

1-7 信号制御における光ビーコン情報の利用性に関する

いくつかの基礎的検討

Some Fundamental Examinations on the Usability of Optical Beacon Information in Traffic Signals Control

奥谷巖¹・三井達郎²・中田勇介³

Okutani Iwao, Mitsui Tatsuro, and Nakada Yusuke

抄録：本研究は、高度交通管制システム構築の中で模索が始められている光ビーコンから得られる情報の利用に関して基礎的な検討をしたものである。まず光ビーコンとの間で双方向通信機能を担う車載機を搭載した車両割合と旅行時間情報の信頼性の関係について簡単なシミュレーションによって調べたが、車載機搭載率20%以下の範囲では搭載率の増加に伴う誤差率の減少割合は顕著であることが分かった。さらに適応型の信号制御を指向した交差点間の旅行時間の推定について、光ビーコン情報を入力情報とするニューラルネットワークモデルとウェーブレットニューロンモデルを考えNETSIM（米国で開発された汎用型シミュレーションモデル）によるシミュレーションから得られたデータで適用性を検討したが、後者のモデルは学習が迅速である反面、前者との比較ではわずかながら入力情報に含まれる誤差の影響を受けやすいことが明らかとなった。

Abstract: In this study, conducted are the fundamental examinations on the optical beacon information usage which has been being sought for in developing the ITCS(Integrated Traffic Control System). Firstly, investigated is the relationship between reliability of travel time derived from optical beacon information and the rate of vehicles carrying apparatus for communication with optical beacon. It is revealed that the mean travel time estimation error reduces rather rapidly according as the rate of vehicles equipped with communication apparatus increases in the range up to 20%. Secondly, as an estimator for travel time between signalized intersections developed are the two alternative neuro-type models, the one employing the neural network and the other adopting wavelet neuron idea both of which utilize up-link information derived from optical beacon as an input to the model. After widely executed testings of the models using data from traffic simulation done by NETSIM, it is exhibited that the wavelet model, when compared to the neural network model, works faster in learning process although the output is slightly liable to be affected by the noise included in the model inputs.

キーワード：光ビーコン、アップリンク情報、信号制御、ニューロモデル

Keywords：optical beacon, up-link information, traffic signals control, neuron model

1. はじめに

本研究では、光ビーコンを用いた新しい信号制御システムに関して基礎的な検討を行う。現在の信号制御システムでは、主として超音波式車両感知器からのデータに基づいて信号制御パラメータの設定・更新を行っている。超音波感知器は、交通量と時間占有率を測定する装置であるが、測定地点が感知器設置地点と感知対象車線に限定されているため、車の動きを線的、面的に把握できないという欠点がある。これに対して、平成4年から警察庁によって整備が進められている光ビーコン(光学式交通情報収集

提供装置)は、交通量、時間占有率を計測できる感知機能に加え、道路と車両間の双方向通信機能を備えている。双方向通信機能とは光ビーコンからドライバーに対して車載機を通じて交通情報等をリアルタイムに提供すると同時に、車両側から光ビーコンに車両のID、通過した光ビーコン番号等の情報を送信する機能である。光ビーコンは現状では主として交通情報の提供装置として用いられているが、双方向通信機能により、車載機搭載車両の走行経路、旅行時間、車種などの高度な情報の収集が可能である。したがって、このような光ビーコン情報の活用により交通流の実態に即した適応型信号制御システムを実現できる可

1 : 正会員 工博 信州大学 教授 工学部社会開発工学科

(〒380-8553 長野県長野市若里4-17-1, Tel:026-269-5304, E-mail: iokutan@gipwc.shinshu-u.ac.jp)

2 : 正会員 博士(工学) 科学警察研究所交通科学第一研究室長 (〒277-0882 千葉県柏市柏の葉6-3-1)

3 : 学生会員 信州大学 学部生 工学部社会開発工学科

能性がある。

本研究はこうした信号制御を視野に入れた基礎的検討を実施するものであるが、まず第2章では旅行時間の計測精度について、車載機搭載率(全交通量に占める車載機搭載車の割合)との関連性に着目して検討する。次に、自律的信号制御システム構築のため、信号制御パラメータ及び交差点の交通状況と平均旅行時間の関連性をシステム自らが自動的に学習することができる二つの代替的モデルを提案しその有効性をNETSIMによるシミュレーションから得られたデータにより検証する。

2. 車載機搭載車の割合とリンク旅行時間測定精度の関係

(1) 概説

信号制御からみた光ビーコン情報の最大の利点は、制御の実行によってリンク旅行時間などの交通流の効率性を示す指標がどのように変化したかをリアルタイムで把握できることである。信号制御の評価指標としては交通量全体としての平均的な旅行時間等が用いられるが、車載機の普及が十分でないという現状を考慮すれば、すべての車の旅行時間が光ビーコンによって得られるわけではない。現実には、車載機を搭載した何割かの車に対して測定された旅行時間の実測値から、そこを通る車全体の平均的旅行時間を推定することになる。そこで、信号制御システムの検討の前に、車載機搭載車の全交通量に占める割合が信号制御の基礎データとなる全通過車両の平均的旅行時間の推定精度にどのような影響を及ぼすかをシミュレーションを用いて調べる。

(2) シミュレーションの概要

光ビーコンによる個々の車の旅行時間計測状況をシミュレートするためには、車両1台ごとの走行軌跡を出力できる機能が必要である。次章でもちいるシミュレーションモデルNETSIMはこの機能を持っていないため、Hidas¹⁾が提案した追従理論式を導入した新たなシミュレーションモデルを開発した。この理論式は、希望車間距離という概念に基づいて導出されたものであり、現実の追従行動を正確に再現できることが示されている。

