

アナログ出力ニューラルネットワークを用いた 駐車率の直接推定方法

上田 浩次[†] 山田 宗男^{††} 堀場 勇夫[†]
池谷 和夫[†] 鈴木 賢治[†]

広大な駐車場における効率的な駐車状況の検出を目的として、既に著者らは部分駐車状況から全体駐車状況をマクロ的に推定するニューラルネットワーク（N.N）についてアプローチを行ってきた。このN.Nの構成としては、入力層に部分駐車率を与え、出力層には3つのマクロ出力（「満車」、「混雑」、「空車」）のニューロンを配置し、全体駐車状況の推定を行うようにした。しかし、この方法の場合、駐車状況基準の変更時にも学習用データの収集および再学習が必要となり、単純な状況基準の変更が容易に行えるとは言いきれない。この実用上の問題点を解決するため、本論文では駐車状況の基準となる駐車率を直接推定するためのN.Nを提案する。すなわち、従来よく用いられているシグモイド関数が極値である1.0, 0.0を出力しにくい点を示し、その改良方法として、新たに出力層の応答関数をリニア関数としたアナログ出力N.Nについて述べる。この改良方法に対して、シミュレーション実験および以前に収集した東名高速道路足柄S.Aでの実測データを用いた評価を行い、その効果を検証した。その結果、真値からの標準偏差がパーセント駐車率で10%以内となる結果を得ることができ、実用化への十分な可能性を得ることができた。そして、ここで得た成果をもとに、東京外環道新倉P.Aに本方式を導入し、実用時の効果についても検証を行った。この結果についても、実測データによる評価と同様、真値からの標準偏差がパーセント駐車率で10%以内の良い結果を得ることができた。

A Direct Estimation Method of Occupancy Rate in Parking Lot Using Analogue Output Neural Network Model

KOUJI UEDA,[†] MUNEO YAMADA,^{††} ISAO HORIBA,[†]
KAZUO IKEGAYA[†] and KENJI SUZUKI[†]

In this paper, we propose to use the Neural Network model (N.N), which gives a direct estimation of occupancy rates. In this proposal, we have indicated, that it is difficult to output the limits 1.0, 0.0 of the Sigmoid function, which has up until now often been used. As a method to improve this, we will explain a new method, Analogue Output N.N which uses output layer response function as a linear function. In concern to this improvement method, we assessed it using a simulation test and practical data collected prior to this from Ashigara S.A and the effect was verified. We were able to find that the result came within 10 % of the percent occupancy rate's standard deviation from the true value and were able to obtain sufficient possibilities for practical use. And based on this positive result, this method was adopted for Niikura P.A and moreover the effect when practically applied was also verified. As a result of this verification, the evaluation is the same as the practical data in Ashigera S.A and we were able to obtain the positive result of the standard deviation from the true value being within 10 % of occupancy rates.

1. はじめに

車両保有台数の増加に伴う駐車場不足は、深刻な社会問題となってきている。このため、地方自治体では駐車場案内システム¹⁾を導入し、適切な駐車場への誘

導、情報提供を行うことで、この問題の緩和に努めている。また、高速道路においても、同様な状況が発生しており、東名高速道路では利用の平準化、効率的運用を目的とした満車情報システム²⁾が導入されている。

近年、このような社会状況を反映して、駐車車両のセンシングに関する新しいアプローチが行われてきており、特に、被検出対象が広範囲に分布することから

[†] 名城大学理工学部

Faculty of Science and Technology, Meijo University

^{††} 名古屋電機工業株式会社

Nagoya Electric Works Co. LTD.

画像処理による検出方式の研究が盛んである^{3)~5)}。しかし、この画像処理による駐車車両検出方法を用いたとしても、高速道路の休憩施設(S.A.P.A)のように数百台の駐車を可能とする広大な駐車場においては、TVカメラ(センサ)台数の増加とその設置用設備の増加、更にシステムの巨大化を招き、実現性が薄くなる。つまり、駐車車両のセンシングと合わせて、駐車状況の効率的な抽出方法へのアプローチも重要な課題であると考えられるが、この内容については、ほとんど研究がなされていないのが現状である。

そこで我々は、この点に注目し、高速道路の休憩施設(S.A.P.A)を対象とした駐車状況の自動収集方法について研究を進め、その実用化を行ってきた⁶⁾。この研究の中では、内部の駐車車両のセンシング方式として動画像処理を基本とした方法⁵⁾を採用し、更にTVカメラ(センサ)台数の削減を目的として、部分駐車状況から全体駐車状況をマクロ的に推定する方法に対して、ニューラルネットワーク(N.N)を適用した新たなアプローチを行った⁷⁾。このN.Nの構成としては、3層構成とし、入力層に部分駐車状況(部分駐車率)を与える、出力層に3つのマクロ出力(「満車」、「混雑」、「空車」)のニューロンを配置し、状況出力を得るようにした。つまり、このN.Nの適用は全体駐車状況の推定を部分駐車状況(部分駐車率)入力による3つのカテゴリへの非線形分類問題としてとらえた。この結果、従来行われてきた線形回帰分析による推定方法⁸⁾に比べ、良い結果を得ており、汎化能力の高さ、非線形な変動に対する追従性の良さを実証した。

