

深層学習を利用した画像からの橋梁劣化判定

Detecting Bridge Deterioration from Images using Deep Learning

阿 部 建

要 約 橋梁の点検業務は有資格者による現地点検と診断が義務付けられ、熟練の技術者や予算の確保、技術者による結果のばらつき抑制などが課題である。BIPROGYは深層学習を利用して画像から劣化の要因および損傷の程度を判定することで、課題の解決を目指した。深層学習モデルやその前後処理に対し、点検業務の専門知識を取り込むことで、最終的に劣化の要因については90.8%、損傷の程度については84.4%の精度を達成した。これは技術者による判定と同水準である。開発した判定技術は業務プロセスへ取り込むにあたってプロトタイプを用いた実地検証と、処理速度改善を経て、システムサービスとしてリリースした。開発したシステムサービスを活用した実証実験では国土交通省の第4回インフラメンテナンス大賞の優秀賞を受賞し、社会的にも高い評価を得ることができた。

Abstract Bridge inspections require on-site check and diagnosis by engineers. However, skilled engineers and budgets are limited, and the results vary depending on engineers. BIPROGY solves these problems by using deep learning to infer the cause of deterioration and the degree of damage from images. By incorporating the inspection business expertise into the deep learning model and its pre- and post-processing, we achieved an accuracy of 90.8% for the cause of deterioration and 84.4% for the degree of damage. This is at the same level as the results inspected by engineers. When incorporating this technology into the business process, we implemented it as a system service after a field verification using a prototype and improvement of processing speed. The demonstration experiment using the developed system service won the Excellence Award at the 4th Infrastructure Maintenance Awards from Ministry of Land, Infrastructure, Transport and Tourism, and was highly evaluated by society.

1. はじめに

日本国内に存在する橋梁の老朽化が深刻となっている。橋梁の安全性を保つために、専門の資格を持つ技術者（以下、有資格者）の近接目視による現地点検を5年に一度行うことが2014年7月より義務付けられている。しかし、有資格者を含む熟練の技術者の確保や点検結果のばらつきなど、点検作業には多くの課題が存在する。そこで、BIPROGY株式会社（以下、BIPROGY）は深層学習を利用して画像から橋梁劣化を判定し、橋梁点検作業の省力化を図る検証（以下、本取り組み）を行った。本稿では本取り組みについて述べる。2章では橋梁の老朽化の現状や橋梁点検業務のプロセスと本取り組みの適用箇所について説明する。3章では本取り組みの体制とスケジュールについて、4章では初期検証で定めた基本的な実装方針やその後の精度改善と結果について述べる。5章では技術検証で開発した機能をシステムサービスへ組み込む際に発生した課題と対応について述べる。

本取り組みは国土交通省および石川県産業創出支援機構の助成^{[1][2][3]}を受けた、株式会社日本海コンサルタント（以下、日本海コンサルタント）および金沢大学近田康夫名誉教授と

BIPROGYの共同研究である。なお、本稿ではAI機能の実現方法や技術検証の過程を対象とし、これをユーザに提供するシステムサービスについては深く言及しない。

2. 橋梁の老朽化の現状と点検作業のプロセス

日本では高度経済成長期以降に数多くのインフラが整備されたため、2023年現在、建設後50年を超えるものが急速に増加している。特に橋梁は全国に73万橋と多く、その他のインフラと比較して最も老朽化が進むことが見込まれている（表1）。

表1 建設後50年を経過する社会資本の割合^[4]

	2018年3月	2023年3月	2033年3月
道路橋 【約73万橋注1】（橋長2m以上の橋）】	約25%	約39%	約63%
トンネル 【約1万1千本注2】】	約20%	約27%	約42%
河川管理施設（水門等） 【約1万施設注3】】	約32%	約42%	約62%
下水道管きょ 【総延長：約47万km注4】】	約4%	約8%	約21%
港湾岸壁 【約5千施設注5】（水深-4.5m以深）】	約17%	約32%	約58%

注1) 建設年度不明橋梁の約23万橋については、割合の算出にあたり除いている。

注2) 建設年度不明トンネルの約400本については、割合の算出にあたり除いている。

注3) 国管理の施設のみ。建設年度が不明な約1,00施設を含む。（50年以内に整備された施設については概ね記録が存在していることから、建設年度が不明な施設は約50年以上経過した施設として整理している。）