シミュレーションは、**図-1**に示す信号交差点の1流入部を対象に行った。光ビーコンは交差点の手前500mの地点(ビーコンA)、交差点を直進して流出した地点(ビーコンB_S)、交差点を左折して流出した地点(ビーコンB_L)、交差点を右折して流出した地点(ビーコンB_R)に設置されているものとする。光ビーコン搭載車については、ビーコンAの通過時刻とビーコンB_S、B_L、B_Rのいずれかの通過時刻の差によって地点Aから交差点を流出するまでの時間(リンク旅行時間)を計測できるが非搭載車についてはリンク旅行時間は計測できないという想定である。

本シミュレーションでは、車は、流入部上流でランダムに

発生し交差点に向かって走行する。各車の進行方向(直進、左折、右折の区別)及び希望速度、加減速度は車発生時に乱数によって割り当てられる。車線利用状況は、左折車は第1車線(外側車線)、直進車は第1車線と第2車線、右折車は第3車線を走行し、車線変更はないものとした。また、信号周期は100秒、対象流入部に表示される青時間は50秒とした。

一般的に、交通シミュレーションでは擬似乱数によって確率的事象の生起を決める。このことから、入力データが同一であっても乱数系列で異なった結果がえられるが、そのいずれもが確率的現象として起こり得ると解釈できるから、結果が少数の現象のみから成るような場合であれば偏りは避け難いとしても、ある程度以上の現象が結果の中に含まれる状態になっているならば、結果に基づく判断はほぼ妥当なものになると思われる。以下では車1台ごとの旅行時間を求めるシミュレーションを実行するが、結果的には数百台の車について旅行時間の値を得ていることから、それ程大きな偏りは発生しないと考えてよいであろう。

上述の条件下でシミュレーションを実施し、車載機搭載車の割合とリンク旅行時間推定精度の関係を検討した。具体的には、まず、車載機搭載率100%としてすべての車について1台ごとにリンク旅行時間を出力し、それを平均することで全車に対する平均リンク旅行時間を求めた。この値が推計すべき平均旅行時間である。次に車載機搭載率を様々に変化させ、車載機搭載車のみ平均リンク旅行時間を求めた。そして、これらの値と全車に対する平均リンク旅行時間を比較した。シミュレーションは、**表-1**のように交通量が比較的少ない場合(ケースa)と多い場合(ケースb)について行った。各ケースの右左折直進率(平均値)は

■ 光ビーコン




図-1 シミュレーション対象流入部

表-1 シミュレーション実行時の交通量及び右左折直進率

	交通量 (台/時)	直進率 (%)	左折率 (%)	右折率 (%)
ケースa	1360	79.4	13.2	7.4
ケースb	2152	78.6	16.7	4.7

夫々0.05,0.15,0.8としたが表の値はシミュレーション結果(実績値)でこれらの値とは一致していない。また、リンク旅行時間の集計は15分間の出力値を用いて行った。なお、今回は簡単のため車種を乗用車に統一したが、例えば大型車で低速走行する車の存在を考慮すると以下で述べる結果は異なってくる可能性はある。今後の課題としたい。

(3) シミュレーション結果

a) 車両の走行軌跡

シミュレーションの妥当性を確認するために第2車線車両の走行軌跡を調べてみると、交通量が少ないケースaでは赤信号の影響を受けて停止あるいは減速する車とほとんど減速することなく青信号で交差点を通過する車が明確に分かれている。交通量が多いケースbでは、すべての車が直接・間接に赤信号の影響を受けて複雑な加減速行動を行っている状況が見られた。このように、車の走行挙動は個々の車によって異なり、また、交通量によっても異なる。よって、車載機搭載車だけの旅行時間計測値によって全車の平均旅行時間を推定する場合には、車載機搭載率がその推定精度に大きな影響を及ぼすことになる。

b) 車載機搭載率100%の場合のリンク旅行時間分布

図-2、図-3に、15分間に交差点から流出したすべての車についての1台ごとのリンク旅行時間の分布を示す。図-2はケースaの場合で全車両台数は363台である。この図では、分布に2つピークがあるが、これは減速せず交差点を通過する車の旅行時間と赤信号で停止を強いられる車の旅行時間を示している。図-3はケースbの場合で全車両台数は463台である。図-2のような2つのピークはみられず、ほとんどすべての車が赤信号の影響を受けて加減速を繰り返すという前述の現象を反映した結果となっている。図-2、図-3より、リンク旅行時間は1台ごとに異なっており、特に交通量の多いケースbで分布範囲が広いことがわかる。これらの図は、車載機搭載率、搭載車の混入状況(搭載車が分散走行しているか又は搭載車が連続走行しているか)によって全車に対する平均リンク旅行時間の推定精度が大きく影響されることを示している。

c) 車載機搭載車の平均リンク旅行時間分布

図-4、図-5は、ケースa、ケースbについて、車載機搭載車の割合(車載機搭載率)を与えたときに、車載機搭載車だけの平均リンク旅行時間がどのような分布になるかを示したものである。搭載率が一定の場合でも車載機の混入状況(連続する交通流の中における車載機搭載車の配置具合)によって、搭載車の平均リンク旅行時間は異なる。車載機搭載車の配置パターン数は膨大な数になることから(例えばケースaでは、363台の中から搭載率5%として18台の車載機搭載車を選ぶ方法は 1.2×10^{30} パターン存在する)、図-2、図-3では、配置パターンをランダムに500パターン選び、個々のパターンごとに平均リンク旅行時間を算出してその分布を求めた。

図-4、図-5より、車載機搭載車の平均旅行時間の




図-2 全車に対する旅行時間分布(ケースa)




図-3 全車に対する旅行時間分布(ケースb)




図-4 車載機搭載車の平均リンク旅行時間の分布(ケースa)