しかし、このN.Nの構成からわかるように、学習に関しては全体状況が「満車」、「混雑」、「空車」となった時点の部分駐車率を教師データとして与えており、各全体状況の判断基準の変更が必要な場合(例えば、管理形態の変更等から、全体の60%以下の駐車率の時「空車」状況としていたものを50%以下に変更)、変更後の基準に従った全体状況および部分駐車率を再度収集し、これを用いて再学習する必要がある。この教師データの収集に関しては人が全駐車車両台数を計数しているのが現状である。しかも、より多くの状況を学習させるため、極端な場合では導入当初と同様、平日、休日、連休等の各種状況を各日、数時間にわたりて収集することが必要となる可能性を持ち、単純な基準変更も容易に実行できるとは言いきれない。これは、データ収集の困難さがゆえに生じる内容であると考えられる。このデータ収集の困難さについては、この分野に留まるものではなく、一般的なN.Nの応用に関する研究課題として、本学会の中でも取り上げられて

いる⁹⁾。その意味では、本分野においても、N.Nを応用し、実用化していくにあたって、この課題に対するより効率的な方法を検討し、改良を行っていくことも重要な項目であると言える。

この状況判断基準の変更時に生じるデータ収集の必要性については、ここで用いたN.Nが3つのカテゴリへの分類形態をとっているために生じる。これを駐車率自体の推定出力として得られるようすれば変更のためのデータ収集の必要はなく、単純な基準テーブルの変更で済む。また、全体駐車率が直接的に推定できれば、最も基本となる情報を得ることができるため、例えば、現行の3ランクの情報提供のみならず、パーセント表示のような、多様な情報提供形態にも追従が可能となる。そこで、本論文では上述したような実用時の課題を解決するために、部分駐車率から全体駐車率を直接推定するN.Nを提案する。そして、この中では駐車率出力をを行うためのN.Nの形態、応答関数等細部にわたる検討を行い、シミュレーション実験により、その効果を検証する。また、得られた結果とともに、東名高速道路足柄S.Aの1991年5月における実際の収集データを用いた評価結果を示し、実用上の効果を検討する。更に、ここでの方式を東京外環道新倉P.Aにおいて実用化し、その実用時の状況についても報告する。

2. アナログ出力ニューラルネット(A.N.N)

本項では上記で示してきたように、部分駐車率から全体駐車率を直接的に推定する方法について検討する。

一般にN.Nの応答関数としては入力層に恒等関数中間層、出力層に式(1)のシグモイド関数が用いられる。

$$o(x) = \frac{1}{1 + \exp(-x)} \quad (1)$$

このシグモイド関数の出力値は[0,1]の実数として得られる。この出力形態を利用し、これまでのような複数の出力ニューロン間の出力値の比較によるカテゴリへの分類ではなく、出力層のニューロン数を1個として、出力値をアナログ的に扱い、実際の駐車率([0,1])にあてはめれば、目的とした駐車率の直接推定が可能となると考えられる。元来、N.Nの学習で用いられるBP法は出力値と教師データ間の誤差を逐次減少させていく方法であることから、このような形態でアナログ的な学習は可能である。なお、N.Nの学習則として一般的であるBP法¹⁰⁾は3層N.Nの場合次のようになる。

今、教師データ T_k と出力 O_k の間の誤差評価関数 E は次式で扱われる。なお、 k は正の整数で出力層のニューロン数である。

$$E = \frac{1}{2} \sum_k (T_k - O_k)^2 \quad (2)$$

BP 法では、各層間の結合重み W を変化させることで、誤差関数 E を最小化する。この重み W の変化量 ΔW は次式のようになる。

$$\Delta W_{jk} = -\alpha \frac{\partial E}{\partial W_{jk}} = \alpha \cdot \delta_k \cdot H_j \quad (3)$$

$$\Delta W_{ij} = -\beta \frac{\partial E}{\partial W_{ij}} = \beta \cdot H_i (1 - H_i) \cdot \sum_k \delta_k \cdot W_{jk} \cdot I_i \quad (4)$$

ただし、 $\delta_k = \delta \cdot O_k \cdot (1 - O_k)$ 、 $\delta = T_k - O_k$ であり、 i, j はそれぞれ正の整数で入力層、中間層のニューロン数、 I, H はそのニューロンの出力である。また、 α, β は学習係数を示す。

