

ニューラルネットワークを用いた信号制御の自動最適化*

Optimization of Signal Control Using Neural Networks

三井達郎**・奥谷 巖***

By Tatsuro MITSUI**・Iwao OKUTANI***

1. はじめに

現在、信号制御パラメータの設定は、制御方式の如何にかかわらず、まず、交通量、飽和交通量等に関する現場調査データに基づいて基本値を設定し、次にこの基本値を現場の交通状況に合わせて試行錯誤的に調整するという方法で行われる。この方法では、人による現場調査や人による制御パラメータ調整作業が不可欠であるが、現実には費用・労力等の問題から必ずしも十分な現場調査等が行われているわけではない。実際の道路上には、信号制御が交通状況に合致していない交差点が少なからず存在するが、これは、パラメータ設定に人的作業が介在していることが1つの理由と言える。

そこで、本研究では、人の関与を極力少なくした新しい信号制御システムについて検討する。具体的には、信号機新設時に、初期パラメータを現場調査結果によらず適当に定めても、しばらく時間が経過するとその地点の交通状況に合致した最適制御が自動的に達成されるような信号制御システムについて検討する。この制御システムは光ビーコン情報の活用を前提としている。光ビーコンとは、車載機搭載車との双方向通信によってビーコン間旅行時間等の情報を収集する装置で、平成13年度末現在、全国で約3万基整備されている。これら光ビーコンの情報をを用いることにより、制御の実行が遅れ時間にどのような影響を及ぼしたかを直接測定ができる。

本研究では、光ビーコンによって測定される実測遅れ時間、信号制御パラメータ、交差点流入交通流の関係をニューラルネットワークに学習させ、学習済みのネットワークを用いて制御パラメータを自動的に最適化する信号制御システムについて検討を行うことを目的とする。

ニューラルネットワークを用いた信号制御については、過去に中辻ら¹⁾によって行われている。この研究では、スプリットと交通量を入力、待ち行列長等を出力とするニューラルネットワークモデルを構築

*キーワード：交通制御，交通管理，ITS

**正員，博（工），科学警察研究所交通規制研究室
（千葉県柏市柏の葉5-2-11，TEL 0471-35-8001）

***正員，工博，信州大学工学部社会開発工学科
（長野県長野市若里4-17-1，TEL 026-226-4101）

し、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、学習・最適化に必要なデータの実場面での収集方法や計算時間短縮のためのニューラルネットワーク規模の縮小化については言及されておらず、基礎的な検討に留まっている。本研究では、整備が進みつつある光ビーコンの利用を想定し、かつ、小規模ニューラルネットワークの結合という新しい考え方を導入することにより、実用化を視野に入れた信号制御システムの検討を行う。

2. 信号制御の考え方

本研究で検討する信号制御システムの全体像を図1に示す。システムは、時間的に並列して進行する学習プロセスと制御実行プロセスから構成される。

学習プロセスでは、まず、交差点流入部に設置された車両感知器・光ビーコンによって測定された交通流データ、実際に実行された信号制御パラメータ、そして、光ビーコンによって収集される制御実行の結果としての遅れ時間データを常時蓄積する。次に、蓄積データを用いて、信号制御パラメータ及び交通流データと遅れ時間の関連性をニューラルネットワークに学習させる。すなわち、信号制御パラメータと交通流データを入力すれば、それに応じた1台当たり平均遅れ時間が出力されるようなニューラルネットワークを構築しておく。学習頻度は、交通状況が変化しやすい箇所であれば頻繁に行う必要があるし、交通状況がほとんど変化しない箇所では数カ月に1回定期的に行っても良い。