図-5 車載機搭載車の平均リンク旅行時間の分布 (ケースb)

分布は、正規分布に近く、搭載率が高くなるにつれて標準偏差が小さくなる傾向が伺える。尖度および歪度による正規性の検定を行ったところ、いずれのケースでも搭載率のすべての値に対して正規分布であることが確認された(有意水準 $\alpha = 0.05$)。車載機搭載車の平均リンク旅行時間は、図-2、図-3に示した個々の車のリンク旅行時間分布から任意の割合で搭載車のリンク旅行時間をランダムに選び出し、その平均値を求めたものに相当する。よって搭載車の平均リンク旅行時間の分布は、中心極限定理によれば正規分布に従う。図-4、図-5は、この定理を実証したものと云える。

d) 車載機搭載率と推定リンク旅行時間の誤差率の関係

図-2と図-3にすべての車のリンク旅行時間の分布を示したが、車載機搭載車のリンク旅行時間はこれらの分布からのランダム抽出とみなすことができる。よって、車載機搭載車がある割合で混入する場合に、搭載車のリンク旅行時間の計測値から全車に対する平均リンク旅行時間を推定する問題は、標本平均から母平均を推定する問題に帰着する。ここで、母平均は全車に対する平均リンク旅行時間、標本平均は全交通量にランダムに混入している車載機搭載車の平均リンク旅行時間である。

中心極限定理によれば、平均 μ 、分散 σ^2 の任意の母集団分布から大きさ n の標本 X_1, X_2, \dots, X_n を取り出した時に、その平均値 $\bar{X} = (X_1 + X_2 + \dots + X_n) / n$ は、 $N(\mu, \sigma^2/n)$ に従う。

この場合、ある与えられた定数 α に対して、

$$\bar{X} - z_\alpha \sigma / \sqrt{n} \leq \mu \leq \bar{X} + z_\alpha \sigma / \sqrt{n} \quad (2.1)$$

を満足する確率が $1 - \alpha$ となる。

ここで z_α は、 $Z = (\bar{X} - \mu) / (\sigma / \sqrt{n})$ とすれば、

$P(|Z| \leq z_\alpha) = 1 - \alpha$ を満足する値である。

式(2.1)は、以下のように書き換えることができる。

$$\frac{\mu - \bar{X}}{\mu} \leq \left| \frac{z_\alpha \sigma}{\sqrt{n} \cdot \mu} \right| = E \quad (2.2)$$

上式の E は、標本平均 \bar{X} で母平均 μ を推定したときの最大誤差率が $1 - \alpha$ の確率で E であることを示す。

式(2.2)を平均リンク旅行時間推定の問題に置き換えれば、 μ は全車のリンク旅行時間の平均値、 σ は全車のリンク旅行時間の標準偏差とみなすことができ、また、 \bar{X} は車載機搭載車のリンク旅行時間の平均値、 n は車載機搭載車の台数である。車載機搭載率を λ 、全車両台数を N とすれば、 $n = \lambda \times N$ であるから、誤差率 E は次式で表される。

$$E = \left| \frac{z_\alpha \sigma}{\sqrt{\lambda \times N} \cdot \mu} \right| \quad (2.3)$$

図-6に、ケースaの場合 ($N = 363$) の車載機搭載率 λ と誤差率 E の関係を示す。また、図-7に、ケースbの場合 ($N = 463$) の車載機搭載率 λ と誤差率 E の関係を示す。ここで、 μ 、 σ の値は、ケースaではそれぞれ 52.3、16.3、ケースbではそれぞれ 78.7、26.5 である(図-2、図-3参照)。各図には、 $\alpha = 0.05$ 及び $\alpha = 0.10$ の2つの曲線を示してある。これらの図から、車載機搭載車の割合が増加するにつれて誤差率が低下し、特に車載機搭載率20%以下では、搭載率の増加に伴う誤差率の減少割合が大きいことがわかる。また、ケースaとケースbの比較では、車載機搭載率と誤差率の関係はほぼ同様である。すなわち、交通量が表-1に示した程度では、交通量が旅行時間推定精度に及ぼす影響は比較的少ないと云える。なお、両





図-6 車載機搭載率と誤差率の関係(ケースa)



図一七 車載機搭載率と誤差率の関係(ケース b)

図では、車載機搭載率 100%の場合でも誤差率が 0 にならないが、これは式(2.3)を導くに際し無限母集団を仮定しており、通過全車に車載機が搭載されているとしても得られた平均旅行時間は標本とみなしているからである。つまり、期間を限定しなければ車の台数は無限であるから、ある特定期間の通過車全部が車載機を搭載していたとしても、過去及び今後の全ての車の搭載率が 100%であることを意味しない。よって無限母集団の仮定は妥当と考えられる。

本節では、旅行時間計測期間を15分間に設定して、車載機搭載率と平均旅行時間推定精度の関係の1例を示した。計測期間を15分間に設定した理由は、現行の信号制御システムの多くが5分～15分間隔で信号制御パラメータを更新していることを勘案したからである。しかし、式(2.2)からわかるように、リンク旅行時間の推定誤差は、車載機搭載車台数 n によって決定される。したがって、旅行時間計測期間をより長くすれば、測定期間中の交通量が多くなるため、たとえ搭載率が低くても多くの車載機搭載車の旅行時間を測定することができ推定精度が高くなる。一方、計測時間を短くすれば、計測期間中の交通量は少なくなるので搭載率が高くても推定精度が低くなる場合がある。本章で検討の対象としている適応型信号制御システムでは、信号制御パラメータの更新間隔が短いため計測期間中の交通量が少なくなることが予想される。よって、適応型信号制御システムに関しては、同一の搭載率であっても旅行時間推定誤差率は、図一六、図一七よりも大きくなることになる。車載機搭載車の普及にはかなりの時間を要することを勘案すれば、光ビーコン情報を用いた信号制御システムを実用化するためには光ビーコンの旅行時間計測情報に加えて車両感知情報を補助的に利用した新しいリンク旅行時間推定方法についても今後研究を進める必要があると考えられる。

