

ディープラーニングによるコンクリート構造物の劣化要因判定支援システムの開発に関する基礎的研究

Experimental study on development of the system which supports that an engineer judges a factor of the deterioration for the concrete structure by Deep learning

町口敦志[†]・喜多敏春*・多田徳夫**・武井宏将***・近田康夫****
 Atsushi Machiguchi, Toshiharu Kita, Norio Tada, Hiromasa Takei, Yasuo Chikata

[†]修（工）金沢大学大学院自然科学研究科環境デザイン学専攻博士後期課程
 （株式会社 日本海コンサルタント，〒921-8042 石川県金沢市泉本町 2-126）

*博（工），株式会社 日本海コンサルタント（〒921-8042 石川県金沢市泉本町 2-126）

**株式会社 日本海コンサルタント（〒921-8042 石川県金沢市泉本町 2-126）

***修（工），修（理），日本ユニシス株式会社（〒135-8560 東京都江東区豊洲 1-1-1）

****工博，金沢大学教授，理工研究域環境デザイン学系（〒920-1192 石川県金沢市角間町）

In recent years, the problem of aging of infrastructure and countermeasures against lack of resources and technical shortage due to the declining birthrate and aging population are becoming a social issue. In maintaining and managing structures, it takes a great deal of labor and cost because there are huge numbers of stocks and high quality technicians are required to judge the deterioration factor at the time of inspection. This is a base study that aims to develop a system which mechanically judges the deterioration factor from photographs of deteriorated concrete structure with Deep learning which has produced many results in the field of image recognition and image authentication in recent years.

Key Words: deep learning, AI (artificial intelligence), concrete structure, deterioration factor Judgment

キーワード：ディープラーニング, AI, コンクリート構造物, 劣化要因判定

1. はじめに

今日、インフラの老朽化問題や少子高齢化による財源不足・技術者不足への対策が社会的な課題とされており、維持管理における劣化メカニズムの分析や補修技術・工法の開発、アセットマネジメントシステムの研究・開発¹⁾²⁾³⁾等が国内外で進められている。2014年には道路法の改正に伴い、各種構造物の定期点検（5年ごと、近接目視）が義務付けられ、橋梁を例にとれば全国約70万橋の点検に膨大な労力とコストを要しており、今後、より一層効率的で効果的な維持管理が求められている。

また、国土交通省は、構造物の点検について技術者資格登録規約（2015年10月）に基づき技術者資格登録簿を

[†] 連絡著者 / Corresponding author

E-mail: a-machiguchi@nihonkai.co.jp

示しており、ここでは、例えば橋梁（コンクリート橋）の点検については、高度な技術を必要とする診断作業（健全性の判定を含む行為）と点検作業（健全性判定を除く行為）に区分している。点検作業は比較的資格保有者が多い資格を認定しているが、診断作業については国家資格である技術士（建設部門）のほか、民間資格ではコンクリート診断士やRCCM（コンクリート）といった高度な資格が対象とされている。点検対象の構造物の数に対して有資格者数が不足している現状にあり、今後より一層技術者不足が進行すると想定されていることを考えると診断作業に関する省力化・省人化は、喫緊の課題といえる。

コンクリート構造物の健全性の判定を行うには、劣化要因を推定した上で、劣化予測を行い、部材の各性能（耐荷性・耐久性・第三者影響度等）を評価し、対策の可否を判定することとなる。劣化要因の推定は、外観の劣化状況等からコ

ンクリートの診断技術と技術者の経験を基に総合評価する必要があり、高度な技術を要するものである。そのため、有資格者が1つ1つの劣化を確認し、劣化要因を判定しているのが現状であり、判定作業に有資格者の多くの時間を要している。また、劣化判定は、定性的な判定となるため、近年、判定結果のばらつき⁹⁾が問題視されている。

一方、国土交通省は、これらの課題に対し、近年、急速に発展しているAI(人工知能)を含むICT技術を活用した建設現場の生産性革命(i-Construction)を推進している。主にプログラムを利用したアルゴリズムとして、これまでニューラルネットワークやマルコフ連鎖モンテカルロ法⁵⁾⁶⁾等について研究がされてきた。他、SVM(Support Vector Machine)を用いて劣化写真からひび割れ検出・パターン分析して劣化程度を分類する研究⁷⁾や橋梁診断エキスパートシステムに関する研究⁸⁾等がされている。ニューラルネットワークについては、コンクリート構造物の劣化分析⁹⁾¹⁰⁾や構造ヘルスマニタリング¹¹⁾、景観分析¹²⁾等、様々な分野に対して研究されてきたが、近年、ディープラーニング(深層学習)技術が開発され、これまで複雑で表現できなかった画像認識・画像認証等において多くの成果¹³⁾を出しており、土木分野への適用が望まれている。

