

ニューラルネットワークを用いたコンクリート実験のデータ解析に関する研究

関口 司*・魚本健人**・高田良章***・
渡部 正****

コンクリートの促進中性化試験及び練り混ぜ試験の結果に対して、ニューラルネットワークを用いたモデルを考え、従来からの提案式の代用や影響因子の推定についての可能性を検証した。その結果、ニューラルネットワークを用いた本手法はそれらの事柄に対して有効であることが確認できた。これは、ニューラルネットワークの特徴である柔軟さや学習機能の有効性が、十分に発揮されていることを示すものである。

Keywords : neural network, analysis, experimental data, carbonation, mixing

1. はじめに

コンクリート工学は、多くの実験や現場での施工における過去の膨大な知識、ノウハウの蓄積の上に成り立っているといつても過言ではなく、そこから導き出された経験式も数多く存在する。これは、コンクリートの特性上避けることができない不確定性の要素が多く含まれているためであると考えられる。したがって、コンクリートの品質特性値を評価する場合においても、不確定性を考慮した処理法が有効かつ合理的であると判断される。

近年、あいまいさを含むデータの取り扱いに対して、人間の脳の中で行われている情報処理を模擬したニューラルネットワークの研究が盛んに行われている。この手法では、強い論理的なつながりを持たずに、情報を広く分散して表現しているため、あいまい性を含んだデータ処理が可能である。このような特徴を生かして、文字認識や音声認識、ロボットの制御など様々な分野においてその応用が試みられている。

そこで本研究では、コンクリートの促進中性化試験と、練り混ぜ試験によって得られたそれぞれの結果に対して、ニューラルネットワークを用いたモデルを考え、従来からある経験式の代用や、影響因子の推定の手がかりを得ることの可能性について検証する。

2. ニューラルネットワーク

(1) ニューラルネットワークの原理

従来のコンピュータは、逐次直列処理を用いて論理的思考を追究してきた。そのため、人間の能力をはるかにしのぐ、緻密で正確な情報処理が可能である。しかしそ

の一方で、人間が普段行っている行動を従来型のコンピュータを使って実現しようとすると、融通が効かないために大変複雑で事細かなプログラムが必要となり、また、その限界も指摘されている。

この欠点を補うために、脳における情報処理を模擬して考え出されたのがニューラルネットワークである。これは従来のコンピュータとは全く違った情報処理方法であり、内部では多数のプロセッシングエレメントが同時に動作して並列型処理を行う。これら内部のエレメントは、強い論理的なつながりを持たずに情報を広く分散して表現しているため、論理的に厳密な処理には必ずしも適していないと考えられるが、“あいまい性”を含んだ情報の処理、例えば、類推や連想処理といったことに適している。しかも、これまでのコンピューターと違い、複雑なプログラムを考える必要がない。あらかじめ学習データを用意してやり、入力に対してネットワークが输出する結果の正誤をフィードバックしてやる事で、ネットワークは内部の論理的なつながりを徐々に変え、正しい結果が出るように学習していく。このため、新しい事柄を取り入れ、情報の体系を少しずつ変えていくことや、入力される情報が不完全であっても、それを補っていく“柔らかさ”を持つことができる。

(2) 形式

人工的な脳細胞のモデルとして、通常図-1に示されるような多入力、1出力の素子が用いられ、ユニットと呼ばれる。ユニット間は神経繊維に対応する線で結ばれるが、信号は一方向にだけ伝わり、ある重みをつけられて結合されたユニットに入力される。この重みの大きさによって、ユニット間の結合の強さが表わされる。重みをつけられたそれぞれの入力値は、総和がとられてしまい値をひいた後、応答関数（本研究ではシグモイド関数を用いた。図-2参照）による変形をうけて出力される。また、結合の重みの値やしきい値は学習によって変化さ

* 正会員 工修 東日本旅客鉄道（株）東京工事事務所
(〒151 東京都渋谷区代々木2-2-6)

** 正会員 工博 東京大学生産技術研究所教授

*** 正会員 藤沢薬品工業（株）筑波コンクリート研究所研究員

**** 正会員 前田建設工業（株）技術研究所主任研究員

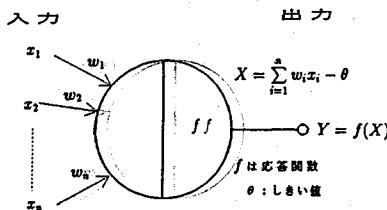


図-1 ユニット

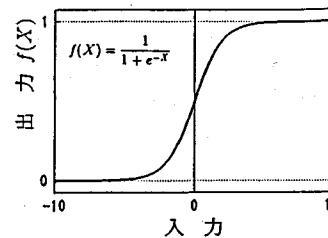


図-2 シグモイド関数

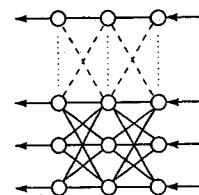


図-3 階層型ネットワーク

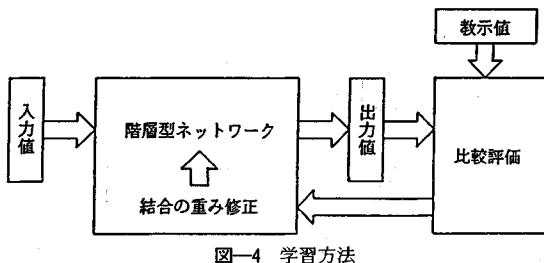


図-4 学習方法

せることができる。このような処理要素であるユニットをネットワーク状に結び付けて、情報処理を行わせる。本研究で用いたモデルは、図-3に示した階層型と呼ばれるもので、左側の入力層から右側の出力層へ信号が伝わるものである。

(3) 学習方法^{1)～5)}

本研究で用いる階層型ネットワークに関しての代表的な学習のメカニズムを以下に示す(図-4参照)。

入力層にあるパターンを入力すると、その時点でのユニット間の結合の重みの値に従ってある値が出力される。この出力値とあらかじめ与えられている教示値との二乗誤差を評価関数として、ユニット間の結合やしきい値の修正に用いる。しきい値の学習については、常に値-1をとるユニットを一つ用意し、それとの結合を作つておくことで、ユニットの結合の学習と同様に扱うことができる。