3. 光ビーコン情報を利用した旅行時間推定

(1) 概説

現行の信号制御システムの問題点の1つは、信号制御パラメータの設定値が交通流の経年変化に追従できないことである。信号制御パラメータを設定した当時の交通流と比べて現在の交通流が大きく変化しているにもかかわらず、以前と全く同じ信号制御を行っている箇所も少なくない。この理由は、現在の信号制御システムの多くは、現場調査データに基づいて解析的に信号制御パラメータを設定しているという事情による。したがって、交通流の経年変化に対応するためには、定期的に現場調査と制御パラメータ調整を繰り返す必要があるが、このような作業には膨大な労力、時間、費用が要求されるため、すべての交差点で実施することは極めて困難である。


前述したように、光ビーコンの利点は、制御の実行によってリンク旅行時間などの効率性を示す指標がどのように変化したかをリアルタイムで把握することができることである。そこで、システムが実行した制御内容(信号制御パラメータの設定値)と制御実行に伴う交通流の変化情報を自動的に収集できることに着目し、両者の関連性をシステム自身に学習させることが考えられる。このような学習を最新のデータを用いて常時行い、その学習結果に基づいて、交通流計測値に応じた最適な信号制御パラメータを求めることができれば、交通流の経年変化もちろん交通流の時間変動にも自動的に追従できる適応型の信号制御システムが実現できることが期待される。

以上の考え方に基づく信号制御は、過去に中辻ら²⁾によって研究されている。これらの研究では、信号制御パラメータと交通量を入力値とし、待ち行列長やマクロシミュレーション TRANSYT から得られる評価指標(Performance Index)を出力とするニューラルネットワークモデルを構築している。中辻らは、簡単な構造をもつモデルに対して、主として学習方法、最適化方法について考察している。しかしながら、光ビーコン情報を用いることは全く想定しておらず、実用化の観点からの検討は十分にされていない。なお、光ビーコン情報を直接的に利用した信号制御に関しては、光ビーコン情報から得られる飽和交通量、飽和度、遅れ時間を用いてサイクルとスプリットを調整する方法を示した研究³⁾があるが、この研究は光ビーコン情報を感応制御に応用したものであり、ここで考えている学習型の適応制御とは根本的に異なる。

(2) ニューラルネットワークモデルによる推定

まず、信号制御パラメータ及び交通流データと光ビーコンによって得られるリンク旅行時間の関連性をニューラルネットワークを用いて学習させることを試みる。

図一八に模式図で示したような街路網を考えこれを基本街路網として位置付ける。マルで囲ったものが交差点で中の数値は当該交差点番号のである。ま



図一8 基本街路網

た矢線で示したものは街路区間で付されている数値はその街路区間番号を表している。

ここでは交差点2から交差点3に向かう交通が被る平均旅行時間をニューラルネットワークの出力として推定するモデルを考えるが、基本街路網に対する当該区間交通の旅行時間推定モデルが完成すれば、その適切な組み合わせによって一般的街路網に対応できることから、制御における有用性はかなり高いものとなる。

モデルに用いる入力値の候補としては次のようなものを考える。まず、信号制御パラメータとして交差点2及び3の西行き方向の青信号時間、交差点2に対する交差点3のオフセットの3変数を採用する。交通状態を表す変数としては交差点3の西行き交通量、交差点2の西行き交通量、交差点2の南行き交通量、交差点2の北行き交通量並びに交差点3の西行き交通に対する流入部の混雑状況の5変数を考える。最後に示した交差点3の西行き交通に対する流入部の混雑状況であるが、他の交通量4変数が全く同じであったとしても、混雑状況が異なれば旅行時間にも大きな開きがあるのでという事実を考慮して導入したものである。具体的変数としては、光ビーコンから得られるアップリンク情報を利用することを考えるが、今回の研究が交差点信号パラメータの時々刻々の適応的設定に主眼を置いていることを意識し、制御対象時間帯の直前に入手できる旅行時間を利用する。具体的に本研究では特に1周期ごとの制御を想定することとして、当該周期の1周期前の交差点間平均旅行時間を、混雑状況を表す変数として採用する。言うまでもなくこの変数は推定対象である交差点2、3間の旅行時間とはかなり強い相関を有するであろうことが容易に推量できるが、我々の究極的に目標としているものは信号の適応的制御であって旅行時間の推定はそのための手段に過ぎない。したがって、平均旅行時間推定はその説明変数に決定変数としての信号パラメータを含むことが必要要

件となるのである。

なお、交通量として推定する旅行時間に直接関与する交差点3西行き交通量以外に上流側交差点の3方向からの流入交通量を考えているが、これは例えば交差点2の北行き交通の左折率が卓越しているようなときに交差点2から3へ向かう車群パターンがかなり影響を受けることが予想されるので、こうした特殊条件のもとでも良好な推定を可能とするモデル構築を目指しているからである。


最終的には一般的街路網に適用することを想定しているので、ニューラルネットワークの構造はできるだけシンプルなもの望ましい。そこで今回は3層構造のものを考えた。まず入力層であるが、上記の入力変数をすべて採用する場合には、ニューロン数は8個となる。一方、出力は旅行時間のみであるから出力層ニューロンは必然的に一つである。中間層ニューロンについては、出力の精度と計算時間を考慮して試行錯誤的に決定する必要がある。

