

ファジィ c-means 法による渋滞情報の補間方式

古川 武志 狩野 均

筑波大学

概要

本稿では、交通量計測器が設置されている道路(リンク)から得られる交通量から、交通量を計測していないリンクの交通量を推定する方法を提案する。現行のカーナビゲーションシステム(カーナビ)が道路種別に応じた標準速度を推定値としているのに対して、本手法ではファジィ c-means 法を用い、交通量計測器の設置点との距離関係から周辺道路の交通量を補間する。また、ニューラルネットワーク(NN)を用いて、特定のリンクの交通量を補間する。実際の交通量データを用いて評価した結果、本手法が交通量補間方式として有効であることを確認した。

Interpolation of Traffic Jam Information Using Fuzzy c-means

Takeshi Furukawa Hitoshi Kanoh
Tsukuba University

Abstract

This paper describes a new method of travel time estimation for car navigation systems. The method estimates traffic of a road without a traffic measuring device from traffic of roads with traffic measuring devices. Current commercial car navigation systems estimate a travel time using a fixed standard velocity. In contrast, the proposed method can interpolate a velocity using fuzzy c-means based on the distance between a measured point and a non measured point. In addition, the velocity on the specific road can calculate using neural networks. Experiments using real traffic data prove that the proposed method is effective as a traffic interpolation.

1. はじめに

自動車向けテレマティクスサービスの本格展開に伴い、ドライバーは走行中、運転に必要な広域交通情報をリアルタイムに得ることができるようになってきた[1]。

しかし、現状の経路探索では渋滞の予測、推移[2]など、渋滞の予測値を考慮した探索が行われていない。また現行のカーナビゲーションシステム(カーナビ)では、旅行時間の算出にあらかじめ設定した標準速度をもとにしている。これらの結果として予定到着時間の遅延など、不正確な経路探索とおこなわれる場合がある。

以上の問題点を改善するため、本稿では実際の交通量データに基づいて、ファジィ c-means 法

とニューラルネットワーク(NN)[3]の手法を用いた渋滞情報の補間方式を提案する。

2. 本研究の概要

2.1 カーナビの概要

現在使われているカーナビにはナビ研S規格フォーマット(ナビゲーションシステム用データベース)のデジタル地図データが用いられている。このデータには法定速度、距離、道路種別などの道路情報に加え、ランドマークやドライブに必要な店舗情報などの目的地情報も入力されている[4]。

また、昨今のカーナビ[1,5]には交通量データをリアルタイムに受信する機能が搭載されている。ここで指す交通量データとは全国の主要道路上

のある地点における車の通過時間、通過台数などの情報を 5 分おきに集積したデータである。このデータを受信することによって、ドライバーは渋滞の起きている道路を回避することが可能となった。

2.2 現状技術の問題点

現在市販されているカーナビでは、交通量データを受信して経路探索に活用しているものもあるが、予測値を考慮した探索は行われていない。そのため、探索時点では渋滞していなかった道路で渋滞が発生すると、当初予定していた到着時間に遅延が生じることがある。また、交通量計測器が設置されていないリンクの通過時間は、あらかじめ設定された標準速度を用いて計算しているため、このリンク上で渋滞が発生すると、計算値と実際の所要時間にずれが生じる可能性がある。

2.3 提案手法の方針

2.2 節で述べた問題点を解決するためには、空間データの補間技術と時系列データの予測技術を新たに開発することが必要であると考えられる。空間データの補間技術は広域道路網上の交通量計測地点における交通量から、交通量を計測していない道路の交通量を推定する技術である。また、時系列データの予測技術は現在の交通量データから数分ないし 1 時間先の短期の交通量を予測する短期予測技術、ならびに、過去データに基づいて、数日から数時間先の長期の交通量を予測する長期予測技術である。

本稿では、空間データの補間方式を提案する。

3. 提案手法

3.1 提案手法の位置づけ

本稿では、カーナビにおける交通量データとして車の速度を考え、以下の 3 つのレベルに分類して補間方式を提案する。

・レベル 0 (標準速度) :

法定速度に基づいて設定した速度。

・レベル 1 (交通量データ補間速度) :

交通量情報から計算した空間補間データ。交通量計測器が設置されていないリンクに対する速度。

・レベル 2 (特定リンク補間速度) :

交通量情報とプローブカー収集データから空間補間したデータ。交通量計測器が設置されていないリンクの中で、プローブカーが通過したリンクに対する速度。

現状のカーナビがレベル 0 のみを考慮しているのに対し、本手法ではレベル 1 にあたる部分をファジィ c-means 法、レベル 2 にあたる部分を NN を用いて補間することで、旅行時間をより正確に算出する。なお、今回の実験で用いるデータはプローブカーのデータが現時点で得られないため、交通量計測器が設置されているリンクのデータで代用した。

3.2 ファジィ c-means 法によるデータ補間

ファジィ c-means 法は、ファジィクラスタリング手法の一種である[6]。通常のクラスタリングでは、ある個体は必ず 1 つのクラスに属すると想定されていたが、ファジィクラスタリングでは、ある個体があるクラスに属す度合いが帰属度によって表されているとする。