注4) 建設年度が不明な約2万kmを含む。（30年以内に布設された管きょについては概ね記録が存在していることから、建設年度が不明な施設は約30年以上経過した施設として整理し、記録が確認できる経過年数毎の整備延長割合により不明な施設の整備延長を按分し、計上している。）

注5) 建設年度不明岸壁の約100施設については、割合の算出にあたり除いている。

資料) 国土交通省

一方で、市町村の約2割、村に限定すると約6割で橋梁管理に携わっている土木技術者が存在せず、技術者の確保が困難となっている（図1）。また、点検技術の差も大きく、技術者によって点検の結果にばらつきが生じることや、近接目視の義務付けから省力化が図られにくいことも問題である。

橋梁点検作業の流れを図2に示す。初めに①現地踏査と既存資料の整理を行う。次に②現地近接目視によって劣化状況を点検し、③結果を調書に記す。最後に④調書に基づき精密検査や補修の必要性について診断する。このうち、②現地点検と④診断は有資格者により行われることが多い。特に④診断は各種情報や技術的知見、ノウハウ等をもとに総合的に判定を行うため、高度な専門技術が求められる。

そこで、本取り組みでは②現地点検から④診断において、カメラやスマートフォン等で撮影した画像から、橋梁の劣化要因やその損傷程度を示す健全度の判定を自動的に行うことで、技術者の省力化と結果のばらつきの低減を図った。

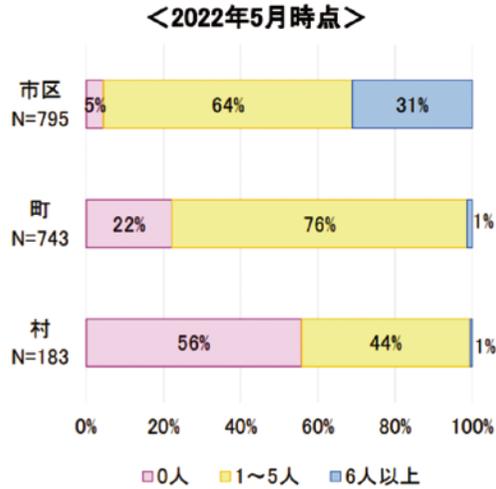


図1 橋梁管理に携わる土木技術者の割合^[5]

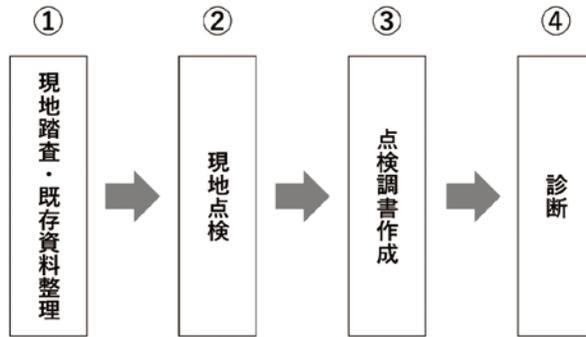
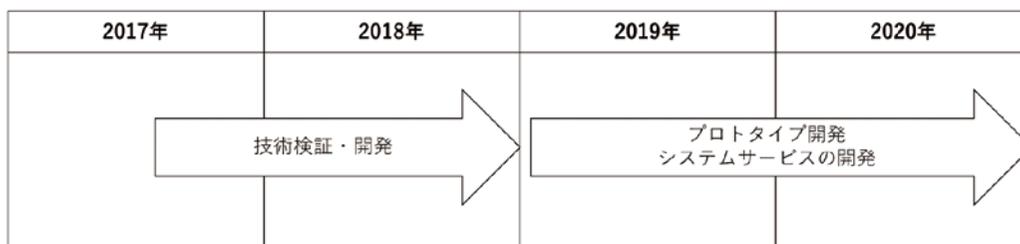


図2 橋梁点検作業プロセス

3. 取り組み体制とスケジュール

日本海コンサルタントは社会資本の点検から補修・補強による長寿命化方策に携わっており、橋梁点検業務における専門的知見を有する。BIPROGYはシステムインテグレータとしてシステム開発を行っており、深層学習や画像解析における専門的知見を有する。