この学習アルゴリズムに従い、図 1 のように、入力層 I_i に部分駐車率を入力し、その時の全体駐車率をアナログ値の教師データ T_1 として与え、出力 O_1 との間で学習することで、駐車率推定を行う。しかし、式(1)の関数形態からわかるように、得られる出力の最小値 0.0 および最大値 1.0 を得るためにには、 $-\infty, +\infty$ の入力が必要になる。実際に駐車率においてはこの最大、最小値が存在し、このままの応答関数では駐車率の両極値が output されにくい形となる。また、この点を考慮して、学習に用いる教師データを [0.1, 0.9] の範囲で扱う指摘がされている¹⁰⁾。

元来、3 層以上の層構造の場合、分類対象の性質、汎化性能等は中間層を持つことで実現される。このことは XOR 問題での実験により紹介されている¹¹⁾。また、分類対象の性質が中間層を含んだ重みにより表現されることも別に報告されている^{12), 13)}。これらの知見を基に、上述した極値での応答特性を改善することを目的として、中間層には従来どおりのシグモイド関数を用

いて非線形性への対応および汎化性能の確保を考慮し、出力層には式(1)のシグモイド関数に代わり式(5)に示すリニア関数を新たに採用した駐車率推定量 N.N を提案する。

$$o(x) = x + 0.5 \quad (5)$$

このリニア関数を用いた N.N は [0, 1] の出力に限らず、アナログ値を表現できることから、以後アナログ出力 N.N (A.N.N) と呼ぶ。一般に、出力関数をリニア関数とした報告^{13), 14)} はこれまでにされているものの、ここで対象としたような、極値での応答特性に対する改善を目的とした例はない。なお、この A.N.N における結合重みの学習量は式(3), (4) の誤差成分 δ_k における応答関数の微分項が消え、次式のようになる。

$$\Delta W_{jk} = \alpha \cdot \delta \cdot H_j \quad (6)$$

$$\Delta W_{ij} = \beta \cdot H_i (1 - H_i) \cdot \sum_k \delta \cdot W_{jk} \cdot I_i \quad (7)$$

ただし、 $\delta = T_k - O_k$ である。

3. シミュレーション実験¹⁵⁾

上記のように、駐車率推定を行うことを目的とした A.N.N に関して、その能力を評価するため、A.N.N と N.N を用いたシミュレーション実験を行う。なお、A.N.N では教師データを [0.1] の範囲で直接扱うようにし、N.N に関しては、参考文献 10) にあるように、[0, 1] の範囲の教師データを直接扱うではなく、教師データを [0.1, 0.9] の範囲に一旦圧縮して学習し、学習後の重みを用いた N.N の出力に関して、再度 [0, 1] に拡張する方式とする。また、従来提案されている方法として、線形回帰分析による方法⁸⁾ も対象となるが、我々が別に報告⁷⁾ したように、駐車状況という非線形な対象に対しては N.N での有効性を既に得ており、ここでは扱っていない。

この能力評価を行うに当たって、対象とするデータは [0, 1] の範囲で変化することを条件として、式(8) に示す sin 関数を用いることとした。

$$f(x) = 0.5 \sin x + 0.5 \quad (8)$$

この関数中、図 2 の印の 17 点を教師データとして選び、学習を行う。なお、中間層のニューロン数については確実な決定方法が存在していないことから、従来の N.N を用いて学習回数を 1 万回、学習係数 0.5 に固定して、中間層ニューロン数を 2~5 まで可変させ、式(2) の誤差が最も小さくなるものを用いることとした。この結果は表 1 のようになり、中間層のニューロン数が 4 個の時に誤差が最小となることから、このシミュレーションに関しては入力層 1, 中間層 4,

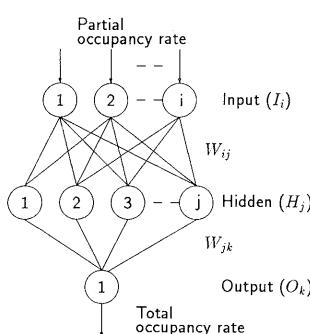


図 1 アナログ値推定のための N.N モデル
Fig. 1 N.N model for analogue data estimation.

出力層1(以後、1-4-1と呼ぶ)のニューロン構成とした。また、N.NとA.N.Nの能力比較を基本とするため、この構成および学習に関する各種パラメータ(学習回数1万回、学習係数0.5)はA.N.Nにおいても同一とした。この学習結果の重みを用いて、学習データ17点を含み、未学習である点間の値とあわせて361点を両ネットワークへ入力し、この出力値を得た。その結果を図3に示す。この図3から明らかなように、N.Nに比べA.N.Nの方が極点での追従性が良く予想どおりの結果を得た。また、図4はこの時の学習曲線を示しており、A.N.Nの場合、学習が進んできた1,000回以降で非常に効率よく学習が行われている。学習後の誤差量(式(2))はN.Nで0.00522、A.N.Nで0.0004となっており、学習の最終誤差量としても桁が違う程の差がでている。これらの実験結果から[0,1]

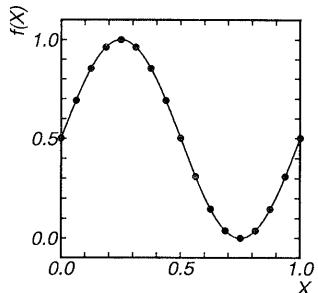


図2 \sin 関数と学習点
Fig. 2 The \sin function and learning points.