以上を踏まえ、本研究では、写真を用いたコンクリート構造物の劣化要因判定の方法の1つとして、ディープラーニングの可能性を確認することを目的に基礎的な研究を行った。

2. 劣化要因判定支援システムの構成

2.1. 劣化要因判定支援システムの概要

本研究において想定する劣化要因判定支援システムの概要を図-1に示す。本研究では、学習時にディープラーニングのモデル(識別器)を作成し、このモデルをコアとして判定時に撮影した写真を入力すれば劣化要因判定結果を出力するシステムを想定する。

ディープラーニングによりモデルを作成するには、コンクリート構造物の部材の劣化(損傷を含むとする)を撮影した写真(以下、劣化写真と称す)のデータ(JPEG・PNG等)及び教師データとなる劣化要因判定結果(劣化要因の分類名、以下クラスと称す)を1組とし、可能な限り多くの写真枚数かつ多くのパターン(損傷種類・形状)を含んだデータをもとにディープラーニングのモデルを作成する。

劣化要因判定支援システムは、道路管理者やコンクリートを専門とする技術者等によって定期点検や日常点検等の診断作業・点検作業で活用されることを想定し、以下の効果を期待できると考える。

- ・省力化・省人化(特に専門技術者の省人化)
- ・品質確保・向上(劣化要因判定精度)
- ・作業時間の短縮(判定作業)

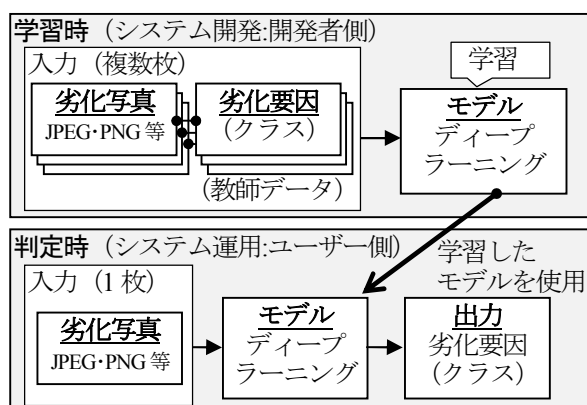


図-1 劣化要因判定支援システムの概要

表-1 対象とした劣化要因の外観上の特徴

劣化要因名(クラス)	外観上の特徴	概略図(例)
ASR	膨張ひび割れ(拘束方向・亀甲状)、ゲル、変色	
塩害	鋼材軸方向ひび割れ、さび、コンクリート剥離	
中性化	鋼材軸方向ひび割れ、さび、コンクリート剥離	
凍害	微細ひび割れ、スケーリング、ポップアウト、変形	
乾燥収縮	ひび割れ(一方向・微細・隅角部)	

※劣化の外観: 部材の特徴や拘束方向によって異なる

表-2 本研究で対象または対象外とした劣化の種類¹⁶⁾

対象とする劣化	対象外とする劣化
<ul style="list-style-type: none"> ・ひび割れ ・剥離・鉄筋露出 ・漏水・遊離石灰 ・抜け落ち ・うき ・変色・劣化・変形・欠損 	<ul style="list-style-type: none"> ・補修・補強材の劣化 ・PC 定着部の異常 ・漏水・滞水・土砂詰り ・異常な音・振動・たわみ ・洗掘・沈下・移動・傾斜

2.2. 対象とする劣化要因

コンクリートの劣化要因の種類は、既往文献¹⁴⁾¹⁵⁾を参考に、アルカリ骨材反応(以下、ASRと称す)・塩害・中性化・凍害・施工不良(乾燥収縮等・豆板等)の他、疲労(床版)・火害・化学的腐食・外力(衝撃・衝突・地震等)・強度不足・磨耗・風化に加え、これらの複合劣化と多様に存在している。ディープラーニングの計算では、計算対象の劣化要因を増やす程、判定は難しくなる。本研究では、代表的な劣化要因である「ASR・塩害・中性化・凍害・乾燥収縮」を対象として計算を行なった。対象とする劣化要因の外観上の特徴を表-1に、対象または対象外とした劣化の種類を表-2に示す。塩害と中性化は異なる劣化要因であるが、ともに内部鉄筋が腐食環境下となり、その腐食の膨張圧でひび割れが生じて最終的には鉄筋露出に至る劣化である。このことから、同様の外観

