

ニューラルネットワークを用いた コンクリート製造管理システムに関する研究

大矢 孝¹・魚本健人²・堤 知明³

¹正会員 工修 東京電力(株) 地中線建設所与野工事事務所(〒338 埼玉県与野市上落合1099-1)

²正会員 工博 東京大学生産技術研究所教授(〒106 港区六本木7-22-1)

³正会員 工修 東京電力(株) 技術研究所主任研究員(〒230 横浜市鶴見区江ヶ崎町4-1)

ニューラルネットワークを用いたコンクリートの品質推定と感度解析, および感度に基づく最適化手法の適用によって, 所要の品質のコンクリートが得られるような配合条件, 練り混ぜ条件を算定する方法を示した。そして, 現場実験で得られたデータでこれを検証したところその有効性が確認されたので, 最後にニューラルネットワークを用いたコンクリート製造管理システムの提案を行った。

Key Words : neural network, control system, sensitivity analysis, optimization, mixing

1. はじめに

従来からコンクリート製造の際には, 所要の品質が得られるように配合設計が行われている。しかし, 現場のように骨材の表面水量をはじめとした変動要因が数多く存在し, しかもその計測が精度良く行えていないところでは, 指定された配合で計量しても練り上がったコンクリートの品質は一定とはならない。また, コンクリートの品質を推定する手法はいくつか提案されているが, 上記のような不確実性から, 実現場における精度は, まだ十分とは言えない。従って, コンクリートの品質管理は事後管理が一般的な手法となっており, 全バッチについてのサンプリングも行っていないため不良なコンクリートを出荷している可能性があるなどの問題点がある。このため, 材料の品質変動に対応して直ちに配合を修正し, 全バッチについて所要の品質のコンクリートが定常的に得られるように練混ぜを制御する必要がある。

ニューラルネットワークは, 理論的に推定が難しい問題に対してもデータを収集して学習させることで対応可能であり, また, 学習後のネットワークの結合係数から感度解析を行うことができるので, 影響因子の抽出とその定量的な評価が行え, 条件の変動に対する結果の変動を予測することができる。

コンクリート練り混ぜへのニューラルネットワークの適用については, 室内実験の結果に対しては, 精度よく推定できることが報告されている¹⁾。そこで本研究は, ニューラルネットワークを用いてコンクリートの品質を推定し, 感度解析の結果を使って最適化手法を適用することで, 所要の品質が得られるような配合条件, 練り混ぜ条件を求め, 常に一定品質のコンクリートを製造できるようなコンクリート製造管理システムの構築を目的と

して実施したものである。

2. ニューラルネットワーク^{2)~4)}

(1) ニューラルネットワークとは

ニューラルネットワークは, 脳の神経回路(ニューロン)の働きとその結合をモデル化したもので, 多数のユニットが結合しあったネットワークを形成している。従来のコンピュータは逐次直列型の情報処理を行い論理的な推論をしているのに対し, ニューラルネットワークは並列分散型の情報処理をしているので, 演算処理が速く, データの矛盾や欠落などのある問題に対しても対応できる柔軟かさをもっている。また, 従来のように難しいプログラミングを必要とはせず, 繰り返し情報を与えることで正しい答が出るように学習していくという特徴がある。このようなことから, パターン認識問題, 数式化や定式化が困難な問題の解決, 組合せが膨大な問題の準最適解の究明などを得意としている。

ニューラルネットワークには相互結合型のものと階層型のものがあるが, 本研究では図-1に示す階層型のモデルを用いた。

(2) ユニット

ユニットは脳細胞をモデル化したもので, 図-2に示すような多入力, 1出力の形式のものである。ユニットの状態量 u_j は, 入力 y_i に結合の重み ω_{ji} を乗じたものの総和からしきい値 θ_j を引いた値で表されるが(式(1)), 次のユニットへの出力はそれをある応答関数で変形して行われる。応答関数として一般的に用いられているのは, シグモイド関数と呼ばれるものであり(式(2)), これは $[0, 1]$ で連続的に変化する関数で




図-1 階層型ニューラルネットワーク




図-2 ニューラルネットワークのユニット

ある。

階層型のネットワークでは、入力層から入った信号は各ユニットで次のような変形を受けて、出力層まで伝達される。

$$u_j = \sum \omega_{ji} y_i \quad (1)$$

$$y_i = f(u_j) \quad (2)$$

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

(3) 学習アルゴリズム

ニューラルネットワークの学習は、ある誤差関数を極小にするように、ネットワークの結合の重みとしきい値を決定する作業である。階層型ニューラルネットワークでは、学習データに対するネットワークの出力と、望ましい出力（教示値）との誤差が減少する方向に重みとしきい値を変化させていくことで行う。

いま、誤差関数として、

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

$y_{j,c}$: ネットワークの出力 $\hat{y}_{j,c}$: 教示値

を考える。

この誤差関数 E によって定義される値を高さと考えれば、E は重み空間上の超曲面として“誤差曲面”を与えることになる。任意の重みの初期値から、この曲面の極小値に到達するには、各重み ω_{ji} を

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

ずつ変化させていけばよい。これは最急降下法といい、誤差曲面の最も傾斜の急な方向に進んで行くことに相当する。

ユニット j に関して、入出力関数が式 (1) ~ (3) のように定義されているとき、式 (5) は次のように展開される。

$$\frac{\partial E}{\partial \omega_{ji}} = \sum_c \frac{\partial E}{\partial y_{j,c}} \cdot \frac{\partial y_{j,c}}{\partial u_{j,c}} \cdot \frac{\partial u_{j,c}}{\partial \omega_{ji,c}} \quad (6)$$

