を利用して目的地に行った回数から減ることはないためであると考えられる。抜け道や別経路利用時には、その目的地に対する走行回数が増えるが、同時に総走行回数も減るため、大きな確率変化は発生しにくい。そのため、全出発地手法と比較して正しい目的地に対しての確率が右肩上がりとなったと考えられる。

一方で出発地別で学習した場合は、分母が少ないことから明らかにとおり、予測に用い

表 4 2 手法の予測結果の遷移が示す目的地に対しての意味

Table 4 Meanings of changing the combination of methods for the destination.

状況	全出発地	出発地別	状況の示す意味
i	上昇	上昇	その目的地に行く際によく利用する道路に入った。
ii	上昇	下降	その目的地に行く際には、現走行の出発地からはあまり利用しないが、別の出発地から利用する道路に入った。
iii	下降	上昇	その目的地に行く際にその道路をよく利用するが、別の目的地にもよく利用している道路に入った。
iv	下降	下降	その目的地に行く際にはあまり利用しない道路に入った。

表 5 2 手法を組み合わせた確率変化の発生割合

Table 5 A probability of predicting correct destination in changing the combination of methods.

状況	全出発地	出発地別	発生頻度	正しい目的地の割合	求められる予測手法
i	上昇	上昇	12.6% (239 回)	61.9% (148 回)	目的地の確率を下げない手法
ii	上昇	下降	2.0% (38 回)	28.9% (11 回)	不明瞭
iii	下降	上昇	1.7% (33 回)	57.6% (19 回)	不明瞭
iv	下降	下降	83.6% (1,586 回)	1.2% (19 回)	目的地の確率を下げられる手法

る走行データが集まりにくいという欠点がある。これはたとえユーザの向かう目的地が何度も訪問している場所であっても、その出発地から訪問したことがなければ、まったく予測できないといった問題や、学習回数の少なさから確率変化が大きくなりやすいといった問題を生む。

4.4 2 手法の予測の差異を用いた予測

出発地別予測手法の評価実験から、出発地別予測手法と全出発地手法の 2 手法にはメリットとデメリットがあることが分かった。そこで、これらの 2 手法を有効に利用するため、走行経路をいくつかの状況に分類し、適切な手法を選択的に用いることを考える。状況分類にはいくつかの方法が考えられるが、手法の特徴が直接現れる確率変化を用いることが直観的であると考え、2 手法の確率変化を用いる。具体的には、道路リンクの遷移が発生したときに、2 手法それぞれの予測結果がどのように変化するかで場合分けを行う。予測結果の遷移から分類した状況とその意味を表 4 に、その発生頻度および、その状況が本来の目的地に対して発生する割合について前節と同じデータを用いて調査した結果を表 5 に示す。

結果から、2 手法の結果が異なる状況は、全データに対して約 4%とそれほど多くないことが分かった。また、これらの状況になった目的地が正しい目的地である割合は、2 手法で予測確率が上昇した場合でも 61.9%と確実とはいええない一方、2 手法とも減少している場合




図 8 提案したベイジアンネットワーク

Fig. 8 Our structured bayesian network.

は 1.2% であることから正しい目的地に対して 2 手法の予測が下がることはほとんどないことが分かった。さらに、2 手法で結果が異なる際には、出発地別予測が上昇している方が、本来の目的地である割合が高いことが分かる。以上から、各状況において表 5 右端列に示すような予測手法を適用すればよいといえる。状況 i ではその目的地は高い確率で正しいといえるものの、正しい目的地でない可能性も同程度あるため、その目的地を高い確率で維持できる手法が良いと考えられる。逆に状況 iv では、その目的地はほぼ確実に正しくないといえるため、その目的地の確率を大きく下げられる手法が良いと考えられる。状況 ii および iii では、どのような手法が適するか現段階では不明瞭である。これらの状況において、具体的にどのような手法を用いるかは、4.6 節で述べる実験によって導出する。

4.5 運転環境を考慮した手法

これまでに提案した手法は車両の道路リンクレベルの移動経路をもとに予測を行ったが、実走行においては、経路からの予測が困難な場合もあると考え、時間帯、曜日、乗員数、天気などの運転環境および広域のエリア遷移を用いる**運転環境別予測手法**を提案する。