いまユニット j に関して

$$[\text{入力}] \quad u_j = \sum_i w_{j,i} x_i - \theta_j \quad (1)$$

$$[\text{出力}] \quad y_j = f(u_j) \quad (2)$$

$$f(u_j) = \frac{1}{1 + e^{-u_j}} \quad (3)$$

ただし $w_{j,i}$: ユニット i との結合の重み

x_i : ユニット i からの入力

θ_j : しきい値

を考える。このとき、次のような誤差関数を考える。

$$E = \frac{1}{2} \sum_{j,c} (y_{j,c} - \hat{y}_{j,c})^2 \quad (4)$$

$\hat{y}_{j,c}$: ある入力ベクトル c に対してユニット j が输出すべき望ましい値

$y_{j,c}$: ある入力ベクトル c が与えられたときのユニット j の実際の出力

パラメータで微分してその最急降下方向である gradient 方向にパラメータを変更するという、最急降下法を用いて、各重みを

$$\Delta w_{j,i} = -\varepsilon \frac{\partial E}{\partial w_{j,i}} \quad (\varepsilon > 0) \quad (5)$$

ずつ変化させていけば、 E の極小値を求めることができます。このときのアルゴリズムは

$$\frac{\partial E}{\partial w_{j,i}} = \sum_c \frac{\partial E}{\partial y_{j,c}} \frac{\partial y_{j,c}}{\partial u_{j,c}} \frac{\partial u_{j,c}}{\partial w_{j,i}} \quad (6)$$

$$\left\{ \begin{array}{l} \frac{dy_{j,c}}{du_{j,c}} = f'(u_{j,c}) \\ \frac{\partial u_{j,c}}{\partial w_{j,i}} = y_i \end{array} \right. \quad (7)$$

$$\frac{\partial u_{j,c}}{\partial w_{j,i}} = y_i \quad (8)$$

$$\Delta w_{j,i} = -\varepsilon \sum_c \frac{\partial E}{\partial y_{j,c}} f'(u_{j,c}) y_i \quad (9)$$

となる。すべての入出力パターンが与えられた後にはじめて結合の重みを変化させることになるが、 ε が十分に小さければ各入出力が与えられるごとに結合の重みを反復的に変化させても全体の変化量は最急降下法とほぼ等しくなる。

$$\Delta w_{j,i} = -\varepsilon \frac{\partial E}{\partial y_{j,c}} f'(u_{j,c}) y_i \quad (10)$$

このように、評価関数の形があらかじめわかっていない場合でも、各データが得られるごとに、そのデータに関して最急降下することを繰り返すと、学習は平均的に最適なところに収束する。この方法は確率的降下法と呼ばれるものである。

出力層のユニットにおいては、

$$\frac{\partial E}{\partial y_{j,c}} = (y_{j,c} - \hat{y}_{j,c}) \quad (11)$$

$$f'(u_{j,c}) = \frac{e^{-u_{j,c}}}{(1 + e^{-u_{j,c}})^2} = y_{j,c}(1 - y_{j,c}) \quad (12)$$

であるから

$$\Delta w_{j,i} = -\varepsilon (y_j - \hat{y}_j) y_i (1 - y_i) y_i \quad (13)$$

$\frac{\partial E}{\partial y_j}$ は簡単に求まる。一方、中間層のユニットにおいては、 $\frac{\partial E}{\partial y_j}$ が簡単には求まらない。そこで、ネットワーク

における第 k 層のユニットの $\frac{\partial E}{\partial y_i^{(k)}}$ を求めることを考える。

$$\begin{aligned}\frac{\partial E}{\partial y_i^{(k)}} &= \sum_i \frac{\partial E}{\partial y_i^{(k+1)}} \frac{dy_i^{(k+1)}}{du_i^{(k+1)}} \frac{\partial u_i^{(k+1)}}{\partial y_i^{(k)}} \\ &= \sum_i \frac{\partial E}{\partial y_i^{(k+1)}} f'(u_i^{(k+1)}) w_{i,j}^{(k+1)} \dots \quad (14)\end{aligned}$$

$\frac{\partial E}{\partial y_i^{(k+1)}}$ は前回計算済み（誤差が後ろから前へ伝播する）であるから $\frac{\partial E}{\partial y_i^{(k)}}$ は求まる。つまり誤差が順次、出力層の側から入力層の側へ逆に伝播していく。この三乗誤差最小化の学習を、多層のネットワーク全体の学習に用いるための学習アルゴリズムが、バックプロパゲーションと呼ばれるもので、階層型ネットワークの学習則として、現在盛んに用いられているものである。

実用上の問題となることは、学習1回あたりの重みの修正量などの学習定数、中間層のユニット数や中間層の層数などの合理的な決め方が、現在のところ明らかになっていないことである。

3. 促進中性化試験結果への適用

(1) コンクリートの中性化

通常、コンクリートは高いアルカリ性を示すが、長年の供用に伴い、大気中の炭酸ガスがコンクリート中へ拡散して、中性化が表面から内部へ徐々に進行する。この中性化の進行を予測する提案式は種々あるが、その中最も一般的に用いられているのが、次式の \sqrt{t} 則と呼ばれるものである。

$$X = k\sqrt{t} \dots \quad (15)$$

ここで X : 中性化深さ

t : 経過時間

k : 中性化速度係数

一方、コンクリートの耐久性を早期に評価する目的で、炭酸ガス濃度や温度を高めた促進中性化試験が行われている。しかし、自然環境下における中性化の進行との対応が十分明らかになっていないため、同一試験内での相対的な比較にとどまっている。このため、炭酸ガス濃度、温度や湿度などを含めた中性化速度式の導出が望まれるところである。

(2) 既往の研究

魚本らによる研究⁷⁾では、中性化に影響を及ぼすと考えられる代表的な要因として、水セメント比、促進温度、炭酸ガス濃度をとりあげ、それらと中性化速度の関係を明らかにしようと試みている。まずははじめに、促進中性化試験結果においても \sqrt{t} 則がほぼ成立することを確認した後、中性化速度係数が、促進温度、水セメント比、炭酸ガス濃度の関数で表せるものと仮定して、実験結果及び既往の論文からのデータから、次のような式を提案