また、式 (1) ~ (3) から

$$\frac{\partial y_{j,c}}{\partial u_{j,c}} = f'(u_{j,c}) \quad (7)$$

$$\frac{\partial u_{j,c}}{\partial \omega_{ji}} = y_{ji,c} \quad (8)$$

したがって、

$$\Delta \omega_{ji} = -\epsilon \sum_c \frac{\partial E}{\partial y_{j,c}} f'(u_{j,c}) y_{ji,c} \quad (9)$$

中間層が学習するときには $\frac{\partial E}{\partial y_{j,c}}$ の値を出力層から逆方向に計算して行くことを考える。

第 l 層の素子 j の $\frac{\partial E}{\partial y_j^l}$ の計算は、第 (l+1) 層の素子 i の $\frac{\partial E}{\partial y_i^{l+1}}$ から、

$$\frac{\partial E}{\partial y_j^l} = \sum_i \frac{\partial E}{\partial y_i^{l+1}} \frac{\partial y_i^{l+1}}{\partial u_i^{l+1}} \frac{\partial u_i^{l+1}}{\partial y_j^l} \quad (10)$$

また、式 (1) から

$$\frac{\partial u_i^{l+1}}{\partial y_j^l} = \omega_{ij}^l \quad (11)$$

これらから、

$$\frac{\partial E}{\partial y_j^l} = \sum_i \frac{\partial E}{\partial y_i^{l+1}} f'(u_i^{l+1}) \cdot \omega_{ij}^l \quad (12)$$

したがって、 $\frac{\partial E}{\partial y_j^{l+1}}$ (計算済) から $\frac{\partial E}{\partial y_j^l}$ が、求まる。これは、出力層の誤差を前の層へと順に伝えていくことを意味し、バックプロパゲーション法と呼ばれているものである。

3. データ収集

ニューラルネットワークを適用するためには、まず広範囲にわたった多数の学習データを用意する必要がある。そこで、現場の 3 m³ 練りの強制 2 軸練りミキサを使用して実験を行った。

実験は、練り上げたコンクリートをミキサ車に落としたりミキサ横の試験ヤードに運び、スランプ、空気量、単位容積質量の測定および圧縮強度試験用のテストピースの採取という手順で行った。また、表面水率測定のための骨材採取を計量時に、全材料投入までの時間の計測を練り混ぜ中にモニタを見ながら行った。なお、通常スランプは 0.5 cm 単位で測定するが、今回は 0.1 cm 単位で測った。空気量の測定は無注水法により行った。

測定したバッチ数は、表-1 に示した 3 配合について各 3 バッチ、および表-2 に示した 1 3 配合について各 1 バッチである。1 3 配合の実験は、広範囲にわたるデータを収集して、ネットワークに汎化性をもたせるためのものである。また、測定項目および測定回数は表-3 に示すとおりである。スランプなどのコンクリート品質は複数回測定しており、試験人員の関係から 1 度では

表-1 配合表

No.	配合条件			単位量 (kg/m ³)						
	W/ (C+F)	s/a	水	セメント	フライ アッシュ	粗骨材		粗骨材		混和剤
						川砂	陸砂	川砂利	砕石	
1	50.1	32.1	167	268	66	-	558	1235	-	0.835
2	46.2	37.7	162	281	70	465	199	1149	-	0.878
3	47.6	41.5	169	284	71	506	217	745	317	0.888

表-2 配合目標値

No.	W/C (%)			G _{max} (mm)	単位水量 (kg/m ³)			練り混ぜ時間 (sec)			
	40	55	60		25	40	150	165	180	60	120
1	○			○			○		○		
2		○		○			○		○		
3			○				○		○		
4	○				○		○		○		
5		○			○		○		○		
6	○								○		○
7	○				○		○		○		
8		○					○				
9	○				○		○				○
10		○						○	○		
11		○						○		○	
12								○			○
13		○			○		○				○

表-3 測定項目および回数

配合	バッチ数	1バッチ当たりの測定回数						
		骨材 表面水量	消費 電力量	材料の 計量値	スラブ	空気量	圧縮強度	単位容積 質量
表-1	3	1	1	1	30	30	90	30
表-1	90	1	1	1	5 or 6	6	3	6
表-2	13	1	1	1	15	15	5 or 15	15




図-3 コンクリート品質推定モデル

測定できないが、いずれの場合も各人の繰返し測定回数は3回以内とし、試験時間をなるべく短くしてスラブロス等の品質変化を最小限に抑えるように配慮した。

なお、実験で得られたコンクリートのスラブは、8.4~19.4cm、空気量は4.3~6.0%、圧縮強度は21.2~33.2MPaであった。

これらの実験によって、合計106バッチ分のデータが得られた。

4. コンクリート品質の推定

(1) 推定モデル

まず、階層型のニューラルネットワークを用いて、材料の投入量とコンクリート練り混ぜ時の情報から、コンクリートの品質を推定させる。ニューラルネットワークモデルは図-3に示すような2段階のモデルであり、まず骨材表面水量を推定してバッチ内に投入された真の配合量を推定し、その上でコンクリート品質の推定を行うものである。学習はそれぞれのネットワークについて別々に行い、学習後に1番目のネットワークの出力を2番目のネットワークに入力することで、材料の投入量とミキサ消費電力とからコンクリート品質を推定させる。