本取り組みは大きく分けて2017年から2018年にかけて実施した技術検証・開発と、2019年から2020年にかけて実施したシステム開発の二つからなる。技術検証・開発では、日本海コンサルタントが橋梁点検業務における専門知識に基づく助言とシステム構想・学習データの作成を行い、BIPROGYが深層学習、画像解析の専門知識から実装を行うことで、両者の専門知識を融合し、業務知識をうまくAIへ取り込んだ。システム開発では、日本海コンサルタントは実証実験・深層学習モデルと画像解析方法の再構築を実施し、BIPROGYはプロトタイプ開発、及びシステムサービス開発と改善結果の取り込みを行った(図3)。



担当	技術検証・開発	プロトタイプ開発・本番システム開発
日本海コンサルタント	<ul style="list-style-type: none"> ・橋梁点検業務の専門知識の提供 ・業務観点から検証結果の評価、改善提案 ・システム構想 ・学習データの作成 	<ul style="list-style-type: none"> ・深層学習モデルと画像解析方法の再構築 ・実地検証の実施 ・精度改善検証の実施
BIPROGY	<ul style="list-style-type: none"> ・深層学習、画像解析技術の実装 ・AI観点から検証結果の評価、改善提案 	<ul style="list-style-type: none"> ・システムサービスの実装 ・処理性能の改善 ・再構築した深層学習モデルと画像解析方法の取り込み

図3 スケジュールと役割

4. 技術検証

本章では2017年から2018年にかけて行った技術検証について述べる。初めに検証初期に定めた基本方針と初期検証の結果について、次に精度改善のために基本方針に加えた方策とその結果について述べる。

4.1 基本方針

全体の処理は大きく分けて画像の前処理、深層学習モデルによる判定、判定結果の集計処理の三つからなる。本節ではこれらの処理の基本方針に加え、学習・識別に用いるデータについて述べる。

4.1.1 データ

初期検証で使用したデータの詳細を表2に示す。日本海コンサルタントが保有していた画像から、解像度が800×600以上のもののみを採用した。

表2 初期検証で使用したデータ

項目	説明
データ数	970枚
データ収集法	<ul style="list-style-type: none"> ・日本海コンサルタントが保有していた写真 ・北陸地方。早期劣化（ASR・塩害）が確認されている新潟、富山、石川、福井。 ・解像度が高い（800x600以上）もののみを使用

自動判定する項目は表3のとおりである。劣化の原因を示す劣化要因は、劣化していないことを示す健全部クラスを含めて7分類である。健全度は数字が小さくなるほど劣化しているこ

とを表し、劣化していないことを示す健全度5を含めて5段階である。

学習に用いるデータには、画像毎にこれら劣化要因と健全度の正解ラベルを付与した。劣化要因は画像1枚あたり一つのクラスを割り当てた。一方、健全度は画像に映る橋梁部分の場所によって異なるため、健全度により異なる色で該当箇所を塗りつぶすようなデータを用意した(図4)。以降、この塗りつぶした領域のことをマスクと呼ぶ。

表3 自動判定する項目

劣化要因	ASR
	塩害
	中性化
	凍害
	収縮系・疲労
	豆板系
	健全部
健全度	健全度5(健全)
	健全度4
	健全度3
	健全度2
	健全度1(不健全)

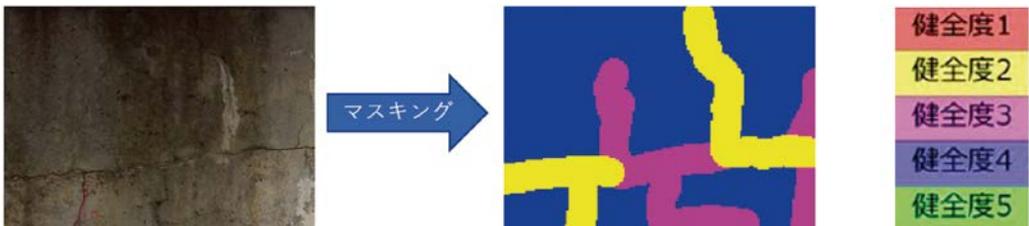


図4 健全度正解ラベルの例

4.1.2 画像の前処理

前処理では画像サイズを揃えたうえで、小片に分割する(図5)。劣化要因や健全度を判定するためにはヒビなどの微細な情報が重要である一方で、高解像度の画像は深層学習で扱いづらい。そこで、小片画像毎に深層学習モデルで学習・識別を行うことで、精度の向上を目指した。この時、橋梁と関連のない画像を抜き出さないよう、小片画像はマスクと照らし合わせ、橋梁部分のみを切り出した。また、各小片の正解ラベルはこのマスクに準じて付与した。

