

ニューラルネットワークによるRCD用コンクリートのVC値の推定手法に関する研究

安田 登¹・堤 知明²・関根裕治³・赤松英樹⁴・松島 学⁵

¹正会員 工博 東京電力㈱電力技術研究所構造研究室主管研究員 (〒230 横浜市鶴見区江ヶ崎4-1)

²正会員 工博 東京電力㈱電力技術研究所構造研究室主任研究員 (〒230 横浜市鶴見区江ヶ崎4-1)

³正会員 工修 東京電力㈱葛野川水力建設所第三工事事務所第一土木課長 (〒409-06 大月市七保町瀬戸1646)

⁴正会員 工修 東京電力㈱葛野川水力建設所第三工事事務所第二土木課長 (〒409-06 大月市七保町瀬戸1646)

⁵正会員 工博 東電設計㈱技術開発本部耐震技術部課長 (〒110 台東区東上野3-3-3)

本論文は、RCD用コンクリートの品質管理項目であるVC値の推定に、ニューラルネットワークの適用性を検討したものである。入力項目として、既知である練混ぜ前ならびに練混ぜ時に得られる配合条件及びミキサ消費電力量を、出力項目として、未知データである練混ぜ後に得られるVC値を予測するシステムを構築した。実プラントに適用した結果、VC値を精度よく推定することが確認された。また、完成されたシステムを用いてVC値のばらつき要因の分析を行った。その結果、感度のある因子は水分量に関係のある細骨材表面水率、細骨材量、投入水量ならびに積算消費電力量である。

Key Words : neural network, RCD concrete, VC-value, mixing quality control

1. はじめに

近年ダム用コンクリートは、その経済性ならびに施工性などの優位性から、RCD (Roller Compacted Dam) 用コンクリートが用いられることが多い。RCD用コンクリートは単位水量が少なく、水分量の変化が品質 (コンシステンシー) に敏感に影響を及ぼすため、配合時の水分量管理が極めて重要である。従来は水分量の管理方法を、骨材の表面水率測定と練混ぜ終了後VC試験により行っている。前者の骨材表面水率測定は各練混ぜ毎に行うが、後者のVC試験は、通常1時間に1回程度を目安に行う抜き取り試験である。

コンクリートは、骨材やセメント、水などから構成される不均質な複合材料であり、高粘性流体を仮定したモデルがないため、物理モデルを介したコンシステンシーの予測が困難である。このような物理モデルが当てはまらない場合、計測で得られたデータを用いた一種の逆問題から推定を行うことが一般的である。このような推定は、統計的手法である回帰分析や数量化理論の援用に頼っていた。しかし、統計的手法は原理的に線形問題を対象としていることから、多くの説明変数のうち相関の高いものを除去したり、非線形な部分を変数変換などにより擬似的な線形回帰に置き換え

る必要があった。従来の統計的手法で推定が困難な課題に対して、有効な手段として着目されているのが、ニューラルネットワークシステム^{1),2)}である。

ニューラルネットワークを土木分野へ実際に適用した例は未だ多くないが、複雑で経験的な判断を代替または分析評価する事例に、景観の評価³⁾、斜面の安定性評価⁴⁾あるいは筆者らによる建造物の健全度評価の分析^{5)~8)}などがある。コンクリート材料に関しては、スランプを有する普通コンクリートの練混ぜ品質管理に対し、ニューラルネットワークを適用した魚本らの研究^{9),10)}がある。具体的には、コンクリートの配合条件とミキサの消費電力の最大値や積算値を入力データとして、コンクリートのスランプ、空気量ならびに圧縮強度が推定出来ることを示しており、バッチャープラントにおける品質のばらつきを小さくするための最適化システムを提案している。RCD用コンクリートは、スランプを有する普通コンクリートに比べて、ミキサ練混ぜ時のトルクが練り混ぜ初期に増加し、その後ほぼ一定値となるため、普通コンクリートの品質管理手法をそのまま適用することは困難である。