コンクリート品質の推定は、ミキサ消費電力として積算値以外の項、例えば最大値などを用いれば、このように2段階に分けなくても、精度よく行える。しかし、本論では最終的に配合条件、練り混ぜ条件の修正を行うことを目的としており、その際にニューラルネットワークをシミュレータとして利用し、感度の値も学習後のネットワークの重みとしきい値から算定する。したがって、

表-4 入出力因子 (骨材表面水量推定)

入力因子 (13ユニット)		出力因子 (2ユニット)
消費電力	全材料投入後の積算値 収束値 最大値	全骨材の表面水量 細骨材の表面水量
材料投入量	水 セメント フライアッシュ 細骨材 (2種) 粗骨材 (3種) 減水剤 補助剤	




図-4 ミキサ消費電力

入力因子としてそれぞれ独立に変動を制御できるものを選ばなくてはならない。例えば、骨材表面水量推定に用いた、ミキサ消費電力の最大値や収束値などは、コンクリート配合に関係し、コントロールすることもできないので不適当である。

そこで、消費電力の積算値と材料の計量値 (骨材表面水量で補正していない量) から、直接コンクリートの品質を推定させてみたが、ここに示した2段階のネットワークに比べて、スラブに対する推定精度がかなり低い結果となった。

表-5 推定結果まとめ (骨材表面水量推定)

項目	平均2乗誤差 (kg/m ³)		相関係数	
	学習データ	未学習データ	学習データ	未学習データ
細骨材の表面水量	2.41	4.16	0.990	0.974
全骨材の表面水量	6.10	3.41	0.983	0.981

(注) 平均2乗誤差: 推定値と実験値の差の2乗の平均。

以上のようなことから、コンクリート品質推定に2段階のネットワークを用いるものとする。

なお、ここで入力因子として選んだ項目の他にも、コンクリート温度、骨材・セメントの品質等コンクリートの品質に影響する要因は存在する。しかし、今回の実験は短期間(平成5年7月~8月)で行ったものであり、それらの値は実験期間中ほぼ同等であったため、入力項目からは外した。

(2) 骨材表面水量の推定

a) 推定モデル

骨材の表面水量の推定には、表-4に示す入出力因子をもった、中間層のユニット数18の3層階層型ニューラルネットワークモデルを用いて学習を行わせた。骨材は細骨材、粗骨材とも数種類あるが、各々の骨材表面水量の推定はできないので、細骨材および全骨材の表面水量を推定させるものとする。使用したデータは、実験で得られた106バッチのデータから、消費電力量や骨材の表面水率の計測に失敗したものを除いた計97バッチ分のデータである。消費電力量は図-4に示す3項目でいずれも空練り時の消費電力量を差し引いたものである。材料投入量は計量された重さで、投入直前に毎バッチ計測しているものである。骨材の表面水量は、この計量値にバッチ毎に取ったサンプルから測定した表面水率を乗じて求めている。なお、これらのデータはすべて0から1の間の数値に変換してから学習させている。

学習の進行とともに学習データの推定誤差は減少していくが、未知のデータ(学習に使用していないデータ)の推定誤差は、学習データの推定誤差が極小になる前に増加に転じる。これは過剰学習と呼ばれるもので、ネットワークに汎化性を持たせるためには避けなければならない。そこで、ネットワークの学習は、全97データの中から検証用に6組のデータを学習データからランダムに抜きだし、その推定誤差を逐次チェックしながら行った。そして、それが極小値をとって増加に転じる前に学習を終了させた。

b) 結果と考察

結合の重みとしきい値の初期値は理論的に決定することができないため、試行錯誤的に何度か変えて学習を行い、最も収束状況のよいものを選んだ。図-5は10万回学習後のネットワークの、未知のデータに対する推定結果を示したもので、非常によく推定できている。なお




図-5 推定結果 (骨材表面水量)

骨材表面水量はコンクリート1m³あたりの量である。

これらの結果のまとめを表-5に示す。表から、骨材表面水量の平均推定誤差が、細骨材で約2kg/m³、全骨材で約1.9kg/m³となる。単位水量が160~170kg/m³なので、計量値が正しいとすると、バッチ内に含まれる全水量の推定誤差はわずか1.2%である。また、細骨材の表面水率の推定誤差に換算すると、単位細骨材量が558~723kg/m³なので、0.2~0.3%である。現在開発されている水分計の測定精度が±0.5%前後であることから、ニューラルネットワークによっても、それと同等以上の推定精度が得られることがわかる。とくに、今回表面水率10%前後の品質のよくない細骨材を使用したことを考えると、非常に良い精度であると考えられる。

(3) コンクリート品質の推定

a) 推定モデル

骨材の表面水量が精度よく推定されたので、次に、材料の計量値を表面水量で補正した、真の配合値からコンクリートの品質を推定する。ネットワークの入力因子は表-6に示す8項目である。細骨材量と全骨材量を入力項目に選ぶことで、全骨材量一定で細骨材率を変化をシミュレートできる。つまり、全骨材量の入力項を一定にして細骨材量の入力を変動させることで、全骨材量一定下の条件でのs/aの変動を表現できる。出力因子は、スランプ、空気量、28日圧縮強度の3項目とした。また、中間層のユニット数は18である。

ネットワークの学習は、表面水量推定時と同様、過剰学習を防ぎ汎化性をもたせるため、学習データの中から無作為に6組のデータを除き、その推定誤差を逐次モニタリングしながら行った。

また、コンクリート品質特性値は、表-3に示したように複数回測定しているが、学習データはそれらの平均値とした。

b) 結果と考察

検証用のデータの誤差が増加しはじめ、かつ、学習がある程度収束した時点で学習を止めた(学習回数2000回)学習後のネットワークの、未学習データに対する推定結果を図-6に、結果のまとめを表-7示す。