している。

$$\begin{aligned}X &= (2.804 - 0.847 \log C) \times e^{(8.748 - \frac{2563}{T})} \\ &\times (2.39W^2 + 44.6W - 3980) \times 10^{-4} \times \sqrt{Ct} \dots \quad (16)\end{aligned}$$

ここで X : 中性化深さ (mm)

C : 炭酸ガス濃度 (%)

T : 絶対温度 (K)

W : 水セメント比 (%)

t : 経過時間 (週)

(3) ネットワークの適用 (I)

a) 推定モデル

まず最初にニューラルネットワークを用いて、前述の研究での提案式と同様、温度、水セメント比、炭酸ガス濃度の3個の要因から、中性化速度係数の推定を行うことができるかを検証する。前述の提案式を決めるために用いたのと同じデータを使って、ネットワークに学習を行わせる。データは合計150個で、20種類以上の既往の論文から集められたものである⁷⁾。なおこれらのデータは普通ポルトランドセメントを使用したものに限定しており、温度10°C~40°C、水セメント比30%~80%、炭酸ガス濃度0.07% (自然環境下)~100%の範囲のものである。これらのデータより、入力として (温度、水セメント比、炭酸ガス濃度) の3個を与え、中性化速度係数を出力させる。ただし、養生条件、湿度など他の要因の影響や実験誤差が存在するため、上記の3個の入力の数値がそれぞれ同じデータについては、中性化速度係数を平均をして教示値とした。その処理をした結果、71個の学習データとなった。図-5に示すようにネットワークは3層とし、入力層3個、中間層6個、出力層1個で学習を行わせた。

b) 結果と考察

学習が進み、収束がほぼ止まったところでネットワークの動作の様子を確認した。学習1回あたりの重みの修正量など、学習のさせ方を変えて行った学習結果の1例 (学習回数80 000回) を示す (表-1、図-6参照)。

また、学習により得られたネットワークで、処理をする前の150個のデータに対する推定を行い、先の提案式による推定の結果と比較する (表-2)。この結果、今回対象とした実験結果の範囲内においては、ニューラルネットワークを用いて推定した方が、提案式よりも良い結果を示すことが分かった。

次に、要因として選んだ3個の変数 (温度、水セメント比、炭酸ガス濃度) のうち、2変数を固定し1変数を少しずつ変化させた場合、および1変数を固定し、他の変数を変化させた場合のネットワークによる中性化速度係数の推定値の変化のしかたの例を示す。グラフ中の凡例は、 T : 温度 (°C)、 W : 水セメント比 (%)、 C : 炭

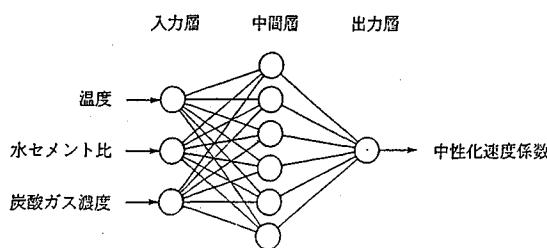


図-5 ネットワークモデル（I）

表-1 教示結果（入力3）

データ数	71
平均二乗誤差	0.7364
相関係数	0.9570

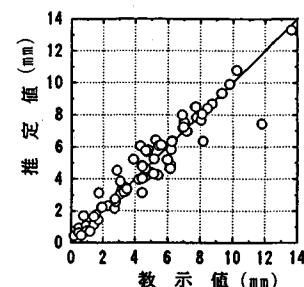
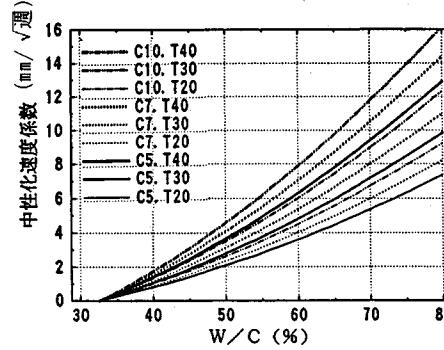
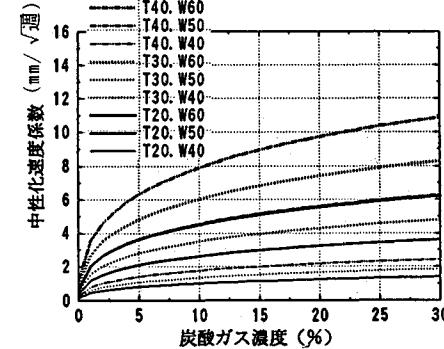
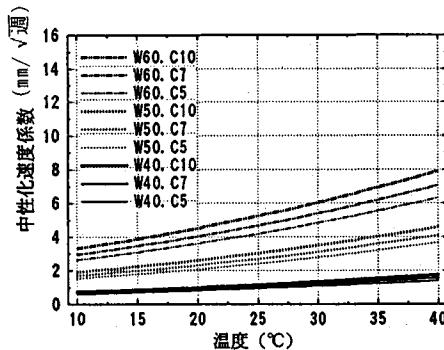
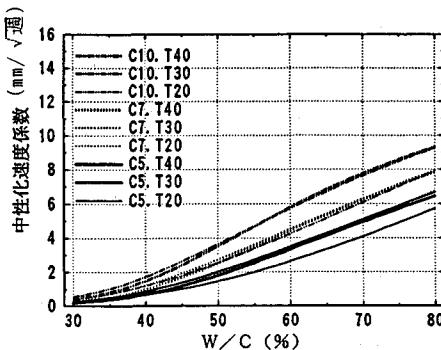
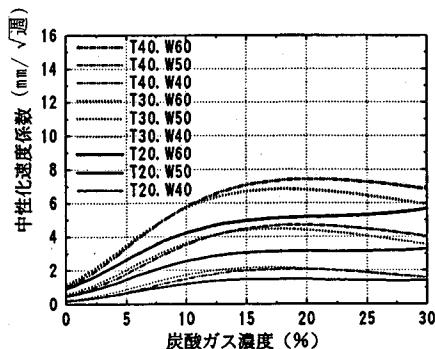
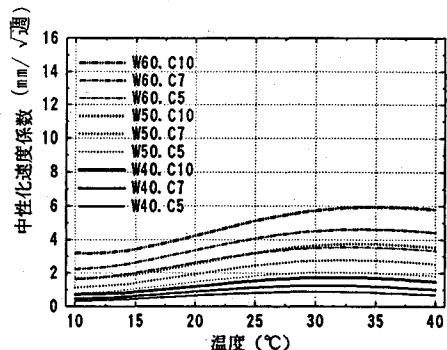


