

CS-157

ニューラルネットワークを利用したコンクリート表面色の評価方法

ーその2ー

鹿島建設(株) 正会員○伊藤功也 正会員 近藤嘉広
渡辺克彦

1. はじめに

打放しコンクリートの表面色は使用材料や施工方法、設置された環境等の影響によって変化するが、未だ因果関係は明らかにされていない。また、その表面色について定量的に評価する方法も確立されていない。今回、ニューラルネットワークを用いコンクリート表面色評価モデルの構築を試みた。その結果、人間の評価に合う汎化能力の高い評価モデルを得ることができた。その1では評価モデルの概要と統計的解析手法との比較について報告し、本報告では、ニューラルネットワークモデルの構造と学習方法、そしてモデルの分析結果について報告をする。

2. ニューラルネットワークの構造

今回用いたニューラルネットワークは4層（入力層：49、隠れ層1：7、隠れ層2：5、出力層：4）の階層型である。入力データは色彩計から得られる数値データであり、これを正規化して観測点分を入力層に与える。正規化については、学習の際にユニットの出力値が、伝達関数の有効な動作範囲（Sigmoid関数では-6～6）を超えないようにする（図-1、表-1）。

出力層は人間の評価で採用した4段階をそれぞれユニットに対応させた。4段階評価を数値化して1つの出力ユニットに表現する方法もあるが、連続性が必ずしも保証されない場合には、シンボルとして分ける方がよいようである。また複数人の評価値を教師データとする場合、ばらつきのある評価をうまく表現できるメリットもある。

各隠れ層のユニット数は試行錯誤を行い、2乗平均誤差(RMSE Error)（式-1）の収束具合から判断した。隠れ層、出力層のユニットは前層のユニットの出力値に重みを乗じた値の総和としきい値の差をSigmoid関数で変換し出力する。

ユニット間の重み変更を行なう学習規則には、デルタルールを用い、その学習規則（最急降下法）によって起こる局所解から抜け出すために、広域探索学習を試みた。この学習方法により、学習データに特化したモデルではなく、テストデータにも反応する汎化能力のあるモデル構築が可能となる。モデルの評価方法としては、RMSE Errorを用いた。




図-1 Sigmoid Function

表-1 入出力データの正規化範囲

	Sigmoid function
Input Network Ranges	-1.0 ~ 1.0
Output Network Ranges	0.2 ~ 0.8

$$RMSE Error = \left(\sum_{n=1}^k (T_n - O_n)^2 / k \right)^{1/2} \quad (\text{式-1})$$

T_n : 出力層における教師値

O_n : 出力層におけるネットワークの出力値

k : 出力層におけるユニット数

3. 広域探索手法

学習時において単純に学習回数を重ねると、ネットワークは学習データに特化したものになってしまう。特に感性に基づく人間による評価においては、教師データとなる大量の評価データを得るのが難しく、いきおい、非常に特化したモデルになりがちである。

そこで、一定回数ごとにテストデータを用いてネットワークの汎化能力を検証する。これによって過学習つまり、外挿に対しネットワークの能力が低下し、個々の学習データの記憶を始めようとする状態を回避することができる。また今回、学習規則に用いたデルタルールは、誤差を減少させるため

に最急降下法を用いている。この方法では、多峰探索域において現在地と目的地の間に「上り坂」がある場合、目的地に到達することができなくなる。

そこで、広域探索手法を採用し、ネットワークが「谷（局所解）」に落ちた時点で、ユニット間の重みのある範囲で変化させ、局所解から抜け出すことを可能にしている。今回の実験では、重みを5回変化させることで、ネットワークが準最適モデルに近づいている（図-2）。

また、この広域探索手法の利用では学習回数が多くなり学習時間も長くなる。階層型ネットワークでは、各層ごとに別の学習係数を適用すると学習時間が減少する。特に、入力層側に出力層側より大きい係数があると収束が早い。これら学習係数も試行錯誤により決定した。




図-2 学習データ、テストデータに対するRMS Errorの推移




図-3 学習中における各ユニットの相関係数値の推移

4. モデルの分析結果

人間がコンクリート表面色の評価を行う場合、マイナス（×）の評価決定は迅速である。つまり、人間の中ではマイナスへの評価基準が明確に形成されていると考えられる。図-3は、出力層の各ユニットの相関係数値を、学習の推移とともに表したものである。これによると、4段階評価の×に対する学習収束速度が著しく速いことが分かる。今回構築したモデルが、人間の評価傾向を抽出していると考えられる。

さらに、感度解析をテストデータ25個用いて行った。表-2は、各出力項目に対して影響度の強い入力項目数を、明度 L^* と色度 a^* 、 b^* 、それぞれについてまとめたものである。その結果、各評価段階において、 L^* の影響度が強いことがはっきりと分かる。これは、今回の評価で人間が明度を主体にしていると考えられ興味深い。

表-2 感度解析結果

	L^*	a^*	b^*
◎	3	2	3
○	4	2	2
△	5	1	3
×	5	2	1
合計項目数	17	7	9

5. おわりに

学習データに特化した評価モデルを避け、広域探索学習を用いて汎化能力の高いモデルを構築した。また、一般にブラックボックスと考えられているニューラルネットワークモデルの分析を行うことで、モデルの正当性をみた。しかし現段階では、隠れ層のユニット数、学習係数、重みの変化量とタイミングなどは、人間が決定している。今後は、これらの自動化など、最適モデル構築の研究をさらに進める予定である。

参考文献

- 1) 近藤嘉広他：色彩計によるコンクリート表面色の評価方法, 第49回土木学会
- 2) Fu, Li & Chen, Tinghui, "Sensitivity analysis for input vector in multilayer feedforward neural networks." 1993 IEEE Int Conf Neural Networks