表-6 入出力因子
(コンクリート品質推定)

入力因子 (8ユニット)		出力因子 (3ユニット)
消費電力量の積算値		スランプ 空気量 圧縮強度
配合 (修正後)	水 セメント フライアッシュ 細骨材量 全骨材量 減水剤 補助剤	




図-6 推定結果 (コンクリート品質)

この推定モデルでは、スランプで約1 cm、空気量で約0.25%、圧縮強度で約0.96 MPaの平均誤差が生じている。このことは、本ネットワークを使って配合修正をし、設定値と合った配合を得たとしても、実際に練り上がったコンクリートの品質はこれだけの範囲にばらつく可能性があることを示している。しかし、JISに定められた許容誤差、スランプで設定値±2.5 cm、空気量で±1%、を満たしており、実用上の精度は十分確保されている。なお、未学習データの方が良く推定できているものがあるのは、その数が6個と少ないためであろう。実際に際しては、データを大量に収集することで、検証用データを増やすことが必要である。

5. 感度解析

(1) ニューラルネットワークによる感度解析

感度解析とは、あるパラメータの変動に対して、解の受ける影響度の大きさを算定することである。工学的には、最適設計や再解析法の要素の1つとして盛んに研究がなされている。算定された感度の値は、解に対する影響因子の抽出や、最適化手法による最適設計、パラメータの変動に伴う解の変動を計算する効率の良い再解析法などを行う際に有効な解決手段を与えるものである。

ここでは、感度を用いた最適化手法によるコンクリート配合の最適設計を目的とし、学習後のニューラルネットワークの重みとしきい値から、感度を求めることを考える。

いま、ネットワーク素子 j に対して、

入力

$$u_j = \sum_i w_{ji} \cdot y_i - \theta_j \quad (13)$$

出力

$$y_j = f(u_j) \quad (14)$$

$$f(u) = \frac{1}{1 + e^{-u}} \quad (15)$$

また、 N 層階層型ニューラルネットワークの出力層の素子 i に対する、入力層の素子 j の感度 $\frac{\partial y_i^{(N)}}{\partial y_j^{(0)}}$ は、次のように展開される。

$$\frac{\partial y_i^{(N)}}{\partial y_j^{(0)}} = \sum_{k_1} \sum_{k_2} \dots \sum_{k_{N-1}} \frac{\partial y_i^{(N)}}{\partial y_{k_1}^{(N-1)}} \frac{\partial y_{k_1}^{(N-1)}}{\partial y_{k_2}^{(N-2)}} \dots \frac{\partial y_{k_{N-1}}^{(1)}}{\partial y_j^{(0)}} \quad (16)$$

表-7 推定結果まとめ (コンクリート品質推定)

項目	平均2乗誤差		相関係数	
	学習データ	未学習データ	学習データ	未学習データ
スランプ	1.20 cm	1.14	0.927	0.830
空気量	0.042%	0.072	0.933	0.817
圧縮強度	17.0 MPa	9.36	0.939	0.973

ここで、式(13)~(15)より、

$$\begin{aligned} \frac{\partial y_i^{(q+1)}}{\partial y_j^{(q)}} &= \frac{\partial y_i^{(q+1)}}{\partial u_i^{(q+1)}} \cdot \frac{\partial u_i^{(q+1)}}{\partial y_j^{(q)}} \\ &= f'(u_i^{(q+1)}) \cdot w_{ij}^{(q)} \end{aligned} \quad (17)$$

である。

とくに3層の場合には、

$$\begin{aligned} \frac{\partial y_i^{(3)}}{\partial y_j^{(0)}} &= \sum_k \frac{\partial y_i^{(3)}}{\partial y_k^{(2)}} \frac{\partial y_k^{(2)}}{\partial y_j^{(0)}} \\ &= \sum_k f'(u_i^{(3)}) \cdot w_{ki}^{(2)} \cdot f'(u_k^{(2)}) \cdot w_{kj}^{(0)} \\ &= y_i^{(3)}(1 - y_i^{(3)}) \sum_k w_{ki}^{(2)} \cdot y_k^{(2)}(1 - y_k^{(2)}) w_{kj}^{(0)} \end{aligned} \quad (18)$$

である。

以上より、ネットワーク各層の重みとしきい値、および各ユニットの出力から、任意の入力ポイントにおける感度が計算されることになる。

(2) 感度算定のモデル

本論においては、最適化手法を適用する際の繰返し計算に、感度の値を利用する。したがって、算定された感度の値を吟味することは本論の大筋からははずれるが、以下に計算結果の1例を示す。

感度解析に使用したネットワークは、表-8に示す入出力因子の3層階層型のネットワークで、中間層のユニット数は18である。学習後のネットワークの推定精度は前節で示した品質推定のネットワークとほぼ同程度である。ここで、練り混ぜ条件として消費電力量を用いないのは、各入力因子が独立でないことと算定された感度の値の評価ができないからである。ただし、細骨材量と全骨材量という2つの因子を入力としているのは、全骨材量一定の条件下での細骨材率の変動と、細骨材量一定の条件下での細骨材率の変動を近似的に表現するためである。学習後のネットワークによる感度計算は、学習データ

表-8 入出力因子 (感度算定)

