

# 論文 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

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

**要旨:** RCD用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敏感に及ぼすため、配合時の品質管理が極めて重要である。コンクリートの製造には、様々な要因が絡み合っているため、単純に両者の関係を数式化し品質の管理を行うことは困難である。そこで、ニューラルネットワークという理論的に予測が困難であるような問題に非常に有効なシステムを用いて、RCD用コンクリートの品質の推定を行った。さらに、感度解析によって品質に影響する要因の抽出と定量化を行い、この結果を用いて要求性能を満たす配合を出力する配合最適化システムの構築を行った。

**キーワード:** ニューラルネットワーク、品質管理、感度解析、配合最適化

## 1. はじめに

ダムコンクリートの施工の合理化を目的として、超硬練り貧配合のコンクリートを振動ローラを用いて締め固める工法（RCD(Roller Compacted Dam-Concrete)工法）が多くのダムで利用されている。この工法に用いられるコンクリート（RCD用コンクリート）は単位水量が非常に少ないため、水量の変化がフレッシュコンクリートの品質に敏感に影響を及ぼし、結果として配合時の品質管理を非常に難しいものにしている。現在、一般的なRCD用コンクリートの品質管理としては、VC試験で行われているが、この試験は各練混ぜごとに行うのではなく通常1時間に1回を目安にして行われている。しかし、1時間間隔の品質管理では、例えば骨材の表面水量や気温などが

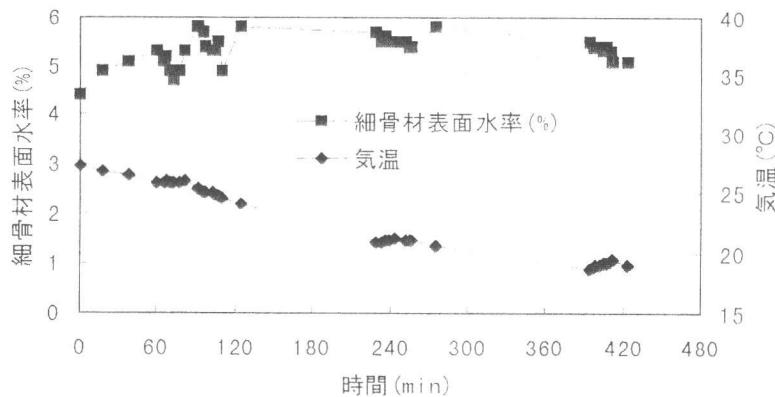


図-1 時間変動

変動すると（図-1参照）、コンクリートとしての品質も変動してしまうのは当然のことである。このような場合、リアルタイムでコンクリートの品質管理を行うことが重要となってくる。

そこで、本研究はニューラルネットワークを用いて実験データを学習させることによってRCD用コンクリートの品質を推定し、学習結果を用いて感度解析を行うことによって品質に影響する要因の抽出と定量化を行う。最終的に、この結果を用いて要求性能を満たす配合を出力する配合最適化システムの構築を行うことを目的とした。

\*1 東京大学生産技術研究所 助手 (正会員)

\*2 東京大学生産技術研究所 教授、工博 (正会員)

\*3 東京電力(株)電力技術研究所 構造研究室 主任研究員 工修 (正会員)

## 2. ニューラルネットワーク

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、演算速度が速く、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らかさを持っている。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えができ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、組み合わせが膨大な問題の順最適解の究明などを得意としている。

現在までに、著者らはニューラルネットワークを普通コンクリートの品質管理手法[1,2]およびRCD用コンクリートの品質推定[3]に関して適用し、このシステムの妥当性を確認している。

表-1 配合表

配合番号	粉体量 (C+F) (kg/m <sup>3</sup> )	F比 F/(C+F) (%)	水粉体比 W/(C+F) (%)	細骨材比 s/a (%)	単位量 (kg/m <sup>3</sup> )								AE減水剤 (kg/m <sup>3</sup> )
					水 W	セメント C	フライアッシュ F	細骨材 S	粗骨材 (mm)				
1	120	30	75	28	90	84	36	632	413	413	413	413	0.3

(注) G1 : 粗骨材寸法120~80、G2 : 80~40、G3 : 40~20、G4 : 5~0 (mm) である

## 3. データ収集

現場における配合最適化システムの構築を考え、今回実プラントでミキサ容量3,000リットルの水平2軸強制練りミキサを用いてRCD用コンクリートを対象としてデータの採集を行った。採集したデータの配合は表-1に、配合におけるそれぞれの測定項目は表-2に示す通りである。現在使用中のミキサには2種類あり、両者ともデータの採取は行ったが、ミキサが異なると練混ぜ性状が異なり、結果として積算電力量の値が統一性の無いものになる。このようなことは、ニューラルネットワークによる推定において、推定精度を著しく低下させる要因であるため、本研究ではミキサNo.1によるデータを使用した。VC試験に関しては、写真-1に示す試験体を使用し、40mmでウェットスクリーニングしたものに関して計測を行った。

