

# ディープラーニングによる多成分系コンクリートの中性化深さ予測

田坂 誠一\*

## Prediction of Carbonation Depth of Multi-Component Concrete Using Deep Learning

Seiichi TASAKA

### ABSTRACT

Prediction of the carbonation depth of multi-component concrete admixing fly ash and blast furnace slag is studied. A set of 62 data given by the accelerated carbonation test, each containing variables of mix proportion, measured carbonation depth and curing period, is applied to the regression analysis implemented by deep learning (DL) procedures. The classical principal component analysis and deep auto-encoder are used to figure out some important features of the multi-component concrete. The DL regression analysis is applied also to the prediction of reaching time, i.e. the time at which the carbonation front reaches a specific value of carbonation depth is investigated.

**KEY WORDS:** fly ash, blast furnace slag, concrete, carbonation, reaching time, deep learning

### 1. はじめに

コンクリートに使用されるセメントは製造過程において大量のCO<sub>2</sub>を排出するため、産業副産物であるフライアッシュ (FA) や高炉スラグ微粉末 (BFS) を主にセメントの置換材として活用した、いわゆる多成分系コンクリートの開発が進められている。これらの混和材料は環境負荷を抑制する効果があるとともに、流動性、発熱低減性、アルカリシリカ反応抑制性等、コンクリートの種々の性能向上にも有効であることが知られている<sup>1,2)</sup>。このようなことから、混和材料の置換率を高めるなどして、より効果の高いコンクリートの開発や性能評価が行われており、特にコンクリートの耐久性に関わる中性化の評価については多くの研究がある<sup>3~10)</sup>。

一方、多成分系コンクリートでは調査パラメータの

数が増大することから、複数の混和材料による中性化進行への影響は複雑となり、設定した調査がコンクリートの中性化進行にどのように影響するかを推定することは容易ではない。また、多成分系コンクリートの中性化深さに関するデータの蓄積は必ずしも十分ではないため、古典的な統計解析に基づくデータの特徴分析や目的事象の将来予測を精度よく行うことは難しい。

本論では、多成分系コンクリートの中性化深さ進行を高精度かつ効率的に行う目的のため、複数の隠れ層を有するニューラルネットワーク手法であるディープラーニング (DL) による推定について考察を加える。既往の文献<sup>4,7,8)</sup>から収集した促進中性化試験データを使用して、DLによる回帰分析を行う。DLを使用すれば、線形重回帰分析に限定されない、入出力の非線形関係に基づく推定が可能である。回帰分析では、目的変数として任意の促進中性化時間 (以後、経過時間という。) における中性化深さ並びに指定された中性化深さに到

\*建築学科

達するまでの経過時間 (以後、到達時間という。) <sup>11)</sup> を取り上げ、教師あり学習で学習した DL モデルの推定精度を検討する。

DL にはいくつかのライブラリーが公開されているが、ここでは H2O. ai <sup>12, 13)</sup> の R ライブラリー <sup>14, 15)</sup> を使用する。

## 2. データの諸特性

### 2・1 概要

表 1 に本論で使用するデータの概要を示す。データはいずれも JIS A 1153 の促進中性化試験に基づくものである。

表 1 データの概要

データ数	62
目的変数	X, year
説明変数	W, C, BFS, FA, S, G, s/a, W/C, W/B, (X, year)

目的変数には X と year が含まれているが、X (year) を目的変数とする回帰分析では year (X) は説明変数として扱われる。表 1 の記号の意味は以下の通りである。

X : 中性化深さ (mm)

year : 経過時間 (年)

W : 単位水量 (kg/m<sup>3</sup>)

C : 単位セメント量 (kg/m<sup>3</sup>)

BFS : 単位高炉スラグ微粉末量 (kg/m<sup>3</sup>)

FA : 単位フライアッシュ量 (kg/m<sup>3</sup>)

S : 単位細骨材量 (kg/m<sup>3</sup>)

G : 単位粗骨材量 (kg/m<sup>3</sup>)

s/a : 細骨材率 (%)

W/C : 水セメント比 (%)

W/B : 水結合材比 (%)

いずれのデータもフライアッシュは第 2 種を使用している。高炉スラグ微粉末は 4000 と 6000 の 2 種類であり、4000 の使用率はデータ全体の約 70% である。

各変数の相関係数を表 2 に示す。中性化深さ (X) は C と負の相関、W/C と正の相関があり、一般的なコンクリートと同様の傾向を呈している。X と混和材料との相関については、BFS より FA の方が若干強い。X と最も強い相関があるのは year である。なお、本論で使用するデータ変数の値の範囲は表 3 の通りである。

