

## ニューラルネットワークを適用した駐車状況推定方法

上田 浩次<sup>†</sup> 堀場 勇夫<sup>†</sup>  
池谷 和夫<sup>†</sup> 小野寺 浩<sup>††</sup>

現在、駐車場利用の空間的、時間的偏りを平準化するため、駐車場の利用状況を事前に提供する駐車場案内システムが普及してきている。この駐車場の駐車状況検出方法としては、センサにより内部の駐車台数を漏れなく計数し、その駐車率から「満車」、「混雑」、「空車」等のマクロ的な駐車状況が利用者に提供されている。しかし、高速道路の休憩施設のように、数百台規模の駐車場において同様なことを考えた場合、設備規模が大きくなり実現が難しくなる。このため、部分駐車状況からマクロ的な全体駐車状況を推定する試みとして部分と全体の駐車率間における相関関係に注目し、線形回帰分析より部分駐車率から全体駐車率を推定する方式が行われた。しかし、この利用状況は常に一定の線形関係を保つとは考えにくくむしろ非線形であると予想される。また、各駐車場ごとの設置環境の差異から生じる固有の特質等も存在することが考えられる。このような状況に対して、本論文では、部分から全体の駐車状況を推定する方法にニューラルネットワークを用いた方法を提案する。この中では、ニューラルネットワークを駐車状況推定に適用する方法について言及し、従来行われた線形回帰分析との比較を行うことでその効果について検証する。また、実際の運用上の評価についても述べる。

### An Estimation Method of the Parking Condition Using a Neural Network Model

KOUJI UEDA,<sup>†</sup> ISAO HORIBA,<sup>†</sup> KAZUO IKEGAYA<sup>†</sup> and HIROSHI ONODERA<sup>††</sup>

This paper describes an application of a neural network model to estimation of parking conditions. Different from a conventional method which uses the linear regression relationship between the partial and total parking rate, the new method is concerned with nonlinear relation between them. Then structures of this neural network model are presented in detail. To verify the validity of the proposed method, we compare simulated results of the proposed method with the conventional method using counted data by persons. Good results are obtained in comparison with the conventional method. This paper gives also a practical application which has been done in Ashigara S.A. on Tomei highway.

#### 1. はじめに

近年、慢性的な路上駐車が発生によって交通流の阻害等が発生し、社会問題として取り上げられてきている。この施策として、地方自治体では駐車場案内システム<sup>1)</sup>を導入し、適切な駐車場への誘導、情報提供を行っている。このシステムは、一定地域内にある駐車場の混雑状況を利用者に提供し、時間的、空間的偏りを平準化することで利用効率の向上、道路交通の円滑化を目的としている。また、高速道路においても、大都市近郊の休憩施設(SA)に集中する傾向が強く、利

用の平準化、効率的運用を目的とした満車情報システム<sup>2)</sup>が実用化されている。これらシステムにおいては、駐車状況の検出が不可欠であり、その基本となる車両のセンシング方式として超音波反射式、ループコイル式の個別車両センサに加え、1台のTVカメラで数十台の車両検出を可能とする画像処理方式が開発されている。特に、広大な駐車場での車両認識を考えた場合、画像処理式の効果は高い。しかし、高速道路のSAにおいてすでに整備が進んでいるように、利用台数の増加にあわせた駐車場の拡大により、許容台数は数百台規模となってきている。このような駐車場を対象とした場合、この画像処理式を用いたとしても全駐車スペースを包括するには設備規模が非常に大きなものとなる。ただし、駐車場内部における細部の誘導を行う場合を除き、利用者に提供する情報内容は「満車」、「混雑」、「空車」のような全体の駐車状況をマク

<sup>†</sup> 名城大学理工学部  
Faculty of Science and Technology, Meijo University

<sup>††</sup> 名古屋電機工業株式会社  
Nagoya Electric Works Co. Ltd.