図-6 推定結果（I）

表-2 推定結果の比較（I）

データ数	ネットワーク	提案式
150	1.3823	1.7244
相関係数	0.8878	0.8572



ネットワーク

提案式

図-7 推定値の変化（2変数固定）

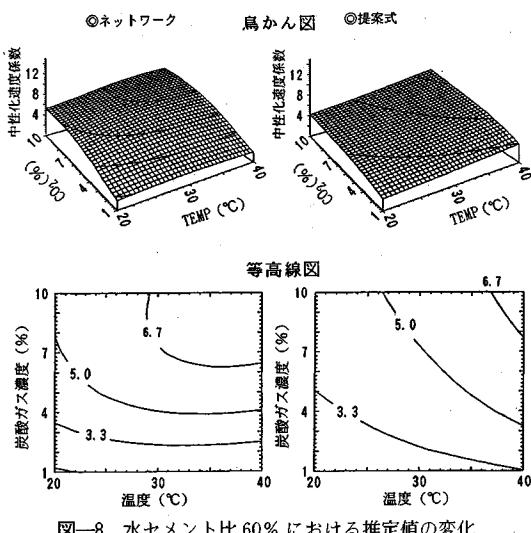


図-8 水セメント比 60% における推定値の変化

酸ガス濃度(%)を表し、例えば $T40, W60$ とは、温度 40°C 、水セメント比 60% の条件で、炭酸ガス濃度を少しづつ変化させた場合の結果である。比較のために、先の提案式でも同様の事を行う(図-7、図-8 参照)。ネットワークによる出力は、理論的な考察から導かれた提案式と大きく異なることはなく、同様な傾向を示していることがわかる。ただし、養生温度を変化させた場合には変化傾向が若干異なっている。これは、提案式が養生温度 $20\sim40^{\circ}\text{C}$ の範囲の実験データを基にして導かれたものであり、提案後、 50°C まで変化させた実験結果では、本ネットワークで得られた曲線と同様な変化傾向となることが明らかとなっている。

(4) ネットワークの適用(II)

a) 推定モデル

次に、中性化速度係数に与える影響が大きいと考えられる養生条件を入力に追加する。他の 3 個の要因のように具体的な数値では表せないため、養生条件を表すためのユニットを 3 個用意し、それぞれに(水中養生)(湿潤養生)(散水養生)という項目を対応させ、Yes である場合には 1、そうでない場合には 0 を与えることとする。気中養生の場合は 3 つの項目すべて No であるとする事で、養生条件を 4 種類に分類する。なお、前述の(3)で用いたデータは、水中養生が圧倒的に多いので、その他の養生条件のものを中心に 46 個のデータを新たに加えた。学習に用いるデータは、(3)と同様、6 個の入力値がそれぞれ同じになるものは、その中性化速度係数を平均する。その結果、合計 96 個の学習データとなった。用いるネットワークは入力層を 6 個、中間層を 8 個に変更した以外は(3)と同様である(図-9)。

b) 結果と考察

学習が進み、収束がほぼ止まったところでネットワー-

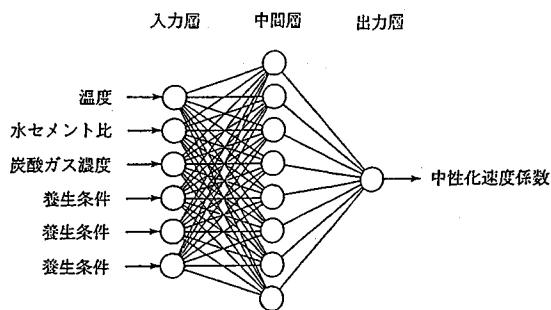


図-9 ネットワークモデル(II)

表-3 教示結果(入力 6)

データ数	96
平均二乗誤差	0.5274
相関係数	0.9705

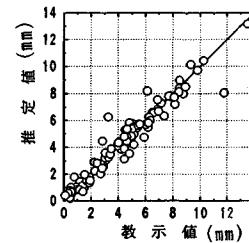


図-10 推定結果(II)

表-4 推定結果の比較(II)

	ネットワーク		提案式
	入力 6	入力 3	
データ数	141	141	141
平均二乗誤差	0.9124	1.3616	1.5912
相関係数	0.9285	0.8914	0.8218

クの学習をやめた。学習 1 回あたりの重みの修正量など、学習のさせ方を変えて行った数例の結果の 1 例(学習回数 150 000 回)について、その教示値と推定値の関係を示す(表-3、図-10)。これらの結果から入力が 3 個の場合より、教示値と推定値の相関係数は向上していることがわかる。また、入力層 3 個のネットワークおよび先の提案式による推定の結果を比較するために、(3)で用いた 150 個のデータのうち、養生条件がわかっている 141 個のデータに関して推定を行い、結果を比較した(表-4)。この結果、養生条件を新たに加えた入力層 6 個のネットワークでは、入力層 3 個のネットワークや既往の提案式より、良い推定が可能になっていることがわかる。

4. 練り混ぜ実験結果への適用

(1) コンクリートの練り混ぜ

本来、コンクリートの練り混ぜ操作は、製造されるコンクリートの品質が最良となるようにして行うべきであ

る。しかしながら、現状におけるミキサでの練り混ぜ方法（時間、投入方法等）は、JIS A 1119 の試験を実施して、コンクリート中のモルタル量、骨材量のばらつきがある一定値以下となるようにして決定されているだけであり、コンクリートの品質特性値に関しては全く考慮されていない。また、コンクリートの練り混ぜに関して従来より行われてきた様々な実験や研究の結果は、使用したミキサの形式や容量の違いによらない定量的な指標がないため、同一実験内の相対的な比較にとどまっている。