表 3 データ変数の値の範囲

	単位	最小値	最大値
W	kg/m <sup>3</sup>	121	185
C	kg/m <sup>3</sup>	64	288
BFS	kg/m <sup>3</sup>	16	305
FA	kg/m <sup>3</sup>	17	123
S	kg/m <sup>3</sup>	726	970
G	kg/m <sup>3</sup>	907	1067
s/a	%	43.9	48.8
W/C	%	50	234.4
W/B	%	30	60.7
X	mm	1.02	29.4
year	年	0.011	0.249

図 1 は、使用したデータの中性化深さ (縦軸、記号は y) と経過時間 (横軸、記号は x) との関係性をべき関数式を用いて最小二乗近似で求めたもので、次式のように表される。

$$y = 21.08x^{0.336} \quad (1)$$

表 2 変数の相関係数

	W	C	BFS	FA	S	G	s.a	W/C	W/B	X	year
W	1.000										
C	0.220	1.000									
BFS	-0.132	-0.849	1.000					sym			
FA	0.154	-0.149	0.061	1.000							
S	-0.631	-0.529	0.442	-0.086	1.000						
G	-0.954	-0.057	-0.047	-0.200	0.500	1.000					
s.a	0.149	-0.575	0.576	0.066	0.627	-0.351	1.000				
W/C	0.043	-0.910	0.831	0.140	0.417	-0.179	0.663	1.000			
W/B	0.731	0.304	-0.534	-0.080	-0.528	-0.636	-0.033	-0.169	1.000		
X	0.163	-0.404	0.109	0.225	0.233	-0.155	0.354	0.421	0.328	1.000	
year	-0.338	-0.007	-0.006	-0.016	0.336	0.349	0.021	-0.074	-0.257	0.457	1.000




図1 中性化深さと経過時間の関係

$\sqrt{t}$  則との比較のため、経過時間が0.15年の時点で中性化速度係数を求めると、28.8mm/ $\sqrt{\text{年}}$  (4.0mm/ $\sqrt{\text{週}}$ ) 程度となる。


### 2・2 特徴分析

ここでは、使用するデータの特徴を主成分分析 (PCA) とオートエンコーダ (AE) により分析する。PCA ではRの関数 prcomp を使用し、主成分数を2として分析を行う。AE では隠れ層を [100, 10, 2, 10, 100] の5層とし、第3層の二つのノードにおいて分類状況を調べる。データはXの降順に並び替え、データ番号 (1~62) を付したものを使用する。


図2に主成分分析の結果を示す。図中の番号はデータ番号である。また、変数 W.C、W.B、s.a はそれぞれ W/C、W/B、s/a の代用である。図2(a)はデータのスケールリングを行わない場合であり、変数の矢印の長さが分散の大きさを表している。第1 (PC1) 及び第2主成分 (PC2) の寄与率はそれぞれ64%と23% (PC2までの累積寄与率は87%) である。分散の小さい変数は識別が困難であるが、BFSはW/Cとほぼ同方向にあり、Cとは反対方向にある。すなわち、BFSとW/Cは中性化の進行を促進する作用があるものと考えられる。PC1 (横軸) は主に結合材の調合特性を、PC2 (縦軸) は主に骨材や水量の調合特性を表現していると考えられる。

図2(b)はデータのスケールリングを行った場合の結果である。BFS、W/C及びs/aなどが、Xの値が大きいデータに関連付けられていることがわかる。FAはXとの相関はある程度見られるものの、BFSに比較して明確な特徴付けは困難である。

図3はAEによる結果の一例を示したものである。AE



(a) スケールリングなし



(b) スケールリングあり

図2 主成分分析

は初期値をランダムに決定するため分析ごとに結果は若干異なる。学習は全データを用いて行った。図2と同様にデータ番号を付しているが、PCAと比較すると分類の分解能は高い。Xの値は調合だけでなく経過時間にも依存する。図中の左下の集団 (42, 46, 51, 57) は経過時間が最も短いデータであり、Xの値は比較的小さい。一方、図中の右端に位置する1, 4, 16, 10, 19などは経過時間が最も長いデータであり、Xの値は比較的大きい。Cに関する分類状況では、図中の上部 (58, 62, 60, 44, 39, 40など) がCの値が大きいデータであり、Xの値は比較的小さい。BFSに関する分類状況を見ると、BFSの値が大きいデータは図中の下半




図3 オートエンコーダ分析

表5 変数重要度

	変数名	変数重要度
1	year	1.000
2	s/a	0.718
3	W/C	0.688
4	FA	0.671
5	G	0.652
6	C	0.631
7	BFS	0.625
8	W	0.618
9	W/B	0.607
10	S	0.578