(3) ウェーブレットニューロンモデルによる推定

a) ウェーブレットニューロン⁴⁾

ウェーブレットニューロンは非線形のシナプスを持ち、ニューロン出力はそれら非線形シナプスの出力を加算するのみの単純な構造である。 j 番目のニューロンの入力値を x_j ($j=1,2,\dots,M$)、 j 番目のニューロンからの出力を f_j ($j=1,2,\dots,M$)、出力値を \hat{d} としたときのウェーブレットニューロンのアーキテクチャを図一9に示す。

各ウェーブレットシナプスでは、次式で表される特定の入力空間のみで定義されるコンパクトな“台”を持つウェーブレット関数を考える。これにより、計算領域がある特定の“台”の範囲に限られ大幅に計算量が削減できる。



図一9 ウェーブレットニューロンのアーキテクチャ

$$\psi(x) = \begin{cases} \cos x & (-0.5 \leq x \leq 0.5) \\ 0 & (x < -0.5, 0.5 < x) \end{cases} \quad (2.4)$$

また、ウェーブレットは次式のものを用いる。

$$\psi_{a,b}(x) = \psi(ax - b) \quad (2.5)$$

よって j 番目のウェーブレットシナプスは **図-10** の

ようになる。ただし $\theta_{a,b}^j$ は重み係数である。ここで式

(2.5)からわかるように、ある特定のウェーブレットは、入力がある特定の範囲内の時のみ値を持つ。その他の場合は0であるので、対応する重み係数の学習は行われな。したがって、学習時間の格段の短縮が期待できる。

b) 旅行時間推定方法

ウェーブレットニューロンに対する入出力はニューラルネットワークと同じであるが、ウェーブレットニューロンについてはあまり普遍的に知られてはいないので本研究では若干説明をしておくことにする。いま学習用データが T 組あるとき、 t 組目のデータにおける j 番目ニューロンの入力値を $x_j(t)$ とし、基底の深さを n 、 j 番目のニューロンにおけるウェーブレット

$\psi_{a,b}(x_j(t))$ の重み係数を $\theta_{a,b}^j$ とすると t 組目のデータに対するニューロンの出力は

$$f_j(x_j(t)) = \sum_{a=0}^n \sum_{b=0}^a \theta_{a,b}^j \psi_{a,b}(x_j(t)) \quad (j=1,2,\dots,M) \quad (2.6)$$

となる。しかし、ウェーブレットは式(2.4)のものを用いたので、ある入力に対して、各々の基底 a で用いるウェーブレットはひとつだけである。 x の整数部分を $INT(x)$ とすると、各ニューロン出力は以下のように求められる。




図-10 ウェーブレットシナプス

$$f_j(x_j(t)) = \sum_{a=0}^n \theta_{a,b}^j \psi_{a,b}(x_j(t)) \quad (2.7)$$

$$b = INT(a \cdot x_j(t) + 0.5) \quad (2.8)$$

これにより、計算の格段の短縮を可能にしている。

出力である遅れ時間の教師データである旅行時間 $d(t)$ の推定値 $\hat{d}(t)$ は式(2.6)または式(2.7)を足し合わせることで求められる。

$$\hat{d}(t) = \sum_{j=1}^M f_j(x_j(t)) \quad (2.9)$$

ここで求められた推定値は実際の値 $d(t)$ とは一致していない。そこでニューラルネットワークと同様、 $d(t)$ と

その推定値 $\hat{d}(t)$ の誤差を減少させる方向へ結合係数を調整する。

t 組目のデータに対する修正を行なう場合、エネルギー関数としては

$$E = \frac{1}{2} \{d(t) - \hat{d}(t)\}^2 \quad (2.10)$$

を用いる。これを最小にするように重み係数 $\theta_{a,b}$ を調整していく。 $x_j(t)$ を入力した時の $\theta_{a,b}$ の修正量 $\Delta\theta_{a,b}$ は次式であらあされる。

$$\Delta\theta_{a,b}^j = \alpha \varepsilon \frac{\partial E}{\partial \theta_{a,b}^j} = -\alpha \varepsilon \{d(t) - \hat{d}(t)\} \psi_{a,b}(x_j(t)) \quad (2.11)$$

ただし

$$\alpha = \frac{1}{M \cdot n} \quad (2.12)$$

ここで ε は学習係数である。 α を式 (2.12) とおくのは、ある特定の入力値に対して過大な重み係数の修正を防ぐためである。これにより学習がスムーズに進む。結合係数の修正方法としては、ニューラルネットワークモデルと同様に、モーメント法及び修正モーメント法あるいは一括修正法が考えられる。

(4) 有効性の検証

a) シミュレーション及びデータ

有効性の検証にあたっては NETSIM によるシミュレーションから得られるデータを用いて行った。NETSIM は、米国連邦道路局の支援を受けて開発されたタイム・スキニング型のマイクロ・シミュレーションモデルである。このモデルは、主として交通管理対策の評価用として開発されたもので、車線変更、交差点における対向直進車の間隔を利用した右折、横断歩

行者の影響、駐車車両の影響、交通現象のほとんどを再現することができる。NETSIM は現在、米国の他、多くの国で実務・研究の両面で広範に使われており、わが国でも研究ベースで用いられている。

次に、シミュレーション実行条件について示す。各交差点及び、各リンク(方向を考慮した道路区間)の番号は、**図-8**に示す通りとする。車は、外部から流入する12本のリンク(1、4、7、10、リンク13~20)において、停止線から500m上流部の地点で与えられた変動パターンに従って発生する。発生パターンは2分間隔で変化し、これを1周期として合計19周期(38分間)がシミュレーションされる。最初の流入交通量はピーク時の約5割とし、少なめで、徐々に多くなって行き、10周期目から一定で比較的多い交通量となり、18分間繰り返されるようにした。初期段階での交通量では比較的スムーズな交通流が生まれるように設定されており、徐々に交通量を増やす事で交通流に変化を与える。そして、10周期目からの18分間では比較的多い交通量を一定値で与える事で、渋滞を生み出す事とした。