(2) 既往の研究

岸らの研究⁸⁾では、同一材料、同一配合のコンクリートを使用し、ミキサの種類と練り混ぜ時間がコンクリートの品質に及ぼす影響について検討を行っている。その結果、練り混ぜ時間にともなってミキサ内のコンクリートの構成材料が均一になっても、スランプや圧縮強度などの品質特性値はそれ以降においても変化し、その変化傾向がミキサの種類により異なるため、練り混ぜ時間を同一にしても得られるコンクリートの品質は、同一にはならない事を明らかにしている。そのうえで、異なるミキサで練り混ぜる場合には、ミキサの消費電力（コンクリート単位体積あたりの積算消費電力）が同一となる時間で練り混ぜることにより、ほぼ同一品質のコンクリートを得ることができるとしている。ミキサの消費電力量を測定することは、練り混ぜ時においてミキサの羽根に直接作用する力（回転トルク）を測定することの簡易的方法であり、コンクリートに対して加わる外力の総和である仕事量を評価指標にしようというものである。

さらに魚本らの研究⁹⁾では、配合条件を変えた場合において同様な検討を行い、水セメント比、単位水量、粗骨材最大寸法や添加する混和剤などの配合条件が違う場合においても、練り混ぜ時間にともなって品質は変化するが、その傾向は同様であることを明らかにしている。そして、ミキサ形式や配合が異なる場合も含めて、ミキサ消費電力量を指標にした定量的な評価手法を提案している。コンクリートの品質性状を表わす指標として、スランプ、空気量、圧縮強度をとりあげ、それぞれ相対スランプ、相対空気量、相対圧縮強度などとして一般化し、回帰曲線を示している（式(17)～(19)）。なかでも、練り混ぜ時間にともなうスランプ値の変化は大きく、練り混ぜ時間にともなって増大し、ある時間で最大値に達した後は減少するという特徴的な傾向を示す（図-11）。

[スランプ]

$$Slr = 95.74 - 29.07 \log P - 49.63 (\log P)^2 \quad (17)$$

ここに Slr ：相対スランプ

（各練り混ぜ時間でのスランプ Sl と最大スランプ Sl_{max} の比 = $(Sl/Sl_{max}) \times 100$ ）

P ：ミキサ消費電力量 (wh/ℓ)

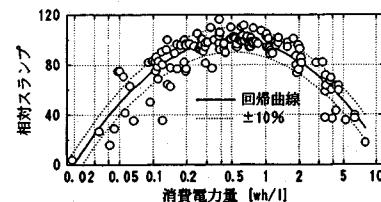


図-11 スランプの変化曲線の一般化

ただし 高性能減水剤を使用した場合を除く
[空気量]

(a) プレーンコンクリートの場合

$$Airr = 100.0 - 15.7 \log P + 15.7 (\log P)^2 \quad (18. a)$$

(b) AEコンクリートの場合

$$Airr = 100.3 - 102.9 \log P - 3.6 (\log P)^2 + 93.3 (\log P)^3 \quad (18. b)$$

ここに $Airr$ ：ミキサの消費電力量が 1 wh/ℓ の時を 100 とした相対空気量

P ：ミキサ消費電力量 (wh/ℓ)

[圧縮強度]

$$CSr = 100.0 + 407 \log P \quad (19)$$

ここに CSr ：ミキサの消費電力量が 1 wh/ℓ の時を 100 とした相対圧縮強度

P ：ミキサの消費電力量 (wh/ℓ)

ただし $P > 0.05$ wh/ℓ

(3) ニューラルネットワークを用いた影響因子の検証

a) 検証方法

既往の研究において提案されている、ミキサの消費電力量を指標として、練り混ぜ操作にともなうコンクリートの品質の変化を評価することの有効性を確認するために、ニューラルネットワークの持つ学習機能を応用する。入力する要因と出力させる項目とのあいだに合理的な関係があり、その相関の度合が強い要因を入力として与えた場合の方が、そうでない場合より学習の収束のレベルが良くなることが予想される。

そこで、魚本らの実験⁹⁾で得られたデータを使用して、階層型ネットワークに学習を行わせる。その実験において、練り混ぜ操作に関する指標として測定している、練り混ぜ時間、ミキサ種類、消費電力量の 3 個の要因のうちから 5 通りの組合せを考え、ネットワークに入力として与えて、学習結果を比較する。組合せは [消費電力量]、[練り混ぜ時間]、[消費電力量+ミキサ種類]、[練り混ぜ時間+ミキサ種類]、[消費電力量+練り混ぜ時間+ミキサ種類] の 5 通りとし、水セメント比や添加する混和剤などの配合に関する要因は、すべての組合せに入力として共通に与える。推定させる品質特性値としては、スランプ、空気量、圧縮強度の 3 種類とする。

b) モデル化

表-5 学習データの配合

配合名	G _{max} (kg/m ³)	W/C (%)	単位水量 (kg/m ³)	混和剤	ミキサ種類	
F 1	10	55	213	AE剤	パン型F	
F 2	20	55	196			
F 3	40	55	182			
F 1'	10	55	198			
F 2'	20	55	182			
F 3'	40	55	169			
M 1	20	40	165			
M 2	20	40	165	減水剤	パン型M	
M 3	20	40	165	高性能減水剤①		
M 4	20	40	165	高性能減水剤②		
M 1'	20	40	165	二軸型		
M 2'	20	40	165	減水剤		
M 3'	20	40	165	高性能減水剤①		
M 4'	20	40	165	高性能減水剤②		
M 5	20	40	175	パン型M		
M 6	20	55	175			
M 7	20	70	178			
M 8	20	40	185			

学習に用いるデータは合計 108 個で、水セメント比 40%~70%，粗骨材最大寸法 10 mm~40 mm，単位水量 165 kg/m³~185 kg/m³ の範囲で、添加する混和剤としては、AE 剤、減水剤、高性能減水剤の 3 通りで、高性能減水剤の添加量は 2 通りである。実験に使用したミキサは 3 種類で、容量 100% で羽根の最外縁の周速の異なる 2 種類のパン型ミキサと、容量 90% の水平二軸型ミキサである。表-5 に示した配合において、それぞれ 10 秒~1000 秒で 6 通りの練り混ぜ時間においてスランプ、空気量、圧縮強度を測定している。表-5 からわかるように、それぞれの配合シリーズにおいては、特定の要因の影響を探るためにそれ以外の要因は一定にして実験が行われており、学習データの分布範囲には偏りがある。また、入力する項目として、表-5 に挙げた 5 種類のほかに練り混ぜ時間に関する項目が加わり、合計 6 項目となるのに比較して、学習するデータの少なさは否定できない。