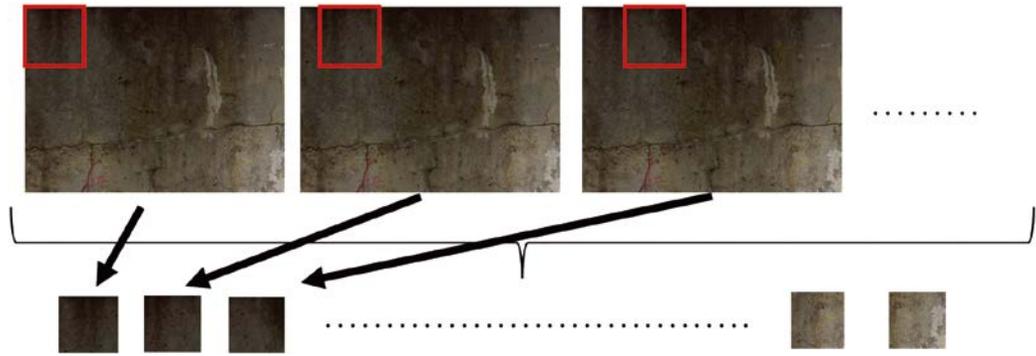


図5 小片分割のイメージ

4.1.3 深層学習モデル

学習・識別を行う深層学習モデルには、畳み込み層とプーリング層、全結合層など^{*1}を用いた画像分類モデルを使用した(図6)。劣化要因と健全度には関連性があると考え、全結合層よりも前の層は劣化要因と健全度それぞれで共有するネットワークとしている。

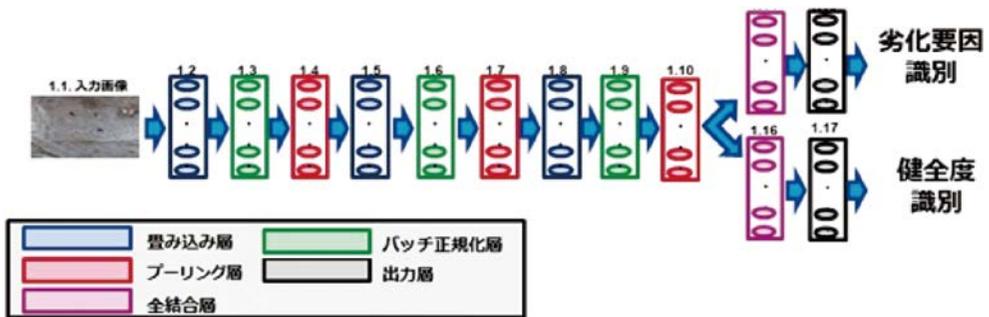


図6 深層学習モデルのネットワーク構造

4.1.4 判定結果の集計処理

判定結果の集計処理では、深層学習モデルから出力される各小片画像の結果を集計し、画像全体の劣化要因と健全度を決定する。小片画像は、互いに領域が重なるようにトリミングしているため、元の画像の一つのピクセルに対し、複数の識別結果が存在する。そのため、識別結果の多数決により各ピクセルの識別結果を決定した(図7)。最後に、識別結果のうち最もピクセル数の多い(つまり、面積の広い)識別結果を、画像全体の識別結果とした(図8)。



図7 各ピクセルの識別結果

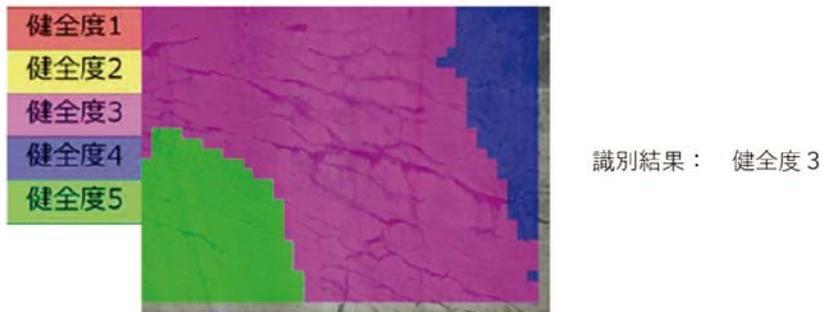


図8 画像全体の識別結果

4.1.5 結果

4.1.1項に示すデータにおいて4.1.2項から4.1.4項までに示す処理を行った結果、劣化要因の正解率は53.9%、健全度の正解率は47.3%であった(図9)。