RCD用コンクリートでは、コンクリート1m³中のペースト容積を細骨材の空隙容積で除したペースト細骨

材空隙比(α)¹¹⁾がコンシステンシーと関係があることを利用して、配合特性 α と VC 値の関係が線形回帰可能であるとの考え方¹²⁾がある。この考え方は、将来的に配合設計などに有効であると考えられるが、リアルタイムに VC 値を予測することに対しては入力因子が限定されていて、現時点では実用上問題が残されている。

本論文は、試験施工に際し実プラントで行われた練混ぜ試験結果に基づき、骨材量、結合材量、投入水量、細骨材表面水量、骨材比重、吸水率ならびに練混ぜ時の消費電力を入力値にしてニューラルネットワークを構築し、実プラントでのリアルタイムの VC 値予測の可能性を検証したものである。さらに、構築したニューラルネットワークを用いて感度解析を行うことにより、VC 値に影響を及ぼす因子を明らかにした。

2. ニューラルネットワークを利用したVC値の予測

(1) RCD 用コンクリートのミキサトルク

パッチャープラントにおけるコンクリートの品質管理は、従来からトルク値が操作盤に表示されていることもあり、オペレータがミキサトルクを見る習慣があった。経験豊富なオペレータは、トルク値の微妙な変化が細骨材の表面水率の変化と関連していることを熟知しており、配合の表面水率の変動等によるコンシステンシーの変化を経験的に調整している。さらに、ミキサの消費電力量とスランプとの間には密接な関係があり、コンクリートの練混ぜ時間に最適値があることも示されている^{13),14)}。魚本ら⁹⁾によれば、ミキサの消費電力量を測定することは、練混ぜ時においてミキサの羽に直接作用する力(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とすることが可能であるとしている。つまりミキサのトルク値は、ミキサを駆動する電動モータが消費する電力と等価であることから、トルク値としてミキサの消費電力を測定した。

RCD 用コンクリートと有スランプの普通コンクリートのミキサ消費電力を比較して、図-1および図-2に示す。ミキサ消費電力の時系列波形のうち、ミキサの羽の回転による高周波の脈動は両者共に観測されるが、全体形状は、RCD 用コンクリートがほぼ平坦であるのに対して、普通コンクリートでは、山なりのカーブを描き、大きく異なる。この理由は、粗骨材に対し潤滑剤の働きをしているモルタル分の比率の違いにある。普通コンクリートの場合は練混ぜ初期つま




図-1 ミキサの消費電力(普通コンクリート)




図-2 ミキサの消費電力(RCD用コンクリート)

り材料投入直後はモルタルが十分形成されておらず、粗骨材同士が噛み合う摩擦が支配的で、練混ぜが進むにつれてモルタル成分が十分出来上がり徐々に粘性体へと移行すると考えられる。一方、RCD 用コンクリートの場合、モルタル分の比率が小さいため、練混ぜが進んでも粗骨材の周囲にモルタルが付着している程度で、粘性体とは成らず、始めから終わりまで摩擦が支配的であると想定される。RCD 用コンクリートは、消費電力の全体波形がフラットであるため、代表させるパラメータとしてはフラット部分の平均値を用いることが可能である。ここでは、平均値の代わりとして、消費電力の時系列波形の積分値を継続時間で除した単位時間当たりの積算消費電力量を入力データとして採用した。普通コンクリートのように、波形全体の特徴が利用できないが、逆に積算電力のように単純なパラメータで定義することが可能となる。

(2) システムの入出力項目

本ニューラルネットワークは、練混ぜ前ならびに練混ぜ時に得られるデータを入力項目とし、練混ぜ後に得られる VC 値を出力項目とした。入力項目は表-1に示すとおり 19 項目とした。入力項目の選定基準は、