学習データの与え方は、水セメント比や消費電力量などの項目に関しては、その数値を入力値とする。添加する混和剤やミキサの種類など具体的な数値で表わせない項目に関しては、3.4 同様それぞれに対応するユニットを用意し、1 または 0 を与えることとする。ネットワークは 3 層とし、中間層のユニットの個数は、4.(3)a) で考へた 5 通りの組合せ（セット）に対して、それぞれ 3 通りの場合で学習を行わせる（表-6）。これは、中間層のユニットの個数が不適切なために、学習の進み方が悪くなるということを避けるためである。入力層のユニット数はセット A, B が 8 個、セット C, D が 11 個、セット E が 12 個となる（図-12）。

c) 学習の結果の比較

各ケース学習回数 10 000 回までの学習の結果を表-7 に示す。5 種類の入力の組合せにおいて学習条件をそろえるために、学習 1 回あたりのユニットの結合の修正量

表-6 ネットワークのバリエーション

ケース	入力する練り混ぜ操作に関する指標			中間層の数
	消費電力量	練り混ぜ時間	ミキサ種類	
A-1	○			1 0
A-2	○			1 2
A-3	○			1 4
B-1		○		1 0
B-2		○		1 2
B-3		○		1 4
C-1	○		○	1 2
C-2	○		○	1 4
C-3	○		○	1 6
D-1		○	○	1 2
D-2		○	○	1 4
D-3		○	○	1 6
E-1	○	○	○	1 2
E-2	○	○	○	1 4
E-3	○	○	○	1 6

入力層 中間層 出力層
(8~12) (10~16) (3)

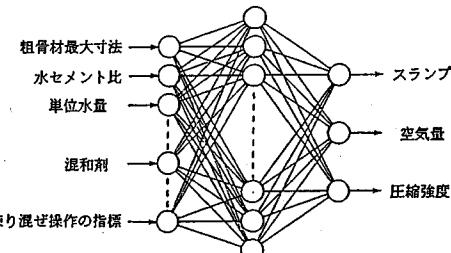


図-12 ネットワークモデル

など学習定数は各ケースとも同一とした。

どのケースにおいても、空気量と圧縮強度の推定値はスランプの推定値に比べて推定の精度が良く、ほぼ収束しており練り混ぜ操作に関する指標の組合せによる違いは認められない。

また、どのセットにおいても中間層の数の違いによる収束レベルの差は少ない。練り混ぜ操作に関する 3 個の指標すべてを入力として与えたセット E と比較して、やや収束のレベルが劣るのがセット C, D である。セット A, B はセット E と比べた場合、かなり収束のレベルが悪い。また、セット A とセット B, セット C とセット D をそれぞれ比較すると、指標を消費電力量あるいは練り混ぜ時間としてもほぼ同一の結果が得られており、両者に差はほとんど認められない。また、ミキサ種類に関する入力があるセット C, D と、それがないセット A, B の学習の収束レベルの違いから考えると、練り混ぜ操作の特性を表わす指標としては、練り混ぜ時間または消費電力量のみより、ミキサ種類も加えた方が良いようである。

このことを確認するために、セット A, B に関しては、さらに 30 000 回まで学習を続け、最終的な学習の収束のレベルを調べた（表-8）。セット B の方が若干収束のレベルは良いが、ほとんど差はないといえる。また、セッ

表-7 教示結果（学習回数10000回）

ケース	スランプ		空気量		圧縮強度	
	平均誤差	相関係数	平均誤差	相関係数	平均誤差	相関係数
A-1	4.3072	0.9117	0.0273	0.9801	474.88	0.9874
A-2	5.8087	0.9087	0.0331	0.9757	443.87	0.9867
A-3	5.5401	0.9043	0.0332	0.9758	360.76	0.9857
B-1	4.3311	0.9126	0.0307	0.9775	577.96	0.9850
B-2	5.7860	0.9063	0.0329	0.9780	414.81	0.9890
B-3	8.0331	0.8910	0.0366	0.9733	321.18	0.9904
C-1	0.9319	0.9712	0.0146	0.9893	247.97	0.9926
C-2	0.9871	0.9695	0.0172	0.9875	247.94	0.9927
C-3	1.0656	0.9671	0.0205	0.9850	264.49	0.9921
D-1	0.8806	0.9728	0.0154	0.9888	254.58	0.9924
D-2	1.0564	0.9674	0.0164	0.9880	271.37	0.9920
D-3	0.8738	0.9731	0.0139	0.9899	247.15	0.9927
E-1	0.8839	0.9728	0.0137	0.9900	253.72	0.9925
E-2	0.8122	0.9750	0.0122	0.9911	249.52	0.9926
E-3	0.7442	0.9771	0.0116	0.9916	234.11	0.9931

* 平均誤差とはそれぞれの指標の推定値と教示値の二乗誤差の平均を表す

表-8 教示結果（学習回数30000回）

ケース	スランプ		空気量		圧縮強度	
	平均誤差	相関係数	平均誤差	相関係数	平均誤差	相関係数
A-1	2.6750	0.9339	0.0221	0.9838	709.89	0.9845
A-2	2.2918	0.9504	0.0176	0.9872	371.42	0.9893
A-3	2.3083	0.9502	0.0219	0.9841	353.04	0.9902
B-1	3.4495	0.9315	0.0226	0.9835	759.98	0.9840
B-2	2.2529	0.9517	0.0262	0.9810	363.14	0.9903
B-3	7.4777	0.9018	0.0344	0.9753	350.44	0.9899

* 平均誤差とはそれぞれの指標の推定値と教示値の二乗誤差の平均を表す

表-9 回帰式による推定結果

	スランプ	空気量	圧縮強度
データ数	84	72	105
平均二乗誤差	0.6428	0.0320	358.24
相関係数	0.9708	0.9908	0.9902