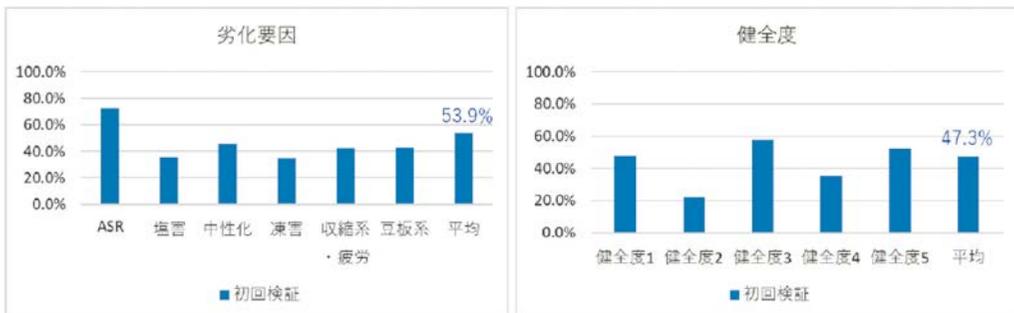


図9 初期検証の精度

劣化要因について誤った識別を行っているケースを調査したところ、見た目が似ている要因間で識別に誤りが多いことがわかった(図10)。2章で述べたように、実際の診断作業では目視情報のみならず、多角的な観点から総合的に判断している。このため、画像のみを利用した

初期検証の手法では十分な精度が得られなかったと考えられる。



図10 見た目が似ている劣化要因

また、健全度について誤った識別を行っているケースを調査したところ、健全度2、4が健全度3に判定されるケースが多かった。これも劣化要因と同様に、健全度1や健全度5といった極端な状態ではない限り、見た目が似ており、周辺情報から診断されているためだと考えられる（図11）。



図11 健全度2、3、4の見た目が似ているケース

4.2 精度改善

4.1節に示した基本方針に対し、劣化要因、健全度それぞれの精度を向上するために様々な改善を行った。本節ではそのうち効果の大きかった、実際の有資格者の判定に近づける三つの取り組みについて述べる。

4.2.1 諸元等情報の追加

実際の有資格者の判定に近づけるため、架設されている地域の特性など画像以外の情報を利用した。日本海コンサルタントの助言を受けて、診断に用いられる知見で収集が容易な、表4の諸元等情報を採用した。

表 4 諸元等情報一覧

情報	分類	情報名	選 択 項 目
諸元	経年系	架設年 (西暦)	数値 4 桁 (XXXX 年), 不明
	環境系	ASR 地域	地域内・外
		塩害地域	地域内・外
		凍害地域	地域内・外
		凍結防止剤散布	地域内・外
構造系	部材情報	主桁・横桁・床版 (コンクリート橋・鋼橋)・下部工・他	
	材料情報	PC・RC・無筋	
損傷	損傷系	最大ひび割れ幅	0.0 ~ 3.0mm
		断面欠損系	無・欠損有 (小・大)・うき有 (さび有・無)・鉄筋露出有 (減肉有・無)

諸元等情報を橋梁点検業務における業務知識として深層学習モデルに取り込むにあたり、劣化要因と健全度のモデルを分け、画像の畳み込み結果と諸元等情報を結合したうえで全結合層による分類を行うネットワークを採用した (図 12)。

