

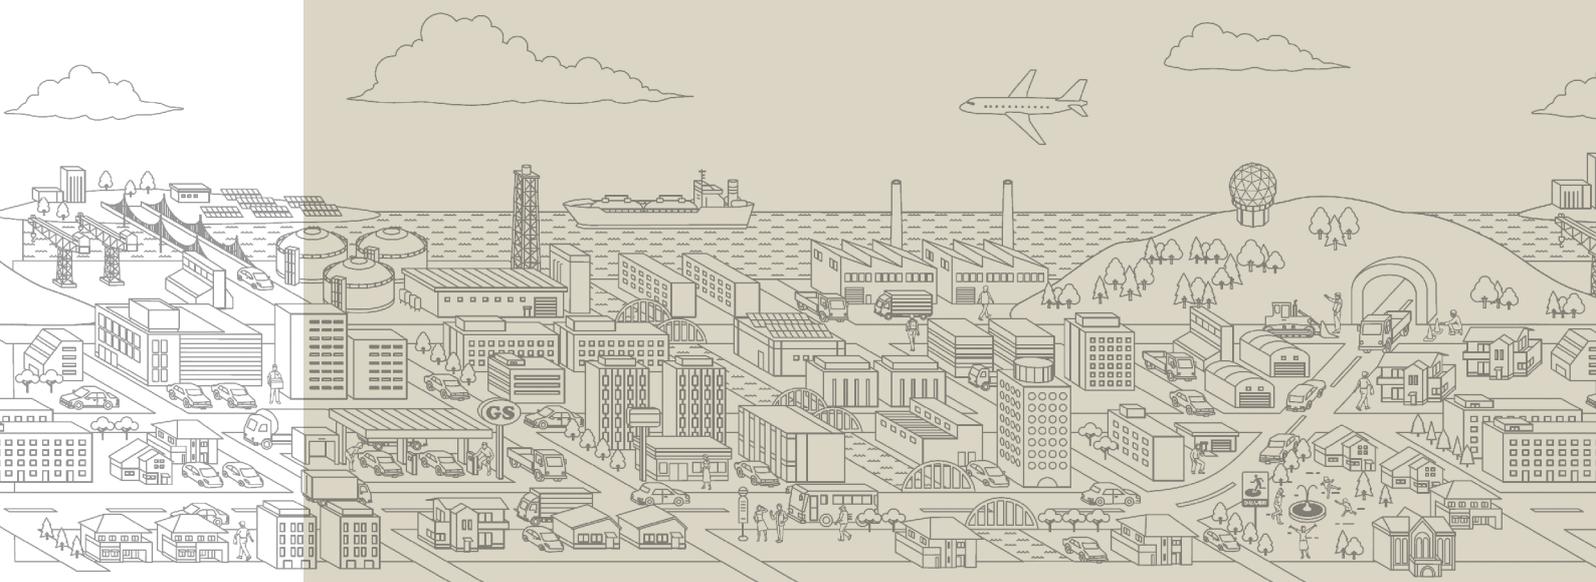
SIPインフラ連携委員会報告

インフラ維持管理へのAI技術適用のための 調査研究報告書



SIPインフラ連携委員会報告

インフラ維持管理への AI技術適用のための 調査研究報告書



Research and Development Report
on Applications of Artificial Intelligence
to Infrastructure Maintenance

SIP Infrastructure Program Coordinate Committee
Organization for Promotion of Civil Engineering Technology, JSCE

序

2014年から内閣府総合科学技術・イノベーション会議の主導で始まった、SIP インフラ維持管理・更新・マネジメント技術（以後 SIP インフラと略す）は内閣府のプロジェクトということで普段はインフラとはあまり関係が深くない企業、国立研究所、大学等が参加してくれたことは大変うれしいことであった。また出身分野も土木系は半分にとどまり、電気電子、通信、情報、ロボティクス、センサー、材料科学、さらに社会システム、経済など他分野の方に多く参加いただき、60 チームが大変活発な研究開発活動を開始した。

2016年に発表された第5期科学技術基本計画で大きく打ち出されたのは Society 5.0 という考え方であった。莫大なデータを収集し、それをベースに様々なサービスを提供するというのが構想の基本とされている。その為には、様々なデータを解釈し、判断するという技術が当然必要となる。また、時期を合わせて、深層学習など人工知能（AI）の分野でも第3の革命が起こり、AIがいろいろな場面で適用できる状況が生まれてきた。

内閣府総合科学技術・イノベーション会議でもこのAIの活用について国を挙げて取り組む姿勢を打ち出し、SIPのいくつかの課題はAIに対する対応を指示された。SIPインフラでは人工知能を活用した研究が数個のチームですすでに行われていたが、さらにそれを増やし、また今後のインフラメンテナンスやそのマネジメントに、このAIをどのように活用していくかを議論していく必要が生じた。JSTの阿部雅人フェローからSIPインフラの中にAIを議論する場を若手中堅で設置する提案をいただいた。これを受けて2017年から始まったのが本研究会である。

ここでもSIPインフラのいい意味での特徴が現れ、土木分野の若手中堅に加え、人工知能、画像、情報などの他分野の方が混じった交流の場ができたことは大変うれしく思っている。研究会では、SIP関係者だけでなく、最先端の研究を行っている方々に講演にきていただき、研究内容を理解するとともに、意見交換を通じて最新の情報を獲得する機会をもったと聞いている。講演に来ていただいた方に、心よりお礼を申し上げたい。

『防災情報サービスプラットフォームのプロトタイプ構築の取り組みについて』

防災科学技術研究所 災害過程研究部門 鈴木進吾 主幹研究員

『ひび割れ自動検出技術開発へのAI導入について』

産業技術総合研究所 知能システム研究部門 永見武司 主任研究員

『大規模人工システムのためのデータ駆動型異常検知について』

東京大学 大学院工学系研究科 航空宇宙工学専攻 矢入健久 准教授

『ソーシャルメディアの実社会応用について ～医療分野での事例を中心に～』

奈良先端科学技術大学院大学 研究推進機構・情報科学研究科 荒牧英治 特任准教授

『KDDIのスマートドローンおよび5G時代を見据えたAI活用について』

KDDI株式会社 商品・CS統括本部 商品戦略部 商品1グループ 杉田博司 様

『データ同化ならびにデータサイエンス手法の応用事例紹介』

明治大学 総合数理学部 現象数理学科 中村和幸 専任教授

『人工知能技術の社会実装における課題とデータ駆動型 AI と論理知識型 AI の融合の提案』

九州工業大学 大学院生命体工学研究科 人間知能システム工学専攻 我妻広明 准教授

2年あまりの研究会の活動成果をまとめたものが本報告書であり，このような活発な交流活動が土木学会において継続されることを大いに期待する。

主査を引き受けていただいた矢吹信喜氏（大阪大学），副主査をつとめていただいた阿部雅人氏（JST），西尾真由子氏（横浜国立大学）そして委員の方々に，その活発な活動に深く感謝する。また，研究会のマネジメントを担当した JST の松村隆爾氏にもお礼を申し上げたい。

内閣府 戦略的イノベーション創造プログラム（SIP）

「インフラ維持管理・更新・マネジメント技術」

プログラムディレクター 藤野 陽三

土木学会 SIP インフラ連携委員会構成

アドバイザー：藤野 陽三（横浜国立大学、SIP インフラ PD）

魚本 健人（東京大学名誉教授）

阪田 憲次（岡山大学名誉教授）

委員長：田崎 忠行（（一社）日本建設機械施工協会、SIP インフラ サブPD）

幹事：○阿部 雅人（（国研）科学技術振興機構）

岩城 一郎（日本大学）

岩波 光保（東京工業大学）

岡田 有策（慶應義塾大学、SIP インフラ サブPD）

新田 恭士（（国研）土木研究所）

○信田 佳延（（国研）科学技術振興機構）

若原 敏裕（清水建設（株）、SIP インフラ サブPD）

○和田 祐二（（国研）科学技術振興機構）

（○印；代表幹事）

委員：小澤 一雅（東京大学）

黒田 保（鳥取大学）

建山 和由（立命館大学）

手塚 寛之（国土交通省）

土橋 浩（首都高速道路（株））

中村 光（名古屋大学）

長井 宏平（東京大学）

野澤伸一郎（東日本旅客鉄道（株））

濱田 秀則（九州大学）

福森 浩史（清水建設（株））

前川 宏一（横浜国立大学）

松田 浩（長崎大学）

水口 和之（東日本高速道路（株））

宮武 晃司（内閣府）

矢吹 信喜（大阪大学）

横田 弘（北海道大学）

六郷 恵哲（岐阜大学）

オブザーバー：渡邊 基史（内閣府）

千田 篤史（（国研）科学技術振興機構）

生井 達朗（（国研）新エネルギー・産業技術総合開発機構）

AI 適用検討部会構成

- 主 査 : 矢吹 信喜 (大阪大学)
- 副主査 : 阿部 雅人 ((国研) 科学技術振興機構)
西尾 真由子 (横浜国立大学)
- 委 員 : 櫻井 彰人 (横浜国立大学)
土橋 浩 (首都高速道路(株))
野村 泰稔 (立命館大学)
福森 浩史 (清水建設(株))
湧田 雄基 (北海道大学)

目次

1. 本調査研究報告書の発刊に当たって.....	1
1.1 はじめに.....	1
1.2 本書の構成.....	2
2. 画像・空間分布データを用いた研究開発チームにおける関連研究.....	3
2.1 橋梁の打音検査ならびに近接目視を代替する飛行ロボットシステムの研究開発...	3
2.2 床版の AI 解析検討.....	9
2.3 インフラ予防保全のための大規模センサ情報統合に基づく路面・橋梁スクリー ニング技術の研究開発と社会実装.....	17
2.4 高温超電導 SQUID 磁気センサを用いた鋼床版き裂検査技術.....	24
3. 音響・時系列データを用いた研究開発チームにおける関連研究.....	31
3.1 学習型打音解析技術の研究開発.....	31
3.2 レーザー打音高速検査システムの開発.....	39
3.3 上水道における漏水検知システム.....	45
3.4 近接目視・打音検査等を用いた飛行ロボットによる点検システムの研究開発....	54
4. 社会実装に向けての首都高速道路での取り組み.....	59
4.1 インフラマネジメントシステム.....	59
4.2 コンクリート構造物診断技術.....	62
4.2.1 学習型打音解析技術の研究開発.....	62
4.2.2 高感度近赤外線分光を用いたインフラの遠隔診断技術の研究開発.....	67
4.3 今後の展望.....	71
5. 画像・空間分布データを用いたプロジェクトチームによる横断的取り組み.....	74
5.1 画像・空間分布データ取り扱いの基礎的な方法.....	74
5.2 深層学習を用いたデジタル画像からのコンクリート表面変状の検出.....	79
5.3 SUSTERA 高感度磁気検査の AI 活用.....	86
6. 音響・時系列データを用いたプロジェクトチームによる横断的取り組み.....	89
6.1 音響・時系列データの取り扱いの基礎的な知識・方法.....	89
6.2 レーザー打音装置によるコンクリート部材の試験データに対するニューラル ネットワークの適用.....	92
6.3 加速度波形データによる高力ボルトの軸力診断への深層学習の適用.....	97

7. テキストデータを用いたプロジェクトチームによる横断的取り組み	103
8. 研究動向調査	106
8.1 調査の方法.....	106
8.2 既往研究の概要紹介.....	106
9. インフラ維持管理へのAI活用ビジョン	123
9.1 はじめに.....	123
9.2 短期ビジョン：早期に実現すべきAI活用の姿.....	131
9.3 長期ビジョン：理想とする将来でのAI活用の姿.....	137
9.4 短期ビジョン早期実現のために取り組むべき事項.....	142
10. データセット	149
10.1 はじめに.....	149
10.2 機械学習研究におけるデータセット.....	150
10.3 土木工学分野におけるデータセット構築に向けた考察.....	158
10.4 維持管理分野におけるデータセット整備に関する考察.....	165
11. AI活用に向けた課題と道筋	168
12. 執筆者・関係者一覧.....	173

1. 本調査研究報告書発刊に当たって

1.1 はじめに

1980年代、論理学をベースに知識を記号により記述すれば、推論エンジンにより、専門家と同等の回答が自動的に得られるということから、AIは第2次ブームを巻き起こした。しかし、その後、コストと手間がかかる割には効果が限定的であることが明らかとなり、下火になった。ところが、AIの一分野である「機械学習」においてディープラーニング（深層学習）と呼ばれる新しい技術が開発されたことと、大量のデータ（ビッグデータ）を比較的容易に扱うことが出来るようになってきたことから、囲碁や将棋で世界的に著名な棋士にAIマシンが勝利したこともあり、昨今は第3次ブームとなっている。ディープラーニングと従来の機械学習との違いは、従来はデータの属性を人間が全て明示的に拾い出し、プログラム化する必要があったのに、ディープラーニングでは、属性そのものを機械が勝手に想定しながら学習活動を実施してくれる点である。そのため、ディープラーニングでは、過学習とならないようにするためにも、大量の様々なデータが必要である。

従って、インフラ維持管理にAIを活用していくためには、大量のデータを収集することが必要であるが、一体どのようなデータをどれだけ集めると、どんなことがわかるのか、という道筋を明らかにしていくことが重要である。現在でも、コンクリートのひび割れや鋼材のさびなどを、写真（画像）からAIを利用して特定する研究がなされているが、こうした事例から、要するに画像処理なのだな、と判断してしまえば、AIの可能性を限定してしまう懸念がある。

インフラの維持管理は、非常に多くの種類の情報と様々な専門分野の知識が複雑に絡み合わせた総合的なエンジニアリング・マネジメントであり、日々、熟練技術者らはその仕事を、五感と頭脳を駆使して判断しているわけである。従って、実際の構造物の維持管理における種々のデータ、情報を入手し、利用して、それらの間の膨大な数の相関関係をAIに判断させて、仮説を検証していくことが重要である。

内閣府戦略的イノベーション創造プログラム（SIP）は、総合科学技術・イノベーション会議が主導して、府省の枠や旧来の分野の枠を超えた研究開発マネジメントを行い、科学技術イノベーションを実現することを目指すものである。「インフラ維持管理・更新・マネジメント技術」は、2014年度に開始された第1期10課題の中の一つであり、ニーズとシーズをマッチングさせて、インフラの事故を未然に防ぐとともに、予防保全によるインフラのライフサイクルコストの最小化を目指して、研究開発を実施している。インフラ維持管理・更新・マネジメント技術のプログラムの中の各研究課題においても、AIが取り入れられているものも多い。

そこで、インフラ維持管理におけるAIの革新的な活用を加速化し、各研究課題を横断的に組織化し、インフラ維持管理を起点としたSociety 5.0実現の戦略立案と実データによる試行を行うことを主目的として、2017年度に「AIのインフラ維持管理への活用検討プロジェクトチーム」を発足し、具体的には以下の取り組みを進めた。

- 1) 将来において、インフラ維持・管理にAI技術をどのように適用するかを提言。
- 2) 実データを用い、AI技術の各種インフラ維持管理技術への適用法を示す。
- 3) AIの技術をインフラ・維持管理に適用し、各種課題を解決。
- 4) AIをインフラに適用した論文を収集、分類、データベース化し、より高度な活用に供する。

本報告書は、このプロジェクトチームの活動ならびに各研究課題で実施されたAI関連研究を体系的に整理して示すことで、インフラ維持管理におけるAI活用の現状と将来像を提示しようとするものである。

1.2 本書の構成

本書は大きく分けて三つの部分から成り立っている。

まず、第2章から第4章までの最初の部分では、SIPインフラ維持管理における各研究課題で実施された関連課題の紹介である。AIに限らずデータサイエンス的な手法を取り入れているものも併せて収録している。第2章では画像・空間分布データ、第3章では音響・時系列データを中心とした課題を取り上げた。また、第4章では、AI関連技術の社会実装例として、首都高速道路での取り組みを紹介している。

以降の章はプロジェクトチームでの取り組みである。第二の部分である第5章から第7章では、画像・空間分布データ、音響・時系列データ、テキストデータそれぞれについて、現状におけるAI活用の方法を整理している。また、現在、多様な方法が開発され、また、その適用や選択の方法論が確立されていないことから、共通のデータを用いた多様な手法による多面的な検討は極めて有効であると考えられる。そこで、第2章から第4章で紹介されたデータの一部について、プロジェクトチームで横断的かつ多面的に解析した事例も併せて掲載した。

第8章から第11章までの三つ目の部分では、インフラ維持管理へのAI活用の今後の方向性を議論している。第8章ではインフラ分野におけるAI活用の研究の動向を、包括的な文献調査に基づいて明らかにしている。第9章では、インフラ維持管理へのAI活用ビジョンを、早急に実現すべき短期的な視点と長期的な将来の視点から提案している。第10章では、特に第5章から第7章の共通データを用いた解析から明らかになった、インフラにおけるデータセットのあり方に関する課題について整理した。第11章は、これらの検討を受けた課題と提言をまとめたものである。

このように、本書では具体的かつ個別の取り組みを端緒に、それを横断的に検討して一般化していくという構成になっている。インフラ分野におけるAI活用は、いまだ発展途上であり、本書で提案されている方法論やビジョンなども、完成形と言えるものではないと思われる。今後のこの分野における活発な議論と発展の一つの礎となれば幸いである。

2. 画像・空間分布データを用いた研究開発チームにおける関連研究

2.1 橋梁の打音検査ならびに近接目視を代替する飛行ロボットシステムの研究開発

2.1.1 研究の概要

本プロジェクトでは、受動回転球殻機構を持つマルチコプタ（図 2.1.1 参照、以下「球殻ヘリ」と呼ぶ）を使った橋梁点検・調書作成システムを研究開発している（国立大学法人東北大学，株式会社リコー，株式会社千代田コンサルタント，一般財団法人航空宇宙技術振興財団，東急建設株式会社による共同実施）。球殻ヘリ（同図(a)）は橋梁の各部位に近接して飛行し，当該橋梁の表面部の画像を網羅的に撮影する。撮影された画像データは，PC で動作する専用のソフトウェア（同図(b)）を使って目視での点検や確認に利用する。具体的には，点検員がソフトウェアの支援を受けつつ，画像から変状や異常の有無を調査し，その結果をまとめた点検調書を作成できるようになっている。

同システムの狙いは，飛行ロボットを利用することで，橋梁の変状のスクリーニングや点検を手軽に行えるようにすることにある。交通規制や足場の設置を行わずに済むため，必要なコストの削減が期待できる。われわれのシステムには次のような特長がある。

- 球殻ヘリは飛行中に構造物にぶつかっても直ちには落下しないため，対象物に近接しての画像撮影が可能である。橋の桁間に進入したり，添架物の背面を撮影することも可能である。
- 点検支援ソフトウェアは，近接撮影された画像群から，例えば床版の展開画像をほぼ自動で生成することができ，局所部分の撮影画像上で傷を特定すれば，自動的に全体の橋梁におけるその位置が同定される仕組みを備える。

プロジェクトの当初計画では，当時の技術水準や点検に求められる責任の所在を踏まえ，点検の主体はあくまで人（同システムを利用する点検員）であり，その点検作業をサポートすることを想定していた。つまり AI を含む自動化技術はあくまで人の支援にとどめ，人が行う作業を代行することは目標ではなかった。しかしながらその後，最近の AI の急速な技術的進展等を踏まえ，また実証実験を通じて明らかになった種々の課題の解決を目指して，AI の導入を主に技術的



図 2.1.1 「橋梁の打音検査ならびに近接目視を代替する飛行ロボットシステムの研究開発」の概要 (a)受動回転球殻機構を持つマルチコプタ（球殻ヘリ） (b)点検支援ソフトウェア

観点から検討し、実際に研究開発を行ってきた。なおこの部分の研究開発については、理化学研究所革新知能統合研究センターと共同で行っている。

2.1.2 研究テーマの中でのAIの活用

球殻ヘリを用いて行う点検作業は、i)球殻ヘリの操縦、ii)撮影画像を用いた点検、iii)調書作成の3つに大別される。理化学研究所と行っている共同研究では、最終的にこのすべてをAI技術によって自動化することを目標としており、研究内容は多岐に渡るが、ここでは主に画像を対象とした問題にしぼり、研究開発の状況と今後の展望を述べる。

現在AIという語はかなり広い意味で用いられているが、その中核にあるのは深層学習、すなわち深層ニューラルネットワークを使った機械学習の方法であると言って良い。特に、画像を扱うコンピュータビジョンの分野（AIの主要分野の一つ）では、最近5年余りの短い間に、ほぼすべての問題解決に深層学習が利用されるようになり、研究開発の方法論が一変した。これに伴って、数多くのブレークスルーが見られ、従来難しかった様々な問題のいくつかが解決に近づく一方で、学習データの収集が、多くの場合に問題解決のボトルネックとして認識されるようになった。つまり、研究開発の成否の大部分が学習データの収集の可否に左右されるようになった。

さて、橋梁点検にこのようなAI・深層学習の技術を応用しようとするとき、学習データの収集はやはりボトルネックである。その理由として、実空間で大きな構造を持つ橋という対象に対し、画像を初めとするデータを撮影するには相応のコストがかかることがある。この点で、先に成功した、あるいは成功に近づきつつあるウェブ応用や医療画像などにはない難しさがある。さらに、例えば変状の自動検出を目的とする場合、変状とは基本的には「稀な異常」であり、数を集めにくいことも課題となる。

この問題を解決すべく、国のレベルで機械学習のための変状データを集める計画が、国土交通省ならびに土木研究所により開始されており、われわれ（東北大学・理化学研究所）もそこに参加している。学習データの問題が解消された後には、公共インフラの点検に課せられる社会的な責任を前提に、AI点検の性能評価とその保証をどのように行うかという課題が待っている。国のレベルで議論を進めることで、これらの課題もやがて解決されるだろう。

なお深層学習において、少ない学習データで高い性能を達成可能な方法を実現することは、関連分野でも最大の関心事の一つであり、執筆者の研究室でも主要研究テーマの一つである。世界中でこれまでに様々な検討が行われ、その結果、転移学習やデータ拡張などの対処法が確立される一方（ただし、これらだけでは多くの場合不足である）これに加えて、コンピュータグラフィクス等のシミュレーション技術による学習データの合成や、合成データと実データのずれ（ドメインシフト）の影響を小さくするドメイン適応など、成果は少しずつ重ねられている。一方で、無教師学習や半教師あり学習—少量の正解付きデータと大量の正解なしデータを利用する—といった、従来本命と考えられていた方法に大きな進展は見られない。以上の研究状況を要約すると、現時点で将来は不透明である、ということになる。すなわち、少ない学習データで高い性能を達成可能な深層学習の方法がいつころまでに出来るかは、そもそも実現可能なのかも含めて

不明である。したがって今後しばらく、学習データの収集はボトルネックであり続けるし、遠い将来に渡ってもそうかもしれない。

一般変状の検出

われわれは、画像から橋梁の変状を自動検出する技術の研究開発を行っている。問題を、画素単位でクラス分類を行うセマンティックセグメンテーションとして定式化し、畳み込みニューラルネットワークの教師あり学習を適用している。一定量の学習データを収集し、これを用いて学習を行っている。国土交通省の橋梁定期点検要領に定めのある変状の種類のうち、画像のみで確実に判定できると期待できる数種類を対象にした結果の一例が図 2.1.2 である。検出精度は学習データ量に比例して向上することを実験で確かめており、データを増やす方策を取るとともに、いかに限られたデータで高い精度の検出を行えるかを旨として研究を行っている。

コンクリート表面のひび割れ検出

コンクリート表面に出来た微細なクラック（ひび割れ）を、その撮影画像から自動検出する技術には深層学習以前から期待があり、様々な研究がなされてきたが、実用化には結びついていなかった。理由を簡単に言えば、従来の画像認識の方法は、画像の局所的な情報を扱う（例えば細かく短い傷を検出する）ことはできても、大域的な情報を扱う（例えばそれらを長い構造を持つ微細なひび割れと区別する）ことが難しかったことによる。深層畳み込みネットはまさにこのような大域情報の扱いにおいて従来手法を凌駕することから、性能の大幅向上が期待できる。

実際、深層学習を使って、画像に写ったコンクリートの表面やアスファルト表面のひび割れを自動検出する試みが、様々な研究者によって発表されている。そのほとんどが、畳み込みネットを画像認識に適用する極めて標準的な方法が採用されており、それらの間に技術面違いはほとんどない。なお大抵の論文において、自前で作成したデータセット上で評価を行っており、公平な比較評価はほとんどなされていない。

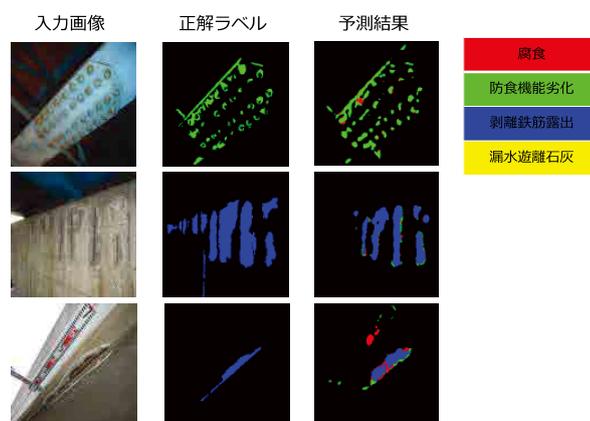


図 2.1.2 一般変状の検出例

さて、われわれも同様の方法の評価は以前から行っている。そこで明らかになったことは、ひび割れの検出には、上述したような一般的な変状の検出問題とは異なる性質のあることである。幅が1画素に満たない、かなり細かいひび割れは画像に映らない。画像に写っていない（＝情報がない）のであれば当然、検出は不可能である。問題は、どの細さから検出が可能でありどこから不可能となるか、その境界が定かでないことである。このことが、正解ラベルの付与を困難とし、また性能の評価を難しくしている。

これを例証するため、図 2.1.3 に画像とひび割れの検出例を示す。画像とそれに人手でつけたひび割れのラベル、およびわれわれの方法で推定した結果の例である。なお、手法は畳み込みネットワークを使ったものだが、ネットワークの構造と使い方にいくつかの工夫がある。同図(a)は、検出結果が人がつけた正解ラベルと一致した例であり、同図(b)は、検出結果が人によるラベルと食い違いが見られた例である。通常画像認識の方法と評価のやり方に従えば、(a)は正解、(b)は不正解ということになるが、現実には上述のようにそうは言い切れない。われわれはこの問題について研究開発を行ってきているが、現時点で成果公表前のため解決方法はここでは触れない。

画像修復・超解像

深層学習の用途は変状の検出などの画像認識だけでない。ここでは、画質の改善への適用を紹介する。ドローンで撮影した画像を変状検出に利用する上、画像の品質（画質）の高さは本質的に重要である。変状検出では、細かいクラックを対象とする場合など、画質と解像度が成否に直接影響するためである。しかしながら、ドローンを橋梁の周囲を飛行させながら撮影した画像には、一般に様々な画質の劣化が生じてしまう。具体的には、モーションブラー、センサのノイズ、降雨時の雨筋の映り込みなどである。

これら画質劣化要因の発生やその程度は、撮影条件、特に照明条件に大きく左右される。曇天下、あるいは橋梁下部に入り込んで撮影する場合には、最新の CMOS センサを搭載したカメラで

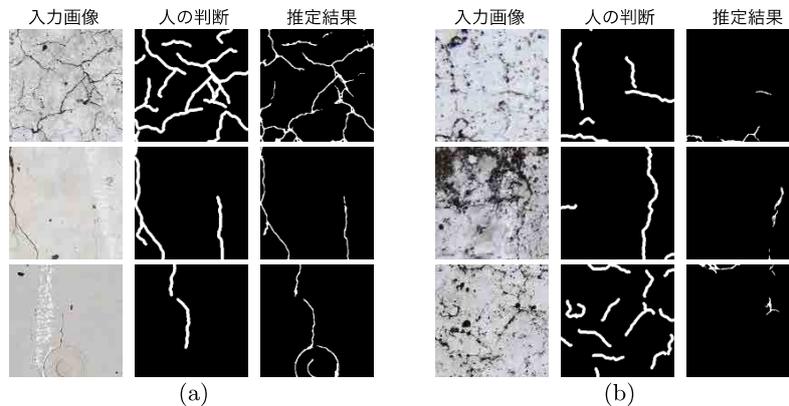


図 2.1.3 クラック検出の結果の例. (a)概ね正解、あるいは人の判断と一致する場合
(b)不正解、あるいは人の判断と一致しない場合

あっても、環境の光量は十分とは言えない。光量不足を補うためにシャッター速度を小さく（シャッターの開いている時間を長く）すると、ドローンの動きに応じたモーションブラーの発生が避けられなくなる。逆にシャッター速度を上げると、今度は十分な輝度が確保できず、輝度のゲイン上げると画像にノイズが発生する。また屋外で使用するため、少量の降雨時でもドローンを飛ばさざるを得ないだろう。その場合、画像に雨筋が映り込んでしまう。

このような画質劣化に対する対策が必要である。画質劣化要因を除去し、画像をきれいに「復元」する手法の研究が昔から盛んに行われている。近年、深層畳み込みネットを応用することにより、このような画像復元の性能は劇的に向上しつつある。また画質劣化の改善のみならず、積極的に画像の解像度を向上させる「超解像」の技術が、ほぼ同じ枠組みで研究され、良い成果を挙げつつある。そのような研究分野の状況にあって、われわれも画像復元技術の研究開発を行っている。そこでは主に、画像復元の精度をより高くするためのネットワーク構造、および学習方法を探求している。本稿執筆時未発表のを含むため詳細は省略するが、モーションブラー、超解像、ノイズ除去、雨筋の除去等の代表的な要因の解決において、世界最高水準の除去性能を達成している。図 2.1.4 にモーションブラーの補正の例を示す。図のように、石畳の詳細や、積み上げた石の間の隙間、ナンバープレートの数字、コンクリート表面の微細構造など、入力画像中ではモーションブラーによってほとんど判読不能だったものが、きちんと見えるまでに復元できていることが分かる。



図 2.1.4 単一画像からのモーションブラーの補正例. 左列から入力画像（ブラーあり）、モーションブラー補正画像、正解画像. 上2つはGoPro データセット、下は道路橋コンクリート表面の画像

球殻ワイヤの実時間除去

球殻ヘリでは、球殻内部にカメラを含むすべての構造物があるため、撮影された画像には必ず球殻を構成するワイヤや支持物が映り込む。これはオフラインでの点検の妨げになるほか、現場でFPVによる操縦を行う場合、一層問題になる。これらの問題を解決すべく、球殻のワイヤや支持物を画像から、実時間で除去する方法を開発した。

動くシーンを撮影したビデオを対象とするとき、いわゆる **video inpainting** の技術により、ビデオ画像から遮蔽物を除去することができる。画像内で、前景物と背景が独立に画像上で運動する場合、背景のある部分がある瞬間の画像内で前景物に遮蔽されていても、別の時刻の画像中ではあらわになる場合がある。そのような場合には、見えている時刻の画像の画素値を、遮蔽されている場合に転写することで、あたかも前景の遮蔽物がない場合の画像を合成することができる。この方法はある程度確立しているが、一般に処理に時間を要し（1枚あたり数分のオーダー）、実時間で画像を合成するのは全く不可能であった。

これに対し、深層畳み込みネットワークを用いてオプティカルフロー（シーンの各点の画像上での速度場）を推定し、しかもその時遮蔽物の背後のフローを補間して推定できるようにすることで、実時間での遮蔽物除去を可能にした。畳み込みネットワークは多層構造だが、順伝播の計算1度だけで推定が完了するためフロー推定自体は毎秒60～100フレーム程度の速度で実行でき、しかもその精度は十分高い。このため、従来の **video inpainting** のどの方法よりも高速に遮蔽物の除去が可能になり、毎秒30フレームというビデオレートでの処理ができるようになった（図2.1.5）。

なおこの方法は、除去したい前景物を指定する必要がある。そのため、ジョイント位置をビデオ画像上で検出し、これを球殻の設計形状と比較対照することで、ワイヤを画像上で特定し、そこから除去領域を推定している。現在、ジョイント位置の検出には、単純な画像特徴に基づくカスケード型の検出器を用いているが、検出精度と頑健さの向上を狙って、この部分も畳み込みネットワークで実行する方法を研究している。



図 2.1.5 ビデオ画像からの前景物体消去の事例. (a)Davis データセットでの性能評価. (b)球殻除去の例. いずれも上段が入力ビデオ画像列内の画像（消去対象物体は赤色のマスクで指定）、下段は上段の画像から前景物体を除去した結果

2.2 床版のAI 解析検討

2.2.1 背景

東京大学石田哲也教授が研究責任者を務める「道路インフラマネジメントサイクルの展開と国内外への実装を目指した統括的研究」の研究テーマの一つである、PC床版の余寿命評価は、図2.2.1に示すように、大別して2つのステップからなる。第一のステップは、床版を撮影した写真より当該床版のひび割れ図を作成すること、第二のステップは、マルチスケール解析に基づくコンピュータシミュレーションによるコンクリート床版の余寿命推定の結果（入力ひび割れ図、出力は、劣化の指標としてのたわみ量の変化量がある閾値を超えるまでの等価繰り返し走行回数）を近似する機械学習モデルを用いて、余寿命を評価することである。両ステップとも未確立な技術を用いるため、これらを構築することが本研究の目的となっている。

第二のステップに対し、コンピュータシミュレーションを用いて得る評価値の近似値を、機械学習を用いて高速に得る方法を構築する目的でのデータの分析手法について検討を行い、典型的な環境条件の下、実用的な精度、高速性、意味付与が可能な近似式を得た¹⁾。本稿では、コンクリート床版の写真から、余寿命評価を行うに必要な程度に正確なひび割れ図を自動作成する方法について行った検討経過を記す。

2.2.2 背景：コンクリート床版の余寿命評価

まず、マルチスケール解析を用いた余寿命評価について、その概要を説明する。

図2.2.1に示すように、コンクリートのマルチスケール物理モデル（結晶レベル、水和物レベル、粒子レベル、実験室レベル、構造物レベル）を作成し、それを有限要素法で数値的に解く。

実際には、RC床版に輪荷重（道路橋を自動車が行くときの力学的モデル）を加える条件下での、コンクリート内部の応力、ひび割れの時系列的変化を数値シミュレーションする。

その場合、初期条件として、ひび割れ図から推定される床版表面（実際の橋梁においては、床

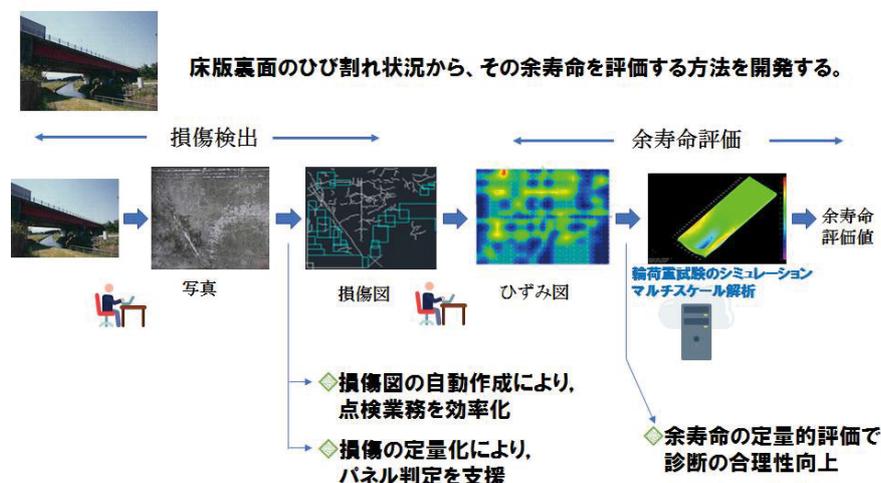


図 2.2.1 コンクリート床版の余寿命推定

版の下面になる) 上のひび割れ, 応力を用いる。これによって, 新規の床版の寿命を求めただけでなく, 使用途中の床版を観察し, その表面ひび割れから余寿命を推定することが可能になる。ただし, 初期応力として知りうるのは表面 (正確には表面を構成する小ブロックの集まり) 内の応力だけであり, 物理的に意味のある応力分布の推定は困難であるため, 単純にこの方法は適用できない。

そこで, 輪荷重走行試験機を用いた, 実際の実験での途中結果 (途中のひび割れ状況) をデータ同化の考えに従い, 数値シミュレーションの途中結果をこれに合わせるよう様々なパラメータを更新することにより, コンクリート床版内部の応力を推定しつつ, 床版の歪, そして床版中央の最大たわみの計算を正確にするパラメータを求めることができる。このパラメータを用いて, 床版の初期表面応力を入力とし, その余寿命を数値シミュレーションで求めることができるようになる。

本機械学習では, 実際に得られた表面ひび割れ図から求めた表面の応力分布を入力とし, 余寿命 (輪荷重回数で測る) を出力するモデルを作ることとする。

2.2.3 データの属性

作成すべきひび割れ図は, 余寿命評価という目的に照らせば, 従来作成されているひび割れ図ほど正確である必要はない。

まず, 横浜国立大学前川教授によると, 骨材の大きさから考えると, その最大径である 2cm より細かい解像度は必要ではないと考えられる。ひび割れは, こうした骨材を回避するよう (ほぼ骨材に沿って) 生成されるため, その部分は, ほぼランダムに位置を変えると考えられるからである。つまり, 床版余寿命の推測にあたっては, ひび割れ位置を 2cm より細かい精度で特定する必要はないということである。