といえるが、中性化は塩害に比べ施工不良（コンクリートのかぶり不足）が複合していることが多い等の特徴があり、ディープラーニングで分類が可能か検討する。また、疲労（床版）は代表的な劣化要因の1つであるが、写真枚数が少なかった関係で今回は対象外とした。

2. 3. ディープラーニングの入力データ

本研究における判定時のディープラーニングの入力は、写真データに基づくものとし、出力は劣化要因の種類（クラス）とする。学習時には、各写真のクラスを教師データとして入力する。なお、劣化の度合い（潜伏期、進展期、加速期、劣化期）によっても外観上の特徴が変化することが想定されるが、本研究では、これについては包括し、劣化要因に着目したクラスとしている。

また、ディープラーニングによる判定精度は、学習時の入力データに大きく依存するため、収集する劣化写真の数と品質（劣化の特徴の多様性や特徴の明確さ等）が判定精度に大きく関わる。特徴が多様である場合や特徴が明確でない場合は、精度を満足するためにより多くの学習データ数が必要となる。さらに、教師データとなる劣化要因の判定結果については正確さが求められる。本研究で入力するデータは、日本コンクリート工学協会のコンクリート構造物（橋梁・擁壁等の土木構造物や建築物）の「劣化事例写真集¹⁷⁾」及び著者らが現地撮影（市販される一般的なカメラ）した写真（JPEG データ）をもとに選定・抽出した。なお、写真の抽出は、より典型的かつ特異な劣化が含まれない写真、障害物等の誤差が少ない写真を抽出（計245枚、表-3）し、リサイズ（400×300pixel）を行った。なお、劣化事例写真集のデータは、PDF データであり、写真を1枚ずつJPEG データに切り出して抽出している。抽出した写真の例を図-2に示す。各写真と対となる劣化要因は、劣化事例写真集の場合は掲載されている劣化要因を採用し、現地撮影写真の場合は複数名の有資格者（技術士（建設部門：鋼構造及びコンクリート）及びコンクリート診断士）により診断・照合した劣化要因を採用した。

2. 4. モデルの設定

(1)ディープラーニングの概要

本研究では、AI・機械学習の1つであるディープラーニングを使う。従来型ニューラルネットワークは、入力層と隠れ層1層と出力層で構成されるアルゴリズム（図-3）であり、ディープラーニングは、隠れ層が多層化（深層化）していることが特徴である。

また、ディープラーニングには、従来型ニューラルネットワークと同様に教師データ有りの学習と教師データ無し学習があるが、本研究では、教師データとなる劣化要因判定結果を用意できるため、教師データ有りの学習を対象とする。学習では、出力層のノード誤差から隠れ層のノードの誤差を順番に算出しその誤差に基づき結合部の重みを更新（最適化）する誤差逆伝搬法を採用し、

