ニューラルネットワークによるエレベータ交通流の検出[†]

岩田 雅史*・匹田 志朗**・駒谷 喜代俊*

Detecting Elevator Traffic Patterns with Neural Networks

Masafumi IWATA*, Shirou HIKITA** and Kiyotoshi KOMAYA*

Traffic control systems, like elevator group control systems, have the aim of improving their performance within limits of their resources, and they have to take specific control actions under particular traffic conditions. The origin-destination (OD) matrix is usually employed to represent traffic flows. While we have practical means to measure traffic counts, we cannot obtain the OD matrix directly from accumulated counts. Therefore, conventional elevator group control systems detect typical traffic patterns instead of estimating the OD matrix.

In this paper, we have proposed a detection system of typical elevator traffic patterns with neural networks. Inputs of the system are traffic counts, and outputs are feature modes of traffic. The advantage of our system is easy to apply any buildings without specific adjustments. Furthermore our system has robustness for stochastic fluctuations of input data. We have made some simulations and experiments using real traffic counts, and their results show the successful performance of learning and detecting elevator traffic patterns.

Key Words: neural network, traffic flow, traffic pattern, group control, elevator

1. はじめに

交通システムの制御は交通流に応じて円滑かつ効率よく人やものを輸送することを目的としている。また、交通流はFig. 1に示されるように通常は一日を周期として時刻とともに変化している。ここで、交通流とは交通の状態をあらわす測度であり、単位時間内に発生する交通の総量、発生間隔、OD (Origin and Destination) 行列によって記述できる時間の関数である。OD行列はある出発地からある目的地への交通の発生量を成分とする。複数のエレベータを1つの群として制御するエレベータ群管理^{1)~3)}においても、出勤時や昼食時などの交通流の変化に合わせて制御方法⁴⁾を変更する必要がある。

さて、一般に交通の発生総量と発生間隔は測定可能であるが、OD行列の測定は実用上は困難である。このため、交通流を推定する、あるいはその変化を検出することは交通システムの制御において重要な問題である。たとえば、各エレベータは重量センサーを備えており、各階の乗降客数を上下方向別に測定(この値を交通量と呼ぶ)できるが、OD行列を測定するためには乗客1人1人を追跡しなければならない。

Fig. 1 Elevator Traffic

そこで、交通流の変化を検出するために、時刻を用いる方法、特定の交通量データを用いる方法、複数の交通量データから定義された特徴ベクトルを用いる方法⁵⁾が従来から用いられてきた。ところで、エレベータの運行は交通流の変化だけでなく、乗降車のタイミングやスピードなどの確率的要素や群管理の影響を受けて変動する。そのため、特定の交通量データのみを用いて交通流の検出を行った場合、エレベータ運行の影響を受けて検出結果が変動することが予想される。また、用いる交通量データの種類を増加させると検出のアルゴリズムが複雑になり、調整が煩雑となり、実用的でないという問題点があった。

従来手法では、定量的な基準を与えて交通流の変化を検出

[†] 第36回自動制御連合講演会で発表(1993・10)

* 三菱電機(株)産業システム研究所 尼崎市塚口本町8-1-1

** 三菱電機(株)稲沢製作所 稲沢市菱町1

* Mitsubishi Electric Co., Amagasaki

** Mitsubishi Electric Co., Inazawa

(Received November 21, 1995)

(Revised October 24, 1996)

していたため、ビルの仕様と検出結果の使用目的に特化することが必要となり、上記の問題点が生じていると考えられる。本論文では、従来手法とは逆に、より一般的で簡易なアプローチを取ることににより、上記の問題点を克服できると考え検討を行った。具体的には、交通流の変化検出を交通流パターンのマッチング問題と考え、ニューラルネットワークがもつパターン学習・判別能力に着目して、エレベータ交通流の変化を検出する手法を提案する。本手法では、エレベータ交通流に見られるいくつかの交通流パターンと測定される交通量データとの関係を記述する交通流特徴モードを定義し、その特徴モードをニューラルネットワークで学習・判別する。また、本手法を用いることによりビルごとの調整を自動的に行うとともに、エレベータ運行の影響を受けにくい交通流の検出システムを構成できることを実測データとシミュレータを用いて明らかにする。