ロ的にとらえた情報<sup>1),2)</sup>であり、この程度の情報でも十分な状況把握が可能であるとともに実用上の効果も得ている。このため、状況認識についても、全駐車スペースの車両の有無を漏れなく検出することを前提とするよりは、マクロ的な認識法に注目した方がシステム規模も小さくなり、実現上において有利であると考えられる。

この認識方法に関するアプローチとして、駐車場内の部分領域の駐車率（全駐車スペースの中の一部分における駐車率で、以後部分駐車率と呼ぶ）と全体駐車率との相関に注目し、線形回帰分析により部分駐車率から全体駐車率を推定する試みがなされた<sup>3)</sup>。しかし、この利用状況は常に一定の線形関係を保つとは考えにくく、むしろ非線形な関係であると予想できる。また、各駐車場ごとの設置環境の差異から生じる駐車場固有の特質等も存在することが考えられる。そこで、本論文では、この非線形推定問題を部分駐車率の情報をもとにした3つのカテゴリー（満、混、空車）への分類としてとらえ、ニューラルネットワーク（以後、NN と呼ぶ）を適用した方法を新たに提案する。

NN は多層パーセプトロン (MLP) にバックプロパゲーション (BP) 学習則<sup>4)</sup>を適用した並列分散モデル (PDP) が実用的モデルとして注目されており、文字認識<sup>5)</sup>、音声認識<sup>6)</sup>、画像認識<sup>7)</sup>等認識対象が曖昧（非線形）な性質を持つような系において積極的な応用研究が行われており、その能力、可能性を見いだすためにも種々の分野における、より多くの応用成果が望まれている。特に、NN は変換規則が不明で非線形な対象に対しても、与えられる教師信号をもとにニューロン素子間の結合強度（重み）を自動調整（学習）することで、所望の変換、認識規則を得るとともに、教師信号に含まれない入力に対しても、妥当な出力が得られる（汎化）能力を持つことから、高度な情報処理を実現できる点に大きな特徴を持つ。

この NN をマクロ的駐車状況推定に適用するに際し、NN の情報処理能力を次のように仮定した。

(1) 学習能力：部分駐車率（入力）から全体駐車状況（出力）を推定する際、その変換則は複雑な関係であると予想されるが、与えられた教師データを学習することで非線形な入出力関係の自動抽出および駐車場固有の変換則を NN 内部に構築する。

(2) 汎化能力：学習に用いたデータ以外に生じる部分駐車率の変化に対しても、適切な出力が期待できる。

以上の仮定をもとに、本論文では NN の応用事例として、駐車状況推定に適用した場合の効果について検討することを目的とする。この中では、NN の構成方法について詳細に述べ、実際のフィールドで収集した計測データを用いて、従来検討された線形回帰分析による結果との比較を行い、NN の適用における効果を検証する。また、本方式は画像処理型駐車車両検出装置（以後、単に検出装置と呼ぶ<sup>8)</sup>とともに東名高速道路下り線足柄 SA においてすでに設置されており、その実用時の状況についても述べる。

## 2. 対象駐車場の形状と情報提供内容<sup>8)</sup>

今回対象とした駐車場は、東名高速道路下り線足柄 SA で図1のような形状である。この SA は4つの大きな駐車ブロック（図1中、A~D）に分かれており、全駐車許容台数は小型換算（大型車は小型2台分）で604台の巨大な駐車場である。また、図1中のハッチング部分（②~⑬）はすでに導入された検出装置<sup>9)</sup>の監視範囲であり、%表示は各駐車ブロックにおける監視率を示している。さらに、図1中①⑭はそれぞれ入出の通過台数を検出する検出装置であり、図中I~IVの矢印のように各方向の通過台数を計数している。

この駐車場内部における情報提供内容としては、広大な駐車場での混乱を防止するため、A~Dの駐車ブロック入り口部に「満車」、「混雑」、「空有」の3ランクによる表示提供が行われることになった。つまり、各駐車ブロックをおのおの1つの駐車場として扱い、情報提供が行われることになる。

そこで、以後の検討に当たっては、各駐車ブロックごとの駐車状況をそのブロックに属する部分領域の駐車率から推定するように考える。また、入出の通過台数についても、駐車状況と深い関係を持つことが十分予想できるため、部分領域の駐車率と合わせて推定情報として利用する。




図1 足柄 SA の形状  
Fig. 1 Form of Ashigara S.A.