表-3 抽出した劣化写真の枚数（劣化要因ごと）

	劣化要因	写真枚数
1	ASR	50 枚
2	塩害	46 枚
3	中性化	66 枚
4	凍害	36 枚
5	乾燥収縮	47 枚
	合計	245 枚

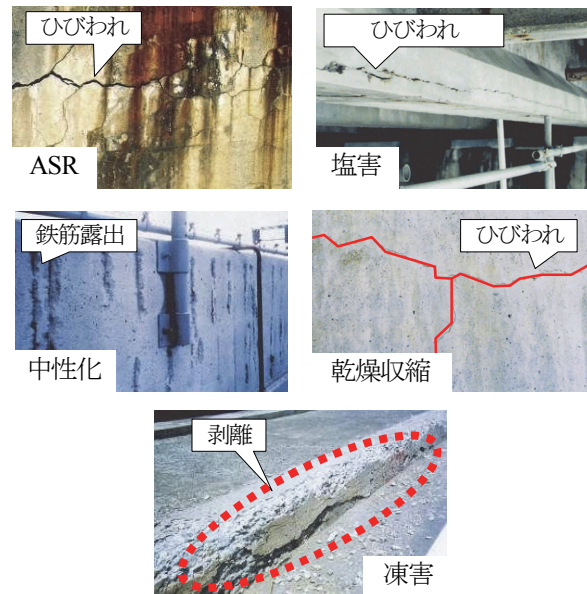


図-2 抽出した劣化写真の例




図-3 従来型ニューラルネットワーク

試行計算の結果から判定精度をモニターし、学習回数を打ち切るものとする。

ディープラーニングのアルゴリズムには、Convolution Neural Network（以下、CNN と称す）や Auto Encoder, Recurrent Neural Network 等があり、本研究では、他のアルゴリズムに比べて画像認識が得意とされている CNN を採用する。CNN は、畳み込み層とプーリング層、全結合層、出力層を持つ構造である。畳み込み層とは、前の層の局所的なノードが次の層のノードと接続する構造を持つ層（抽象化した結果を次の層に伝える層）であり、プーリング層とは、前の層のノードの局所的な部分の中からノードの最大値を次のノードの値とする層（最大値を次の層に伝える層）である。出力層は、前の層の値を受け、確率ベクトルを出力する層である。全結合層は、前の層の全てのノードが当該層の個々のノードに対し相互に連結されている層であり、隠れ層の後半や出力層に設けることが多い層である。

また、結合部の重み係数の更新方法には、バッチ法やミニバッチ法（訓練データから少数のデータを適当に選んで更新処理を行う方法）、確率的勾配法等があるが、本研究では、多くの写真を要することが想定されること、劣化写真は特徴のパターン数が多いと想定されること、学習時間が重要な役割を担うこととなることを考慮し、学習速度が速いミニバッチ法を採用した。

各ノードの出力値に関係する活性化関数には、Sigmoid関数やRelu関数等があるが、本研究ではディープラーニングにおいて一般的に使用されるRelu関数を採用する。なお、Relu関数は、0より小さい値は勾配が0となる特徴がある。また、出力層の活性化関数には、識別問題に適しているsoftmax関数を採用し、出力層の値を確率ベクトルに変換する。損失係数には、確率ベクトル間の類似度を算出する交差エントロピーを採用する。なお、本研究で用いるディープラーニングモデルの構築には、プログラミング言語Pythonを使用し、ディープラーニングのフレームワークは、Chainerを使用する。なお、参考までに本研究で使用しているマシンのスペックを表-4に示す。

(2)ディープラーニングの学習・判定

本研究でのディープラーニングの学習・判定の流れを図-4に、画像処理（マスキング）の例を図-5に示す。机上作業で方針検討後、写真と判定結果を収集し、劣化写真のマスキングを行う。次に、プログラム上での画像処理とデータの分類を行った後に学習及び判定を行う。写真データには対象部材面以外も写っていることが多いため、対象となる面をマスキング（単色塗り、RGB:0・0・255）し、プログラムでマスキング範囲を認識させ、抽出させた。

次に、写真データ（サイズ:400×300）から小片画像（サイズ:120×120）の切り出しを行なった。小片の切り出しでは、縦横ともに中心座標を20ピクセルずつ移動して切り出すことで、学習データを増加している。なお、学習における画像の入力サイズは固定とし、入力数は、小片画像数となる。写真枚数と画像数の関係を表-5に示す。小片画像切り出しは、モデルへの入力時に対象写真及び対象写真にマスキングした写真をセットで取り込み、マスキングの範囲内について小片画像の切り出しを行った。なお、本研究のようにひびわれといった比較的小さな特徴を対象に判定する場合や学習する写真枚数が限られ小片画像に分割することで学習枚数を増加することができる場合は、小片画像の切り出しが判定精度の向上に有効である場合が多くなるとの著者らの経験から、本研究では小片画像の切り出しを採用した。

全小片画像を取り込み後、学習データと判定データに4:1で無作為に分類した。なお、学習と判定は、別の写真から切り出す小片を使用することとしている。

ディープラーニングの層構成とパラメータ等を図-6に示す。層構成やパラメータは、図書¹⁸⁾¹⁹⁾及び著者らの

表-4 本研究で使用しているマシンのスペック

OS	Windows10 Pro 64bit
メモリ	64GB
CPU	インテル(R) Core (TM) i7-770
GPU	NVIDIA GeForce GTX 1080 Ti