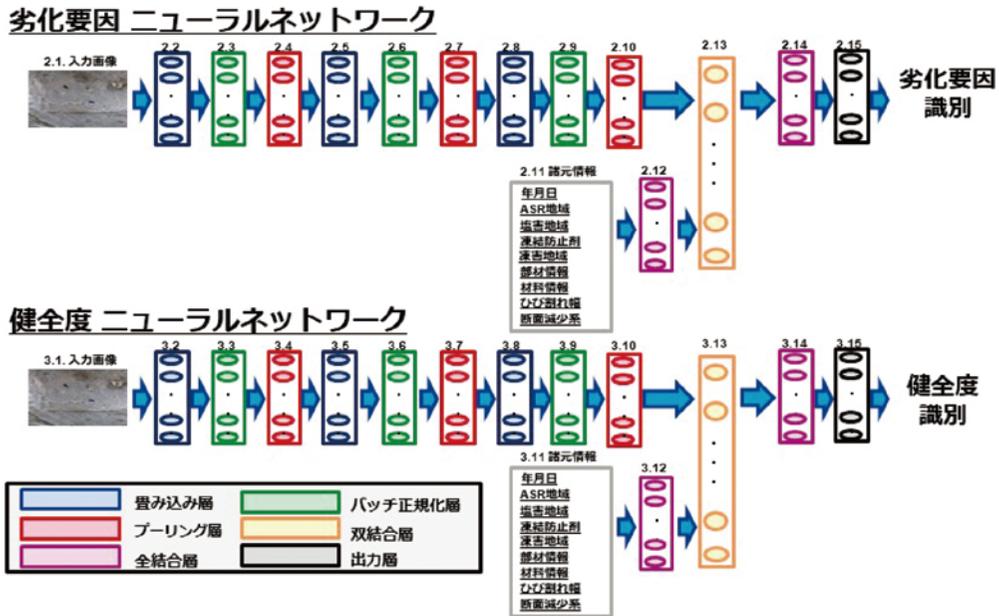


図 12 諸元等情報を入力に加えたネットワーク構造

4. 2. 2 健全度計算方式の変更

実際の有資格者の判定に近づけるため、各小片画像の結果から画像全体の健全度を決定するロジックを改善した。日本海コンサルタントによると、総合的な健全度の判断は健全性の範囲の広さよりも、一部の低いほう、つまり状態が悪いほうが優先される。そこで、初期検証では最もピクセル数の多い識別結果を採用していたことに対し、全てのピクセルのうち最も低い健

全度を、画像全体の健全度として採用するように修正した。ただし、小片画像の誤判定によるノイズも考慮し、閾値を設けて一定以上の面積を持つことを必要条件とした（図13）。

面積割合の閾値を5%とする場合

健全度	面積割合	累積割合
5	30%	100%
4	60%	70%
3	4%	10%
2	3%	6%
1	3%	3%

面積割合は閾値より小さいが、累積割合が閾値を超えるため、採用する

面積割合閾値より小さいため採用しない

図13 改善後の健全度計算方式

4.2.3 データの改善

一般に深層学習モデルは学習に用いるデータが多いほど精度が向上する。そこで日本海コンサルタントの協力を得て、初期検証より多くのデータを学習に利用した。利用したデータの詳細を表5に示す。このとき、ピントが合っていない画像や、極端に遠方から撮影して目視による判別が困難な画像は学習のノイズになると考え、あらかじめ除いた。

表5 追加後のデータ

項目	説明
データ数	1485枚
データ収集法	<ul style="list-style-type: none"> ・日本海コンサルタントが独自に現地踏査した写真 ・北陸地方、早期劣化（ASR・塩害）が確認されている新潟、富山、石川、福井、 ・解像度が高い（800x600以上）もののみを使用

4.2.4 結果

4.2.1項から4.2.3項までの改善策を取り込んだ結果、劣化要因の精度は91.4%、健全度の精度は82.7%となった（図14）。日本海コンサルタントの調査によると、これは技術者の判定精度と同等であり、本機能の利用目的が技術者の支援であることから、十分な精度を達成したと言える。

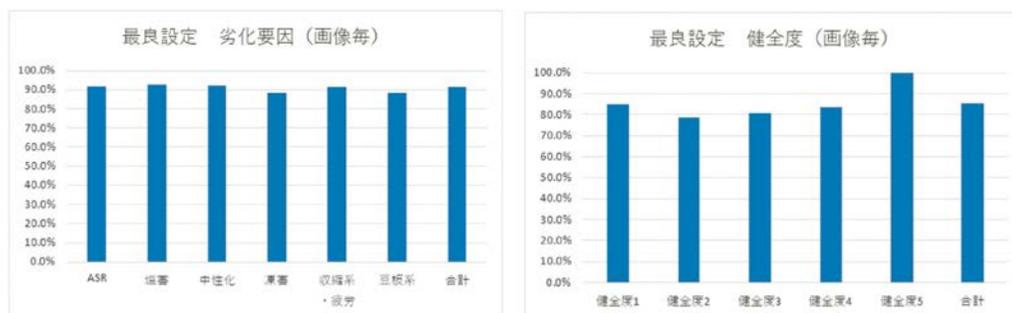


図14 改善活動後の精度

5. システム開発

4章の検証結果をふまえ、本機能を実業務に取り込むため、プロトタイプを用いた実地検証と、システムサービス開発を行った。本章では実地検証とシステムサービス開発で見つかった課題と対応、および最終的に開発したシステムサービスの概要について述べる。