2. エレベータ交通流と交通流特徴モード

交通システムの制御には交通流の変化検出が必要であるが、交通流を観測することは実用上困難である。一方、交通量データの観測は可能であるが、交通量データから交通流を求めることは、変数の数に対して方程式の数が少ないため、唯一解が得られない。そこで、ある特徴を持った交通流の集合(交通流パターン)とそれに対応する交通量データの集合の関係を表す交通流特徴モードという概念を導入し、交通量データを入力として交通流特徴モードをサンプリング時刻ごとに判別することにより、交通流の変化検出を行うことを提案する。Fig. 2に交通流特徴モードの概念を示す。TFは交通流空間、TCは交通量空間、 $RTC \subset TC$ はエレベータの設置されたビルに実際に発生する交通量データの集合を表す。交通流パターンは、ある特徴を持った代表交通流 tf_i およびその近傍領域によって定義され、図中では TMF_i で表されている。このとき、 tf_i から発生するRTC上の交通量データ tc_i とその近傍領域 TMC_i の集合の関係を記述する交通流特徴モード TM_i を考え、その集合を TM とする。このとき TM は次式で表される。($i = 1, 2, \dots, M$: M は交通流特徴

Fig. 2 Traffic Feature Mode

モードの数)

$$TM_i = \{\text{label_}f_i, \text{label_}c_i\} \in TM \quad (1)$$

$$\begin{cases} \text{label_}f_i = f_{\text{label_}f}(TMF_i) \\ \text{label_}c_i = f_{\text{label_}c}(TMC_i) \end{cases},$$

$$\exists i, \forall j \neq i, \Rightarrow \begin{cases} \text{label_}f_i \neq \text{label_}f_j \\ \text{label_}c_i \neq \text{label_}c_j \end{cases}$$

ここで、 $\text{label_}f_i$ は TMF_i のラベル、 $\text{label_}c_i$ は TMC_i のラベルであり、 $f_{\text{label_}f}$ 、 $f_{\text{label_}c}$ はそれぞれ、 TMF_i 、 TMC_i のラベルを与える関数である。以上のように交通流特徴モード TM_i を定義すると交通流特徴モード判別の方式は入力を交通量データ $tmc_i \in TMC_i$ 、出力を TM_i とする、RTCから TM への(2)式で表される写像であると考えられる。

$$TM_i = f(tmc_i) \quad (2)$$

ところで、ここでの問題設定では特徴モード TM_i に対応する交通量データ tmc_i の例が用意できるため、ニューラルネットワークを用いて(2)式の写像 f を実現することが可能である。つまり、ビルごとに与えられる例題(各交通流特徴モード TM_i とそれに対応する交通量データ tc_i 、 tc'_i 、 tc''_i 、 $\dots$ 、 $\in TMC_i$)によってニューラルネットワークの学習が可能であるため、ビルごとの f の設定や調整を自動化できる。また、ニューラルネットワークの汎化能力により学習時に与えられた例題の入力に似た交通量データが入力された場合に例題と似た交通流特徴モードを出力することが可能である。そこでニューラルネットワークを用いて(2)式の写像 f を実現し、交通流特徴モードの判別を行なう方式を提案する。

3. 特徴モード判別システムの構成

3.1 ニューラルネットワークの構成

エレベータ交通流の特徴モードの判別に用いるニューラルネットワークの構成をFig. 3に示す。また、ニューラルネットの入出力関係は(3)式のように表される。

$$O(t) = f_{NN}(W, I(t)) = f_{NN}(W, tc(t)) \quad (3)$$

ここで、 $O(t) = \{O_1(t), O_2(t), \dots, O_M(t)\}$ 、 $I(t) =$

Fig. 3 Neural Networks

$\{I_1(t), I_2(t), \dots, I_N(t)\}$, であり, f_{NN} はニューラルネットワーク全体の入出力関数を, W はニューラルネットワークのシナプス結合荷重を表す.

まず, ニューラルネットワークの入力について考える. $I_i(t)$ は $i \in \{1, 2, \dots, N\}$ 番目の入力層ニューロンへの入力を表しており, 各階床別に方向別の乗車/降車人数の過去5分間の積算値を求め, さらにいくつかの階床を1つにまとめたゾーンごとに, それらの積算値の和を求めることにより与えられる. つまり, ゾーン数を K とすると, その要素の数は $N = 4K$ であり, $tc(t) = \{ \text{GetOn}(t, \text{up}, \text{zone}_j), \text{GetOn}(t, \text{down}, \text{zone}_j), \text{GetOff}(t, \text{up}, \text{zone}_j), \text{GetOff}(t, \text{down}, \text{zone}_j), \dots \}$ の形で表現される. ここで, GetOn は乗車人数, GetOff は降車人数, up は上方向に向かうエレベータ, down は下方向に向かうエレベータ, zone_j はゾーン j を表している. このような入力を与えることにより, 測定される交通量データをもれなく同時に扱うことができる.