今回の実験における目標VC値は20(sec)であり、採取したVC値の範囲および測定値の分布は図-2の通りであった。また、データ採取期間は10月~12月である。

## 4. 品質推定

現在までに、階層型のニューラルネットワークを用いて材料投入量(計量値)とコンクリートの練混ぜ条

表-2 測定項目

測定項目
骨材表面水率
消費電力量
材料の計量値
コンクリート体積
気温
湿度
コンクリート温度
VC値



写真-1 VC試験体

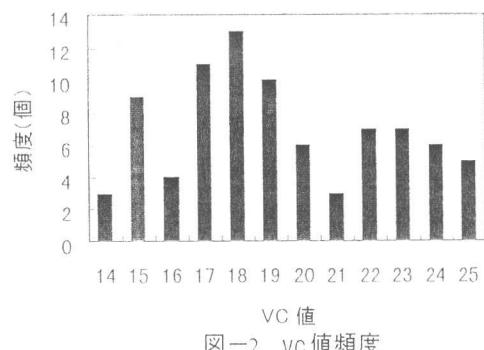


図-2 VC値頻度

件および環境条件の情報から、直接 VC 値を推定させるモデルを構築し、リアルタイムの VC 値の予測システムの可能性に関して検証を行っている[3]。しかし、本研究ではニューラルネットワークを用いた最適化配合システムの構築を目指しているため、推定モデルとして図-3 に示すような 2 段階のモデルを考えた。

このモデルは、最適化配合時に非常に重要であると考えられる、実際にミキサ内に投入された真の配合を推定するために、1 段階目（以下 NN1 と

記す）で骨材の表面水量の推定を行う。さらに、NN1 によって推定された真の配合から RCD 用コンクリートの品質管理値である VC 値を推定する 2 段階目（以下 NN2 と記す）のネットワークを考えている。粗骨材寸法によって 4 種類に分けた粗骨材の表面水量をそれぞれ独立に推定させたのは、RCD 用コンクリートには粗骨材の寸法の効果が影響していると考えられ、最終的に配合最適化をねらう場合、それを独立に取り扱った方が、より最適な配合を提案できるものと考えたからである。さらに、実際に最適化配合をコントロールする項目である NN2 における入力項目は、容易にコントロールすることが可能でありながら、全体として VC 値を精度良く推定しなければならない。したがって、コントロールすることが困難と思われる NN1 の入力項目で用いた湿度やミキサ温度などは、適切な入力項目とはいえない。

そこで、NN2 の入力項目を数種類設定してそれぞれ学習を行い、推定状況から NN2 の入力項目を決定することにした。それぞれの学習結果の一部を図-4 に示す。NN1 で採用した 13 項目を NN2 の入力項目として採用したものは、精度良く推定がなされているが、項目が一つ抜けただけで推定精度が著しく落ちてしまうことがわかる。以上により、NN2 の入力項目を図-3 に示