表 2 全体駐車率と部分駐車率間の相関係数

Table 2 Correlation coefficients between the total and partial parking rate.

	Aブロック						Bブロック					
	No.1	No.2	No.3	No.4	No.5	No.16	No.1	No.6	No.7	No.8	No.9	No.16
相関係数	0.74	0.92	0.85	0.91	0.82	0.67	0.22	0.28	0.78	0.66	0.37	0.23

	Cブロック					Dブロック				
	No.1	No.10	No.11	No.12	No.16	No.1	No.13	No.14	No.15	No.16
相関係数	0.24	0.90	0.93	0.87	0.20	0.25	0.92	0.79	0.80	0.02

台数の変化で内部駐車状況を予測するためには、車両の移動時間を十分に考慮した工夫が必要であると考えられる。また、B、C、Dブロックについては、入出路が共通しているため、かなり相関が弱い結果となった。

4. 線形回帰分析による駐車状況推定方法

上記検討結果から、A~Dの4つのブロックの中で、最も相関の強いAブロックとその逆に相関の弱いBブロックを検討対象として選んだ。この両ブロックにおける計数データを用いて、線形回帰分析による駐車状況の推定を行う。その推定方法は以下のとおりである。

(1) 5月1日の10分間隔計数データにおいて、A、Bブロック内に属する部分領域  $n$  ( $=2\sim 9$ ) の単位時間 (10分間隔) における部分駐車率および入出車率

( $n=1, 16$ ) を独立変数 ( $x_i$ )、その時の対象ブロックにおける全体駐車率を従属変数 ( $y_i$ ) として、各部分領域に対する5月1日の回帰直線方程式 ( $y_n$ ) を求める。

$$y_n = ax + b,$$

$$a = \bar{y} - b\bar{x},$$

$$b = \frac{\frac{1}{k} \sum_{i=1}^k (x_i - \bar{x})(y_i - \bar{y})}{\frac{1}{k} \sum_{i=1}^k (x_i - \bar{x})^2}$$

(2)

- $x$ : 変数,
- $\bar{x}$ : 部分駐車率  $x_i$  の平均,
- $\bar{y}$ : 全体駐車率  $y_i$  の平均,
- $k$ : 計数データ数.

(2) 得られた直線方程式に各日の10分間隔の部分駐車率 ( $x_i$ ) を代入し、ブロックごとの単位時間推定全体駐車率 ( $y_n(i)$ ) を算出する。この部分駐車率から求められる推定全体駐車率の平均をその単位時間における最終的な推定全体駐車率 ( $P_A(i), P_B(i)$ ) とする。

$$P_A(i) = \frac{\sum_{n=2}^5 y_n(i) + y_{16}(i)}{6},$$

$$P_B(i) = \frac{\sum_{n=6}^9 y_n(i) + y_{16}(i)}{6}$$

(3)

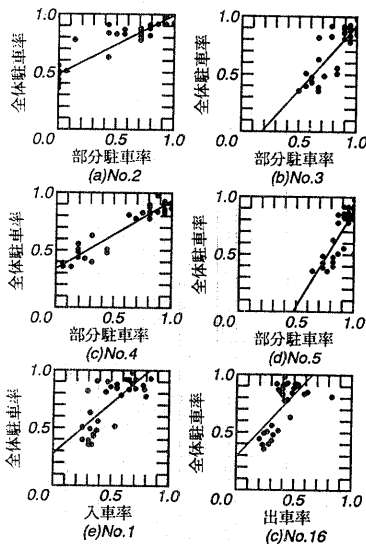


図 2 Aブロックにおける散布図  
Fig. 2 Scatter diagrams for A block.

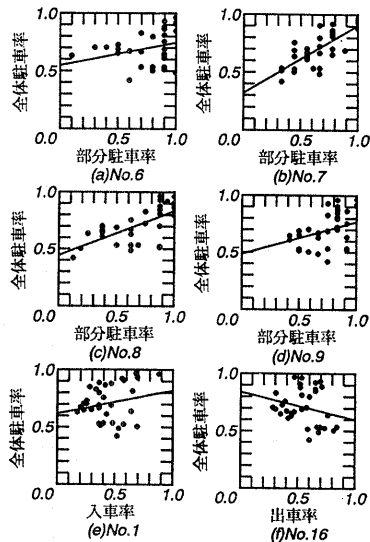


図 3 Bブロックにおける散布図  
Fig. 3 Scatter diagrams for B block.