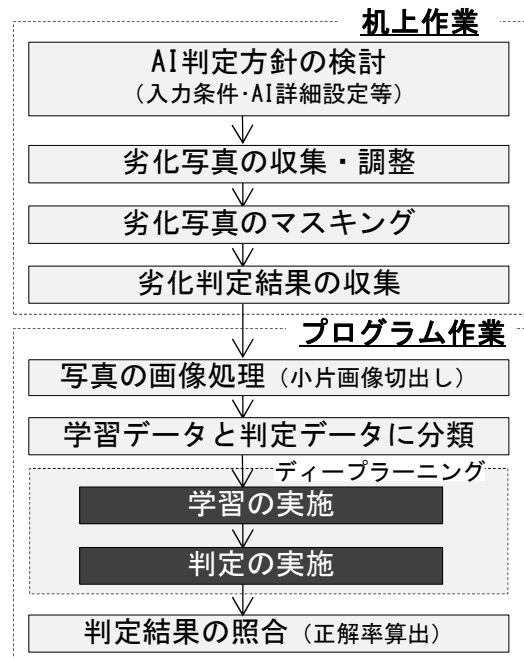


図-4 劣化要因判定支援システムの作業フロー




図-5 画像処理（マスキング）の例

表-5 入力する劣化写真枚数と小片画像数

劣化要因	写真枚数	小片画像数		
		学習	判定	合計
ASR	50枚	579画像	115画像	694画像
塩害	46枚	703画像	221画像	924画像
中性化	66枚	969画像	341画像	1310画像
凍害	36枚	325画像	91画像	416画像
乾燥収縮	47枚	692画像	215画像	907画像
合計	245枚	3268画像	983画像	4251画像

経験からディープラーニングで画像判定する際に比較的精度が高くなるものを採用している。

2. 5. ディープラーニングの出力データ

ディープラーニングの出力は、判定する小片画像の劣化要因（クラス）となる。本研究では、事前に準備した判定結果（正解）とディープラーニングによって判定された結果を照合し、正解率を算出して評価する。

3. 劣化要因判定結果と考察

3. 1. 劣化要因判定結果の概要

判定は、劣化要因の数が精度に影響すると考え、クラスを2・3・4・5種類と変えて学習を行った。計算条件は、クラス数以外全て同じとしている。なお、学習回数は、1,000回から20,000回までの試行計算の結果（図-7）より、2~5クラスで精度が概ね高い数値で安定する5,000回としている。

劣化要因判定結果を図-8、表-6に示す。クラス数増減の影響を比較するため、便宜上、各劣化要因の正解率を単純平均した「平均正解率」により結果を確認すると、劣化要因が2つの際は98%と高い正解率となっているが、クラスを1つ増やすごとに78%（3クラス）、59%（4クラス）、42%（5クラス）と減少した。

3. 2. 劣化要因判定結果の考察

劣化要因数（クラス数）ごとに結果の考察を記載する。なお、従来型のニューラルネットワークにおいて、入力層が特定項目で構成される場合には、結合部の重みから内部構造をある程度分析できるが、本研究ではディープラーニングの入力を小片画像（画素）としており、結合部の重みを基に説明することは困難であったため、本研究では、入力した小片画像と正解率をもとに考察する。

(1) 2クラス判定結果の考察

劣化要因2クラス（ASR・塩害）の判定の結果、ASRは100%、塩害は97%の正解率であった。これは、ASR（ひびわれ、図-9）と塩害（鉄筋露出、図-10）の外観性状が大きく異なることから、高い精度で判定できていると考える。

(2) 3クラス判定結果の考察

劣化要因3クラス（ASR・塩害・中性化）の判定の結果、ASRは83%、塩害は81%、中性化は70%の正解率であった。劣化要因に中性化（図-10）を増やしたことで、ASRの正解率は100%から83%に、塩害の正解率は97%から81%に大きく減少した。これは、クラスの数が精度に大きく影響していることを示している。

(3) 4クラス判定結果の考察

劣化要因4クラス（ASR・塩害・中性化・凍害）の判定の結果、ASRの正解率が81%と高く、続いて塩害は71%、中性化は64%、凍害は21%となった。

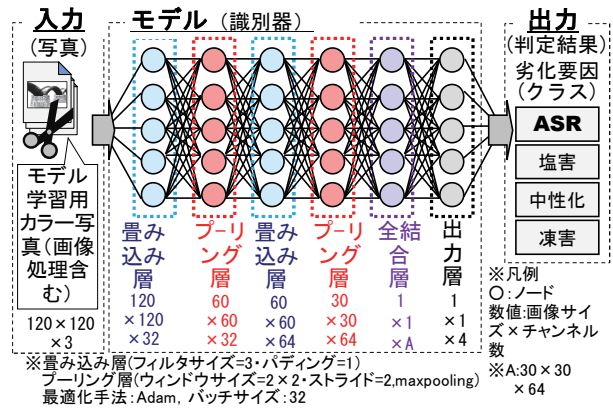


図-6 ディープラーニングのパラメータ等(4クラスの場合)