一方、制御実行プロセスでは、まず、車両感知器・光ビーコンによって流入交通流を測定する。続いて、学習済みのニューラルネットワークを用いて信号制御パラメータの最適化を行う。具体的には、測定した交通流データを入力し、出力値である1台当たりの平均旅行時間を最小とするような信号制御パラメータを求める。そして、最適化したパラメータで実際の制御を行う。制御実行後、制御の結果として得られる遅れ時間データを交通流データと信号制御パラメータとともに再び蓄積する。制御実行プロセスを短い時間間隔で反復することにより、交通流の変動に対応した適応型信号制御が可能となる。

このシステムでは、ニューラルネットワークは、




図 1 信号制御の全体像

最新のデータを用いて定期的に更新される（学習プロセス）したがって、交通流の経年変化の影響はニューラルネットワークに自動的に反映され、常に現実の交通状況に合致した最適な適応型信号制御が実現できるという仕組みである。ただし、システム導入時など蓄積データが不十分な場合は、システム稼働の準備期間を設け、この間に通常のパターン選択制御などによって学習用データを蓄積しておくことが必要となる。

以下では、単独交差点のスプリット制御を対象として、ニューラルネットワークによるスプリット自動最適化手法の具体的内容について述べる。なお、本研究では、車載機搭載車の割合が高く、1 周期毎の平均遅れ時間は正確に測定されるものと仮定して論を進める。また、検討にはシミュレーションで作成したデータを用いる。

3．単独交差点でのスプリット制御

図 2 に制御対象交差点を示す。各道路区間の上流端には光ビーコンが設置されており、各光ビーコンの下を通過する車の車両 ID および通過時刻が測定できるものとする。また、制御対象交差点の信号周期、隣接交差点とのオフセットは一定とし、対象交差点の現示は通常の 2 現示とする。以上の条件の基でスプリット制御を考える。

（1）ニューラルネットワークの学習

交差点の流入部ごとに構築したニューラルネットワークを基本単位し（図 3）この基本単位を結合することで交差点全体の遅れ最小化制御を実現する。学習を行う基本ネットワークを小規模とすることにより、学習効率を大幅に改善することができる。

具体的ネットワークの構造は 3 層型ネットワークとした。入力層ユニットは、対象流入部に表示され

る青時間、短時間間隔(例えば 10 秒)で測定した交




図 2 制御対象交差点




図 3 ニューラルネットワークの基本単位

表 1 入力層のユニット

ユニット No.	入力値
1	流入部に表示される青時間
2	光ビーコンを時間間隔 0-10秒間に通過した流入車台数
3	光ビーコンを時間間隔 10-20秒間に通過した流入車台数
⋮	⋮
11	光ビーコンを時間間隔 90-100秒間に通過した流入車台数
12	直前の 1 周期で生じる 1 台当たり平均遅れ時間

差点への流入台数、直前の 1 周期に生じる 1 台当たり遅れ時間である。周期 100 秒、流入台数測定間隔 10 秒としたときの入力値を表 1 に示す。表中のユニット 2～11 は、図 3 に示す光ビーコン設置位置で測定した交差点への流入パターンを示す。遅れ時間は単に交通量だけでなく交差点への車の到着のしかたによっても影響をうけることから、これらのユニットを設定した。また、ユニット 12 は、交差点流入部の混雑状況を示す指標である。このユニットを設定した理由は、流入部上流端で測定した流入パターンが同じでも交差点付近の混雑状況によって遅れ時間が影響を受けることが考えられるためである。なお、出力値は、当該流入部で発生する 1 台当たり平均遅

れ時間とした。

学習は、シミュレーション (Hidas²⁾ の追従式を採用した離散モデル) で得たデータを用いて行った。シミュレーションは、図 2 の流入部 1 を対象に実施した。L1、L2 はそれぞれ 300m, 280m に設定し、周期は 100 秒とした。流入パターンおよび青時間を周期ごとに様々に変化させ、周期ごとに 1 台あたり平均遅れ時間を求めた。そして合計 3060 周期分の入力値と出力値のデータセットを得た。次に、これらのデータセットを用いてニューラルネットワークの学習を行った。ここで、入力層のユニットは表 1 のとおりとし、中間層のユニット数は 40 とした。ニューロンの出力特性を定めるユニットの応答関数はシグモイド関数を用い、結合係数の修正方法は、モーメント法を用いた。