表 3 各部分領域に対する回帰係数 (Aブロック)  
Table 3 Regression coefficients for each partial region (A block).

$$y_n = ax + b \quad (n \text{は部分領域の番号で} 1 \sim 16)$$

	n = 1		n = 2		n = 3	
	a	b	a	b	a	b
回帰係数	0.87	0.28	0.51	0.49	1.13	-0.20

	n = 4		n = 5		n = 16	
	a	b	a	b	a	b
回帰係数	0.59	0.34	1.67	-0.70	1.08	0.29

表 4 各部分領域に対する回帰係数 (Bブロック)  
Table 4 Regression coefficients for each partial region (B block).

	n = 1		n = 6		n = 7	
	a	b	a	b	a	b
回帰係数	0.20	0.62	0.20	0.55	0.59	0.32

	n = 8		n = 9		n = 16	
	a	b	a	b	a	b
回帰係数	0.39	0.45	0.29	0.49	-0.24	0.84

(3) 情報提供内容と同じく、3ランク判定を行うため、基準値を以下のように設定する。

満車=95% 以上

混雑=60% 以上 95% 未満

空有=60% 未満

なお、この基準値については、現在、東名高速道路において適用されている内容を用いた。

この設定に対し、線形回帰分析から得られる推定全体駐車率 ( $P_A(i), P_B(i)$ ) をこの設定範囲に当てはめ、最終的に3ランクの判定結果を得る。

ここで、図2、3はそれぞれA、Bブロック内に属する部分駐車率とブロック別全体駐車率との散布図を示し、図中直線は回帰直線を表している。また、表3、4はその回帰係数の算出結果である。なお、表中のaは直線の傾き、bは切片を示している。

### 5. NNによる駐車状況推定方法

本章では駐車状況推定のためのNNの構成および学習方法について述べる。

#### 5.1 NNの構成

今回採用したNNは図4のような3層MLP構成とし、各ユニットの応答関数は式(4)に示すようなシ




図 4 ニューラルネットワークモデル  
Fig. 4 A neural network model.

グモイド関数を用いた。また、学習方法は式(5)に示すBP法を適用し、最も基本的な構成とした。

$$f(x) = \frac{1}{1 + \exp(-x + \theta)} \quad (4)$$

x: ユニットの入力の総和,

θ: オフセット値 (しきい値),

f(x): ユニットの出力。

$$E = \frac{1}{2} \sum_{i=1}^k (O_i - T_i)^2,$$

$$\Delta w = -\epsilon \frac{\partial E}{\partial w} \quad (5)$$

E: 誤差評価関数,

$O_i$ : 出力値,

$T_i$ : 教師信号,

k: 出力ユニット数,

$\Delta w$ : 重み係数修正量,

w: 重み係数,

ε: 学習効率。

この構成において、入力層にはブロックに属する各部分領域における10分間隔ごとの部分駐車率および入、出車率がそれぞれ入力層の1ユニットに対応して入力され、出力層からは満車、混雑、空有の3ランク出力をそれぞれ得る。なお、出力層からの出力に対する教師データとしては、満車時 [1, 0, 0], 混雑時 [0, 1, 0], 空有時 [0, 0, 1] となる。

#### 5.2 中間層ユニット数および各種パラメータ

NNにおける中間層のユニット数はその認識能力に与える影響が大きく、理論的にはユニット数を増やしていくことで、あらゆる形の入出力関数が表現できることが証明されている<sup>9)</sup>。しかし、中間層ユニット数の増加は、学習時の収束時間に跳ね返り、むやみに




図5 中間層ユニット数による学習曲線の比較  
Fig. 5 Comparison of learning curves by unit numbers of the hidden layer.

