AI によるコンクリートのひずみ分布を用いた劣化要因の予測

太平洋セメント(株) 正会員 〇小池 耕太郎, 落合 昴雄, 早野 博幸

1. はじめに

現状, RC 構造物の劣化診断を行う場合,最も簡易的な手法は外観からの目視点検である. コンクリート表面の ひび割れやゲル,錆汁の滲出といった劣化状況を人間が視認し,劣化診断を行う.しかし,判定精度は技術者の知 識や経験に依存し,外観上の変化が確認できない潜伏期での診断が困難である.一方で,劣化現象に伴うひずみや ひび割れには劣化現象特有のパターンが見られ,そのパターンを学習させた AI による画像認識モデルを用いるこ とで,劣化要因の診断を行うことが期待できる.本研究では,RC 構造物の劣化診断に AI 技術を適用し,コンクリ ート表面のひずみ分布から各劣化要因の判定が可能な技術の構築を目的とし,実験的な検討を行った.

2. 実験概要

2.1 試験体および実験概要

使用材料を表-1,配合を表-2に示す.本実験では, 劣化要因の対象を暫定的にASR,DEF,乾燥収縮(以下,DRY), ASR-DRY(複合劣化)の4種類とした.

試験体概要を図-1に示す. 試験体の寸法 は 400×400×50mmの平板とし,使用鉄筋は

D10, D13 および D16 を 1 軸方向 のみ,または 2 軸方向に配筋し た.材齢 3 日で脱型し,材齢 7 400 375 日まで湿布養生をした後,ASR は 40℃_R.H.95%以上で促進養生, DRY および ASR-DRY (促進養生 を行い約 1000µ 膨張後)は 20℃_R.H.60%, DEF は成形後に 前置き 2 時間, 20℃/h で最大 90℃



表一1 使用材料						
材料	産地/銘柄	記号	概要			
セメント	普通ポルトランドセメント	С	密度:3.16 g/cm ³			
細骨材	山砂	S	表乾密度:2.56 g/cm ³			
粗骨材A	反応性骨材	GR	表乾密度:2.65g/cm ³			
粗骨材B	硬質砂岩	G1	表乾密度:2.64g/cm ³			
試薬	水酸化ナトリウム	NaOH	NaOeqで8.6kg/m ³ になるよう添加			
	硫酸カリウム	K_2SO_4	セメントのSO3に対し2.0%追加			

表-2 コンクリートの配合





図-2 ひずみデータの変換工程

となるように蒸気養生を行った後,水温 20℃で水中養生を行った.また,各材齢における計測は既報¹⁾と同様に試 験体計測面の画像を取得し,デジタル画像相関法(以下,DICM)によりひずみ分布を求め,材齢 9 週までの各水 準で隔週にデジタル画像の取得,ひずみ分布の算出を行い学習データに用いた.

2.2 画像認識モデルの構築および検証

ひずみデータの変換工程を図-2 に示す. DICM により求められたひずみ分布は,187×342 の行列データとして出 カし,以下の3 段階によって数値データを処理した.①: ひずみ数値データを小さい順に並び替え,「最小値から 75%に位置する値」から「四分位範囲の1.5倍」を足した値以上を上限値,「最小値から25%に位置する値」から「四 分位範囲の1.5倍」を引いた値以上を下限値とする.ここでは,ひずみの最小値や最大値付近を除く,特徴のある ひずみ分布の範囲をより抽出しやすいようにする.②:前述した上下限値を除去したひずみ数値データを画像化す るため,256段階(0~255)の輝度を表す画像となるよう数値を正規化する.③:②から64×64pixelの画像を縦7pixel, 横 5pixel ずつ移動させ,異なる画像を1000枚抽出した.

検証は層化 k 分割交差検証により、ひずみを変換した数値データを検証用データと学習用データに分割し、両者 を入れ替えながら予測精度の評価および検証を繰り返し行った.なお、画像認識モデル構築の際に使用した開発言

キーワード AI, 画像認識, デジタル画像相関法, 面的ひずみ分布, 診断 連絡先 〒285-8655 千葉県佐倉市大作 2-4-2 太平洋セメント(株) 中央研究所 TEL043-498-3902 語は Python, 学習ライブラリとしては TensorFlow を用いた.