学習済みのニューラルネットワークで推定した遅れ時間とシミュレーションによる遅れ時間の相関係数は、0.9936 と高い値が得られた。よって、表 1 のように入力ユニットを設定することにより、入力値と、出力である平均遅れ時間の関係を比較的正確に学習できると言える。

(2) ネットワークの結合

流入部ごとに学習させたニューラルネットワークを図 4 のように結合する。同図で NN_i は流入部 i についてのニューラルネットワーク、 G_h は制御対象交差点の水平方向青時間、 G_v は垂直方向青時間である。また、 Q_i は、流入部 i における流入パターン等の入力値 (表 1 のユニット 2 ~ 12 に相当)

d_i は流入部 i の一台あたり遅れ時間である。結合したニューラルネットワーク NN_0 は、 G_h 、 G_v および Q_i ($i=1 \sim 4$) を入力すれば、各流入部の一台中たり平均遅れ時間が出力されるものである。




図4 ネットワークの結合

(3) スプリットの最適化

NN_0 を用いて Q_i が与えられたという条件下で G_h 、 G_v を最適化する。最適化の評価関数は式(1)のように設定する。

$$D = \sum (q_i \times d_i) / \sum q_i \quad (i=1 \sim 4) \quad (1)$$

式(1)で q_i は、流入部 i の交通量である。 q_i は一般に

周期毎に変化するが、スプリットの最適化を行おうとする時間帯の平均的な値を用いることにより、 D は近似的に交差点全体としての 1 台あたり平均遅れ時間を表すと考えられる。

評価関数 D の最小化は、評価関数値そのものを出力層における誤差信号と考え、結合係数を固定した状態で誤差信号を入力方向へと逆伝播させその結果に基づいて G_h 、 G_v を修正することで達成される³⁾。そして、最小の出力値 D が得られるような G_h 、 G_v が最適スプリットとなる。 G_h と G_v の修正にあたっては、 G_h と G_v 間の関連性、すなわち入力値間の関連性を考慮する必要がある。一般に、入力値相互間に関連性がある場合は、その関連性を表現する付加的なニューラルネットワークを NN_0 に組み込み、入力値相互間の制約条件を保持した状態で入力値を修正することが必要である。しかしながら、本研究で検討対象としている 2 現示のスプリット制御では、 G_h と G_v は、次式のような単純な関係式で表される。

$$G_h + G_v = C - L \quad (2)$$

上式で、 C は周期、 L は 1 周期当たりのロス時間である。したがって、誤差の逆伝播によって得られる G_h の修正量 ΔG_h 、 G_v の修正量 ΔG_v の間には、次式の関係がある。

$$\Delta G_h = - \Delta G_v \quad (3)$$

式(3)が成立することから、式(2)の制約条件をニューラルネットワークに組み込む必要はなく、 $Q_1 \sim Q_4$ が与えられたときのスプリット最適化の手順は以下のようになる。

手順 1: G_h 、 G_v の初期値を式(2)を満足するように適当に設定する。そして G_h 、 G_v を出力層へ順伝播し、 $d_1 \sim d_4$ を求める。

手順 2: d_i を誤差信号をみなし、結合係数を固定して誤差逆伝播を行う。

手順 3: ΔG_h^{NN1} 、 ΔG_h^{NN3} を、それぞれ $NN1$ 、 $NN3$ の誤差逆伝播によって得られる ΔG_h の修正量、 ΔG_v^{NN2} 、 ΔG_v^{NN4} を、それぞれ $NN2$ 、 $NN4$ の誤差逆伝播によって得られる ΔG_v の修正量とする。式(3)の関係を考慮すれば、 ΔG_h の修正量は、式(4)のように表される ($i=1 \sim 4$)

$$\Delta G_h = (q_1 / \sum q_i) \Delta G_h^{NN1} - (q_2 / \sum q_i) \Delta G_v^{NN2} + (q_3 / \sum q_i) \Delta G_h^{NN3} - (q_4 / \sum q_i) \Delta G_v^{NN4} \quad (4)$$