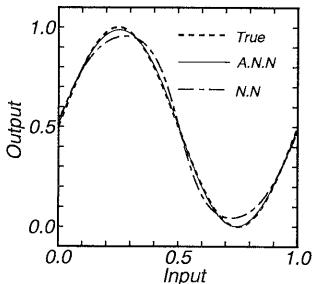


図3 学習結果
Fig. 3 Learning results.

表1 中間層のニューロン数に対する誤差の比較
Table 1 Comparison of the error to neuron number of hidden layer.

ニューロン数	誤差
2	0.02044
3	0.00573
4	0.00522
5	0.00642

のアナログ値に対して、A.N.Nの有効性を示すことができ、駐車率推定の可能性を得た。

4. 実測データを用いた検証結果

図5は東名高速道路下り線足柄S.Aの形状を示している。このS.Aは図中A～Dのように4つの大きな駐車ブロックに別れており、駐車状況の検出に関しては各駐車ブロック単位で行われる。なお、この図のハッキング部分(1～16)は、既に導入された画像処理型検出装置の監視範囲である。この検出結果を用いて、図6のように各駐車ブロックごとに用意したN.Nの入力層にブロック内の部分駐車率および出入車率を与

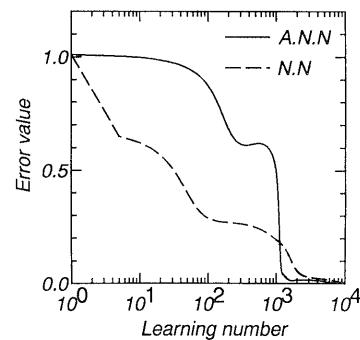


図4 学習曲線
Fig. 4 The learning curve.

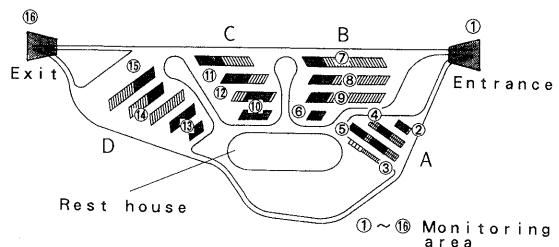


図5 足柄 S.A の平面図
Fig. 5 Plane of Ashigara S.A.

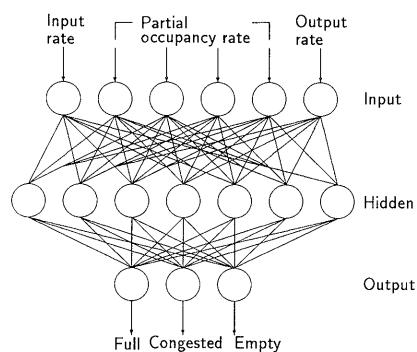


図6 従来のN.Nモデル(足柄S.A.Aブロック)
Fig. 6 The usual N.N model (A block in Ashigara S.A.).

え、出力層から 3 ランクの全体推定状況を得る方法について報告してきた⁷⁾。なお、部分駐車率とは各監視範囲の最大駐車台数に対する駐車検出台数の比であり、2~15 の検出装置により各々算出される。また、入出車率は 1,16 の検出装置による通過車両の検出結果から、あらかじめ定めた単位時間(10 分間)当たりの最大通過台数に対する入出車両の通過検出台数の比として規格化している。本項では、この報告の中で使用した実測データを流用し、図 7 のような N. N および出力層ニューロンの応答関数をリニア関数とした A. N. N による駐車率の直接推定を行い、この両者の推定能力を検証し、実用化への可能性を検討する。

対象としたデータは、小型車の駐車領域である A ブロックの 3 日間(1991 年 5 月 1 日、2 日、6 日)での収集データを用いて行う。なお、N. N, A. N. N における入力層、中間層のニューロン数については 6,7 とし、出力層を除いて、前回の報告で示した構成と同一とした。もちろん、出力層は駐車率を直接出力するように 1 としている。そして、学習方法についても前回同様、