表4 順位相関係数

	X	year	C	BFS	FA	W/C
X	1.000					
year	0.589	1.000			sym	
C	-0.468	-0.071	1.000			
BFS	-0.042	0.004	-0.680	1.000		
FA	0.189	0.059	-0.186	-0.149	1.000	
W/C	0.451	-0.118	-0.847	0.617	0.149	1.000

(成分2の負側)に集まっている(56、37、24、16、57、42、50、・・・、4、5、2、1など)が、Xとの関係に有意な傾向は見られない。

参考のため、表4にいくつかの変数を対象としたスピアマンの順位相関係数を示す。Xとyearに関する無相関検定のp値は $8.4 \times 10^{-07}$ であった。また、XとBFS及びXとFAについては5%水準で有意ではなかった。

AEによりXに影響を及ぼす変数の相対的な重要度(変数重要度)を求めた結果を表5に示す。経過時間の影響が最も大きいことがわかる。それ以外の変数の重要度には大差がないが、FAとBFSではFAの重要度が若干大きい。

### 3. 回帰分析

回帰分析では、全データからランダムに抽出した42個のデータを学習データとしてモデルの学習を行い、残り20個を試験データとしてモデルの推定精度を調べる。活性化関数はTanhを使用し、隠れ層は[100, 100, 100]の3層とする。交差検証は適用していない。比較のため、h2o.glm関数(線形モデル)による回帰分析の

結果も併せて示す。


#### 3・1 中性化深さ

図4は学習データを用いてモデルの学習精度を確認したものである。図4(a)はDL、(b)は線形モデルによる結果である。Corは相関係数を、RMSEは平均平方二乗誤差を意味する。図の縦軸は推定データ、横軸は実データを表す。図中の実線は回帰直線、点線は推定データ=実データの基準線である。図に見られるように、DLでは実データと推定データが良く一致しており、相関係数や誤差においてもより推定精度が高いことがわかる。


図5は学習に使用していない試験データを用いてモデルの推定精度を確認したものである。CorやRMSEの値は大差がないが、DLにおける推定データは試験データのばらつきと概ね同程度であり、回帰直線が基準線により近い推定となっていることがわかる。

#### 3・2 到達時間


式(1)に示した中性化深さ(y)と経過時間(x)の関



(a) DL (Cor=0.999, RMSE=0.205)




(a) DL (Cor=0.864, RMSE=2.63)



(b) 線形モデル (Cor=0.905, RMSE=2.84)

図4 モデルの学習精度 (中性化深さ)



(b) 線形モデル (Cor=0.876, RMSE=2.74)

図5 モデルの推定精度 (中性化深さ)

数式を  $x$  について解くと次式が得られる。


$$x = 0.000115y^{2.976} \quad (2)$$

これは中性化深さの値が与えられたとき、その深さに達する時間 (到達時間) の推定式と考えられるが、データのばらつきが大きいこともあり実際の推定に適用するのは難しい。このため、ここでは前節で用いた学習データ・試験データと学習モデルを適用して、DLによる到達時間の回帰分析を行う。


図6は、学習データを用いて到達時間に関するモデルの学習精度を確認したものである。図に見られるように、学習データに対するDLの推定精度は線形モデルと比較して非常に高い。図7は試験データによる推定

結果を示したものである。CorやRMSEの値は線形モデルと大差がないが、DLの回帰直線は基準線に近く、推定データは実データのばらつきを良好に反映していると考えられる。


表6は、上記の学習モデルを使用し、試験データから4個のデータを抽出して式(2)、DL及び線形モデルによる到達時間 (year) の推定を行い、推定誤差を比較したものである。式(2)は個々のデータの推定に用いるには誤差が大きいという難点がある。一方、本例ではDLの推定誤差は線形モデルに比較していずれのデータについてもより小さいが、BFSの混入量が多いデータでは、データ数が少ないこともあり、十分な精度は得られていない。データの整備が今後の課題である。




(a) DL (Cor=0.998, RMSE=0.00525)



(a) DL (Cor=0.920, RMSE=0.0309)



(b) 線形モデル (Cor=0.832, RMSE=0.0454)



(b) 線形モデル (Cor=0.822, RMSE=0.0386)

図6 モデルの学習精度 (到達時間)

図7 モデルの推定精度 (到達時間)

表6 到達時間の推定誤差

W	C	BFS	FA	S	G	s/a	W/C	W/B	X	year	推定誤差		
kg/m <sup>3</sup>	kg/m <sup>3</sup>	kg/m <sup>3</sup>	kg/m <sup>3</sup>	kg/m <sup>3</sup>	kg/m <sup>3</sup>	%	%	%	mm	年	数式(2)	DL	線形モデル
170	252	29	22	860	907	49	67	56	6.2	0.0575	54.4%	2.4%	25.8%
124	186	62	62	871	1060	45	67	40	11.01	0.2493	41.9%	0.5%	35.0%
121	152	91	61	877	1067	45	80	40	13.81	0.2493	14.1%	0.7%	27.0%
141	77	247	57	950	998	49	183	37	9.44	0.0767	19.5%	19.2%	22.8%