この手法をデータ補間に応用する場合、ここでは、以下のように定式化する。まず、道路網におけるリンクを個体と見なし、全リンクをクラス分けすることを考える。つぎに、1 つの交通量計測器が 1 つのクラスを代表していると考え、そして、交通量計測器の設置されていないリンクの交通量を計測器で測定した交通量とクラスの帰属度から計算する。なお、リンクの交通量としては、ここでは、車の通過時間を採用する。

あらかじめ設定されている標準速度も考慮すると、リンクの通過時間を次式により計算する。

$$x_k = (1-R) \times \sum_{i=1}^n u_{ik} \times v_i + R \times V \quad (1)$$

ただし、記号を次のように定義する。

- i : 交通量計測器の番号
- n : 交通量計測器の個数
- k : リンク番号
- v_i : 交通量計測器を設置したリンクを車が通過するときの平均速度(計測値)
- x_k : リンク k を車が通過するときの平均速度(計算値)
- u_{ik} : リンク k が交通量計測器 i に属す度合い(すなわち帰属度)
- V : 標準速度(設定値)
- R : 標準速度の利用率($0 \leq R \leq 1$)

3.3 ニューラルネットワークによるデータ補間

本研究で用いた NN を図1に示す。

問題点にも挙げたように、交通量データは点の情報であるため、渋滞予測を行う上で情報を補間する必要がある。そこで、入力層に補間する地点の近辺の交通量データを NN の入力に用いることで、出力に車の速度を導出することができ、この結果にもとづいた道路情報を補間することが可能であると考え。

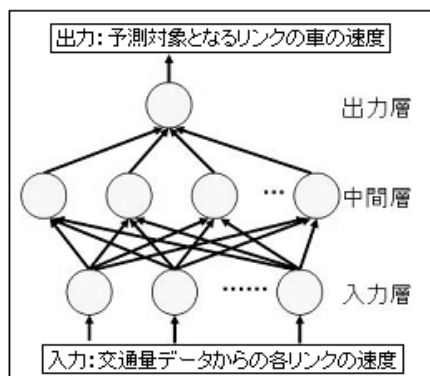


図 1: 実験で用いるニューラルネットワーク

4. 評価実験

4.1 実験環境・条件

今回の実験では、交通量データの量が多く、車の流出・流入が比較的多い首都高速箱崎 JCT を中心とした首都高速道路を実験対象とした(図 2)。実験で用いたリンクを表 1 に示す。実際の交通量データとして 2003 年 3 月のものを使用した。一例

として図 3 に交通量データを示す。グラフの横軸の原点を午前 0 時とした。実験時間を 5~24 時(1 日)、6~9 時(朝)、10 時~14 時(昼)、15 時~21 時(夕)の 4 つの時間帯に分けて結果を比較した。ここで i 番目のリンク長を l_i 、補間対象のリンク長を l_k 、途中通過するリンク長の合計を l_t とすると総リンク長 l_{ik} は次式により定義する。

$$l_{ik} = l_t + (l_i + l_k) / 2 \quad (2)$$

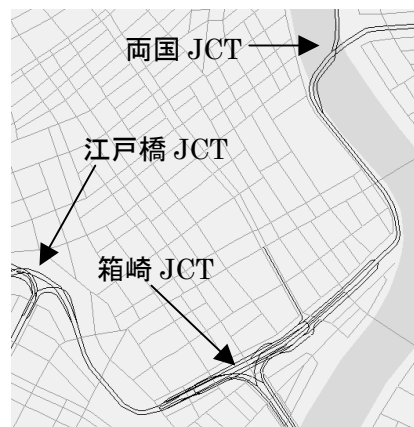


図 2: 首都高速箱崎ランプ周辺地図

表 1: 実験で用いたリンクのデータ

場所	補間対象	リンク 1	リンク 2	リンク 3
江戸橋	100	99	102	103
→両国	{327m}	(396m)	(545m)	(1132m)
両国→	123	122	125	121
江戸橋	{141m}	(276m)	(641.5m)	(791m)

(注)

- ・対象リンクは補間の対象となるリンク番号。{}内は、リンク長。
- ・リンク 1~3 は、対象リンクに近いリンク。番号は近い順番。
- ()内は、リンクの midpoint と対象リンクの midpoint との距離。




図 3: 交通量データの例

4.2 時間・曜日における交通流のふるまい

交通流[7]は対象とする時間、曜日、対象とするリンクとの距離によってそのふるまいが異なる。そこで、交通量情報のデータから各時間帯、距離における相関係数の変化を調べた。実験対象とする交通流は江戸橋→箱崎→両国方面とした。結果を図4と図5に示す。なお、平日は月曜日、休日は日曜日のデータを用いた。




図4: 距離との相関関係(3日平均・平日)




図5: 距離との相関関係(3日平均・休日)