リアルタイム推定が目的であるため、日常管理を行う際に入手可能であり、極力自動入力できるデータに限定した。従って、細骨材の粗粒率、骨材の実積率、0.15mm以下の微粉量あるいはG4粗骨材の表面水率などは、コンシステンシーに関係があると考えられるが、今回構築したシステムの入力項目には含めなかった。粗骨材量は、実プラントにおいて表面水率を1日1回程度計測し配合補正を行っているため、表面に付着した水量も含む重量となっている。しかしながら、細骨材の表面水率は、VC値に大きく影響することから各バッチごとに測定されており、独立の入力項目とした。骨材の比重および吸水率を入力値にした理由は、ダムサイトの骨材採取場所により岩石の種類が変化し、その結果がVC値に影響することを考慮するためである。コンクリートのコンシステンシーにはこの他に、練り温度の影響も大きいことが知られているが、今回使用したデータは春季から夏季にかけての短期間であり、気温は18℃～30℃に変化したものの、コンクリートの練上がり温度は21℃±1℃の範囲であり、温度変化が極めて僅かであったため、入力項目には含めなかった。

出力項目は、RCD用コンクリートのコンシステンシーの管理にVC試験を行っていることから、その指標であるVC値とした。なお、ここで用いたVC値は小型VC試験の値であり、試験に供する試料は事前にウェットスクリーニングを行い40mm以上の粗骨材を除いて測定したものであり、バッチャープラント内のコンクリートのコンシステンシーとは厳密な意味では異なる。しかしながら、小型VC試験の値とフルサイズの骨材を用いる大型VC試験の値には、相関関係がある¹³⁾ことが知られており、現場の管理試験としても小型VC試験が適しており、実際に小型VC試験で日常管理が行われているため、今回のシステムでは小型VC試験の値を用いることとした。VC値の推定精度をさらに向上させるためには、大型VC試験の値も今後検討する必要があると考えられる。

使用したセメントは、中庸熟ポルトランドセメントを、混和剤はAE減水剤を使用した。試験での練混ぜ時間は90secとし、ミキサ消費電力量は材料投入完了から30secの積算値とした。

(3) ニューラルネットワークのシステム構成

ニューラルネットワークは、脳神経細胞におけるニューロンとシナプスを数学的にセルとネットワークによってモデル化したシステムで、良く吟味された入出力の組み合わせデータを学習させることにより、複雑な非線形性の強いモデルに対しても適応能力が優れている¹⁵⁾。本研究では、図-3に示す教師付きの

表-1 入力項目

入力項目	データの範囲
1. 粗骨材 G1 (80~120mm)	916~1096kg
2. 粗骨材 G2 (40~80mm)	748~812kg
3. 粗骨材 G3 (20~40mm)	630~790kg
4. 粗骨材 G4 (5~20mm)	818~978kg
5. 細骨材量 S	1278~1464kg
6. 結合材量(セメント+フライッシュ)	207.4~264.9kg
7. 投入水量(水+混和剤)	53.46~127.40kg
8. 細骨材表面水率	3.1~8.3%
9. 粗骨材比重(G1)	2.7~2.74
10. 粗骨材吸水率(G1)	0.19~0.39%
11. 粗骨材比重(G2)	2.70~2.75
12. 粗骨材吸水率(G2)	0.18~0.50%
13. 粗骨材比重(G3)	2.70~2.74
14. 粗骨材吸水率(G3)	0.33~0.87%
15. 粗骨材比重(G4)	2.68~2.73
16. 粗骨材吸水率(G4)	0.79~1.53%
17. 細骨材比重	2.65~2.67
18. 細骨材吸水率	1.34~1.82%
19. 積算消費電力量(30sec)	606~680kWh




図-3 ニューラルネットワークシステム

学習法である階層型ニューラルネットワークを採用した。中間層は一般的に最もよく用いられている1層モデルを採用している。中間層の素子数はそれを決定する一般的な考え方はないが、経験的に入力層の1.0