図-7 学習回数に関する試行計算の結果




図-8 劣化要因判定結果（正解率）

表-6 劣化要因判定結果（正解画像数）

劣化要因	全画像数	正解画像数			
		2クラス	3クラス	4クラス	5クラス
ASR	115画像	115画像	95画像	93画像	35画像
塩害	221画像	214画像	180画像	156画像	154画像
中性化	341画像		239画像	219画像	126画像
凍害	91画像			19画像	20画像
乾燥収縮	215画像				105画像




図-9 ASRの特徴（亀甲状ひび割れ・変色他）

正解率が高かった ASR は、ひび割れが亀甲状に入っており、小片とした際に他の要因に比べてひび割れのパターン等を認識できていると考える。また、今回の ASR の写真では、ASR ゲルや遊離石灰が生じているケースやひび割れ周辺が変色（黒色）しているケースが多く、これらが認識されていた可能性がある。

次に、正解率が比較的高かった塩害と中性化は、主な外観性状がともに比較的わかりやすい形状（鉄筋露出）であり、他の劣化要因と分類しやすい劣化であると考えられる。一方で、正解率が 64～71%に留まっているが、これは、塩害と中性化の外観性状が似ているためと考えられ、ディープラーニングの精度を向上させるには、塩害と中性化を差別化する情報等が必要となる可能性があると考えられる。

凍害（図-11）は、凍結融解を繰り返し表面のコンクリートが脆弱化・剥離し骨材が露出する現象であるが、画像では細かな模様となるため、他の劣化状況や健全部にあるコンクリートの気泡等との差別化が難しく、比較的精度が低かったと考える。また、主部材・付属物（地覆他）等、部材によってコンクリート材料や施工条件が異なることや撮影方法（角度・距離等）が異なることによって同一の劣化要因内で異なるパターン（変状や度合いの違い）があり、精度を低下させていると考える。他にも、凍害の学習画像数は 325 画像と他の劣化要因と比べて少ないことも影響していると考えられた。

(4) 5 クラス判定結果の考察

劣化要因が 5 クラス（ASR・塩害・中性化・凍害・乾燥収縮）の判定の結果、塩害の正解率が 70%と最も高く、次に、乾燥収縮 49%、中性化 37%、ASR 30%、凍害 22% の順序となった。乾燥収縮をクラスに入れることで、全体的に影響があり、特に 4 クラスの判定で最も精度の高かった ASR の正解率が 51%減少した。

4 クラスと 5 クラスの判定結果を比較し、ASR の判定精度が大きく減少した理由としては、ASR と乾燥収縮の外観上は、ともにひび割れが主な損傷であり、比較的類似した劣化要因であるといえる。また、画像内にある色を集計すると、ASR・乾燥収縮ともに、特徴を示すひび割れ（黒色）は小さな面積であり、コンクリートの健全な面（灰色）が大きな面積であることも影響していると考えられる。他にも、中性化は、4 クラスの判定時と比較して正解率が 27%減少した。これは、劣化要因が増えることで、他の劣化要因のモデルも各々変化し、その影響を受けたものと考えられる。

また、乾燥収縮は、正解率が 49%であったが、今回使用した乾燥収縮（図-12）のデータには、建築物の窓枠（斜め方向ひび割れ等）や河川水門のコンクリート部（細かな表面ひび割れ等）、トンネルの継ぎ目部（一方向ひび割れ）といった構造物の種類の違いによるひび割れ形状の違いが含まれたこと等が精度を低下させる要因の 1 つと考える。



図-10 塩害と中性化の特徴




図-11 凍害の特徴（骨材の露出）



図-12 乾燥収縮の特徴（ひび割れ形状の違い）

4. おわりに

4. 1. 本論文の要約

本論文の要約を以下に述べる。

(1) ディープラーニングによる劣化要因判定の可能性

ディープラーニングによりコンクリート構造物の劣化写真（ASR・塩害・中性化・凍害）及びその劣化要因判定結果をもとに学習するモデルを構築し、劣化写真を入力して判定した結果、2 つの劣化要因の学習・判定では 98%の平均正解率となり、3 つの劣化要因では 78%、4 つの劣化要因では 59%の平均正解率となった。このことから、ディープラーニングは、コンクリートの劣化要因を画像判定できるアルゴリズムの 1 つとなる可能性があると考えられた。ただし、本研究では、入力する写真の画像処理の方法やディープラーニングのパラメータ等を一般的な値や著者らの経験等によって設定しており、今後、判定精度を向上させるために、これらの検討が必要であると考えられる。