この予測手法では、履歴に基づく行為推定に多用されているベイジアンネットワークを用いる。運転環境別予測手法では、運転を行う時間帯、曜日、天気、荷物量、乗員数といった運転環境は、目的地を決定する互いに独立している要因であり、どのエリアの通過は、目的地が決定したときの結果である、という因果関係に基づき、最も単純な形として図 8 に示すベイジアンネットワークを構築した。ベイジアンネットワークでは、過去の走行時の運転環境から、表 6 のように運転環境ごとの目的地訪問回数を記録した運転環境別目的地訪問回数表を学習し、この表を用いて各状況における条件付確率を算出し、目的地を予測する。各条件付き確率の初期確率分布は一様分布で与えた。各運転環境の粒度を、表 7 に示す。

4.6 状況を考慮した目的地予測手法

これまでにを行った実験から、2 手法の予測結果の遷移から状況を判断し、適応的に予測手

表 6 運転環境別目的地訪問回数表の一例

Table 6 Number of visits in driving contexts.

運転環境 (時間帯, 曜日, 天気, 乗員数, 荷物重量)	目的地候補地			
	A	B	...	Z
(朝, 休, 晴, 1 人, 少)	1	2	...	1
(朝, 休, 晴, 1 人, 多)	1	4	...	1
⋮			...	
(夜, 平, 雨, 複数, 多)	1	3	...	5

表 7 運転環境の粒度

Table 7 Particle size of each driving context.

運転環境	粒度
時間帯	朝, 昼, 夜
曜日	平日, 休日
天気	晴れ, 雨
乗員数	1 人, 2 人, 大勢
荷物重量	少ない, 多い




図 9 状況 i において各手法を用いたときの総走行距離に対する正しい目的地が Top1, Top4 に入る距離の割合

Fig. 9 The rate that the prediction includes correct destination in Top-1 and Top-4 in case i.

法を選択する**状況別予測手法**を提案する。具体的には、つねに単純手法と出発地別予測を並列に行い、予測結果から表 4 に示す場合分けに基づき、目的地予測手法を変化させる。

4.6.1 状況別予測手法の導出

被験者 1 の実験データを用い、表 4 に示すそれぞれの状況に、全出発地手法、出発地別予測手法、運転環境別予測手法を考慮した手法を適用し、もっとも予測結果のよい組合せを求める。評価指標としては、総走行距離において正しい目的地が上位 1 位 (Top1) および上位 4 位 (Top4) に入る距離の割合を用いる。これは、3 章で述べたとおり、提案システムでは予測の上位 4 位以内に正しい目的地があることが重要であるためである。

結果を図 9 ～図 12 に示す。図 9 は、状況 i において、総走行距離に対して正しい目的地が Top1 あるいは Top4 に含まれていた距離の割合を、各手法別に計測した結果を示している。同様に図 10, 図 11, 図 12 は、それぞれ状況 ii, iii, iv に関する結果である。結果から、状況 i, 状況 iv に対しては、運転環境別予測手法以外の手法が適しており、状況 ii には、どの手法も大差は見られなかった。状況 iii には、Top1 を予測する際には出発地別予測、Top4 には全出発地手法が適していることが分かった。また有意な差は確認できなかったが、状況 i には出発地別予測、状況 iv には全出発地手法が適しており、状況 ii で Top4 の




図 10 状況 ii において各手法を用いたときの総走行距離に対する正しい目的地が Top1, Top4 に入る距離の割合
Fig.10 The rate that the prediction includes correct destination in Top-1 and Top-4 in case ii.




図 11 状況 iii において各手法を用いたときの総走行距離に対する正しい目的地が Top1, Top4 に入る距離の割合
Fig.11 The rate that the prediction includes correct destination in Top-1 and Top-4 in case iii.




図 12 状況 iv において各手法を用いたときの総走行距離に対する正しい目的地が Top1, Top4 に入る距離の割合
Fig.12 The rate that the prediction includes correct destination in Top-1 and Top-4 in case iv.

表 8 提案する状況別予測手法

Table 8 Prediction method in each context.