一方, $O_k(t)$ は第 k 番目の出力層ニューロンの出力値であり, 出力層ニューロンと特徴モードは1:1で対応するため, 特徴モードの数 M 個だけ用意する. そして, 交通流特徴モード $TM(t) = TM_k$ に対する出力を $O_k(t) = 1.0$, $O_p(t) = 0.0 (\forall p \neq k)$ と定義し, バックプロパケーションアルゴリズムにしたがって学習を行う.

さて, ニューラルネットワークの出力は $(0, 1)$ の区間の任意の実数であり, 学習を行なった交通量データ以外のデータに対してニューラルネットワークの1つの出力だけが1.0となり他が0.0となることは稀である. そこで, ニューラルネットワークの出力値 $O_i(t)$ から交通流特徴モードを決定するために閾値フィルタを用意した. 閾値フィルタの出力 $TM^*(t)$ はニューラルネットワークの出力値 $O_i(t)$ があらかじめ設定した閾値 th よりも大きな場合にそのニューロンが表す特徴モード TM_i となる. ただし複数のネットワークの出力値 $O_i(t)$ が閾値 th を越えていた場合には特定不能 TM_{ns1} を, どの出力値 $O_i(t)$ も閾値 th を越えていない時には判別不能 TM_{ns2} を出力する.

3.2 シミュレーション実験

ここでは予備実験として, Fig. 3のニューラルネットワークによって交通流特徴モードの判別が可能であることを, 異なる交通流から発生させた交通量データを使って検証する. まず, Table 1に示す代表交通流を用いて, 早朝型特徴モード (P1), 出勤時ピーク型特徴モード (P2), 平常時型特徴モード (P3) を設定した. これより, 出力層ニューロンの数

は3個とする. また, ビルは3つのゾーンに分割し, 入力層ニューロンは12個用意した. なお, 出力層には最大10個の, 入力層には最大40個のニューロンを用意することを想定している. さて, 中間層の構成はニューラルネットワークを適用する問題の複雑さと, 汎化能力, 学習速度, 計算機リソースなどによって決定すべきである. ここでは, 次節以降に述べるシミュレーション実験ならびに実測データを用いた実験の結果, 2層の中間層にそれぞれ30個のニューロンを用意することが妥当であると判断した. なお, このほかにも14棟のビルの実測データについても検証を行ったが, 中間層の構成に問題はなかった. よって, 以下では中間層の構成は実装を簡易にするため, 前述の数に固定する. 次に, 各特徴モードごとに30分間のエレベータ交通のシミュレーションを行ない, サンプル時間を5分として交通量データを6個づつ, 合計18個作成して, ニューラルネットワークの学習を行った.

Tables 1, 2において, Arrival Rateは1時間あたりに発生する総乗客数を表す. また, OD Matrixの i, j 成分は乗客総数に対するゾーン i からゾーン j へ移動している乗客の百分率を表している. つぎに, 3つの特徴モードを補間するように, Table 2に示す交通流をP1, P2の間で5種類 (C1 ~ C5), P2, P3の間に5種類 (C6 ~ C10) を設定し, 先程の3つの代表交通流と合わせて13種類の交通流ごとに3時間のシミュレーションを行い, 各36個の交通量データを作成し, チェッキングデータとした. これらのチェックデータに対するニューラルネットワークの出力値の平均値を Fig. 4に示す. Fig. 4の結果より, ニューラルネットワークの判別結果がP1からP2, P3へと連続的に変化している. この結果より, 交通量データを入力とし, その交通量データに対応する交通流特徴モードを判別するニューラルネットワークを構成することが可能であり, そのネットワークは汎化能力を持つことがわかる.

Fig. 4 Simulation Results

Table 1 Learning Traffic-Feature-Mode

		P1	P2	P3
Typical Traffic Flows	Arrival Rate	50	1500	500
	OD	0 50 50	0 40 40	0 15 15
		0 0 0	0 5 5	15 10 10
	Matrix	0 0 0	0 5 5	15 10 10

3.3 交通流特徴モード判別システムの構成

ニューラルネットワークを使った交通流特徴モード判別システムの動作は判別フェーズと学習フェーズの大きく2つに分類できる.

