

論文 AAR 膨張予測に関する基礎的研究

王 鉄成*1・劉興業*2・西林新蔵*3

要旨： 本研究では、オートクレーブ促進試験におけるアルカリ骨材反応コンクリートを対象とした膨張予測への、ニューラルネットワークを用い、無隠れ層および隠れ層有りバックプロパゲーション予測システムを構築し、ニューラルネットワークの適用性を検討した。その結果、AARコンクリートの膨張を容易に、しかも極めて短時間に推定することができた。膨張の実際測定と構築システムによる判定が高い精度で一致し、ニューラルネットワークは有効な方法であることが示された。

キーワード：アルカリ骨材反応、膨張、ニューラルネットワーク、バックプロパゲーション

1. はじめに

近年、世界でコンクリートの早期劣化現象が指摘されている。その劣化現象の一つにはアルカリ骨材反応（記：AAR）による劣化があげられている。AARコンクリート構造物は、膨張で経年的に外観が損なわれる劣化を受け、さらには中性化および鉄筋腐食による劣化を招き、コンクリートの強度、耐久性が低下する。そのためには、AAR膨張が生じるコンクリートの損傷状態と膨張の進行はコンクリート耐久性を把握する上で重要である。AARが発生したコンクリートの膨張程度は、反応性骨材、アルカリ量および環境条件などの多くの要因の組み合わせによって変化する。したがって、膨張予測には、膨張に及ぼす要因の影響を総合的に判断する必要がある。

従来より、AARコンクリートの膨張特性についての各要因の影響及び損傷状態などを検討したが、影響要因が多く、要因の相互作用が複雑で、通常、膨張予測には困難である。最近、人の脳の働きをシミュレートするニューラルネットワーク

の応用が各分野で試みられ、曖昧性のあるデータから相互作用の複雑な表現により結果推定システムを構築することができ、その有用性が示唆されている。ニューラルネットワークによる情報処理は多くの単純な処理要素が相互に結合して信号を交換するようなネットワーク状の機構により情報処理を行い、人の脳における情報処理を模擬して考えられたものである。本研究では、AARコンクリートの膨張を把握することをすするために、ニューラルネットワークを用い、AAR膨張に及ぼす要因の総合的影響を判断することを模擬し、膨張を予測するシステムを構築することを目指すものである。一例としてオートクレーブ促進試験における試験要因とコンクリート中のアルカリ量を入力データとし、実測定した膨張量を学習に用いる学習データとし、膨張を予測する無隠れ層と隠れ層有りシステムの構築を試み、さらに構築したニューラルネットワーク膨張予測システムの有効性を検証する。

*1 天津大学教授 建築工程学院土木工程系 工博（正会員）

*2 天津大学教授 建築工程学院土木工程系

*3 鳥取大学教授 工学部土木工学科 工博（正会員）

2. オートクレーブ促進試験

コンクリートのアルカリ骨材反応の研究においては、試験によって種々の条件下の膨張特性および劣化の進展を直接的に明らかにすることが重要であるが、試験においては結果を得るためには長期間の観察、測定が必要となる。したがって、アルカリ骨材反応による膨張特性を早期に把握し、進展予測、劣化程度および膨張に及ぼす影響を明らかにするためのオートクレーブ促進試験方法が開発されている¹⁾。オートクレーブ促進試験では処理圧力、処理時間およびコンクリート中のアルカリ量などは膨張に大きい影響を及ぼす要因であると考えられる。

本研究では、データを抽出したオートクレーブ試験の実験要因としては、オートクレーブ処理時間は1, 2, 4, 6, 8, 12時間、処理圧力は0.1, 0.2MPaである。コンクリート材料は、アルカリ含有量が0.5%である普通ポルトランドセメントと反応性細骨材 (T2) を用い、添加アルカリ化合物としては試薬1級NaOHを練混ぜ水に溶かして使用した。骨材の物理的性質および化学法 (JCI AAR-1) によるアルカリ骨材反応性試験結果を

Table1に示す。また、添加アルカリ量は1.0, 1.5, 2.0, 2.5, 3.0%の5水準、水セメント比は0.54とした。細骨材は100%反応性骨材とし、Table1に示す反応性骨材を粉砕したものである。粗骨材の最大寸法は20mmで、供試体寸法は75×75×400mmである。これらのコンクリートの配合をTable2に示す。

コンクリートは打設翌日に脱型し、膨張量の初期値を測定した後、オートクレーブ処理を行った。その後、恒温室 (20℃, R.H.80%) で24時間保存して膨張量を測定してから、40℃, R.H.100%の促進養生を行った。長さ変化の測定は各材令ごとに行った。それらの測定した膨張量をニューラルネットワークの学習データとした。