状況	全出発地	出発地別	Top4 予測で用いる手法	Top1 予測で用いる手法
i	上昇	上昇	出発地別予測手法	出発地別予測手法
ii	上昇	下降	運転環境別予測手法	全出発地手法
iii	下降	上昇	全出発地手法	出発地別予測手法
iv	下降	下降	全出発地手法	全出発地手法

予測には運転環境別予測を用いた手法, Top1 の予測には全出発地手法が良い結果であった。

これらの結果から, 表 8 に示す分類分けで, 適応的に予測手法を変化させることとする。基本的にはシステムの目的から Top4 予測のための手法を用いるが, 音声案内など 1 つの目的地のみの情報しか提示できないようなサービスに応用する際は Top1 予測を用いるといったように用途に分けて活用することも考えられる。

5. 評価

提案手法を実装し, 評価を行った。用いた走行データは実験データのうち, 状況別予測手法の導出に利用しなかった被験者 2 のデータを用いた。学習量による効果を調べるため, 4 カ月の走行データのうち, 学習と評価に用いたデータの割合を, 1 カ月と 3 カ月, 2 カ月と 2 カ月, 3 カ月と 1 カ月と変化させて評価を行った。なお, 評価に用いたデータのうち, 学習時に訪問していない目的地は除外している。評価指標は, 総走行距離に対して正しい目的地が予測の上位 1 位 (Top1) もしくは 4 位 (Top4) に入っていた距離の割合とした。

結果を図 13, 図 14 に示す。結果から, 状況別手法はほとんどの学習量において, Top1 における予測で約 5% 程度, Top4 で約 10% 精度改善されていることが分かる。一方, この手法では学習が進むにつれて, 予測可能な距離が短くなる傾向がある。これは, 学習量が増えることで目的地候補数も増加したためであると考えられる。なお, 1 カ月の学習地点で目的地候補数は 9 カ所, 2 カ月の地点で 14 カ所, 3 カ月の地点で 17 カ所であった。一方で, 出発地別予測手法や抜け道考慮手法は学習量が増加するにつれ, 予測可能な距離が長くなることが分かる。これは, 学習が進むにつれ, 少しずつ予測が改善されているためだと考えら




図 13 総走行距離に対して正しい目的地が Top1 に入った割合
Fig.13 Performance of the proposed method by Top-1.




図 14 総走行距離に対して正しい目的地が Top4 に入った割合
Fig. 14 Performance of the proposed method by Top-4.




図 16 総走行距離に対して正しい目的地が Top-k に入った割合 (2 カ月学習)
Fig. 16 Performance of the proposed method by Top-k (trained for 2 months data).




図 15 総走行距離に対して正しい目的地が Top-k に入った割合 (1 カ月学習)
Fig. 15 Performance of the proposed method by Top-k (trained for 1 month data).




図 17 総走行距離に対して正しい目的地が Top-k に入った割合 (3 カ月学習)
Fig. 17 Performance of the proposed method by Top-k (trained for 3 months data).

れる。運転環境別予測は、ほとんどの場合で予測が行えておらず、より多くの走行データを集める必要があると考えられる。

また、Top-k 予測に関して k を 1~4 に、学習量を 1 カ月~3 カ月に変化させた際の結果を図 15、図 16、図 17 に示す。図から、どの学習量においても状況別予測手法を用いれば、ほとんどの走行経路において正しい目的地が Top2 以内に入ることが分かる。出発地別予測手法も Top2 付近で頭打ちしており、状況別予測手法より低い割合にとどまっている。これは、ある目的地に向かう際、その出発地から出発してその目的地に行っていない場合に、まったく予測できないことに起因していると考えられ、状況を判断し、適切に予測手法を切り替えることで正しい目的地を予測できる状況別予測手法が有効に機能していること

が分かる。

6. 考 察

6.1 出発直後の予測

全出発地手法および出発地別予測手法のどちらの手法も、道路リンクを通過することで目的地予測を更新するため、出発直後は予測が外れることが多いと考えられる。逆に、運転環境を考慮した手法は、運転時の時間帯や乗員数など、運転においてある程度静的な要素を利用するため、出発直後でも予測できると考えられる。この予想を検証する。

結果を図 18 に示す。予想と異なり、出発直後でも全出発地手法が最も長い期間予測でき




図 18 出発直後に目的地が Top1, Top4 に入った割合

Fig. 18 The rate that the prediction includes correct destination in Top-1 and Top-4 at the early stage.