(2) クラスの分類と学習データに関する考察

ASR・塩害・中性化・凍害の劣化要因に乾燥収縮を追加した 5 つの劣化要因についてモデル化し、計算した結果、42%の正解率となり、4 つの劣化要因時の正解率(59%)に比べて 17%低下した。これは、クラスの分類や数がディープラーニングに大きな影響を与えていることを示している。他にも、ディープラーニングの判定結果において凍害は正解率が低かったが、凍害の画像枚数が少ないことや凍害の特徴がモデル化できていないこと（外観上の劣化が細かく差別化が難しかったこと等）が低い正解率となった要因の 1 つと考えられた。

4. 2. 今後の課題・展望(判定精度の向上)

劣化要因数を増やすことで判定精度の減少が確認された。今後、劣化要因判定支援システムを実用化するには、さらなる劣化要因の追加が考えられるため、判定精度の向上が必要であると考えられた。劣化判定の結果に基づき、今後、ディープラーニングの精度を向上できる可能性がある事項について考察した結果を以下に述べる。

(1) データの増加・データの品質向上

ディープラーニングは、データへの依存度が高いアルゴリズムであり、劣化写真データを増加することで精度向上を見込めると考える。データを収集するにあたり、ディープラーニングの特性上、劣化パターンを分析・分類し、各分類で極端な過不足がないようにデータを収集すると効果的であると考えられる。また、写真データに人為的なマーキング(点検時のチョーキング、落書き)や構造上の境界(目地部等)、自然的支障物(草木・蔦等)がある等、学習の誤差となる情報が含まれる場合がある。これらについては、実際の写真ではより多いと想定され、品質向上対策(画像処理等)が必要であると考えられる。

(2) マスキング方法の変更

劣化要因のうち乾燥収縮は、写真によってひび割れ形状が異なるものであったが、劣化メカニズムからひび割れは浅く、他の劣化要因に比べて方向性が細かく異なるものとなっていると考えられた。そのため、マスキングを劣化部に着目して詳細に囲うこと(図-13)で、他の類似する劣化要因との差別化を図ることができる可能性があると考えられる。

(3) 分類方法の変更(モデルの分類・クラス分類等)

構造物や部材・材料(無筋・RC・PC)が異なる場合、劣化パターンが異なるため、構造物ごとのモデル作成やクラスの細分化等により精度を向上できる可能性がある。他にも、影響が大きいと考えられる写真の撮影距離や撮影角度を分類・整合させることで精度向上の可能性がある。ただし、ディープラーニングは、ある程度データ数を要するため、分類ではこれに留意する必要がある。

(4) モデルへの構造物諸元・環境情報の考慮

ニューラルネットワークの概念は、人の脳をモデル化したものであり、人の劣化判定作業に必要な情報を取り込むことで精度向上につながる可能性がある。人が劣化要因を判定する場合、主に外観上の劣化の状況(種類・程度・形状・パターン等)をもとに判定するが、これに加え、橋梁の建設環境(塩害環境等)や設計・施工情報(構造物種類・部材種類・部材厚等)、過去の補修・補強情報等を考慮した上で、現場での外観状況や検査情報(打音検査等)をもとに総合的に判定している。そのため、これらの情報をディープラーニングのモデルに考慮することができれば、精度を向上できる可能性があると考えられる。

(5) パラメータの検討と他の手法との比較

今回は、ディープラーニングのパラメータを一部固定して計算を行ったが、今後、より精度を高めるため、最




図-13 マスキングの変更イメージ

適なパラメータを検討していく必要がある。

他にも、ディープラーニング以外の手法も合わせて検証し、精度、さらには判定作業全体の効率化や解析時間等の面から比較を行っていくことも必要であると考えられる。特に、本研究では写真をマスキングすることを前提としたため、判定時(システム運用時)においてもマスキングを要することとなる。システムを使うユーザー側の作業の効率化のため、簡易なマスキング方法・機能の検討やマスキングの自動化を検討する必要があると考えられる。

4. 3. 今後の課題・展望(システム構築)