3. ニューラルネットワークに基づいた膨張予測

3.1 ニューラルネットワーク

生物の神経回路網はニューロン (神経細胞) と呼ばれる基本単位が無数に存在している。それらの基本単位がシナプス結合と呼ばれる結合をなしている。この神経回路網を数理的にモデル化し

Table1 Properties of Aggregate

Kinds and symbols of aggregate	F.M.	Density	W.A. (%)	Chemical method (m mol/L)		Sc/Rc
				Rc	Sc	
sandstone (non reactive)	6.64	2.7	0.65	21.5	30	1.39
natural sand (non reactive)	2.79	2.67	1.4	-----	-----	-----
Pyroxene Andesite (reactive)	6.53	2.64	1.59	67.5	301	4.46

Note: W.A.- water absorption

Table 2 Mix proportion of concrete

Slump	Air (%)	W/C	s/a (%)	Unit weight (kg/m ³) (*: absolute volume)			
				W	C	S	G
12-15	2	0.54	43	189	350	*292	*397

たものがニューラルネットワークである。ニューラルネットワークは生物の神経回路網に対応するユニットとユニット間結合によって構成されている。ユニットはFig.1のように複数の入力と一つの出力および各入力に対する重みとユニットのしきい値によって構成される。ニューラルネットワークにおけるユニットはユニットの複数個結合したものであり、あるユニットの出力は他のユニットの入力となる構造を持っている。また、ユニットを数学的にモデル化したものはセルと呼ばれる²⁾。




Fig.1 Visual neuro model and stratum

ニューラルネットワークの最大の特徴は、従来のように難しいプログラミングは必要でなく、学習によって自らのパターン認識能力を高めることができ、パターン認識問題、数式化や定式化が困難な問題の解決、組合わせが膨大な問題の準最適解の究明などを得意とし、情報の体系を少しずつ変えていくことや、入力された情報が不完全であっても、それを補っていく"柔軟かさ"を持つことである。

ニューラルネットワークの学習は入力層に特定の入力を与えたとき、望ましい出力を教師データとして出力層に与え、結合の重みを変化させることである。学習程度は入力値を与えたとき、学習の完成程度を表すネットワークの出力値と教師値との平均誤差によって判断する。平均誤差が小さいほど学習がより効果的に行われていることを表している。出力層に出力されたシステム信号と教師信号と呼ばれる望ましい値との誤差を修正する

ために、重み付けとしきい値の調整を、学習操作には出力層から入力層に向かって行うために、一般に逆誤差伝播法と呼ばれる学習の基本的な数学的処理を採用する。入力出力が1組となった複数の学習データを順番に入力してバックプロパゲーションを行う操作を1回の学習とし、学習を繰り返すことにより、重み付けとしきい値を変化させて教師信号との誤差を減少していく。ニューラルネットワークの学習フローチャートをFig.2に示す。

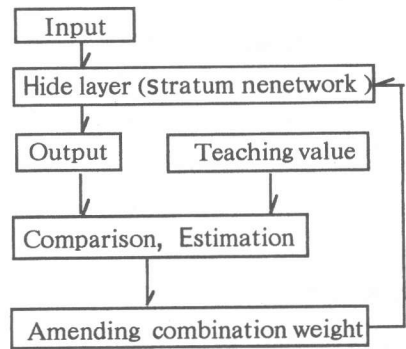


Fig.2 Flow chart of study

3.2 解析処理とした学習データ

ニューラルネットワークの学習はいくつかの学習データを与えることによってそれらの学習データをまねるようにネットワークの重みとしきい値を決めることである。重みはセル間の結合に対する定義されるもので、しきい値は第2層以上のセルに対して定義されるものである。それらの初期値は乱数の発生によって決定する。

本研究では、AARコンクリートのオートクレーブ試験のデータベースの中から膨張に及ぼす量的構成要因（アルカリ量、処理圧力、処理時間）に関するデータを抽出し、ニューラルネットワークシステムの入力データを作成し、オートクレーブ促進試験で得られたAARコンクリートの膨張量を学習教師値とし、応答関数による学習で膨張予測データを出力された。

本研究における使用した学習データは45件のデータで、検証用データは別に12件のデータを用いて、学習が終了したニューラルネットワーク膨張予測システムにより判定させた。

3.3 ニューラルネットワークによる膨張予測システム

ユニット間の結合には種々の型があるが、通常は入力層、中間層、出力層に分類される階層型ネットワークをよく用いる。入力層と出力層以外の層は中間層（隠れ層）と呼ばれ、入力層から入力された情報を変形させながら伝達し、出力層に情報をわたす役目をするものである。

