

# 論文 ニューラルネットワークを用いた配合最適化システムの 実プラントへの適用

後藤充志<sup>\*1</sup>・加藤佳孝<sup>\*2</sup>・魚本健人<sup>\*3</sup>・堤知明<sup>\*4</sup>

**要旨:** 硬練りコンクリートは単位水量が少なく、水量の変化がフレッシュコンクリートの品質に大きな影響を及ぼすので、配合時の品質管理が極めて重要である。しかし配合時に際して、骨材の表面水量をはじめとする不確定な要因が多数存在し、品質を管理することは極めて困難である。そこで、ニューラルネットワークを使った硬練りコンクリートの配合最適化システムを、実プラントに応用することによって、このシステムの適用性を検討した。その結果、実験時の条件に問題があったので、最適化・推定値の精度はよくなかったが、今後の課題として他の制限条件を追加することなどが考えられた。

**キーワード:** ニューラルネットワーク、品質推定、配合最適化、スランプ値

## 1. はじめに

ダム建設現場において、ダム本体に RCD 用コンクリートが多く用いられるが、岩盤との付着部分などには、スランプが約 3cm 程度となるよう配合された硬練りコンクリートが使用される。この硬練りコンクリートは単位水量が少ないので、練混ぜ時の水量の変化が、フレッシュコンクリートの性状に対して大きく影響する。その結果、配合時の品質管理が十分でなければ、期待した性能のコンクリートとは異なったコンクリートとなる。このため、例えば骨材の表面水量やフレッシュコンクリートの温度変化など、材料の品質変動に対応させて、常時それに適した配合を修正し直さなければ、所要の品質のコンクリートを定常的に得ることができない。

そこで、本研究は実験データを学習させたニューラルネットワークを用いて実際のプラントにおける硬練りコンクリートの品質を推定し、さらにその推定値と所望する品質の値（本研究ではスランプ値）との差から、もとの配合設計の各要素をどれほど修正させれば良いかを計算させ、要求性能を満たすコンクリートを製造するための配合最適化システム[1]が、適用可能か否かを検討した。

## 2. ニューラルネットワーク

### 2.1. ニューラルネットワーク

ニューラルネットワークとは、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。従来の逐次直列型の情報処理を行い論理的な推論をする計算法と違って、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のある問題に対しても適切な教示値を与えることによって柔軟に対応できる。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、組み合わせが膨大な問題の準最適解の究明などを得意とする。このニュー

\*1 東京大学大学院 工学系研究科社会基盤工学専攻（正会員）

\*2 東京大学生産技術研究所助手（正会員）

\*3 東京大学生産技術研究所教授、工博（正会員）

\*4 東京電力（株）電力技術研究所主任研究員（正会員）

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

## 2.2 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出力の形をなす。ユニットの状態量  $u_i$  は、入力  $y_i$  に結合の重み  $\omega_{ij}$  を乗じたものの総和からしきい値  $\theta$  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に変形して行われる。応答関数はシグモイド関数(式2,3)を用いた。すなわち、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。

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

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

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

## 2.3 学習方法

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)との二乗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。

すなわち、誤差関数として

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

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

を考える。

この誤差関数  $E$  の極小値を求めるために、任意の重みの初期値  $\omega_{ji}$  から  $\Delta \omega_{ji}$  ずつ変化させていく。