増加させることは実用上の問題を生じる。また、最適な中間層ユニット数の決定方法についても、研究が進んでいるが<sup>10)</sup>、現時点では確実な方法が存在していない。さらに、式(5)で示されている学習効率の決定方法についても同様な状況である。

本論文で扱う検討の目的としては、NNの適用による効果に主眼を置いているため、まず、これらのパラメータを固定し、その性質を見いだすことが必要であると考えられる。そこで、学習効率は中間的な0.5に固定し、中間層ユニット数を2, 7, 10に変化させた場合の収束状況および学習速度を確認することで、今回の検討に用いるユニット数を決定することとした。なお、この検討に当たっては、Aブロック5月1日のデータを基にした。

この結果は図5のようになり、x軸は学習回数で対数軸として表し、y軸は式(5)で示される2乗誤差量のサンプル数による平均を示す。なお、5月1日の10分間隔のサンプル数は34サンプルである。このように、収束の初期段階においては中間層ユニット数による学習速度の差が生じているが、100回以上の学習経過段階ではその収束形態および収束速度にほとんど差がない。なお、ユニット数2の場合、最終収束段階の誤差量がやや大きく、7, 10ではほぼ同じ結果を得ている。この結果から、最終収束時の誤差量の大きさ、学習に要する処理量および演算速度を考慮し、中間層ユニット数は7で統一して扱うこととした。また、学習回数も十分収束が可能な1万回で統一する。

### 6. 推定結果の比較

これまで述べてきた線形回帰分析およびNNによる駐車状況推定方法について、5月1日、2日、6日におけるA, Bブロック計数データを用いた推定結果を比較検討する。なお、この場合、汎化性についての評価も重要な項目となるため、A, Bブロック両者の推定とも5月1日のデータをもとに得た分析、学習結果(線形回帰分析の場合は回帰係数、NNの場合は重み係数)から、5月2日、6日の駐車状況推定を行った。つまり、5月1日の推定結果はクローズ状態、2日、6日はオープン状態の結果となる。

表5は5月1日Aブロックにおける結果を示しており、これを図示したものが図6のようになる。さらに、5月2日、6日の結果は図7, 8のようになる。この結果、Aブロックにおいては、回帰分析による推

表5 推定結果(Aブロック)  
Table 5 Supposition results (A block).

1991年5月1日

時間	計数結果		回帰分析結果		NN出力結果			
	全体 駐車率	判定	推定 駐車率	判定	満車 (01)	混雑 (02)	空有 (03)	判定
10:10	0.83	混	0.83	混	0.01	0.99	0.01	混
:20	0.87	混	0.83	混	0.01	0.99	0.01	混
:30	0.92	混	0.84	混	0.01	0.99	0.01	混
:40	0.93	混	0.90	混	0.05	0.99	0.01	混
:50	0.91	混	0.82	混	0.01	0.99	0.01	混
11:00	0.88	混	0.83	混	0.05	0.99	0.01	混
:10	0.78	混	0.79	混	0.01	0.99	0.01	混
:20	0.83	混	0.81	混	0.01	0.99	0.01	混
:30	0.84	混	0.83	混	0.01	0.99	0.01	混
:40	0.63	混	0.62	混	0.01	0.99	0.01	混
:50	0.78	混	0.78	混	0.01	0.98	0.02	混
12:00	0.92	混	0.84	混	0.01	0.99	0.01	混
:10	0.98	満	0.87	混 ×	0.96	0.99	0.01	混 ×
:20	0.82	混	0.72	混	0.01	0.99	0.01	混
:30	0.88	混	0.85	混	0.01	0.99	0.01	混
:40	0.92	混	0.87	混	0.01	0.99	0.01	混
:50	0.92	混	0.86	混	0.01	0.99	0.01	混
13:00	0.90	混	0.82	混	0.01	0.99	0.01	混
:10	0.81	混	0.85	混	0.01	0.99	0.01	混
:20	0.84	混	0.81	混	0.01	0.99	0.01	混
:30	0.91	混	0.86	混	0.01	0.99	0.01	混
:40	0.86	混	0.78	混	0.01	0.99	0.01	混
:50	0.85	混	0.84	混	0.01	0.99	0.01	混
15:10	0.48	空	0.57	空	0.01	0.01	0.99	空
:20	0.51	空	0.54	空	0.01	0.01	0.99	空
:30	0.43	空	0.51	空	0.01	0.01	0.99	空
:40	0.40	空	0.52	空	0.01	0.01	0.99	空
:50	0.36	空	0.48	空	0.01	0.01	0.99	空
16:00	0.39	空	0.49	空	0.01	0.01	0.99	空
:10	0.36	空	0.47	空	0.01	0.01	0.99	空
:20	0.51	空	0.67	混 ×	0.01	0.01	0.99	空
:30	0.56	空	0.61	混 ×	0.01	0.01	0.99	空
:40	0.49	空	0.51	空	0.01	0.01	0.99	空
:50	0.44	空	0.52	空	0.01	0.01	0.99	空