そこで, 余寿命予測に用いるひび割れ図は, 床版写真を約 2cm 角の矩形に分割し, そこにひび

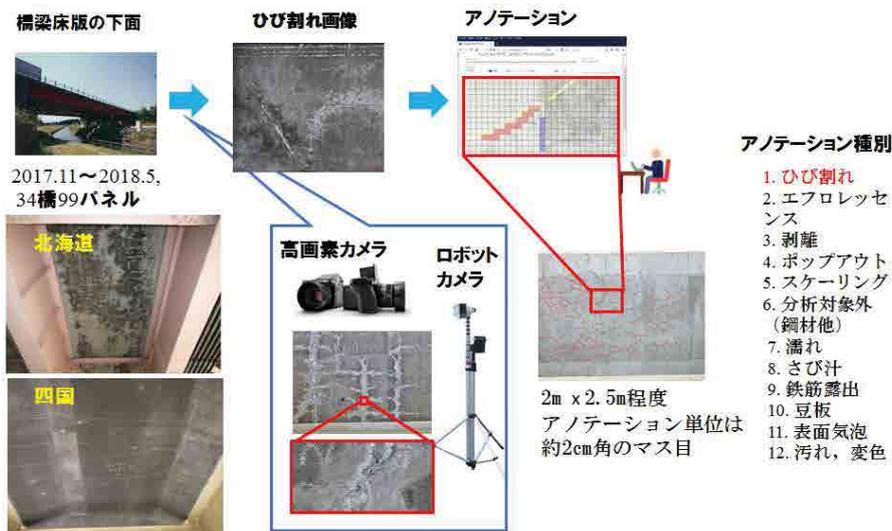


図 2.2.2 コンクリート床版へのアノテーション

割れが存在するか否か、存在する場合にはどの程度の大きさであるかを記述することとした。こうしたアノテーションを行うのは、当然ながら熟練者が行なう必要がある。また量が膨大である。

仮に2m x 3mを画角とする床版写真を撮影したとすると、2cm角のマスの個数は、15,000枚となる。こうした床版写真を、訓練データとして、機械学習を行うには、データの多様性を確保するため、環境条件や施工時期の異なる全国の橋梁について、得る必要がある。例えば、全国で20橋、各橋梁につき3パネルを抽出し、パネルごとに4枚の写真を撮影すると仮定すると、マスの総数は360万個となる。これにラベルを付すのは極めて大変な作業となる。またラベルの内、ひび割れの大きさを表すひび割れ幅を計測することを多数枚に渡って行うことは、精度の面から、非常に困難であると考えられる。一方、ひび割れの存在が分かり、それがある程度の範囲でひび割れと特定できるのであれば、その大きさを推定することは、従来の画像処理技術を組み合わせた方法で、精度よくできることは知られている²⁾。

また、今回の開発技術を床版劣化度判定のスクリーニングに用いることを目的とすると、ひび割れが相対的に大きいか否かが分かればよい。なぜなら、ひび割れの相対的に大きいものから順に、検査員の指示に従い提示し、その判断を仰げばよいからである。要求されればすべて提示することも可能である。その場合の課題は、ひび割れ幅の相対的な大きさ判断する能力を機械学習が獲得することになる。ひび割れ画像を収集して機械学習を適用すれば、ひび割れ幅が相対的に大きなひび割れを含むマス目は、ひび割れ幅が相対的に小さなひび割れを含むマス目より、よりひび割れらしく、つまり、ひび割れであると判断するのに必要な特徴量を強く、または多く含むことになると想像される。従って、この場合も、ひび割れ幅のアノテーションは必要ないことになる。

そこで、最初に、ひび割れ幅に関するアノテーションは行わず、約2cm角のマスのごと、その中にひび割れがあるかないかをアノテートすることとした。

なお、本稿に記す検討内容とは異なるが、他12種の変状についてもアノテートすることは計画している。

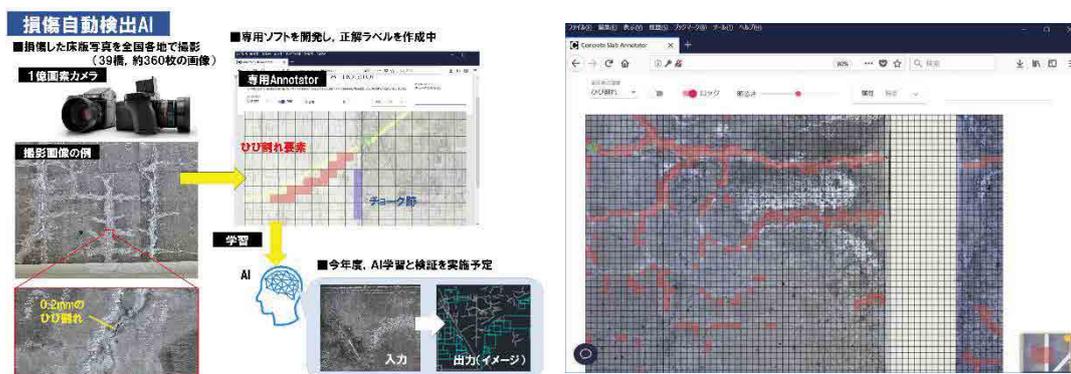


図 2.2.3 ひび割れ自動検出の枠組みとアノテーション支援ツール

2.2.4 アノテーション作業

アノテーション作業を行うツールの作成を行った。参考のために、簡単な説明を記す。本ツールは、web service として実装することとした。これは、ネットワークを必要とするが、アノテータの環境によらず使えること、データを配布する必要のないこと等のメリットがあるからである。画面例を図 2.2.3 に示す。アノテータは、画像を目的に応じて拡大・縮小できる。拡大し、視認上の問題がないと考えられる拡大率のとき、約 2cm 間隔の、縦横の罫線を表示する。罫線により区切られたマス目はマス目毎にクリックでき、クリックすると選択が反転する(トグル)。選択とは、ひび割れがあると判断するかないと判断するかを示す。なお、アノテータには画像の寸法がモニタ上の寸法に近い拡大率でアノテートするよう依頼している。

対象とするマス目が非常に多いため、しかし、近傍に連続することが多いことを考慮し、連続して選択することができるような機能もある。

他の変状についても同様である。

2.2.5 データの概要

北海道から九州まで 34 橋 94 パネルに対し、438 枚の写真がある。これらの写真は 1 枚約 1 億画素あり、ピクセル間隔は 0.15mm~0.25mm である。そのため 2cm 角のマス目は、一辺 80 ピクセル~130 ピクセルとなる。

アノテーションは、9 月現在、9 パネルについて、ひび割れの有無のアノテーションが付されている。

2.2.6 機械学習による実験 1

ひび割れの有無を判定する機械学習の試行を行った。北海道のある 1 橋 1 パネルの写真 3 枚を training データとし、同パネルの異なる 1 枚を validation とした(ただし、学習の繰り返し回数(エ



図 2.2.4 ひび割れのアノテーション実例
(Chubu-6-2 と Hokuriku-3-2)

ブロック数) は固定値としたため、validation set としては用いていない)。また test 用に同橋の別パネルの写真1枚を用いた。

ひび割れ有のマス目よりひび割れ無しのマス目が多いため、今回は、ほぼ同一となるよう、ひび割れなしのマス目はランダムにサンプリングした。その結果、訓練データとしては、ひび割れありが 2,659 枚、ひび割れなしが 2,664 枚、validation 用にはひび割れありが 738 枚、ひび割れ無しが 728 枚、test 用にはひび割れありが 375 枚、ひび割れ無しが 371 枚となった。

各マス目の大きさは、84 x 84 ピクセルとした。

機械学習手法としては、深層学習を用いた。特に、今回は実装が容易かつ標準的である、convolutional neural network を用いた。また構造は、vgg16³⁾と呼ばれるものを基礎とし、入力画素数を 84 x 84 とし、convolution 層はそのまま使用し (サイズは変わる。チャンネル数は同じ)、出力に近い fully connected 層は2層とし、活性化関数はシグモイド関数とした。convolution 層の学習開始時に用いる、結合荷重の初期値としては、de facto standard となっている、ImageNet で学習した結果を用い、学習は行わない固定とした。すなわち fully connected 層のみの学習とした。損失関数は2カテゴリのクロスエントロピー、学習方法はSGDとし、momentumを用いる加速を行った。過学習抑止には、標準の drop out を用いた。

バッチサイズは16、学習エポック数は40とした(固定)。

精度評価としては accuracy (両カテゴリを公平に扱い、正解サンプル数/総サンプル数である)を用いた。

2.2.7 実験1の結果

40 エポック時には、学習データ、validation データ、test データのいずれに対しても、accuracy は 70%前後となった。

必ずしもよい結果ではないので、誤り例を見てみる。以下では、ひび割れが表面に出たと思われるものをひび割れと呼ぶことにする。

図 2.2.5 は、ひび割れ無しという教師ラベルの 2cm 角のマス目に対して、ひび割れ有と推定した false positive の例である。ひび割れありとした確信度合 (各図の上に記載されている crack の値, 最大値 1) の大きいものから表示した。

(左上から右に向かって1より番号付けすると) 5 および床版の継ぎ目と思われる 2, 4, 8 を除いては、ひび割れと推定してもやむを得ない図となっている。

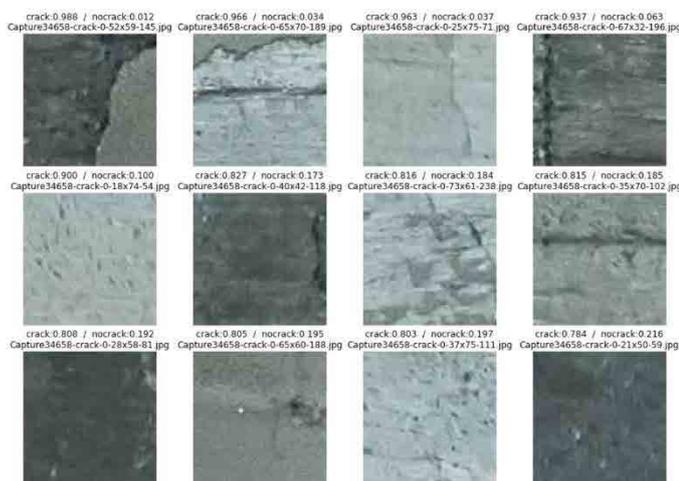


図 2.2.5 実験1で false positive となった画像の例

図は、ひび割れありという教師ラベルの2cm角のマス目に対して、ひび割れなしと推定した false negative の例である。ひび割れなしとした確信度合（各図の上に記載されている nocrack の値、最大値 1）の大きいものから表示した。（左上から右に向かって 1 より番号付けすると）5, 6 のようにひび割れらしきものが見えるものもあるが、多くはひび割れを見出すのが難しい。これはひび割れが細い場合や浅い場合、特に、（このマス目の外側である、その）上下や左右にひび割れが認められ、その間を埋めるものとしてひび割れありと推定して教師ラベルを付した可能性が考えられる。

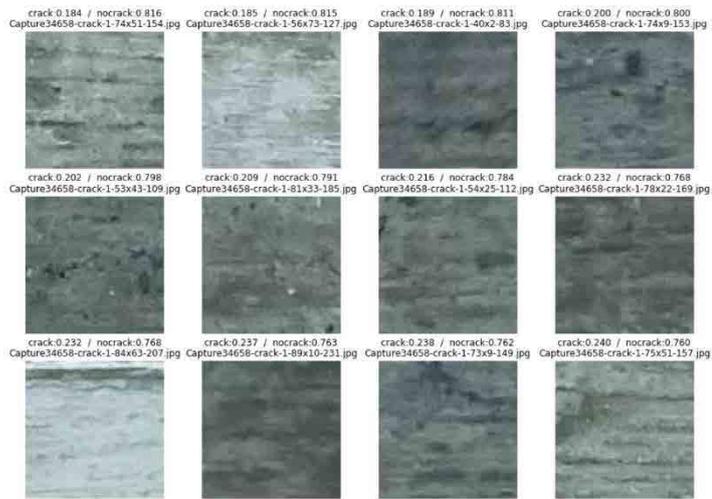


図 2.2.6 実験 1 で false negative となった画像の例

2.2.8 実験 1 の結果のまとめ

学習データとして約 5300 枚を用いた実験例であり、学習データは同じパネルから得たものであるため、結果の一般化はできないが、あえて言えば、ひび割れをよく認識しているように見える。ただ、教師データに不足している、床版の継ぎ目をひび割れと誤る例が目立つ。

今後さらに多様なデータを用いて学習させ、またテストには全く異なる環境にある橋梁の床版写真を用いることを試みる（今回は validation データや test データに関する accuracy の方が学習データに対する accuracy より高かったため、その事実だけからは、過学習を行わず、一般化が適切に行われていると言える）。

2.2.9 実験 2

実験 1 では、テストデータは、学習データと同じ橋梁だが、異なるパネル（桁で囲まれた一間をパネルと呼ぶことにする）の画像である。実験 2 では、より実的な汎化能力を調べるため、別橋梁の画像を validation データ・test データとして用いることにした。

実験時使用できたデータは、実質 8 橋のため、2 橋を 1 組として 4 組に分け、この 4 組に対して、cross-validation 的な実験を行うこととした。ある 3 組のデータを学習データとし、残り 1 組 2 橋のデータをテストデータとした。学習中に validation データは使用せず、固定かつ共通なエポック数（80 エポック）を学習時間とした。なお、各橋から（複数ある写真の内）1 枚写真を選ぶこととした。各写真を 84 ピクセル角（約 2cm 角）とする正方形の画像に分割した。ひび割れ有とする画像とほぼそれと同数のひび割れ無しの画像とを training データ・test データとした。各写真に、ひび割れ有の画像枚数が大きく異なる。そこでひび割れなしの画像数をひび割れ有の画像数

とほぼ同じになるようにした。表 2.2.1 には、その枚数が記してある。

学習器としては、Inception-ResNet V2⁴⁾ を用いた。深層学習のフレームワークとしては、TensorFlow/Keras を用いたので、そこに標準として含まれている InceptionResNetV2 を使用し、荷重の初期値として ImageNet で学習した値を用いた。初期値として用いたので、一般的には学習毎に異なった値となる。なお、InceptionResNetV2 では、荷重初期値として、学習済みの値を用いることは必須である。ランダムな初期値からは容易に、適切な値に収束することは困難である。

表 2.2.1 実験 2 で使用したデータと結果. 精度は、項番(1,2), (3,4), (5,6), (7,8) を組みとし、3 組を学習データとし、残り 1 組の各データをテストデータとした時の予測精度である

項番	地域	橋番号	パネル番号	画像枚数	ひび割れ有無予測精度
1	Hokkaido	3	1	999	0.77
2	Tohoku	4	3	4165	0.77
3	Hokuriku	1	3	480	0.67
4	Chubu	6	2	2329	0.69
5	Hokuriku	3	2	3276	0.78
6	Kinki	1	1	582	0.74
7	Sanyo	3	2	2069	0.72
8	Hokuriku	5	1	2782	0.70

2.2.10 実験 2 の結果と考察

表 2.2.1 に示す。精度のマクロ平均値（各写真に対応するデータの画像枚数は考慮しない平均値）は約 72% である。この値は、実験 1 で用いた vgg16 によるものよりはよいが、決してよい値とはいえない。

しかし、これは、学習方法が適していないことを意味するわけではない。むしろ、データそのもの、つまり、付されているラベルの精度が必ずしも高くないことが考えられる。その最大の原因は、写真上のひび割れという概念が well-defined ではないことが挙げられる。3 次元のコンクリート床版で物理的にひび割れが定義できたとしても、それと写真上での（正しく定義した）ひび割れとを正確に対応させるのは困難であると考えられる。また物理的に定義できたとしても、実際、（小さい、細い）ひび割れが、その幅や長さがどのくらいになれば、実務上考慮すべきひび割れと認めるべきなのかは難しく、意見が分かれている。

また橋によるばらつきが大きい。基本的には、劣化の程度・態様が橋の置かれた環境条件によって大きくばらつくことに原因があるが、写真撮影時の環境が統一できないことも原因の一つで

あると考えられる。

いずれにせよ、写真のみから判断した場合、どの程度の精度が期待できるかを、現状では困難と考えられるが、予め評価しておくことが必要であると考えられる。

参考文献

- 1) E. Fathalla, Y. Tanaka, K. Maekawa, and A. Sakurai, Quantitative Deterioration Assessment of Road Bridge Decks Based on Site Inspected Cracks, Applied Sciences, vol. 8, no. 7, 1197 (2018).
- 2) 小山 哲, 丸屋 剛, 堀口 賢一, 澤 健男, ガボールウェーブレット変換を用いたコンクリートのひび割れ画像解析技術の開発, 土木学会論文集 E2 (材料・コンクリート構造) 68 巻 3 号, 178-194 (2012).
- 3) K Simonyan and A Zisserman, Very Deep Convolutional Networks for Large-Scale Image Recognition, arXiv preprint arXiv:1409.1556 (2014).
- 4) C. Szegedy, S. Ioffe, and V. Vanhoucke, Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning, arXiv preprint arXiv:1602.07261v1 (2016).

2.3 インフラ予防保全のための大規模センサ情報統合に基づく路面・橋梁スクリーニング技術の研究開発と社会実装

2.3.1 研究概要

わが国では、これまで約9千キロの高速道路を整備し、一般道まで含めれば道路延長は約127万キロに及ぶ。道路の点検実施率は高まっているものの、点検周期が決まっていないため、予算上の制約から実質的に多くの道路が適切な点検が行われていない。舗装の調査は、高速道路や幹線道路においては高価な路面性状調査車により行われているものの、生活用道路などの一般道においてはその多くがパトロールによる目視点検にとどまっている。舗装の長寿命化に向けた効率的な修繕には点検が必要となるが、目視点検は比較的安価で頻繁に実施することが可能である一方、定量的・客観的な評価が難しい。また、高精度な計測が可能な路面性状調査車は高額な初期コストおよび、運用コストや手間が課題となり、頻繁に利用されるには至っておらず、適切な点検が行われていない状況である。

このような状況の中、広範な道路舗装の状況を安価で、かつ簡易的、定量的に把握する技術が注目されている。

そこで本研究では舗装の状況を把握する技術として、スマートフォン及び、市販の小型デジタルビデオカメラ（アクションカメラ）を利用することとした。アクションカメラは、小型で Full HD (1920*1080) が撮影できる SONY 製の AS300 を採用した。これらを使用し道路管理者が日々のパトロール業務の傍ら路面状況を計測し、取得した路面状況を基に舗装の修繕計画へ連携するシステムを開発した。路面状況の評価指標としては、乗り心地を表す指標である IRI (International Roughness Index) を基本とした。IRI は車両の1輪のみをモデル化した QC (クォーターカー) モデルを一定の速度で走行させたときに車両が受ける上下方向の運動変位の累積値と走行距離の比 (m/km または mm/m) で表れされる。そのため路面凹凸の少ないひび割れは IRI では表れにくい。一方、マンホールやジョイントが連続する箇所は IRI に影響するが早期な修繕は不要である。このようなことから、アクションカメラにより撮影した路面の動画から画像解析を用いて、ひび割れやマンホール、ジョイントなどの路面評価に影響をおよぼす路面変状を検出し、IRI と組み合わせた健全度評価手法の確立を目指した。

2.3.2 研究テーマの中での AI 活用

本研究では、道路管理者が日々のパトロールの傍ら路面撮影を行い、その動画ファイルより路面変状を検出することを想定している。そのため、路面変状は、安価で、かつ簡易的に操作可能な市販のアクションカメラを利用し、撮影した路面の動画より画像解析を用いて検出する AI 技術を利用することとした。路面変状は、IRI と組み合わせて舗装の修繕が必要か否かを判定することに着目し、IRI の乗り心地の指標に表れにくい変状や、IRI に影響するが早期な修繕が不要な変状を検出する。検出結果は、要因を分析し IRI を補足した健全度を評価するため、路面管理において一般的な評価基準として使用されているひび割れ率のような区間内に対する割合を算出す

るのではなく変状の大きさや個数を検出することとした。

(1) AI 手法の検討

近年、画像処理の様々な課題において、AI（ディープラーニング）による方法が効果的であることが広く検証されている。特に一般物体認識において、従来の方法を大きく上回る性能¹⁾を示し、近年注目が高まっている。画像認識にディープラーニングを使用する際には、畳み込みニューラルネットワークがよく用いられている。畳み込みニューラルネットワークは、画像の2次元的情報を考慮することで画像認識の精度を向上させている。このようなディープラーニングを用いた画像認識を路面画像へ適用し、路面のひび割れやポットホールの評価が行われている²⁾⁴⁾。本研究では、ディープラーニングによる方法を用いてひび割れ等の路面変状に加えてマンホールやジョイント等も検出することを目指して検討を行った。画像認識の手法として、画像の一部を切り出す処理を必要としない物体検出の方法を適用することとした。物体検出では、画像内の物体の位置とその種類を検出することができる。このような物体検出の手法には、FasterR-CNN, YOLO, SSD, YOLOv2 といった様々なものが開発されており⁵⁾、比較検討した結果、本研究では、精度と速度が優れているYOLOv2^{6),7)}を使用した。YOLOv2は、畳み込みニューラルネットワークを用いた物体検出アルゴリズムであり、画像全体をグリッド分割し、物体の領域とその種類の検出を同時に行うものである。このようなディープラーニングを用いて検出を行うためには、図 2.3.1 に示すように教師データを用意し、学習させる必要がある。

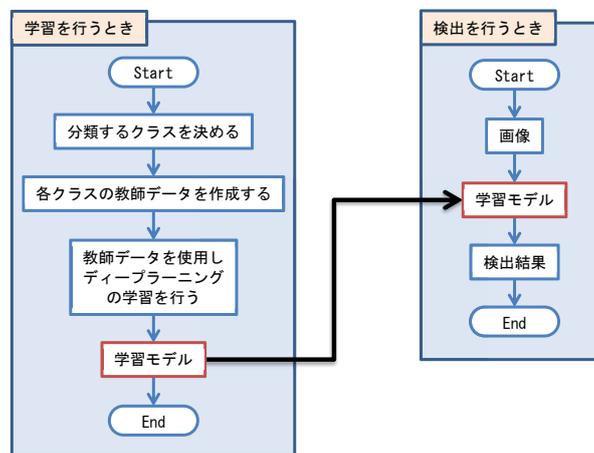


図 2.3.1 ディープラーニングを用いた学習と検出のフロー

(2) 教師データ作成

ディープラーニングによる物体検出を行うには、対象物の正解値となる画像と識別子となるラベルを組み合わせた教師データ（データセット）が必要となる。マンホールの例として図 2.3.2 に示す。教師データはディープラーニングの学習を行うことにより学習モデルが生成され、検出精

度を左右する重要なデータとなる。人や動物、果物など一般的な検出対象物の場合はインターネット上にデータセットが公開されているが、ひび割れやパッチングなど、特殊性をもった対象物を検出する場合、自ら教師データを作成し、学習モデルを生成する必要がある。

本研究では、任意の道路を不特定に撮影した動画ファイルを使用し、一定間隔で抜き出した静止画像から対象物をラベリングし教師データを作成した。検出する対象物として 10 種類の識別子を作成しクラス分けしたものを表 2.3.1 に示す。

また、ラベリングには LabelImg⁸⁾ツール(図 2.3.3)を使用した。本ツールは画像内の対象物を矩形で囲み対象物のラベルを付与することにより、ディープラーニングのデータセットとして一般的な Pascal VOC 形式のファイルを作成することが出来る。

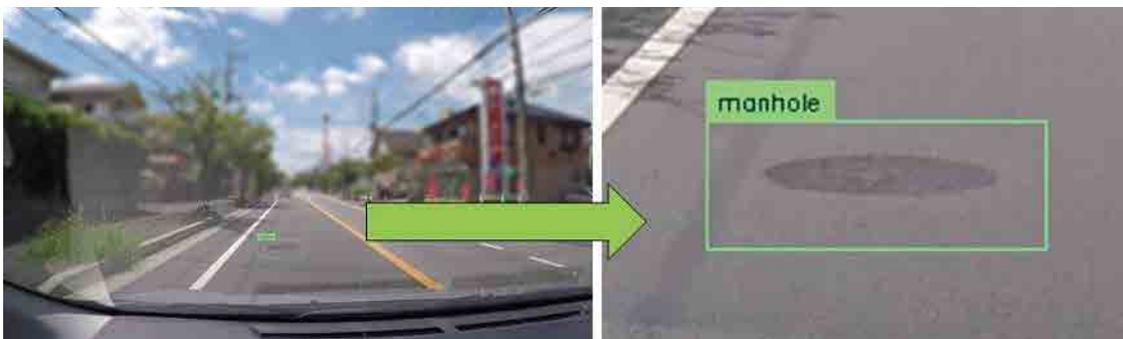


図 2.3.2 データセット

表 2.3.1 教師データクラス分け

検出対象物	ラベル名
線状ひび割れ	linear crack
線状ひび割れ補修跡	linear crack_p
亀甲状ひび割れ	alligator crack
亀甲状ひび割れ補修跡	alligator crack_p
ジョイント	joint
マンホール	manhole
パッチング	patch
短い白線	white line
長い白線	long white_line
グレーチング	grating



図 2.3.3 LabelImg

(3) 路面変状検出

路面変状検出には、車載カメラにより路面を撮影した動画を使用した。動画から一定間隔で抜き出した静止画から、学習済みモデルを使用したディープラーニングの処理を行い、変状等を検出した。結果として、図 2.3.4 に示すように変状の種類と位置、大きさが矩形情報として得られる。

任意の道路を撮影した 169 本の動画ファイルから約 27000 枚の教師データを作成した。作成した教師データ数を表 2.3.2 に示す。この教師データを用いて学習を行い、学習済みモデルを作成した。検出結果の評価指標として、検出率（＝正解を検出した数/正解数）と的中率（＝正解を検出した数/検出数）を求めた。検出率と的中率を求めるときには、教師データとは別に 207 枚のテスト用データを用意した。これは、教師データを用いて結果の評価を行うと未知のデータに対する評価ができないためである。テスト用データは、各クラスのデータ数が同程度になるように画像を選出した。あらかじめ人間が目視で正解を決めておき、ディープラーニングの結果が正解を正しく検出できているかを集計し、検出率と的中率を求めた。得られた検出率と的中率を表 2.3.3 に示す。



図 2.3.4 検出結果例

表 2.3.2 教師データ数

No.	クラス名	データ数
1	線状ひび割れ	8572
2	亀甲状ひび割れ補修跡	93
3	亀甲状ひび割れ	2536
4	線状ひび割れ補修跡	1439
5	ジョイント	1016
6	マンホール	3140
7	パッチング	5639
8	短い白線	2566
9	長い白線	764
10	グレーチング	1602
	合計	27367

表 2.3.3 検出率と的中率

	検出率	的中率
線状ひび割れ	80%	58%
マンホール	97%	100%
ジョイント	97%	100%
亀甲状ひび割れ	96%	75%
パッチング	58%	67%

表 2.3.3 に示した結果では、マンホールやジョイントのような路面と対象物体の区別がはっきりしているものは、高い精度で検出できた。これらは、誤検出低減用のクラス（「短い白線」等）を作成した効果もあり、高い的中率となった。しかし、線状ひび割れは図 2.3.5 のようなパッチング、電線の影および、フロントガラスへのダッシュボード映り込みなど誤って検出される中率が低くなった。一方パッチングは図 2.3.6 のように補修から期間が経過しパッチング跡が薄くなっている箇所の検出漏れや、線状ひび割れとして誤って検出したケースがあり検出率が低くなって

いる。線状ひび割れ、パッチングは同じような形状をしており、お互いの誤検出により精度低下につながった。



図 2.3.5 線状ひび割れの誤検出の例



図 2.3.6 パッチングの検出漏れの例

(4) 結論と課題

ディープラーニングを使用した物体検出の学習を行うための教師データ作成について、様々な方法を試行錯誤し技術として蓄積した。車載カメラで路面を撮影した画像から、物体検出の手法により、ひび割れ等の変状と同時にマンホールやジョイント等も検出することが可能となった。また、変状の大きさについても検出物の範囲が矩形情報として検出できた。

線状ひび割れとパッチングについては、検出漏れ、誤検出を減少させて精度を向上させる必要がある。教師データの作成方法やカメラの性能および画像の解像度により、精度への影響が大きい要因を明確にし、合わせて教師データの母数、品質を上げることで精度向上を図る。また、検出した位置、矩形情報から奥行きを考慮し変状の大きさを明確にする。

(5) 今後の展開

舗装点検要領⁹⁾では、道路管理者が舗装の管理基準を設定してよいと記載されているものの、補足として大型交通車両の交通量が多い幹線道路においては、ひび割れ率、わだち掘れ量、IRIの3指標を使用することを基本とすると明記されている。今後は、画像解析の対象物を広げわだちの検出を検討する。また、対象物全体の検出精度を高めることにより信頼性の向上を図る。検出したひび割れやわだちなどの大きさや個数による路面状況とIRIを組み合わせた健全度評価手法を確立する。

参考文献

- 1) Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton: ImageNet Classification with Deep Convolutional Neural Networks., Advances in neural information processing systems, pp.1097-1105, 2012.
- 2) 全邦釘, 井後敦史, 南免羅裕治, 黒木航汰, 大窪和明: 車載カメラにより撮影された舗装画像からのディープラーニングによるひび割れ率評価, 土木学会論文集 E1 (舗装工学), Vol.73, No.3, pp.I_97-I_105, 2017.
- 3) 丸山記美雄, 大浦正樹, 木村孝司: 深層学習によるポットホール判別技術に関する基礎的検討, 第 61 回 (平成 29 年度) 北海道開発技術研究発表会, 2017.
- 4) Hiroya Maeda, Yoshihide Sekimoto, Toshikazu Seto, Takehiro Kashiya, Hiroshi Omata: Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone., arXiv:1801.09454, 2018.
- 5) Li Liu, Wanli Ouyang, Xiaogang Wang, Paul Fieguth, Jie Chen, Xinwang Liu, Matti Pietikäinen: Deep Learning for Generic Object Detection: A Survey, arXiv:1809.02165, 2018.
- 6) Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi: You Only Look Once: Unified, Real-Time Object Detection., The IEEE Conference on Computer Vision and Pattern Recognition, pp.779-788, 2016.
- 7) Joseph Redmon, Ali Farhadi: YOLO9000: Better, Faster, Stronger., The IEEE Conference on Computer Vision and Pattern Recognition, pp.6517-6525, 2017.
- 8) Github:<<https://github.com/tzutalin/labelImg>>
- 9) 国土交通省道路局: 舗装点検要領, 2016.< http://www.mlit.go.jp/road/ir/ir-council/pdf/yobo28_10.pdf>

2.4 高温超電導 SQUID 磁気センサを用いた鋼床版き裂検査技術

研究の概要

近年，都市部高速道路や大型の橋梁で使用されている鋼床版に発生する疲労き裂が，道路保全上の大きな問題となっている。鋼床版は，鋼板（デッキプレート）を縦リブ，横リブで補強した構造をもち，鋼板の上面は通常，直接アスファルトで舗装されているが，長期間に亘る車両の通行荷重負荷により，裏面の溶接線に沿って疲労き裂が発生する¹⁾。疲労き裂は溶接部に留まることもあるが，鋼板方向に進展すると，最終的に鋼板の上面まで貫通する。貫通き裂が生じると舗装面の陥没など通行上の障害に繋がる可能性があるため，早期にき裂を検知し，適切な補修を行うことが必要になっている。

超音波探傷法を用い鋼床版の裏面から疲労き裂を検知する技術が開発され実用化されている²⁾，鋼床版全体の検査を行うための時間とコストが大きな負担となっている。一方，電磁検査手法である渦流探傷法を用い，アスファルト舗装の上から長さ 100mm 程度以上の貫通き裂を検知する技術も開発され³⁾，スクリーニング検査に用いられているが，より小さなき裂の検出や検査速度の向上など検査性能向上への期待は大きい。

厚さ 60-80mm あるアスファルト舗装の上からの電磁検査では，欠陥から発生する磁気信号自体が小さく，センサとの距離が離れるため，検出される磁気信号が著しく小さくなるという問題がある。超電導センシング技術研究組合（SUSTERA）では，舗装の上からの疲労き裂検査の高性能化を目的に，超高感度の磁気センサである高温超電導 SQUID（Superconducting Quantum Interference Device: 超電導量子干渉素子）を利用した渦流探傷システムを開発した。SQUID 磁気センサは，図 2.4.1 に示すように，フラックスゲート等の汎用磁気センサと比べ桁違いに高いフムトテスラ（fT = 10^{-15} T）レベルの感度をもつ。酸化物高温超電導材料を用いた高温超電導 SQUID (HTS-SQUID) は極低温の液体ヘリウムによる冷却が必要な金属系超電導材料を用いた SQUID (LTS-SQUID) に比べ，感度は 1 桁程度劣るが，取扱が容易で安価な液体窒素による冷却で使えるため，屋外フィールドでの使用に適している。渦流探傷法の深さ方向の測定限界を示す一つの指標として $\delta = 1/\sqrt{\pi f \mu \sigma}$ (f は印加交流磁場の周波数， μ は透磁率， σ は導電率) で与えられる渦電流の導電体への侵入深さ（表皮深さ）がある。鋼床版に用いられる鋼材（例えば SM490A）の比透磁率は 150 程度と大きく，非磁性材料に比べ表皮深さは浅くなるが，SQUID は直流から高周波まで感度が一定という他の磁気センサにはない特長をもつため，周波数を下げることで，鋼材の表面だけではなく，内部や

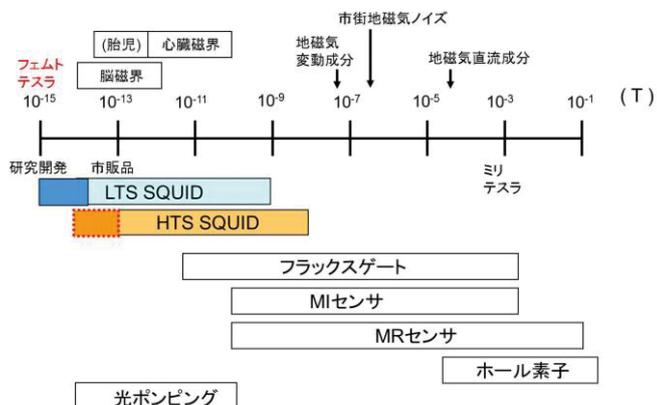


図 2.4.1 各種磁気センサの感度比較

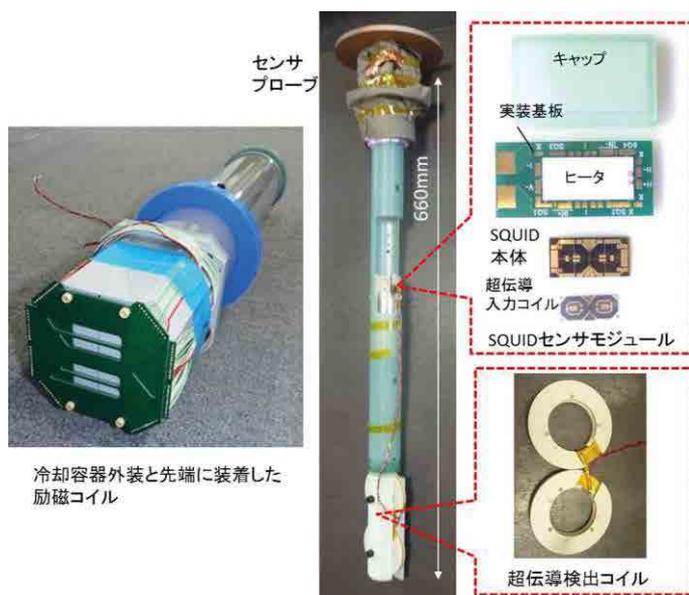


図 2.4.2 SQUID を用いた磁気センサ部

は、プローブの中間部に配置した SQUID センサモジュール⁵⁾で計測される。検出コイルとセンサモジュールの超電導入力コイルは銅線で接続され、入力コイルと SQUID 本体は磁氣的に結合されている。ジョセフソン接合を含む SQUID 本体は SUSTERA の保有する高温超電導薄膜積層技術を用い製作している⁶⁾。SQUID センサモジュール自体は、高温超電導バルク材料と高透磁率金属材料からなるカプセルで 2 重に磁気シールドが施されている。このように、SQUID センサ本体を磁気シールドし、試験対象である鋼板から離して配置することにより、環境磁気雑音や鋼板の磁化によるセンサの不安定動作を防ぐことができる。センサプローブのフランジから下の部分をプラスチック外装で保護したガラスデュワに挿入し、プローブ下から 2/3 程度の部分まで液体窒素で冷却する。ガラスデュワの周りに適切な電磁シールドを施すことで、電磁雑音の多いフィールドでも安定動作が可能である。冷却容器（クライオスタット）の先端には、遠方に同一方向の磁場を印加できる電流ダイポール型の励磁コイルを装着している。電流ダイポールの方向は検出コイル面と垂直になるように調整し、励磁磁場が検出コイルに直接鎖交しないようにしている。

開発した磁気センサ部を、図 2.4.3 に示すように、レール上を移動可能な木製ステージに固定した室内実験システムを構築し、模擬欠陥を導入した鋼板試験体を用いた検証実験を行った。ステージ上には、励磁コイル電源、SQUID 駆動回路（FLL 回路）、ロックインアンプ、データロガーなどの電源、計測機器が搭載されて

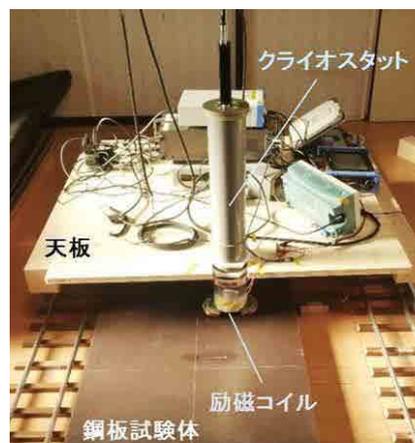


図 2.4.3 室内実験システム

裏面の欠陥を検出することも期待できる。

図 2.4.2 には、鋼床版検査用に開発した磁気センサ部⁴⁾の写真を示す。センサプローブの先端には、高温超電導テープ線材を巻いた磁場検出コイルが配置されている。検出コイルとしては、デッキプレートに平行な磁場成分の垂直方向の偏差 (dB_x/dz) を計測する微分型のコイルを採用しており、デッキプレートのき裂を渦電流が回り込むことによる磁場の乱れを検出する。検出コイルに流れた電流の大きさ