今回用いた膨張予測階層型ニューラルネットワークは、セルを入力層、出力層及び中間層に分けて配置し、隠れ層（中間層）有りとなし隠れ層の二つの階層型で、結合したものである。

検討に用いた階層型ニューラルネットは、多入力、1出力の形式で、セルを多数結合させたものである。セルには、入力層と出力層があり、隠れ層有りの場合には、その間には幾つかのセルが設けられておる中間層がある。各層のセルはシナプス結合で結ばれており、セルの刺激信号を入力層から出力層へ向かって一方通行に順次伝えるようになっている。刺激信号の強さはセルやシナプスを伝わる間に、重み付けやしきい値により変化する。結合の重み値としきい値は学習によって変化させる。

各セルから出力値は入力値に与えられる重みとしきい値により設定されるが、その応答特性を表すモデルとしては [0, 1] で連続的に変化するシグモイド (Sigmoid) 応答関数を用いている。

$$f(\text{net}_j) = \frac{1}{1 + e^{-\text{net}_j}} \quad (1)$$

ただし、

$$\text{net}_j = \sum_{i=1}^n W_{ji} O_i - \theta_j \quad (2)$$

ここに、 $f(\text{net}_j)$ は出力された作用関数（刺激の強さ）、 W_{ji} はシナプス結合値（重み付け係数）、 O_i は入力された作用関数（刺激の値）、 θ_j はしきい値である。

学習のアルゴリズムには、バックプロパゲーション (backpropagation - 逆誤差伝播法) 手法で、出力値とあらかじめ与えられている教師値との二乗誤差を評価関数（誤差関数）とし、誤差関数を極小にするように、入力層にあるデータを入力し、出力層に出力されたシステムの信号と教師値との誤差を修正するために、学習は平均的に最適なところに収束するとき、重み付けやしきい値の調整を、出力層から入力層へ逆に伝播させていく。このとき、誤差関数として

$$E = \frac{1}{2} \sum_{k=1}^n (y_k - \bar{y})^2 \quad (3)$$

が考えられる。

ここに、 y_k はネットワークの実際の出力、 \bar{y} は教師値である。

学習定数、隠れ層のセル数と階層数は現在、扱っているバックプロパゲーションによる学習方法を用いたシステムでは、合理的な規模を決定する一般的な手法が明らかになっていないことである。本研究では、膨張を予測するバックプロパゲーションシステムの構築にあたり、今回用いたデータは膨張予測結果を客観的に表現している数値化の可能なもので、膨張に影響を及ぼす要因であるアルカリ量、オートクレーブ促進試験における処理圧力と処理時間をデータベースの項目より選定した。用いた隠れ層有りの階層型ニューラルネットは、入力層はアルカリ量、処理圧力と処理時間の3セル (x, y, z) で、出力層は膨張値の1セルで、隠れ層のセル数は、まず、ある範囲で種々組み合わせ学習の収束状況を確認し、適切な確信度により隠れ層のセル数を決定した。入力出力項目とその内容をTable3に示す。

Table 3 Input and output items

Input item	Data content	Output item
Alkali content	1.0 ~ 3.0 (%)	Expansion
Treating pressure	0.1, 0.2 Mpa	
Treating time (hours)	1, 2, 4, 6, 8	

一方、隠れ層のセル数と階層数の決定を避けるために、重みとしきい値によりシグモイド応答関数を用い、入力層のセル数を3個 (x, y, z) から25個 (x, sin(π x), cos(π x), sin(2 π x), cos(2 π x), y, sin(π y), cos(π y), sin(2 π y), cos(2 π y), z, sin(π z), cos(π z), sin(2 π z), cos(2 π z), xy, x sin(π y), x cos(π y), yz, y sin(π z), y cos(π z), xz, z sin(π x), z cos(π x), xyz) に増強させ、出力層は1セルとするような無隠れ層システムを構築してみた。重みとしきい値の初期値は、-1.0 と1.0の間の乱数で与えた。また、学習の進行とともに学習データの推定誤差は減少していくが、学習に使用していないデータの推定誤差は学習データの推定誤差が極小になる前に増加に転じれば、過剰学習で、ニューラルネットワークに汎用化を持たせるためには避けなければならない³⁾。