誤り計 3 誤り計 1

分類: 満=満車, 混=混雑, 空=空有

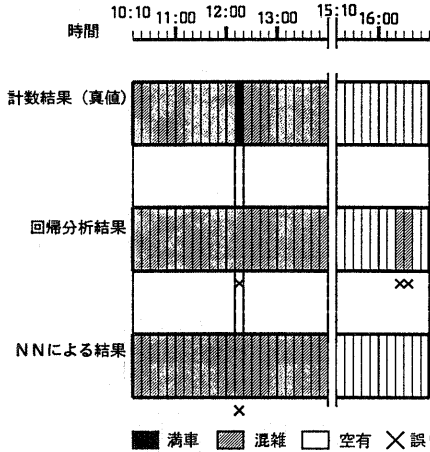


図 6 比較結果 (5月1日, Aブロック)  
Fig. 6 A comparison result (May 1, at A block).




図 8 比較結果 (5月6日, Aブロック)  
Fig. 8 A comparison result (May 6, at A block).




図 7 比較結果 (5月2日, Aブロック)  
Fig. 7 A comparison result (May 2, at A block).




図 9 比較結果 (5月1日, Bブロック)  
Fig. 9 A comparison result (May 1, at B block).

定において誤り総数が5データ, NN では4データとなり, 両方法とも同等の推定結果を得た。また, 線形性も安定しており, 汎化性についても良い結果を得ている。

同様に, Bブロックの5月1日の推定結果を図9に示す。この図9から, Bブロックの場合, 部分駐車率と全体駐車率との相関が弱いため, 線形回帰分析での結果では誤りが34データ中11データとなっており, 多くの誤りを生じている。また, Aブロック同様, 5月2日に適用した結果を図10に示す。この図10において, 線形回帰分析結果は36データ中半数以上の24データに誤りを生じ, 相関関係が弱い場合には推定が良好に行われなことがわかる。しかし, NNでの結果についても5データに誤りを生じ, 回帰分析を用い

た推定結果よりは良いものの, Aブロックの結果に比べて誤り数は多くなっている。そこで, 追加学習として, 学習の基本となる5月1日の全データに, 2日で生じた誤りデータ(回帰分析で24, NNで5データ)を加えて再度回帰分析およびNNの学習を行った。その結果を用いて推定したものを図11, 12に示す。なお, 図11は5月1日の結果, 図12は2日の結果である。図12では両方法とも誤りデータはなく, 学習が良好に行われたことがわかる。しかし, 図11の回帰分析による結果では, 14データの誤りを生じ, 基本データの追加前における図9の結果よりもさらに悪くなっている。結局, 線形回帰分析の場合, 1つの状態変化に追従させようとするとの他の推定に影響を及ぼす結果となった。これに対し, NNでは誤りデータがすべて改善され, 5月1日, 2日とも追加学習の効果




図 10 比較結果 (5月2日, Bブロック)  
 Fig. 10 A comparison result (May 2, at B block).




図 12 追加学習後の比較結果 (5月2日, Bブロック)  
 Fig. 12 A comparison result after the additional learning (May 2, at B block).




図 11 追加学習後の比較結果 (5月1日, Bブロック)  
 Fig. 11 A comparison result after the additional learning (May 1, at B block).




図 13 追加学習後の比較結果 (5月6日, Bブロック)  
 Fig. 13 A comparison result after the additional learning (May 6, at B block).