いる。使用した試験体は、長さ 1 m、幅 0.7 m、厚さ 6 mm の鋼板 (SM490A) に長さ 50-200 mm のスリットホール (幅 0.3 mm) を導入したものである。レールによる移動方向 (x 軸とする) に沿って測定を行うが、鋼板位置を横 (y 軸) 方向に 30 mm ずつシフトし測定を繰り返すことで 2 次元データを取得した。図 2.4.4 には、長さ 200 mm (x 軸方向) のスリット欠陥を電流ダイポールの方向を変えて測定した例を示す。励磁コイルと鋼板の距離 (リフトオフ) は 75 mm で励磁周波数は 20 Hz とした。台車の移動速度は約 50 mm/s である。図 2.4.4(a) は、電流ダイポールと移動方向 (x 軸) の角度 α が 90° で測定した I_m 成分の等磁束線図である。等磁束線の間隔は $0.1 \phi_0$ (ϕ_0 は磁束量子 $\approx 2.07 \times 10^{-15}$ Wb) で、正の最大値が赤、負の最大値が青になるように表示している。欠陥の両端部に四重極のパターンが検出され、信号ピークは欠陥上ではなく両横上に並んでいる。また、図の両端には、試験体端部に起因する大きな信号が見られる。 α が 0° の場合にも、同様に欠陥両端には四重極パターンが観測されるが、それぞれのピークの極性は反転する。一方、図 2.4.4(b) は α が 45° の場合の等磁束線図 (間隔は同じく $0.1 \phi_0$) であるが、欠陥直上に大きな信号ピークが現れており、この条件が欠陥検出により適していると考えられる。さらに、試験体端部の信号のようなある閾値を超える信号をカットし、また緩やかな変化の信号をカットするハイパス処理等の画像処理を施した結果を図 2.4.4(c) に示すが、欠陥をより明瞭に識別できることがわかる。

図 2.4.5 には、リフトオフを 50, 75, 100 mm と変えて、励磁周波数 20 Hz、 α が 45° の条件で測定して得られたスリット欠陥上の信号ピーク強度の欠陥長依存性を示す。同じリフトオフの条件では、欠陥の長さに比例してピーク強

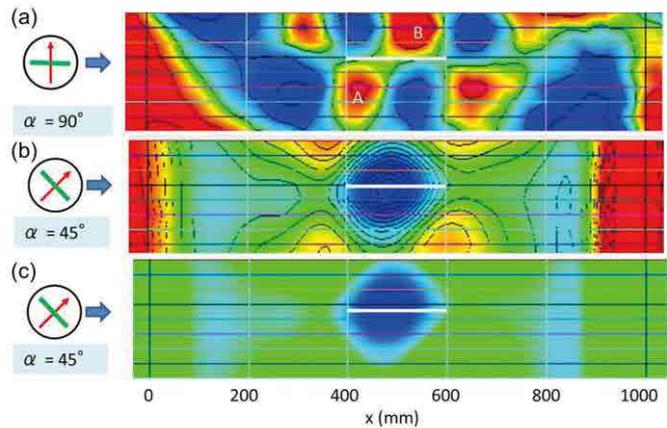


図 2.4.4 鋼板試験体中の 200 mm 長欠陥の測定結果、
(a), (b) は等磁束線図, (c) は画像処理後
センサ部を表す左の丸印の中の赤矢印は電流ダイポールの方向、緑線はセンサの検出コイル面を示す

移動速度は約 50 mm/s である。図 2.4.4(a) は、電流ダイポールと移動方向 (x 軸) の角度 α が 90° で測定した I_m 成分の等磁束線図である。等磁束線の間隔は $0.1 \phi_0$ (ϕ_0 は磁束量子 $\approx 2.07 \times 10^{-15}$ Wb) で、正の最大値が赤、負の最大値が青になるように表示している。欠陥の両端部に四重極のパターンが検出され、信号ピークは欠陥上ではなく両横上に並んでいる。また、図の両端には、試験体端部に起因する大きな信号が見られる。 α が 0° の場合にも、同様に欠陥両端には四重極パターンが観測されるが、それぞれのピークの極性は反転する。一方、図 2.4.4(b) は α が 45° の場合の等磁束線図 (間隔は同じく $0.1 \phi_0$) であるが、欠陥直上に大きな信号ピークが現れており、この条件が欠陥検出により適していると考えられる。さらに、試験体端部の信号のようなある閾値を超える信号をカットし、また緩やかな

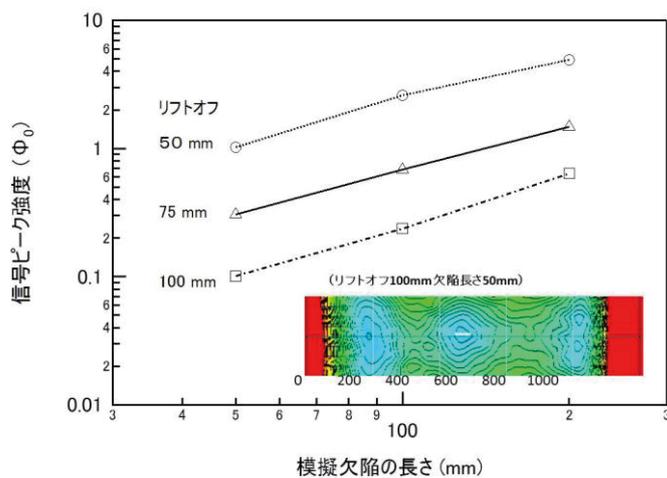


図 2.4.5 スリット欠陥上の信号ピーク強度の欠陥長依存性
(挿入図は 50 mm 長欠陥に対する等磁束線図)

度が増大しており、信号強度から欠陥長さの推定ができる可能性がある。図中には、リフトオフ 100 mm の条件で測定した長さ 50 mm のスリット欠陥に対応する等磁束線図を示すが、欠陥が明瞭に検出できていることがわかる。図 2.4.6 には、リフトオフ 75 mm で測定した長さ 50 mm の欠陥直上を通る走査での磁気信号波形プロファイルの励磁周波数依存性を示す。励磁周波数の上昇に伴い信号強度は増大するが、鋼板の磁気特性のゆらぎに起因すると思われるベースラインの変動が現れ始め、S/N 比としては劣化している可能性がある。しかしながら、50 mm 長欠陥からの信号は 640 Hz でも明瞭に検出されている。励磁周波数を上げると、ロックインアンプの時定数を短くでき短時間でデータ取得ができるため、走行速度を上げることができる。実際、励磁周波数 640 Hz、時定数 20 ms の条件では室内実験システムの限界である 50 cm/s (2 km/h) の走行条件でも信号プロファイルがほとんど変わらないことを確認した。原理的には、20 km/h 程度の走行速度での測定も可能と考えられる。

図 2.4.7 には、施工技術総合研究所において疲労試験機を用いて作製された、溶接部に発生した貫通き裂を測定した等磁束線図を示す。試験体は、厚さ 12 mm の鋼板の裏面に U リブを模擬した厚さ 5 mm の鋼板を片側溶接し、上から繰り返し荷重を加えて作製したものである。貫通き裂は 560 mm と長いため、単一ピークではなく両端から内部に大きなピークが 2 つ現れているが、スリット欠陥と同様に疲労き裂も検出できることが示された。図 2.4.8 には、非貫通のスリット欠陥を含む模擬試験体で観測された Re 成分の等磁束線図を示す。励磁周波数 20 Hz、リフトオフ 50

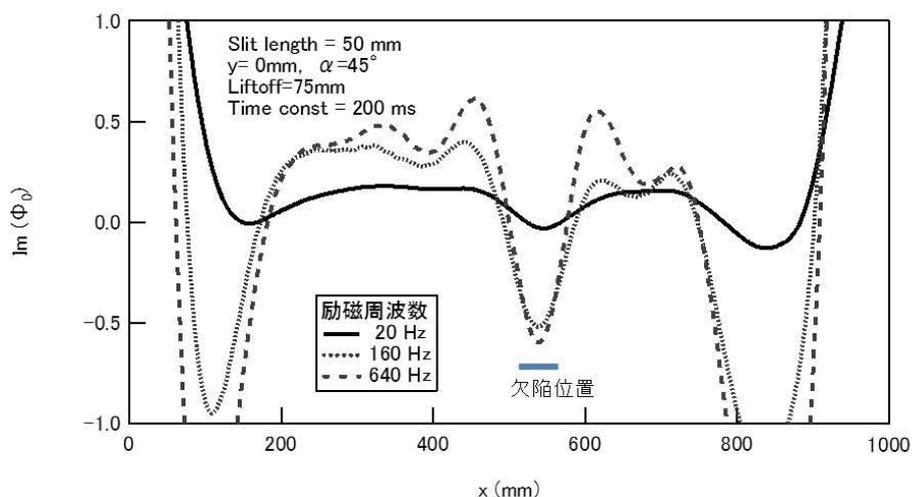


図 2.4.6 50 mm 長欠陥による信号プロファイルの励磁周波数依存性

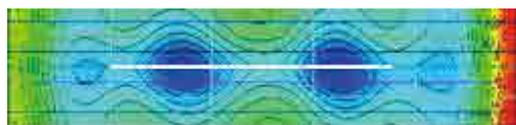


図 2.4.7 疲労き裂 (長さ 560mm) を含む試験体を測定して得られた Im 成分の等磁束線図 ($\alpha=45^\circ$)

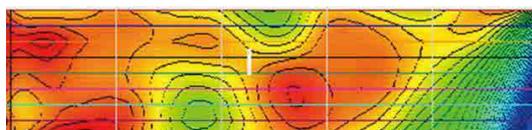


図 2.4.8 非貫通スリット欠陥 (50 mm 長、残板厚 2 mm) を測定して得られた Re 成分の等磁束線図 ($\alpha=0^\circ$)

mm, α が 0° の条件で長さ 50 mm, 残板厚 2 mm の非貫通欠陥の両端に四重極パターンが観測されている。これは、非貫通欠陥の検出可能性を示す結果ではあるが、より系統的な検証が必要である。表 2.4.1 には、室内検証実験から得られた 1 チャンネル (ch) の SQUID 磁気センサ部を用いた検査装置の性能と、次に述べるセンサ 3 ch のプロトタイプ機の予測到達性能をまとめる。

表 2.4.1 検査装置の予測到達性能

装置	SUSTERAプロトタイプ機	SUSTERA試験機(現状)
原理	渦流探傷(ECT,SQUID)	渦流探傷(ECT,SQUID)
検査方向	舗装上面側	舗装上面側
センサch数	3 ch	1 ch
駆動方法	手押し	手押し
検査速度	>50 cm/s(貫通き裂) 20 cm/s(非貫通き裂)	20 cm/s(スリット状欠陥、 3回走査)
検出性能	長さ5 cm以上の貫通き裂 (及び非貫通き裂)	長さ 2-5cm以上の貫通スリット状 欠陥(非貫通は一部)*
検出幅	~ 270 mm	~90 mm

*疲労き裂の検出可能性は確認済み (図 2.4.7)

室内実験システムでは、センサが 1 ch のため、2次元検査データを得るためには、繰り返し走行しての計測を行う必要があった。実際の道路上検査では、一度の走行で検査できる幅を広げて、検査時間の短縮を図る必要がある。検査幅を広げる方法としてセンサを並列に多数並べればよいが、コストとの兼ね合いから、図 2.4.9 に示すような 3 ch のセンサを手押し台車に搭載した路上試験用のプロトタイプ検査装置を開発した⁷⁾。台車の大きさはワンボックスカーで運搬可能な長さ 1.6 m, 幅 0.8 m で、3つのセンサ部を横方向間隔 93 mm で斜めにずらして配置している。これにより U リブの一溶接線に沿った約 270 mm 幅の領域の検査が可能である。ロックインアンプや AD コンバータなどの計測機器類は PC と共に測定系ボックスに納められている。励磁コイルの周波数等のパラメータやロックインアンプのパラメータは 3 ch 独立して調整できるようにしており、実際に各チャンネル間の相互干渉を防ぐため、励磁周波数は少しずつずらして設定している。車輪に接続したエンコーダによる位置情報も含めた検査データは、無線 LAN に



図 2.4.9 開発した路上試験用 3 ch プロトタイプ検査装置

よりタブレット PC に送られ、操縦者以外の人が監視可能になっている。

図 2.4.10(a)に示すような長さ 2 m、幅 1 m、厚さ 3 mm の模擬鋼板試験体の計測を行った結果を (b)及び (c)に示す。

図 2.4.10(b)は、ch 2 のセンサが 2 つ並んだ 100 mm 長のスリット欠陥の直上を走査した場合の、各 ch の I_m 信号成分のプロファイルである。100 mm 長欠陥の信号は ch 2 だけでなく、ch 1 及び ch 3 にも現れているが、ch 2 の信号強度が最大になっている。また、ch 3 及び ch 2 には 50 mm 長欠陥からの信号も明瞭に捉えられている。図 2.4.10(c)は、 $x = 1.5$ m 付近の欠陥信号のない場所で各 ch の信号レベルを調整

し得られた 2 次元マッピングイメージであるが、ch 2 直下の位置にある 100 mm 長欠陥からの信号が明瞭に識別できる。

開発したプロトタイプ試験装置は、施工技術総合研究所のテストコースを利用した長距離走行試験において、少なくとも数 100 m の距離走行で安定してデータ所得ができることを確認している。今後、実際の高速道路上でのフィールドテストで装置性能を実証し、社会実装に繋げる予定である。上に示したように、模擬鋼板試験体のスリット状欠陥や疲労き裂は比較的明瞭に識別できたが、実際の鋼床版検査では、溶接部の磁性的揺らぎや、鋼床版同士あるいは橋桁との接続部など他の構造物に起因する磁気信号が重畳されると考えられる。このような複雑な磁気信号パターンからき裂を識別する方法として AI の活用への期待は大きい。その取り組みの一例を

5.3 SUSTERA 高感度磁気検査の AI 活用を示す。

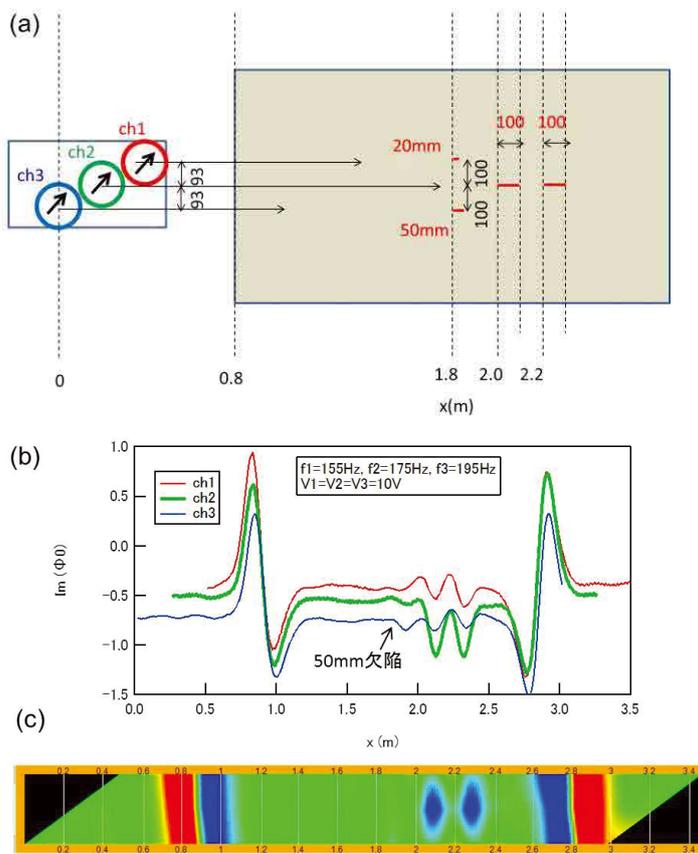


図 2.4.10 (a)使用した鋼板試験体, (b)各 ch の測定信号プロファイル, (c)2 次元マッピングイメージ

参考文献

- 1) 鋼床版の疲労〈2010年改訂版〉(鋼構造シリーズ) 土木学会
- 2) 関東地方整備局 鋼床版疲労き裂の検知手法の検証について
http://www.ktr.mlit.go.jp/ktr_content/content/000624166.pdf
- 3) 角 和夫, "舗装の下に隠れた金属のき裂を早期発見 ~赤外線と電磁誘導と超音波の力で~, 月間建設 17 (2017) 68.
- 4) A. Tsukamoto, T. Hato, S. Adachi, Y. Oshikubo, W. Cheng, K. Enpuku, K. Tsukada, and K. Tanabe, "Eddy Current Testing System Using HTS-SQUID with External Pickup Coil Made of HTS Wire", IEEE Trans. Appl. Supercond. 27 (2017) 1600505.
- 5) A. Tsukamoto, S. Adachi, Y. Oshikubo, K. Tanabe and K. Enpuku, "Development of a HTS SQUID module for use with an external pickup coil", Supercond. Sci. Technol. 26, 015013 (2013).
- 6) S. Adachi, A. Tsukamoto, T. Hato, J. Kawano, K. Tanabe, "Recent Developments of High-Tc Electronic Devices with Multilayer Structures and Ramp-Edge Josephson Junctions", IEICE Trans. Electron. E95-C (2012) 337.
- 7) A. Tsukamoto, T. Hato, S. Adachi, Y. Oshikubo, K. Tsukada, and K. Tanabe, "Development of eddy current testing system using HTS-SQUID on a hand cart for detection of fatigue cracks of steel plate used in expressways", IEEE Trans. Appl. Supercond. 28 (2018) 1601505.

3. 音響・時系列データを用いた研究開発チームにおける関連研究

3.1 学習型打音解析技術の研究開発

3.1.1 研究の概要

本研究開発は、点検員の技術に左右されず正確に変状の検出が可能な打音検査技術の開発を目的とし、さらにその技術を実現するシステムとして、現場で使用する打音装置と検査結果を現場で変状推定マップとして表示できるタブレット表示装置の開発も目的とする。この目的達成のために SIP 事業では、3つの実施項目（1）打音解析手法の開発（2）打音装置および打音解析システムの開発（3）打音データセット構築と性能評価、で研究開発を行った。

打音解析においては機械学習を用いた打音解析手法の開発を行い、2段階の学習的手法で変状を推定するアプローチをとることにした。1段階目では、取得した大部分の打音は正常であるという仮定のもと、検査対象ごとに正常パターンを統計的に学習させる（教師無し学習）。これにより、さまざまな種類の打音データが集まらなくとも欠陥の有無を判断することができる。二段階目では、一段目の判定結果に熟練者による教師ラベルをつけて蓄積した結果をもとに判別学習を行う（教師有り学習）。これにより欠陥検出の精度を向上できるようになる。教師なし学習手法においては、4種類の手法で比較・評価実験を行い、教師あり学習手法においては、教師ラベルの準備、打音特徴表現の探索、判別学習方式の各要素技術の研究とそれらの統合を行った。

システム開発では、2種類の打音装置と、そこで取得した打音を上述した解析手法によって異常検知するシステムをそれぞれ開発した。一つは、点検ハンマによる打音の違いを機械学習し、構造物の異常箇所と異常の度合いを自動検知する「AI 打検システム」である（図 3.1.1）。検知結果を点検員にリアルタイムで提示し、レーザー光による測域センサで人手によるハンマの打撃位置を簡便に取得し、打音解析結果と統合することで異常度マップを自動的に作成する。もう一つは、アスファルト舗装面の上からコンクリート床版上層部の土砂化を検知するための、台車型打音装置とその解析システムである。台車型打音装置は、3か所のハンマ打撃部があり、検査員が台車を手押しすることで、それぞれの打撃力が平均 15kN 以上を得られる。

AI 打検システムの性能評価では、打音採取実験とその正常異常の正解ラベルをつけたデータセット構築、およびそれを用いた性能評価試験を行った。試験では、人力による詳細な叩き点検を実施し内部欠陥（浮き）が確認された7つの実橋等に対して、AI 打検システムによる点検を実施し、その結果の比較を行った。大まかなブロック単位ですべての場所で欠陥の見落としが無く、また打音1音ごとの正答率は、最高で93.2%、平均で84.0%という良好な結果を得た。AI 打検システムを用いた点検作業フローを検討し、現地作業での実測値を用いて比較した結果、従来手法より1～2割程度の時間増加となったが、本システムでは検査結果が点検員の技量に依存せずコンター図が得られる、等のメリットが得られる。

台車型打音装置の性能評価では、実橋で事前に打音採取を行い、その後アスファルト舗装面の除去が行われる際に、熟練者による打撃検査で舗装面全面の変状図を入手し、それを正常異常の

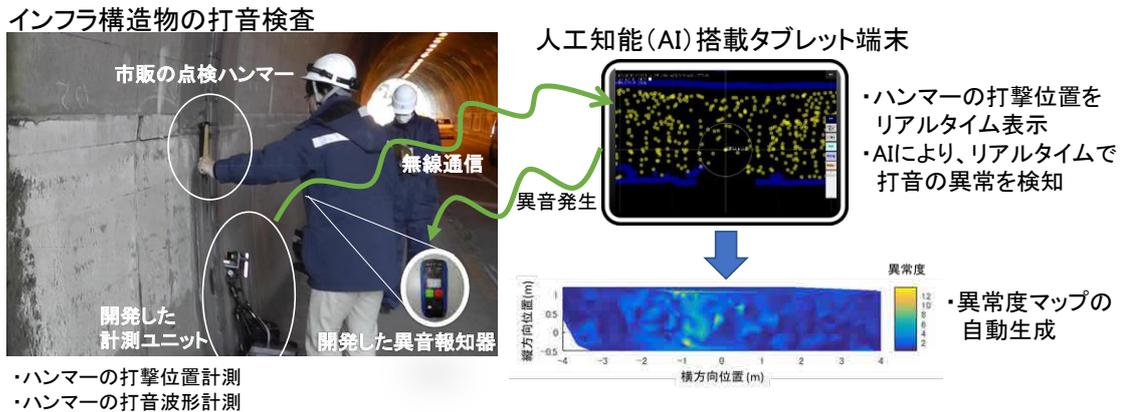


図 3.1.1 人工知能により打音検査をアシストする「AI 打検システム」

正解としてデータセットを構築した。このデータセットを用いて最終的な異常検出性能を正答率で評価したところ、H橋 82.1%、I橋 80.2%、K橋 93.0%の性能が得られた。台車型打音装置を使った打音調査と従来の人力打音調査の施工時間について現地作業で確認した結果、30m×3mの範囲の調査で205分が65分に短縮され140分の大幅な削減効果が得られた。

3.1.2 研究テーマの中でのAIの活用

一般的な打音検査において、検査員は検査ハンマーを用いてコンクリート構造物を打撃し、その打撃音を聞いて、その構造物の状態を判断している。これは、検査員の経験や感覚に依存することになり、検査員によってその検査結果にバラツキやミスが生じる可能性がある。一方、インパクトエコー法は、1980年代に提案され、コンクリート構造物の非破壊検査手法として多く使われてきた¹⁾。一般的な定義として、インパクトエコー法ではハンマー等による打撃がコンクリート構造物の表面に加えられる。その後、打撃点付近に設置されたセンサによって、打撃によって引き起こされ構造物内を伝播してきた衝撃波を計測する。その計測された信号をフーリエ変換によって周波数領域において調査することで、コンクリートの状態が評価される。打音のスペクトルの卓越周波数のみがコンクリート状態評価の指標（特徴量）として使われることが一般的であった²⁾。

しかしながら、単一の特徴量のみを使うだけでは、ノイズの影響を受けやすいという、その他の特徴を捨ててしまっていることになる。そこで本研究では、AIにおける機械学習技術で打音の解析を行うアプローチで、より正確な欠陥検出を目指した。具体的には図 3.1.2 に示すようなステップで解析を行う。

このように機械学習技術を打音解析に適用しようとした場合、一番大きな課題としては、学習対象となる打音データが十分に集まらない点にある。これは、機械学習に基づき正常と欠陥を区別しようとした場合、事前に正解がわかっている正常と欠陥の打音データを多数集めて、それらの統計的性質から識別器を学習させることになる（教師有り学習）。しかしながら欠陥のデータは

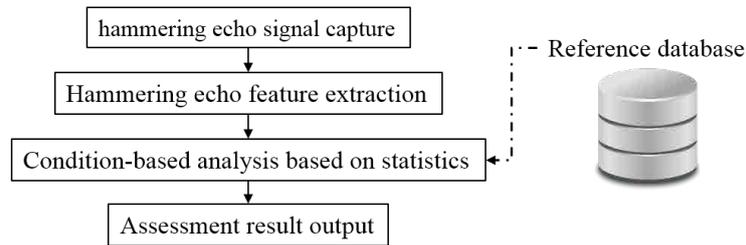


図 3.1.2 機械学習に基づく打音解析フロー

正常データと比較すると一般的になかなか数が集まらない。特にコンクリート構造物の材質の違いや、打撃ハンマの種類の違いなどを考慮すると、すべての組み合わせを網羅的に収集するには工数がかかる。そのため、データが集まるまで学習ができない、もしくは、データが集まらなかった欠陥の種類については、誤って正常と判定してしまうという問題点が生じる。

そこで我々の解析手法においては、2段階の学習的手法で変状を推定するアプローチをとった。1段階目では、取得した大部分の打音は正常であるという仮定のもと、検査対象ごとに正常パターンを統計的に学習させる（教師無し学習）。学習した正常パターンから逸脱したものを欠陥の疑いありと検出する。これにより、さまざまな種類の打音データが集まらなくとも、まずは欠陥の有無を判断することができ、対象物の種類によらない汎用的な手法となる。二段階目では、一段目の判定結果に熟練者による教師ラベルをつけて蓄積し、蓄積した結果をもとに判別学習を行う（教師有り学習）。これにより欠陥検出の精度を向上できるようになる。

(1) 教師なし学習手法

本研究で開発した4種類の教師なし学習方法を以下に列挙する：

- 1) 特徴量空間内の距離に基づく異常検出
- 2) 部分空間法に基づく異常検出
- 3) Bag-of-echoes モデルによる異常検出
- 4) スペクトラルクラスタリングに基づく異常検出

いずれの手法においても共通した仮定は、計測した大多数の打音サンプルが正常であり、異常箇所に対する打音サンプルは、正常なサンプルとは異なり特徴量空間で正常パターンからは離れた場所に散らばっているとしている。その離れた度合いを異常度として定量化すれば、欠陥箇所を検出できるという考え方である。

各手法の概要のみ説明し、比較検討・実験の結果から、各手法の得失を述べる。1)は、最も基本的な手法であり、すべての打音サンプル間での特徴量空間内での距離を算出する。各打音サンプルごとに、他の打音サンプルへの距離の和を異常度として算出する。この異常度が一定の閾値を超えたものを欠陥の疑いありとする。この手法の弱点は、打音のノイズに大きく影響をうける

点にある。打音を採取する環境は交通量が多い場所もあり、特にトンネルの内部など環境雑音の影響で性能が大きく低下してしまう。

2)は、大部分の正常パターンを部分空間によって低い次元数で表現し、判定したい打音サンプルのこの部分空間への距離を異常度として算出する。より低い次元数での表現により、ノイズ、測定誤差などの外乱に頑健になる。部分空間を用いた教師なし学習方法は主成分分析を用いるが詳細は³⁾などを参照されたい。部分空間法は、他の非線形手法と比べて計算量が少ないという利点もある。

上述した^{1),2)}の手法は、正常パターンが一つのクラスタ（特徴量空間内での塊り）で表現できることを想定しているが、実構造物での打音検査においては、正常パターンが複数クラスタであることもある。そこで、複数の打音パターンのクラスタで正常パターンを表現する“Bag-of-echoes”モデルを開発した³⁾。この手法では、計測した打音パターンを特徴量空間上でGMM（混合ガウス分布⁴⁾）に基づく教師なし学習手法でクラスタリングし、その結果得られた複数のクラスタの中心点で打音パターンを代表させる。これにより打音パターンの分布をコンパクトに表現することができ、ノイズ等に頑健になる。

またこの手法による大きな利点は、学習結果の可読性である。つまり、各クラスタの代表点の打音を検査員に提示することで、実際の欠陥の有無や種類などとの対応を確認する作業量を低減できる。計測した打音すべてを検査員が確認することは現実的に難しいが、この手法で得られるクラスタの数は、打音全サンプル数に比べると大幅に小さな数に減らせるので、検査員によって確認すべき数が現実的な数となる。この確認作業で得られる正解ラベルと打音をデータベースに保存することで、2段目の教師有り学習ステージで活用できるようになる⁵⁾。

2)の手法で用いた次元削減手法は部分空間法に基づいていたが、特徴量空間内の局所性（接続性）を考慮して次元圧縮することでより正常パターンが複数クラスタある場合や特徴量に大きなノイズが重畳されている場合などに性能を向上できる可能性がある。これを行うのが、スペクトルクラスタリングと呼ばれる手法であり⁶⁾、この手法を応用した。比較実験の結果、この手法が4つの手法のうち最もきれいなコンター図を生成することができたが、データサンプル数が多くなったときに、計算量が多くなるという欠点がある。

(2) 教師あり学習手法

図3.1.3に検討した教師有り学習手法における解析手順ごとの要素技術を示す。

それぞれの手法の詳細については割愛するので、図中に示した参考文献を参照されたい。ここで重要なのは、機械学習においては手順3および4の手法に関心が集まることが多いが、手順1および2も工数がかかり、その後の性能を決める重要な工程であることを強調しておく。また、手順3の打音の特徴表現方式については、深層ニューラルネットワークを用いた特徴表現学習などさらなる深化を目指した関連研究も別途行っている¹²⁾。

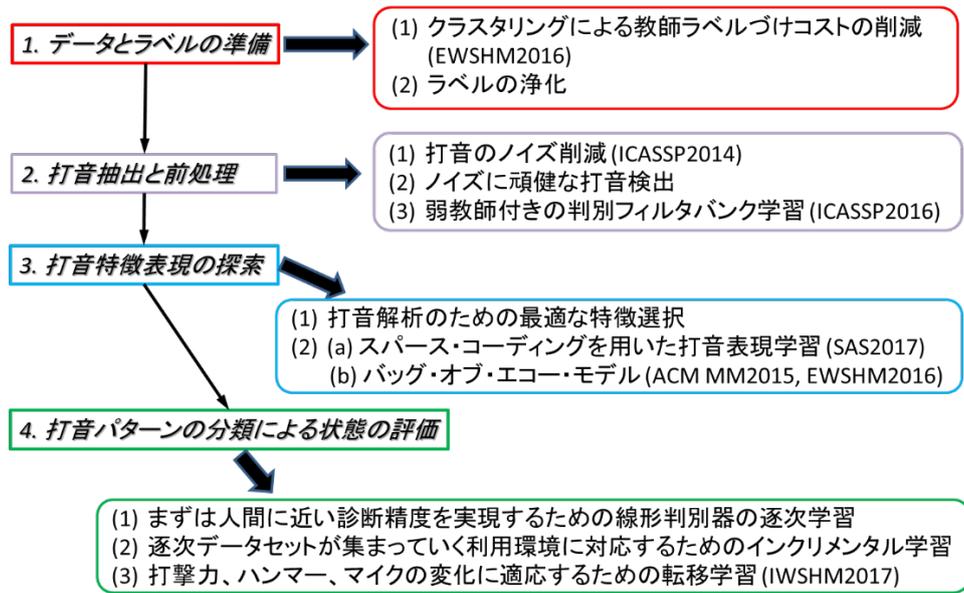


図 3.1.3 検討した教師あり学習手法における解析手順ごとの要素技術^{5),7)-10)}

(3) 実構造物での性能評価

実構造物（9橋）を対象とした AI 打検システムの評価実験を行った。AI 打検システムの評価実験は、人力による詳細な叩き点検を実施し内部欠陥（浮き）が確認された構造物に対して、AI 打検システムによる点検を実施し、その結果の比較を行った。「正確度」の算出方法として、まずおおまかなブロック（異常箇所の一連の打撃）単位で見落としがないかどうかをまず確認した。その結果、すべての結果で見落としがないことを確認した。さらに打音 1 音 1 音で、正常箇所を正しく正常と判定し、異常箇所を正しく異常と判定した割合（合致率）を算出した。教師なし学習を用いて解析を行い得られた異常度マップの例として、評価実施箇所 No.4 の結果を、図 3.1.4 の右側に示す。異常度マップでは、黄色が異常度の高い打音、青色が健全な打音の部分を示す。左側の写真には、人力による詳細な叩き点検を行った範囲（黄枠内）と変状が認められた範囲（赤枠内）を示している。この写真と異常度マップを比較すると、変状範囲が大体一致していることが分かる。

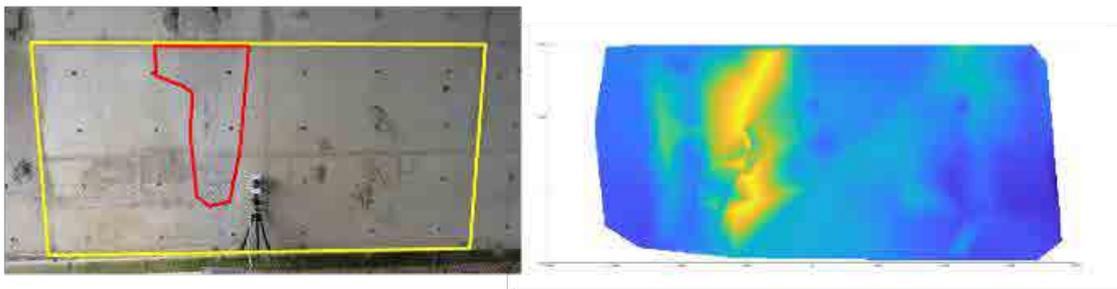


図 3.1.4 評価実施箇所 No.4 で得られた異常度マップ

教師なし学習における各評価実施場所での合致率を表 3.1.1 の上段にまとめる。最高で 93.2%、平均で 84.0%という良好な結果が得られた。この結果より、教師なし学習は実構造物での打音検査に適用可能な打音解析能力を持つと言える。なお、評価実施箇所 No.3 と No.6 は、合致率算出の対象から除外しているが以下の理由による。実施箇所 No.3 では、検査領域の大部分が変状領域であったため、教師なし学習手法の前提条件を満たしておらず正しく変状打音を検出できなかった。評価実施箇所 No.6 は変状領域が認められない箇所で、95.8%の合致率を得られたが、例外的な計測対象とした。

表 3.1.1 教師なし・あり学習の合致率比較

場所No.	1	2	3	4	5	6	7	8	9
教師なし学習	93.18	73.94	-	80.67	83.87	(95.8)	82.61	86.08	87.90
教師あり学習	89.39	76.97	(73.23)	81.21	87.43	(100)	80.43	83.03	85.31

次にこれらの7橋で得られた教師ラベルを用いて教師あり学習を行った。一般的に教師あり学習のほうが、機械学習にとって有益な情報を与えられているため性能が高くなるが、十分に教師データが集まっていない段階では性能は得られたデータの状況に依る。実験結果を表 3.1.1 下段に示す。教師あり学習の教師データとテストデータの作成には、データ数が少ない場合によく用いられる方法である"Leave one out"の一種として"Leave one bridge out"（学習では、評価対象の1橋以外のすべての橋のデータを使用し、評価では学習に用いなかった1橋でテスト）を用いた。この結果、7橋というバリエーションが少ない場合でも、平均で 83.4%という教師なし学習と同等の打音解析性能を得た。さらに、教師なし学習では原理的に対応が難しかった実施箇所 No.3 (大部分が変状領域)においても、教師あり学習を用いることによって対応できるようになり、73.2%の合致率を得られた。

教師なし・あり学習の合致率比較を行うと、教師あり学習により、合致率が上がる場合と下がる場合があることが分かる。合致率が下がる原因として、評価対象の構造物と似た教師データが少なすぎて、教師データが有効に働かなかったことが考えられる。つまり、過去に似たデータが集まっていない打音を持つ構造物では、教師なし学習のほうが有効に働き、似た打音データが集まった構造物では、教師あり学習のほうが有効と考えられる。この比較に関しては、さらに教師データ数を増やした検証が必要であるが、この研究開発で最初に設定した2段階で機械学習を行う戦略は、教師なし学習手法に基づき効率的に教師データを蓄積しながら教師あり学習手法の検討を行うことができ、研究開発の立ち上げ期には妥当であったことが示せた。

3.1.3 今後重要となる機械学習技術

上述した実験結果から教師あり学習では十分なデータが集まれば教師なし学習の性能を上回ることが示唆されており、その段階では前段での教師なし学習手法の使用は不要となる可能性もある。ただし、最初に述べたように対象構造物の違い、ハンマの違い、センサの違いなど、すべての組み合わせを網羅してデータ取得するのは難しい。そこで重要となる技術が、転移学習と呼ばれる技術である。過去の別の環境で得られた学習結果を転用して、新しい環境で大量の教師データを取得しなくとも、わずかなデータで認識できるように学習を効率化することを目的とする。すでに文献10)において、供試体を用いた欠陥検出実験において転移学習の有効性を示しており、教師データ取得のコスト低減のカギとなる技術と考えている。

また機械学習技術は、データに基づく統計的な手法であることから、一定の認識誤りが存在することは避けられない。この誤りを作業者に訂正してもらい、使いながら精度を向上させていくような、人と協調するAI技術も重要となる。その際には、どのように作業者に提示し追加学習するかインタフェース・インタラクション技術や、どのような基準で機械学習が判断したかを、作業者に説明できるような機械学習結果の可視化技術も必要となる。

参考文献

- 1) M.J. Sansalone and W.B. Streett, "Impact-echo: Nondestructive Evaluation for Concrete and Masonry", Bullbire Press, 1997.
- 2) ASTM D 4580-03, "Standard Practice for Measuring Delaminations in Concrete Bridge Decks by Sounding", ASTM International, 2003.
- 3) H. Hassani, "Singular spectrum analysis: methodology and comparison", Journal of Data Science, Vol.5, No.2, pp. 239-257, 2007.
- 4) C. M. Bishop, "Pattern Recognition and Machine Learning", Springer, 2006.
- 5) J. Ye, M. Iwata, and M. Murakawa, "Statistical impact-echo test using Bag-of-feature model for concrete condition assessment", Proc. 8th European Workshop on Structural Health Monitoring (EWSHM2016), 2016.
- 6) A.Y. Ng, M.I. Jordan, and Y. Weiss, "On spectral clustering: Analysis and an algorithm", Advances in neural information processing systems, pp. 849-856, 2001.
- 7) J. Ye, T. Kobayashi, M. Murakawa, and T. Higuchi, "Robust Acoustic Feature Extraction for Sound Classification based on Noise Reduction", Proc. 39th International Conference on Acoustics, Speech, and Signal Processing (ICASSP2014), 2014.
- 8) T. Kobayashi and J. Ye, "Discriminatively Learned Filter Bank for Acoustic Features", Proc. 41st International Conference on Acoustics, Speech, and Signal Processing (ICASSP2016), 2016.
- 9) J. Ye, T. Kobayashi, M. Iwata, and M. Murakawa, "Noise Robust Hammering Echo Analysis for Concrete Structure Assessment under Mismatch Conditions: A Sparse Coding Approach", Proc. 2017 IEEE Sensors Applications Symposium (SAS 2017), 2017.