Table 2 Checking Traffic

		C1			C2			C3			C4			C5		
Traffic Flows	Arrival Rate	100			250			500			750			1000		
	O-D Matrix	0	48	48	0	46	46	0	45	45	0	44	44	0	42	42
		0	1	1	0	2	2	0	2.5	2.5	0	3	3	0	4	4
		0	1	1	0	2	2	0	2.5	2.5	0	3	3	0	4	4
		C6			C7			C8			C9			C10		
Traffic Flows	Arrival Rate	1250			1000			800			750			600		
	O-D Matrix	0	36	36	0	32	32	0	29	29	0	26	26	0	22	22
		2	6	6	4	7	7	6	7.5	7.5	8	8	8	10	9	9
		2	6	6	4	7	7	6	7.5	7.5	8	8	8	10	9	9

3.3.1 判別フェーズ

判別フェーズは群管理と並行してオンラインで行なわれる。

Fig. 5 に判別フェーズにおけるシステムの構成を示す。判別

Fig. 5 System for Detecting Procedure

フェーズではエレベータから重量センサーを使って測定した交通量データ $tc(t)$ をニューラルネットワークに入力し、得られる出力 $O(t)$ を閾値フィルタに入力して $TM^*(t)$ を得る。同時に、交通量データ $tc(t)$ は、学習フェーズで用いるために交通量データベースに蓄えられる。さて、閾値フィルタの出力 $TM^*(t)$ として特定不能 TM_{ns1} 、判別不能 TM_{ns2} が検出された場合には、交通流特徴モードを選択できない。また、交通量データは乱数性が高いためサンプリング時間ごとに個別に特徴モードを決めていては、特徴モードがサンプリング時間ごとに変化するハンチング現象が生じる可能性がある。そこで、実用上の理由から、特定不能、判別不能を除去し、ハンチング現象を抑えるためにサブフィルタを用いる。サブフィルタでは閾値フィルタの出力 $TM^*(t)$ の時間的な前後関係や、ある時間に優先的に選択されるデフォルト特徴モードによって特定不能、判別不能が検出されたサンプル時刻に対する特徴モードを決定する。

3.3.2 学習フェーズ

学習はシステムがビルに設置後、一定期間ごとに、群管理とは関係なくオフラインで行なわれる。学習フェーズは学習サブフェーズと評価サブフェーズにわけられる。Fig. 6 に学習サブフェーズのシステム構成を示す。学習サブフェーズではまず、判別フェーズで蓄積された交通量データベースのデータから、代表交通流に対応する交通量データを選択し、学習データセットを作成する。なお、具体的な学習データの設定方法の例については4.2節で述べる。学習データセットは複数の入力信号(交通量データ)と出力に与える教師信号からなる。交通流特徴モード TM_i に対する教師信号 $Teach(TM_i)$

Fig. 6 System for Learning Procedure

は(4)式のように与える。

$$Teach(TM_i) = [T_1(t), T_2(t), \dots, T_M(t)] \quad (4)$$

$$\begin{cases} T_i(t) = 1, \\ T_j(t) = 0 \end{cases} \quad (\forall j \neq i, j \in \{1, \dots, M\})$$

ここで、 $T_i(t)$ は第 i 番目出力層ニューロンの出力 $O_i(t)$ に対する教師信号である。この教師信号を用いてバックプロパゲーションアルゴリズムに従い、(3)式の W を更新する。なお、 W の初期値はランダムに設定する。学習データは実測された交通量データから作成するが、その選択条件は実装を簡易にするために、ビルごとにその設定を変えることなく、画一的で定性的な条件とする。この場合、交通システムの確率的性質により、日によって観測される交通量データが異なるため、学習データに偏りが生じる場合がある。その結果、学習の際に出力層での誤差が十分に収束しない場合や、出力層の誤差が十分収束しても交通流特徴モードが選択できない場合がある。前者の場合、新たに学習したニューラルネットワークは破棄し、日を改めて次の機会に学習を行う。後者の場合、学習したニューラルネットワークの良否を評価サブフェーズで評価し、その時点で判別フェーズで使用しているニューラルネットワークに対する評価と比較する。この時、新たに学習したニューラルネットワークの評価値が、判別フェーズで使用中のニューラルネットワークの評価値に対して改善されていれば、判別フェーズで用いるニューラルネットワークの入れ換えを行う。改善が見られなければ、新たに学習したニューラルネットワークを破棄し、日を改めて次の機会に学習を行う。Fig. 7 に評価サブフェーズのシステム構成を示す。

