

ニューラルネットワークを考慮した経路誘導情報システムに関する研究

(株) オリエンタルコンサルタンツ 正会員 ○氏島康雄

鳥取大学工学部 学生会員 都 明植

鳥取大学工学部 正会員 小林潔司

1.はじめに

本研究では、階層型ニューラルネットワーク（以下、*NN*）モデルのもつ学習能力に着目し、センサーを介して観測されるリンク内の交通情報をもとに、経路誘導のための経路走行時間を予測するメカニズムの実験的な構築を試みる。さらに、シミュレーションによって学習された*NN*モデルにおける未学習の入力データに対する汎化能力を、赤池の情報量規準(*AIC*)を用いて評価し、望ましい*NN*モデルを作成する方法について考察する。

2. 基本的枠組み

(1) 経路情報システムの設計 図1で示した交通ネットワークを考察する。公共主体は各経路上のセンサーを介して当該期首の経路交通量、および分岐点にさしかかった通過交通量を観測し、当該期に実現するであろう経路走行時間を予測する。そして、予測した結果をそのままドライバーに提示する。そこで、各ドライバーは各経路の走行時間に関して期待を形成し、それが最大になるような経路を選択する。その結果として、当該期の経路走行時間が確定する。その際、公共主体は提供した経路情報と実現した経路走行時間を比較することで、予測モデルのパラメータを更新する。このような手順を繰り返すことによって、公共主体は望ましい経路情報をドライバーに提供することが可能になるものと考える。

(2) 学習アルゴリズム 本研究で提案する*NN*モデルは、ドライバーの情報に対する反応を考慮したような学習過程を設計している点に特徴がある。センサーを介して観測した走行状態とそれに対応する交通情報を推定するモデルによって予測した結果をそのままドライバーに提供する。走行時間予測モデルによる予測結果が正確であれば、ドライバーに提示する情報も正確である。換言すれば、本研究で提案する*NN*モデルは、走行状態である入力値に基づいてそれに対応する提供すべき交通情報を選択するメカニズムに他ならない。そこで、人間の脳の機能を模倣し、学習と並列性に優れている階層型*NN*

モデルを適用することによって、より精度の高い推計を行う。そのアルゴリズムとして、パターン認識、制御などで広く用いられている*NN*モデルの代表的なバックプロパゲーション（以下、*BP*）法を用いる。

3. *NN* モデル

(1) モデルの仮定 本問題に*NN*モデルを適用する際、以下のような仮定を設定する。

(1) 基本的な*NN*モデルの層数は、入出力層を含めて3層を採用する。(2) 入力層のニューロンの素子数 *M* は、当該期首 *n* における経路交通量、通過交通量で、 $x_i[n]$ ($i = 1, \dots, 3$) と表す。(3) 中間層におけるニューロンの素子数 *H* を増減させたときのモデルの挙動を検討する。(4) 出力層のニューロンの素子数 *K* は、*NN* の選択経路の数 *i* (= 2) に等しいとし、それぞれ当該期 *n* + 1 の予測走行時間 $y_i(\Theta)[n+1]$ を出力する。(5) 結合マトリックス *W* と閾値ベクトル θ で構成されるパラメータベクトル Θ を更新する。初期値は、乱数で与えるものとし、その範囲を-0.1と0.1の間で与える。

(2) シミュレーションモデルの定式化 以上の仮定の下で、具体的な*NN*モデルの学習過程をモデル化する。

(1) ドライバーの初期主観期待を設定し、私的情報にガンベル乱数を割り当てる。(2) 結合マトリックス *W* と閾値 θ (パラメータ Θ) を初期設定する。(3) *BP*アルゴリズムに基づいて、出力 $y(\Theta)[n+1]$ の計算。(4) 公共主体が提示したメッセージ *e* に対応するドライバーの期待効用値を各経路に関して計算し、各ドライバーの選択経路を決定する。その結果、ドライバーの選択結果と内々交通量から経路走行時間 $t[n+1]$ が算定される。本研究では、この実現した経路走行時間を教師信号として定義する。(5) *BP*アルゴリズムに基づいて、結合マトリックス及び閾値の修正。(6) 選択されたメッセージに対応するドライバーの主観的期待を更新する。(7) 手順3から6まで繰り返す。ただし、次期の経路走行時間を

予測する際、手順5で更新された結合マトリックスを用いる。

4. 学習の複雑さと汎化性

本研究では、モデルの中の一つである機械の良さを計る評価関数として損失関数 $d(x, y; \Theta)$ を導入する。これは BP 法では平均2乗誤差 E として表される。これを用いて学習の際に生じるパラメータ Θ の揺らぎを統計的に扱い、学習に用いるデータ数を増やすと機械のパラメータの推定精度はどのように変わるか、またそれにより機械の性能がどのように向上するか、あるいはそうした向上の度合いは機械の構造とどのような関係にあるかを検討した。また、この結果を用いて機械の大きさ、構造およびデータ数が損失関数に与える影響を明らかにし、機械の設計・選択などに対して一つの規準量を導いた。