発生車両の車種は乗用車100%とし、自由走行速度はすべてのリンクで50km/時に設定した。また、各交差点流入部の右左折直進率は直進85%、左折10%、右折5%のように設定し、停止線からの流出する際の平均車頭時間は2秒(飽和交通流率1800台/青1時間に相当)とした。なお、内部リンク(リンク2、3、5、6、8、9、11、12)の途中で発生吸収する交通量(細街路や駐車場等から流入、流出する交通量)、及び交差点における横断歩行者は無いものとした。

各交差点の信号現示パターンは**図-11**に示す4つである。各交差点の間隔は300mとなっており、光ビーコンは交差点2に流入してくる道路の280m先と、交差点2から交差点3に向かい、手前側20mの地点に設置してあるものとした。

遅れ時間を推定するニューロモデルの学習のためにはさまざまな信号制御パターンにおける交通流のデータが必要となる。本研究では、信号の共通周期を120秒とし、交差点1、交差点4、交差点5の信号スプリット等については固定して考えた。

交差点2、交差点3の信号スプリット及び交差点3の交差点2に対するオフセットをさまざまな値に変化させ合計403の信号制御パターンについてシミュレーションを行なった。ひとつの信号制御パターンにつき38分間、つまり19周期分のシミュレーションを行なうが、1周期前の旅行時間を入力変数として用いることから得られるデータセットの数は

$$\begin{aligned} & \text{信号制御パターン} \times (\text{周期の数} - 1) \\ & = 403 \times (19 - 1) \\ & = 7254 \end{aligned}$$

となる。これをランダムに並べ替えたものを最終的に学習・検証用データとしたが、学習用とし全体の約半数の4000組を用い残りを検証用とした。

b)適用性の検討

予備的検討の結果、ニューラルネットワークモデルの中間層ニューロン数は20、ウエーブレットニューロンの深さを表すNは30として設定した。なお、学習完了の条件としては平方根二乗誤差(以下RMSE)が0.03に達した時点とした。

図-12及び**図-13**はそれぞれニューラルネットワークモデル(以下NNモデル)とウエーブレットニューロンモデル(以下WVモデル)の学習結果を繰り返し回数200の範囲で示している。入力として光ビーコン情報から得られる1周期前の旅行時間を使用した場合と使用しない場合について示しているが、不使用の場合双方のモデル共に1000回の繰り返し回数でも目標としたRMSE0.03には遠く届かなかったが、光ビーコン情報使用の場合、0.03に到達した繰り返し回数はNNモデルで約800回、WVモデルで約30回で計算時間(CPU833MHz,メモリ512MBのパソコン使用)は前者で15分50秒、後方で15秒となった。

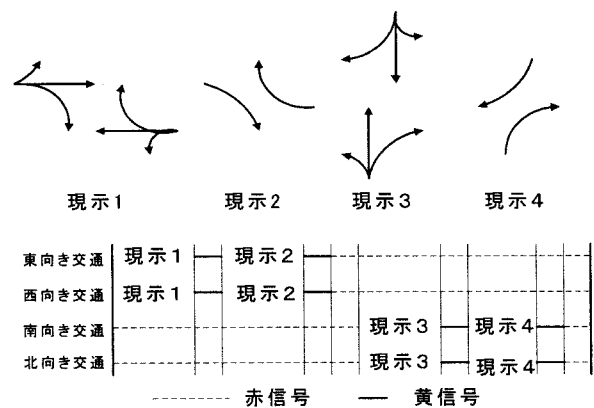


図-11 信号現示パターン




図-12 ニューラルネットワークモデルの学習結果




図-13 ウェブレットニューロンモデルの学習結果

学習済みのモデルに検証用のデータ(3254組)を入力した計算結果を相関図の形で図-14~図-17に示した。なお、検証のために利用したモデル係数は200回の収束計算終了時点のものを採用している。図の標題で真値と書いたのはシミュレーションから得られた平均旅行時間でありグラフの縦軸にはシミュレーション出力値として記しておいた。

まず光ビーコン情報使用の場合、図-14及び図-16を見れば分かる通り、提案した二つのモデル間に大きな差異はなく、双方ともある程度妥当な推定をなし得ていると言える。因みに図-14の場合RMSEは0.0329、相関係数は0.976であり、図-16の場合はRMSE0.0285、相関係数0.983となっている。しかしながら、光ビーコン情報を使用しない場合には、推定値とシミュレーション出力値との乖離は大きくなりNNモデルではRMSEが0.0932、相関係数が0.791、WVモデルではRMSEが0.1008、相関係数が0.767となる。このようにして、光ビーコンからのアップリンク情報を信号制御システムの中に組み込むことは極めて有効であることが分かる。

状態量としてのモデル入力値として、交通量と1周期前の旅行時間を用いているが、これらは実際の制御においては誤差を含むことになる。すなわち、交通量は予測値としての誤差は不可避であるし、1周期前の平均旅行時間であっても前章で検討したように、車載機搭載率等の要因によって誤差の混入は避けられない。したがって、我々は状態量を表すこれらの入力値を期待値とした正規乱数を発生させ、それを新たな入力値とした場合についてもモデルの検証を行うことにした。誤差の程度は変動係数で間接的に表すものとし、変動係数5%~30%の範囲で実験を行った。

表-2はその結果を纏めたものであるが、表中の数値はすべて5回の実験(つまり学習用データと検証用データをランダムに選ぶ操作を5回行った)結果の平均値である。まず光ビーコン情報使用の場合であるが、NNモデルに比べWVモデルの方が入力誤差に対す