Fig. 7 System for Evaluation Procedure

ここでは、交通量データベースに蓄えられたデータをニューラルネットワークに入力し、その出力を閾値フィルタで処理した時に発生する特定不能 TM_{sn1} と判別不能 TM_{sn2} の割合によってニューラルネットワークの評価を行なう。また、判別フェーズで使用中のニューラルネットワークに対しても同様に評価を行い、新たに学習したニューラルネットワークの評価と比較する。

4. 実測データを用いた交通流特徴モード判別方式の評価

4.1 実測データを用いた実験

システムの性能評価を行なう場合、実際に運用する場合と同じ条件で評価することが望ましいが、それが不可能な場合も多く存在する。そのような場合、シミュレーションによる実験で評価するケースが多いが、シミュレーションの精度が問題となり、シミュレーションで得られた性能が実システムでは得られない場合も多い。

今回、ここで提案している交通流の検出方式も、実際の交通流は時間と共に変化しており、測定可能な交通量データはエレベータ運行の影響を受け変動する。そのため、シミュレーションによる実験では、実際のエレベータでの挙動が予測しにくい。そこで、我々は Table 3 で示す3種のオフィスビルで実際に運用されているエレベータについて交通量データを測定し、それらを用いて、以下の節で説明する4種の実験により交通流特徴モード判別方式の評価を行なった。

Table 3 Building Specific Data

Building	A	B	C
Number of Floors Above Ground	9	15	17
Number of Basements	2	1	1
Number of Cars	6	6	6
Maximum Traffic Counts in the Morning (passengers/5minute)	180	134	80

4.2 実測データによる交通流特徴モード判別

本節では、3章で提案した交通流特徴モード判別方式により実測データの判別実験を行う。ここでは出力として、早朝モード、出勤時モード、平常時モードの3つの交通流特徴モードを持つニューラルネットワークを用意し、交通流特徴モードの判別結果を示す。実測データは Table 3 のオフィスビルAの午前中(7:00 - 11:00)データを用いる。実験は次の手順で行なう。

Table 4 Traffic Flow Feature Mode and Teaching Data

Traffic Feature Mode	Characteristics of Traffic Flows
Slack Time	Traffic Counts : Small Main Traffic Flow : Up
Up-peak	Traffic Counts : Large Main Traffic Flow : Up
Morning interfloor	Traffic Counts : Medium Main Traffic Flow : Interfloor

- 実測データを月曜日から金曜日までの5日分用意する。
- 5日分の実測の乗降客数データをサンプル時間5分、サンプル周期5分でゾーンごとに積算し、学習フェーズ用の交通量データを作成する。なおゾーンは、地下ゾーン、主階床ゾーン(1F)、上方階ゾーン(1F以上)の3つに分割した。この分割方法は Table 3 のビルに共通である。
- 上記のデータのうち、月曜日のデータから Table 4 に示す条件で、1つの特徴モードに対して、5~10個程度の教師データを選択する。なお、数種類オフィスビルの実測データを用いた実験に基づいて、共通の教師データ選択条件を決定した。よって、Table 4 の選択条件が一般的なオフィスビルに対して利用できると考える。
- ニューラルネットワークの構成は前節の実験と同様入力層ニューロン12個、出力層ニューロン3個、中間層は2層とし、それぞれ30個のニューロンを用意した。
- 教師データを使って、ニューラルネットワークを学習する。学習は2000回で終了とする。
- 学習終了後、先に作成した学習フェーズ用交通量データを順次ニューラルネットワークに入力し、その出力を閾値フィルタで処理した際に発生する、特定不能、判別不能の割合を求める。
- 次に、実測の乗降客数データをサンプル時間5分、サンプル周期1分でゾーンごとに積算し、判別フェーズ用の交通量データを作成する。
- 判別フェーズ用交通量データを使って、1分ごとの交通流特徴モードの判別を行なう。

以上の手順でニューラルネットワークの学習を行なった結果、教師データ全体に対する出力誤差の二乗平均は0.005746まで収束し、その時の5日分の学習用フェーズ用交通量データを判別した結果発生した特定不能・判別不能の割合は0.833%であった。このネットワークを用いて、教師データを作成した日とは別の日(金曜日)の判別フェーズ用データの判別結果を Fig. 8 に示す。