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

これを最急降下法といい、傾きの急な方向に進んでいくことに相当する。

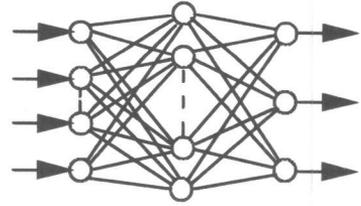


図-1 階層型ニューラルネットワーク

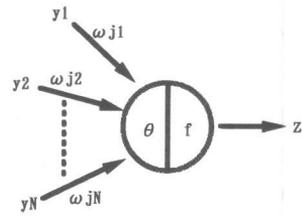


図-2 ニューラルネットワークのユニット

これらの式より、出力層の誤差をそれ以前の層（入力層方向の層）へと順に伝え、2乗誤差を最小化することができる。

### 3. データの採取

現場における配合最適化システムの構築を考え、実プラントでミキサ容量 3.0m<sup>3</sup>の水平2軸強制練りミキサを用いて、硬練りコンクリートを対象としてデータ収集を行なった。配合は現場で「A配合」、「C配合」と呼ばれる2種類であり、それぞれの測定項目は表-1に示す。「A配合」と「C配合」は打設する箇所によって使い分けられている。スランプ値を計測するときは、ミキサ内の各バッチの上部、中部、下部におけるフレッシュコンクリートを採取し、40mmのふるいをういウェットスクリーニングしたものを計測し、その平均を用いた。現場で稼働中のミキサは2種類あるが、両ミキサから得られたデータのうち、本研究では1つのミキサで練られたコンクリートからのデータを用いた。2種類のミキサの積算電力量は、互いに練混ぜ性状が異なるので統一性がなく、1つのニューラルネットワークにおいて同時に入力することは、推定精度を低下させる原因となるからである。データを採取した時期は、11月～12月と4月～9月である。採用したデータのスランプ値を各バッチ毎に表したものが図-3であり、データの範囲は2.0cm～4.4cmである。

表-1 測定項目

測定項目
骨材表面水率
消費電力
材料の計量値
コンクリート体積
コンクリート温度
スランプ値

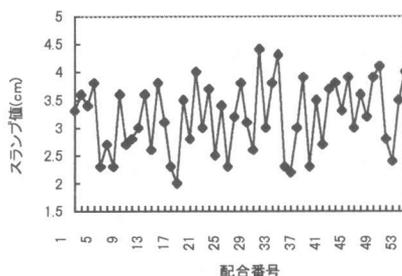


図-3 採用したデータ

### 4. 品質推定

本研究では図-4に示したような2段階の推定モデルを用いた。図中の粗骨材1は寸法が120～80(mm)、粗骨材2は寸法が80～40(mm)、粗骨材3は寸法が40～80(mm)、粗骨材4は寸法が5～0(mm)である。また、混和剤1と混和剤2は種類が異なる。このモデルの特徴は、第1段階のニューラルネットワークで骨材の表面水量の推定を行い、これによって得た真の配合を用いて、第2段階のニューラルネットワークで硬練りコンクリートの品質の1つであるスランプ値を推

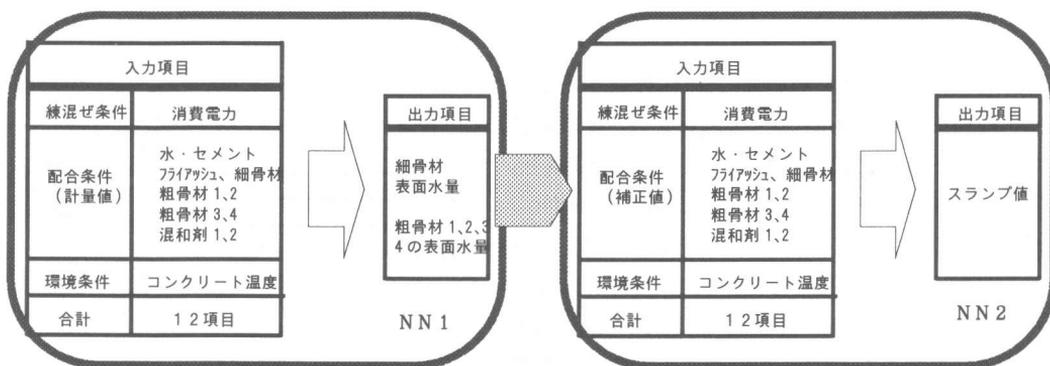


図-4 推定モデル

定することである。第1段階のニューラルネットワークで表面水量を求める理由は、各バッチ毎にサンプルとして1部分採取した骨材の表面水量だけでなく、積算電力量や各骨材量なども考慮して推定させることにより、より真実の値に近い表面水量が得られるからである。粗骨材寸法によって粗骨材表面水量を4種類に分けて推定さ

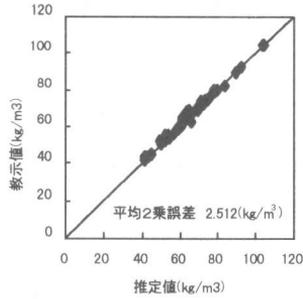


図-5 細骨材表面水量

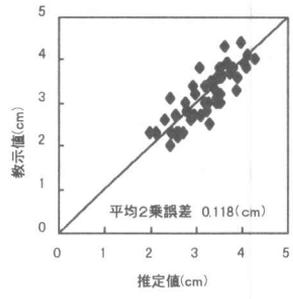


図-6 スランプ値

せたのは、硬練りコンクリートの品質に粗骨材の寸法の効果が影響しており[1]、それぞれを独立に扱った方が、最終的により最適な配合を設計できると考えたからである。第1段階と第2段階のニューラルネットワークの入力項目は同じである。