図4、図5の結果から、次のことがわかる。

- ・補間の対象とするリンクとの距離が 0.5km を超えると相関が低下する
- ・時間帯によって、および平日・休日によって相関関係が異なる

4.3 ファジィ c-means 法による補間結果

ファジィ c-means 法による補間の実験は平日のデータを用いた。結果を図6,7に示す。図6(上)は補間の対象となるリンクから最も近い交通量計測器の設置リンクのデータを用いた場合($n=1$)、図6(中)は、1番目と2番目に近いデータを用いた場合($n=2$)、図6(下)は、1~3番目に近いデータを用いた場合($n=3$)に対応する。また、図7に同時刻におけるファジィ c-means 法に使用するデータ数による違いを示す。道路ネットワークに対する同様の実験結果を図8,9に示す。ここでは、 u_{ik} としてリンク長の相対値をとり、リンク間の経路長が近いほど値が大きくなるようにしている。また、 z_{ik} を次のように定義する。

$$z_{ik} = 1/l_{ik} \quad (3)$$







このとき、帰属度 u_{ik} を次のように定義する。

$$u_{ik} = l_{ik} / \sum_{k=1}^n z_{ik} \quad (4)$$

なお、標準速度は首都高速道路で広く採用されている 60km/h とした。

図6~図9より、交通流や時間帯、道路ネットワークの違いによる変化が若干見られるものの、全体としての傾向は似ていることがわかる。また、標準速度使用率 $R=1$ のとき、すなわち現在使われているカーナビの誤差と比べると、図7の結果より誤差が約 75%、図9の結果から約 50%小さいことがわかる。

さらにファジィ c-means 法に適用する使用点数は1点のときより2点、3点の場合、誤差が図7で約 45%、図9で約 20%小さくなっていることがわかる。これは c-means 法よりもファジィ c-means 法が交通量データを補間する手法として、より優れた方法であることを示している。



◆ 5~24時 ■ 6~9時 ▲ 10~14時 × 15~21時

◆ 5~24時 ■ 6~9時 ▲ 10~14時 × 15~21時

図6 ファジィ c-means 法の補間結果
 <江戸橋→箱崎→両国方面>
 (上): $n=1$ 、(中): $n=2$ 、(下): $n=3$

図8 ファジィ c-means 法の補間結果
 <両国→箱崎→江戸橋方面>
 (上): $n=1$ 、(中): $n=2$ 、(下): $n=3$





図7 クラス数 n (点の数)による比較

図9 クラス数 n (点の数)による比較

4.4 ニューラルネットワークによる補間結果

4.3 節の結果をふまえ、交通量データをもとに NN を用いて速度情報の補間を行う。入力には、あらかじめ 70km/h を1とする線形スケーリングをおこなった車の速度を使用している。また、学習には誤差逆伝播法を用い、教師信号として実際の交通量情報のデータを用いる。実験における各パラメータは以下のとおりである。

- ・学習回数…500
- ・入出力:速度(0~1 にスケーリング)
- ・中間層のニューロン数…4 個

交通量データの使用点数の違いについて、NN における学習の結果を図 10 に示す。中間層のニューロン数が 3 個のときが一番良い結果を出している。これは、2 個のときは情報量が足りず、4,5 個のときは入力に用いる交通量データと補間対象のリンクとの経路長が大きくなるからと考えられる。

また、各時間帯における速度の誤差の平均を表 4 に示す。表 4、図 4 から、各時間帯における相関が高いほど学習が成功しやすく、実際の速度との誤差が小さくなることがわかる。

この結果と現在普及しているカーナビを比較すると、実際の速度が 30km/h、法定速度が 60km/h であった場合、その誤差は 30km/h になり、誤差の値が約 80%改善されていることになる。これは NN による速度の予測が十分実用に耐える性能であることを示している。




図 10: 6~9 時の時間帯における学習の結果 (入力層のニューロン数=2~5 個)

表 4: 各時間帯における速度の誤差(平日)

	5~24 時	6~9 時	10~14 時	15~21 時
誤差 平均	5.0km/h	4.2km/h	7.3km/h	5.7km/h

5. おわりに

実際の交通量データを用いてファジィ c-means 法と NN による、リンクの交通量データの補間を行い、その有効性を示した。今後は、各実験におけるパラメータの変更などを行い、誤差をより小さくする方法を検討する。そして短期・長期予測ならびに予測経路探索手法の検討を実施する予定である。

参考文献

- [1] 佐野, 小谷, 吉田, 田中: 渋滞予測のシステム化について, 土木学会第 49 回年次学術講演会, IV-369, 1994.
- [2] 山崎: ナビゲーションシステム体系と今後の展開, 人工知能学会誌 15 巻 2 号 pp.226-233, 2000.
- [3] 伊庭, 福原: 複雑系入門, NTT 出版, pp.135-147, 1998.
- [4] IT ナビゲーションシステム研究会: ナビ研ソフト作成ガイドブック, S 規格(Version2.2)準拠(1997).
- [5] 狩野・中村: 知識の集団を用いたGAによる不特定な立ち寄り地を含む経路探索, 人工知能学会論文誌, vol.17, No.2, pp.145-152 (2002).
- [6] 宮本: クラスタ分析入門, 森北出版 (1999).
- [7] K.Nagel, S.Rasmussen: Traffic at the edge of chaos, ARTIFICIAL LIFE IV, pp.222-235(1994).