表-10 ネットワーク（C-1）による推定

	スランプ	空気量	圧縮強度
データ数	84	72	105
平均二乗誤差	0.4254	0.0172	199.29
相関係数	0.9801	0.9950	0.9952

トC～セットEほどには誤差は減少していない。このことから判断しても、練り混ぜ時間や消費電力量のみを練り混ぜ操作の特性を表す指標とするよりも、ミキサの種類についても入力として与えた方が良いと考えられる。ただし、学習データの数は一定なので入力項目を増やした方が、ネットワーク内部の結合の自由度が大きくなり、推定の精度が良くなるのは当然であるということもできる。また、今回の解析では、練り混ぜ操作に関する指標として練り混ぜ時間を採用した場合と消費電力量を採用した場合での、各推定値の精度には大きな違いは認められなかった。

d) 考 察

既往の研究での回帰式との比較：前述の研究⁹⁾での回帰式（式（17）～式（19））より計算される一般化された

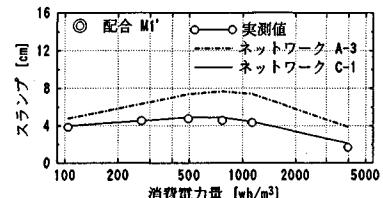
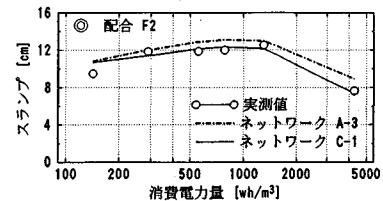


図-13 教示値とネットワークの出力（1）

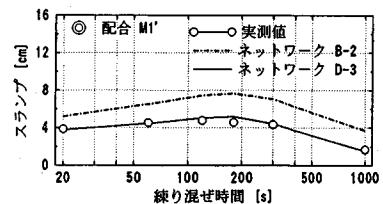
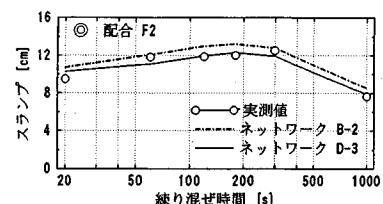


図-14 教示値とネットワークの出力（2）

値に、各配合ごとにそれぞれ実験値より回帰して求めた最大スランプ、ミキサの消費電力量が1 wh/m³の時の空気量、圧縮強度などの基準になる数値を乗じてやり、もとの値を推定することとし、ネットワークによる出力と比較する。これら回帰式とネットワークでは、入力する情報が異なること、また、回帰式の方は推定する対象を限定していることなどのために、本質的な比較にはならないが、ネットワークによる推定の精度を評価するうえで参考になるであろう（表-9）。同一データに対するネットワークによる推定の結果もあわせて表示する（表-10）。練り混ぜ操作に関する入力の組合せが消費電力量とミキサ種類であるネットワークC-1を用いた。

これらの比較より、どの指標についてもネットワークによる推定値の方が優れており、ネットワークによる推定の精度の良さが確認できた。

ネットワークの動作の様子：各配合における教示値とネットワークによる推定値の関係を調べるために、横軸を消費電力量と練り混ぜ時間の2通りの場合に分けて、スランプの推定結果の数例を示す（図-13、図-14）。

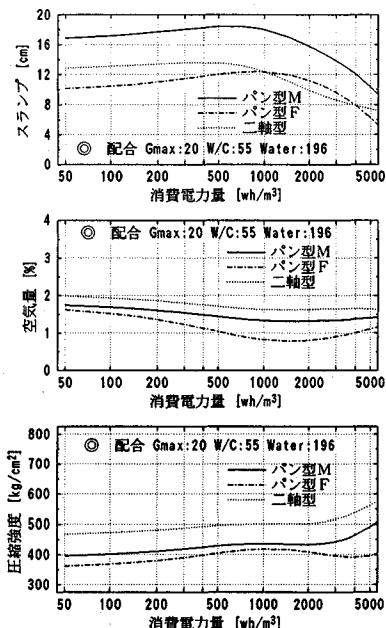


図-15 ミキサ種類の違いによる推定値の変化（1）

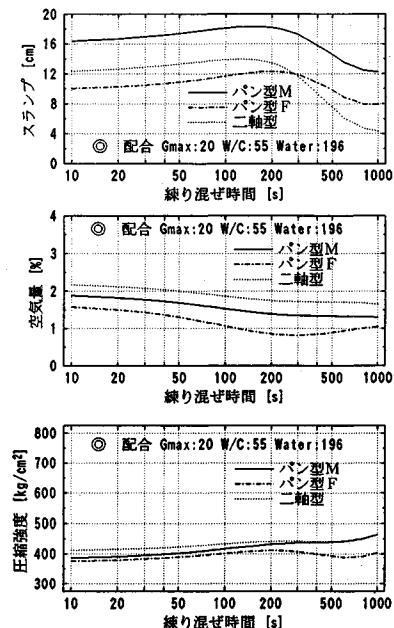


図-16 ミキサ種類の違いによる推定値の変化（2）

練り混ぜ操作に関する指標（横軸）が消費電力量であるか練り混ぜ時間であるかの違いは特に認められず、どちらの場合も推定の精度は良い。

また、ミキサの種類に関する入力があるセット C とセット D では良好な推定が行われているといえるが、ミキサの種類に関する入力がない場合に、配合 M 1' では横軸にとった指標（消費電力量または練り混ぜ時間）の変化にともなう推定値の増減の傾向は一致するが、推定値が大きくなるという傾向を示す。このことは、ミキサの違いによる影響が存在することを示唆していると考えられる。

このことをふまえてある配合を仮定し、使用するミキサの種類を 3 通りに変えて、消費電力量または練り混ぜ時間を変化させた場合に、ネットワークによる各推定値の出力はどのように変化するかを示す（図-15、図-16）。

いずれの場合もミキサの種類の違いによって推定値の傾向が異なるという結果が得られた。しかし、さきにも述べた通り学習データの分布範囲に問題があるため、これら得られた結果の信頼性については疑問が残る。