- 10) J. Ye, T. Kobayashi, H. Tsuda, and M. Murakawa, "Robust hammering echo analysis for concrete assessment with transfer learning", Proc. International Workshop on Structural Health Monitoring (IWSHM2017), 2017.
- 11) J. Ye, T. Kobayashi, M. Iwata, H. Tsuda, and M. Murakawa, "Computerized Hammer Sounding Interpretation for Concrete Assessment with Online Machine Learning", Sensors, Vol. 18, No. 3, 833, 2018.
- 12) T. Hasegawa, J. Ogata, M. Murakawa, and T. Ogawa, "Tandem Connectionist Anomaly Detection: Use of Faulty Vibration Signals in Feature Representation Learning", Proc. 2018 IEEE International Conference on Prognostics and Health Management, 2018.

3.2 レーザー打音高速検査システムの開発

3.2.1 はじめに

高度経済成長期に建設された数多くのトンネルや橋梁などのコンクリートを使用した社会インフラは高経年化が進んでいる。道路トンネル点検要領によってトンネルなどのインフラの保守保全作業は、検査員の近接目視確認による手作業（触診・打音・叩き落とし）に委ねられている。特に国内の道路および鉄道トンネルの状態確認は、全て人手に頼る状況が続いている。SIP「インフラ維持管理・更新・マネジメント技術」では将来的に保守保全作業の間隔を短くすることや安全確認作業の自動化に関して、高速・非接触・遠隔操作が可能な新しい検査技術の開発を精力的に進めている。その中で、従来の打音法と同様の検査をレーザーを用いて遠隔で行うことが可能と期待されるレーザー打音法の研究開発を実施している。これまでに西日本旅客鉄道株式会社、公益財団法人鉄道総合技術研究所、公益財団法人レーザー技術総合研究所によりレーザーを用いたトンネル覆工コンクリート欠陥検査手法の原理実証及び現場での検証試験が行われており、その有用性が示されてきた¹⁾。レーザー打音法では、パルスレーザーをトンネル内壁に照射することでコンクリートを振動させ、その振動を別のレーザーによって分析することにより、コンクリート内部の欠陥を検出する^{2),3)}。我々はレーザー打音法の実用化に向けた研究開発の1つとして、高強度パルスレーザーの繰り返し性能とコンクリート表面の振動の計測速度を向上させることでレーザー打音検査の高速化に取り組んできた。



図 3.2.1 「レーザー打音」概念図

ハンマーで叩いて耳で聞く打音法をレーザーを用いて同様の検査を行う

3.2.2 レーザー打音法の高速化

一般的にレーザーは、「遠方までまっすぐ進むこと」、「波長（色）が決まっていること」、「レンズを用いて小さい点に集光できること」や「干渉を起こす」というような波の形が揃っているという特徴を持っている。このような特徴を用いて、従来はハンマーでコンクリートを叩き、検査員の耳で音（振動）を聞いていた打音法をレーザーによって置き換える手法の開発を行っている。ハイパワーパルスレーザーである「振動励起用レーザー」は、打音検査におけるハンマーに相当し、遠隔でコンクリートに強い衝撃を与える。パルスレーザーをコンクリート表面に集光し、表面にエネルギーを吸収させる。その際、

表面から僅かに吹き出すアブレーション（蒸散）を発生させ、その反動による衝撃波によりコンクリートを振動させる。発生したアブレーションの反作用によりコンクリートが振動し、コンクリートの内部に欠陥がある場合には、打音検査の場合と同様に、その振動に変化が生じる。一方、連続発振レーザーを用いた「振動計測システム」は打音検査における耳に相当するレーザー干渉計を構成し、コンクリート表面の微細な振動を遠隔・非接触で検出する。振動しているコンクリート表面から反射してくる信号光の周波数は、ドップラー効果により変調するため、変調していない規準の光と干渉させることで、表面の振動を時間的な周波数変化に変換し計測することが可能である。2種類のレーザーを用いることで、打音検査における「打撃」と「音の検知」を遠隔・非接触で行うレーザー打音法の概念図を図 3.2.1 に示す。また、検査面を高速に走査させるためのガルバノミラーの導入やレーザー干渉計測技術の高速化というハード面の改善を行うと同時に、干渉信号波形の取得、解析、欠陥判定アルゴリズムによる高速欠陥判定システムを開発しソフトウェア面でも向上を図り、それらを組み合わせた高速レーザー振動計測システムを構築した。一般に人間の耳に聞こえるのと同程度の周波数領域（5 Hz～20 kHz まで）の振動をレーザー技術により検出することで打音法における人の耳と同じ役割を持たせることができる。

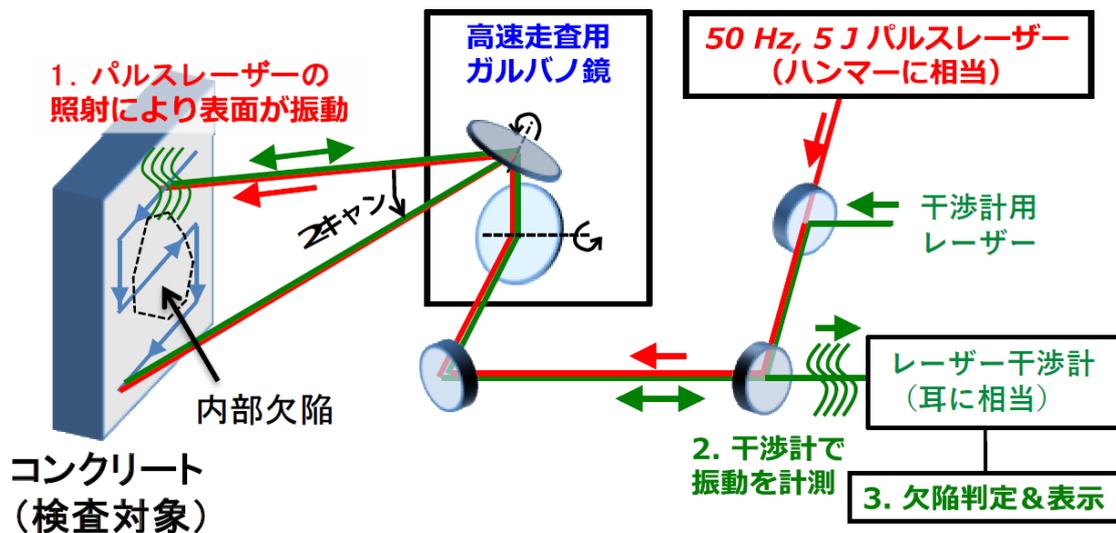


図 3.2.2 高速レーザー打音システム模式図

ハンマー等を用いてコンクリート表面を振動させる打音検査と同程度に、レーザーを用いてコンクリート表面を叩くアブレーションを起こすには、パルスあたり 1 J 以上の出力エネルギー、マイクロ秒以下の短パルス性、5 m 以上離れた位置での集光性能が振動励起用レーザー装置に必要とされる。同様に 5m 以上離れたトンネル内壁からの反射光を確実に検出するためには、振動計測システムで用いられるレーザーも数 W 程度の出力を持つことが理想と考えられる。レーザー打音法における検査速度は、この「振動励起用レーザー」、

動計測システム」に加えて、「高速走査装置（スキャナー）」の動作速度によって決定される。振動励起用レーザーと振動計測用レーザーは、ミラーを用いて同じ光路上に結合される。結合された2つのレーザー光は、電磁石に流す電流値により角度を高速かつ精密に制御することが可能なガルバノミラーによって検査対象の高速スキャンを実施する。1秒間におけるレーザーパルス数（繰り返し周波数）を増加させることで、検査速度の高速化が可能となるが、高速走査装置の動作速度やレーザー振動計測に用いる周波数領域等を踏まえると、おおよそ1秒間に100回程度（レーザー繰り返し周波数100 Hz程度）までが理想となる。図3.2.2に高速レーザー打音システムの模式図を示す。

3.2.3 レーザー打音高速検査システム

これまでの研究開発において、高繰り返し・高出力の振動励起パルスレーザー⁴⁾とコンクリート表面の高速検査を組み合わせることで、模擬的な欠陥が埋め込まれたコンクリート供試体を対象とした検査速度の高速欠陥検知技術（最大50Hz）の基礎技術開発を実験室内外で行った⁵⁾⁷⁾。このレーザー打音高速検査システムを屋外模擬トンネルでの実証試験を実施するために改造し、レーザー打音高速検査システムの移動車両の搭載と屋外トンネル構造物環境下でのレーザー打音高速検査による欠陥検知の実証試験を実施した。図3.2.3(a)は、模擬トンネルとそこに設置したレーザー打音高速装置搭載車両である。レーザー装置等の電源は別途発電機を用いて供給した。移動車両への搭載ため、振動励起用レーザー⁸⁾、レーザー振動計測システム、高速走査ユニットの3つの装置を共に、屋外でも計測可能な防塵・防振対策を施した筐体内に搭載した。図3.2.3(b)は、開発したレーザー打音高速検査システムを車載した状態であり、発電機以外の装置を4tトラックに搭載している。模擬トンネル内に設置された打音検査用の大型コンクリート供試体を対象とした検査速度50 Hzでの欠陥検出試験を行った。



図 3.2.3 (a)模擬トンネルにおける設置状況
(b)レーザー打音高速装置搭載車両

コンクリート供試体には、図 3.2.4 の点線で囲った領域に、模擬的な欠陥が表面から深さ 10 mm の位置に埋め込まれている。レーザー打音法による観測点は、33 mm 間隔で、330 mm × 330 mm の領域を水平 11 点×垂直 11 点の 121 点の観測を行った。高速レーザー打音検査の結果を図 3.2.5(a)に示す。赤色の部分が欠陥と判定された領域、緑色の部分は健全と判定された領域を示している。図 3.2.5(b)に観測された振動スペクトルの例を示す。健全部では、振動強度が弱く、かつ特徴的なスペクトルは観測されていない。これは内部に特異的な構造が存在していないことを示している。これに対し欠陥部では、振動スペクトルに鋭いピークが観測されている。これは、表面で生じた振動波が内部に存在する境界（空隙、き裂等の密度の急激な変化）で反射し、その後干渉することで、特定の周波数の共振（卓越振動）が生じたことを示している。本計測システムではこの卓越振動を観測することで欠陥の判定を行っている。50 Hz 動作のレーザー打音高速検査装置を用いることで、約 2 秒間で約 121 点の打音検査を終了し、その後、欠陥判定アルゴリズムを用いた欠陥判定の結果を表示することが可能である。

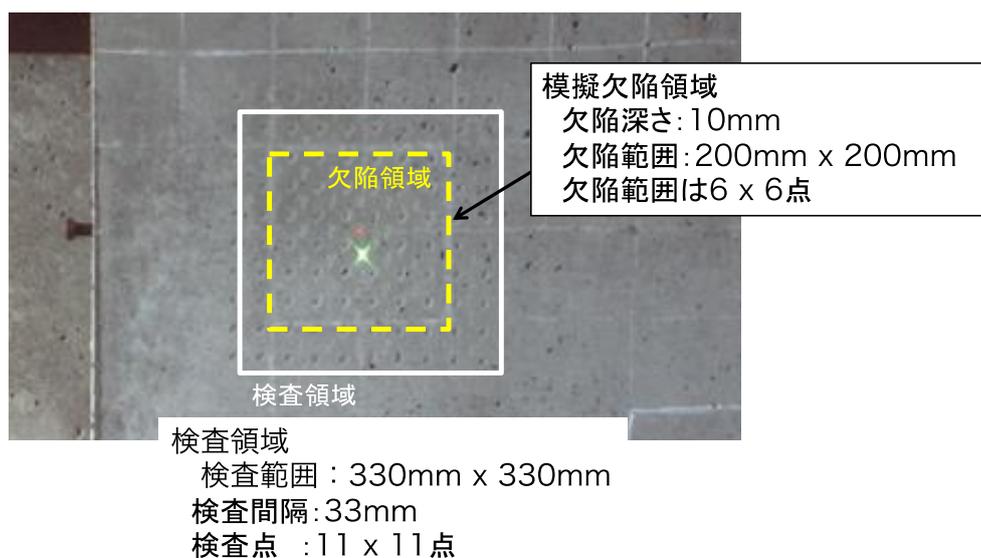


図 3.2.4 コンクリート供試体の検査領域と欠陥領域

本計測では、得られた振動スペクトルの卓越振動が見られたピーク周波数を中心にピーク強度比法や周波数面積比法等を用いて欠陥の有無に関する判定を実施している。そこでレーザー打音検査法の欠陥検査評価指標として独自の検出率と的中率を下記のように定義した。精度の指標となる検出率を $[(\text{欠陥部位数}-\text{見落とし数})/\text{欠陥部位数}]$ とし、また、的中率を $[(\text{計測点数}-\text{誤検出数}+\text{見落とし数})/\text{計測点数}]$ とした。ここで、欠陥部位数は、打音検査で欠陥判定された点の合計数を、見落数は、打音検査で欠陥判定された点を健全判定した点の合計数、誤検出数は、打音検査で健全判定された点を欠陥判定した点の合計数とする。図 3.2.5(a)の結果では、誤検出数は 0 であったが、200mm x 200mm の欠陥領域の端の部分

中心に 11 点の見落としがあった。このピーク強度比法等を用いた計算アルゴリズムのみを用いた場合検出率が[検出数 25 点/欠陥部位数 36]となり約 70%であった。また、的中率は、[正解数 110 点/計測点数 121 点]となり約 90%となった。ピーク検出法等を用いた欠陥評価アルゴリズムでは、図 3.2.5(b)に示したような単純な振動スペクトルではない場合に、欠陥の見落としが発生することがわかった。それに対し、121 点の振動スペクトルをアルゴリズムではなく、人間が判定した場合、見落とし数 0 点、誤検出数 0 点で、図 3.2.6(a)のように 100%の検出が可能であった。

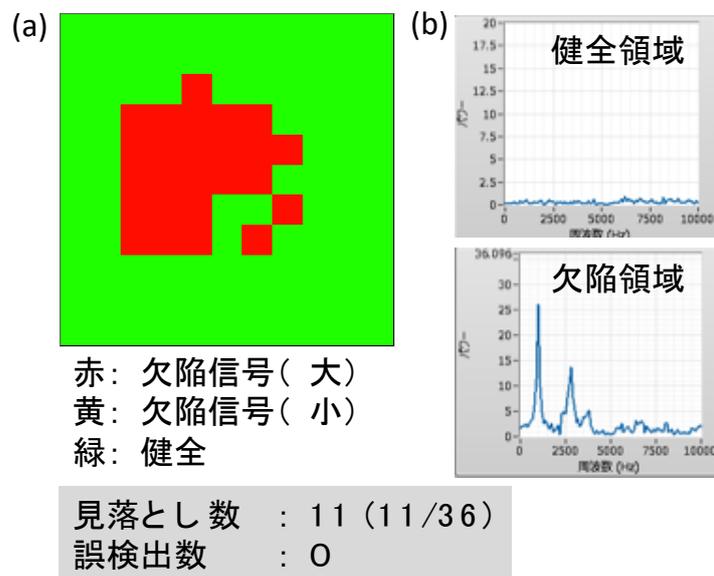


図 3.2.5 (a)欠陥検出アルゴリズムによる判定結果, (b)健全部と欠陥部の振動スペクトル

今回、品質保証の手法として知られているマハラノビス・田口 (MT) 法⁹⁾を欠陥判定に試験的に使用し、検査結果の評価を実施した。コンクリート供試体の健全部の振動スペクトルを学習させた上で、各計測点の振動スペクトルからのマハラノビス距離を算出すると、統計的に乖離度を評価できる。振動スペクトルから特徴抽出された 2 変数が正規分布に従っていると仮定すると、マハラノビス距離の二乗の値は自由度 2 のカイ二乗分布に従う。学習データの標準偏差を σ とした場合、マハラノビス距離の二乗の値が 2σ 以内の点を健全[緑]、 2σ から 3σ の間の値をとった点を欠陥信号(小) [黄色]、 3σ 以上の値をとった点を欠陥信号(大) [赤色]で表した。結果を図 3.2.6(b)に示す。MT 法を用いた手法では、見落とし数 2 点、誤検出数 2 点となり、検出率が[検出数 34 点 / 欠陥部位数 36]で 94%、また、的中率は、[正解数 117 点/計測点数 121 点]となり約 97%とピーク検出法等を用いたアルゴリズムに対して大きく見落とし数が改善された。しかし、シンプルな 2 変数を用いた MT 法では計測データ中におけるノイズ成分由来のスペクトル信号処理に課題があることがわかった。最終的な判定精度の向上のためには、今後、MT 法だけでなく他の機械学習等の手法を含めて判定手

法を複合的に組み合わせることで、人の判定結果に近づけることが可能であると考えられる。

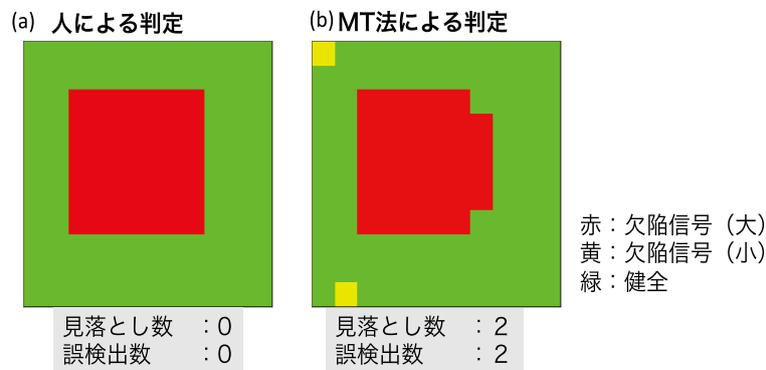


図 3.2.6 (a)人による欠陥判定, (b)MT 法による欠陥判定の結果

3.2.4 おわりに

レーザー打音高速検査システムを開発し、模擬トンネル内において車載した状態で 50 Hz の検査速度での欠陥検知に成功した。その計測結果に対して複数のアルゴリズムを用いて計測結果における欠陥判定の精度の向上を図っている。「レーザー打音法」は、打音法との高い互換性が期待できるため、検査の遠隔化、自動化だけでなく、その計測データの蓄積と人間の手による打音検査の定量的な比較等が今後の重要な課題である。今後は、実際のトンネル環境下での実証試験を行い、レーザー打音高速検査システムの性能や安定性を向上させ、実際の計測データと検査員の判定の比較等を行うことにより、さらなる装置の高度化を進めていく予定である。

参考文献

- 1) 御崎哲一著：「レーザーを用いた覆工コンクリートの欠陥検出方法に関する研究」(2015).
- 2) 島田義則：検査技術, vol.11, No.9, pp.8-14(2016).
- 3) 篠田昌弘・他：RTRI REPORT, Vol.23, No.12(Dec.2009).
- 4) K. Mikami *et al.*: Jpn. J. Appl. Phys. 56 (2017) 082701.
- 5) 長谷川登 他, 検査技術, 22(3), pp.57-61, 2017.
- 6) 錦野将元 他, 建設機械, 53 (5), pp.20-24, 2017.
- 7) S. Kurahashi *et al.*, J. Appl. Remote Sens., 12 (2018) 015009.
- 8) 岡田大 他, レーザー研究, 45, pp.427-432 (2017).
- 9) W. H. Woodall *et al.*, Technometrics 45, pp.1-15(2003).

3.3 上水道における漏水検知システム

3.3.1 はじめに

日本に敷設された上水道管の総延長は 66 万 Km におよび、高度成長時代に集中的に敷設されたため、40～60 年と言われる耐用年数を超える老朽管が急増している¹⁾。水道事業を営む地方自治体の多くは、人口減、財政縮小の中で水道設備の更改は十分とはいえない。現状年間管路更新率は 0.76%といわれ、このままでは管路更新に 130 年が必要と試算されている²⁾。耐用年数を超えた水道管の急増により、交通遮断や断水など、漏水を原因とする社会問題が心配される。

さらに、現状の漏水検査は漏水検知機器および聴音棒などの道具を使った人による巡回検査を中心に行われているが、水道設備の検査員の高齢化が進んでおり、今後熟練技術者が不足するとも言われている。

我々は、人の聴音による漏水検知と同等の精度を持つ自動漏水検知システムの実現を目的として、

- ① マンホール等を利用して地下の管路に漏水センサを設置し、無線伝送技術によって観測データを収集する技術
- ② 収集された観測データから漏水有無を識別するセンシングデータ処理技術
- ③ 効率の良い漏水センサ配置計画を実現する技術
- ④ 社会実装に向けた高感度漏水センサ端末の設計技術

の研究開発を行っている。

これら研究成果により、熟練技術者に代わって、誰もが簡単に漏水検知を行うことが可能な新たな漏水監視システムを実現し、水道設備の維持管理費用の削減、漏水発生事故の削減に貢献することを目指す。本報告では①～④のテーマのうち、AIを活用した漏水音の検知技術を中心に述べる。

3.3.2 本研究テーマにおける AI の活用

センシングデータ処理技術は観測データから漏水有無を識別する技術である。ここでは AI 手法の一つである機械学習として実績のある SVM(Support Vector Machine)を用いて、多数の漏水あり、漏水なしのデータから学習モデルを作成するとともに、新たに定常性に着目した不規則ノイズ除去や、場所による観測音の大きさの違いを補正する標準化処理の導入により、熟練技術者に代わる漏水検知の自動化システムの実現を目的とする。

3.3.3 漏水音の発生メカニズムと漏水検知の課題

漏水音は加圧されている水道水が水道管の亀裂や穴から外部の自由空間に放出される際に水の振動によって発生する。その振動は水道管の管材および管路内の水に伝搬して周辺に伝わり、漏水音として観測される。漏水音の周波数分布は、亀裂の状態や穴の大きさ、水道管の材質、水圧によって異なる。また漏水音の音圧は漏水音が管路を伝搬する際には減衰が生じ、漏水点から

遠い地点での漏水音の音圧は非常に小さくなる。

一方、水道管には漏水音以外にもさまざまな音が重畳している。例えば近辺の自動車走行音や自動販売機の動作音、下水や人の話し声など、生活の中で発生するさまざまな音が環境音となって水道管に伝搬する。上水道管の場合、管内に異物を入れることは、水道事業者からの許可が得られにくく、困難である。従って、センサは管の外壁に設置する必要があるため、こうした環境音の影響を受けやすい。

すでに商品化され自治体で使われている漏水検知装置の例では、管路に漏水センサを設置し、一定期間観測した観測音の音圧の平均値を計算し、その値に対してしきい値を用いて、音圧がしきい値を超えた場合に漏水であると識別を行っている。このような手法では、環境音の大きさに応じてしきい値を変えて使用する場合が多いが、適切なしきい値の設定には経験が必要である。また生活音が大きい場合や、漏水音が小さい場合には漏水検知が困難な場合も生じる。

漏水音の周波数成分を分析した報告例³⁾では漏水検知には周波数成分に着目することが有効であるとしている。また、複素フーリエ成分を用いたPCAに基づく自動漏水検知手法⁴⁾が報告されており、いずれも音の識別には周波数成分が有効であることが報告されている。

これら先行する研究事例は、漏水音が固有の周波数スペクトルを持つ、あるいは漏水音が固有の周波数スペクトルの変化を持つことを前提に、漏水音と漏水音以外の音の識別を行う手法である。しかしながら漏水音のバリエーションは様々であり、漏水条件や漏水音を観測する場所が異なれば漏水音も変わる。したがって漏水音の周波数スペクトルに固有の特徴があることを前提とした漏水検知法では漏水検知に限界があると思われる。

本報告で説明する漏水検知法は、漏水のないことが確認された場所にセンサを常設し、以後漏水の発生を監視する運用を前提とする。そこで漏水を同一の場所で観測された音響データの漏水なしを基準として、漏水が発生すると観測データに漏水音が重畳されたことにより音圧および周波数成分が増加することに着目し、その差から漏水有無を検知することで高精度の漏水検知を目指す。漏水検知は、観測データが漏水あり、漏水なしのどちらであるかを識別する問題であり、ここでは機械学習の手法の一つであるSVMの2クラス分類問題を適用する。SVMでは漏水ありの観測データから求めた特徴ベクトルと、漏水なしのデータから求めた特徴ベクトルをもとに、多数のデータを学習することで、漏水あり、漏水なしを分離するための最適な識別境界を求める。このためこれまで使われてきた漏水検知機器のように、経験値としてしきい値を設定する必要がなく、誰もが利用できる漏水検知を可能とする。

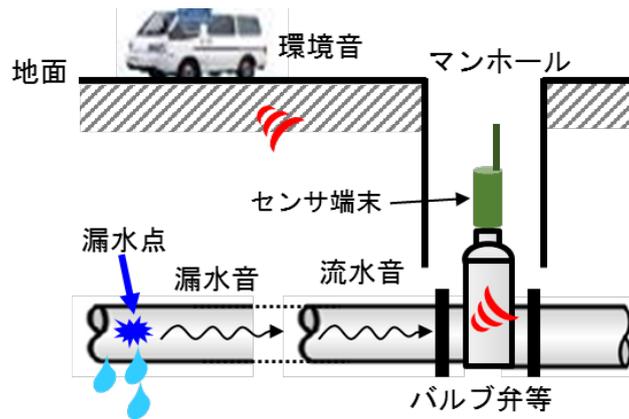


図 3.3.1 漏水音の伝搬と環境音の混入

3.3.4 漏水検知法の構成

漏水有無を識別するために、水道管路のマンホール、消火栓等を利用して水道管路、バルブ等に漏水センサを設置する。漏水センサは圧電素子により管路に伝搬する振動を観測することが可能である。観測されたデータは、漏水センサに付属する無線ユニット（特定小電力無線）を介して収集される。

マンホール内に設置された漏水センサを図 3.3.2 に示す。



図 3.3.2 マンホールに設置された漏水センサ

漏水検知処理は、SVM で漏水検知を行うための学習モデルを作成する工程（学習工程）と、観測データに対して漏水有無を識別するための漏水検知を行う工程（検知工程）、ならびに学習工程、検知工程に共通した前処理工程から構成される。

(1) 前処理工程

前処理工程は、観測データに重畳される自動車走行音などの環境音の影響を最小にするための弱定常性に着目した不規則ノイズの除去と、観測地点に依存する観測音の大きさ（音圧）の違いを補正するための標準化処理から構成される。

(2) 弱定常性に着目した不規則ノイズの除去

漏水音は、漏水量の増加により、少しずつ変化すると考えられるが、比較的短い時間内では変化のない連続音である。一方、車の通過によって発生するノイズは、短時間に大きく変動する。同様に漏水有無の検知を妨げる多くの環境ノイズは、時間的に変動が大きいと考えられる。

そこで時系列データとして観測データの定常性に着目し、非定常なデータを不規則ノイズとして除去を行う。

以下に定常性に着目した不規則ノイズ除去の方法を示す。

$\{Yt\}_{t=1}^T$ を時刻 $t=1$ から T までに観測された時系列データとする。

時系列データ $\{Yt\}$ に対して、ラグタイム j 、ウインドウ幅 w (ただし $1+j+w \leq T$) で表した時系列データ $\{Yt\}_{t=1+j}^{1+j+w}$ において、任意のラグタイム j に対して時系列データの平均値、分散値、共分散値が変わらないとき、その時系列データは定常であると定義する。

また任意のラグタイム j に対して時系列データの平均値、分散値が変わらないとき、弱定常であると定義する。

本報告においては弱定常に着目した不規則ノイズの除去を、以下の方法により行った。

観測された時系列データ $\{Yt\}$ を 1 秒間隔 ($\Delta n=1$) に分割し、300 個 ($m=300$) のデータ Yti を作成した。

$$Yti = \{Yt\}_{t=i\Delta n}^{(i+1)\Delta n} \quad (3.3.1)$$

$i=1, 2, \dots, m$

分割された m 区間の最小平均値 $Emin$ 、最小の標準偏差 $Vmin$ を算出した。

分割された m 個の観測データごとに算出した区間 i の平均値を Ei 、標準偏差を Vi として、予め定めた閾値 a 、 b を用いて

$$Ei > Emin + a \quad \text{または} \quad Vi > Vmin + b$$

のとき区間 i の観測データは弱定常ではないと判定し、不規則ノイズとして除去する。

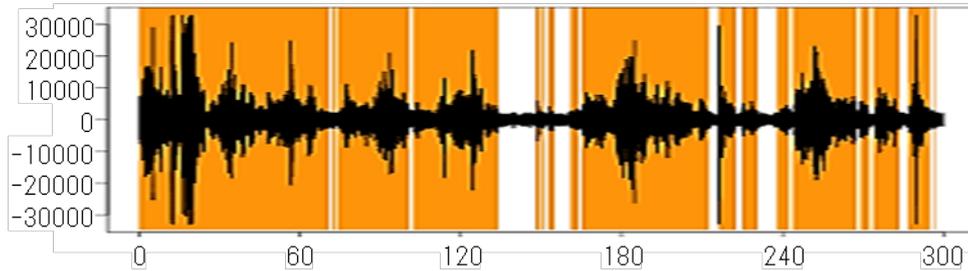
なお閾値 a 、 b は時系列データ $\{Yt\}$ の標準偏差を定数倍して決定した。

(3) 不規則ノイズの除去例

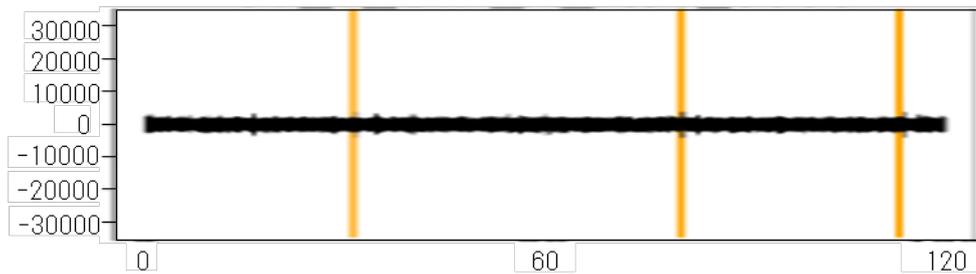
不規則ノイズを除去した事例を図 3.3.3 に示す。

大きな不規則ノイズが混入した場合にもノイズが除去されている一方、漏水点から遠く、観測データの音圧が非常に小さくなっている場合にも、観測データに含まれるわずかなノイズが除去できることが確認された。

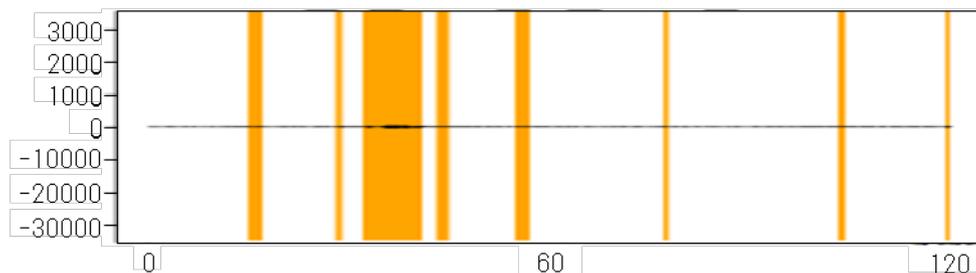
(オレンジ色が不規則ノイズとして除去される部分)



例 1. 大きなノイズが混入した例



例 2. 漏水音の音圧が高く、ノイズが少ない例



例 3. 漏水音の音圧が低い例

図 3.3.3 不規則ノイズの除去

(4) 学習工程

学習工程では、不規則ノイズを除去し漏水なしの音圧平均値を一定値に揃える標準化処理を行ったデータについて、SVM で処理するための特徴量の抽出と、実際に多数の漏水ありのデータ、漏水なしのデータから抽出された特徴量を用いて、学習モデルの作成を行う。

使用する特徴量は、漏水の発生によって音圧が上昇すること、漏水の発生によって漏水音の周波数成分が重量されることに着目し、以下に定義される音圧分布特徴、周波数分布特徴を算出し、2つを合わせて多次元特徴量⁹⁾とする。以下に多次元特徴の算出方法を示す。

不規則ノイズを除去した観測データ Y_t を用いて Y_t の高速フーリエ変換を行い、パワースペクトルを求めた。得られたパワースペクトルを周波数 10Hz 単位に 4KHz までの 200 次元に変換したデータを周波数分布特徴 $H(f)$ とした。

また同じ観測データ Y_t を音圧の出現頻度によってヒストグラムを作成し、328 次元に変換した

データを音圧分布特徴 $P(k)$ とした。音圧分布特徴は観測データ Y_t の振幅の一定時間内の出現確率密度と等価である。

周波数分布特徴、音圧分布特徴を合わせて、528次元の多次元特徴量とした。

(5) 漏水検知工程

SVM を用いた漏水検知では、水道管に設置した漏水センサから得られた観測データに対して、学習工程と同様に不規則ノイズの除去、学習時と同じ条件の標準化処理を実施し、周波数に関する特徴、音圧に関する特徴からなる多次元特徴を算出する。得られた多次元特徴量を、学習工程で作成した学習モデルを用いた SVM の入力として、漏水あり/漏水なしの検知を実行する。

なお SVM 等機械学習では、学習に用いたデータを評価データとして使用した場合、高い分類能力を示すことが知られている。このため性能評価データは学習に用いたデータを含めないことが一般的である。

学習工程、検知工程の処理の流れを図 3.3.4 に示す。

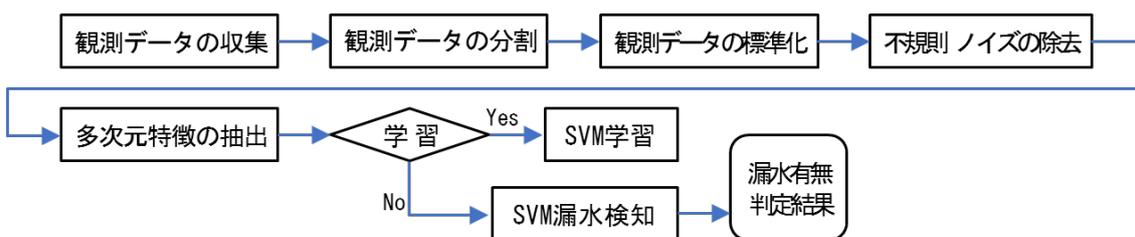


図 3.3.4 学習・検知工程の処理の流れ

3.3.5 実証評価実験

漏水検知の評価対象データは、水道事業者の協力を得て市街地に設置されている実際の水道管を用い、漏水を想定した放水を行う消火栓を疑似漏水点とし、漏水点から離れた 40 地点（漏水点からの距離 18.9m ～687.8m）の水道管バルブ、消火栓に漏水センサを設置し収集した。

学習モデル作成に用いたデータは、上記評価対象データには使わず、疑似漏水だけでなく、実際に発生した漏水現場で収集したデータも使用した。

(1) 漏水音伝搬の距離特性

漏水点で発生した漏水音は、管路内の水を媒体として伝搬するが、漏水点からの距離によって漏水音の大きさは減衰する。また観測点が異なると環境ノイズの有無やセンサの設置状態の違いから、観測される音圧は変化する。そこで前述の学習工程で述べた標準化処理によって、観測点ごとに漏水のない音圧を一定にする標準化を行うとともに、観測データの一定時間内の絶対値振幅値を計算し、漏水点での値を 0dB とした減衰量で表し、漏水点からの距離の関係を求めた。結果を図 3.3.5 に示す。

この結果、漏水量毎分 30L、10L のいずれも距離が遠くなると減衰量が大きくなるが、500m 地

点においても漏水なしよりわずかに大きく、漏水音が到達していると考えられる。500mを超えた地点では、漏水あり漏水なしの関係がくずれるため、漏水音が到達していないと考えられる。

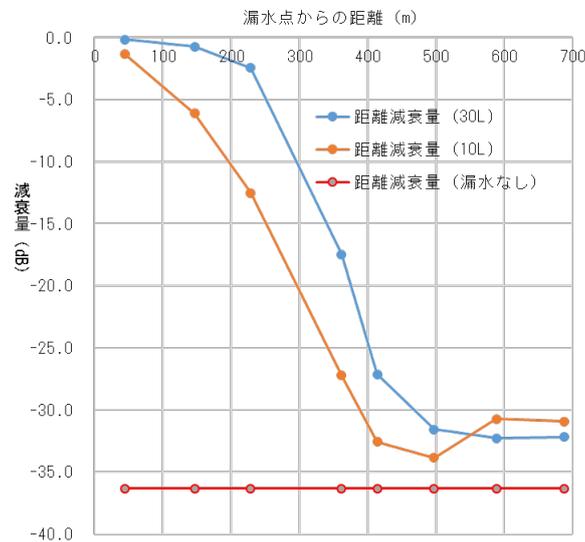


図 3.3.5 漏水音の減衰と距離の関係

(2) 評価結果

漏水検知能力を評価するため、疑似漏水音が到達していると判断された漏水点からの距離 500m 以下における識別率、適合率を求めた。また漏水検知手法を開発するにあたり、達成目標として漏水点から 150m 以内で漏水量毎分 10L 以上の識別率 95%以上としているため、距離 150m 以下で漏水量毎分 10L 以上の結果を分計した。漏水点からの目標としている距離 0m から距離 150m 以下の範囲において、漏水量毎分 10L 以上で識別率 100%、適合率 100%、漏水見逃し率 0%が得られ、目標を達成した。なお目標を超える距離 0m から距離 500m 以下の範囲で水量毎分 5L 以上においても、識別率 90.7%、適合率 100%、漏水見逃し率 11.7%となり、高い識別能力が得られた。従来より難しいとされていた漏水検知だが、漏水なしの音を予め観測し、そこからの変化を捉えることで漏水検知問題を単純化したことが、高い識別能力が得られた要因と考えられる。

現在自治体で使われている漏水センサの漏水検知の適用範囲は、概ね漏水量毎分 10L 以上に対して漏水点からの距離が 100~200m とされている。漏水音の伝搬距離は、漏水量、管路の材質や口径、分岐の有無等で異なるため単純な比較はできないものの、本報告では最大で毎分 5L、429.3m 地点で漏水検知が可能であったことは、従来の漏水センサを大きく上回る性能が得られていると推察される。

以上のように本手法で高い漏水検知性能を実現した理由は下記であると考えられる。

- ① 標準化処理により漏水なしの音圧を一定値に揃え、漏水センサの取り付け方や場所による音圧の違いを補正したこと

- ② 本稿では説明を省略したが、音圧特徴と周波数特徴を併用した多次元特徴を併用したことで精度向上が得られたこと
 - ③ 標準化処理により識別問題を単純化し、代表的な機械学習である SVM を用いて、漏水あり、漏水なしの特徴空間を最適に分離する識別境界を自動的に算出することにより、従来の漏水検知装置では人が経験に頼って行う必要があった閾値設定を不要にしたこと
- なお本報告では、漏水検知能力を疑似漏水に対して実施した結果を述べたが、実漏水についてもこれまでに評価実験を実施しており、識別率 93.5%、適合率 97.7%を得ている⁹⁾。

3.3.6 まとめ

本報告では、自治体水道局の協力を得て市街地に設置されている実際の水道管の 40 地点に漏水センサを設置するとともに、消火栓から疑似漏水を発生させ漏水音を観測・収集し、漏水検知の評価実験を実施した。漏水検知においては水道事業を行っている自治体ヒヤリングから得られた目標精度の実現を目指し、そのための漏水検知手法として、音圧の特徴と周波数の特徴を併用した多次元特徴を算出するとともに、代表的な機械学習法である SVM を用いた。また漏水音以外の環境ノイズを除去するための不規則ノイズの除去を組み合わせることにより、漏水検知能力を向上させた。

この結果、漏水点からの目標としている距離 150m 以下の地点において、識別率 100%、適合率 100%、漏水見逃し率 0%が得られ、目標を達成した。なお目標を超える距離 500m 以下においても、識別率 90.7%、適合率 100%、漏水見逃し率 11.7%となり高い識別能力が得られた。

今後、本識別法をもとに、事業化を想定した漏水検知システムを構築するとともに、社会実装にむけた評価を実施する予定である。

参考文献

- 1) 公益財団法人水道技術研究センター，“水道ホットニュース 604 号 管路更新率の推移について（その 1）－平成 27 年度水道統計に基づく試算結果－，”
”<http://www.jwrc-net.or.jp/hotnews/pdf/HotNews604.pdf>
- 2) 厚労省，“平成 28 年度水道事業に係る施策の概要，”
”<https://www.mhlw.go.jp/file/06-Seisakujouhou-10900000-Kenkoukyoku/0000119863.pdf>
- 3) 川村和湖他，“水道管路のセンシングデータを用いた漏水有無の判別分析”，土木学会論文集 G, Vol72, No6, pp.187-194, 2016.
- 4) 近藤智香子 他，“複素フーリエ成分の PCA に基づく水道管自動漏水検知手法，”日本建築学会環境系論文集, vol.74, No.642, 965-972, Aug. 2009.
- 5) 水野孝昭 他，“機械学習を用いた水道管漏水検知手法の検討，”2016 年信学会総合大会, B-18-55, March 2016.