ることが分かる。これは、検証に用いたユーザ・学習量では、よく行く目的地が出発直後から上位に必ず予測され、逆に運転環境を考慮した手法では、ふだんと異なる環境要素が与えられた場合に現状のページアンネットワークでは予測できなかったことを示している。学習が進み候補地が増えた場合に改めて検証が必要であるが、学習量の少ない初期利用段階では、全出発地手法が最も有効に機能することが分かる。

6.2 学習量の与える影響

本研究で用いた実験データは4カ月というそれほど長期間でない。その影響で、ページアンネットワークの学習が不足していたり、出発地別予測手法において、ある出発地点から訪問したことのない目的地がいくつか評価時に含まれていたりするなどの問題が発生した。

しかし、本研究で想定しているカーナビゲーションシステムは民生用の一般利用を想定しており、利用ユーザによっては週末の買い物や駅への送迎程度にしか、自動車を利用しないユーザも少なくないと考えられる。そのようなユーザを考えた場合、自動車の利用は月に数回程度であり、そのような状況でも目的地を正確に予測する必要がある。幅広い利用ユーザを考えた場合、本研究の評価実験に用いた1カ月の学習データ(25回の走行)程度の走行回数でも目的地をある程度予測できる必要がある。さらに、人の生活は変化するものであり、1年も利用すれば目的地の傾向が変化することも考えられる。現在の目的地予測手法はこのような変化に対応していないが、今後、生活の変化を取り入れた手法に拡張する場合には、数カ月で数回の利用でも目的地を予測できる必要がある。

6.3 出発地、目的地の記録

提案システムでは出発地や目的地の認識が必要であるが、プロトタイプシステムでは手作業で目的地や出発地を記録している。日常利用を考えた場合、出発地や目的地を自動的に

記録する仕組みが必要となる。目的地は、エンジンを停止させる、シートベルトをはずす、サイドブレーキを引くなどの車両から推測でき、出発地点は前回車両を停車した位置、最初に記録された位置を用いることで取得可能となると考えている。ただし、これらの目的地は位置情報であり、目的地に関する情報検索に利用するためには、停車位置の近くの建物など意味のある目的地名に変換する必要がある。

7. おわりに

本研究では、目的地予測型カーナビゲーションシステムのための走行履歴と運転状況を考慮した目的地予測手法を提案した。評価から、提案したいくつかの手法を単体で用いるより、状況によって適切な手法を選択的に利用することで長い距離の間、ユーザの向かっている目的地を上位に予測できることが明らかとなった。

今後の課題としては、学習量と予測手法の関係を明らかにし、予測手法に応用することが考えられる。また、長期の利用を考えた場合、ユーザの生活の変化から、目的地候補が変化することも考えられるため、目的地候補の削除やしばらく訪問を行っていない目的地に対して負の学習を行うような手法も必要である。さらに、目的地に関連する情報の提示の有効性の検証や実機を用いた評価を行う予定である。

謝辞 本研究の一部は、文部科学省グローバル COE プログラム(研究拠点形成費)、文部科学省科学研究費補助金基盤研究(A)(20240009)、特定領域研究(21013034)、特別研究員奨励費(19-55371)によるものである。ここに記して謝意を表す。

参考文献

- 1) 国土交通省道路局 ITS ホームページ. <http://www.mlit.go.jp/road/ITS/j.html/>
- 2) Liao, L., Fox, D. and Kautz, H.: Learning and inferring transportation routines, *Proc. National Conf. on Artificial Intelligence (AAAI 2004)*, pp.348–353 (July 2004).
- 3) Patterson, D.J., Liao, L., Fox, D. and Kautz, H.: Inferring high-level behavior from low-level sensors, *Proc. Ubiquitous Computing (UbiComp 2003)*, pp.73–89 (Oct. 2003).
- 4) Peeta, S. and Yu, J.W.: Adaptability of a hybrid route choice model to incorporating driver behavior dynamics under information provision, *IEEE Trans. Systems, Man and Cybernetics, Part A: System and Humans*, Vol.34, No.2, pp.243–256 (2004).
- 5) Terada, T., Miyamae, M., Kishino, Y., Tanaka, K., Nakagawa, T., Yamaguchi,

Y. and Nishio, S.: Design of a Car Navigation System that Predicts User Destination, *Proc. Int'l Workshop on Tools and Applications for Mobile Contents (TAMC)*, pp.54-49 (May 2006).