また、判別結果は示さないが、オフィスビルB、Cについても2000回の学習回数で出力誤差の二乗平均を0.006以下まで収束させることが可能であり、その時の5日分の学習用フェーズ交通量データを判別した結果発生した特定不能・判別不能の割合は1%以下であった。以上より、ニューラルネットワークが実測データに対して交通流特徴モードの学習と判別が可能であることが示された。この結果から、実際のエレ

Fig. 8 Result of Detecting Morning Traffic Flow

ベータ交通においても本方式によって、交通流特徴モードの学習と判別が可能であると考えられる。

4.3 再現シミュレーションを用いた交通流特徴モードの判別

従来、エレベータ交通のシミュレータにおいて、交通流はODや交通量によって決め、それを入力としてシミュレーションを行なっていた。そのようなシミュレータにおいては交通流が定常状態にあるシミュレーションは可能であるが、既に述べたように実際のエレベータ交通においては交通流は一日周期で変化している。そこで、匹田ら⁶⁾は実測データをもとにエレベータ交通を再現し、シミュレーションを行なう手法を提案している。この再現シミュレーション手法により、実際のビルで発生している交通流の変化に即した、時間変動のある交通量データの作成が可能となる。

この節では、再現シミュレーションによる交通量データに対する交通流特徴モードの判別結果と実測の交通量データを用いた判別結果の比較を行う。ニューラルネットワークは4.2節で学習を行なったものを用いる。ここでは、検出結果のうちTable 3の3つのオフィスのそれぞれ5日間のデータに対する出勤時モード開始時刻をTable 5に示す。Table 5に示した結果において、実測データに対する判別結果と再現シミュレーションによる交通量データに対する結果にほとんど違いがみられない。よって、交通流特徴モード判別方式の評価を行なう上で、再現シミュレーションは十分正確であ

Table 5 Results of Comparison Between Real Counted Data and Reproduced Simulation Data

Building	Data	Starting Time of Morning Up-peak				
		Mon	Tue	Wed	Thu	Fri
A	Counted	8:01	7:57	8:02	8:04	8:06
	Reproduced	8:01	7:58	8:02	8:03	8:06
B	Counted	8:11	8:11	8:11	8:13	8:12
	Reproduced	8:11	8:11	8:17	8:13	8:12
C	Counted	7:58	7:58	8:02	7:59	7:59
	Reproduced	7:56	7:58	8:02	7:59	7:58

ると考えられる。

4.4 交通流特徴モード判別方式のロバスト性

すでに述べたように、エレベータ運行は交通流の変化以外にも、乗降車のタイミングやスピードなどの確率的要素や群管理の影響を受け、その結果、本方式の入力である交通量データが変動する。そこで、その変動が特徴モードの判別結果に与える影響について検証する。実験では同じ交通流のもとでエレベータ運行を変動させるために、シミュレーションの条件をTable 6に示す12種類用意し、同じ乗客発生データを用いてそれぞれの条件下で再現シミュレーションを行った。これらシミュレーションによって得られる交通量データについての交通流特徴モードの判別結果は等しくなることが望ましい。この実験をTable 3の3種類のオフィスの5日分のデータと4.2節で学習を行なったニューラルネットワークを用いて行った。Fig. 9にオフィスビルAの火曜日

Table 6 Conditions of Reproductive Simulation Experiments

Conditions	i	ii	iii	iv	v	vi
Number of Cars	4	6	8	4	6	8
Parking Policy A	×	×	×	○	○	○
Parking Policy B	×	×	×	×	×	×

Conditions	vii	viii	ix	x	xi	xii
Number of Cars	4	6	8	4	6	8
Parking Policy A	×	×	×	○	○	○
Parking Policy B	○	○	○	○	○	○

Elevators park at a lobby floor with the parking policy A, and park at a heavy demand floor with the parking policy B.