#### 4. まとめ

本論では、多成分系コンクリートの中性化進行の推定を行うため既往の文献から収集した促進中性化深さのデータを使用し、DL及び線形モデルによる回帰分析について比較検討を行った。使用したデータは、PCAやAE等を適用して特徴分析を行い、FAやBFSを含む多成

分系コンクリートの統計的諸特性について考察した。主たる結論は以下の通りである。

- (1) 中性化深さと最も相関の強い変数は経過時間であり、経過時間は変数重要度の順位も第1位であった。次に相関が強いのはW/Cであった。BFSと

FA を比較すると FA との相関が若干強く、変数重要度でも同様の傾向が見られた。

- (2) AE は PCA に比較してデータの特徴分析をより高い分解能で行うことが可能である。
- (3) 中性化深さと到達時間に関する回帰分析では、DL モデルの学習精度は非常に良好であった。試験データによる DL の推定精度は線形モデルを若干上回った。
- (4) 試験データに含まれるいくつかのデータに対して行った到達時間の推定では、DL の推定誤差が最も小さかった。線形モデルでは調合が異なるデータに対してはほぼ同程度の推定誤差が生じたが、DL はデータ数の少ない調合データについては誤差が増大する傾向があった。

## 謝辞

本論では、既往の文献のデータに加え、当研究室の卒業研究（平成 26 年度：前菌翔太、平成 27 年度：永井陽呂、平成 28 年度：勝田壮良、平成 29 年度：大月康平（敬称略））において収集した実験データを使用した。フライアッシュは第 2 種、高炉スラグ微粉末は平成 26 年度には 4000、それ以降は 6000 を使用した。混和材料の一部は寄贈されたものである。ここに記して関係各位に謝意を表す。

## 参考文献

- 1) 日本建築学会：フライアッシュを使用するコンクリートの調合設計・施工指針・同解説、日本建築学会、10 月、2007.
- 2) 日本建築学会：高炉スラグ微粉末を使用するコンクリートの調合設計・施工指針・同解説、日本建築学会、7 月、2001.
- 3) 島添洋治、白川敏夫、麻生實：フライアッシュおよび高炉スラグ微粉末を用いたコンクリートの中性化に関する研究、日本建築学会大会学術講演梗概集、9 月、1999、943-944.
- 4) 松家武樹ほか：フライアッシュおよび高炉スラグ微

粉末を用いたローカーボンコンクリートに関する基礎的研究、セメント・コンクリート論文集、No.64、2010、295-302.

- 5) 樋原弘貴ほか：高炉セメントとフライアッシュを使用したコンクリートの乾燥収縮および諸特性に関する研究、セメント・コンクリート論文集、No.65、2011、340-345.
- 6) 福留和人ほか：フライアッシュおよび高炉スラグ微粉末を用いたローカーボンコンクリートの強度特性と細孔構造に関する研究、ハザマ研究年報、12 月、2012、1-7.
- 7) 溝渕麻子ほか：混和材を高含有したコンクリートの性能改善に関する実験的研究、コンクリート工学年次論文集、Vol.35、No.1、2013、157-162.
- 8) 小林利充ほか：混和材を高含有したコンクリートの中性化に関する一考察、コンクリート工学年次論文集、Vol.36、No.1、2014、112-117.
- 9) 内藤哉良ほか：各種混和材を混入したコンクリートの中性化に関する検討、土木学会第 58 回年次学術講演会、9 月、2003、25-26.
- 10) 吉澤千秋、峯 秀和、石川嘉崇：高炉スラグ細骨材とフライアッシュを組み合わせたコンクリートの特性と実用化、コンクリート工学、Vol.55、No.6、6 月、2017、510-516.
- 11) 石田崇人、田坂誠一：フライアッシュコンクリートの中性化深さのベイズ推定—信頼度評価と到達時間の不確定性、日本建築学会大会学術講演梗概集（材料施工）、9 月、2015、709-710.
- 12) D. Cook : Practical Machine Learning with H2O, O'Reilly Media, Inc., 2017.
- 13) H2O.ai : <https://www.h2o.ai/>
- 14) The R Project for Statistical Computing : <https://www.r-project.org/>
- 15) Package 'h2o' (R Interface for H2O) : <https://cran.r-project.org/web/packages/h2o/h2o.pdf>