入力因子		出力因子
練り混ぜ時間		スランプ
配合 (修正後)	水 セメント フライアッシュ 細骨材量 全骨材量 減水剤 補助剤	
		圧縮強度

表-9 感度算定の基準値

配合	配合 (kg/m ³)							練り混ぜ時間 (sec)
	水	セメント	フライアッシュ	細骨材	全骨材	減水剤	補助剤	
1	175.7	251.7	62.1	597.5	1869.6	3.38	2.01	39.4
2	164.4	266.7	65.7	675.6	1842.6	3.63	1.50	39.2
3	175.6	280.3	68.9	725.1	1792.1	3.76	1.50	39.2

表-10 影響の大きい因子

順位	スランプ			空気量			圧縮強度		
	配合1	配合2	配合3	配合1	配合2	配合3	配合1	配合2	配合3
1	+W	+W	+W	-a	-a	-a	-補	+F	+F
2	-補	-F	-F	+s	+補	+補	+F	-W	-s
3	+s	-C	-C	+補	-C	-C	+減	-s	-W

(注) W: 水量, C: セメント量, F: フライアッシュ量, s: 細骨材量, a: 全骨材量, 減: 減水剤量, 補: 補助剤量, +は正の相関を、-は負の相関を表す。




図-7 感度解析計算結果

の最も多い3種類の配合を基準として行う(表-9)。また、前項の式(18)は、出力信号に対する入力信号の感度を算定するものであるが、結果は入力が増加した場合の出力の変動の大きさに直してある。

(3) 結果と考察⁵⁾

各入力因子の感度計算の結果を図-7に、影響の大きい要因を3つずつ抜きだした結果を表-10に示す。表および図中の符号は入力を大きくしたとき出力が増加するならば‘+ (プラス)’, 減少するならば‘- (マイナス)’とする。なお、この結果は他の要因を一定に保ったまま、ある1つの要因を変化させたときの品質変動である。1要因(配合量)の増加は他の要因の相対量の低下をもたらすので、入力を1%増加させるという今回のような計算法では単位量1%に対する品質変動とはなっていないので注意が必要である。ここで計算しているのは、配合が単独に1%増加した場合の品質変動の大きさ、つまり、計量誤差の影響の大きさである。

a) スランプに対する影響

通常考えられているように、水量の影響が非常に大きい。その大きさは、一般に単位水量1.2%の増加に対してスランプ1cm程度の増大と言われているが、今回の結果では、それより小さい値となった。

セメントおよびフライアッシュ量の増加は、水結合材比を低下させ、今回の計算では相対的な水量の減少をも

たらすため、スランプを小さくするが、このことは計算結果と合っている。

なお、補助剤については、学習データがほとんど同じであったので、結果の信頼性は確かではない。

b) 空気量に対する影響

単位セメント量の減少および細骨材率の増大(今回の計算では、細骨材量の増加および全骨材量の減少)に対して空気量は増大するが、計算結果はこのことと合っている。また、本配合では細骨材量、全骨材量1%の変動は細骨材率0.3~0.4%の変動に相当するが、それに対する空気量の変化量は一般に言われているよりも小さかった。つまり、細骨材率0.5~1%の増加は空気量1%の増加にあたると言われているが、この計算ではその1/10程度の変動しかなかった。しかし、これは単位水量を増やさない条件下で、細骨材率を上げたために算定された結果であろう。

補助剤はAE剤であるので、その増加にともなって空気量も増えている。しかし、その大きさについては上に述べたように確かではない。

c) 圧縮強度に対する影響

セメントおよびフライアッシュ量の増大は、水結合材比を低下させ、圧縮強度を増大させる。計算結果はこの傾向と合っている。また、フライアッシュ1%の変動というのはセメント1%よりも量的には少ないが、1%の変動に対する強度増はセメントのそれより大きい。フラ

イアッシュ添加による強度増進が大きかったことになる。なお、一般にはフライアッシュ添加によって短期強度は低下するが、それはセメントと置換した場合であって、この計算条件とは異なる。

d) 総括

学習後のニューラルネットワークは、学習データの入出力関係を重みとしきい値という形で圧縮している。また、学習データの範囲内では滑らかに内挿することからニューラルネットワークによる感度解析の結果は、データのもっている傾向を正しくトレースしているものと考えられる。しかも、感度の大きさを定量的に求めることができるということは、大きな利点である。これにより練り混ぜ現象の解明だけでなく、計量誤差の管理基準の設定にも役立てることができるものと思われる。

6. 配合最適化

(1) 最適化理論⁶⁾

設計や計画の問題を解こうとする場合、通常いくつかの前提条件、制約条件が与えられる。一般に、これらの条件を満たす解は複数存在するが、常に最もよい解を選ぶことが求められる。この際に必要となる作業が最適化であり、数学的には以下のように表される。

制約条件

$$g_j(X) \geq 0 \quad (19)$$

$$h_j(X) = 0 \quad (20)$$

のもとで目的関数を最小化、すなわち

$$f(X) \rightarrow \text{Min} \quad (21)$$

とするような変数ベクトル X 、または変数 X_1, \dots, X_n を見いだすこと。

最適化問題を解く方法は多数あるが、本論では変換法の一つである内点法によって、制約条件付きの問題を制約条件なしの問題に帰着させ、ニューラルネットワークの学習アルゴリズムに用いられている最急降下法で最適化を行った。以下にその説明をする。

a) 最急降下法

最急降下法は目的関数を極小化（あるいは極大化）するように、関数の傾斜の最も急な方向へ設計変数を変化させて行く方法である。この傾斜の急な方向を各ステップごとに探索し、設計変数を繰返し変更していけば、極小点へ短時間で効率良く到達することができる。