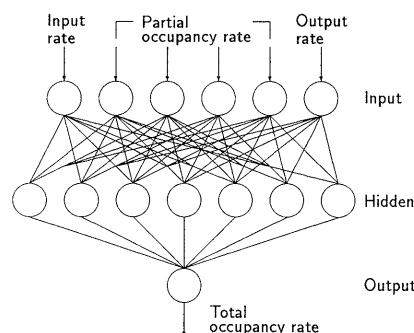
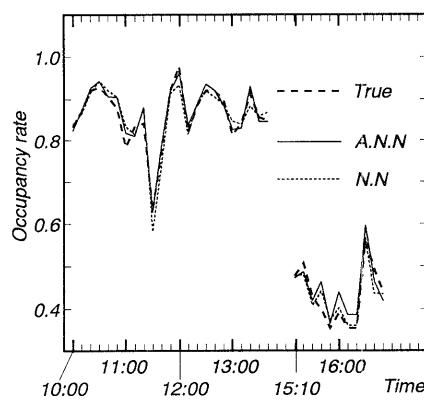
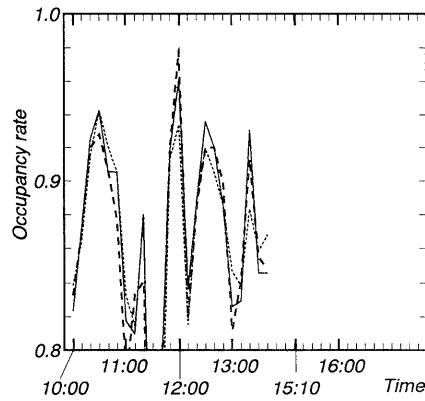


図 7 足柄 S. A 内 A ブロック向け A. N. N
Fig. 7 A. N. N model for A block in Ashigara S. A.



(a) All data



(b) Over 0.8 data

図 8 足柄 S. A の A ブロックにおける学習結果(91 年 5 月 1 日)
Fig. 8 Learning results on A block of Ashigara S. A. (91, May, 1).

5 月 1 日に収集した 34 データ(10 分間隔)を教師データとして与え、式(2)の誤差が 0.01 になるまで学習を行った。なお、学習係数は 0.1 である。この時の N. N の学習回数は 135,508 回、A. N. N では 130,148 回となり、やはり A. N. N における学習のほうが早く収束している。この学習結果を用いたクローズ状態(5 月 1 日)での結果を図 8 (a) に示す。この図において、縦軸は駐車率、横軸は計測時間を示しており、図中細かい点線は N. N、実線が A. N. N での推定結果で、点線は真値である。この結果から、N. N, A. N. N とともに真値に良く追従していることが分かる。ここで、A. N. N の特徴である極値での応答性能を確かめるため、駐車率 0.8 以上のデータを抜き出し、拡大したものが (b) である。この図中において、ピークとなる 12:00 の点(駐車率真値 0.978)では N. N の推定値に比べやはり A. N. N での追従が良くなっている。なお、この時の駐車率の推定値は N. N が 0.934 で A. N. N が 0.961 であった。

更に、この学習後の重みを用いて、未学習である 5 月 2 日(36 データ)、6 日(30 データ)の駐車率推定を行った結果が図 9 である。つまり、図 9 がオープン状態である。この推定結果を定量的に評価するため、真値からの標準偏差(STD)を次式に従い算出した。

$$STD [\%] = \sqrt{\frac{\sum_k (T_k - O_k)^2}{k}} \times 100 \quad (9)$$

なお、この式(9)のように、STD はパーセント駐車率で示す。この結果は表 2 のようになり、クローズ状態である 5 月 1 日での結果は除いて考えても、5 月 2 日、6 日の 66 パターンに対して、真値からの標準偏差はパーセント駐車率で 10% 以内となり、汎化性能に對

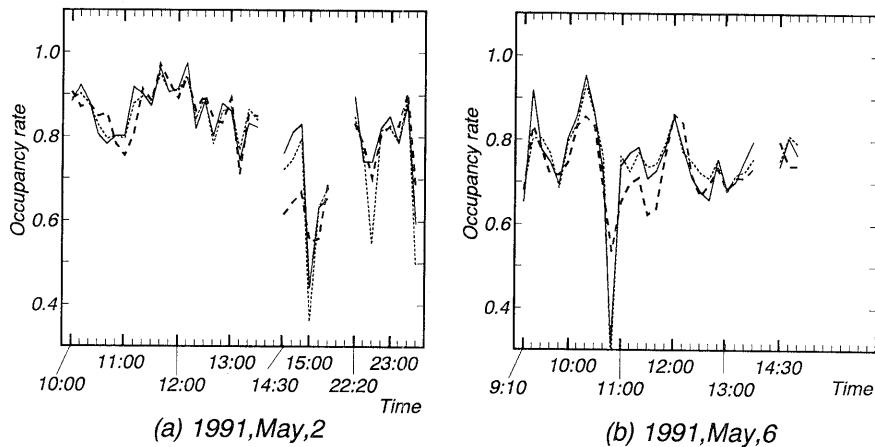


図9 足柄S.A のA ブロックにおける検証結果
Fig. 9 Verified results on A block of Ashigara S.A.

表2 足柄S.A における標準偏差の比較結果
Table 2 Comparison results of the STD (standard deviation) with field data on Ashigara S.A.