表-2 試験施工の配合一覧

番号	水結合材比(%) W/C+F	結合材 量 C+F (kg/m ³)	単位量 (kg/m ³)								AE 減水剤 Ad(%)	データ数 (): 検 証データ
			水 W	セメント C	フライアッシュ F	細骨材 S	粗骨材					
							G 1	G 2	G 3	G 4		
1	78.2	110	86	77	33	637	417	417	417	417	0.275	3(1)
2	82.7		91			634	415	415	415	415		5(2)
3	87.3		96			630	412	412	412	412		1(0)
4	70.8	120	85	84	36	635	416	416	416	416	0.300	4(2)
5	75.0		90			632	413	413	413	413		20(6)
6	79.2		95			628	411	411	411	411		4(1)
7	69.2	130	90	91	39	629	412	412	412	412	0.325	10(3)
8	75.0	120	90	84	36	699	396	396	396	396	0.300	2(0)
9	79.2		95			695	394	394	394	394	0.300	5(0)
10	75.0		90			636	416	416	416	396	0.300	15(4)
11	73.3	120	88	72	48	636	416	416	416	416	0.300	7(2)
粗骨材最大寸法 G _{max} =120mm, 空気量 Air=1.5±1%											合計	76(21)

～2.0 倍の範囲が適切¹⁶⁾とされている。本研究で採用した中間層の素子数は、入力層の 1.5 倍の 30 個であり、事前のケーススタディで最も学習効率の高いことが明らかとなっている。また、シグモイド関数の温度 T は、0.2～2.0 の範囲が適切¹⁶⁾とされており、本研究では温度 1.0 とした。

3. 学習に利用した入力データ

使用データは、練混ぜ容量 3,000リットルの水平 2 軸強制練りミキサ（写真-1）を備えた実プラント（写真-2）から採取した。VC 値に及ぼす各ばらつきの要因は、① VC 試験の誤差、②骨材表面水率の変動、③材料の計量誤差が考えられる。今回使用した計量装置の誤差は、80mm 以上の粗骨材(G1)では計量値の 3%以内、細骨材および 80mm 以下の粗骨材(G2～G4)では 2%以内であり、セメント、フライアッシュおよび水は、計量値の 1%以内である。試験施工では、表-2 に示すとおり配合の組み合わせを変化させて、結合材量 110, 120 および 130kg/m³ の配合で、97 個のデータが得られた。前述の表-1 に併記したデータの範囲は、実際の配合である 1 バッチ 2,000リットルの値であり、同一配合条件とした場合の変動幅よりも広く、実際のデータが持つばらつきを考慮すれば、システムの信頼性が高いと考えられる。

学習が終了したシステムの検証用に、学習に利用しないデータが必要であるため、全体として偏りがないように予め 21 個のデータを確保した。従って、学習に利用したデータは 76 個となる。ニューラルネットワークは、一般にデータ数が多いほど良いとされており、最小自乗法の評価関数が用いられる一般の線形回




写真-1 ミキサ全景



写真-2 プラント全景

帰モデルと同様である。実データには誤差が含まれているため、使用するデータが母集団を適切に代表していることが重要であり、既往の研究¹⁷⁾よりこの程度の個数があれば母集団を適切に推定できると判断した。

4. 学習ならびに検証

一般に複雑な問題をニューラルネットワークで学習する場合、学習回数の増加とともに認識誤差は小さくなるが、過学習になると汎化性が無くなり、未学習データの推定誤差に問題が生ずると言われている¹⁵⁾。過学習を回避するために、学習回数毎の誤差の推移を算定した。学習データの認識誤差と未学習データの推定誤差を図-4に示す。学習回数が増加するとともに認識誤差は単調な減少傾向を示すが、推定誤差ははじめ減少しその後増加する傾向を示す。過学習の明確な定義は存在しないが、過学習が生じる要因としては学習回数以外に、中間層の層数や素子数などのシステムの構造に起因する要因と、学習に用いたデータや入力項目の選定などの対象とする問題の性質に起因する要因が考えられる。ここでは各種要因のパラメータスタディとして、中間層の素子数を $N=40, 35, 30, 23$ と減少させ、シグモイド関数の温度 $T=0.5, 1.0, 2.0$ と変化させた結果、ほぼ全てのケースにおいて未学習データの推定誤差に極小値が存在することが確認され、最も学習効率の良い $N=30, T=1.0$ のときの学習回数はほぼ7,000回であることが明らかとなった。従って、今回の問題に対して適切な学習回数は、未学習データの推定誤差が極小となる段階と考え、本システムの学習回数を7,000回とした。なお、学習回数は、入力項目や使用したデータに依存するため、回数の絶対値には特に意味がない。また、今回のシステム構築に使用した電算機は、HP-apollo Model 715/50のワークステーションを用いており、学習に要する時間は約5分程度、推定はほとんど瞬時に行うことができる。