図-14 NNモデルによる推定値と真値(光ビーコン情報使用)




図-15 NNモデルによる推定値と真値(光ビーコン情報非使用)




図-16 WVモデルによる推定値と真値(光ビーコン情報使用)

る精度劣化速度が若干早い傾向があることが窺われる。光ビーコン情報非使用の場合は逆にWVモデルの方の劣化速度が遅くなっているものの、双方のモデルともに推定精度は極めて悪い。図-18、図-19は表-2の変動係数20%に対する結果を図-14、図-16に対応させて作成した相関図であるが、光ビーコン情報使用のケースでも推定値は真値にたいして大きくばらついている。しかしながら図-18、19の結果は図-15、17の結果よりそれぞれ良好であって、光




図-17 WVモデルによる推定値と真値（光ビーコン情報非使用）




図-18 入力ノイズを考慮したNNモデルによる推定値と真値（光ビーコン情報使用）

ビーコン情報がいかに効果的の情報たり得るかが分かる。上に示した図-14～図-19ならびに表-2は信号制御の目標となる交差点2、3間の平均旅行時間のモデルによる推定値がシミュレーションから得られた値をどの程度近似するかについて、それぞれグラフと数値指標で示したものであるが、研究の最終的に目指しているものは旅行時間を的確に推定することではなく、信号制御パラメータをどのような値に設定すれば、制御目標値である旅行時間を可及的に減少させられるかということである。こうした視点から考えると、旅行時間そのものの推定精度が重要であることについては言を俟たないものの、それと併せて決定変数である制御パラメータと旅行時間の関係がうまく同定されているか否かを見極めることが不可欠である。したがって、以下では学習済みのモデルが、交差点2、3間のオフセットならびに交差点2と交差点3の西行き方向の青信号時間（これらは基本街路網で制御パラメータとして位置づけている）の変化に対応した両交差点間の旅行時間の変化を的確に表現し得ているか否かについて調べてみる。

既に述べたように、データを得るために本研究で採択したNETSIMでは、与えられた一組の制御パラメータが固定され、交通量のみが毎周期変化してゆくという形で19周期（38分間）分のシミュレーションが実行される。そしてわれわれはそのうちの18周期分の




図-19 入力ノイズを考慮したWVモデルによる推定値と真値（光ビーコン情報使用）

結果を実際の計算に用いている。そこで一つの制御パラメータに対する旅行時間の値としては18周期の総旅行時間を対応させてグラフ上にプロットし、推定値とシミュレーションの結果の変化の状況を見てみることにした。総旅行時間を用いることで交差点間交通量も間接的に評価する利点がある。なお、入力値に対するノイズの混入言い換えれば誤差の混入は不可避という観点から、敢えて表-2の変動係数20%に対する結果を用いる。

図-20、図-21は交差点2、3間のオフセットと総

表-2 入力値にノイズがある場合の適用性

変動係数 (%)	光ビーコン情報使用				光ビーコン情報非使用			
	NNモデル		WVモデル		NNモデル		WVモデル	
	RMSE	ρ	RMSE	ρ	RMSE	ρ	RMSE	ρ
0	0.0345	0.9775	0.03005	0.9806	0.09439	0.80526	0.09952	0.76734
5	0.03652	0.97442	0.03591	0.9723	0.09655	0.7959	0.10544	0.73756
10	0.04207	0.96502	0.04389	0.95884	0.10293	0.76804	0.11074	0.71336
15	0.05002	0.9496	0.05193	0.94326	0.11165	0.73254	0.11516	0.69468
20	0.05797	0.93234	0.0597	0.9266	0.12193	0.69584	0.11747	0.68446
25	0.06781	0.9079	0.06894	0.90376	0.13293	0.66078	0.11901	0.67564
30	0.07698	0.8827	0.07877	0.87832	0.14662	0.6243	0.12033	0.6687

注) RMSE: 平方根平均二乗誤差 ρ : 相関係数

旅行時間の関係の同定結果をプロットしたものであるが、前者は光ビーコン情報使用時のもの、後者は非使用時のものである。図中の太線(凡例で SIM として表記)で示したものはシミュレーション結果であり、実線と破線で示したものは各モデルの推定結果である。光ビーコンを通して得られるアップリンク情報を使用した場合にはモデルによる推定値はかなりの確に真値に追従してオフセット値に応じた変化傾向を見せていると思われるが(図-20)、光ビーコン情報を使用しない場合には推定値と真値の間には無視できない乖離が見られる(図-21)。

同様に、光ビーコン情報を使用した場合と使用しない場合に分けて交差点3の西行き方向の青信号時間と総旅行時間の関係の同定結果を見てみると図-22、図-23のようになった。上述のオフセットの場合と同じように、光ビーコン情報使用時には注目している街路区間の下流端交差点における青信号時間の変化に対して逆比例的に大きく変わる当該区間総旅行時間の増減傾向は、提案した二つのニューロモデルによってほぼ満足し得る水準で推定できている(図-22)。

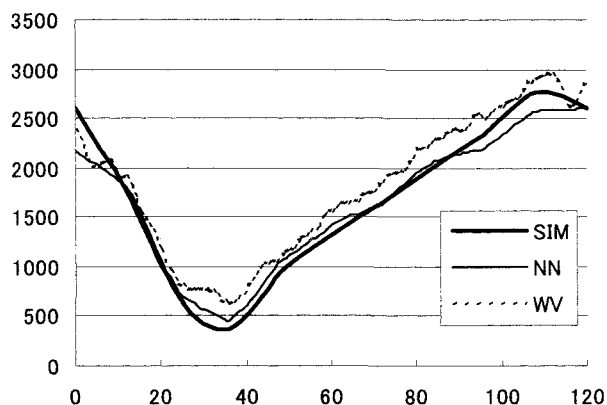


図-20 交差点2、3間のオフセットと総旅行時間の関係の同定結果(光ビーコン情報使用)