Date (Month, Day, Year)	A. N. N STD [%]	N. N STD [%]
May, 1, 91	2.312	2.482
May, 2, 91	6.416	6.678
May, 6, 91	6.542	7.115

しても良い結果を得た。また、標準偏差を用いた総合的な評価に関しては、N. N と比べて大きな差は生じていないが、検証に用いた3日間のいずれの日においても、A. N. N の応答が良い結果を得ている。

このように、A. N. N の駐車率推定能力およびその大きな特長である駐車率1.0近傍の追従性について、実測データに対してもN. Nより優れた結果をえることができ、A. N. N の実用上の可能性を十分得た。

5. 実用時の評価

上記のように、シミュレーション実験、実測データによる検証を通じて、駐車率推定に関するA. N. N の実用上における可能性を十分得た。この結果をもとに、この方式を東京外環道新倉P.A.に適用し、駐車率推定型駐車状況検出システムの実用化を行った。

図10は新倉P.A.の平面図を示しており、中央の休憩施設を挟んで左側が小型車駐車領域(小型車64台駐車)、右側が大型車駐車領域(大型車20台駐車可能)である。この図のハッチング部分が画像処理型検出装置¹⁶⁾の監視範囲で、小型車領域では46.9%、大型車領域で69.5%の監視率となっている。このような、部分的監視範囲から全体駐車率を推定することになる。な

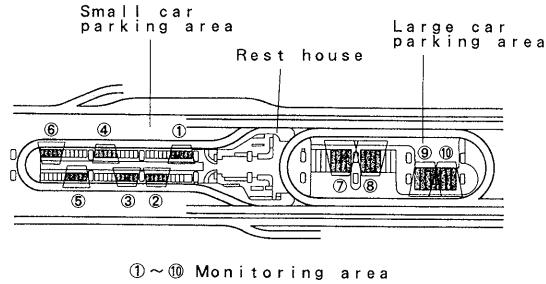


図10 新倉P.A の平面図
Fig. 10 Plane of Niikura P.A.

お、この図の台形枠のそれぞれが部分駐車率の検出箇所となり、小型車領域で6箇所、大型車領域で4箇所の部分駐車率を検出している。また、このP.A.は上下線共用であり、入出路が複雑であることと、装置の設置上の問題から上記足柄S.A.のような入出車台数をとらえるTVカメラが設置できなかった。そこで、A. N. Nへの入力情報を強化するため、検出装置からの結果を総合することで、(全監視範囲内の駐車台数)/(全監視範囲内のマス数)を小型車領域、大型車領域それぞれに求め、入力情報として加えることとした。つまり、入力層のニューロン数は小型車領域用として7個、大型車領域用として5個となる。また、中間層のニューロン数は上記足柄S.A.での構成と同様に、入力層のニューロン数より1個多い形とした。結局、A. N. Nの構成としては小型車領域用として7-8-1、大型車領域用として5-6-1とした。

学習用データの収集に関しては、システム導入前の1993年11月13日、14日の2日間に行い、小型車領域76パターン、大型車領域50パターンを収集した。この

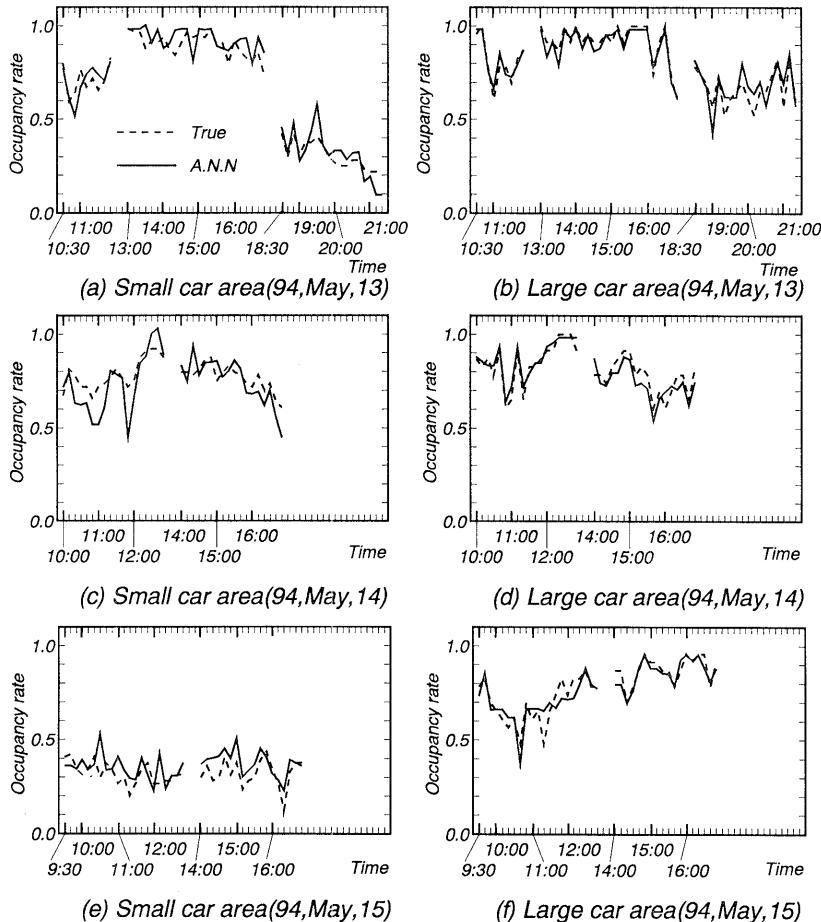


図11 新倉 P. A における検証結果
Fig. 11 Verified results on Niikura P. A.