3.実験結果および考察

3.1 DICMによるひずみ分布の比較

DICM により算出した最大主ひずみ分布の一例を図-3 に 示す. ASR-DRY のみ無筋の試験体,それ以外は D10 を 1 軸 に配筋した試験体における各水準の材齢 3 週目および 7 週目 の最大主ひずみ分布を示す. なお,コンタクトゲージ法で計 測した各材齢における膨張ひずみを記した. ASR では材齢初 期に点状のひずみ分布が発生し,材齢が進むにつれて亀甲状 に 1200×10⁻⁶ 以上のひずみ集中領域が全体的に発生している ことがわかる. DEF はモルタル部のひずみ集中領域が膨張し ていることが確認できる. DRY は, DEF と同様の領域に対し て収縮が発生していることがわかる. ASR-DRY は,亀甲状の ひずみ分布が発生していない領域に対して収縮が発生してい ることが確認された.

3.2 画像認識モデルによる劣化診断

画像認識モデルによる予測結果の一部を表-4 および表-5 に示す.なお、同一試験体から取得したデータは、特徴の 傾向が似ているため、「学習に使用した場合はすべて学習」に

「検証で使用した場合はすべて検証」に使用した.例えばASR 試験体の3,5,7,9週目データは、学習・検証用に分けるこ となくすべて学習用とした.今回は3.1で示した水準のみを 抜粋している.正解率は、1試験体の画像データ(1000枚) につき、分類予測の最頻劣化要因を算出し、最終的な予測結 果とした(1000枚中,900枚が「ASR」と予測すると、こ の検証データの最終的な予測結果は「ASR」となる).

画像認識モデルの平均正解率は 99.4%となり,全体的に 高い正解値を得た.正解率は,材齢が進むにつれて高くな っていく傾向となった.これは,若材齢時では各水準とも 劣化が進んでおらず,劣化要因の特徴量の抽出が難しいこ とが考えられる.また,複合劣化の ASR-DRY では,材齢1 週の段階でいずれの配筋状態においても ASR の単独劣化と 判定している割合が 8~30%となっているが,材齢の進行に 伴って乾燥収縮の影響が増大していくと ASR-DRY の複合 劣化と判定する傾向となった.



図-3 最大主ひずみ分布の比較

表-4 画像認識モデルによる予測結果の一例

少山	学習	検証	促進	正解率(予測結果)				
安田	データ	データ	期間	ASR	DEF	DRY	ASR-DRY	
~I	数	数	(週)	(%)	(%)	(%)	(%)	
ASR	16000	12000	3	91.1	1.5	4.7	2.7	
			5	90.9	9.1	0.0	0.0	
			7	98.4	0.0	0.0	1.6	
			9	96.9	0.0	0.0	3.1	
DEF	19000	14000	1	2.4	97.6	0.0	0.0	
			3	3.4	96.6	0.0	0.0	
			5	0.0	100.0	0.0	0.0	
			7	0.0	100.0	0.0	0.0	
DRY	16000	12000	1	1.4	0.0	94.5	4.2	
			2	0.0	0.0	97.8	2.2	
			4	0.0	0.0	91.2	8.8	
			6	0.7	0.1	86.6	12.6	

表-5 画像認識モデルによる

複合劣化の予測結果

劣化 要因	学習	検証 データ 数	水準	促進	正解率(予測結果)			
	データ 数			期間	ASR	DEF	DRY	ASR-DRY
				(週)	(%)	(%)	(%)	(%)
ASR-DRY	10000	6000	1軸 D13	1	8.0	0.0	0.0	92.0
				5	0.0	0.0	0.0	100.0
			2軸 D13	1	29.9	0.0	0.0	70.1
				3	9.2	0.0	0.0	90.8
				5	6.4	0.0	0.1	93.5
				7	0.6	0.0	1.4	98.0
			無筋	1	16.8	0.0	0.0	83.2
				3	0.0	0.0	0.1	99.9
				5	0.0	0.0	0.1	99.9
				7	0.0	0.0	0.2	99.8

4. まとめ

デジタル画像相関法により得られたコンクリート表面のひずみ分布から, AI の画像認識技術を用いることで劣化 要因の診断が可能であることが示された. 今後は,劣化要因をさらに増やすとともに,現場診断への適用に向けて 検討を行っていく.

参考文献