望ましい学習データ：ネットワークは与えられた学習データによって、内部の結合を変化させて、正しい値を出力するように自己組織化していく。このため、学習に用いるデータの正確さはもちろんのこと、その分布のしかたも重要である。単に、学習したデータについての推定値を教示値に合わせるというのであれば、むしろ学習する範囲に偏りがあってネットワーク内部の結合の自由度が大きい場合の方が、学習データの教示値と推定値の

一致の度合が良くなることも考えられる。しかしこの場合、学習データのない範囲に対しての推定の信頼性は高くない。

学習によって得られたネットワークを上記のように用いるには、各項目がそれぞれ独立に違った値をとるような、できるだけ広い範囲に散らばったデータについて学習しなければ、その信頼性は高くならない。入力する項目数が増えるにしたがって、学習データの数の方も指数関数的に増やしていかなければ理想的である。本解析（表-5 参照）では、学習データをミキサの種類別にみた場合、パン型 F を使用している配合 F 1'~F 3' では水セメント比、パン型 M を使用している配合 M 1'~M 8 では粗骨材最大寸法がそれれ一定であるし、二軸型を使用している配合 M 1'~M 4' では使用した混和剤以外の条件はすべて同一のデータとなっている。このように、入力項目のうち 2 項目あるいはそれ以上が一定であるようなデータのみでの学習では不十分と判断される。

本解析で使用した練り混ぜ実験のデータは、中性化試験の結果と異なり同一の実験者によって行われた結果であることから、実験の実施方法の違いなどによる誤差は少ないと考えられるが、入力する項目の数に比べて学習データの数が少なく、学習したデータの範囲に偏りがある。このため、学習データのない範囲での推定に対する信頼性は低い。

5. 結論

本研究では、コンクリート実験により得られたデータ

に対して、ニューラルネットワークを用いて種々の解析を試み、その適用性について検討を行った。その結果、次のような事柄が明らかとなった。

(1) 促進中性化試験への適用結果

中性化深さを予測する既存の提案式（炭酸ガス濃度、温度および水セメント比を考慮した式）とニューラルネットワークを利用した本手法を用いて、実験により得られた中性化深さを推定して比較した結果、本手法による予測の方がより良い精度で推定できることが明らかになった。また、上記提案式では考慮していない養生条件という項目を、ニューラルネットワークに追加入力することにより、推定精度がさらに向上することが明らかになった。

(2) 練り混ぜ試験への適用結果

練り混ぜ時間に伴って変化するコンクリート品質（ランプ、空気量、圧縮強度）を、どのような指標で評価するのが適切であるかどうかについて、ニューラルネットワークの有する学習機能を利用して検討を行った。その結果、練り混ぜ時間と消費電力量との比較では、どちらの指標が適しているかの明確な違いは認められなかつたが、いずれの場合においても、使用したミキサの種類に関する情報の入力により、推定精度が良くなることが明らかになった。

(3) ニューラルネットワークによるデータ解析

実験データに基づいて経験式や提案式を導く場合、および、重回帰分析を行う場合には、ある程度の理論的背景をもとにして、式の形をあらかじめ決めるなどの仮定を設ける必要がある。この仮定が適当なものであるかどうかによって、得られる結果は大きく異なる。これに対して、本手法は以下のような特徴を有していることが明らかとなった。

- ① 学習後のネットワークを利用すれば、因子間の関係をグラフ化する事ができる。この関係は研究者の主観的な予測が全く入っていないものであるから、これを参考にして、逆に理論的な背景を探るために利用することも可能である。
- ② 入力因子の組合せを変えて、その結果として得られる誤差の収束レベルを比較することにより、どの入力因

子が出力因子に対して影響を与えているかというような情報を容易に得ることが可能である。

- ③ データの信頼性が向上した場合、新たなデータが得られた場合、あるいは、影響因子を新たに追加させたい場合等には、それらのデータを使用した学習を容易に再度行うことができ、それにより推定精度の向上が図れる。
- ④ ネットワークの学習では、教示値とそれ自身の出力値間の誤差を評価基準にしているため、学習に用いるデータの精度が重要であり、分布の範囲に偏りが少なく広範囲に分布した、正確なデータを多数用意することが大切である。

以上のように、従来、ロボットの制御や文字認識などといった分野で主に研究・利用されているニューラルネットワークは、コンクリート実験の分野に対しても十分活用できることを、本研究によって明らかにすることができた。今後、ネットワーク内部の結合のしかたから、入力と出力の因子間の関係についてのより具体的な情報を得ることのできる手法を考案することができれば、さらに活用の範囲が広がるものと考えられる。

参考文献

- 1) 松本元・大津展之：脳とコンピュータ2、ニューロコンピューティングの周辺、培風館、1991.
- 2) 麻生英樹：ニューラルネットワーク情報処理、産業図書、1988.
- 3) 中野馨：ニューロコンピュータの基礎、コロナ社、1990.
- 4) 生研セミナーテキスト：ニューラルネットワークの制御への応用、1991.
- 5) 中野馨ほか：ニューロコンピュータ、技術評論社、1989.
- 6) 岸谷孝一・西澤紀昭：コンクリート構造物の耐久性シリーズ“中性化”，技報堂出版、1986.
- 7) 高田・魚本：コンクリートの中性化速度に及ぼす要因、土木学会論文集、No. 451/V-17, pp.119~128, 1992.8.
- 8) 岸・渡部・山田・魚本：ミキサの種類と練りませ時間がコンクリートの品質に及ぼす影響、土木学会論文集、No. 402/V-10, 1989.2.
- 9) 魚本・西村・渡部・田中：配合条件とミキサ消費電力量がコンクリートの品質に及ぼす影響、土木学会論文集、No. 442/V-16, 1992.2.

(1992.4.7受付)

ANALYSIS OF EXPERIMENTAL DATA USING NEURAL NETWORK

Tsukasa SEKIGUCHI, Takeo UOMOTO, Yoshiaki TAKADA and Tadashi WATANABE

Models using neural network were applied to analyse the data obtained in rapid carbonation test and mixing of concrete. The models were compared with proposed empirical equations by other researchers, and study was made to find important factors which were not considered in the equations.

The results show that the models using neural network is effective both to estimate the experimental results and important factors much easier than conventional analysis. This shows that the neural network is valid for analysing the experimental data not only to estimate the values but also to find important factors governing the phenomenon.