(1) 中間層のユニット数 H の異なるいくつかの NN モデルを考え、各モデルを十分学習させる。(2) 各モデルの学習後のパラメータ Θ を用いて、モデルとして式(3)、損失関数として平均2乗誤差(2)を用いて、式(1)を計算する。(3) 最も小さい AIC を与えるモデルを最良ものものと判定する。

$$AIC = \frac{1}{t} \sum_{j=1}^t d_H(x_j, y_j; \hat{\Theta}) + \frac{1}{t}(H(M+K) + H+K) \quad (1)$$

$$d_H(x, y; \hat{\Theta}) = \frac{1}{2} |y - f_H(x; \hat{\Theta})| \quad (2)$$

$$f_H(x; \hat{\Theta}) = \sum_{k=1}^K \tanh \left(\sum_{j=1}^H W_{jk}^2 \tanh \left(\sum_{i=1}^M W_{ji}^1 x_i + \hat{\theta}_j^1 \right) + \hat{\theta}_k^2 \right) \quad (3)$$

ただし、損失関数は、十分に学習が進んだ NN のパラメータ $\hat{\Theta}$ を用いて計算している。また、 W は結合荷重、 $\hat{\theta}^1, \hat{\theta}^2$ はそれぞれ1,2層の閾値、 $M (= 3)$ は入力層、 H は中間層、 $K (= 2)$ は出力層の素子数を表す。

5. 数値計算事例

(1) 概説 通過交通は300台に固定し、各経路の交通容量はそれぞれ800,1000(台)とし、ドライバーの各経路における初期主観的期待は、それぞれ正規分布 $N1(30, 5), N2(35, 10)$ 、私的情報はガンベル分布 $W(0, 30)$ に従うと仮定する。一方、時点 n の内々交通量 $N_i[n]$ は、 $AR(1)$ モデルに従うと仮定する。以下、経路 $i (i=1, 2)$ の内々交通量と通過交通量の和(経路交通量)は $X_i[n]$ で表し、走行時間関数としては TRB 関数を用いた。

(2) 情報提供モデル 図2より、公共主体がある走行状態に対して予測した経路走行時間に、実現した経路走行時間の平均値が収束していることがわかる。公共主体は、当該期首の走行状態、および1期前

の交通情報により当該期の経路情報を予測し、ドライバーに提供する。予想回数が浅いときには、経路情報としてはそれほど良い精度とはいえないが、回を増す毎に精度が良く、学習効果が得られているとともに、ドライバーの経路選択に関する学習効果が示されているといえる。

(3) 情報提供モデルの評価 図3は規準量と中間層の素子数の関係を示したものである。横軸には中間素子の個数を、縦軸には規準量をとっている。今回のシミュレーションにおいては、中間素子数が5個のモデルが適切であるモデルとして選択された。

6. おわりに

本研究で行ったシミュレーションに限っては、あらゆる走行状態においても提供した情報、つまり予測された経路走行時間は、長期的には実現した経路走行時間の平均値に収束することが判明した。また代替的予測モデルに対し、中間層の素子数を変化させた大きさの異なる機械に、評価規準としての AIC を適用させ、適切なモデルが選択された。

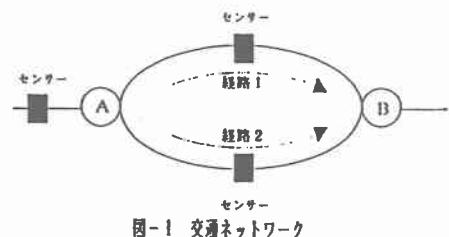


図-1 交通ネットワーク

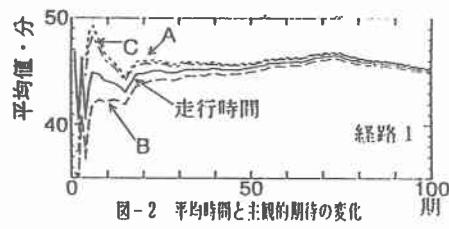


図-2 平均時間と主観的期待の変化
(ルート(40-50,40-50)の場合)

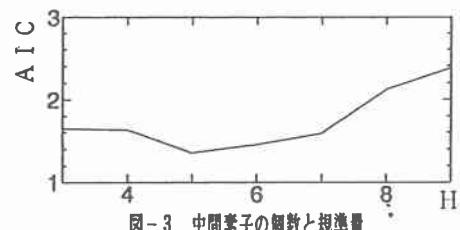


図-3 中間素子の個数と規準量