

論文 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

安田登^{*1}・堤知明^{*2}・松島学^{*3}・村上祐治^{*4}

要旨： 本論文は、超硬練り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積算電力量を、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。

キーワード：超硬練りコンクリート、ニューラルネットワーク、練混ぜ、品質管理

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)用コンクリートと呼ばれる超硬練りコンクリートが用いられることが多い。超硬練り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。従って、コンシステンシーを管理するために、骨材の表面水率は、各バッチ毎に測定している。しかし、品質変動を直接測定する 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り、練混ぜ後の事後管理である。なお、VC 試験とは、まだ固まらないコンクリート供試体に上載荷重を作用させて振動台で締固め、ペーストがコンクリート供試体の表面に浮き上がるまでの秒数を測定する試験で、この時の値を VC 値と呼び、コンクリートのコンシステンシーを表現する指標としている。普通、VC 値は 20 秒程度が適切であるとされている。

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のあてはまらない問題に対しては、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採用に頼っていた。しかし、統計的手法は通常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[1],[2]である。ニューラルネットワークとは、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。筆者らは、今までにも室内試験や実プラントでの試験的な適用を通してニューラルネットワークを利用した VC 値のリアルタイムの予測システムの有効性を検証してきた[3],[4]。

*1 東京電力（株）電力技術研究所構造研究室主管研究員（正会員）

*2 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）

*3 東電設計（株）技術開発本部耐震技術部課長、工博（正会員）

*4（株）間組技術研究所研究第五部主任研究員、工博（正会員）

本研究は、実プラントでの超硬練りコンクリートの製造に基づき、配合条件、練混ぜ時の消費電力などを入力項目にしてニューラルネットワークを構築し、リアルタイムの VC 値の予測システムの可能性を検証したものである。

2. システムの構築

2.1 超硬練り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はあった。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ブ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な値があることも示されている。




図-1 ミキサの消費電力の例

超硬練りコンクリートミキサ消費電力の例を図-1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が見られるが、全体形状はほぼ平坦である。超硬練りコンクリートは、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。

2.2 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。入力項目の一覧は表-1に示すとおり、全 18 項目とした。入力項目のうち粗骨材 (G1,G2,G3,G4) は、表面水率の自動計測が困難であるため、1日1回程度の計測による配合補正のみを考慮し、表面に付着した水量も含む重量としている。粗骨材 (G1,G2) の表面水率は、ほとんど変動が見られず VC 値への影響が小さいことから、入力項目としなかった。粗骨材 (G3,G4) の表面水率は、変動が認められるため、実測されたデータを独立の入力項目とした。細骨材の表面水率は、変動が大きいため、プラントの重量式水分計で自動計測を行って

表-1 入出力項目一覧

入出力項目		データの範囲
入 力	1. 粗骨材量G1 (80~120mm)	774~852kg
	2. 粗骨材量G2 (40~80mm)	844~874kg
	3. 粗骨材量G3 (20~40mm)	854~900kg
	4. 粗骨材量G4 (5~20mm)	846~874kg
	5. 細骨材量	1286~1342kg
	6. 結合材量 (セメント+フライアッシュ)	233.9~264.8kg
	7. 投入水量 (水+混和剤)	52.40~99.58kg
	8. 粗骨材表面水率 (G3)	0.3~1.8%
	9. 粗骨材表面水率 (G4)	0.7~2.0%
	10. 細骨材表面水率	4.3~6.6%
	11. 粗骨材吸水率 (G1)	0.17~0.21
	12. 粗骨材吸水率 (G2)	0.19~0.23
	13. 粗骨材吸水率 (G3)	0.31~0.37
	14. 粗骨材吸水率 (G4)	0.72~1.56
	15. 細骨材吸水率	1.28~1.56
	16. コンクリート練上がり温度	7.2~24.4°C
	17. ミキサ積算消費電力量 (30sec)	0.578~0.651kWh
	18. ミキサナンバー	1~2
出 力	1. VC値	12~80sec

おり、各バッチ毎の計測値を入力することとした。骨材の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。骨材の比重については、吸水率に強い相関があることから、VC 値に直接影響する骨材の吸水率に代表させた。コンクリートのコンシステンシーにはこの他に、練上り温度の影響も大きいことが知られており、ミキサ内で練混ぜ時のコンクリート温度も入力項目とした。使用したセメントは、中庸熱ポルトランドセメントを、混和剤は AE 減水剤を使用した。

2.3 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データを組み合わせた学習により、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。本研究では、図-2 に示す教師付きの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。中間層は一般的な 1 層を採用しており、素子数を決定する一般的な考え方はないが、経験的に入力層の 1.0~2.0 倍の範囲が適切とされている [5]。本研究で採用した中間層の素子数は、入力層の 1.5 倍の 27 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 の範囲が適切とされ⁵⁾、本研究では温度を 1.0 とした。