図-21 交差点2、3間のオフセットと総旅行時間の関係の同定結果(光ビーコン情報非使用)

光ビーコン情報を使用しない場合については、青時間の長さが短い40秒以下の領域での推定誤差拡大が見られ、特にその傾向はWVモデルによる推定結果で顕著である(図-23)。

なお、交差点2の西行き方向青信号時間の長さと同定結果の関係を示すグラフは紙面の都合上割愛する。結果を簡単に纏めておくと、まず光ビーコン使用時には、総旅行時間が交差点2の青信号時間にあまり影響を受けずほぼ横軸に並行して推移するというシミュレーション結果はモデルによっても十分に表される。一方、光ビーコン情報非使用時には、変化が少ないということもあってか交差点2の青信号時間と総旅行時間の間の関係はNNモデルでは光ビーコン使用時と遜色ない形で同定がなされるが、WVモデルでは推定値に若干の乱れが出る。

以上、ニューロモデルによって交差点間の平均旅行時間を推定する方法の適用性について、NETSIMによるシミュレーション結果を用いて検証したが、ここで得られた結論は図-10に示した基本街路網に対するものであって普遍性が保証されるものではない。すなわ




図-22 交差点3の青時間と総旅行時間の関係の同定結果(光ビーコン情報使用)




図-23 交差点3の青時間と総旅行時間の関係の同定結果(光ビーコン情報非使用)

ち、注目する交差点2, 3間のリンク長は300mであり交通条件についてもa)に記した特定条件に限定している。したがって、今後様々な街路網の諸元ならびに交通条件について検討しより一般性がある結論を抽出して行く必要がある。

(5)光ビーコン情報を利用した信号制御システムの枠組み

以上より、光ビーコンによりリアルタイムで測定される旅行時間データを適切に利用することで、信号制御パラメータをどのように設定すれば旅行時間がどのように変化するかということが予め把握できる見通しがついたと言える。本項ではそれを踏まえた適応型信号制御システムの枠組みを示しておく。

システムは制御実行プロセスと学習、最適化プロセスから構成される。制御実行プロセスでは与えられた交通流データをもとに決定された信号制御パラメータを実装し制御を実行する。因みに現行の信号制御システムはいわばこの制御実行プロセスのみで稼動しており信号制御パラメータの設定はパターン選択方式に代表されるように人力に多くを頼っている。これに対して光ビーコンを利用した適応型システムでは、測定された交通流データと設定された制御パラメータ、そして制御実行の結果として光ビーコンにより計測される旅行時間データを常時蓄積し、信号制御パラメータ及び交通流データと旅行時間の関係を基本街路網ごとに学習・更新する。学習は例えば適応的制御の必要が無い夜間閑散時等に毎日行えば良いが、交通状況が変化しやすい箇所では頻繁に、交通状況が殆ど変化しないような箇所では間隔を置いて定期的に実行するという代替法も考えられる。

学習済みニューロネットワークが準備されると、それを使って信号制御パラメータの最適化を行うが、計算は基本街路網ごとに誤差逆伝播方式で実行し、決定変数すなわち信号制御パラメータに対応する入力値の修正量を各基本街路網から得られる値の合計値として与えるという単純な収束計算メカニズムに従えばよい⁵⁾。つまり最適化は結合係数の学習に比しより迅速にその計算がなされることが期待されるのであり、予想としては短時間先の信号制御パラメータを交通状態に応じて刻々と適切な値に設定することができる可能性がある。

4. むすび

本研究では光ビーコン情報から得られる旅行時間の利用性について若干の基礎的な検討を行った。主要結果のみを簡潔に纏めておくと

- ① 双方向通信を可能とする車載機搭載率 20%以下では搭載率の増加による誤差率減少割合は大きい。

- ② 旅行時間集計時間が15分程度であるならば、車載機搭載車の平均旅行時間を全車両の平均旅行時間としたときの推定精度は交通量によってあまり影響されない。
- ③ 平均旅行時間推定のため NN モデルと WV モデルを構築したが、学習速度の点では後者は圧倒的に前者を凌駕する。しかし、推定性能に関しては両者間に有意な差はなく、入力誤差の影響は後者が若干受け易い。
- ④ 光ビーコン情報である過去の旅行時間自身をモデルの入力とすることは旅行時間推定性能向上の点で大きく貢献する。
- ⑤ 提案2モデルによる信号制御パラメータ(オフセット値と青信号時間)と総旅行時間の関係同定は入力値に誤差が含まれるとしてもほぼ満足し得る水準でなされる。

今後は種々の基本街路網諸元に対して、入力ノイズに頑健性を持った旅行時間推定モデルのさらなる改善を図るとともに、得られたモデルを利用した最適信号制御パラメータ設定方法を実験的に検証してゆく必要がある。なお、本研究は学術振興会科学研究費補助金(基盤研究(C))の助成のもとになされた。

参考文献

- 1)Hidas,P.: A car following for urban traffic simulation, Traffic Engineering and Control,pp.300-305,1998.
- 2) 中辻他: ニューラルネットワークモデルの交通制御システムへの適用について、交通科学、Vol.21, No.1, pp.5-19,1991.
- 3)Massart,M. et al: Traffic signal control based on travel time information from beacons, Proc.of the 2nd world congress on ITS, pp.30-35, Yokohama, 1995.
- 4)日本ファジィ学会編: ファジィ・ニューラルシステム、日刊工業新聞社、pp.17-22, 1995.
- 5)矢川元基: ニューラルネットワーク、培風館、pp.17-31,1992.

(2005.5.20 受付)