- 6) 赤穂賢吾, 加藤博一, 西田正吾: 実写ベースカーナビにおける交差点案内の検討と評価, 電子情報通信学会技術研究報告, MVE, マルチメディア・仮想環境基礎, Vol.106, No.234, pp.1-6 (2006).
- 7) 北岡教英, 角谷直子, 中川聖一: 音声対話システムの誤認識に対するユーザの繰返し訂正発話の検出と認識, 電子情報通信学会論文誌 D, Vol.J87-D2, No.7, pp.1441-1450 (2004).
- 8) 小林 誠, 嶋 恵子, 小針里美, 曾布川靖, 伊東幸宏, 酒井三四郎: 車載端末向け情報選別配信システムにおける到着地推定機構, 情報処理学会論文誌, Vol.45, No.12, pp.2688-2695 (2004).
- 9) 宮下浩一, 寺田 努, 田中宏平, 西尾章治郎: 目的予測型カーナビゲーションシステムのためのマップマッチング, 情報処理学会論文誌, Vol.50, No.1, pp.75-86 (2009).
- 10) 吉岡元貴, 小澤 順: 移動先エントロピーを用いた車両の走行履歴による到着地の推定, 情報処理学会論文誌, Vol.46, No.12, pp.2973-2982 (2005).

(平成 21 年 3 月 31 日受付)

(平成 21 年 10 月 2 日採録)



田中 宏平 (正会員)

2005 年大阪大学工学部電子情報エネルギー工学科情報システム工学科目卒業。2007 年同大学院情報科学研究科マルチメディア工学専攻博士前期課程修了。現在, 同専攻博士後期課程に在籍。ウェアラブルコンピューティング, ユビキタスコンピューティングに興味を持つ。



寺田 努 (正会員)

1997 年大阪大学工学部情報システム工学科卒業。2000 年同大学院工学研究科博士後期課程退学。同年より大阪大学サイバーメディアセンター助手。2005 年より同講師。2007 年神戸大学大学院工学研究科准教授。現在に至る。2004 年より特定非営利活動法人ウェアラブルコンピュータ研究開発機構理事。2004 年には英国ランカスター大学客員研究員を兼務。博士 (工学)。ウェアラブル・ユビキタスコンピューティングの研究に従事。IEEE, 電子情報通信学会, 日本データベース学会, ヒューマンインタフェース学会の各会員。



岸野 泰恵 (正会員)

2002 年大阪大学工学部卒業。2004 年同大学院情報科学研究科博士前期課程修了。2007 年同研究科博士後期課程修了, 同年日本電信電話株式会社入社。博士 (情報科学)。ユビキタスコンピューティング, センサネットワークに関する研究に従事。



西尾章治郎 (正会員)

1975 年京都大学工学部数理工学科卒業。1980 年同大学院工学研究科博士後期課程修了。工学博士。京都大学工学部助手, 大阪大学基礎工学部および情報処理教育センター助教授, 大阪大学大学院工学研究科情報システム工学専攻教授を経て, 2002 年より大阪大学大学院情報科学研究科マルチメディア工学専攻教授となり, 現在に至る。2000 年より大阪大学サイバーメディアセンター長, 2003 年より大阪大学大学院情報科学研究科長, その後 2007 年より大阪大学理事・副学長に就任。この間, カナダ・ウォータールー大学, ビクトリア大学客員。データベース, マルチメディアシステムの研究に従事。現在, Data & Knowledge Engineering 等の論文誌編集委員。本会理事を歴任。本会論文賞を受賞。電子情報通信学会フェローを含め, ACM, IEEE 等 8 学会の各会員。