- 6) 赤埴淳一 他, “機械学習を用いた水道管漏水検知手法の評価,” 2018 年信学会総合大会, B-18-21, March 2018.
- 7) S. Teruhi, Y. Yamaguchi, and J. Akahani, “Water Leakage Detection System for Underground Pipes by using Wireless Sensors and Machine Learning,” Journal of Disaster Research, Vol. 12, No.3, pp. 1-12, 2017.

3.4 近接目視・打音検査等を用いた飛行ロボットによる点検システムの研究開発

3.4.1 研究の概要

本研究開発では、橋梁などのインフラ構造物の点検を目的とし、マルチコプターの上部に搭載した駆動車輪と点検機構により、点検面を走行しながら近接目視、打音検査などの点検を実施する点検ロボットと、ロボットが取得した点検信号を画像解析や音響解析などの処理法により、浮き、剥離、ひび割れなどの異常部を検出する信号処理部から構成される点検システムを開発した。

3.4.2 内部欠陥を有する打音供試体

SIPの研究チームの幾つかは、打音による音響データによる欠陥部検出方法を検討している。打音による音響データの特徴は、欠陥位置深さ、欠陥サイズ（幅や広さ）などの幾何学的影響や打音強さなどの打音方法の影響を受けるため、開発チームが異なる供試体を対象として独自の打音機構・欠陥判定法を評価しても、その適用範囲や精度など客観的評価が困難である。そこで、SIPの各チームが自由に利用できることを想定し、道路橋の床版の諸元を参考にして、鉄筋腐食による浮きを想定した打音供試体を作成した。

作成した打音供試体の概要を図3.4.1に示す¹⁾。供試体は、寸法300×1000×200mm、鉄筋かぶり30, 50mmである2体の供試体である。欠陥は広さ120×120mm、幅1.5, 1.0, 0.5mmである3種を、図の通りに配置した。欠陥は、波型のひび割れ面を再現できる段ボールの中芯によって模擬し²⁾、各供試体の鉄筋上に設置した。

供試体の高さを200mmとしたのは、既設の道路橋の床版が昭和48年道路橋示方書³⁾からは最小部材厚さが160mmであり、疲労の問題で近年は200mm以上となることが多いことから、既設から新設までの平均的な値として200mmとした。また、既往の打音に関する供試体では鉄筋を配置しない場合が多く見られるが⁴⁾、鉄筋の影響を想定し100mm間隔で配置した。100mmは道路橋床版では最小間隔に対応し、鉄筋の影響が出やすい配筋となる。かぶりは、昭和40年代までは最小かぶりが30mmであり、塩害対策でかぶりが厚くされた場合を想定し、30mmと50mmの2種類とした。欠陥は、鉄筋腐食によるひび割れを想定しているため鉄筋上面のかぶり深さ位置に配置した。欠陥の幅については、従来空洞を対象として5mm以上の空洞の打音供試体が多く見られるが^{4) 5)}、鉄筋腐食の場合は腐食量が10%程度では1mm以下となることから、0.5mm～1.5mmと既往の研究に見られるものより小さいものとした。欠陥広さは、鉄筋間の水平ひび割れを想定し、鉄筋間隔相当の120mmとした。

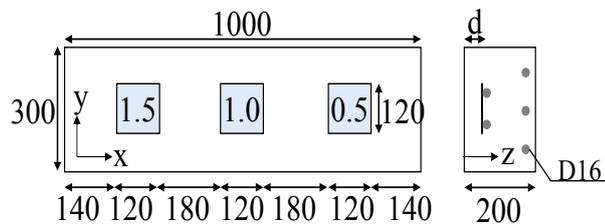


図 3.4.1 供試体諸元

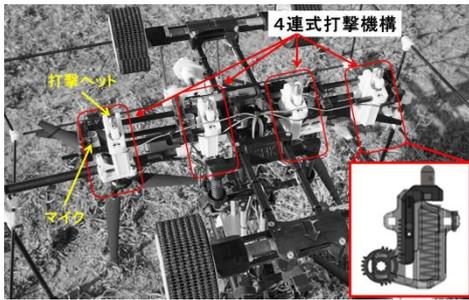


写真 3.4.1 ピストン型の打撃機構

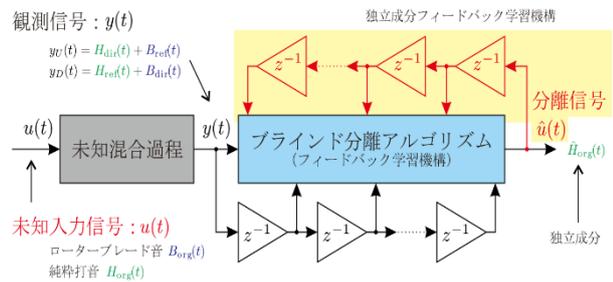


図 3.4.2 ブラインド分離アルゴリズム

3.4.3 点検ロボットに搭載した打音機構の概要

開発した点検ロボットには打音検査を実施可能な機構を搭載している。打音機構はモーター駆動による4連式ピストン打撃機構(写真3.4.1)を採用し、各打撃機構に備え付けた集音マイクにより、それぞれの打撃位置における打音信号を獲得し、周波数解析によりスペクトル分布を得るといったシステムとなっている。ここで、マルチコプターに打音機構を搭載した打音検査の問題点としては、プロペラ音と打音の選別と、抽出した打音信号から内部の欠陥(浮き、はく離、ひび割れなど)を評価する手法が挙げられる。

マルチコプターによるプロペラ音と打音による音が同時に集音マイクに入ってくる問題に対しては、プロペラ音と打音を選別するために、新田ら⁶⁾によって開発されたブラインド分離アルゴリズムによる音響解析(図3.4.2)によってそれぞれを分離し、打音による信号のみを抽出して周波数解析を行うことで解決した。本手法はブラインド分離の中でも、特に独立成分分析と呼ばれる手法である。独立成分分析は独立な信号が混合されたとき、混合信号から元の源信号を復元する手法である。この場合、独立な信号は、プロペラ音と打音であり、それらが独立であるという事実から混合信号にアルゴリズムを適用することで、独立な打音のみを抽出することが可能となる。

3.4.4 欠陥部の評価手法の概要

打音検査には、内部欠陥の領域を検出し、必要とあれば脆弱なかぶり部をたたき落とすことが必要となる。後者においては、飛行ロボットの安全性を大きく損なう可能性があるため、前者の内部欠陥の領域を抽出する1次スクリーニング技術となることを目指した。1次スクリーニング技術として、欠陥部の見逃しを可能な限り低減させることが重要となる。スペクトル分布は、打撃の入力方法による影響だけでなく、欠陥の幅や領域によって大きく変化する¹⁾。したがって、欠陥部を抽出できるような評価指標には、打撃の入力方法の影響、欠陥の幅や領域の影響といった様々な影響を考慮する必要がある。これらの影響がスペクトル分布を多様に変化させる中で、浮きの厚さや内部のひび割れ幅などの定量値を評価することは極めて困難である。一方で、健全部のスペクトル分布は入力による影響のみを受けることから、その位置が健全であるという評価は、欠陥部の評価よりも容易である。また、実構造物では対象構造物や部材でコンクリート強度

などの材料物性や部材厚さが異なり、対象部材の状況を考慮した判定方法が望ましいと考えられる。そこで、点検対象部材の健全部の特徴的な打音特性から健全部判定を行い、健全部ではない領域を欠陥がある可能性がある領域として判別するコンセプトにより、欠陥部の見逃しを低減させる1次スクリーニング技術としての評価手法を構築した¹⁾。

以下に、提案した健全部判定フローを示す。

- ① 点検前に対象部材の健全部と思われる複数箇所にて打撃データを取得する。
- ② 取得した健全部の打撃データから対象部材に対する健全部評価指標のヒストグラムを作成する。
- ③ 健全部判定の閾値を決定する。
- ④ 打音検査を対象部材に対して行い、健全部判定指標の閾値以上を健全部と判定し、それ以外を欠陥を有する可能性のある領域と判定する。

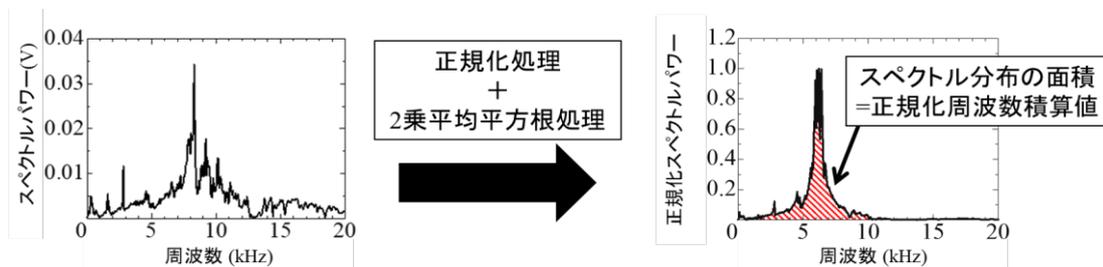
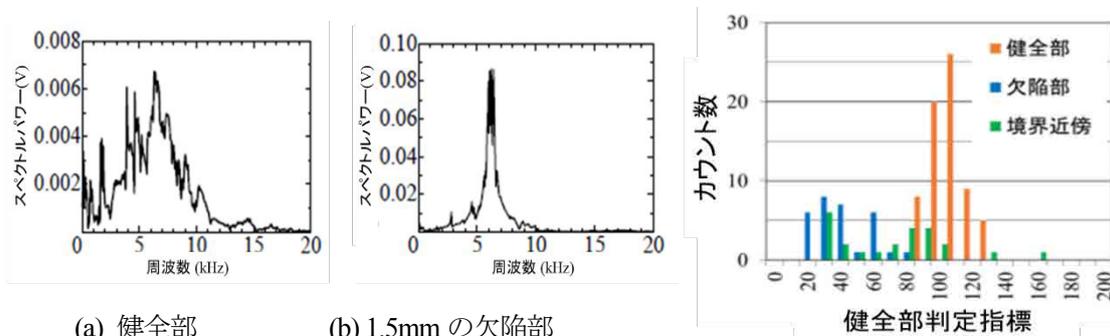


図 3.4.3 正規化周波数積算値の算出方法



(a) 健全部 (b) 1.5mm の欠陥部
図 3.4.4 鋼球落下試験によるスペクトル分布の一例

図 3.4.5 健全部判定指標のヒストグラム

健全部判定指標とは、スペクトル分布の最大値を1として正規化し、よりスペクトル分布の特性を際立たせるために二乗平均平方根処理を各周波数帯のスペクトルパワーに対して行い、さらに周波数帯ごとに積算した正規化周波数積算値（図 3.4.3 参照）である。一例として、図 3.4.1 のかぶり 30mm の供試体の健全部と欠陥部中央（欠陥幅 1.5mm）の鋼球落下試験（鋼球径 20mm、落下高さ 100mm）を行い得られたスペクトル分布を図 3.4.4 に示す。健全部ではブロードな分布であるのに対し、欠陥部ではある周波数帯にスペクトルが卓越するような分布となる。なお、健全部と欠陥部の境界付近に近づくにつれて、欠陥部の特徴的な分布が健全部の分布に漸近するよ

うな傾向が確認されている。このスペクトル分布から正規化周波数積算値を算出すると、健全部では比較的大きく、欠陥部では比較的小さい値となる。既往の健全部と欠陥部が既知である実験データから健全部判定指標のヒストグラムを作成すると図 3.4.5 のようになる。このヒストグラムの分布が正規分布をとると仮定する。健全部での平均値 μ と標準偏差 σ を算出し、健全部判定の閾値を $\mu - \sigma$ と定義すると、閾値は 83.8 となり、ヒストグラムの図からも健全部を抽出していることがわかる。この一連の健全部判定フローを各打撃点のスペクトル分布に対して行うアルゴリズムを構築し、連続的に対象部材平面における健全部判定指標の分布を自動的に作成することを可能とした。供試体を 50mm 間隔で面的に打音して、本健全度判定手法を適用した結果が、図 3.4.6 である。健全部を確実に判断し、0.5mm 幅の欠陥まで健全でないと判断している。

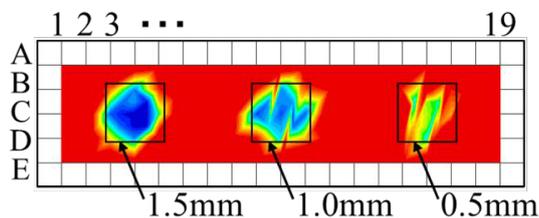


図 3.4.6 基本供試体の健全部判定 (閾値 83.8)

本手法の適用性を、マルチコプターに搭載した打音機構で確認した結果が図 3.4.7 および図 3.4.8 である。図 3.4.7 は、健全部と模擬欠陥部の正規化スペクトル分布の一例であるが、打音供試体と同様に健全部ではブロードなスペクトル分布が、模擬欠陥部では約 8kHz に卓越するスペクトル分布となり、打音供試体と同様の適用が可能と考えられる。健全部のスペクトル分布が図 3.4.4 に示す鋼球落下による実験よりもブロードな傾向であるが、これは打音機構のフレームや打撃機構から生じる音が健全部のスペクトル分布に影響したと考えられる。しかしながら、図 3.4.2 に示す分離手法を併用することから、常時発生する雑音の影響は低減されるものと考えている。

ここで得られたスペクトル分布から健全部判定指標を算出し、図 3.4.1 の供試体に対しヒストグラムを示したのが図 3.4.8 である。かぶり 30mm, 50mm のいずれの欠陥幅でも、大多数の模擬欠陥部の結果は健全ではない、すなわち、欠陥を有する可能性があることが判断されていることが確認でき、健全部判定手法による健全部判定は、マルチコプターに搭載する打音機構においても適用できることを確認した。

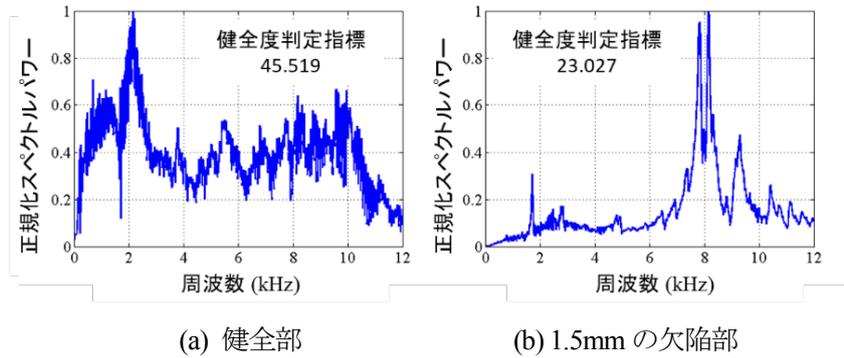


図 3.4.7 打音機構による正規化スペクトル分布

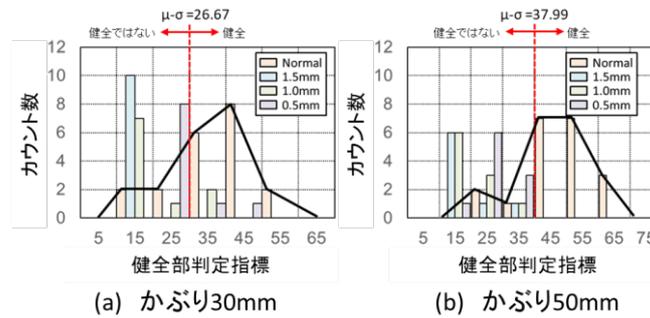


図 3.4.8 打音機構による健全部判定指標のヒストグラム

参考文献

- 1) 鈴木理絵, 多田祐希, 中村光, 三浦泰人: 弾性波法による健全部判定に基づくコンクリートおよび断面修復部内部の欠陥検出, コンクリート工学年次論文集, Vol.40, No.1, pp.1617-1622, 2018.
- 2) Fu L., Nakamura H., Yamamoto Y., Miura T.: Investigation of Influence of Section Pre-Crack on Shear Strength and Shear Resistance Mechanism of RC Beams by Experiment and 3-D RBSM Analysis, Journal of Advanced Concrete Technology, Vol.15, pp.700-712, 2017.
- 3) 日本道路協会: 道路橋示方書・同解説I, 1972.
- 4) 鎌田敏郎, 浅野雅則, 国枝稔, 六郷恵哲: コンクリート表層部欠陥の定量的非破壊検査への打音法の適用, 土木学会論文集, No.704/V-55, pp.65-79, 2002.
- 5) 小池耕太郎, 井山徹郎, 野内彩可, 村上祐貴: コンクリート内部の欠陥深さが打音特性に及ぼす影響: コンクリート工学年次論文集, Vol.37, No.1, pp.1849-1854, 2015.
- 6) 新田益大, 杉本謙二: 独立成分分析に基づく多入力多出力システムのブラインド同定, 電子情報通信学会論文誌 A, J90-A(1), pp.27-34, 2007.

4. 社会実装に向けての首都高速道路での取り組み

4.1 インフラマネジメントシステム¹⁾

首都高速道路では、新たなインフラマネジメントシステム (i-DREAMs) を開発し、2017年7月から実装し維持管理に活用している。このシステムでは、調査・設計、施工、維持管理の各フェーズで得られる必要な情報が有機的につながり、課題の「見える化」、維持管理業務のさらなる効率化、省力化が可能となる。これにより、インフラの建設、維持管理のシームレスなマネジメントが可能となり、従来とは次元を異にする生産性の高い、インフラマネジメントの実現が期待される。

新たなインフラマネジメントシステム (i-DREAMs) の全体像を図 4.1.1 に示す。これは、ICT (情報通信技術) を活用し、各フェーズで得られる属性情報や各種データベースをシームレスにつなぐ新たなシステムである。i-DREAMs の構成は、調査・設計 (DIM : Design Information Management)、施工 (CIM : Construction Information Management)、維持管理 (MIM : Maintenance Information Management) の三つのフェーズからなる。高耐久で品質の高い構造物を建設し、適切に維持管理を行うためには、この各フェーズにおいて必要な情報を

i-DREAMs® (intelligence-Dynamic Revolution for Asset Management systems)



図 4.1.1 i-DREAMs の概要

蓄積、統合 (Integrate) することが重要である。また、維持管理 (MIM) においては、既存のデータベース、点検データ、センシングデータ等を IoT (Internet of Things) を用いて統合するとともに、交通量や軸重データ、環境条件等も含めてシステム上に統合されたビックデータを AI (人工知能) 技術を活用して、構造物の変状や性能を効率的かつ的確、高精度に評価するシステムである。

図 4.1.1 に示すとおり、インフラマネジメントシステム (i-DREAMs) のコア技術を構成するプラットフォームは InfraDoctor である。これは、GIS をベースとしたデジタルプラットフォームで、各種の点検や補修履歴等のデータベースを地図情報上に統合し、「ヒト」と「データベース」を有機的につなげるものである (図 4.1.2 参照)。さらに、図 4.1.3 に示すようにレーザスキャナーやデジタルビデオカメラなどを車両に搭載した移動式高精度三次元計測システム MMS (Mobile Mapping System) や固定レーザスキャナーによって取得される三次元点群データおよびビデオ画像等により、実構造物を三次元のデジタルデータとして当該システム上に再現、蓄積することを可能とした。これにより、点検や維持管理業務の様々な場面で必要となる構造物の位置や実際の寸法、構造物相互の距離等を交通規制や時間の制約などを受けることなく測量、計測することができる。この結果、効率的な維持管理計画の策定が可能となり、生産性の大幅な向上が図られる。



図 4.1.2 InfraDoctor のシステム概要



図 4.1.3 MMS (Mobile Mapping System)

また、三次元のデジタル空間上で、設計成果の現場確認、点検、維持管理工事のシミュレーション等を事前に行うことができるため、手戻りのない作業計画の立案も可能となる。加えて、三次元点群データを用いた交通規制の三次元動的シミュレーションにより安全性の事前確認や規制図面の自動作成ができ協議等の効率化が図られる。さらに、取得した構造物の点群データを時間軸で比較することにより、変状や変位の発生、進行をデジタル空間上で計測、把握も可能となる。この結果、構造物の異常をミリレベルの精度で、マクロ的に把握することが可能となり、点検等の一次スクリーニングとして、または近接目視点検の代替あるいは一部として適用できる可能性もある。現在、2mm~4mm まで凹凸の検出が可能であり、ほぼ実用化のレベルに達している

(図 4.1.4 参照)。さらに、わだち掘れやポットホール等の路面状況 (図 4.1.5 参照)、山間部においては法面の変状等についても把握することができる。

また、今回 MMS により取得した点群データから、二次元あるいは三次元の CAD 図面を半自動で作成することを実現した (図 4.1.6 参照)。これにより、既設構造物の現況図の作成や構造物が別々の図面に分かれている場合、統合した実構造物の図面や管理台帳を作成することもできる。さらに、点群データから作成された実構造物の 3D-CAD 図から FEM 等の構造解析モデル (図 4.1.6 参照) を構築し、構造性能や耐震性能の検証あるいは既設構造物の劣化予測等をシミュレーションするインターフェースも実装している。

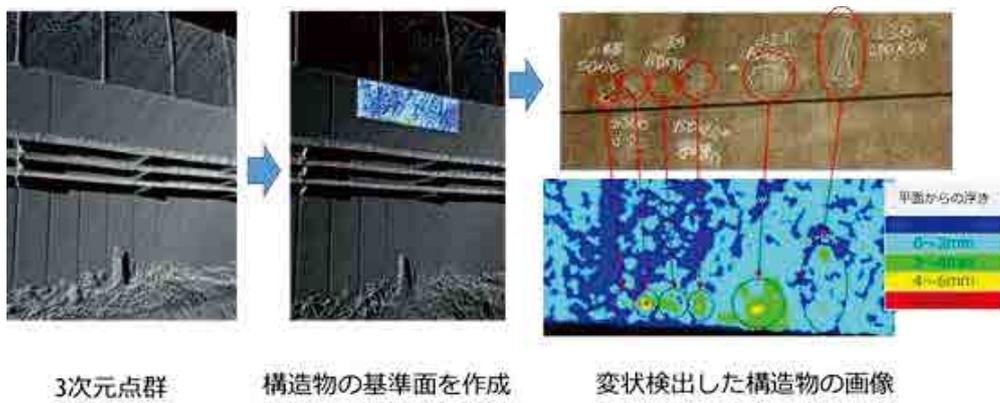


図 4.1.4 コンクリート構造物の変状検出事例

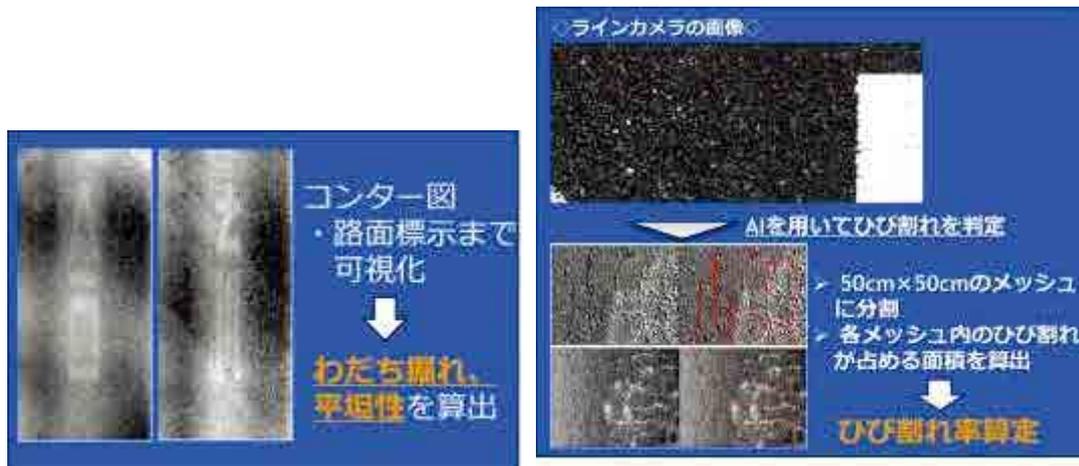


図 4.1.5 路面のわだち掘れ、平坦性、ひび割れを変状検出

一方、ICT を活用して、点検や補修工事の際にタブレットなどの情報端末からホストサーバーの各種データベースにアクセスするなどして、過去の点検履歴や補修履歴などをリアルタイムに確認することも可能となる。これにより、構造物の劣化の進行度や変状の再発など劣化、

変状の状況を現場で確認，検証しながら点検，補修工事を進めることができる。その際 AR (Augmented Reality：拡張現実) を活用することにより，過去の点検データをタブレットの実構造物上に表示して確認できるため，維持管理業務のいっそうの効率化，生産性の向上が期待される。さらに，点検結果をタブレットから，ホストサーバーに送信し，新たなデータベースとしてリアルタイムで更新，蓄積，管理することも可能となる。これら更新されたデータベースは，次の点検，補修・補強計画の策定に反映され，適切なメンテナンスサイクルが実現される。

このように，当該システムは，インフラマネジメントの各種場面で業務支援が可能となることから，今後ますます高齢化する構造物の維持管理業務において，さらなる効率化，省力化を推進するとともに生産性を高めるものとする。以下に，当該システムに活用される各種要素技術のうち，SIP で開発された技術について紹介する。



図 4.1.6 MMS の点群データから CAD 図の作製事例

4.2 コンクリート構造物診断技術

現在，SIP 「インフラ維持管理・更新・マネジメント技術」点検・診断技術の実用化に向けた研究開発で進めている要素技術のうち，コンクリートの劣化診断に活用可能な技術について以下に報告する。

4.2.1 学習型打音解析技術 (AI 打検システム) の研究開発²⁾

(1) 研究の概要

本研究開発は，点検員の技術に左右されることなく正確に変状の検出が可能な打音検査技術の開発を目的に，現場で使用する打音装置と，検査結果を現場で変状推定マップとして表示できるタブレット表示装置を開発した。本研究開発は，(1) 打音解析手法の開発 (2) 打音装置および打音解析システムの開発 (3) 打音データセット構築と性能評価，の3項目から構成される。開発技術の詳細については，前述の 3.1 を参照されたい。

ここでは，点検ハンマーによる打音の違いを機械学習し，構造物の異常箇所と異常の度合いを自動検知する「AI 打検システム」について記述する。本技術により，検知結果を点検員にリ

リアルタイムで提示し、レーザー光による測域センサーで人手によるハンマーの打撃位置を簡便に取得し、打音解析結果と統合することで異常度マップを自動的に作成できる。

また、AI 打検システムを用いた打音採取実験と、その正常異常の正解ラベルをつけたデータセット構築、およびそれを用いた性能評価試験を行った。試験では、人力による詳細な叩き点検を実施し内部欠陥（浮き）が確認された7つの実橋等に対して、AI 打検システムによる点検を実施し、その結果の比較を行った。大まかなブロック単位ですべての場所で欠陥の見落としが無く、また打音1音ごとの正答率は、最高で93.2%、平均で84.0%という良好な結果を得た。AI 打検システムを用いた点検作業フローを検討し、現地作業での実測値を用いて比較した結果、従来手法より1～2割程度の時間増加となったが、本システムでは検査結果が点検員の技量に依存することなくコンター図が得られる等のメリットが得られることから、実務でも優良と考える。

(2) 研究テーマの中の AI の活用 ^{3),4),5)}

AI 打検システムについて、そのシステム構成、各構成デバイス、打音解析部、オプション装置について説明する。なお、AI 技術に関する詳細については、前述の3.1を参照。

インフラ構造物の打音検査を人工知能でアシストし、異常度マップを自動生成するシステムである「AI 打検システム」を開発した。本システムの概要を図4.2.1に示す。本システムは、点検ハンマーによる打音の違いを機械学習し、構造物の異常箇所と異常の度合いを自動検知する。その検知結果を点検員にリアルタイムで提示するとともに、点検ハンマーの位置情報と統合して異常度マップを自動的に作成する。これにより、図面化を含めた作業工数が削減でき、また、非熟練者でも見落としなく点検作業が行えるため、熟練点検員の確保が難しい地方をはじめ今後急増すると予想される全国のインフラ点検作業での活用が期待される。

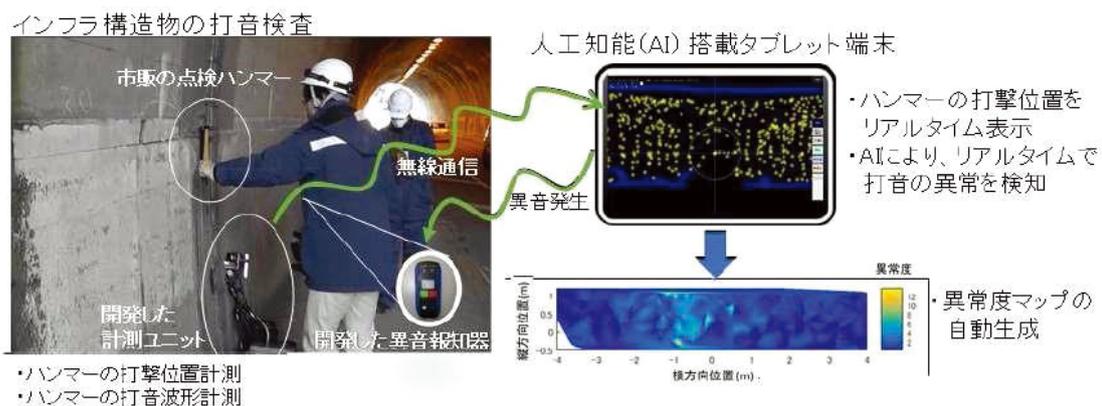


図 4.2.1 AI 打検システムの概要



図 4.2.2 計測ユニット外観



図 4.2.3 異音報知器

今回開発した AI 打検システムは、計測ユニット（図 4.2.2 参照）、AI を搭載する制御・記録・解析用のタブレット端末、異常を通知する異音報知器（図 4.2.3 参照）から構成される。計測ユニットは構造物の壁面など平らな面（平面構造）に立てかける形で使用する（図 4.2.2 参照）。この AI 打検システムは、一般的な点検ハンマーを用いた打音検査に対して、主に二つの機能を提供する。一つは、ハンマーで叩いた箇所の異常の有無を異音解析技術により自動的に判定し、異常箇所を検出すると点検者にリアルタイムで提示する機能である。もう一つは一連の打音検査の作業終了後すぐに、異常度マップを自動的に生成して点検者に提示する機能である。

第一の機能である異常箇所のリアルタイム提示については、計測ユニットに搭載された接触式の音響センサーと、打撃位置取得のための測域センサーにより、点検ハンマーの打音の波形と、平面上のどこを打撃したかの位置情報を合わせて取得できる。第二の機能である異常箇所マップの自動生成機能については、打音検査を終えて検査モードを終了すると、これまで取得した打音位置とそれら打音の異常度を統合した異常度マップが自動生成される。

また AI 打検システムは複数のコンポーネントの組み合わせで構成されており、ユーザーのニーズに応じてオプションを選択可能である。組み合わせ方としては、以下のオプションがある。

- ・打撃部：点検ハンマー / 打診棒 / 点検困難箇所用打撃装置
- ・音響センサー部：接触式打音センサ・マイク併用 / ワイヤレスマイク
- ・測域センサー部：測域センサー あり / なし
- ・センサー設置部：三脚状治具 / 床版向け吸着型治具
- ・AI 解析部：タブレット（教師なし学習）+計測電源ボックス

正確な打撃位置を計測するためにはカメラで打音検査状況を撮影して画像処理により検査器具の位置を計測する手法や、検査器具そのものに計測のためのセンシングデバイスを付加するなど、様々な方法が考えられる。しかし、実際の打音検査の現場において計測範囲を撮影して打撃位置を計測できるだけのスペースを確保することは困難である。また、これまでの作業への聞き取り調査から、検査器具の重量が増すような高機能化への抵抗が高いことがわかっている。

そこで、本研究では検査対象面に接触するハンマーや打診棒といった検査器具の位置を AI 打検ユニット側から計測するために、レーザーレンジファインダー (LRF) を採用した。LRF は正弦波で変調した赤外線レーザーを照射し、測定対象物からの反射光を計測して正弦波の位相遅れを測定することで距離を測定する。一般には高速で回転するミラーなどを用いることで計測範囲内に対してレーザーを走査することで計測範囲の距離情報を取得する。本研究では装置を中心とする中心角 270 度の扇型の平面を計測対象として、この平面と交差する物体までの距離情報を取得可能な LRF を用い、この計測平面を可能な限り検査対象面に平行に、かつ壁面と計測面の距離が可能な限り小さくなるように設置することで、打撃位置の取得を試みた。