$\Delta G_h < \varepsilon$ (ε は十分小さな正数) なら最適化終了。この時点での G_h 、 G_v が最適スプリットとなる。

$G_h \geq \varepsilon$ なら(4)式を用いて、次式のように修正する。

$$G_h \leftarrow (G_h - \Delta G_h) \quad (5)$$

G_v の修正値は、 G_h の修正値を用いて式(2)から求める。

手順 4: 修正された G_h 、 G_v を出力層へ順伝播し d_i

を更新する。手順2へもどる。

4. シミュレーションによる制御実験

本研究で考案したスプリット自動最適化法の妥当性を検証するためシミュレーションによる制御実験を行った。制御対象交差点は、図2に示す交差点とし、4流入部ともに、 $L1=300\text{m}$ 、 $L2=280\text{m}$ とした。周期 $C=100$ 秒、1周期当たりのロス時間=10秒に設定し、50周期分の制御を行った。NN1~NN4(図4参照)は、いずれも3(1)で学習させた同一のニューラルネットワークを用いた。なお、今回の実験では、制御途中でのニューラルネットワークの学習は行わなかった。すなわち、図1の制御実行プロセスのみに対して実験を行った。具体的制御は、以下の~を反復して行った(図5参照)。

スプリット算出時点において、光ビーコン等のデータより過去3周期分の平均的な Q_i 、 q_i ($i=1\sim4$)を求める。

得られた Q_i 、 q_i をNN0に入力し3(3)の手順で最適スプリットを求める。

求められた最適スプリットで制御を実行する。

スプリット算出時点を1周期分進める。

Q_i 、 q_i を求める際の周期数は、本来、制御の安定性と交通量変動への追従性を勘案して決める必要がある。今回の制御では、便宜的に Q_i 、 q_i ともに過去3周期分の平均的な値として設定した。

図6に制御対象期間の流入部別の交通量を示す。交通量は図2中の光ビーコンの設置位置で計測した値である。図7は、制御の実施結果である(シミュレーションが平衡状態に達するまでの時間を考慮し最初の5周期は G_h 、 G_v ともに45秒に固定)。同図より、 G_h 、 G_v は交通量の変動に対して自動的に追従していることがわかる。

5. まとめ

ニューラルネットワークを用いた新しい信号制御システムについて検討した。この信号制御システムは、信号制御パラメータの初期設定作業が従来に比べて大幅に少なくて済むこと、交通状況の経年変化に応じた定期的なパラメータ調整作業が必要ないこと等の特徴がある。光ビーコン情報の活用を前提しているが、光ビーコンに限らず、交差点における遅れ時間がなんらかの方法によってリアルタイムで測定できればシステム構築が可能である。将来交通分野へのIT機器の普及がいっそう進めば効果的な信号制御システムとして期待できると考える。

今後の課題としては、車載機搭載車の割合が低く遅れ時間を測定できる台数が限られている場合の制御方法の検討、オフセット制御など街路網の信号制

御への応用方法の検討などが挙げられる。




図5 制御方法




図6 流入交通量




図7 制御結果

参考文献

- 1) Nakatsuji, T. and Kaku, T. : Development of a self-organizing traffic control system using neural network models, Transportation Research Record 1324, pp.137 ~ 145, 1991
- 2) Hidas, P.: A car-following for urban traffic simulation, Traffic Engineering and Control, May, pp.300-305, 1998.
- 3) 矢川元基: ニューラルネットワーク 培風館
- 4) 吉田、越、安井: プローブカーを用いた交通信号のオフライン最適化に関する研究、第21回交通工学研究