

ニューロンモデルによる信号交差点の遅れ関数の同定

信州大学工学部 正会員 奥谷 巖
科学警察研究所 正会員 三井 達郎
信州大学大学院 ○ 水谷 好伸

1. はじめに

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。この光ビーコンを用いる事で、リアルタイムで走行経路、旅行時間、車種などの高度な情報を収集することが可能である。そこで、光ビーコン情報を活用し、定形、不定形または、飽和、不飽和のような交通流と、時間変動に自動的に追従できる、適応型の人工知能型信号制御システムをニューロンモデルから構築しようとした。

2. 対象街路網

図 1 に示す架空の街路網を対象とした。共通周期 120 秒とし、交差点 1, 3, 4, 5, に流入する交通量、交差点 2 と 3 のスプリットを様々に変化させてシミュレーションし、条件ごとに、光ビーコン設置位置を通過して交差点を流出するまでの 1 台当たりの平均旅行時間と遅れ時間を求めた。そして、得られたデータを学習用のデータセットとモデル検証用のデータセットにほぼ同等数になるように分け、ネットワーク構造の検討を行った。

3. ニューラルネットワークによる方法

ニューラルネットワークの入力値の内訳は、表 1 に示すように、7 個のユニットとした。NO7 の値としては、前回の周期の 120 秒間での 1 台当たりの遅れ時間である。出力値は光ビーコン設置位置を通過して交差点を流出するまでの 1 台当たりの平均旅行時間である。平均旅行時間は、信号制御の評価指標として一般に用いられている、1 台当たりの平均遅れ時間と同様な意味を持つ。

図 2 に階層数 3、中間層 20 で、修正モーメント法を用いて 1000 回繰り返し計算を行った際の、推定値とシミュレーションによる値の相関を示した。また、この時の RMSE は 0.0420 であった。推定値と教師データの相関係数は 0.964 と高い相

関がある。しかし、なかには標準残差が 2.5 を超えるものもあり、すべてのデータについて適応しているとは言えない。これは、ニューラルネットワークによる学習では変極点での近似がうまく行われなためと考えられる。




図 1：対象街路網

表 1：入力値の内訳

ユニット NO.	入力値
1	交差点 1 の現示 1 のスプリット
2	交差点 2 の現示 1 のスプリット
3	光ビーコン D 1 を時間間隔 0-30 秒間に通過した流入台数割合
4	光ビーコン D 2 を時間間隔 30-60 秒間に通過した流入台数割合
5	光ビーコン D 3 を時間間隔 60-90 秒間に通過した流入台数割合
6	光ビーコン D 4 を時間間隔 90-120 秒間に通過した流入台数割合
7	交差点 2 から交差点 3 へ向かう間の混雑状況




図 2：シミュレーションによる値と推定値の相関

4. ウェーブレットニューロンによる方法

4. 1 ウェーブレット

任意の周期関数がフーリエ級数に展開できるように、任意の非周期関数はウェーブレットに展開できる。 $\psi_{j,k}(x)$ を任意のウェーブレットとすると、

$$\psi_{j,k}(x) = 2^{j/2} \psi(2^j x - k) \quad (1)$$

となる。ここで j はスケーリングパラメータ、 k はシフティングパラメータである。ウェーブレットを用いて任意の関数 $f(x)$ は

$$f(x) = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} \theta_{j,k} \psi_{j,k}(x) \quad (2)$$

と展開できる。しかし $\theta_{j,k}$ は計算によって求めるのは極めて難しい。そこで、ニューラルネットワークのように学習によって重み係数を求める。

4. 2 ウェーブレットニューロン

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。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。

$$\psi(x) = \begin{cases} \cos x & (-0.5 \leq x \leq 0.5) \\ 0 & (x < -0.5, 0.5 < x) \end{cases} \quad (3)$$

さらに、ウェーブレットは式 (1) ではなく、次式のものを用いる。

$$\psi_{a,b}(x) = \psi(ax - b) \quad (4)$$

これらウェーブレットのうちの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い。したがって、学習時間の格段の短縮が期待できる。

学習用データが T 組あるとき、 $x_j(t)$ を t 組目のデータのユニット $N \times j$ における入力値とすると、各ニューロンの入力

$$f_j(x_j(t)) = \sum_{a=0}^n \sum_{b=0}^a \theta_{a,b}^j \psi_{a,b}(x_j(t)) \quad (5)$$

となる。ただし、 n は基底の深さである。(5) より教師データ $d(t)$ の推定値 $\hat{d}(t)$ は

$$\hat{d}(t) = \sum_{j=1}^m f_j(x_j(t)) \quad (6)$$

と表される。ただし、 m は中間層の数であり、入力層数と等しい。

(2) 式の重み係数 $\theta_{a,b}$ は出力誤差の二乗 E を最小にするように調整していく。

$$E = \frac{1}{2} \sum_{t=1}^T \{d(t) - \hat{d}(t)\}^2 \rightarrow \min \quad (7)$$

$x_j(t)$ 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。

$$\Delta\theta_{a,b}^j = -\alpha \frac{\partial E}{\partial \theta_{a,b}^j} = \alpha \sum_{t=1}^T \{d(t) - \hat{d}(t)\} \psi_{a,b}(x_j(t)) \quad (8)$$

但し、 $0 < \alpha < 1$ である。(5) 式の重み係数は次式によって更新されていく。

$$\theta_{a,b}^j = \theta_{a,b}^j + \alpha \sum_{t=1}^T \{d(t) - \hat{d}(t)\} \psi_{a,b}(x_j(t)) \quad (9)$$

ウェーブレットの重み係数が学習によって同定されると、遅れ時間の推定値 $\hat{d}(t)$ は (5) 式によって求められる。

4. 3 ウェーブレットニューロンによる係数同定

入力層はニューラルネットワークと同様に表 1 の 7 個のユニットである。また、ニューラルネットワークによる方法と同様にモーメント法、修正モーメント法についても行う。現在のところ全ての結果は出ておらず、これについては発表時に示す。

5. 終わりに

本研究では、ニューロンモデルによる信号交差点の遅れ時間関数の推定を行った。本稿ではニューラルネットワークによる推定の一部を示したが、その他の結果については、発表時に示すつもりである。

【参考文献】

- 1) 中川嘉樹 他：ファジィ・ニューラルシステム 日本ファジィ学会