図 4.2.4 音響センサー

AI 打検システムの計測ユニットでは、インフラ構造物の打音の検出に接触式の音響センサーを採用した。これにより道路のトンネルなど騒音の激しい場所においても低ノイズの打音検出が可能である。接触式の音響センサーは、インフラ構造物の内部を伝搬してきた打音を構造物の表面の振動を検出することで打音の採取を行う。図 4.2.4 に打音の検出に試作した計測ユニットを示す。

この計測ユニットは磁歪素子の音響センサーを使用した。また、接触式の音響センサーに隣接して、補助的に空気伝搬の打音を検出する音響センサーとして コンデンサーマイクを実装した。これにより従来の場合と同様の打音を取得可能であり、接触式の音響センサーによる打音と補完的に使用することが可能である。

タブレット型デバイスを用いての打撃位置表示部は現場で手に持って利用することができることから、たたき残しを防止することができるなど極めて有用性が高い。一方でキーボードやマウスを用いての操作はできないため、ユーザーインターフェースの設計には注意を要する。そこで、利用者が慣れているであろうスマートフォンでの操作を参考にし、基本的には指による操作だけで計測結果表示範囲の移動・拡大・縮小が可能な操作系を実現した。離散的な打撃を行うハンマーと連続的な打撃を行う打診棒の計測結果は、モードを分けて表示することでより直感的な表現で可視化できるようにした。ハンマーモードでは打撃点の再現を重視し、画面中に黄色のスポットを打撃位置として表した。リアルタイム検出、またはオフラインの記録再生で打撃点が順番に描画される (図 4.2.5 参照)。AI 打検システムによる検査結果についても、AR 可視化システムをベースにして、ハンマーの打撃を映像に重ね合わせて AR で提示する手法を実装した (図 4.2.6 参照)。

AR 表示を実現するためにはある程度の距離を確保して実環境撮影用のカメラを設置する必要があることから、適用可能な現場に制約はあるが、検査壁面の後方にカメラを設置することができれば、録画映像の上にハンマーの打撃点を表示して、より現場の状況を把握しやすい、システム評価しやすい環境を構築することができる。

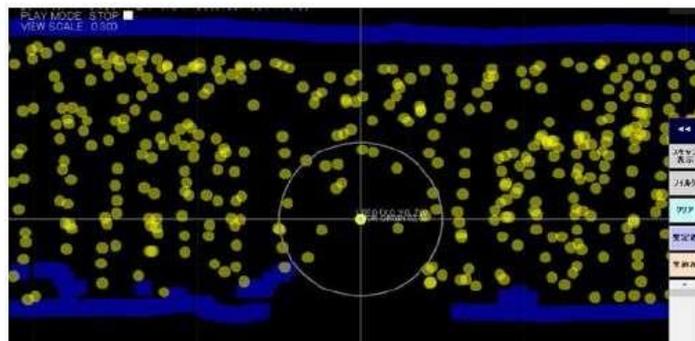


図 4.2.5 ハンマーモードで可視化



図 4.2.6 ハンマー打撃の AR 提示

(3) その他

今回開発した AI 打検システムは、点検ハンマーによる打音の違いを機械学習し、構造物の異常箇所と異常の度合いを自動検知することができた。検知結果を点検員にリアルタイムで提示するとともに、点検ハンマーの位置情報と統合して異常度マップを自動的に作成することが可能となり、これにより図面化を含めた作業工数が削減できる。

今後は、打音をその位置情報とともに記録できるため、計測ユニット自体の絶対位置情報を取得できれば、点検データと構造物の三次元点群データや測量データとの統合管理することが可能となる。現在、4.1 で説明した首都高速道路が開発した InfraDoctor と連携させ、絶対位置情報の取得法などの検討を進め、活用範囲を広めていく予定である。また、実構造物での実証試験を重ね、本システムの完成度を高めていく。さらに図 4.2.7 に示すような高所打検機も現在開発中であり、コンポーネントの組み合わせにより AI 打音システムの有効性の幅を広げることも検討中である。



図 4.2.7 高所打検機（コンポーネント組合せ）



図 4.2.8 版型音響取得機設置状況

4.2.2 高感度近赤外線分光を用いたインフラの遠隔診断技術の研究開発⁶⁾

(1) 研究の概要

コンクリートの劣化診断を行う手法の多くは、コンクリート構造物に近接して点検する必要があり、それに必要な足場の設置に多大な時間と費用とがかかることが課題である。そのため、足場を設置せずに遠方からコンクリートの状態を把握し、足場を設置しての点検の回数を減らす、または点検箇所を限定するための1次スクリーニング技術が求められている。

現在、実用化されている遠方からのコンクリート診断技術は、破損箇所やクラックを検出する視覚的劣化と、赤外線サーモグラフィーのみである。一方、中性化などの化学的な劣化や、塩分などの劣化因子の付着に関しては、遠方からの観測技術が存在しない。そこで、本研究では、化学的な劣化を遠方よりスクリーニングするインフラ遠隔診断技術を開発した。近年、赤外分光法を用いて化学劣化を計測することが可能であることが魚本氏らによって報告された。しかし、現状の近赤外線分光法では、分光器の検出感度が低く、3m以上の遠方から劣化診断を実現するため、インラインマルチチャンネルフーリエ分光による高感度近赤外分光技術を開発した（図4.2.9参照）。近赤外分光分析に基づく、フィールド計測用コンクリート分析装置を試作開発した。

2016年10月に、この試作機を用いて実施したデモンストレーションでは、東品川栈橋のコンクリート桁を測定対象とし、約6メートル離れた位置からの測定を行った。各測定箇所（直径10cmのエリア）において、塩分・水分などが同時に露光時間約20ミリ秒で計測され、自動的に計測箇所が可視カメラ画像上に5段階でマッピングされていく。喫水界面および喫水面で塩化物が多く検出され、実環境に即した結果が得られている（図4.2.10参照）。

定量性の評価のため、各評価用供試体を作製して検証を行った。検証濃度は実際の自然環境下に設置されたコンクリートに合わせており、20%程度の精度での定量が可能であることが確

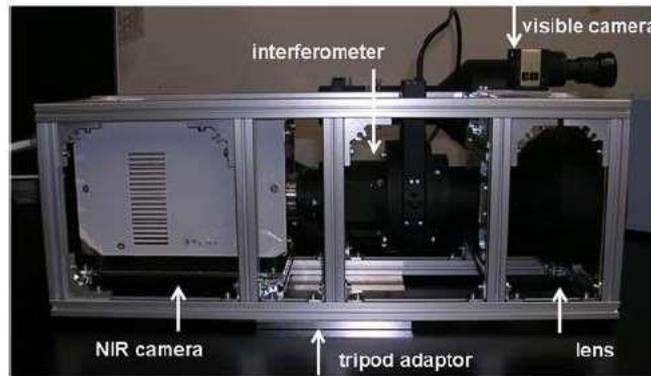


図 4.2.9 計測装置外観

認められた。本研究は1次スクリーニングに用いられることを想定して開発を進めており、コア抜き調査や供試体試験片設置の目安となるように、広いエリアにおける濃度分布（コンター図）が描けるようにソフトウェア設計を行っている。

表面の塩化物イオン濃度に分布が生じている供試体（W/C = 50%モルタル製，D40×W30×H20 cm，塩分濃度分布2水準）を製作し，定量分析のスタンダードとして用いられている蛍光X線で分析した結果と比較を行った。近赤外分光システムが蛍光X線と同様の結果を出すことを示している。蛍光X線では装置を壁面に密着させる必要があり，測定に数分の時間がかかるため中央部のみの測定であるが，高感度近赤外分光で離れた位置から高速に分析できることが確認できた（図4.2.11参照）。

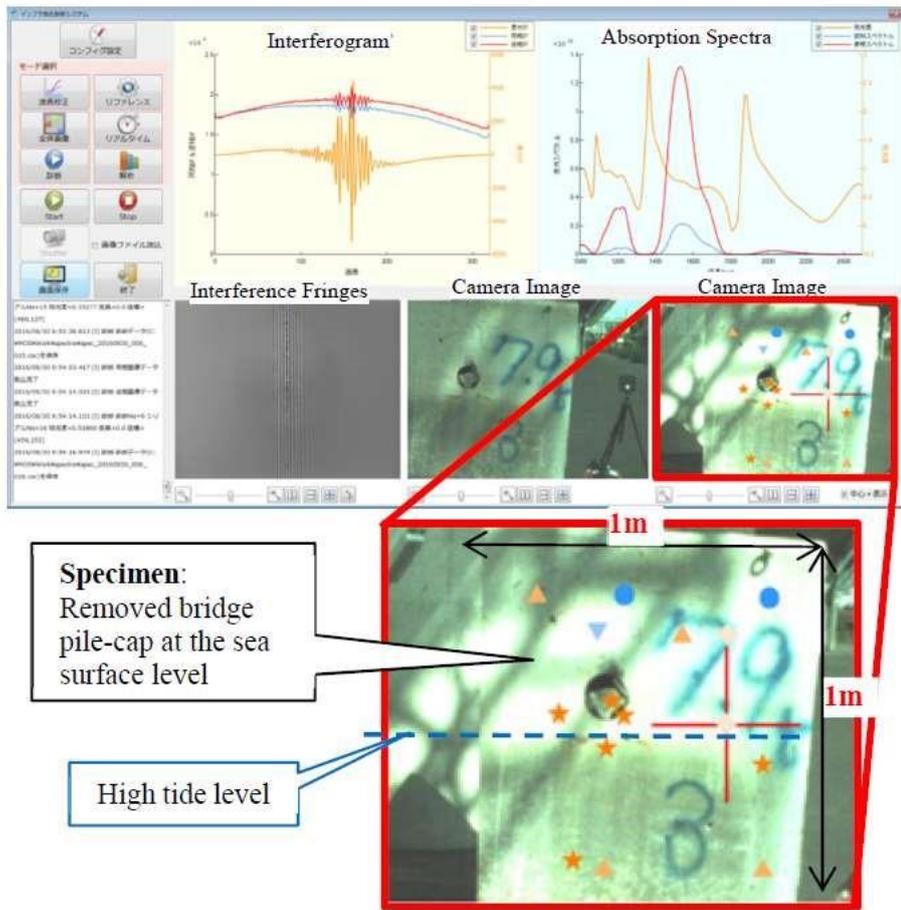
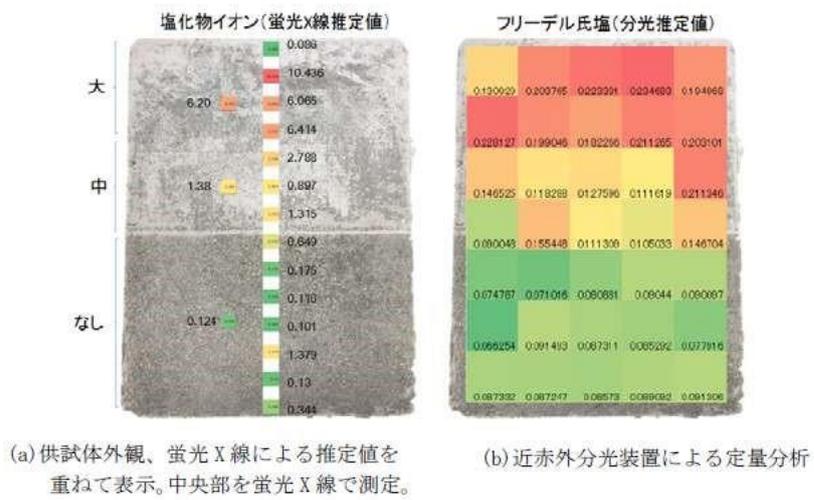


図 4.2.10 東品川撤去桁の計測結果表示



(a) 供試体外観、蛍光 X 線による推定値を重ねて表示。中央部を蛍光 X 線で測定。
 (b) 近赤外分光装置による定量分析

図 4.2.11 東北大学提供の供試体を用いた定量分析

(2) 研究テーマの中の AI の活用

現時点では、分析結果に対してAIの適用は実施していないが、今後データを蓄積、学習させることにより、精度向上が期待できるものとする。なお、本技術については、4.1で述べた*i-DREAMs*の中で、他の要素技術と組み合わせたAIエンジンの開発を進めている。

例えば、本技術の分析結果と点群データによるコンクリート表面の剥離状況や画像解析技術によるひび割れ状況のデータ等を組み合わせて、コンクリートの劣化状況を把握するものである。これにより、塩害や中性化を受けたコンクリート構造物に水が侵入することにより鉄筋が腐食し、コンクリートの表面にひび割れや剥離が発生している現象を把握できるようになる。この結果、点群データからコンクリート表面の剥落の可能性を把握して、緊急対策を実施することに加え、事前に原因の分析も可能となることから恒久対策についても同時に検討でき、必要であれば緊急対策時に適切な対策を実施することも可能となる。現在、供試体により、教師データを蓄積しているところである。

このように、本技術の分析精度を向上させるためAIを活用することに加え、他の要素技術等と組み合わせることにより、より広範にかつ劣化状況の原因分析の把握に適用を拡大することも可能と考える。

(3) その他

上記(2)に述べたとおり、AIを活用することにより本技術の適用をより広範囲に拡大することが可能と考えられるが、以下に本技術の活用案について記す。

1) 事後保全的活用：

橋梁等のコンクリート構造物における被りコンクリートの剥落、鉄筋の腐食などの変状が発見された場合、塩害の可能性があれば近赤外分光装置にて撮影を行い、原因の特定と影響範囲の推定に寄与する。撮影には足場の設置が不要で、調査範囲のスクリーニングによりコア抜き等の微破壊検査を最小限とすることができるため、補修範囲および工法の選定、工事計画立案を短時間かつ安価で正確に実施することが可能である。

2) 予防保全的活用：

定期点検に本技術を取り入れ、変状が発生する前に影響を検知、早期に対策を行うことによりライフサイクルコストの削減に資する。具体的には、塩害の可能性のある地域または使用状況下における橋梁等コンクリート構造物において、例えば年に一回程度近赤外分光システムによる点検を行い、塩害の初期における進展を分析する。これにより、飛来塩分量の多い箇所では洗浄や被覆により塩分の浸透を抑制し、また橋面上における凍結防止剤としての塩化ナトリウム散布の影響が確認された箇所については、事前にジョイントの止水対策や配水管の変状補修などにより、塩害の進展を抑制できる。

4.3 今後の展望 ^{7),8),9)}

新たなインフラマネジメントシステム (*i-DREAMs*) の概要を 4.1 に述べたが、これは GIS を基本とするプラットフォーム (*InfraDoctor*) に CIM (Construction Information Modeling) を統合したものであり、これにより効率的な構造物の維持管理を行うことが可能となる。すなわち、CIM により調査・設計、施工段階の各種データ (初期情報 (initial condition)), 例えば、地質調査・試験データ、設計条件、設計モデル、使用材料、材料試験結果、3D-CAD 図面、施工条件、製作要領、製造管理、出来形等をデジタルデータとして蓄積することができる。また、これらの初期情報に加え、点検や詳細調査から得られる結果や補修・補強等の履歴情報を維持管理段階のデータ (境界条件 (boundary condition)) がシステムに蓄積される。さらに、必要に応じてセンサー等から得られるモニタリングデータをインターネット経由で、リアルタイムにシステムに蓄積することができる。これにより、建設、維持管理段階の各種データが当該プラットフォームに統合され、これまでは個別に管理されていた各種情報を総合的に扱うことが可能となり、課題の「見える化」が図られる。

この結果、トレーサビリティ機能の向上にも資することになる。すなわち、構造物の計画、設計から施工、維持管理にいたるまでの工程を記録し、後工程の段階で、その記録をたどって追跡できるようになる。例えば、構造物の施工段階において問題が発覚した場合、計画・設計段階のデータベースから、どのような調査が行われ、計画・設計がなされたのか、また、維持管理段階で問題が発覚した場合、どのような材料が選定されたのか、どのような施工がなされたのか、配筋は、コンクリートの打設状況は等々、後からトレースが可能となる。このようにバックトレースすることにより、問題の真因を的確に突き止めることができるようになる。また、同種あるいは類似の材料、構造、施工等の実績を検索することも可能となる。このようなトレーサビリティの向上は、問題が発覚した場合、より迅速に対応を前工程に伝えるとともに、同様の問題の発覚を未然に防ぐことも期待できる。

このように統合された初期条件および境界条件等のビックデータに対して AI (ディープラーニング、機械学習) エンジンを用いて処理することにより、異常の兆候パターンを迅速かつ定量的に把握することも可能となる。これにより、変状の評価や劣化の推定が大幅に効率化される。すなわち、過去の点検・診断結果、変状事例や不具合事例等から、AI により異常の発現可能性を検出することが可能となり、劣化、変状の 1 次スクリーニングとして機能する。最終的には、技術者が蓄積されるビックデータの内容を正しく理解、判断し、最適解を導く。このように、従来、個別に管理されていたデータベースをプラットフォーム上に統合し、AI を活用することにより、分析、診断・評価の精度向上を図ることができる。

ただし、データ蓄積で注意すべきことは、とにかく多くの情報を蓄積、統合すれば最適解が得られるということではない。インフラの所有者や管理者が、現場ベースのニーズを軸としてインフラの維持管理に必要な属性情報 (本稿ではこの情報をビックデータと定義する。) を設計、

施工、維持管理の各段階で適切に選定し、設計者や施工者に明確に仕様書等で示すことが必要かつ重要となる。

さらに、CIMで作製される3Dモデルあるいは点群データから生成される3Dモデルを用いて、解析ソフトによりシミュレーションすることで、インフラの構造性能の適切な評価、不具合発生メカニズムの解明、構造物全体あるいは部材単位の劣化を予測することも可能となる。なお、解析にあたっては、プラットフォーム上に統合されている初期情報（初期条件）に加え、様々な点検、非破壊検査等から得られる維持管理情報（境界条件）を適切に用いることにより、解析精度を格段に向上させることが期待できる。以上述べたとおり、初期情報に加え、三次元点群データ、各種点検技術等から得られる結果をIoTを活用することにより、フィジカルな世界から各種情報をデジタルプラットフォームに統合し、さらにこれらの結果を分析・解析する技術や3Dモデリングに加え、このビッグデータにAI等を適用することで、どのタイミングでどのようなメンテナンス（補修や補強）を実施すべきか予測することも期待できる。即ち、従来の事後保全から予防保全、予測保全へと進化させ、画一的な耐用年数や標準的な劣化曲線による統計的な推測ではなく、作用や供用環境の異なる構造物毎にその劣化の進行度、変状状況を高精度に評価、予測ができるようになる。この結果、タイムリーで的確な維持管理を行うことにより、ライフサイクルコストの最適化を実現することが期待される。

このようにICTを活用して計画・設計段階から施工、維持管理段階までの全体のプロセスが一つのシステム上に「つながる」ことにより、シームレスなインフラマネジメントシステムを構築することができる。このシステムから得られる点検・診断、補修・補強の結果、蓄積された経験（暗黙知）や技術（形式知）を、将来のインフラの整備に活かすことも忘れてはならない。すなわち、こうした維持管理段階で得られる知見を新設構造物の建設および既設構造物の補修・補強設計や施工にフィードバックすることにより、高品質で高耐久性能を有し維持管理性能に優れたインフラを建設することが可能となる。イニシャルコストの最小化ではなく、ライフサイクルコストを最小化し安全なインフラの整備および戦略的な維持管理を実践することにより、持続可能な社会の実現が期待される。

さらにインフラマネジメントシステムの開発には、維持管理の技術に加え、通信技術（5G、クラウド）をはじめ各種センシング技術（MEMS等）、ロボティクス、画像解析技術、分析・解析技術、人工知能（AI）等、異分野の様々な技術の統合（Integration）と融合（Fusion）が重要である。なお、IoTの活用にあたっては、セキュリティー技術も重要な要素であり、この分野での技術開発も求められる。

現代はデジタル革命第3期と呼ばれ、IoT化の進展とAI技術の進化によって、デジタルの世界で実現する機能がフィジカルな世界でも、広範囲に影響を及ぼす可能性がある。すなわち、フィジカルな空間（現実空間）から膨大な情報がサイバー空間（仮想空間）に集積され、サイバー空間では統合されたビッグデータをAIが解析し、その解析結果がフィジカル空間の人々やインフラに様々な形でフィードバックされる。このように、サイバー空間とフィジカル空間を高度に融合させたシステム、Society5.0が実現され、これまでにはなかった新たな価値が創造される。

時代の大きな転換期を迎え、いっそうの異分野技術のハードウェアとソフトウェアの融合、コンバージェンスの推進が求められる。新たなインフラマネジメントシステムを開発することにより、従来の枠組みを超えた技術革新、すなわちこれまでの延長線上にある連続で直線的な改革から、不連続（Discontinuous）で指数関数的な改革へと異次元の進化を遂げ、生産性を大幅に高めることが期待できる。このようなパラダイムシフトに積極的に取り組み、これまで培ってきた経験（暗黙知）や技術（形式知）を未来型のインフラマネジメントへと進化させることが今求められている。

参考文献

- 1) 土橋浩, 長田隆信, 神田信也: 首都高速道路のスマートインフラマネジメントシステム i-DREAMs®, 土木技術資料, 平成 30 年 10 月.
- 2) SIP/インフラ維持管理・更新・マネジメント技術/点検・診断技術の実用化に向けた研究開発, 学習型打音解析技術の研究開発: 平成 26 年度~平成 29 年度成果報告書, 平成 30 年 2 月.
- 3) 窪田裕一, 由井稔也ほか: コンクリート構造物の打音法における異音検出の基礎的実験, 第 69 回年次講演会, V-484, 土木学会.
- 4) Yuichi Kubota, et al : Proceedings 30th US-Japan Bridge Engineering Workshop, PP105-114, 2014.
- 5) 窪田裕一, 由井稔也ほか: コンクリート構造物の打音解析に基づくトンネル調査, 第 70 回年次学術講演会, V-030, 土木学会.
- 6) SIP/インフラ維持管理・更新・マネジメント技術/点検・診断技術の実用化に向けた研究開発, 高感度近赤外分光技術を用いたインフラの遠隔診断技術の研究開発: 平成 26 年度~平成 28 年度成果報告書, 平成 29 年 3 月.
- 7) 土橋浩, ICT 技術の活用によりシームレスなインフラマネジメントの創出 橋梁と基礎, 1月号, Vol.50 2016, 建設図書.
- 8) 熱血ドボ研 2030, 新設コンクリート革命 長持ちするインフラの作り方, PP213-232, 2017, 日経 BP.
- 9) 土橋浩: 革新的インフラマネジメントシステム (i-DREAMs®) の開発, 橋梁と基礎, 8月号, Vol.51 2017, 建設図書.

5. 画像・空間分布データを用いたプロジェクトチームによる横断的な取組み

本章では、まず、5.1に画像・空間分布データの取り扱い方の概要について記し、5.2においてはプロジェクトチーム内で提供されたデータ（電源開発(株)）を用い検出精度の確認を実施した。5.3は、SIP研究者から提供を受けたデータ（SUSTERA：高温超伝導磁気センサ，2.4参照）について、SIP研究者と連携をとり、AIの適用性についてプロジェクトチームで検討した結果を示す。

5.1 画像・空間分布データ取り扱いの基礎的な方法

5.1.1 深層学習による画像認識

画像等、空間的に広がりを持つデータから何らかの意思決定を行う際、画像を如何に処理するかが重要となるが、静止画像や動画を扱うコンピュータビジョンの分野では、ほぼすべての問題解決に深層学習が利用されるようになってきている。深層学習が現在のように大きな注目を集めるきっかけになったのは、2012年に開催された大規模画像認識のコンペティション ILSVRC（ImageNet Large Scale Visual Recognition Challenge）である。その年に、深層学習による手法で圧倒的な成績で優勝し、画像認識に対するこれまでのアプローチを覆した。2012年以降のコンペティションでは、常に深層学習が良い成績を収めている。

深層学習は大量のデータを学習することで高い成果を挙げることが知られているが、与えられた情報の中で、システム自体が特徴を選択し、自動的にデータから分類や認識に最適な特徴を抽出する。これが従来の機械学習と異なる点である。図 5.1.1 に示すように、従来の機械学習手法は、物体認識に寄与すると考えられる特徴を、画像処理を駆使して人手で抽出することからはじまり、得られた特徴量を適切な機械学習の手法を選定し、それに入力することで結果を得てきた。

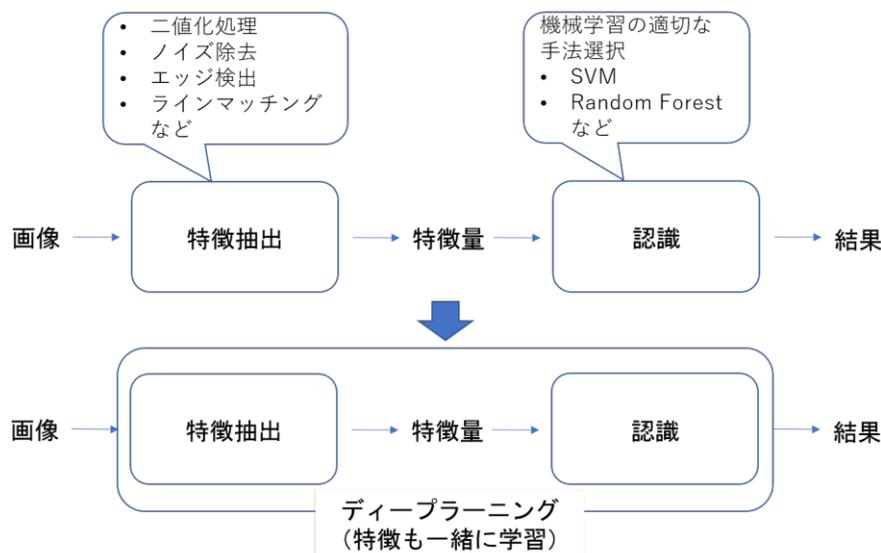


図 5.1.1 特徴抽出に対する変遷（上：従来型 AI，下：深層学習）

一方、深層学習を利用する場合は、人間の経験や勘による特徴抽出を行うことなく、End-to-Endで、自動的にこれらを行うことから、これまで把握できていない新たな特徴を見出す可能性があるとも言える。画像を扱う場合の深層学習の利用形態は多岐に渡るが、インフラ点検・維持管理に用途を絞ると、代表的には、物体認識（画像に移る物体は何か）、物体検出（画像内のどこに何が写っているか）、形状認識（セマンティックセグメンテーション、ピクセル単位での物体認識）、画像生成、超解像技術などが利用可能であると考えられる。ただし、これらの開発の成否はネットワーク構築のための事前に与える学習データの確保であり、大規模なほど成功する可能性が高いと言われている。以下に、SIP の中でも利用されている物体検出技術のうち、先駆けとなった R-CNN (Regions with CNN features)¹⁾の概要と、2018年10月現在、最も高精度・高速度に物体検出を行えるシステムの基礎となる YOLO (You Only Look Once) についてのみ簡単に紹介する。

5.1.2 R-CNN の概要

深層学習を用いた物体検出技術の先駆けとなった R-CNN は、与えられた画像の中から、オブジェクトらしい候補領域を多数選び出して、オブジェクトの各クラス確率を算出し、大きい確率の候補領域を出力するものである（図 5.1.2）。ただし、1枚の画像の中の候補領域は数千にもおよぶ場合があり、その一つ一つの領域に対して畳み込みニューラルネットワークによる推測を行うことは、膨大な時間が掛かる恐れが生じる。例えば、動画等は1秒間に30あるいは60フレームの画像があることから、リアルタイム処理は極めて困難となることが知られている。

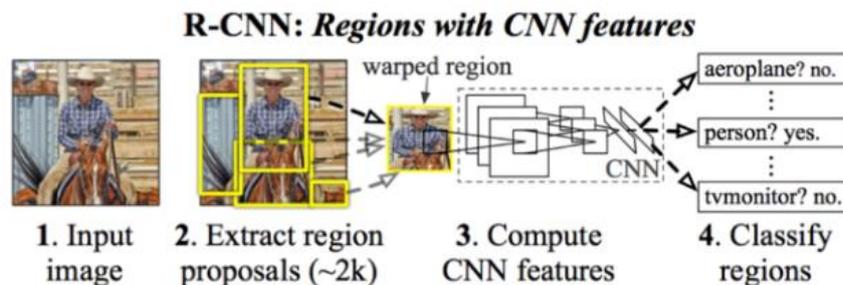


図5.1.2 R-CNNの物体検出手順（文献1の図1より）

5.1.3 YOLO による方法

これに対し、近年、リアルタイム処理が可能な YOLO²⁾⁴⁾というフレームワークが登場し、その後、YOLOv2, YOLOv3 と更新が進み、物体検出の速度・精度が大きく向上した。これらの YOLO 系システムはC言語で作成されたフレームワーク Darknet の一機能として提供されているもので、物体検出に関しての YOLO の大きな特徴は、検出対象オブジェクトの候補領域の切り出しとその候補領域のクラス確率の算出を一回の推測で同時に行う点にあり、このことで、R-CNN やその後続の方法⁵⁾⁶⁾と比較して、非常に高速に物体検出を行うことを可能としている。また、動画に対しても実時間で物体検出を行うことができる。

図 5.1.3 に YOLO の推論手順を示す。まず、入力画像を $S \times S$ のグリッドセルに分割することから始まる。各グリッドセルは、図 5.1.4 に示すような複数の bounding box を持ち、それらの box に対する信頼度 (Confidence) を以下のように計算する。

$$\begin{aligned} \text{Confidence} &= \text{Pr}(\text{Object}) \cdot IOU_{pred}^{truth} \\ IOU_{pred}^{truth} &= \frac{|B_i \cap \text{ground_truth}|}{|B_i \cup \text{ground_truth}|} \end{aligned} \quad (5.1.1)$$

ここで、 $\text{Pr}(\text{Object})$ は、bounding box が何らかの物体を含んでいる確率であり、 IOU_{pred}^{truth} (Intersection Over Union) は、学習時には、グリッドセルから予測される bounding box (B_i) と実際に教師データとして与えた画像内のオブジェクト (ground_truth) との重複の割合である。図 5.1.5 は、教師データとしてひび割れを検出対象のオブジェクトとした場合の ground_truth とグリッドセルから予測される bounding box (B_i) の例を示している。

信頼度とは、bounding box が何らかの物体を含んでいる確率 $\text{Pr}(\text{Object})$ と、bounding box と ground_truth の重複割合 IOU の積として構成される。もし、着目しているグリッドセル内に検出対象オブジェクトが存在しない場合は、それぞれの bounding box には、そのオブジェクトが存在しないことから信頼度は 0 になる。また、それぞれの bounding box は信頼度に加えて、YOLO 内で予測された、自身の中心座標 (x, y) と大きさ (height, width) を保持する。一方、グリッドセルは、検出対象オブジェクトが自分自身のグリッドセル内に含まれるか否か、条件付きのクラス確率 $\text{Pr}(\text{Class}_i | \text{Object})$ を持つ。例えば、図 5.1.4 の着目グリッドセルは、 $\text{Pr}(\text{犬} | \text{Object}) = 0.92$, $\text{Pr}(\text{車} | \text{Object}) = 0.05$, $\text{Pr}(\text{自転車} | \text{Object}) = 0.03$ 等の値を持つ。例えば、文献に示される PASCAL VOC では、画像を 7×7 のグリッドセルに分割し、それぞれのグリッドセルが信頼度の高い 2 個の bounding box を出力し、信頼度の大きさに応じて図 5.1.3 内の bounding box + confidence のように太さで表現する。最後に、閾値を超える信頼度を持つ bounding box だけを採用する。そして、採用された bounding box と対応グリッドセルにおいて最も確率の高いクラスと結合して、bounding box のクラスを決定する (図 5.1.3 内 final detection)。なお、bounding box は、学習の初期段階では一定のアスペクト比でランダムに配置される。ただし教師データの学習を重ねていくと、回帰的アプローチにより、bounding box が適切な大きさと検出対象を囲むように配置される。

以上のように、YOLO による一般物体検出は、各グリッドセル領域に対して行うクラス分類と bounding box による物体候補の領域の検出を行う構造になっている。

学習時の損失関数や畳み込みニューラルネットワークの構造の詳細は文献²⁴⁾を参照されたい。また、これらのシステムはワシントン大学の Redmon らのサイトからコードがダウンロードできるようになっており、Web カメラからの画像を評価する方法などがまとめられている。また任意のオブジェクトを検出する際は別途、教師データを用意しなければならないが、Labellmg⁷⁾や BBOX-Label-Tool⁸⁾などのフリーソフトが利用されている。

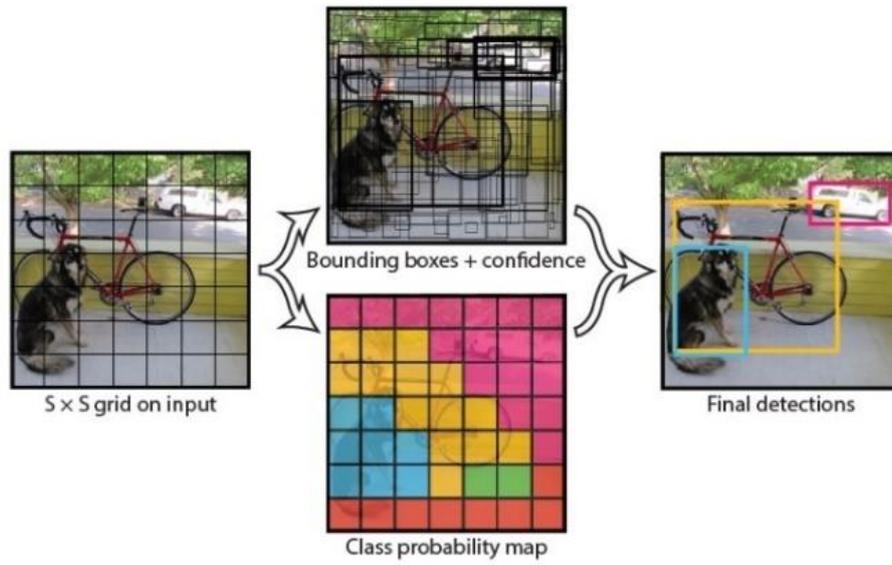


図5.1.3 YOLOの物体検出手順（文献2の図2より）

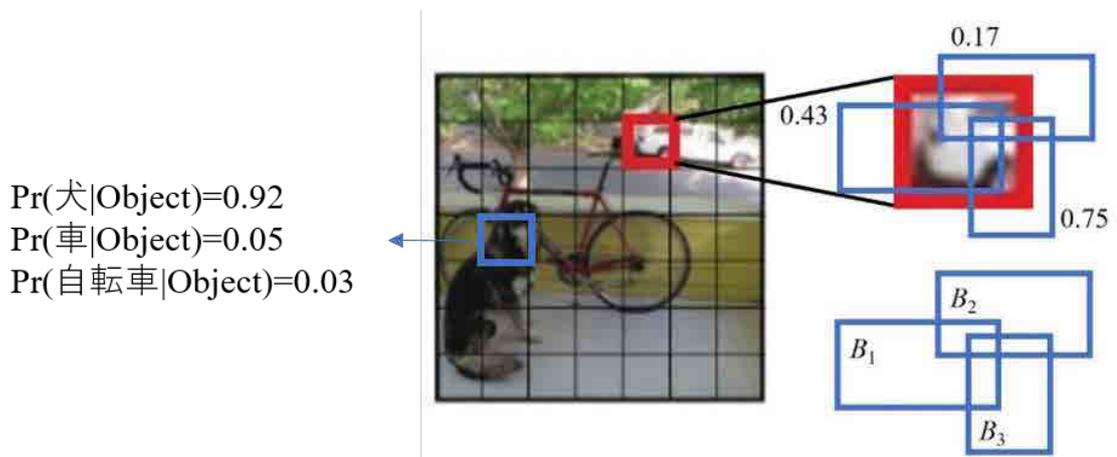


図5.1.4 bounding boxと信頼度

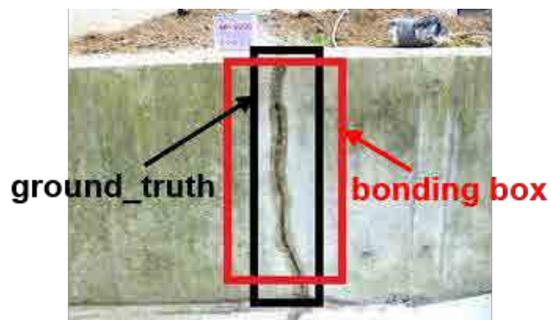


図5.1.5 IOUにおける重複例

参考文献

- 1) R. Girshick, J. Donahue, T. Darrell and J. Malik, “Rich feature hierarchies for accurate object detection and semantic segmentation”, Proc. of the IEEE conference on computer vision and pattern recognition, pp.580-587, 2014.
- 2) J. Redmon, S. Divvala, R. Girshick and A. Farhadi, “You only look once: Unified, Real-Time, Object detection”, arXiv preprint arXiv:1506.02640v5, 2016.
- 3) J. Redmon and A. Farhadi, “YOLO9000: Better, Faster, Stronger”, arXiv preprint arXiv:1612.08242v1, 2016.
- 4) J. Redmon and A. Farhadi, “YOLOv3: “An Incremental Improvement”, arXiv preprint arXiv:1804.02767v1, 2018.
- 5) S. Ren, K. He, R. Girshick and J. Sun, ”Faster R-CNN: Towards Real-time object detection with region proposal networks”, Proc. of Advances in neural information processing systems, pp.1-10, 2015.
- 6) W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.Y. Fu and A.C. Berg, “SSD: Single Shot MultiBox Detector”, arXiv preprint arXiv: 1512.02325v5, 2016.
- 7) Tzutalin. LabelImg. Git code (2015). <https://github.com/tzutalin/labelImg> (2018年10月11日閲覧)
- 8) <https://github.com/puzzledqs/BBox-Label-Tool> (2018年10月11日閲覧)