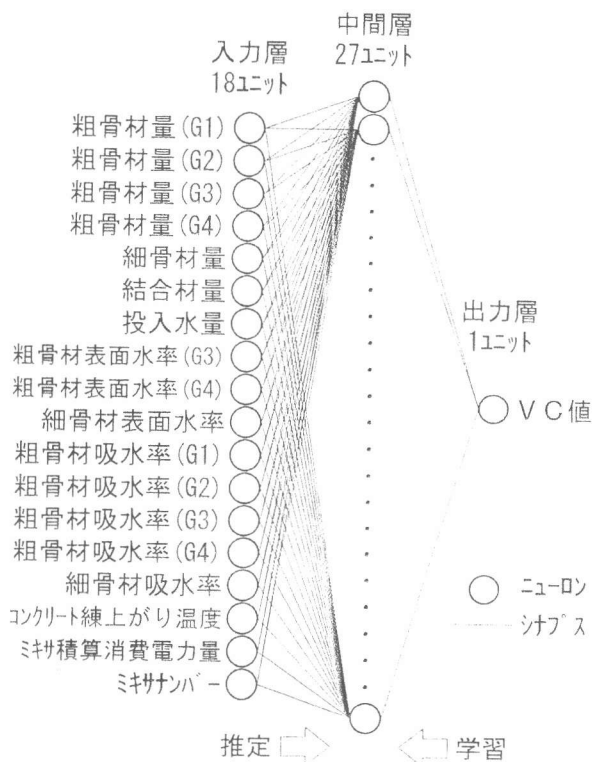


図-2 ニューラルネットワークの構造

3. 学習および検証結果

3.1 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 軸強制練りミキサを備えたバッチャープラントにおいて超硬練りコンクリートを製造する際に得られたデータを用いた。176 個のデータが得られたが、それらのデータは VC 値が目標管理内 (10~30sec) の範囲に安定しており、学習範囲が狭くなる恐れがあることから、VC 値が範囲外となる配合を追加して 6 個のデータを取得した。また、学習が終了したシステムの検証用に、予め学習に用いないデータが必要であるため、46 個のデータを全データから抜き取って確保した。従って、学習に利用したデータは 136 個となる。

3.2 学習および検証

一般に、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、複雑な問題の場合は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 [6]。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、学習の進行に伴い個々のデータのもっている固有の微細構造までを学習する。学習データについての近似精度は向上するが、未学習データに対する精度が悪くなる現象を言う [6]。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-3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。推定誤差の最小値は学習回数が300回と判読できる。一方、学習が不足しているシステムは、適切な入出力関係が得られない場合があり、これは感度解析による感度が既知の傾向と一致しないことなどで判読できる。さらに学習結果の誤差を元来データが有している誤差と比較する方法もある。ここでは、両方の方法を採用した検討を行った。VC値の試験誤差の変動係数は、0.2程度であることが、室内試験[3],[4]から判っている。従って、その値以上に学習することは、過学習と判断して最適な学習回数を考えた。具体的には、得られたVC値の平均値は20secであることから、 $20 \times 0.2 = 4.0\text{sec}$ となり、学習回数は1,000回が上限値と考えられる。図-4に各学習回数、




図-3 誤差の推移

300,800,1,000 および 10,000 回ごとの投入水量と VC 値の変化の関係を示す。本計算は、各学習回数ごとに得られたシステムを使って、投入水量以外の入力因子を平均値に固定し、投入水量だけを変化させ、VC 値を求めたものである。図に見られるように学習回数が1,000回程度であれば、一般的なVC値と水量の関係の知見と一致するが、学習が不十分な場合(300回)も、過学習(10,000回)の場合も、その傾向は一般的な知見と一致しない。この要領で他の因子についても計算したが、同様な判断がなされた。従って、今回の問題に対して適切な学習回数は、上記の傾向を総合的に判断し、本システムの学習回数を1,000回と設定した。




図-4 感度解析結果 (投入水量)

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(a)および図-5(b)に示す。それぞれ実測 VC 値に対する推定 VC 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であることより、その周囲にデータが集中しているが、学習では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。

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(a)および図-5(b)に示す。それぞれ実測 VC 値に対する推定 VC 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であることより、その周囲にデータが集中しているが、学習では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。

学習誤差と推定誤差の標準偏差は、それぞれ $\sigma_L = 2.51\text{sec}$, $\sigma_E = 3.36\text{sec}$ 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。




図-5(a) 学習結果 (N=1,000回)




図-5(b) 検証結果 (N=1,000回)

4. 現場へのシステムの適用

本システムを実際に適用するための現場品質管理装置の構成を図-6に示す。図に示すようにプラント操作盤から得られた消費電力量や配合条件がパソコンに送られ、自動的にニューラルネットワークシステムでVC値を計算し、画面に表示すると共に、10secごとに区分されたパネルにランプで表示される。1日の施工管理の経時変化の一例を図-7に示す。測定されたVC値は、わずか7個(●印)であるが、実線で表した推定VC値と整合性がある。また、投入水量(図中の波線)と推定VC値には相関があり、実用的には適用できるシステムであることを裏付けている。




図-6 RCD用コンクリートの現場品質管理装置の構成




図-7 RCD用コンクリートの現場品質管理の経時変化

5. 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超硬練り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超硬練りコンクリートの 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)本システムを現場のプラントにおいて実際の工事に適用した結果、VC 値を精度良く推定でき、品質管理のためのデータとして有効に利用できることを確認した。

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] 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.
- [4] 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.
- [5] 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ー計算力学・応用力学への応用」,pp.146~148,培風館,1992.5.
- [6] 市川紘: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.