第1段階の細骨材表面水量と第2段階のスランプ値の学習状況を図-5、図-6に示す。

## 5. 配合最適化

### 5.1 最適化方法

配合最適化の基本的なアルゴリズムは参考文献[2]と同様に、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なった。

最適化は、「A配合」を1ケース、「C配合」を2ケースで計3ケース行った。

変化させる項目としては「セメント、フライアッシュ、水、細骨材、粗骨材2・3」の6項目で、人為的に操作が簡単で、最も現場に適用しやすいものを取りあげた。

本研究における硬練りコンクリートのスランプ値は約3 cm前後であり、値そのものが非常に小さいため、数センチメートルの違いで容易に目標値の2倍や2分の1倍の値が出る可能性がある。すなわち、最適化して配合修正した結果得られたスランプ値がニューラルネットワークによるものなのか、あるいは計測誤差や計量誤差によるものであるかわからない。そのような性質上、3回行なった最適化の目標スランプ値を3 cm、4 cm、3 cmと変化させ、この配合最適化システムが的確に作用しているかを調べようと試みた。

### 5.2 結果

最適化の結果を図-7に、同時に行なった品質推定の結果を図-8に、両方の結果を表-2に示す。3ケース行なった配合最適化における配合No.1、No.2、No.3それぞれの最適化前、最適化後をNo.1前、No.1後、No.2前、No.2後、No.3前、No.3後と記す。ここでの品質推定は、最適化前すなわちNo.1前、No.2前、No.3前のスランプ値に関するものである。配合No.1前は「A配合」、配合No.2前とNo.3前は「C配合」である。

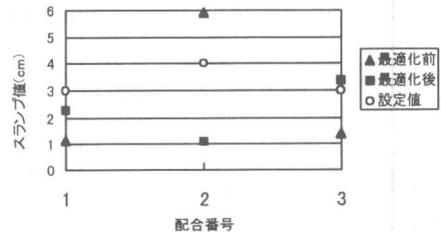


図-7 最適化の結果

まず、図-7の最適化の結果をみると、No.1後とNo.3後の最適化の精度が高いことに対し、No.2後の実スランブ値は設定したスランブ値よりも大きく異なっていることが分かる。同様に図-8の推定結果より、No.1前とNo.3前の推定精度が高いことに比べ、No.2前の推定精度が低いことが分かる。これより、最適化前の配合による品質の推定値の精度が低ければ、最適化も大きな誤差を伴いやすくなることがわかる。逆に、最適化前の配合による品質の推定精度が高いとき、配合

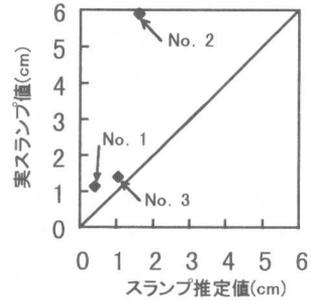


図-8 推定結果

表-2 最適化と推定の結果

	No.1		No.2		No.3	
	前(A配合)	後	前(C配合)	後	前(C配合)	後
実スランブ値(cm)	1.15	2.30	5.90	1.10	1.40	3.40
最適化前のスランブ推定値(cm)	0.43	-	1.63	-	1.04	-
最適化後のスランブ設定値(cm)	-	3.00	-	4.00	-	3.00

最適化も精度良く行われると考えられる。その理由は、最適化前の配合は最適化計算時の初期値として入力されるため、その配合の推定値の精度によって、最適化の精度が影響を受けるからである。

次に推定精度について考察する。No.1、No.3のスランブ推定値は1cm以内の誤差であるが、No.2のスランブ推定精度は低い。その理由として、①入力データにおけるコンクリート温度の範囲が実験時の温度を含んでいないこと、②入力データの骨材表面水量のばらつきより、実験時のばらつきの方が大きいこと、の2つが考えられる。理由①については、本実験を行なったのは1月で、現場は休みのため、この時期の学習データは存在しない。よって、コンクリート温度の学習入力値が11℃～25℃であるのに対し、実際の実験では10℃～11℃と、学習データ範囲から大きく異なっていた。理由②については、この時期は実プラントがしばらく停止していたため、貯蔵庫内の粗骨材表面水が蒸発してしまっていたり、細骨材の表面水率に大きなばらつき(2.4%～6.1%)が見られた。これは、実際の骨材表面水量のばらつきが学習入力値を逸脱していた原因である。そこでNo.1前・後とNo.3前・後の配合データを追加学習させて10℃～11℃のコンクリート温度を学習させ、同時にNo.2前・後のスランブ値の推定を行なった。その結果、図-9のように、学習を10万回行なっても、実際のスランブ値と推定値との間の平均2乗誤差は24.77cmであった。このことより、今回の実験におけるコンクリート温度が学習データのコンクリート温度と異なっていたという理由①よりも、骨材の表面水量のばらつきが学習データ範囲を越えていたという理由②の方が、No.2の配合最適化に誤差を生じさせる大きな原因であったことがわかる。逆に、より大きな骨材表面水量のばらつきを持ったデータを学習に