により、より良い結果を得た。さらに、汎化性を確認するために、この分析、学習結果を5月6日に適用したものが図13である。この図13においても、回帰分析結果に比べ、NNでの推定結果が優れている。

以上のように、部分駐車率と全体駐車率の間の相関関係が強く、安定している場合には、線形回帰分析、NNともほぼ同等の能力を発揮するが、この関係が弱く、非線形な状況ではNNでの推定能力が優れている。また、誤りデータの追加学習により、その状況変化を吸収し、柔軟な対応を達成した。さらに、汎化性についてもNNでの推定結果の方がより良い結果を得た。このことから、NNの適用時における仮定が妥当であることが確認できた。

このA、Bブロックに対するNNの適用において、




図 14 AブロックとBブロックの学習曲線の比較  
 Fig. 14 Comparison of learning curves between A block and B block.

対象の違いとしては、相関関係の強弱にある。この差は、学習の容易性に影響を与えることが予想できるため、おのおののブロックにおける5月1日の学習曲線



を比較した。その結果を図 14 に示す。このように、部分と全体の関係がより複雑で相関関係が弱い B ブロックにおいては、A ブロックに比べて学習の進行状況が遅くなっている。今回の場合、NN の適用効果を第一の目的としたため、パラメータの 1 つである学習回数については固定して扱ったが、この結果から、相関関係の強弱により最適な学習回数が存在すると考えられ、NN の適用時における 1 つの性質を示している。

## 7. 実用上の効果

この NN を用いた駐車状況推定方法は、検出装置とともに 1991 年 6 月東名高速道路下り線足柄 SA において稼働を始めており、そのシステムおよび運用側からの評価については文献 11) に示されており、精度上満足のいく結果を得ている。また、これまでに 1991 年 8 月に SA 内部の休憩施設 (売店) がオープンしたことで、内部の駐車形態が変化 (当初、混雑のなかった駐車スペースが常時混みだした) したが、その状況において追加学習を加えることで、学習後の推定精度は 75 データ中誤りが 2 データとなり、満足の行く結果を得た。1991 年 12 月にも追加学習、状況検証を行い、12 月 25 日から 28 日の 4 日間で 280 データ中誤りは 7 データであった。このように、実用上においても良い結果を得ることができた。

## 8. おわりに

本論文では部分駐車率から全体駐車状況を推定する方法として NN の適用を提案し、線形回帰分析の推定結果との比較、検討を行った。その結果、マクロ的な 3 ランク推定において NN を用いた場合、相関関係の強弱にかかわらず、精度の高い駐車状況推定を可能とすることがわかった。特に、相関関係が弱い場合の推定事例において、誤りを生じたデータを用いた追加学習により、その能力の向上が確認できたことと、実用時に生じた駐車形態の変化に対しても、同様な学習行為により推定精度を維持できたことと、非線形な状況変化に対しても学習により柔軟に対応できることが確かめられた。また、駐車状況推定のための NN の性質として、相関関係の違いにより学習曲線に差を生じ、相関関係が弱い場合には学習の収束が遅く、対象の相関関係により、最適な学習回数が存在することもわかった。

今回、目的とした駐車状況推定のための NN の適用に関してはその実用性を確かめることができたが、

より高い精度、安定性を追求するためには出入車率の取扱いおよびカレンダー情報等、NN への入力データとしての工夫が必要であると考えられる。さらに、学習回数、中間層の数、ユニット数、さらには学習効率等 NN の各種パラメータは演算速度、推定精度に影響を与えることから、これらパラメータの最適化も必要である。また、今回のように、マクロ的な 3 ランク推定を行ってきたが、その基本は駐車率にあり、NN を用いたシステムで直接全体駐車率を推定する方法について検討する予定である。