学習結果ならびに学習が終了したシステムに未学習データを推定させた検証結果を、図-5ならびに図-6に示す。それぞれ実測値に対するシステムの出力値の関係であり、学習ならびに検証が良好であることが読みとれる。目標とするVC値が20secであり、その周囲にデータが集中しているが、30sec以上のVC値に対しても妥当な精度で推定がなされている。また、VC値が大きくなると誤差も大きくなり変動係数が一定になっていると推察できる。さらに、学習における認識誤差と検証における推定誤差の頻度分布を図-7ならびに図-8に示す。

認識誤差と推定誤差の標準偏差は、それぞれ $\sigma = 5.71\text{sec}$, $\sigma = 7.45\text{sec}$ となり、VC値の管理目標である $20\text{sec} \pm 10\text{sec}$ と比較して十分小さく、偏りもないことがわかる。さらに、既往の研究^{18), 19)}でVC試験のばらつきが変動係数で0.2程度であることより、目標VC値20secでの標準偏差が4.0sec程度となることから、ニューラルネットワークがVC値の推定に対して




図-4 学習における誤差の推移




図-5 学習結果 (N=7,000回)




図-6 検証結果 (N=7,000回)

十分精度を有していることが理解できる。

以上の検討により、ニューラルネットワークが多くの入力因子が関連する複雑なモデルに適用可能であることを実例として示すことが出来た。一方、ニューラルネットワークの階層構造を構築する際に、中間層




図-7 学習結果の認識誤差分布




図-8 検証結果の推定誤差分布

の設定や学習回数の決定に対する適切な方法が確立されておらず、試行錯誤的に検討を行う必要があることが、現状における欠点として指摘される。しかしながら、システムの構造が補償されない問題に対しては、次に述べる感度解析を用いることで解決することも可能である。

5. 感度解析

(1) 感度解析の手法

学習が終了したニューラルネットワークを用いて、入力項目の出力項目に対する感度解析を実施した。各入力項目の出力項目に対する感度を比較することにより、本システムが妥当な VC 値の推定過程を学習しているかを検討した。感度解析の理論的な記述については参考文献⁹⁾に譲るとして、ここでは具体的な計算方法について説明する。

本手法では、着目する項目以外を入力値を平均値に固定し、着目する項目を平均値から $\pm 1.0 \sigma$ (標準偏差) の範囲で離散的に変化させ、ニューラルネットワーク

システムを用いて VC 値の変化を計算した。この計算結果を利用して、入力項目 i の平均値近傍の感度 δ_i は式(1)で定義される。

$$\delta_i = \frac{|VC_{+\sigma} - VC_m| + |VC_m - VC_{-\sigma}|}{2 \times VC_m} \quad (1)$$

ここに、 δ_i : 入力項目 i に対する VC 値の平均値近傍の感度、 $VC_{+\sigma}$: 入力値の平均値 $+1.0 \sigma$ に対応する VC 値、 VC_m : VC 値の平均値、 $VC_{-\sigma}$: 入力値の平均値 -1.0σ に対応する VC 値である。

各入力項目毎の平均感度から表面水率の変動に伴う配合補正に関する総合的感度は、式(1)の左辺を利用して $\sum \delta_i^2$ により総合化することから求まる。