データを教師データとして学習を行った。この学習について、現地での学習時間をできるだけ短くすることを考慮し、学習係数は 0.5、最終誤差量は 0.05 になるまで学習した。この時の学習回数は小型で 20,834 回、大型で 4,598 回となった。この学習結果の重みをもとに、1994 年 5 月 13 日、14 日、15 日に再度データ収集を行い、システム導入後の評価を行うこととした。なお、このデータは各日とも 10 分間隔で収集され、5 月 13 日が 51 パターン、14 日が 36 パターン、そして 15 日が 39 パターンの計 126 パターンで、小型車、大型車領域で同時に実行していることから、全パターン数はその 2 倍の 252 パターンとなった。このオープン状態のデータを用いた検証結果を図 11 に示し、式 (9) の標準偏差の算出結果を表 3 に示す。なお、図 11 中点線は真値、実線は A. N. N での推定結果であり、縦軸は駐車率、横軸はデータの計測時間である。この図 11 からわかるように、A. N. N での推定が真値に良く追従して

表 3 新倉 P. A における検証結果

Table 3 Verified results of the STD with field data on Niikura P. A.

Date (Month, Day, Year)	Small car area STD [%]	Large car area STD [%]
May, 13, 94	7.010	5.109
May, 14, 94	9.416	4.999
May, 15, 94	7.745	5.364

ている。また、表 3 から明らかなように、各日、各領域において真値からの標準偏差がパーセント駐車率で 10% 以内となっており、上記足柄 S. A での結果と同様、実用時においても良い結果を得た。なお、この結果において、小型車領域での STD が大型車領域のそれと比べて悪くなっている。これは、小型車領域での監視率が大型車領域に比べ 20% 以上低いためと考えられる。元来、監視率を増やせば全体駐車率との相関は高くなり、推定精度はより良い方向になることが十

分予想され、その意味では最適な監視率の選択も今後検討する必要がある。また、学習回数についても同様のことが生じている。この点においては、我々が前回報告⁸⁾したように、全体の状況と対象とした部分領域の相関の強さにより学習回数が早くなることにより説明できる。ただし、学習回数については、対象とした学習パターン数に26パターンの差があり、その影響も受けているものの、学習回数自体は4.5倍以上の差があることから、やはり、監視率が少ない分全体との相関も弱く、その影響を受けているものと考えられる。

このように、小型車領域での推定結果が大型車領域での結果に比べて若干悪くなっているものの、総合的に評価すれば、3日間いずれの日もSTD値が10%以下となり、十分な結果を得ている。なお、このシステムは1994年3月28日から運用を開始しており、現在も順調に稼働している。また、管理側からの評価についても別に報告をしており、実用上においても問題なく運用されている¹⁶⁾。

6. おわりに

N.Nを用いた駐車状況推定に関して、システム導入後の判定基準値の変更時に生じる学習データの再収集問題を発端として、将来の情報提供形態の変化も考慮した駐車率の直接推定方法について検討した。この中では、出力層のニューロン数を1個とし、アナログ的な推定を行う形態を示した。そして、推定対象である駐車率が[0,1]の実数であり、その最大、最小値が1.0, 0.0であることから、一般的N.Nの応答閾値ではその極値が出力されにくい点を述べ、応答閾値としてリニア閾値を用いたA.N.Nを提案した。このA.N.Nの能力を評価するため、sin関数を用いたシミュレーション実験を行い、N.Nに比べA.N.Nでの極値における応答性が非常に良いことを示した。また、A.N.Nの実用上における可能性を検証するため、以前、我々が収集した足柄S.Aでの実測データを用いてN.Nとの比較を行ったところ、シミュレーション実験同様、駐車率のピーク点における応答性の良さを示すことができた。そして、定量的な評価方法として、真値からの標準偏差を算出したところ、N.N, A.N.Nともにパーセント駐車率で10%以内の精度を得た。このように、総合的な精度としては両者とも同じような結果となったものの、評価に用いた全ての日でA.N.Nの精度が良くなる結果を得た。更に、この結果をもとにして、東京外環道新倉P.Aにこの駐車率推定システムを構築し、実用化を行った。そして、このシステムの導入後の評価を行い、5月13日～15日の3日間、252パ