5.1 実地検証で見つかった課題と対応

プロトタイプを使用した実地検証を日本海コンサルタントが実施するなかで、精度が低下するケースを洗い出し、改善を図った。実際にプロトタイプを使用した実地検証で発生した課題として、橋梁との距離が異なる写真が撮影されることがあった。4.1.2項のとおり、本機能では最初に画像サイズを揃えたうえで小片画像を作成する。一方で、撮影距離が遠い場合と近い場合では、小片画像の縮尺が異なるため、学習データに様々な撮影距離のデータがないと精度が低下することから、より多くの学習データを用意しなければならない。また、撮影距離が遠い場合は解像度が落ち、ヒビなどの微細な情報が失われる可能性がある。そこで、事前に撮影距離を入力として与え、撮影距離に応じて異なる縮尺で画像をリサイズするロジックの提案を日本海コンサルタントから受け、取り込んだ。

その他にも学習データを追加する等のモデルの改善を図った結果、最終的に実地に近い撮影データに対する劣化要因の精度は90.8%、健全度の精度は84.4%となり、本番システム開発に取り組んでいる。

このようにシステムサービスを開発する前に、プロトタイプによる実地検証を行うことは重要である。特に機械学習においては過去のデータから統計的に推論を行うため、机上かつ静かなデータで行った技術検証の結果と、実運用の結果に差が現れることが往々にしてあり、事前に実地検証による精度の担保と実業務におけるROIを評価することは必須である。

また、実地検証以降の深層学習モデル・画像解析方法の再構築を日本海コンサルタントが担った点も本取り組みの成功に繋がった。初期の技術検証・開発はAIやシステムの専門家を中心となってロジックの検討や実装を行うことは避けたいが、最終的にはエンドユーザに近い技術者がシステムの効用やあるべき姿をフィードバック・改善できる体制が望ましい。本取り組みでは初期の段階から日本海コンサルタントとBIPROGYが深く連携して技術検証・開発を行っており、業務の専門家がAI技術に対する造詣を深めたゆえに生じた賜物といえる。

5.2 システムサービス開発で見つかった課題と対応

システムサービス開発に際して4章の検証時より処理速度が低下したため、改善を行った。4章では、学習処理も行うため、GPGPU^{*2}を構築できるハイスペックな機器を用意していたが、システムサービス環境では識別処理のみを行うため、GPUを採用せずスペックも落としていた。

調査の結果、システムサービス環境のメインメモリのサイズが検証環境のGPUメモリサイズよりも小さく、ページング処理が発生し処理速度が低下していることが分かった。システムサービス環境のメインメモリの増設はコスト上困難であったため、ミニバッチサイズを下げることにより処理速度が改善した。

GPUメモリを利用する多くのフレームワークはメモリが足りない場合にハンゲアップするものが殆どで、当該の障害に気づきやすい。識別時のミニバッチ数は処理速度の都合上、メモリの許す限り大きくすることが多いため、GPGPUからCPUへハードウェアを変更する場合

はメインメモリについても特に注意されたい。

5.3 システムサービスの概要

4章の机上検証, 5.1節の現地検証, 5.2節のシステムサービス開発の課題対応を経て, AI橋梁診断支援システム「Dr.Bridge®」を2020年にリリースした。本システムサービスでは現地点検(図15)と点検調書の作成業務(図16)を支援する。ここで重要なのは, AIによる診断はあくまで技術者の支援が目的であり, 診断結果は技術者の判断により変更できるので, 結果を鵜呑みにして詳細調査や補修などの判断までを安易に下さないようにすることである。必ず人がAIの出力を確認したうえで次のアクションを行うことで, このリスクは回避される。

現場で写真撮影

橋梁の劣化箇所をカメラで撮影し、クラウドサーバーへアップロードします。

橋梁諸元・損傷情報をWeb上で入力

部材	○主桁 ○横桁 ○床版 ○床版(鋼橋) ○下部工 ○他
材料	○PC ○RC ○無筋
地域情報	☑ASR地域 ☑塩害地域 ☐凍害地域 ☐凍結防止剤
最大ひびわれ幅	○無 ○0.3mm未満 ○1.0mm未満 ○1.0mm以上 ○最大入力[mm]
欠損	☐無 ☐有 (○小規模 ○大規模)
鉄筋露出	☐無 ☐有 (○減肉無 ○減肉有)
うき	☐無 ☐有