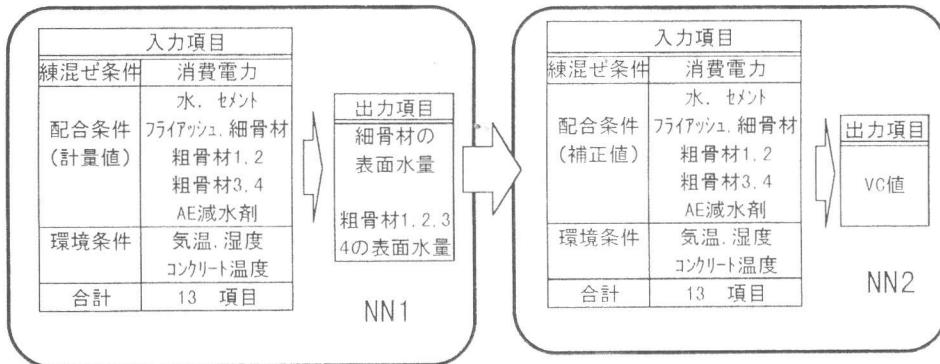


図-3 推 定 モ デ ル

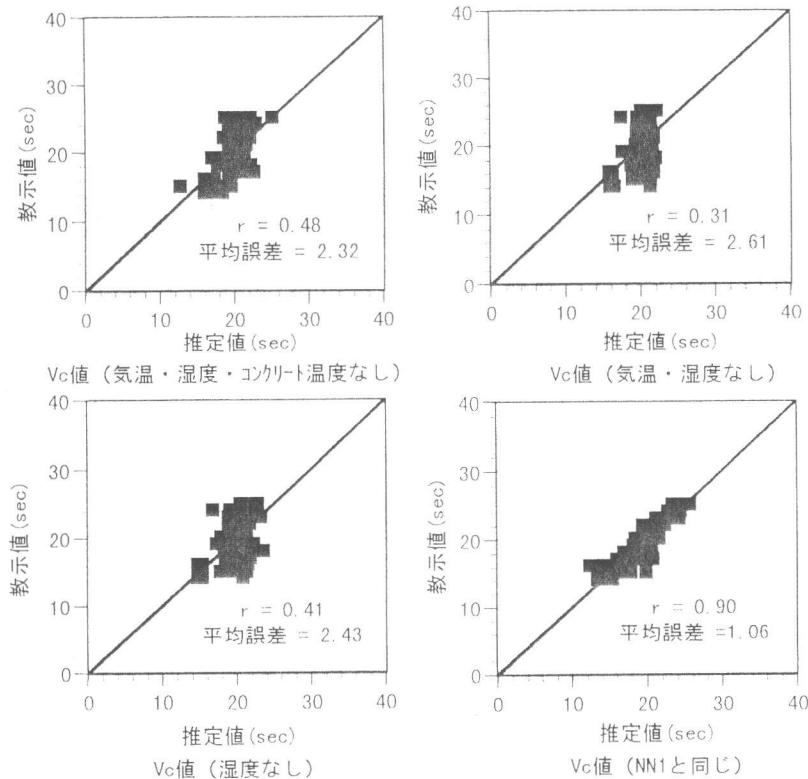


図-4 入力項目を変化させた場合の学習状況 (NN2)

そこで、NN2 の入力項目を数種類設定してそれぞれ学習を行い、推定状況から NN2 の入力項目を決定することにした。それぞれの学習結果の一部を図-4 に示す。NN1 で採用した 13 項目を NN2 の入力項目として採用したものは、精度良く推定がなされているが、項目が一つ抜けただけで推定精度が著しく落ちてしまうことがわかる。以上により、NN2 の入力項目を図-3 に示

したように NN1 と同様にし、最適化配合時には人為的にコントロールが困難である項目に関しては、パラメータとして使用せずにシステムの構築を行うことを目指した。

NN1 の一部と NN2 における学習状況および未学習データの推定状況の結果を図-5、表-3 に示す (NN2 は図-4 参照)。骨材の表面水量および VC 値の学習データにおける推定精度は非常によい結果となっているのに対し VC 値の未学習データにおける相関係数は 0.65 と低い値を示していることがわかる。しかし、ニューラルネットワークの推定精度を検討するのは、推定値と教示値間の相関係数を用いるよりも、平均誤差を用いた方が適切である。なぜなら、ニューラルネットワークの場合、相関係数

というものは “ $y=x$ ” の直線に対するものを探しているのであり、たとえば(2.0)と(0.2)の 2 個のデータが存在すると、相関係数は “1” となってしまうからである。また、現在一般的に用いられている目標 VC 値が  $20 \pm 10$ (sec)であることや VC 値の測定精度の面から考えても、未学習データの推定状況の結果は、平均誤差の値から判断して精度良く学習がなされているといえる。

## 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[1]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った。

最適化を行う上で、NN2 の入力項目中で変化させる項目を決定するために感度解析を行った。感度解析の結果を図-6 に示す。今回の感度解析は、表-1 の配合を基準値として用い各項目が 1% 変動したときの VC 値の変化率を示している。感度解析の結果を見ると、フライアッシュおよび水量の影響が大きいことがわかる。また、人為的にコントロールが困難と思われる環境