いま、目的関数が n 個の変数の関数、すなわち、式(22)で表されるとき、感度ベクトル(傾斜ベクトル)は、式(23)で表される。

$$f(X) = f(x_1, x_2, \dots, x_n) \quad (22)$$

$$\nabla f(X) = \left\{ \frac{\partial f}{\partial x_1}, \frac{\partial f}{\partial x_2}, \dots, \frac{\partial f}{\partial x_n} \right\}^T \quad (23)$$

ただし、 T は転置を表す。

したがって、次式によって設計変数を変更していけば徐々に最適解に近付いていく。

$$x_{k+1} = x_k - \tau \nabla f(x_k) \quad (24)$$

τ : 変更のステップ幅

なお、傾斜ベクトルの値は、その方向がわかれば良いので、次のように正規化する。

$$\overline{\nabla f} = \nabla f / |\nabla f| \quad (25)$$

b) 内点法

変換汎関数を $\varphi[\]$ で表せば、不等式制約条件のある問題は、次のような変換によって制約条件のない問題に帰着する。

$$f^*(x) = f(x) + r \sum_{j=1}^m \varphi[g_j(x)] \quad (26)$$

ここで、 $f^*(x)$ は修正目的関数。 r はペナルティ係数、 $\varphi[g_j(x)]$ はペナルティ汎関数と呼ばれる。

内点法では、ペナルティ汎関数として $[0, \infty)$ で凸な単調減少関数で、制約条件の境界上 ($g_j(x) = 0$) で無限大になるものを選ぶ。例えば、

$$f^*(x, r) = f(x) + r \sum_{j=1}^k \frac{1}{g_j(x)} \quad (27)$$

(ただし、 $r^{(1)} > r^{(2)} > r^{(3)} > \dots$)

という変換を行えば、制約条件なしの場合の解法によって最適化が行える。

なお、今回は設定していないが、等式制約条件があるときも、式(28)のような修正目的関数を作れば同様である。

$$f_m(x, r) = f(x) + r \sum_{j=1}^m \frac{1}{g_j(x)} + r^{-0.5} \sum_j \{h_j(x)\}^2 \quad (28)$$

(2) 解析方法

前節で示した感度解析を用いて、内点法と最急降下法により、所要の品質のコンクリートが得られるような配合条件、練り混ぜ条件を算定する。

計算のフローを図-8に示す。図を見てもわかるように、ネットワークの出力(推定値)と品質の設定値が一致するように、繰返し計算するものである。

いま、目的関数を次式のように定める。ここで、 $S_i(x)$ はネットワークの出力、 C_i は品質の設定値で表-11に示す値を選んだ。

$$f(x) = \frac{1}{2} \sum_i \{S_i(x) - C_i\}^2 \quad (29)$$

制約条件は式(30)のように6つ定め、式(27)により修正目的関数を作成する。

$$\begin{aligned} 145 &\leq W \leq 185 \\ 195 &\leq C \leq 370 \\ 45 &\leq F A \leq 85 \\ 580 &\leq s \leq 780 \end{aligned} \quad (30a)$$

表-11 品質設定値

配合	スランプ(cm)	空気量(%)	圧縮強度(MPa)
1	13.5	5.5	24.9
2	15.0	5.0	27.0
3	15.5	5.0	29.9

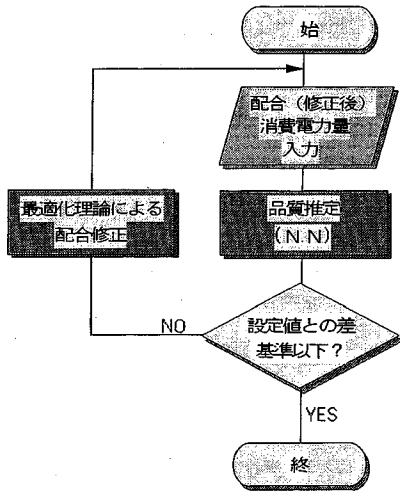


図-8 最適化計算フロー

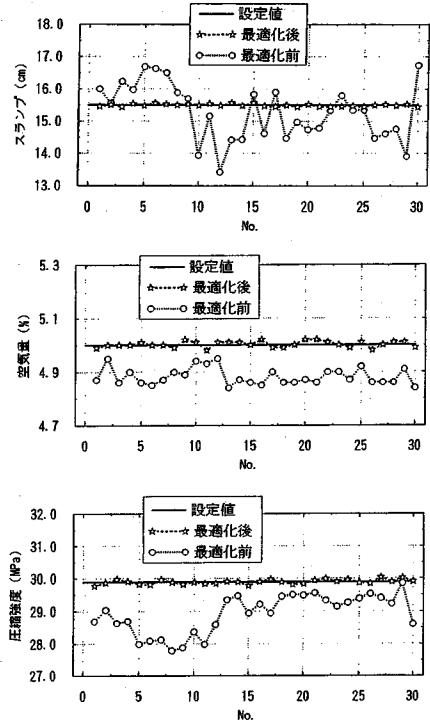


図-9 最適化結果

$$35.0 \leq W / (C + FA) \leq 60.0$$

$$31.0 \leq s / a \leq 42.0 \quad (30b)$$

ここで、W: 単位水量, C: 単位セメント量,
 FA: フライアッシュ量, s: 細骨材量 ... (kg/m³),
 W/(C+FA): 水結合材比, s/a: 細骨材率 ... (%)
 すると,

$$\frac{\partial f^*}{\partial x_i} = \frac{\partial f^*}{\partial f} \frac{\partial f}{\partial x_i} + \sum_j \frac{\partial f^*}{\partial g_j} \frac{\partial g_j}{\partial x_i} + \sum_l \frac{\partial f^*}{\partial h_l} \frac{\partial h_l}{\partial x_i}$$

$$= \sum_j \left\{ S_j(x) - C_j \right\} \frac{\partial S_j}{\partial x_i} + \sum_l \left(-r_l \frac{1}{\{g_l(x)\}^2} \right) \frac{\partial g_l}{\partial x_i} \quad (31)$$