しかしながら、入力項目のうち相関性のある因子が存在する場合は、式(2)に示すように条件付き確率として定義される。

$$P_r = P(E|a)P(a) \quad (2)$$

条件付き確率とは、ある因子 a の条件が存在する場合の E の生起確率 P_r で定義され、感度解析についても同様に考えることが出来る。表面水率と細骨材量などが相関性のある関係となり、細骨材量は前述したとおり表面水率の測定値により配合補正が行われ、表面水率が増加すると細骨材の計量値が増加する傾向がある。相関性のある各因子を全て独立として扱うと、実際に各因子が取り得る値の組み合わせに矛盾が生じるため、感度を算定する場合も相関性のある因子に関しては、条件付き確率の考え方を取り入れることとした。相関性のある入力項目については、相関を有する方向に同時に値を変化させ、他の入力項目を平均値に固定して求めることとした。具体的には、全入力因子間の相関を求め、相関係数が 0.7 以上のものを選択し²⁰⁾、その中で実際のフレッシュコンクリートの性質と矛盾しないものを相関のある因子と仮定した。

得られた相関性のある因子は水量の変動に関係のある因子であり、その例として、図-9 に細骨材表面水率と投入水量の関係、図-10 に細骨材表面水率と細骨材量の関係、図-11 に積算消費電力量と投入水量の関係を示す。以上の関係から「細骨材表面水率」「投入水量」「細骨材量」「積算消費電力量」の4つの因子を完全相関と仮定した場合の複合感度を求めた。それ以外の相関性のない結合材量、粗骨材(G1~G4)量の5つの因子は完全独立として感度を求めた。なお、感度解析を行う際の母集団としては、配合条件が同一のものを対象としているため、骨材の採取場所は同一となり、骨材の種類を特定するための比重ならびに吸水率は一定とした。




図-9 細骨材表面水率と投入水量の関係




図-10 細骨材表面水率と細骨材量の関係




図-11 積算消費電力量と投入水量の関係

(2) 感度解析結果

感度解析は、今回採取した 97 個のデータのうち配合条件並びに骨材が同一の 22 個のデータを用いた。感度解析の対象となる母集団の VC 値の頻度分布を図-12 に示す。VC 値の平均値は 21.8sec、標準偏差は 10.6sec、変動係数は 48.5% と同じ配合条件でも大きくばらつくことがわかる。このデータを利用して VC 値に対する各入力項目の感度を求めた結果を図-13 に示す。

VC 値に対する感度が最も大きな因子は細骨材表面水率である。細骨材表面水率の感度の算定は、水量と細骨材量も同時に考慮していることを考えると、配合補正における水量あるいは細骨材量の変化が VC 値の変動に最も影響しているものと判断できる。このことは、実プラントの技術者が経験的に有している知見、すなわち水分量の管理が VC 値管理の最も重要であるとの認識とも一致している。細骨材の表面水率の測定は各バッチごとに行っているが、そのデータにより配合補正を行うのは次バッチであり、測定された細骨材が投入されたバッチには反映されない。さらに、急激な表面水率の変化を直接配合補正に反映させると結果的にコンクリートのコンシステンシーが不安定になることを経験的に熟知しているため、表面水率の変動の経時的なトレンドを考慮して配合補正を行う複雑な意思決定プロセスを経ている。つまり、他の要因が計量装置の誤差で説明が可能であることと比較して、水分量に関する因子は管理が困難であるが故に複雑にして大きなばらつきの原因となっている可能性がある。

次に、各感度から図-12 のばらつきの再現性に関して検討を行った。前述した各入力項目の感度は、VC 値のばらつきを反映しているものと考えられる。したがって、実測結果のばらつきと入力項目の感度より計算した VC 値のばらつきの総合化した値と比較することにより、今回構築したニューラルネットワークの妥当性を評価することにした。