今後、劣化要因判定支援システムを構築するため、システムの運用方法として、運用上の機能(判定結果の表示方法等)やシステム環境(クラウド型・スタンドアロン型)、システム保守、ビジネスモデル等について、詳細に検討する必要がある。

また、本研究では、ディープラーニングの画像判定技術を用いてコンクリート構造物の劣化判定の可能性を示せたことから、点検において作業頻度が多い健全性判定(I・II・III・IV)¹⁴⁾等、類似する他の画像判定への適用を検討する。また、本研究では、対象をコンクリート構造物(土木・建築)に限定して行ったが、他の構造物や材料(鋼等)への適用範囲の拡大を検討する。

今後、劣化要因判定支援システムを構築できれば、現在多くの構造物を維持管理し多忙を極める管理者や技術者を強力に支援するツールとなると考える。今後本研究を進め、システムの実用化を目指す。

謝辞

本研究では、日本コンクリート工学協会が発行する「コンクリート構造物の劣化事例写真集」に掲載される貴重なデータを使用させて頂きました。ここに記して謝意を表します。

参考文献

- 1)土木学会:アセットマネジメント導入への挑戦, 2005
- 2)玉越隆史,大久保雅憲,渡辺陽太:道路橋の計画的管理に関する調査研究—橋梁マネジメントシステム(BMS),国土技術政策総合研究所資料(第523号),2009
- 3)町口敦志,浦田孔二,Dinh Van Hiep,近田康夫:ベトナム国における橋梁マネジメントシステムの適用と課題,構造工学論文集 Vol.62A,pp.147-155,2016.3
- 4)木内順司,齋藤善之,杉本博之:点検結果のばらつきを考慮した橋梁の最適維持管理計画に関する研究,構造工

- 学論文集, Vol.57A, pp.155-168, 2011.3
- 5) 近田康夫, 鈴木慎也, 小川福嗣: 点検結果に基づく劣化予測のためのマルコフ遷移確率推定方法に関する一考察, 構造工学論文集 Vol.61A, pp.70-80, 2015.3
 - 6) 狩野淳一, 秋山充良, 吉田郁政: 点検・検査情報を活用した既存 RC 構造物の耐久信頼性照査に用いる部分係数, 構造工学論文集 Vol.61A, pp.81-90, 2015.3
 - 7) 広兼道幸, 野村泰稔, 楠瀬芳之: コンクリート構造物のひび割れ形状に基づく損傷度分類への線形SVMの適用, 土木学会論文集 A, Vol.64, No.4, pp.739-749, 2008.11
 - 8) 串田守可, 宮本文穂, 中川正樹: 橋梁診断エキスパートシステムにおける知識獲得手法およびシステム信頼性向上に関する研究, 土木学会論文集 No.598, I-44, pp.44-63, 1998.7
 - 9) 井上裕介, 有馬直秀, 橘吉宏, 近田康夫: ニューラルネットワークを用いた北陸地域における鋼橋 RC 床版の劣化予測, 土木学会道路橋床版シンポジウム(第8回), pp.301-304, 2014
 - 10) 河村圭, 宮本文穂, 中村秀明, 三宅秀明: 階層構造ニューラルネットワークを用いたコンクリート診断エキスパートシステムの実用化, 土木学会論文集, No.665, VI-49, pp.45-64, 2000.12
 - 11) 町口敦志, 横山功一, 原田隆郎, 高木優任: 構造ヘルスマモニタリングにおけるひずみ測定の変位補正に関する研究, 構造工学論文集 Vol.53A, pp.718-726, 2007
 - 12) 近田康夫, 髭本実, 城戸隆良, 小堀為雄: 景観色彩調和分析の色彩変換へのニューラルネットワークの援用, 土木情報システム論文集 Vol.4, pp.17-24, 1995
 - 13) Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton : ImageNet Classification with Deep Convolutional Neural Networks , Neural Information Processing Systems (NIPS), 2012
 - 14) 土木学会: コンクリート標準示方書 維持管理編, 2013
 - 15) 日本コンクリート工学協会: コンクリート診断技術, 2017
 - 16) 国土交通省道路局: 道路橋定期点検要領, 2014.6
 - 17) 日本コンクリート工学協会: コンクリート構造物の劣化事例写真集
 - 18) 武井宏将: 初めてのディープラーニング, リックテレコム, 2016.3.4
 - 19) 斎藤康毅: ゼロから作る Deep Learning, O'Reilly Japan, 2016.9.28

(2017年9月25日受付)

(2018年2月1日受理)