Fig. 9 Results of Detecting Typical Traffic Patterns

のデータを用いて行った、実験条件 iv, v, vi の交通量データと特徴モードの判別結果を示す。交通量データは実験条件によって変化しているが、判別結果にはほとんど違いが見られないことがわかる。また、各ビルにおける出勤時モードの選択開始時刻の分単位の標準偏差を5日分のデータについて求め、その平均値を **Table 7** に示した。この表の結果より出勤時モード選択開始時刻の変動ほとんどないことがわかる。

本節での結果は次のように考察できる。待機方法の変更と設置台数の変更により、エレベータの運行が影響を受け変化し、その結果交通量データも変動する。本方式では入力が交通量データであるため、エレベータ運行の影響を受けることが予想されるが、シミュレーション結果よりその影響は小さいことがわかる。これは、入力データとして測定可能な交通量データをもれなく利用し、さらにニューラルネットワークによりそれらを並列に扱うことによって、エレベータ運行による交通量データの変動に対してロバストな交通流検出方式を実現することが可能となったと考えられる。

Table 7 Average of Standard Deviation of The Time When Up-Peak Traffic Pattern Started

Building	A	B	C
Average of Standard Deviation	0.378	0.900	0.342

5. 結 論

本論文では、各階ごとの上下方向別の乗降客数を入力としてニューラルネットワークを用いて交通流の特徴モードを判別することにより、エレベータ交通流の変化を検出する手法を提案し、シミュレーション、実測データ、再現シミュレーションにより本方式の有効性を検証した。シミュレーションによる実験では、ニューラルネットワークを用いて交通流をいくつかのパターンに分類可能であることを示した。複数のビルにおける実測データを用いた実験では、実際のエレベータ交通においても本方式により、ビルごとの調整をすることなく、交通流の検出が可能であることを示した。さらに、再現シミュレーションにより本方式が、エレベータ運行による交通量データの変動に対してロバストであることを示し、ニューラルネットワークを用いた交通流特徴モード判別方式が実用上有効であることを明らかにした。

また、ここではエレベータ群管理への応用について述べたが、本方式は鉄道システムや道路交通システムなど他の交通システムへの適用も可能であると考えられる。

本研究にあたり、ご指導、ご助言をいただきました関係者各位に謝意を表します。

参 考 文 献

- 1) 匹田他：エキスパートシステムを応用したエレベータ群管理システム AI2100, 三菱電機技報, **63-2**, 54/57 (1989)
- 2) S.Tsujii, M.Amano, S.Hikita: Application of the Expert System to Elevator Group-Supervisory Control, Proc. the fifth Conf. on Artificial Intelligence Applications, 288/294

(1989)

- 3) M.Amano, M.Yamazaki, H.Ikejima: The Latest Elevator Group Supervisory Control System, ELEVATOR TECHNOLOGY 6, Proceedings of ELEVCON '95, 88/95 (1995)
- 4) 匹田, 駒谷: エレベータ群管理における出勤時運転について, 計測自動制御学会論文誌, **31-11**, 1896/1904 (1995)
- 5) 黒沢他: エレベータの知能群管理方式 - その2 学習理論 -, 情報処理学会論文誌, **28-3**, 299/308 (1987)
- 6) 匹田, 駒谷: 実測データに基づくエレベータ群管理シミュレーション環境, 第34回計測自動制御学会学術講演会予稿集, 991/992 (1995)
- 7) 岩田, 駒谷, 匹田: ニューラルネットワークを用いたエレベータシステムにおける交通流特徴モードの判別, 第36回自動制御連合講演会予稿集, 285/286 (1993)
- 8) M.Iwata, S.Hikita, K.Komaya: A Study of Traffic Estimation Using Neural Networks, 4th International Conference on Application of Advanced Technologies in Transportation Engineering, 93/99 (1995)

[著 者 紹 介]

岩 田 雅 史 (正会員)

1992年神戸大学大学院工学研究科計測工学専攻修士課程修了。同年三菱電機(株)入社。現在、産業システム研究所に勤務。エレベータシステムに関する研究に従事。計測自動制御学会、システム制御情報学会会員

匹 田 志 朗 (正会員)

1984年大阪大学大学院工学研究科精密工学専攻修士課程修了。同年三菱電機(株)入社。現在、稲沢製作所勤務。主としてエレベーター管理システムの開発に従事。計測自動制御学会、システム制御情報学会、電気学会などの会員。

駒 谷 喜 代 俊 (正会員)

1979年京都大学大学院工学研究科電気工学専攻修士課程修了。同年三菱電機(株)入社。現在産業システム研究所に勤務。工学博士。システム工学、知識工学の交通システムなどへの応用に関する研究に従事。計測自動制御学会、情報処理学会、電気学会、IEEEなどの会員。