ターンのデータに対し、足柄S.Aでの結果と同様、真値からの標準偏差で10%以内の結果を得ることができ、足柄S.A, 新倉P.A 2つの全く異なる駐車場で良い結果を得ることができたことから、A.N.Nの駐車率推定が実用上も十分有効であることを示すことができた。以上のことから、ここで問題提起した導入後の基準変更に伴う学習用データの収集、再学習は単純な基準テーブルの変更で済み、更に、将来に向けての提供内容の変更等にも柔軟に対応していくことが可能となつた。

今後の課題としては、A.N.Nの中間層数、学習係数、学習回数等の各パラメータに関しては、試行により導いており、この駐車率推定における効率的なパラメータ決定方法を検討する必要がある。また、部分領域の監視率についても的確な方法を見いだしておらず、全体駐車率との相関を基本とした監視率決定法についても検討を要する。そして、このシステムを実際のフィールドに設置したことから、より多くの検証を繰り返し、追跡的な評価を行っていく必要があると考える。更に、A.N.Nは今回のような駐車率推定のみではなく、[0,1]以外のアナログ値に対しても、応用が可能であると考えられることから、他分野への積極的な応用も行っていく予定である。

謝辞 本研究を進めるにあたり、東京外環道新倉P.Aにおけるデータの収集、調査への協力および管理者としての貴重なご意見をいただきました日本道路公団水越信明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、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) 長谷川為春、小沢慎治：移動物体追跡を利用した屋外駐車場における車両計数、電子情報通信学会論文誌、Vol. J 76-D-2, No. 7, pp. 1390-1398 (1993).
- 4) 前田英作、高橋裕子、石井健一郎：環境変動によるバス停の物体有無判定法、電子情報通信学会論文誌、Vol. J 74-D-2, No. 12, pp. 1731-1740 (1991).
- 5) 上田浩次、堀場勇夫、池谷和夫、小野寺浩：画像処理を用いた駐車車両検出アルゴリズム、電子情報通信学会論文誌、Vol. J74-D-2, No. 10, pp. 1379-1389 (1991).
- 6) 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、電子情報通信学会道路交通研究会、RTA-91-14 (1991).

- 7) 上田浩次, 堀場勇夫, 池谷和夫, 小野寺浩: ニューラルネットワークを適用した駐車状況推定方法, 情報処理学会論文誌, Vol. 35, No. 2, pp. 281-290 (1994).
- 8) 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).
- 9) 西村和夫: ニューラルネットワーク応用の現状と今後の課題, 情報処理, Vol. 35, No. 6, pp. 541-542 (1994).
- 10) Rumelhart, D. E. and McClelland, J. L.: *Parallel Distributed Processing*, Vol. 1 and Vol. 2, MIT Press (1986).
- 11) 中野馨: ニューロンコンピュータ, 技術評論社 (1989).
- 12) 中内茂樹, 田井支朗, 三宅誠: 3層ニューラルネットによる色学習とその内部表現解析, 電子情報通信学会論文誌, Vol. 73-D-2, No. 8, pp. 1242-1248 (1990).
- 13) 入江文平, 川人光男: 多層パーセプトロンによる内部表現の獲得, 電子情報通信学会論文誌, Vol. 73-D-2, No. 8, pp. 1173-1178 (1990).
- 14) 林原香織, 山下雅史, 阿江忠: シグモイド関数の連続性/離散性とニューラルネットワークのマシン能力について, 電子情報通信学会論文誌, Vol. 73-D-2, No. 8, pp. 1220-1226 (1990).
- 15) 鈴木賢治, 上田浩次, 堀場勇夫, 池谷和夫: アナログ値予測用ニューラルネットワーク, 電気関係学会東海支部連合大会, 572, p. 286 (1992).
- 16) Mizukoshi, N., Horiba, I., Ueda, K. and Onodera, H.: Parking Condition Discrimination System of Image Processing Type Using a Neural Network Model (On Tokyo Ring Express Way Niikura Parking Area), *Vehicle Navigation & Information Systems International Conference*, A 2-5 (1994).

(平成6年9月19日受付)

(平成7年1月12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。



山田 宗男

昭和40年生。平成元年名城大学理工学部電気工学科卒業。平成2年名古屋電機工業(株)入社。現在、技術部開発課勤務。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、応用物理学会各会員。



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、日本医用画像工学会、日本循環器学会等各会員。



池谷 和夫

大正11年生。昭和20年東京工業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。同年名城大学理工学部電気電子工学科教授。平成6年同大学退職。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、騒音制御工学会、海洋音響学会、米国音響学会等の各会員。



鈴木 賢治

昭和43年生。平成3年名城大学理工学部電気電子工学科卒業。平成5年同大大学院修士課程修了。同年(株)日立メディコ入社。現在、技術研究所企画員。主に医用画像認識、人工知能に関する研究に従事。電子情報通信学会、日本循環器学会各会員。