5.2 深層学習を用いたデジタル画像からのコンクリート表面変状の検出

5.2.1 はじめに

従来、コンクリートのひび割れを画像処理により検出する研究が数多くなされてきている。初期は、輝度値に着目した様々な手法が提案されたが、画像処理における閾値の設定に専門的な知識が必要であり、明暗など外部環境の違いに対してロバスト（頑健）でないなどの問題点が指摘されていた。その後、機械学習によるひび割れ検出手法が多く研究者らによって提案され、以前よりは良い結果が得られるようになったが、特徴量の選択を人間が行う必要があり、最適な特徴量の選択を行うことが困難であった。現在、深層学習の出現により、特徴量選択が不要になったことから、ひび割れなどのコンクリートの変状の自動検出に関する研究が行われ、従来の機械学習手法より高い正解率が得られるようになった¹⁾⁵⁾。

一方、大量の画像データから人や犬、自動車などの一般的な物体を検出する深層学習モデルが AI 研究者らによって開発されている。代表的なものに、R-CNN (Region-based Convolutional Neural Network)⁶⁾、Faster R-CNN⁷⁾、SSD (Single Shot multibox Detector)⁸⁾、YOLO (You Only Look Once)⁹⁾などがある。最近では、こうした既存の深層学習モデルに転移学習や Fine Tuning を用いて、橋梁の変状、道路の複数の種類のひび割れ、建設機械や建設作業員などの検出に関する研究が行われ、それほど大量のデータがなくても比較的良好な検出結果が報告されている¹⁰⁾。

そこで本項では、既存の深層学習モデルの一つである YOLO v3 に一般的な物体の大規模データセットである ImageNet を用いて学習させた重みをベースに、コンクリートの 5 種類の変状（ひび割れ、鉄筋露出、遊離石灰 c、遊離石灰 d、遊離石灰 e（図 5.2.1～5.2.5））を Fine Tuning を用いて学習させ、検出精度の確認を実施したので報告する。

5.2.2 学習および検出精度評価の方法

本研究では、データセットとして既設のコンクリート構造物のデジタル画像を主に用いた。収集した画像に対して labellmg¹¹⁾と呼ばれるツールを用いて、画面上でひび割れや遊離石灰などの変状部分を各々矩形で指定し、その部分の変状種類を XML ファイルに記載してラベルとした。図 5.2.6 に labellmg の操作画面の例を示し、図 5.2.7 に XML で記載されたラベルのファイルの例を示す。データセットは、Training 用、Validation 用、Testing 用の三種類を用意した。Training 用のデータは、重みの更新に利用するデータである。Validation 用のデータは重みの更新には利用しないが、過学習を起こしていないか、学習時にチェックするために利用するデータである。Testing 用のデータは、重みの更新には利用せず、精度評価を行う時に利用するデータである。Validation 用と Testing 用のデータは、全てのデータから約 1 割の割合になるように、ランダムに選択した。尚、過学習になる確率を減らすために、画像を回転、反転などすることによりデータセットの分量を増やす Data Augmentation を実施した。表 5.2.1 に各データセットの個数を示す。



図 5.2.1 ひび割れの例



図 5.2.2 鉄筋露出



図 5.2.3 遊離石灰 c



図 5.2.4 遊離石灰 d



図 5.2.5 遊離石灰 e

写真提供：電源開発株式会社他



図 5.2.6 labelImg の操作画面の例

(画像では遊離石灰 d のデータの位置を矩形で指定している)

```

1 <annotation>
2   <folder>dataset</folder>
3   <filename>image004615.jpg</filename>
4   <path>/Users/anai/Desktop/dataset/image004615.jpg</path>
5   <size>
6     <width>700</width>
7     <height>525</height>
8     <depth>3</depth>
9   </size>
10  <object>
11    <name>free_lime_d</name>
12    <bndbox>
13      <xmin>239</xmin>
14      <ymin>120</ymin>
15      <xmax>350</xmax>
16      <ymax>331</ymax>
17    </bndbox>
18  </object>
19 </annotation>

```

図 5.2.7 XML ファイルの例

表 5.2.1 作成したデータセットの内容

Class	All	Training	Validation	Testing
	Number of objects	Number of objects	Number of objects	Number of objects
Crack	985	791	93	101
Bar	773	612	93	68
Free lime c	309	260	28	21
Free lime d	2017	1621	211	185
Free lime e	765	628	63	74
Number of Images	2308	1870	208	230

深層学習モデルの一つである YOLO はワシントン大学の Redmon らによって開発され、YOLO v2, YOLO v3¹²⁾と改善されてきており、本研究では現時点で最新の YOLO v3 を用いた。深層学習モデルを実装するための開発環境や利用したライブラリについては、表 5.2.2 に本研究で利用した開発環境を、表 5.2.3 に利用したライブラリを示す。

表 5.2.2 システムの開発環境

CPU	Intel (R) Xeon 6-Core E5-1650V4 3.5GHz
メインメモリ	128GB
GPU	GeForce GTX 1080 Ti, memory speed:11Gbps, memory:11GB
OS	Ubuntu 16.04 64-bit
使用言語	Python 3.6.3

表 5.2.3 使用したライブラリ

ライブラリ名	バージョン	概要
Keras	1.2.2	<ul style="list-style-type: none"> Deep Learning フレームワークの1つ Deep Learning モデルの記述に使用
TensorFlow-gpu	1.2.1	<ul style="list-style-type: none"> 機械学習ライブラリの1つ Keras のバックエンドとして使用
Numpy	1.14.5	<ul style="list-style-type: none"> 数値計算用ライブラリ データセットをテンソルとして扱うために使用
Opencv	3.4.1	<ul style="list-style-type: none"> 画像処理を行うためのライブラリ 画像の読み込み, 出力結果の描画に使用

テストデータを用いて、学習して Fine Tuning を施した YOLO v3 の変状検出精度を求めた。精度の指標としては、深層学習の物体検出に一般的に用いられている mAP(mean Average Precision)¹³⁾、¹⁴⁾ を用いた。mAP は AP の平均値であり、AP は式 (5.2.1) ~ (5.2.3) を用いて求められる。各テストデータの変状に対して、正解領域と予測領域を矩形で求め、式 (5.2.1) で求めた IoU が 0.5 以上であり、変状種類が正解である場合は TRUE、さもなくば FALSE と判定する。詳細は文献¹³⁾を参照されたい。

$$IoU(\text{Intersection over Union}) = \frac{\text{area}(B_p \cap B_{gt})}{\text{area}(B_p \cup B_{gt})} \quad (5.2.1)$$

ここに

B_p : Predicted bounding box (予測領域)

B_{gt} : Ground truth bounding box (正解領域)

$$\text{Precision} = \frac{TP}{TP + FP} = \frac{TP}{\text{Number of detections}} \quad (5.2.2)$$

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{TP}{\text{Number of ground truths}} \quad (5.2.3)$$

ここに

True Positive(TP) : The number of detection with $IoU \geq 0.5$

False Positive(FP) : The number of detection with $IoU < 0.5$

False Negative(FN) : The number of ground truth not detected

5.2.3 学習と検出精度評価の結果

深層学習では、学習の際に物体検出結果が正解とどの程度離れているかを損失関数によって計算し（その結果を Loss と呼ぶ）、その値を用いて最適化アルゴリズムにより重みの更新を行う。この作業の繰り返しが学習であり、全ての Training Data を用いて重みの更新を一度行うサイクルをエポックと呼ぶ。また、過学習をチェックするために各エポックにおいて Validation Data を用いて損失を求め、その結果を Val_Loss と呼ぶこととする。

YOLOv3 を用いて学習させたところ、エポック数 100 に対して、学習時間は 3.47 時間となり、エポック当たりでは、125 秒となった。図 5.2.8 に学習時に得られたエポックと Loss および Val_Loss の曲線を示す。エポック 20 くらいで Loss も Val_Loss も小さくなり、それよりエポックを増やしても損失は小さくなっていないことから、エポック 100 で十分学習ができており、過学習もないと判断される。

最後に、学習させた YOLO v3 のモデルに Testing Data を入力して変状検出精度を求めた。図 5.2.9～5.2.12 に各変状の検出サンプルを示す。変状検出精度の結果を表 5.2.4 に示す。

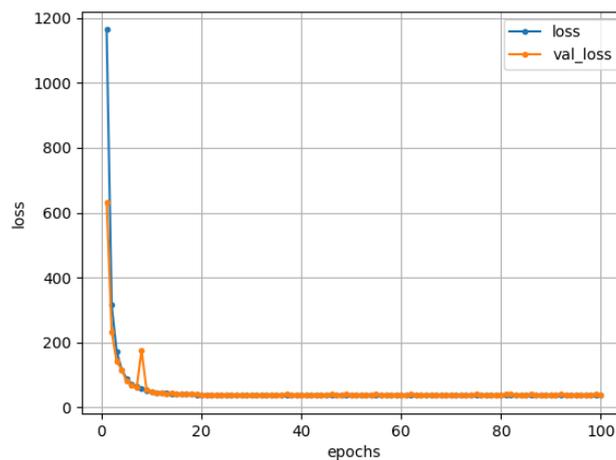


図 5.2.8 YOLO v3 に学習させた際に得たエポック／損失曲線



図 5.2.9 ひび割れの検出例 (YOLO v3)



図 5.2.10 鉄筋露出の検出例 (YOLO v3)



図 5.2.11 遊離石灰 c の検出例 (YOLO v3)



図 5.2.12 遊離石灰 d, e の検出例 (YOLO v3)

表 5.2.4 YOLO v3 の変状検出精度評価

変状の種類	Average Precision (%)
ひび割れ	96
鉄筋露出	95
遊離石灰 c	90
遊離石灰 d	80
遊離石灰 e	95
mAP (mean Average Precision)	91.1

5.2.4 結論

既存の深層学習モデルの一つである YOLO v3 に一般的な物体の大規模データセットである ImageNet を用いて学習させた重みをベースに、コンクリートの 5 種類の変状 (ひび割れ, 鉄筋露出, 遊離石灰 c, 遊離石灰 d, 遊離石灰 e) を Fine Tuning を用いて学習させ, 検出精度の確認を mAP を用いて行ったところ, 91.1%とかなり良い結果を得た。

参考資料

- 1) Cha, Y., Choi, W., Buyukozturk, O.: Deep Learning-based Crack Damage Detection Using Convolutional Neural Networks, Computer-Aided Civil and Infrastructure Engineering, 32, pp.361–378, 2017.
- 2) 全邦釘, 大窪和明, 三輪知寛, 嶋本ゆり: ディープラーニングと幾何学的形状判定手法によるコンクリートのひび割れ自動検出, 土木情報学シンポジウム講演集, Vol.42, 2017.
- 3) Zhun Fan, Yuming Wu, Jiewei Lu, and Wenji Li: Automatic Pavement Crack Detection Based on Structured Prediction with the Convolutional Neural Network, arXiv:1802.02208v1 [cs.CV], 2018.

- 4) Hong-wei Huang, Qing-tong Li, Dong-ming Zhang: Deep learning based image recognition for crack and leakage defects of metro shield tunnel, *Tunnelling and Underground Space Technology* 77, pp.166–176, 2018.
- 5) C. Stentoumis, E. Protopapadakis, A. Doulamis, N. Doulamis: A HOLISTIC APPROACH FOR INSPECTION OF CIVIL INFRASTRUCTURES BASED ON COMPUTER VISION TECHNIQUES, *Remote Sensing and Spatial Information Sciences*, Vol. XLI-B5, 2016.
- 6) R. Girshick, J. Donahue, T. Darrell, and J. Malik: Rich feature hierarchies for accurate object detection and semantic segmentation, in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2014.
- 7) Shaoqing Ren, Kaiming He, Ross Girshick, Jian Sun: Faster R-CNN : towards real-time object detection with region proposal networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137–49, 2016.
- 8) Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., and Berg, A. C.: SSD: Single shot multibox detector, In *European conference on computer vision*, pages 21–37, Springer, 2016.
- 9) Redmon J., Divvala S., Girshick R. and Farhadi A.: You only look once: Unified real-time object detection, *IEEE Conference on Computer Vision and Pattern Recognition*. 2016.
- 10) Nobuyoshi Yabuki, Naoto Nishimura, Tomohiro Fukuda: Automatic Object Detection from Digital Images by Deep Learning with Transfer Learning, *Advanced Computing Strategies for Engineering*, pp.3-15, 2018.
- 11) Tzutalin., “LabelImg”, github, 2015, Available from < <https://github.com/tzutalin/labelImg> >, [Accessed: 1st, April, 2018]
- 12) Redmon, J. and Farhadi, A.: Yolov3: An incremental improvement, *arXiv*, 2018.
- 13) Mark Everingham, Luc Van Gool, Christopher K. I. Williams, John Winn, Andrew Zisserman: The PASCAL Visual Object Classes (VOC) Challenge, *International Journal of Computer Vision*, 88(2), pp.303–38, 2010.
- 14) Jonathan Hui: mAP (mean Average Precision) for Object Detection, Available from < https://medium.com/@jonathan_hui/map-mean-average-precision-for-object-detection-45c121a31173 >, [Accessed: 14th August, 2018]

5.3 SUSTERA 高感度磁気検査の AI 活用

高温 SQUID 磁気センサを用いた超高感度非破壊検査装置による鋼板模擬試験体の評価結果をもとに、人工的に与えたき裂を検出できる可能性があるかどうか検討を行った。そのために用いた試験体は以下に示すものである。なお試験体や測定法、測定装置などの詳細は 2.4 節に示す通りである。

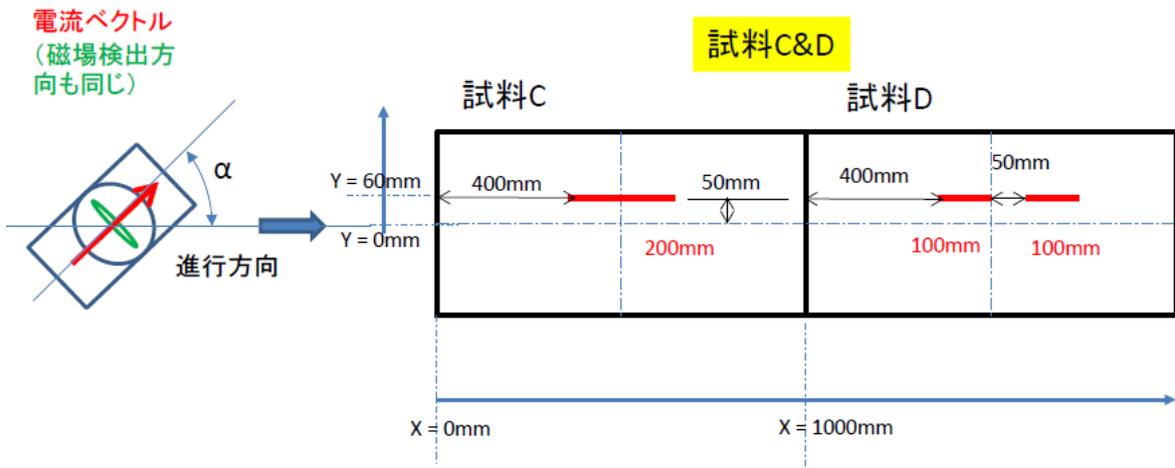


図 5.3.1 試験体 (試料)

この試験体に電磁ベクトルを与えると、例えば図 5.3.2 のような等高線図が得られる。

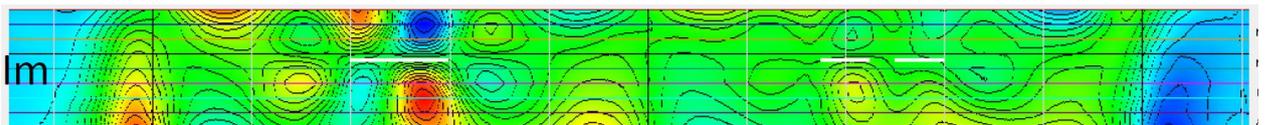


図 5.3.2 信号の等高線図

($\alpha=0^\circ$ で得られた信号について、 40° 位相を回転させた後の Im 成分)

図 5.3.2 は、励磁コイルの電流ベクトルの方向が進行方向と平行の時に得られた信号について、 40° 位相を回転させた後の Im 成分である。ここでは、励磁コイルの電流ベクトルの方向が進行方向と平行の時、および 45° 傾いているときの Im 成分を用いて、 $Y=60\text{mm}$ の位置の欠陥を検出可能であるか、AI の枠組みにより検討を行った。なお、あくまでも本年度は適用性の検討ということもあり、 $x=250\text{mm}\sim 750\text{mm}$ 、 $1250\text{mm}\sim 1750\text{mm}$ のみを、 2mm 間隔で解析対象とした。Y 方向については、学習データとしては 30mm 間隔で $Y=90\text{mm}\sim 150\text{mm}$ のデータを用いている。つまり、データ数としては合計 502 点 $[(500/2+1)\times 2]$ 存在し、それぞれのデータには 9 個の特徴量 $[(150-(90))/30+1]$ が存在する。

具体的には、人工知能・機械学習の一手法である **Random Forest** 法を用いた。Random Forest 法は基本的に決定木の集合体であるため、まず決定木の定式化を行う。決定木とは場合分けを繰り返して値を予測する手法であり、場合分けルールは CART 法というアルゴリズムに従い教師データから学習して作られる。CART 法では、まず以下の式(5.3.1)で表されるジニ係数 $L(t)$ を求める。

$$\begin{aligned} L(t) &= \sum_{j \neq i} P(C_i | t) P(C_j | t) \\ &= \sum_{i=1}^K P(C_i | t) (1 - P(C_j | t)) \\ &= 1 - \sum_{i=1}^K P^2(C_i | t) \end{aligned} \quad (5.3.1)$$

$P(C_i)$, $P(C_j)$ はそれぞれクラス i , j に属する確率, t はノードを表す記号 K はクラス数である。クラス分けのために、不純度の一番大きな分割を選択する。すなわち、分割を s としたとき、

$$\Delta L(s, t) = L(t) - (p_L L(t_L) + p_R L(t_R)) \quad (5.3.2)$$

が最大になるジニ係数を、可能な分割の候補の中から選択する。ここで、 L , R はそれぞれノード t から分割された左側, 右側のノードにあることを示す記号である。決定木は明瞭, 簡潔でわかりやすい手法であるものの、過学習が常に問題となる。その解決のために、剪定などの手法も開発されているが、パラメータの微妙な調整が必要であり、その上で精度もさほど向上しない。Random Forest 法はその解決となる。

Random Forest 法は、多数の決定木の多数決 (分類の場合), または平均 (回帰の場合) として最終的な予測結果を求める手法である。Random Forest の概念図を図 5.3.3 に示す。

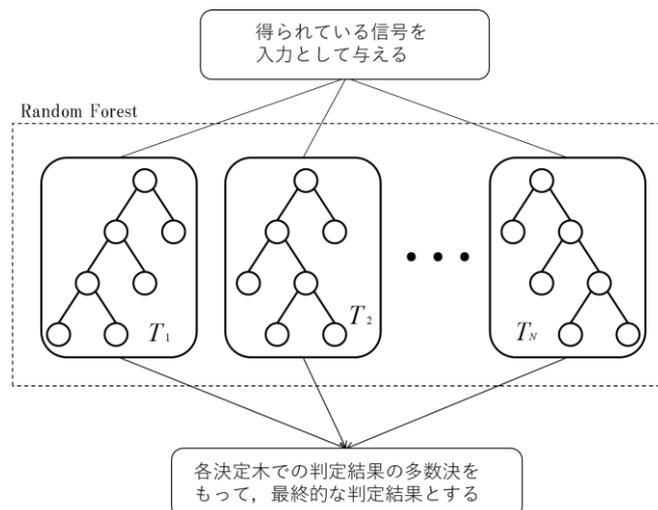


図 5.3.3 Random Forest の概念図

一般的に、分散が σ^2 の独立・同一の分布に従う B 個の確率変数の平均の分散は、 σ^2/B となる。ということは、Random Forest 法で行うように、複数の決定木を作成してその平均を取れば、分散が低減し精度が向上する。ただ、決定木の作成の仕方によっては相関が高くなってしまう。例えば同一の分布に従うが、独立でなく正の相関 ρ を持つ場合、平均の分散は $\rho\sigma^2+(1-\rho)\sigma^2/B$ となる。つまり、平均化の効果が、相関が強い場合には制限されてしまうため、木の相関は低い必要がある。

そのために、Random Forest 法では、それぞれの決定木にすべてのデータ、特徴量を用いず、ブートストラップサンプリングで抽出した学習データ、ランダムで選択された特徴を個々の決定木の生成に用いる。これにより個々の決定木間の相関が低くなり、その結果として過学習の影響が小さくなり、汎化性能が高まるという特長を持つことが知られている。なお今回の解析では、決定木の数は 50 としている。

以下に、解析結果を述べる。なお精度検証については、leave-one-out 交差確認法に基づき行った。leave-one-out 交差検証では、全ての解析対象数を N とすると、 $N-1$ 個を学習に用い、その学習結果を用いて残り 1 個の対象を解析するというのを N 回繰り返す枠組みである。交差検証を行うことで、学習に用いたデータを精度検証の対象に使ってしまい、精度を不当に高く評価することを防ぐことができる。なお今回は $N=502$ である。

leave-one-out 交差検証をもとに判定した結果を図 5.3.4 に示す。概ね良好に正解と同様の結果が得られている。(メッシュ単位での精度は、 $497/502=99\%$)。様々な供試体での検討を行うことで一般性を確認する必要があるが、人工知能技術をもとにき裂を検出できる可能性については示せたといえる。今後は、データ数を大幅に増やすこと、そしてそれに伴い手法の改善・改良を行うこと、今回は解析対象外とした端部の扱い手法の構築が、実用化のために有効であると考えられる。

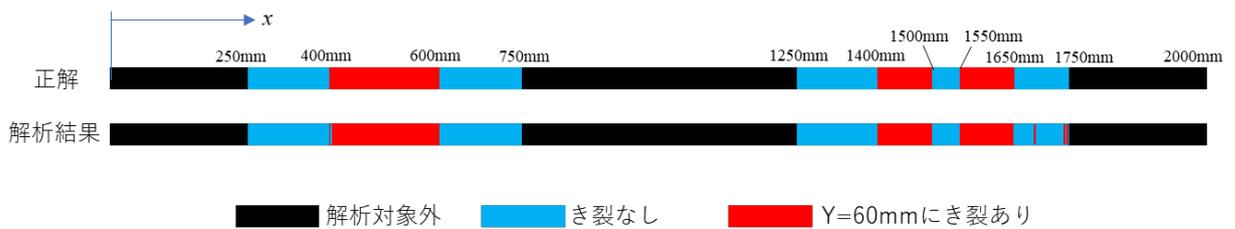


図 5.3.4 正解と解析結果との比較 (上図が正解, 下図が解析結果)

6 音響・時系列データを用いたプロジェクトチームによる横断的取り組み

本章においては、6.1 に音響・時系列データの取り扱いの概要を記し、6.2 では SIP 研究者から提供されたデータ（量研機構：レーザー打音、3.2 参照）について SIP 研究者と連携し、AI の適用性を検討した結果を示す。6.3 は軸力診断への AI 適用についてプロジェクトチームでの検討結果を記述した。

6.1 音響・時系列データの取り扱いの基礎的な知識・方法

6.1.1 はじめに

人は五感を用いてパターン認識を行っている。目でものを見、耳で聞き、匂いで周囲の状況を認識している。一般にパターン認識手法というときは、識別を行う主体はコンピュータであり、人間が行っているパターン認識をコンピュータに代行させようというものである。この場合のパターンは画像や音声信号、各種計測装置による測定結果などのような、1次元あるいは多次元の信号を含む。パターンは文字や音声のように人間が意図的に生成したものと、風景画像のように自然に存在するものに分類することができる。このようなパターンを、その内容によって何らかの概念に結びつける処理がパターン認識である。たとえば文字認識では、「あ」という形状の図形パターンを、ひらがなの「あ」という言語概念に対応付ける。また音声認識では、話者によって発せられた「あ」という1次元音声信号パターンを、同様に「あ」という言語概念に対応させる。つまり、パターン認識は既知のパターンを似たパターンごとにいくつかのグループに分けて、各グループをそれぞれ別個の概念に対応させ、未知パターンがどのグループに属するかを決定する機構である。パターン認識においてこのグループをクラスと呼ぶ。これらのような処理をするためには以下のような問題を解決しなければならない。

- 1) パターンを、どのように記述・表現するのか
- 2) ある複数のパターンが似ていることをどのように判断するのか
- 3) 全体をいくつかのクラスに、どのように分ければよいのか
- 4) 未知のパターンがどのクラスに属するかをどのように決定するのか

われわれは無意識のうちにこれらの処理を非常に高速に行っている。また、われわれがどのようにしてこれらの処理を脳の中で行っているかを知るとは非常に困難であり、生物のパターン認識の詳細な理論と機構はいまだ解明されていない。このため、工学的な応用の観点からは、実現したいパターン認識処理に限定し、対象とするパターンの予備知識などを利用して、限定された機能を実現することが行われている。しかし、その実現方法は一般に設計者によって異なり、すべての処理に有効な汎用的手法は存在しない。

6.1.2 パターン認識の過程

パターン認識の基礎的な過程は、パターン分類の過程と、パターン識別の過程に分けて考えることができる。はじめに、図6.1.1にパターン分類の過程を示す。この図に示すパターンの分類過程における各処理について音響・時系列データのパターン認識を例にして以下に示す。

- 1) 入力：パターンを1次元信号として取得
 - ・音響データ → 聴覚情報
集音マイク, 打診棒, 漏水センサ, 打音モジュール, ポール打検機など
 - ・振動データ → 触覚情報
振動可視化レーダー, 加速度センサ, ひずみセンサ, 角速度センサなど
- 2) 前処理：取得した情報の汎用化
 - ・外れ値処理
 - ・カルマンフィルタ
 - ・ブラインドセパレーション (独立成分分析)
 - ・欠損値処理
 - ・ノイズ除去処理
 - ・正規化处理
- 3) 特徴空間の設定：入力パターンを的確に表現することができるいくつかの特徴を選択することによって特徴空間を設定する。いずれの特徴量についてもデータを一定区間のフレームで区切り区切られたそれぞれのフレーム内での特徴量を抽出する。
 - ・フーリエ変換 (周波数, スペクトルなど) → 周波数
 - ・各種統計量 (平均値, 標準偏差など) → 振幅・位相
 - ・トレンド (微分係数, 減衰率など) → 振幅・位相
- 4) 特徴抽出：特徴抽出部においては、入力パターンに対して、特徴空間の各軸の特徴の大きさを求めることによって、入力パターンを特徴空間上の点に写像する。
- 5) 分類：教師あり学習, 教師なし学習
 - ・教師あり学習
ニューラルネットワーク (Neural Network), 深層学習 (Deep Learning), サポートベクトルマシン (Support Vector Machine), ランダムフォレスト (Random Forest) など
 - ・教師なし学習
クラスタ分析, 階層型クラスタリング, k-means 法, スペクトルクラスタリング, 部分空間法, 混合ガウス分布, 多変量解析など
- 6) 標準パターンの生成：各クラスを代表する特徴空間中の点を決定する。この点は各クラスの平均的な特徴をもった標準パターンである。ただし、クラスの設定については、大変重要で困難とされる閾値の設定が必要となり、試行錯誤して対象となる問題を解決するために最適な値を探索する必要がある。

教師なし学習においては、標準パターンの生成である結論を得ることになる。例えば、クラス数をAとBの2クラスとすれば、どちらのクラスに分類されるかによって結論が得られることとなる。ただし、どちらのクラスに分類されるかについては、クラス間境界を定める（多くの場合は、AとBに対する所属確率などの評価値を設けて、大きい方を選択することによって評価値が等しくなるところを見つけて境界を定める）ことや、閾値を設定することが必要となる。

教師あり学習においては、パターン分類の過程が終了したら、次に未知パターンの識別を行うこととなる。未知パターンを入力として、標準パターンを生成する際に実施した、図6.1.1に示す前処理と特徴抽出を行い特徴空間内における特徴ベクトルを抽出する。学習によって求めた標準パターンの特徴ベクトルを比較することによって、標準パターンが代表している特徴空間中の最も近いクラスに、入力パターンが属するものとして結論を導き出す。

さらに、最近注目されている深層学習では、ニューラルネットワークの中間層に複数の畳込み層やプーリング層を配置して、学習の際に次元圧縮を行っている。このため非常に多次元の特徴ベクトルを入力層に直接入力することが可能となった。このことにより、図6.1.1に示すパターン分類の過程は、前処理、特徴空間の設定、特徴抽出を実施することなく、入力から分類（深層学習）へ直接流れる形となり、複数の中間層において、特徴空間の設定や特徴抽出を機械的に実施してくれることとなる。しかし、設定した特徴空間が何を意味するかの情報がなく、出力された結果の説明が困難なケースが多くなる。ただし、前処理については収集したデータの質によっては必要な場合も考えられる。

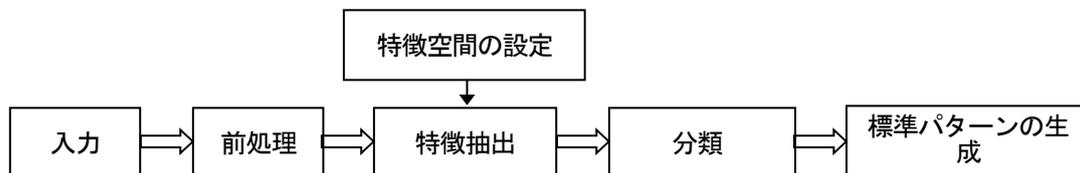


図 6.1.1 パターン分類の過程

6.2 レーザー打音装置によるコンクリート部材の試験データに対するニューラルネットワークの適用

6.2.1 はじめに

ここでは、3.2 節で述べたレーザー打音高速検査システムで得られた振動データに対する AI の適用性についてニューラルネットワークを用いた検討を行う。

コンクリート供試体における健全部 64 点、変状部 36 点、計 100 点に対して 3 回ずつレーザー打音検査を行った結果に対して、その精度や損失、混同行列における各分類の精度から適用性を検討した。なお、本検討では学習に用いることができるデータサンプル数が限られていることから、近年用いられる畳み込みニューラルネットワークなどの深層学習法ではなく、簡易なニューラルネットワークを用いている。

6.2.2 レーザー打音検査の概要

レーザー打音検査法は 3.2 節で述べたようにハイパワーパルスレーザーである「振動励起用レーザー」でコンクリートに強い衝撃を与えて振動させ、連続発振レーザーを用いた「振動計測システム」でコンクリート表面の振動を計測するものである。これにガルバノミラーや高速化したレーザー干渉計測技術を用いた「高速走査装置」によってシステムは構成される。

本検討における実験供試体は施工技術総合研究所に設置されたコンクリート供試体で、図 6.2.1 の模式図に示すように供試体に 200mm×200mm の欠陥領域を設け、それを取り囲むように 300mm×300mm の検査範囲を設けた。レーザーは図中の番号順に左上を起点として、水平方向と下方向に折り返しながら 33.3mm 間隔で照射した。計測点は 10 点×10 点の計 100 点で、健全部は 64 点、欠陥部は 36 点となる。レーザーの照射は 1 計測点につき 3 回連続で行われた。サンプリング周波数は 100kHz ($\Delta t=10\mu s$) で、1 計測点 1 回の照射でデータ長 1200 点(0.012 秒分)のデータが記録された。したがって、検査全体として健全部 192 点、欠陥部 108 点、計 300 計測点分(データ長 36,000 点)のデータを得た。

以上のような測定で得られたデータ長 36,000 点の生データを 1200 点ごとに分割した時刻歴波形が図 6.2.2 である。青線で表示した波形が健全範囲、赤線が欠陥範囲で測定されたデータである。前述のように同一箇所で 3 回連続して計測を行っている。これらの計測波形からは健全部と欠陥部の違いは明瞭でなく、同一の計測位置であっても振動波形は同一とみなすことは難しい。この 1 次元の振動データの特徴をニューラルネットワークで学習し、健全部と欠陥部の判別を行う。

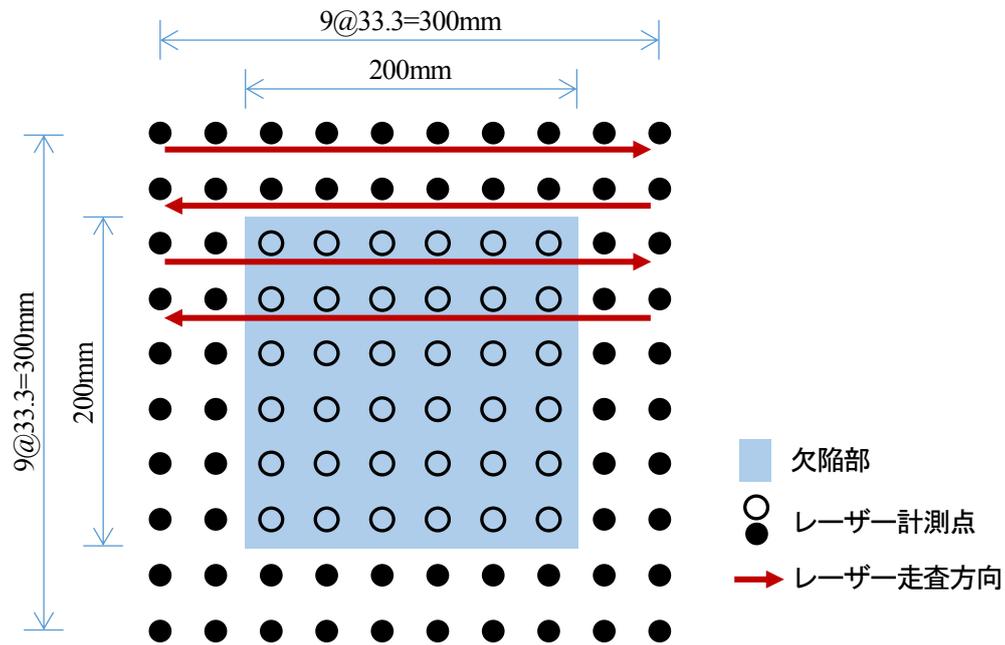


図 6.2.1 供試体上の計測点と変状位置

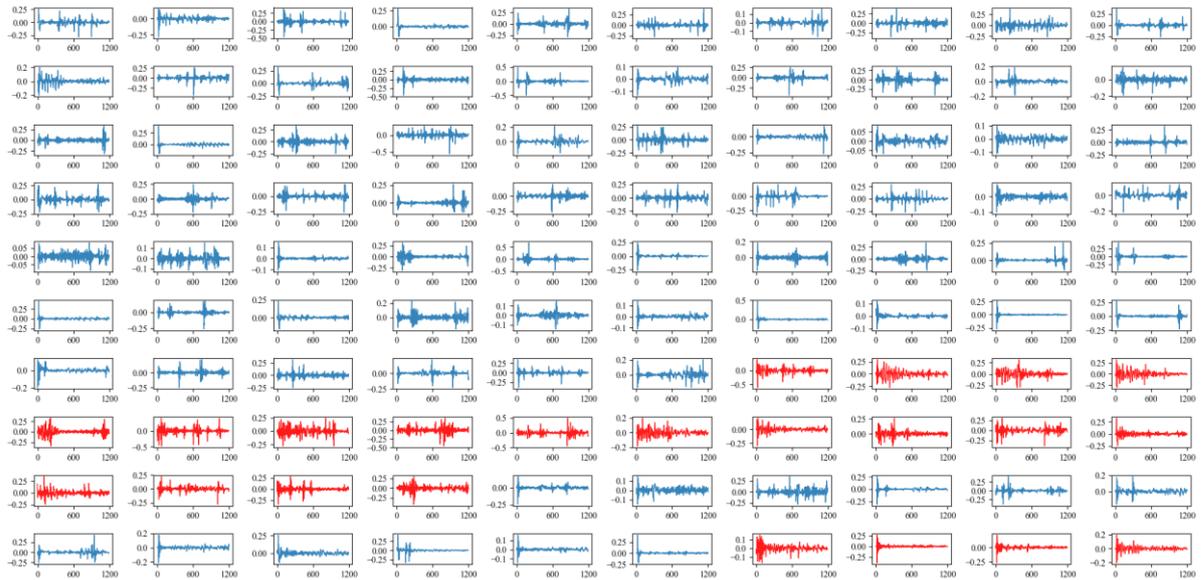


図 6.2.2 レーザー打音検査の時刻歴波形 (赤：欠陥部, 青：健全部)