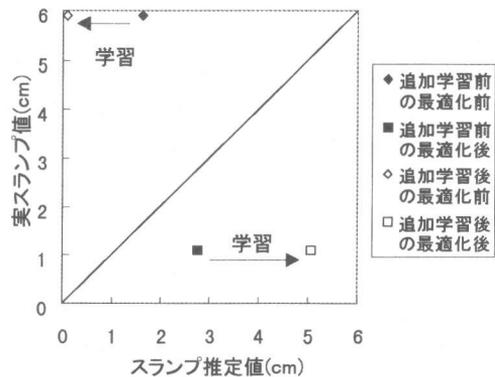


図-9 追加学習の結果

使うことによって、推定・最適化ともに精度を向上することが可能である。

次に、配合最適化が精度よく行われた No.1 後の配合について考察する。この配合のセメントとフライアッシュの合計は  $190\text{kg/m}^3$  であった。本来、「A 配合」のセメントとフライアッシュの合計は  $140\text{kg/m}^3$ 、「C 配合」のセメントとフライアッシュの合計は  $200\text{kg/m}^3$  を基準としており、「A 配合」を修正したはずの配合 No.1 後が、「C 配合」のセメントとフライアッシュの合計値に近づいている。このとき、配合 No.1 後のコンクリートが「A 配合」の性能（充填性や強度など）を保持できない可能性が生じる。本最適化プログラム中では、水、セメント、フライアッシュ、細骨材、粗骨材 2,3 の 6 項目に関して個別に制限条件を課しているが、新たにセメントとフライアッシュの合計に制限条件を加えなければならないと考えられる。そうすることによって、コンクリートが所要の性能を持つよう最適化することが可能である。別の手法として、配合最適化システムの汎用性は損なわれるが、学習データを「A 配合」からのデータだけにすることが挙げられる。この学習によって、性能が「A 配合」から大きく変わらないコンクリートを製造することができるであろう。

## 6. まとめ

本研究で得られた結果を以下にまとめる。

- (1) 配合最適化前の品質推定値の精度が高ければ、配合最適化の精度も高い。これは最適化前の配合が最適化計算時の初期値として入力されるため、その配合の推定値の精度によって、最適化の精度が影響を受けるからである。
- (2) スランプ推定値の精度が高かった配合をネットワークに追加学習した後、精度が低かった配合を推定させても精度が上がらなかった。実際の骨材表面水量のばらつきが学習入力値の範囲を逸脱していたことが原因である。すなわち、より大きなばらつきを含む学習データを入力することで、推定・最適化ともに精度を向上でき、ニューラルネットワークを用いた配合最適化システムは適用可能となる。
- (3) 最適化が精度良く行われた配合を調べると、元の配合よりセメントとフライアッシュの合計量が大きく異なっている。所望のスランプ値を得ることは出来たが、要求する性能（充填性や強度など）を持たないコンクリートである可能性がある。今後の課題としては、要求する性能を満たすよう制限条件を加えることが挙げられる。

## [謝辞]

本研究を行うに当たり、実験データの採集にご協力いただいた方々にここに感謝の意を表します。また、本研究の一部は平成 8 年度文部省科学研究費補助金(試験研究(B)、課題番号 07555436、研究代表：魚本健人)によったことをここに付記する。

## [参考文献]

- [1]加藤佳孝、魚本健人、堤知明：ニューラルネットワークによるコンクリートの配合最適化に関する研究、コンクリート工学年次論文報告集、Vol.18,No.1,pp1323-1328,1996
- [2]大矢孝、魚本健人、堤知明：ニューラルネットワークを用いたコンクリートの製造管理システムに関する研究、土木学会論文集、No.514/V-27,pp9-18.1995.5