3.4 学習結果と検証

本研究における膨張予測システムにより、無隠れ層バックプロパゲーションシステムの場合は、収束の早さに関する学習定数 η を0.2 設け、収束時の振動を抑える効果がある安定化定数 α を0.9 設け、シグモイド応答関数で入力層のセル数を25セルとし、出力層を1セルとした。一方、隠れ層有りバックプロパゲーションシステムの場合は、学習定数 η を0.9 設け、安定化定数 α を0.7 設け、学習回数2万回で、入力層のセル数を3セル、出力層を1セルとし、学習の収束状況と適切な確信度により隠れ層のセル数を8個に決定した。二つのバックプロパゲーションシステムによる検証結果をTable 4 と Table 5 に示す。結果より、膨張予測の平均誤差には隠れ層有りの場合は材令3か月11.07%、6か月5.77%で、無隠れ層の場合は3か月7.57%、6か月8.40%である。予測対象とする膨張値はパーセントで表したもので、その誤差により本研究での無隠れ層バックプロパゲーションシステムでも隠れ層有りバックプロパゲーションシステムでも、膨張の実際測定と構築したシステムによる判定が高い精度で一致した。また、無隠れ層バックプロパゲーションシステムでも学習処理と収束が速く、高い計算精度を得られた。

Table 4 Estimated expansion by including internal layer

No.	Alkali Content (%)	Treating Pressure (MPa)	Treating Time (hour)	Age after Autoclave (months)	Expansion (%)		Relative Error (%)
					Practical Measure Value	Calculation Value	
1	1.0	0.2	4	6	0.1581	0.1426	9.77
2	1.0	0.2	8	3	0.0848	0.0959	13.08
3	1.5	0.2	2	6	0.3261	0.3273	0.37
4	1.5	0.2	4	3	0.2680	0.3191	19.05
5	1.5	0.2	6	6	0.2812	0.2531	9.97
6	2.0	0.2	4	3	0.4112	0.4767	15.92
7	2.0	0.2	4	6	0.4107	0.4228	2.94
8	2.5	0.2	2	3	0.3630	0.3488	3.92
9	2.5	0.2	4	6	0.4755	0.4898	3.00
10	3.0	0.2	2	3	0.5832	0.5608	3.38
11	3.0	0.2	8	6	0.5650	0.6310	11.68
12	3.0	0.1	4	6	0.6481	0.6308	2.66

Table 5 Estimated expansion by no internal layer

No.	Alkali Content (%)	Treating Pressure (MPa)	Treating Time (hour)	Age after Autoclave (months)	Expansion (%)		Relative Error (%)
					Practical Measure Value	Calculation Value	
1	1.0	0.2	4	6	0.1581	0.1400	14.01
2	1.5	0.2	2	6	0.3261	0.2904	10.59
3	1.5	0.2	4	3	0.2680	0.2545	5.04
4	1.5	0.2	6	6	0.2812	0.2703	3.88
5	2.0	0.2	4	3	0.4112	0.4027	2.07
6	2.0	0.2	4	6	0.4107	0.4426	7.77
7	2.5	0.2	1	3	0.3490	0.3891	11.49
8	2.5	0.2	2	3	0.3630	0.4177	15.07
9	2.5	0.2	4	6	0.4755	0.5078	6.79
10	3.0	0.2	2	3	0.5832	0.5587	4.20
11	3.0	0.2	8	6	0.5650	0.5993	6.07
12	3.0	0.1	2	6	0.6672	0.6025	9.70

また、オートクレーブ実験で得られたデータより、今回処理圧力0.1MPaの検証用データは少なく、今後データを追加し、構築したバックプロパゲーションシステムにより検証を行うものとする。

4. まとめ

本研究は、膨張進展を把握するために、ニューラルネットワークによって膨張予測のシステムを構築して試みた。それらの結果、以下のような知見を得ることができた。

膨張に及ぼすアルカリ量およびオートクレーブ促進試験の要因を入力層のセルとし、ニューラルネットワークを用いて予測システムの構築を試み、膨張を容易に、しかも極めて短時間に推定することができた。その構築した膨張予測バックプロパゲーションシステムより、膨張の実際測定と構築した隠れ層有りおよび無隠れ層システムによる判定が高い精度で一致し、ニューラルネットワークはAAR膨張予測には有効な方法であるこ

とが示された。しかし、ニューラルネットワークの予測精度は入力データ数（膨張に及ぼす要因など）及び学習データの精度に左右され、今後、入力項目としてアルカリ骨材反応に及ぼす要因の追加や学習方法改善を考慮し、精度のよいデータより、さらに膨張予測精度を向上させる必要がある。

参考文献

- 1) T.Wang, S. Nishibayashi, K.Nakano and Q.Bian: Study of Autoclave Test Method for Determining Alkali Silica Reaction of Concrete, Int. Conf. On Concrete Under Severe Condition-Environment and Loading, Hokkaido, Japan, Vol.2, No.115, pp.1175-1182, 1995
- 2) 平野広美：Cでつくるニューラルネットワーク、パーソナルメディア株式会社、1991.3
- 3) Zhou Jicheng: Neural Network, Science Diffusion Publishing House, 1993