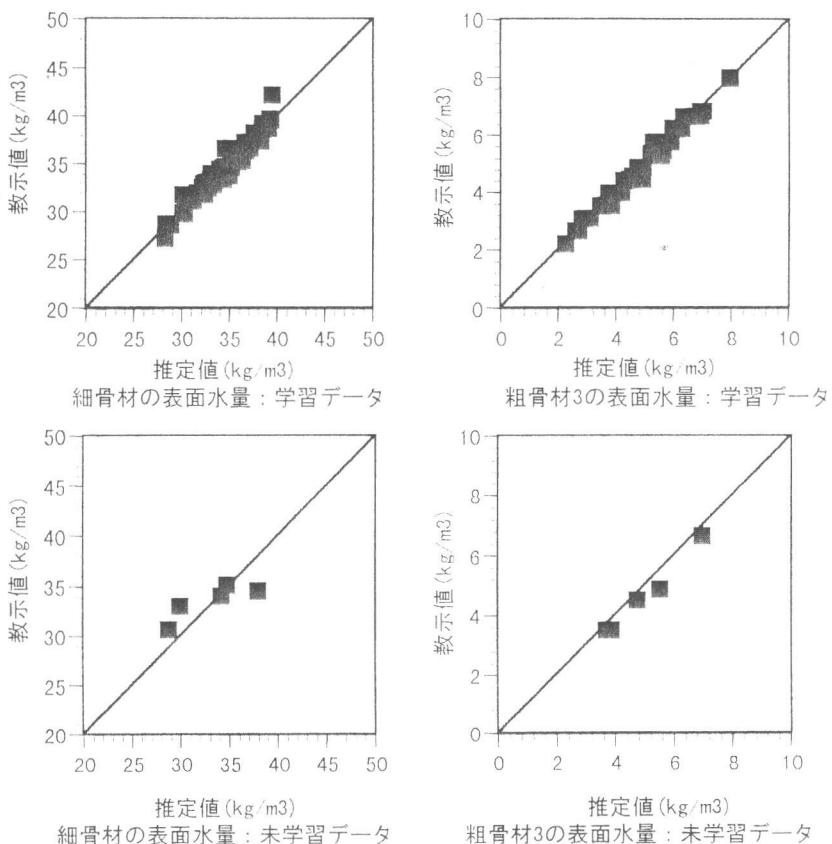


図-5 学習結果

表-3 推定結果まとめ

	平均 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
細骨材の表面水量	0.39 (kg/m³)	1.8 (kg/m³)	0.97	0.81
粗骨材3の表面水量	0.1 (kg/m³)	0.52 (kg/m³)	0.992	0.92
VC 値	1.06 (sec)	2.44 (sec)	0.9	0.65

条件（気温・湿度・コンクリート温度）に関しては、他の要因（水・結合材・骨材）と比較すると相対的に小さいため、変化させる項目として採用する必要がないということがわかった。このように、感度解析を用いることによりコンクリートの品質に与える影響度の高・低を定量的に把握することができる。変化させる項目としては、“水・セメント・フライアッシュ・細骨材・粗骨材2,3”の6項目とし、それぞれに制約条件を設けてある。既存の最適化設計のアルゴリズム[1]では制約条件として取り込まれていなかった、最適化後の配合の全体積に関する条件も組み込み、より実際に適用しやすいシステムを構築した。配合最適化の初期値は実験データの値（未学習データ）を用い、目標値として本研究では、VC値20.0(sec)を想定した。

## 5. 2 結果

最適化を行った結果を図-7に示す。また、最適化のパラメータとして使用した6項目の最適化前後の値（それぞれ骨材の表面水量を補正したもの）およびVC値の変化例を表-4に示す。

参考文献[1]中の最適化設計が最適化前後ともニューラルネットワークによって推定された結果を用いた疑似配合最適化であったのに対し、現場での適用性の確認をするために、図中の最適化前のVC値のデータは、実際に現場で採取したものを使用した。

各配合ともVC値の設定値に合うように最適化がなされていることがわかる（図-7参照）。なお、表-4からわかるようにニューラルネットワークによって構築したシステム中においても、VC値を15および17(sec)から20(sec)にするために水量を少なくしており、実現象に沿ったネットワークの構築がなされていると思われる。

ここで、学習データの推定誤差の推移と各学習時における最適化目標値との誤差の関係を図-8に示す。平均推定誤差は全学習データにおける値であり、学習回数を重ねるごとに小さくなっている。最適化目標値との誤差（配合2・4は表4中のもの）は、No.2の場合ある程度振動しながら約12万回でほぼ誤差が“0”になるのに対し、No.4では1万回後からほぼ“0”になることがわかる。現在の学習モデルは、全学習データの平均誤差を収束条件の判定値として用いているため、データ内での推定精度の偏りがあった場合においても学習を終了してしまう可