各入力因子による VC 値の感度 δ_i は、式(3)により総合化される。

$$\delta_{T_0}^2 = \sum_{i=1}^n \delta_i^2 \quad (3)$$

式(3)は、各入力項目を完全独立と仮定した場合の式であり、厳密には相関を持った因子を考慮して計算する必要があるが、ここでは単純に平方和として総合感度を求めた。計算の結果、 $\delta_{T_0} = 0.49$ が得られた。さらに、実測の VC 値には、VC 試験の測定誤差 δ_m が含まれる。既往の研究^{(15), (16)}による VC 値測定誤差の実測値が $\delta_m = 0.2$ 程度であることから、VC 値のばらつきは、

$$\delta_T^2 = \delta_{T_0}^2 + \delta_m^2 = 0.49^2 + 0.2^2 = 0.53^2 \quad (4)$$

と求められる。図-12 に示した実測 VC 値のばらつき 48.5% と比較して、若干の誤差はあるものの、本システムは妥当な結果を示していると考えられる。従って、ニューラルネットワークが妥当な学習を行ったことを裏付けており、実プラントへの適用が可能であるとされる。

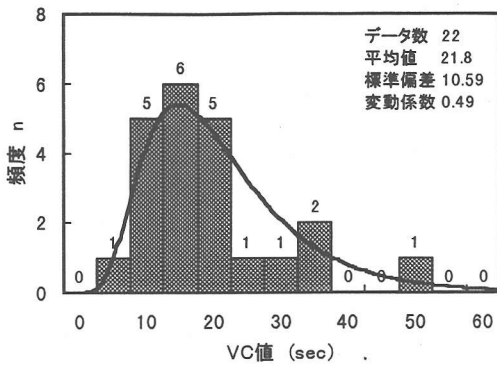


図-1 2 VC 値のばらつき




図-1 3 各因子の感度

6. まとめ

ニューラルネットワークに基づく新しい品質管理システムは、普通コンクリートと比較して品質管理の難しいRCD用コンクリートに関して、リアルタイムで練混ぜ終了後の品質特性を表すVC値を精度良く推定し得ることが明らかとなった。本研究により明らかとなったことをまとめると、以下のとおりである。

- (1) 入力項目に配合条件と消費電力量の他、実プラントに設置されている細骨材表面水率測定装置のデータを含めることで、実プラントにおけるVC値の推定を、ニューラルネットワークを用いて精度良く実現することが出来る。
- (2) ニューラルネットワークを用いたRCD用コンクリートのVC値の予測システムの精度は、5sec程度であり、従来試験員が実施するVC試験の管理基準が 20 ± 10 secであることを考慮すると、十分な精度で推定することが可能である。
- (3) ニューラルネットワークの感度解析を利用してVC値に影響を及ぼす因子を調べた。その結果、最も感度の大きな因子は、水量に関連した細骨材表面水率、細

骨材量、投入水量、積算消費電力量である。

今回構築したシステムは、リアルタイムでRCD用コンクリートの練混ぜ管理に重要なVC値の推定が可能な手法である。実際のダムの施工には結合材量が一定の配合条件でコンクリートを製造する。今回利用したデータが配合条件の異なるデータを含めて良好な推定精度を実現したことは、実施工に対してはさらに単純な管理であることから、実用上十分に満足な品質を保証すると考えられる。但し、ニューラルネットワークの適用上の条件としては、学習に用いたデータの範囲内の推定を行う内挿補間が基本であり、物理モデルを介した推定がある程度の外挿も可能であるのに対して、推定の限界があることを考慮する必要がある。今回用いたデータは、練り上がり温度が一定の期間に採取されているため、冬季の推定を行うためには、さらに低温時のデータを取得して学習を追加する必要がある。このように、推定対象が学習データの内挿範囲内であることをあらかじめ吟味しておくことは、特に重要であると考えられる。

謝辞：本論文を遂行するにあたり、(株)間組技術研究所第四研究室主任研究員村上祐治博士には、データの取得ならびに吟味に関して議論に加わっていただきました。また、東電設計(株)技術開発本部耐震技術部恒国光義氏、中川貴之氏には、データ整理などの煩雑な労苦も惜しまずに協力していただきました。ここに深く感謝をいたします。