AIが瞬時に劣化診断
高画の表示画面です。

AIが劣化箇所を着色することによって劣化要因・健全度を明確化します。

図15 橋梁劣化要因・健全度判定支援機能

- ・ 橋梁情報登録 (橋長・構造形式等)
- ・ 業務情報登録 (点検年・点検者など)
- ・ 写真登録 (損傷写真・全景写真)
- ・ 診断結果 (橋梁健全性・変状の種類等)

※その他機能:

- ・ 一括登録機能
- ・ 診断結果分析機能 (写真単位)

道路橋定期点検要領の様式

出力

Dr.Bridge独自様式

Dr.Bridge入出力
(JPG・CSVファイル)

図16 点検調書作成支援機能

6. おわりに

本稿ではインフラ老朽化という社会課題に対し、AIを活用して解決に取り組んだ。初期検証では精度が十分ではなかったものの、専門的な業務知識を持つ日本海コンサルタントと協力することで、実用に足る精度を達成し、システムサービスのリリースを実現した。また、本システムサービスを活用した七尾市との実証実験では、国土交通省が実施する第4回インフラメンテナンス大賞で優秀賞を受賞し、社会的にも高い評価を得られた^[6]。本稿執筆時点で、この取り組みは4年前のものと古いが、業務知識とAIをうまく融合するための体制やアプローチは、時代や業界・業種を問わず通用するだろう。

一方、AIの適用領域が広がってきている昨今、よりミッションクリティカルな領域に適用するためには多くの課題がある。機械学習は統計的に推論を行うので、結果を担保することは難しいうえ、過去のデータを利用するため、時間の経過とともに精度が劣化することは免れない。更に深層学習においてはブラックボックス化が進み、結果に対する正当性や妥当性を確認することが難しい。2023年現在、これらの課題に対し、AIモデルの運用・監視を行うサービスやAIの推論過程に説明を与える技術が増えてきている。これらの技術によって、より責任あるAIが実装され、多くの社会課題が解決することを願っている。

最後に、本取り組みの関係者、執筆にあたって指導、協力頂いた方々に深く感謝するとともに御礼して本稿の結びとする。

-
- * 1 人間が物体を見る際に生じる経過をモデルに考案された、画像認識の深層学習の手法を構成するコンポーネント。これらを総じて畳み込みネットワークと呼ぶ。
 - * 2 General-purpose computing on graphics processing units の略で、本来画像処理を高速に実行する目的で作られたGPU (Graphics Processing Unit) の演算資源を、汎用的な計算に転用すること。

- 参考文献**
- [1] “i-Construction を推進する 17 技術を新規採択—平成 29 年度建設技術研究開発助成制度の採択課題決定について—”，報道発表資料，国土交通省，2017 年 8 月 14 日，http://www.mlit.go.jp/report/press/kanbo08_hh_000438.html
 - [2] “i-Construction を推進する 5 技術を新規採択しました—平成 30 年度建設技術研究開発助成制度の採択課題決定—”，報道発表資料，国土交通省，2018 年 8 月 27 日，http://www.mlit.go.jp/report/press/kanbo08_hh_000506.html
 - [3] “事業化促進支援事業採択案件”，新製品・技術開発，公益財団法人石川県産業創出支援機構，2019 年，<https://www.isico.or.jp/site/shinseihin/jigyouka-saitaku.html>
 - [4] “社会資本の老朽化の現状と将来”，インフラメンテナンス情報，国土交通省，https://www.mlit.go.jp/sogoseisaku/maintenance/02research/02_01.html
 - [5] “老朽化対策の取組み”，道路の老朽化対策，国土交通省，2022 年 12 月，<https://www.mlit.go.jp/road/sisaku/yobohozen/torikumi.pdf>
 - [6] “第 4 回インフラメンテナンス大賞 受賞概要”，インフラメンテナンス情報，国土交通省，2020 年 11 月，https://www.mlit.go.jp/sogoseisaku/maintenance/03activity/03_award_04.html

※ 上記参考文献に含まれる URL のリンク先は、2023 年 1 月 24 日時点での存在を確認。

執筆者紹介 阿 部 建 (Takeru Abe)

2016年日本ユニシス(株)入社。数値回帰、レコメンド技術の適用や社内AI技術適用の推進活動を経て、画像や3Dデータを対象とした技術検証/開発/適用に主に携わる。2022年より、特定のデータ・技術に依らないAIプロジェクトの標準化、知財化、企画推進に携わる。