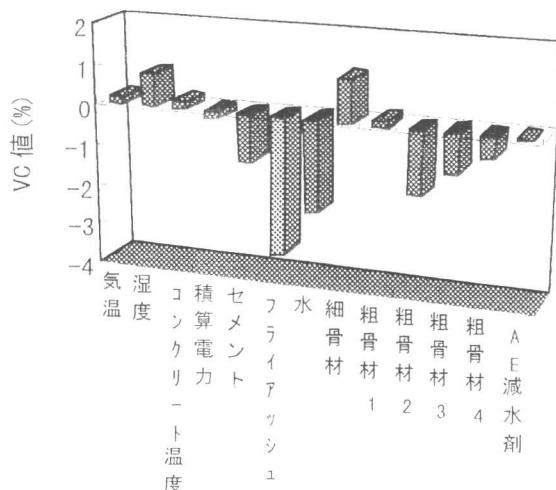


図-6 感度解析結果

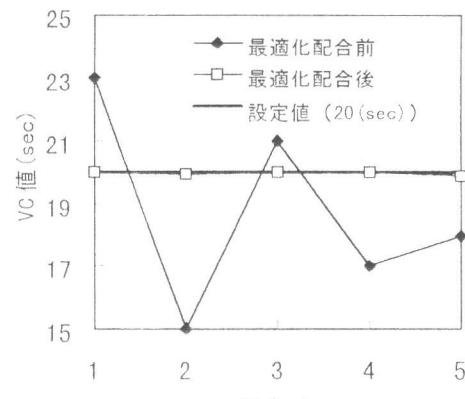


図-7 最適化配合結果

表-1 最適化前後の配合

配合 (No.)	項目 (kg/m <sup>3</sup> )						VC値 (sec)
	W	C	F	S	G2	G3	
2 前	83.8	92.3	39.7	626.0	431.1	432.7	15
2 後	82.3	91.6	41.9	643.6	447.9	413.1	19.96
4 前	84.2	92.3	40.4	628.5	429.8	436.3	17
4 後	83.1	92.9	38.8	620.6	461.2	427.4	20.02

(注) 表中のW,C,F,S,G2,G3は表-1と同様である

能性がある。このような場合、図-8のNo.2・No.4に見られるように一方は学習回数の非常に少ない時期に精度良く推定可能になるのに対し、他方はかなりの学習回数を必要とするものが生じてくる。本研究においては、採取したデータ全てに対して精度良く推定が可能であるようなネットワークを構築することができたが、以上のようなことを考慮すると、今後最適化配合を行うには学習モデル中に全ての学習データを精度良く推定できるような収束

条件を取り込んで学習を行う必要があると考えられる。

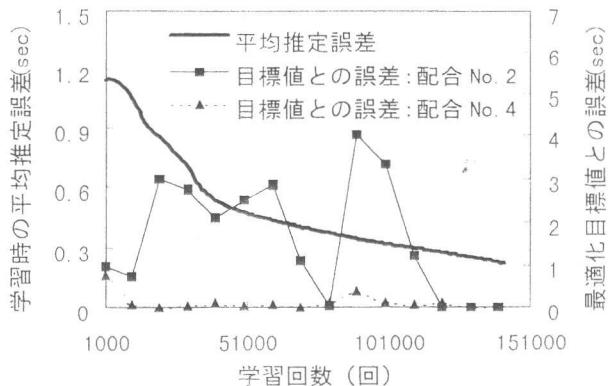


図-8 学習時の平均誤差変化と最適化目標値との誤差の関係

## 6.まとめ

本研究は、RCD用コンクリートの製造管理をニューラルネットワークを用いることにより、常に一定の品質のコンクリートを製造することが可能であるということを示したものである。以下に本研究で得られた成果をまとめる。

- (1) RCD用コンクリートの品質推定として、2段階のネットワークを組み、真の配合とVC値の関係を求めることによって、精度良く品質の推定が可能である。
- (2) 今回の実験の範囲内ではVC値に影響を及ぼす項目は、水量・結合材・骨材であるのに対して、環境条件はほとんど影響を与えないということがわかった。今回の実験は、比較的気温が一定であったことから考えて、年間を通したデータ（気温の差が明確にあるような場合）を採取しネットワークの構築を行った場合、環境条件もVC値に対して影響を及ぼす要因であると考える。
- (3) 水・セメント・フライアッシュ・細骨材・粗骨材をパラメータとして配合最適化を行うことによって、利用者が所望する品質を満足する配合を精度良く抽出することが可能である。

### [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7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] 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, pp.9-18, 1995.5
- [2] 加藤佳孝、大住道生、魚本健人、堤 知明：季節変動を考慮したコンクリートの品質管理システム：土木学会第50回年次学術講演会講演概要集第5部、pp.140-141, 1995.9
- [3] 安田 登、堤 知明、恒国光義、村上祐二：ニューラルネットワークを利用した超硬練りコンクリートの練混ぜ品質管理手法の実プラントへの適用、コンクリート工学年次論文報告集、第17卷、pp.1291-1296, 1995.6