参考文献

- 1) 合原一幸：ニューラルコンピュータ，東京電機大学出版局，1988。
- 2) 高木英行：ニューラルネットワークの学習およびファジィと境界，日本ファジィ学会ファジィ推論とエキスパートシステムに関するワークショップ資料，1989。
- 3) 渡邊英一，古田均，森本浩之，利根川太郎：ニューラルネットワークを用いたダム構造物の景観設計支援システム，土木学会構造工学論文集，Vol. 38, No. 2, pp. 617-624, 1992
- 4) 白木渡，松保重之：ニューラルネットワークによる斜面崩壊予測に関する研究，土木学会第3回システム最適化に関するシンポジウム講演論文集，pp. 153-158, 1993. 12.
- 5) 安田登，白木渡，松島学，堤知明：ニューラルネットワークによるコンクリート構造物の劣化評価，コンクリート工学年次論文報告集，第15巻1号，pp. 847-852, 1993. 6.
- 6) N. Yasuda, T. Tsutsumi, T. Kawamura, S. Matsuo and W. Shiraki: Assessment of Deteriorating Reinforced Concrete Structures Using Artificial Neural Networks, Proc. of ISUMA'93, pp. 581-586, 1993. 4.

- 7) 白木渡, 松保重之, 安田登, 河村知之, 川野賢司: ニューラルネットワークによる塩害を受けるRC構造物の健全度評価, 土木学会第48回年次学術講演会概要集, 第I巻, pp. 1234-1235, 1993. 9.
- 8) 安田登, 白木渡, 松島学, 堤知明: ニューラルネットワークに基づいたコンクリート構造物点検技術者の思考過程の評価, 土木学会論文集, No. 496/V-24, pp. 76-85, 1994. 8.
- 9) 関口司, 魚本健人, 高田良章, 渡部 正: ニューラルネットワークを用いた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.
- 10) 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.
- 11) 建設省河川局開発課監修, (財) 国土開発技術研究センター編集: 改訂 RCD 工法技術指針(案), pp. 41-44, 53-55, 山海堂, 1989. 8.
- 12) 志水茂明, 柳田 力: RCD 工法における大型供試体試験, ダム技術, No. 26, pp. 3-14, 1988.
- 13) 魚本健一, 西村次男, 渡部正, 田中恭一: 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, pp. 109-118, 1992. 2.
- 14) 岸 清, 渡部 正, 山田一字, 魚本健一: ミキサの種類と練混ぜ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, pp. 53-60, 1989. 2.
- 15) 矢川元基編: 計算力学とCAEシリーズ 12 「ニューラルネットワーク—計算力学・応用力学への応用」, 培風館, pp. 146-148, 1992. 5.
- 16) 市川絃: 階層型ニューラルネットワーク-非線形問題解析への応用, 共立出版株式会社, 1993. 6.
- 17) 松島 学, 松井邦人: 採取個数から母集団の推定誤差に関する一考察, 土木学会第47回年次学術講演会概要集第I巻, pp. 1224-1225, 1992. 9.
- 18) 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による超硬練りコンクリートの品質管理, 構造工学論文集, Vol. 41A, pp. 1015-1021, 1995. 3.
- 19) 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巻, pp. 1291-1296, 1995. 6.
- 20) 石村貞夫: 統計解析のはなし, pp. 52-53, 東京図書株式会社, 1988.

(1996. 1. 26 受付)

PREDICTION METHOD FOR VC-VALUE OF ROLLER COMPACTED DAM CONCRETE USING NEURAL NETWORK

Noboru YASUDA, Tomoaki TSUTSUMI, Yuuji SEKINE,
Hideki AKAMATSU and Manabu MATSUSHIMA

In this paper, an advanced method of quality control for roller compacted dam concrete mixing is presented. The method to predict workability function VC-value belonging to input factor of mix proportion and mixing energy based on neural network was carried out. The successful neural network system for prediction of VC-value was constructed using experimental data. According to sensitivity analysis, the parameters, surface moisture of fine aggregate, volume of fine aggregate, volume of containing water and power consumption are obtained as important parameters which have effect on VC-values.