であり、出力に対する入力の感度 $\partial S / \partial x$ は計算できるので、入力因子 x を

$$x_{k+1} = x_k - \tau \nabla f^*(x_k, r_k) \quad (32)$$

$$\nabla f^*(x, r) = \left\{ \frac{\partial f^*}{\partial x_1}, \frac{\partial f^*}{\partial x_2}, \dots, \frac{\partial f^*}{\partial x_n} \right\}^T \quad (33)$$

ずつ変化させ、繰返し計算することで、目的関数(推定値と設定値との誤差)を最小化することができる。

収束条件としては、式(34)の2つを定め、どちらかの条件を満たしたとき、収束したものとみなす。

$$f^* \leq \epsilon$$

$$\frac{|f^*(r_{i-1}) - f^*(r_i)|}{|f^*(r_i)|} \leq \delta \quad (34)$$

ϵ, δ : 微小な定数

表-12 最適化前後の配合

配合	W/(C+F)(%)	配合 (kg)							消費電力 (kwh/m ³)	
		水	セメント	FA	細骨材	全骨材	減水剤	補助剤		
1	前	55.0	172.6	251.9	62.1	593.5	1872.7	3.38	2.01	0.0957
	後	45.5	157.7	279.5	67.2	564.0	1872.7	3.15	2.01	0.0871
2	前	52.3	173.7	266.7	65.7	673.8	1833.3	3.63	1.50	0.0972
	後	45.9	155.0	271.5	66.4	654.1	1833.3	2.59	1.50	0.0721
3	前	50.6	176.8	280.3	68.9	722.7	1790.9	3.76	1.50	0.0782
	後	49.8	172.2	273.3	72.5	641.5	1790.9	2.53	1.50	0.0762

注) FA: フライアッシュ

表-13 最適化前後の品質

配合	スランプ (cm)	空気量 (%)	圧縮強度 (MPa)	
1	前	15.7	5.4	23.3
	後	13.51	5.47	24.9
2	前	16.1	4.9	29.0
	後	15.04	4.98	27.0
3	前	16.5	4.7	29.2
	後	15.48	4.98	29.8

変化させる要因は、[消費電力量]、[水量]、[セメント量]、[フライアッシュ量]、[細骨材量]、[減水剤量]の6項目とした。

なお、最適化の初期値は実験データの値(配合、消費電力量)を用いた。

(3) 結果と考察

最適化の結果を図-9に示す。また、収束前後の配合

量、消費電力量の例を表-12に、そのときの品質の値を表-13に示す。なお、骨材は表面水のない状態の重量、水量は骨材表面水を含んだ重さである。また、配合前後のコンクリート量は、制約条件として入れていないので、必ずしも一致しない。

3 配合とも、設定値に合うように最適化がなされている(図-9)。ただし、図中の値は最適化前、最適化後ともにニューラルネットワークの出力であるので、実際に得られる品質にはネットワークの推定誤差の分だけの誤差が生じる可能性がある。しかしながら、図を見てもわかるように、実際に製造されたコンクリート品質のばらつきは大きいので、ニューラルネットワークを用いることでより安定した品質のコンクリートを得ることができるものと思われる。

収束までの繰返し計算回数は、いずれも数十回程度であった。この収束計算は、初期値としてよいデータを与えることや、目的関数の形、収束計算の方法を改良することで、さらに速めることができるものと思われる。

7. システムの提案

これまでに述べた結果から、骨材の表面水量およびコンクリートの品質を精度良く推定でき、所要の品質が得られるように配合条件、練り混ぜ条件を最適化することも可能であることが明らかとなった。そこで、これらを総合した、コンクリート製造管理システムを提案する。

システム全体のながれを図-10に示す。大きく分けて、骨材表面水量を推定する部分と、所要の品質になるような配合とミキサ消費電力量を算定する部分の、2つに分けられる。

まず、ニューラルネットワーク1(N.N1)により各材料の計量値とミキサの消費電力量3項目(積算値、最大値、収束値)から、骨材(細骨材と全骨材)の表面水量を推定させる。

次に、ニューラルネットワーク2(N.N2)により骨材表面水量で補正後の配合と消費電力量から、コンクリート品質を推定し、推定された品質が所要の品質と異なる場合には、最適化理論により配合条件、練り混ぜ条件の修正を行う。この際必要になる感度の値は、ニューラルネットワーク2の重みとしきい値とから求める。最適化の各ステップごとに品質を推定し、設定された品質との誤差がある基準値以下になるまで繰返し計算する。

以上の計算により、所要の品質のコンクリートが得られるような適正な条件を求めることができる。学習後のネットワークの出力は瞬時に行き、最適化の際の繰返し計算回数も数十回程度であるので、この計算は、通常のパーソナルコンピュータによっても数秒単位で行える。したがって、各バッチごとに結果をフィードバックする