謝辞 本研究を進めるにあたり、対象とした東名高速道路足柄 SA における調査等に対して、多大な協力をいただきました日本道路公団小山泰一氏に感謝いたします。

## 参考文献

- 1) 松田文夫, 大野正大, 浅井邦彦: 名古屋市駐車場整備計画について, 第 18 回日本道路会議論文集, p. 1028 (1989).
- 2) 小野寺浩: 交通情報の監視制御システム, 電気学会論文誌, Vol. 110-d, No. 6, pp. 612-616 (1990).
- 3) 竹谷栄一, 田中直樹: 休憩施設の駐車情報システムの研究, 高速道路と自動車, Vol. 32, No. 1, pp. 37-49 (1989).
- 4) Rumelhart, D. E. and McClelland, J. L.: *Parallel Distributed Processing*, Vol. 1 and Vol. 2, MIT Press (1986).
- 5) 森 吉弘: PDP モデルによる手書き漢字認識, 電子情報通信学会論文誌, Vol. J73-D-II, No. 8, pp. 1268-1274 (1990).
- 6) 磯 健一, 渡辺隆夫: ニューラル予測モデルを用いた不特定話者音声認識, 電子情報通信学会論文誌, Vol. J73-D-II, No. 8, pp. 1315-1321 (1990).
- 7) 大橋剛介, 大矢晃久, 名取道也, 中島真人: 超音波エコー画像の 3 次元表示のためのニューラルネットワークを用いた輪郭抽出法, 電子情報通信学会論文誌, Vol. J76-D-II, No. 2, pp. 368-373 (1993).
- 8) 内丸年雄, 小山泰一, 小野寺浩, 上田浩次, 堀場勇夫, 池谷和夫: 東名高速道路足柄 SA (下り) における画像処理型駐車場案内システム, 電気学会道路交通研究会, RTA-91-14 (1991).
- 9) Irie, B. and Miyake, S.: Capabilities of Three-Layered Perceptrons, *Proc. IEEE*, ICNN 88, 1-641 (1988).
- 10) 栗田多喜夫: 情報量基準による 3 層ニューラルネットの隠れ層のユニット数の決定法, 電子情報通信学会論文誌, Vol. J73-D-II, No. 11, pp. 1872-1878 (1990).

- 11) 小泉光政, 小山泰一: 東名高速道路足柄 SA (下り線) 駐車状況判別システム (画像処理型), 高速道路と自動車, Vol. 35, No. 1, pp. 32-40 (1992).

(平成 5 年 7 月 9 日受付)  
(平成 5 年 10 月 14 日採録)



上田 浩次 (正会員)

昭和 34 年生. 昭和 56 年名城大学理工学部電気工学科卒業. 同年名古屋電機工業(株)入社. 昭和 63 年名城大学大学院修士課程修了. 平成 5 年同大学院研究生. 現在, 名古屋電機工業(株)技術部開発課. 主に交通系における画像処理応用に関する研究に従事. 電子情報通信学会, 日本音響学会各会員.



堀場 勇夫 (正会員)

昭和 23 年生. 昭和 49 年名古屋大学工学部電気工学科卒業. 同年(株)日立メディコ入社. 昭和 62 年名城大学理工学部電気電子工学科講師. 平成 3 年同助教授. 工学博士. 主に交通系における画像処理応用, 生体情報の計測および医用画像処理に関する研究に従事. 電子情報通信学会, 日本 ME 学会, 日本放射線技術学会, 日本超音波医学会, 日本循環器学会等各会員.



池谷 和夫

大正 11 年生. 昭和 20 年東京工业大学電気工学科卒業. 通信省電気試験所研究員, 電気通信省技官, 電電公社電気通信研究所調査役, 名古屋大学工学部電気工学科教授を経て, 昭和 60 年名古屋大学名誉教授. 現在, 名城大学理工学部電気電子工学科教授. 工学博士. 音響工学, 医用電子工学, 騒音制御, 情報システムの研究に従事. 日本音響学会, 日本 ME 学会各名誉会員. 電子情報通信学会, 日本フェジィ学会, 騒音制御工学会, 海洋音響学会, 米国音響学会等の各会員.



小野寺 浩 (正会員)

昭和 21 年生. 昭和 44 年名城大学理工学部電気工学科卒業. 同年名古屋電機工業(株)入社. 現在, 技術部部長. 可変情報板システム, 気象観測システム, 画像処理等の研究開発を経て道路交通関連システムの開発検討業務に従事. 電気学会会員.