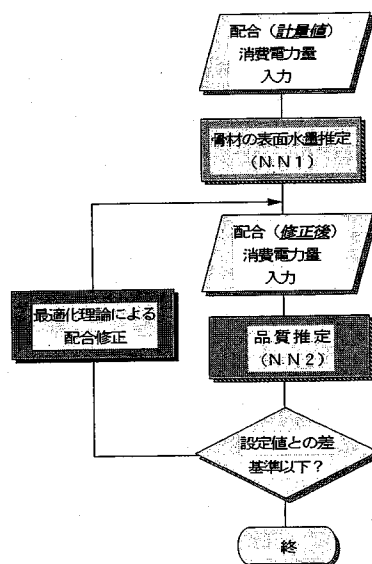


図-10 コンクリート製造管理システムフロー

ことが可能である。ただし、このシステムでは、骨材表面水量の推定に積算消費電力量が必要であるので、当該バッチでの修正を行うことができない。しかし、2段階練りのミキサを使用して、上段で骨材表面水量を推定し、下段で本練りを行うようにすれば、各バッチでの調整が可能となり、さらに精度の高いシステムとなる。

8. 結論

本研究では、コンクリートの製造管理にニューラルネットワークを適用することを考え、実際の現場で収集した実験データを使って検討を行った。その結果、以下のようなことが明らかとなった。

(1) 骨材表面水量の推定

骨材の表面水量のような、予測することが困難な要因についても非常に精度良く推定できることが明らかとなった。また、未学習データに対する推定精度も良く、10%以上の表面水率を有する砂を使用したにも関わらず、バッチ内の全水量の平均推定誤差はわずか1.2%程度であった。このことから、これまで推定することが難しくコンクリートの品質変動の大きな原因であったバッチ内の水量の変動を、正確に把握することが可能になるものと思われる。

(2) コンクリート品質の推定

現場で収集したデータによってもコンクリートの品質を推定することが可能であり、室内実験のデータによる結果¹⁾と同程度以上の精度をもっていることが確認され

た。これにより、ニューラルネットワークを現場で適用することが可能であ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感度解析

学習後のネットワークの重みとしきい値を使った感度解析によって、影響因子の抽出と影響度の算定が可能であることが明らかになった。これにより、配合の変動に対するコンクリートの品質変動の大きさを定量的に評価することができ、材料の許容計量誤差の確認や、計量誤差が原因となる品質変動を予測することができる。

この方法は、選定した入力因子のデータを用意して学習させることより比較的簡単に行うことができ、また、得られた結果は解析する者の主観が入っておらず、定量的な評価もできるため、様々な現象における因果関係の解明に非常に有効な手段となり得るものと思われる。

(4) 配合最適化

ニューラルネットワークによる品質推定と感度解析から、最適化手法を用いることで、コンクリート品質を所要のものにするように配合、練り混ぜ条件を修正することができた。

ただし、本システムでは積算消費電力量のデータが必要であるので、当該バッチでの修正ができず、結果は次バッチあるいは2バッチ後の配合に活かされることになる。しかし、2段練りミキサを使用すればこの問題は解決される。つまり、砂あるいは硬練りコンクリートを上段ミキサで練り、その際の消費電力量から骨材表面水量を推定し、練り混ぜ水の調整を行い下段ミキサで本練りをする方法である。そして、この方法に対しても本論と同様の展開方法で対応可能である。

(5) まとめ

現在のコンクリート製造管理手法では、各バッチの品質をリアルタイムで把握することができず、また、人間の勤や経験に頼っている部分が大きいため、結果的として、製造されるコンクリートの品質は一定とはなっていない。しかし、ニューラルネットワークを用いることで製造されているコンクリートの品質を容易に、しかも極

めて短時間に推定することができるので、練り上がり後すぐに品質の把握ができ、素早い対応も可能である。

ニューラルネットワークは、学習機能によって知識の拡張と汎化性の向上を図れるという利点をもっている。しかし、ネットワークの推定精度は学習データの精度に左右され、また、学習データの範囲からはずれた入力データに対しては推定精度が落ちるなどの問題もある。したがって、今後は精度のよい、広範囲にわたったデータを収集するための体制の整備をも含めた、総合的な製造管理システムづくりを目指さなければならない。また、入力項目の追加（練り混ぜ温度等）や学習方法の改善などにより、システムの精度を向上させて行くことも重要である。

謝辞：実験を実施するにあたって、多くの方々にお手伝い頂きました。また、東京大学生産技術研究所 浦環教授および東京大学 前川宏一助教授には有意義な御助言を頂きました。この場をお借りして厚く御礼申し上げます。

参考文献

- 1) 関口, 魚本ほか: 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, 土木学会論文集, No.460/V-18, pp.65-74, 1993.2.
- 2) 浦環, 橋本秀紀: 生研セミナーテキスト, ニューラルネットワークの基礎と新しい展開, 1992.7.
- 3) 中野馨ほか: ニューロコンピュータの基礎, コロナ社, 1989.
- 4) 矢川元基ほか: 計算力学とCAEシリーズ12 “ニューコンピューティングの周辺”, 培風館, 1991.
- 5) コンクリート技術講習会委員会編: コンクリート技術の要点, '91, 日本コンクリート工学協会, pp.73-123, 1991.
- 6) 山川宏: 計算力学とAEシリーズ9 “最適化デザイン”, 培風館, 1993.

(1994.3.29 受付)

A NEW QUALITY CONTROL SYSTEM FOR CONCRETE PRODUCTION USING NEURAL NETWORK

Takashi OHYA, Taketo UOMOTO and Tomoaki TSUTSUMI

A new method to find out the most suitable condition of mix proportion and mixing energy for required quality of concrete is presented in this paper. The method is based on the application of neural network to predict quality of concrete at any values of mix proportion and mixing energy. And by knowing the sensitivity of their relations, the optimized conditions can be obtained.

The verification of this method has been done by comparing calculated results with the experimental data obtained on site. As a result, a new quality control system for concrete production is proposed.