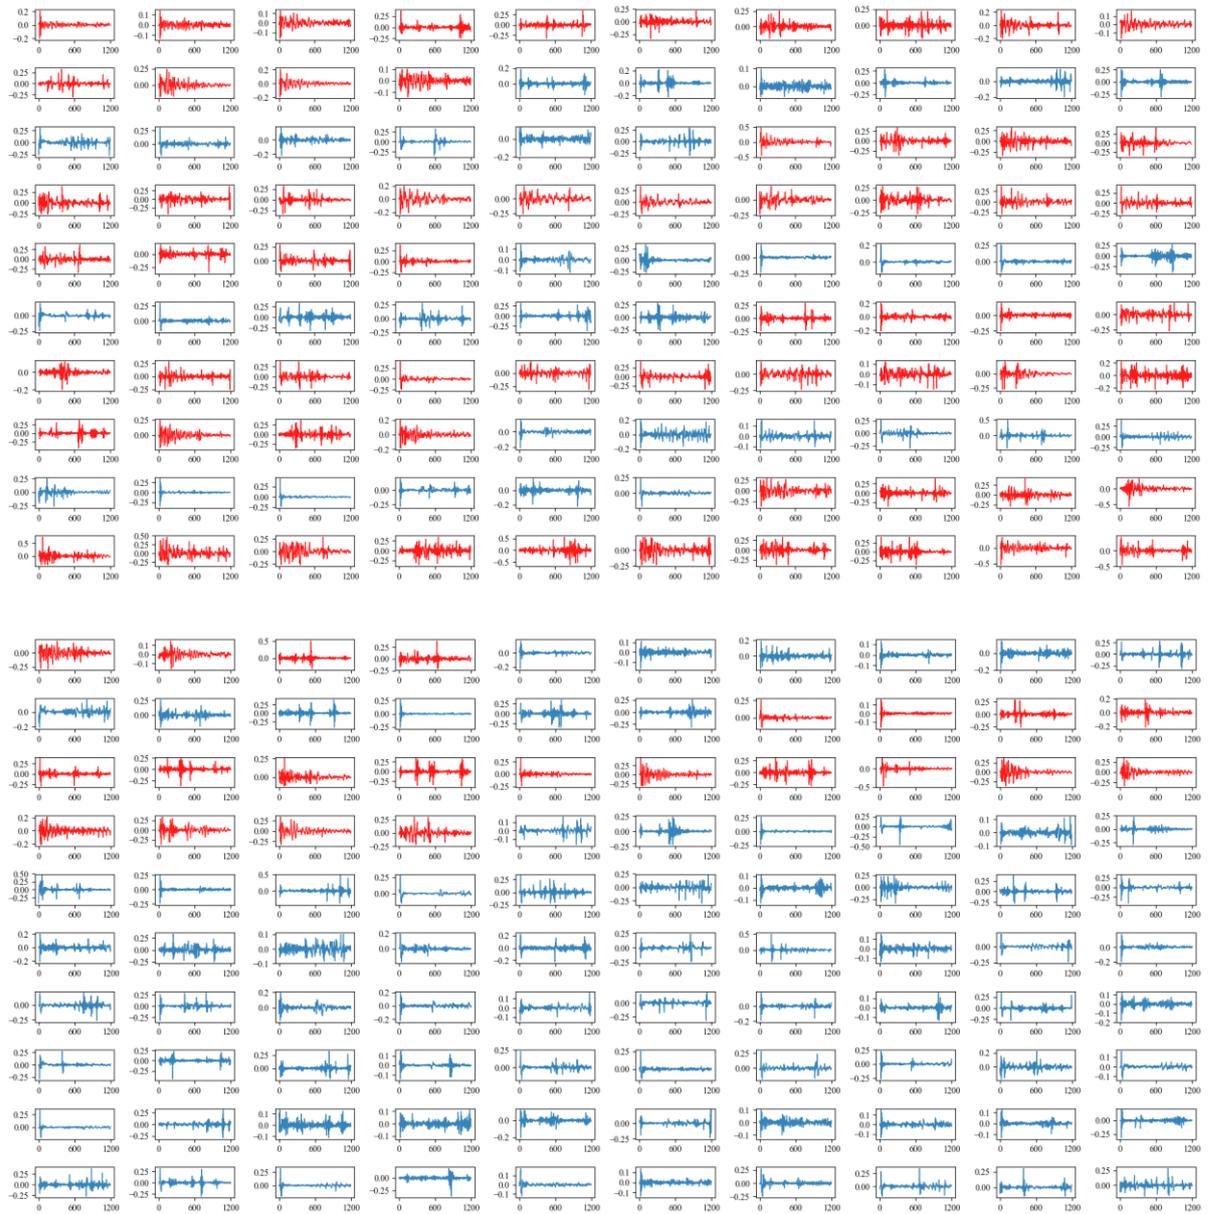


図 6.2.2 レーザー打音検査の時刻歴波形（赤：欠陥部, 青：健全部）（つづき）

6.2.3 本検討におけるニューラルネットワークの構造

本検討では1次元の時系列データである振動データに対して、教師あり学習で健全部と変状部の2分類の簡易的なニューラルネットワークを適用することとし、表 6.2.1 のような構造とした²⁾。損失関数は交差エントロピー (categorical cross entropy)、最適化アルゴリズムは確率的勾配降下法 (Stochastic gradient descent) を採用し、学習率は0.01 である。またドロップアウト率は0.75 である。

表 6.2.1 ニューラルネットワークの構造

Layer (type)	Output Shape	Activation	Trainable Parameters
Input (InputLayer)	1200	N/A	-
ds1 (Dense)	512	ReLU	614912
ds2 (Dense)	128	ReLU	65664
dp1 (Dropout, Ratio: 0.75)	128	N/A	-
ds3 (Dense)	2	ReLU	258
Total Trainable Parameters		Softmax	680834

6.2.4 学習とバリデーシンの結果

レーザー打音検査で得られた 300 サンプルのデータを学習セット(80%: 240 サンプル), バリデーシオンセット(20%: 60 サンプル)に分割して, ニューラルネットワークで学習を行った。ニューラルネットワークの設定は表 6.2.1, 学習における精度と損失の履歴は図 6.2.3, 図 6.2.4 の通りである。

図 6.2.3 では 67 epoch 以降で学習, バリデーシオンともに 90%以上の精度に達した。図 6.2.2 の波形は複雑な形状だったが, 健全と欠陥の 2 分類であるため, 比較的簡易で少ないデータセットでも精度の高い結果となったと考えられる。図 6.2.4 の損失の履歴では, 67 epoch 以降でバリデーシオンの損失が上昇しており, 過学習が始まっていると考えられる。

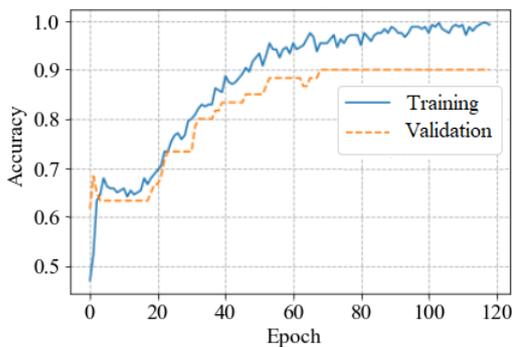


図 6.2.3 精度の履歴

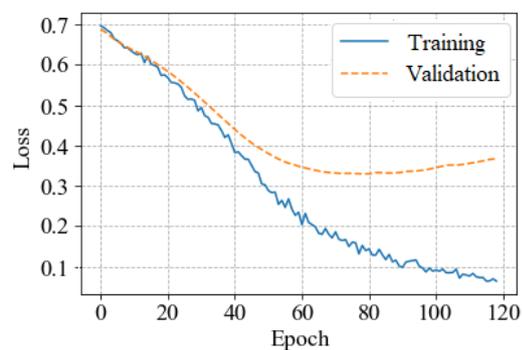


図 6.2.4 損失の履歴

学習を終了した 117 epoch でのモデルを用いたバリデーシオンにおける混同行列は図 6.2.5, 図 6.2.6 の通りであり, 前者はサンプル数, 後者は無次元化した正解率で整理した。バリデーシオンに用いた 60 サンプル中, 54 サンプル (90%) が正解し, 特に健全部については 97%の正解率であった。欠陥部では正解率が 77%と低下するが, これは全体のサンプル数が健全部の方が多かったためと考えられる。欠陥部のサンプル数を増やしたり, 全サンプル数を増やしたりすることで健全部, 欠陥部ともに精度を向上させることが期待できる。なお, 3.2 節の検出率と的中率の定義による算出では, 検出率は 77%, 的中率は 90%である。測定対象が異なるがほぼ同程度の結果であり, レーザー打音高速検査システムによりコンクリート内部の欠陥を有効に検出可能であることが確認できた。

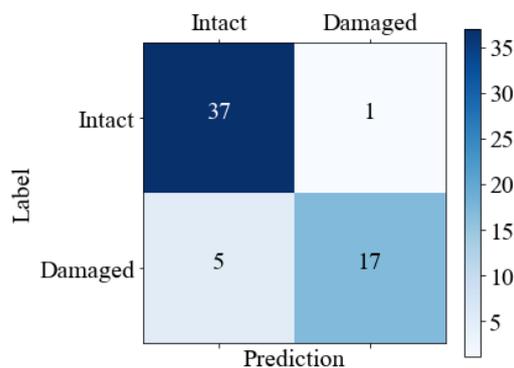


図 6.2.5 混同行列

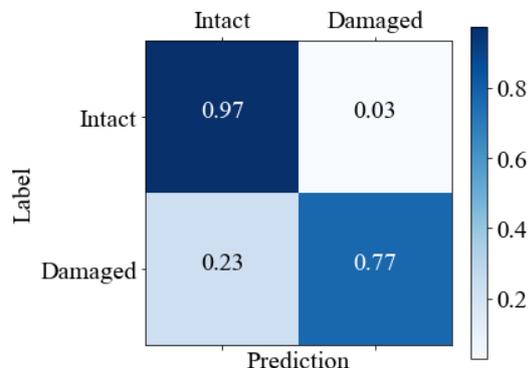


図 6.2.6 無次元化混同行列

6.2.5 まとめ

コンクリート供試体における健全部 192 点、欠陥部 108 点のレーザー打音検査の結果に対して、ニューラルネットワークにより AI の適用性を検討した。学習に使用できたデータはいわゆるビッグデータと比較して限定されたサンプル数だったが、適切にラベル付けされたデータに対して、比較的簡易なニューラルネットワークを適用し、その精度や損失、混同行列における各分類の精度から適用性を検討した。

- (1) 学習セット 80%、バリデーションセット 20%とした場合、300 サンプル程度のデータセットでもニューラルネットワークによりレーザー打音結果を、健全と変状に精度よく 2 分類することができた。
- (2) 時刻歴波形の目視からは判然としない特徴を、ニューラルネットワークで判別可能であった。さらに十分な学習データを確保すれば、ニューラルネットワークの性能はさらに向上し、自動的な変状判別が実現できると期待される。
- (3) データセットにおいて健全部と欠陥部のサンプル数が異なり、ラベルごとの精度が異なったことから、データセットのバランスも重要である。

参考文献

- 1) S. Kurahashi et al., J. Appl. Remote Sens., Volume 12, Issue 1, 015009, 2018.
- 2) Rumelhart, D. E., Hinton, G. E., & Williams, R. J., Learning representations by back-propagating errors. Nature, Volume 323, Issue 6008, pp.533-536, 1986.

6.3 加速度波形データによる高力ボルトの軸力診断への深層学習の適用

6.3.1 研究の概要

近年、高度経済成長期に建造された橋梁などの構造物の老朽化が進み、健全度診断の必要な構造物の数が急激に増加している。橋梁などの構造物の建造時には高力ボルトと呼ばれる高張力のボルトが用いられる。建造時に用いられた高力ボルトは振動による影響や時間の経過とともに緩みや腐食が発生し軸力が低下する可能性があり、補修が必要になるため定期的な点検を行う必要がある。現在利用されている非破壊検査技術の一つに打音検査があり、国土交通省の橋梁点検要領などに点検の標準的方法として記載されていることから広く定着している¹⁾。特別な機材を使用しない診断方法ではあるが、経験豊富な熟練検査員の育成が課題となっている。本研究では熟練検査員によって行われる打音検査による高力ボルトの軸力診断を自動化し、非熟練者であっても正確に軸力診断を行えることを目的とする。打音検査を自動化する研究として、打音時の高力ボルトの打音波形における周波数や減衰率といった特徴量をもとに SVM などを用いて高力ボルトの軸力診断を行おうという試みもされているが、精度のさらなる向上が課題となっている²⁾。そこで本研究ではより高い精度の獲得のために、近年様々な分野で高い能力を発揮している深層学習の手法を高力ボルトの軸力診断に用いることを検討し、その精度を検証した。

6.3.2 加速度波形データの収集

高力ボルトの軸力診断のためのニューラルネットワークの学習と評価に用いるデータは鋼材に高力ボルトを締結した小型試験体を用いて採取を行った。試験体には表 6.3.1 に示す軸長が異なる 2 種類の高力ボルトを用意し、TYPE-1 は軸長が 80mm の M22×80 の F10T 高力ボルト、TYPE-2 は軸長が 105mm の M22×105 の F10T 高力ボルトで締結している。小型試験体にはひずみゲージが設置されており、設置されている高力ボルトの軸力を測定している。実験では設計軸力である 205kN を基準 (100%) として、100%、80%、60%、40% の 4 種類の軸力に締めた小型試験体に振動計を設置して打撃することで、図 6.3.1 に示すような軸力別の加速度波形データを採取した。振動計のサンプリング周波数は 5000Hz に設定し、打音の振動を含む 1 秒間の振動加速度データを用いて学習を行った。TYPE-1、TYPE-2 の 2 種類の試験体ごとに 4 つの軸力で 20 ずつ、合計 160 の振動加速度データを採取した。うちそれぞれ 16 ずつ、計 128 の振動加速度データを学習用、残りの 32 の振動加速度データを評価用に用いた。

6.3.3 学習に用いたニューラルネットワーク

本研究においては 1 次元の時系列データである加速度波形データに対して、畳み込み層とプーリング層を持つ畳み込みニューラルネットワークを用いて学習を行う³⁾。さらに、それぞれのニューラルネットワークの学習時にドロップアウトを適用したものとそうでないものを比較用に構築した。ドロップアウトは、多層ネットワークのユニットを確率的に選別して、学習を行う方法である。構築したニューラルネットワークの一覧とその構造を表 6.3.2 に示す。C1~C8 は畳

畳み込み層を用いたものであり、F1, F2 は全結合ニューラルネットワークである。全結合ニューラルネットワークは、その構造を比較検討した複数のニューラルネットワークの中で最も性能が高かったものを選び、比較対象とした。各ニューラルネットワークは TensorFlow ライブラリを用いて構築、学習された。中間層のユニットの活性化関数には正規化線形関数を用い、出力層ではソフトマックス関数を用いている。畳み込み層で用いるフィルタのサイズは 3, 4, 5, 6 の 4 種類とした。ドロップアウト率は構築したそれぞれのニューラルネットワークで 0% と 50% の 2 パターンを適用して学習させて、診断結果の精度を比較することとした。最適化アルゴリズムには学習率を誤差関数の勾配に基づき設定する Adam を用いて学習を行なった³⁾。

6.3.4 識別実験の結果と評価

学習したニューラルネットワークに評価用の 32 個の振動加速度データを入力し診断した軸力を出力させた。構造の異なるニューラルネットワークでの評価を、後述する性能指標 A と F 尺度の 2 種類の評価指標を用いて分析し比較した。学習中の誤差関数の値の変動や、過学習による性能の低下、学習後の評価のばらつきを考慮して、学習途中に最も軸力診断の性能が高かった時点の評価し、学習と評価をそれぞれ 10 回ずつ行いその評価の平均をとりニューラルネットワークの性能を確認した。今回構築した全てのニューラルネットワークにおいて、学習終了時に測定した学習用データでの平均再現率は約 93.75% で一致し、それ以上の向上は見られなかった。しかし、評価用データを用いた平均再現率はニューラルネットワークの構造によって異なっており、汎化性能に大きな違いが生じている。以下では学習用データでの評価は省略し、評価用データでの評価に限定して説明を行う。

性能指標 A は高力ボルトの軸力診断性能の評価に必要なニューラルネットワークの出力した軸力の軸力教師ラベルからの乖離の程度を、差の積の総和をとることで考慮した指標である。よって、性能指標 A の値が小さいほどニューラルネットワークの軸力診断性能が高いと言える。

F 尺度とは、情報探索などの情報工学の分野において、システムの出力した検索結果や判定結果などの正確性と網羅性を総合的に評価するために用いられる指標であり、F 尺度が高い値であればより軸力診断性能が高いと言える。今回の軸力診断結果は多クラスであり複数の軸力が出力されるので、全ての軸力について求めた F 尺度を平均した値を評価指標として用いる。

図 6.3.2 に示すように、今回構築したニューラルネットワークのうち評価用データでの性能指標 A が 10 回平均で最も良い値となったのは C4 であった。ドロップアウトを用いていない畳み込みニューラルネットワークのうち性能指標 A が最も良い値となったのは C5 であった。F 尺度の傾向は、図 6.3.3 に示すように概ね性能指標 A が示すものと同じ結果になった。以下で、性能評価 A 及び F 尺度で高い評価が得られた C3, C4, C5 のニューラルネットワークの識別結果について考察する。

C3 は畳み込み層とプーリング層を持ち、畳み込み層でのフィルタサイズは 4 のニューラルネットワークである。学習時にドロップアウトは行なっていない。C3 の性能指標 A は平均で 9.2, F 尺度は平均で 0.84647 となった。診断性能の細部について、C3 では誤診断により、100%

の軸力の振動加速度データでの再現率が 77.50%と低い値になっている。同様の誤診断はドロップアウトを行っていない C1, C5, C7 にも多く見られる。40%の軸力の振動加速度データの再現率については C1 と比較して 5.00%高い値となっており、フィルタサイズの変更で低い軸力の高力ボルトの診断性能に向上が見られた。

C4 は C3 と同じ構造のニューラルネットワークであるが、学習時にドロップアウトを行うことで軸力診断性能が向上している。C4 の性能指標 A は平均で 2.6, F 尺度は平均で 0.92583 となった。診断性能の細部について、C4 では 100%の軸力の振動加速度データでの再現率が 100.00%と高い値になっており、C3 と比較して平均で 12.50%の性能の改善が見られた。80%, 60%の軸力の振動加速度データでの再現率についても、同じく向上が見られた。しかし、40%の軸力の振動加速度データでの再現率が 75.00%と、C3 と比較して 11.25%低下している。これらの傾向は C1 と C2, C5 と C6, C7 と C8 の間にも見られており、ドロップアウトを行うことで高い軸力の高力ボルトの軸力診断性能は向上するが、低い軸力の診断性能は低下するといった現象が発生している。40%の軸力の振動加速度データでの再現率は C2 と比較しても 2.50%低下しており、フィルタサイズを増やしてドロップアウトを行うことで低い軸力の軸力診断の性能が低下することが確認できた。

C5 は畳み込み層とプーリング層を持ち、畳み込み層でのフィルタサイズは 5 のニューラルネットワークである。学習時にドロップアウトは行っていない。C5 の性能指標 A は平均で 7.6, F 尺度は平均で 0.86963 となった。診断性能の細部について、C5 では C1, C3 と同じく 100%の軸力の振動加速度データを 40%や 60%と診断する誤診断が発生している。その他の値について C3 と比較すると、100%, 80%, 60%の軸力の振動加速度データでの再現率はそれぞれ向上しているが、40%の軸力の振動加速度データでの再現率は 1.25%と僅かに低下している。この値はフィルタサイズが 3 から 4 となった C1 と C3 の間では増加しており、フィルタサイズの増加が軸力診断性能に与える影響は振動加速度データの軸力によって異なることがわかった。

6.3.5 考察

構築したニューラルネットワークのうち評価用データでの評価が 10 回平均で最も高かったのは、畳み込み層のフィルタサイズが 4 で学習時にドロップアウトを用いている畳み込みニューラルネットワークの C4 であった。軸力診断の性能を評価するために用いた性能指標 A や識別器の総合評価のために用いた F 尺度で見ると、ドロップアウトを用いたニューラルネットワークは用いていないニューラルネットワークよりも良好な値を示している。

(1) 畳み込み層のフィルタサイズ による軸力診断性能の変化

総合的に見て今回構築したニューラルネットワークにおける畳み込み層での最適なフィルタサイズは、ドロップアウトを用いないときは 5, 用いたときは 4 であった。これより、高力ボルトの軸力診断に最適なフィルタサイズが存在することが確認された。さらにフィルタサイズを増やしても軸力診断の性能が著しく向上することはなく、僅かに低下する結果となった。畳み込みニューラルネットワークが意図しているユニットの結合の制限による重みの数の削減と、構造

的な制約による位置的な情報の表現が効果的に働き、下層でより高力ボルトの軸力診断に適した特徴が学習されたためと考えられる。

(2) ドロップアウトの有無による最適なフィルタサイズの変化

C1～F2のうち性能指標 A, F 尺度共に最も良い値となったのは C4 であるが、学習時にドロップアウトを用いていないニューラルネットワークのうち最も良い値となったのは C5 であった。学習時にドロップアウトを行っていない時はフィルタサイズ 5 の C5 がフィルタサイズ 4 の C3 よりも性能で上回っているにもかかわらず、ドロップアウトを行うとフィルタサイズ 5 の C6 の性能がフィルタサイズ 4 の C4 に比べて低い性能となっている。このことは、ドロップアウトの有無によって最適な畳み込み層のフィルタ数が異なることを示している。この理由として、ドロップアウト率とフィルタサイズの組み合わせによっては、ドロップアウトを行いニューラルネットワークの自由度を制限したことが影響を及ぼした可能性があると考えられるが、さらなる考察が必要である。

(3) ドロップアウトの適応による一部軸力の再現率の低下

ドロップアウトを用いた畳み込みニューラルネットワークは同じ構造のニューラルネットワークでドロップアウトを用いないものと比較して、100%、80%、60%の軸力の振動加速度データでの再現率が大幅に増加しているにもかかわらず、40%の軸力の振動加速度データでの再現率が極端に低下している。これは、学習時のドロップアウトの有無が振動加速度データでの再現率に与える影響に、軸力による違いが見られるということを表している。この現象は全結合層のみで構築された同じ構成のニューラルネットワークでドロップアウトの有無が異なっている F1 と F2 では発生していないため、ドロップアウトと今回構築した畳み込みニューラルネットワークの組み合わせが再現率を低下させる要因と関連している可能性が高い。40%の軸力の振動加速度データに他の軸力の振動加速度データと比べて何らかの異なる特徴が存在しており、今回構築した畳み込みニューラルネットワークではその特徴を学習できなかったためであると考えられる。該当の再現率の低下が全体の軸力診断性能に大きな影響を及ぼしている上、40%という低い軸力の振動加速度データにおける性能が低いことは高力ボルトの軸力診断の性質上大きな問題であるため、この問題を改善したニューラルネットワークを構築する必要がある。ドロップアウトを用いていない畳み込みニューラルネットワークでフィルタサイズが 5 の C7 では 40%の軸力の振動加速度データでの再現率が 88.75%となっているので、ニューラルネットワークの構造を変更することで該当の再現率の低下を防ぎ、高力ボルトの軸力診断の性能をより向上させることは可能であると考えられる。

参考文献

- 1) 国土交通省：橋梁定期点検要領，2014
- 2) 広兼道幸・中田弘一・小西日出幸・鈴木直人：パターン認識を用いた高力ボルトの軸力診断に関する研究，土木学会論文集 F6（安全問題），第 69 巻，pp.69-74，2013
- 3) 人工知能学会：深層学習－Deep Learning－，近代科学社，2015

表 6.3.1 振動加速度データの収集

タイプ	軸力(%)	軸力(kN)	打音箇所	計測箇所	計測回数
TYPE-1 (HTB M22×80 F10T)	100	205	ナット辺	ナット横	20
	80	164			
	60	123			
	40	82			
TYPE-2 (HTB M22×105 F10T)	100	205			
	80	164			
	60	123			
	40	82			

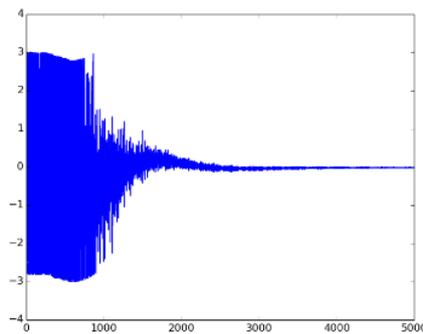


図 6.3.1 採取した加速度波形データの例

表 6.3.2 各ニューラルネットワークの構造

ニューラルネットワーク名	C1	C2	C3	C4	C5	C6	C7	C8	F1	F2
学習率	0.001									
学習ステップ数	10000									
活性化関数	正規化線形関数 (出力層ではソフトマックス関数)									
フィルタサイズ	3		4		5		6			
ドロップアウト率	0	0.5	0	0.5	0	0.5	0	0.5	0	0.5
中間層の構造	第1 畳み込み層 (20 チャンネル) プーリング層 第2 畳み込み層 (20 チャンネル) プーリング層 全結合層 (128 ノード)								第1 全結合層 (2500 ノード) 第2 全結合層 (1250 ノード) 第3 全結合層 (128 ノード)	

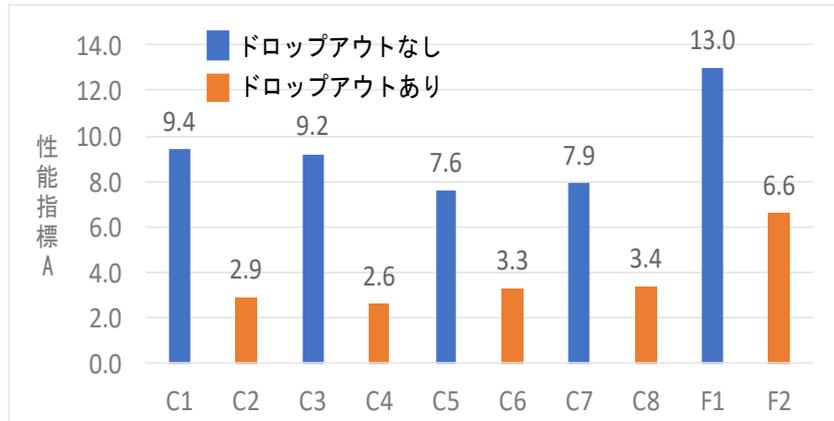


図 6.3.2 性能指標 A (10 回分の平均)

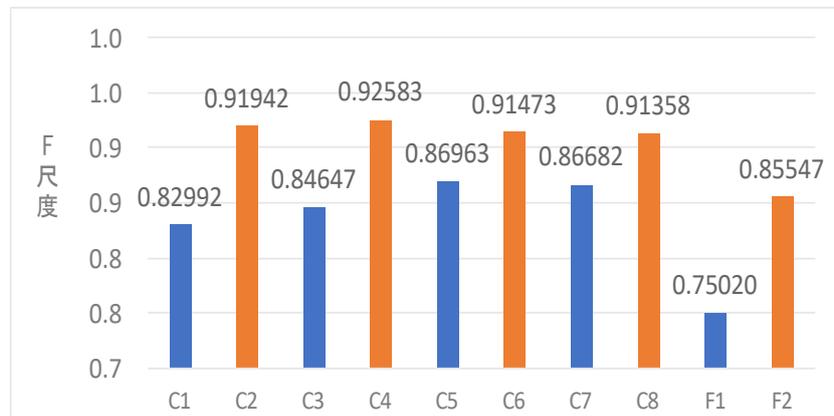


図 6.3.3 F 尺度 (10 回分の平均)

7 テキストデータを用いたプロジェクトチームによる横断的取り組み

本章では、7.1 にテキストデータの取り扱いについて概要を記した。

7.1 テキストデータ取り扱いの基礎的な知識・方法

7.1.1 テキストデータの種類

インフラ維持管理分野におけるテキストデータを対象とする研究としては、「文字列情報を含む表形式のデータ」を対象とした推定や判別に関する分析に関する研究¹⁾⁴⁾が主である。その他、「文章データ」を対象にテキストマイニング等の解析を適用する研究⁵⁾⁶⁾も報告されている。本節では、維持管理分野における AI 適用の事例の多い表形式データを対象とした研究について述べる。

インフラ維持管理分野においては、複数の表形式データに分け、別々に管理されている場合が多く見られる。例えば、構造物の諸元と点検結果が分かれて管理されているなど、業務で用いる「台帳」により、分かれている場合がある。構造物毎の諸元情報や点検結果情報を管理する上では、表形式データは、業務に適合しやすいと考えられる。

7.1.2 量的データと質的データ

維持管理業務において記録される表形式データについては、数値データ（量的データ）と文字列データ（質的データ）のどちらもが記録される場合も多い。量的データには、点検記録における「変状の寸法」や「判定結果のグレード」、「センサ値」のほか、諸元における「橋長」や「経過年」等の数値情報や「座標」や「距離標」等の位置情報がある。また、環境情報としては、「雨量」等の天候や、「交通量」等の環境情報がある。一方で、質的データについては、構造物の「名称」や「型式」、「変状の種類」のほか、点検員による「備考」や「所見」等の文章情報もある。質的データをデータ分析等で活用する場合には、一般的には量的データへの変換が必要である。構造形式や変状の種類等の所謂カテゴリデータであれば、数量化処理によって、該当するデータか否かを示す数値に変換する事も有効である。しかし、自由文で記載された情報や、変状等の判定記録における A~C など順序のある記号については、単純に数値化が可能なものとは限らないため数量化の処理には注意が必要である。

7.1.3 分析に向けた前処理

量的データと質的データとが混合しており、なおかつ台帳毎に分割された表形式データを対象に、データ分析等を適用するためには、分析手法に適した入力データを得るためのデータの「前処理」が必要となる。この前処理については、「データクレンジング」と「データ調製」の二つがある。

データクレンジングは、データ分析の信頼性や精度向上のため、データに含まれるエラーを

修正する操作である。また、データエラーを排除することで、データ自体の可読性も向上することができる。一方で、データ調製は、成果目標や分析目標に応じて分析用入力データを適切に調製することで分析結果の精度や解釈性を向上させる操作である。データ分析の結果は、入力するデータに大きく影響される。また、分析手法によっては、対象となるデータ形式が限定されているため、適用できるように調製が必要な場合もある。

7.1.4 データの分析

分析対象となる表形式データに対する分析については、目的毎に様々な手法が用いられる。目的については、東京大学 社会連携講座における整理⁷⁾によれば、次の目的に分類される。

- ルール抽出（探索的データ分析）
 - データの相関/共起を調べる
 - データの相違を調べる（仮説検証）
 - データ削減（縮退/要約）
 - 類似性評価（クラスタリング）
- 推定
 - 量の推定（回帰）
 - 質の推定（判別/識別）

また、分析手法としては、前処理によって質的データを量的データに変換することにより、様々な機械学習手法や統計等の手法を用いる事ができる。また、前処理を行わず、入力データに質的データを想定した分析手法には、林らによる数量化Ⅰ類・数量化Ⅱ類がある。これらの手法であれば、前処理を行うことなく、質的データを入力とした分析が可能である。

詳細は、多変量解析の教科書などを参照されたいが、大まかに、表 7.1.1 のような手法を用いることが一般的である。また、この表には掲載していないが、説明変数に量的データと質的データが混在する場合に適用可能な分析手法についても、研究が進められ、インフラ維持管理分野における適用事例も発表されている。

表 7.1.1 テキストデータの分析に用いる手法⁷⁾

区分	分析の目的	目的変数 (従属変数)	説明変数(独立変数)		
			量的	質的	
ルール抽出 (探索的 データ分析)	データの相関/共起を調べる	なし	<ul style="list-style-type: none"> 相関図 相関係数 因子分析 	<ul style="list-style-type: none"> クロス集計 アソシエーション分析 ベイジアンネットワーク 	
	データの相違を調べる (仮説検証)		<ul style="list-style-type: none"> t検定(対応の無い2変数) F検定(2変数) 分散分析(3変数以上) 	<ul style="list-style-type: none"> カイ二乗検定 (2変数間/3変数以上) 	
	データ削減(縮退/要約)		<ul style="list-style-type: none"> 主成分分析 (PCA) 		
	類似性評価/クラスタリング		<ul style="list-style-type: none"> クラスター分析 数値化IV類 	<ul style="list-style-type: none"> 数値化III類 	
推定 (多変量解析/ 機械学習)	量の推定 (回帰)	あり	量的	<ul style="list-style-type: none"> 重回帰分析 	<ul style="list-style-type: none"> 数値化I類
	質の推定 (判別/識別)		質的	<ul style="list-style-type: none"> 判別分析 決定木分析 SVM 	<ul style="list-style-type: none"> 数値化II類 アソシエーション分析

参考文献

- 1) 本城 勇介, 大竹 雄, 佐藤 敦: 岐阜県橋梁点検データベースの統計解析に基づく簡易橋梁健全度評価指標, 構造工学論文集.A 日本学術会議土木工学・建築学委員会, 第60巻, pp. 462-474, 2014.
- 2) 山崎 崇央, 石田 哲也: 生存時間解析を用いた東北地方における橋梁コンクリート部材の劣化定量分析, 土木学会論文集F4 (建設マネジメント), 第71巻, 第4号, pp. I_11-I_22, 2015.
- 3) 長谷川隆, 石川雄章, 門間正挙, 川端一嘉, 森治郎, 勝木康博: 要因分析と損傷予測手法の研究開発とマンホール保全データによる評価, 情報処理学会第76回全国大会, 第3巻, pp. 6, 2014.
- 4) 佐溝 昌彦, 渡邊 諭, 杉山 友康, 岡田 勝也: 統計的手法による鉄道橋梁の増水時における被災注意橋脚抽出手法, 土木学会論文集D3 (土木計画学), 第69巻, 第3号, pp. 237-249, 2013.
- 5) Zhi-Gang, M. and Han-Bin, L.: Study on the Maintenance of Subway Equipment Based on Data Mining Techniques, 2017 International Conference on Smart City and Systems Engineering (ICSCSE), pp. 209-215, 2017.
- 6) Edwards, B., Zatorsky, M. and Nayak, R.: Clustering and classification of maintenance logs using text data mining, Proceedings of the 7th Australasian Data Mining Conference-Volume 87, pp. 193-199, 2008.
- 7) 東京大学大学院情報学環: 「情報技術によるインフラ高度化」社会連携講座,
<<http://www.advanced-infra.org/english.html>>, (入手2018.11.11)

8 研究動向調査

8.1 調査の方法

本章は、東京大学大学院情報学環「情報技術によるインフラの高度化」社会連携講座における、インフラ維持管理に対するAI(Artificial Intelligence)やデータの高度な活用に関する既往研究調査を元に、本検討会による調査を加え、文書化したものである。

既往研究の調査は、キーワード検索による文献調査を行うと共に、土木情報利用技術論文集(2009～2010年)および、土木学会論文集(土木情報学2011年～2017年)に対し網羅的に調査を行った。以上で対象となった約2,300件の文献に加え、AIや機械学習に関連のあるキーワードによりGoogle Scholarにて検索した約5,000件の対象文献の中から、調査対象とした内容に該当し、具体的な報告が含まれる事例として、約100件の文献を抽出した。これらの文献について、独自に定義した研究の区分毎に概略を紹介する。

8.2 既往研究の概要紹介

8.2.1 個別変状の検出/判別

構造物に生じる変状を対象としたデータ分析に関する研究事例について紹介する。ここでの変状とは、ひび割れ、漏水、剥離・剥落、凍害、など、点検業務により観測され、項目化し記録される「個々の現象」を指す。変状情報は、背後に繰り広げられる劣化事象が表出した観察可能な現象を点検業務により記録した情報である。変状の分析は、次の措置段階における対策に対する緊急性などに関与が深いため、業務上の関心が高い研究事例である。

Rahmanら²⁾は、ニューラルネットワーク(NN: Neural Network,)を用いて、橋脚の洗掘状態の推定に関する試行を報告している。

そのほか、山口ら³⁾は、床版に対する超音波計測結果データを対象に、周波数解析を行い、ひび割れを推定する研究を行っている。

貝戸、小林らの研究⁴⁾⁵⁾では、目視点検データを対象に、混合ポアソンモデルを用いて、RC床版のかぶりコンクリートの剥離・剥落発生の推定を行っている。貝戸らは、剥離・剥落の発生は、時間の経過にともない床版の劣化に応じて発生する「劣化事象」と、時間に依存することなくランダムに発生する「ランダム事象」の二つの傾向があるとの仮説を立て、モデル化を行っている。そこで、定常的な剥離・剥落発生過程を斉次ポアソンモデルで、一方で、時間に非定常な剥離・剥落過程を時変な非斉次ポアソンモデルを用いて、それぞれ定式化している⁴⁾⁵⁾。その上で、両者の発生過程が混合して観測されるような混合ポアソン劣化モデルの定式化を行い、このモデルを用いて、目視点検データを説明変数とし

た分析を行っている。

変状検出について多く見られるデータの一つに画像がある。画像を用いた検出技術については、コンクリート表面やアスファルト表面の変状検出が多く報告されている。

Kochら⁶⁾の報告では、コンピュータビジョン技術の土木技術への適用について、画像処理の流れ(レベル)に沿って、それぞれの段階でよく用いられる手法を整理している。例えば、特徴抽出のレベルでは、ハフ変換(Hough Transform)やHoG(Histogram of Oriented Gradients)やウェーブレット変換(Wavelet transform)、物体認識から構造解析のレベルではSVM(Support Vector Machine)やニューラルネットワークやMR(Multi-view Reconstruction)等が挙げられている。論文で紹介されている事例では、例えば、トンネルの変状検出については、モデルベースアプローチや画像パターンに基づくアプローチなどが挙げられている。モデルベースアプローチでは、線トレースによるひび割れ検出⁷⁾や、ひび割れの背後で生じる透水をモデル化した上で高速にひび割れ検出を行う手法⁸⁾が例示されている。画像パターンベースのアプローチでは、SVMによる手法⁹⁾等が挙げられている。

前田、長谷山ら¹⁰⁾は、橋梁点検記録の写真に含まれる変状の画像領域を自動的に抽出し、SVM、FK-NN(Fuzzy K-nearest neighbor)、ベイジアンネットワーク(BN: Bayesian network)の3種類の手法による判別結果を統合し、変状種別に基づく画像の分類技術を提案している。

トンネル等のコンクリート面に対する画像認識を用いた変状検出事例については、Dawoodら¹¹⁾は、画像処理手法に基づく地下鉄のコンクリートと壁の水漏れ・劣化箇所の検出方法を提案している。また、Makantasisら¹²⁾は、深層学習(Deep Learning)手法としてCNN(Convolutional Neural Network)を用いたトンネル壁面の変状検出技術について報告を行っている。特に、CNNの前段にて、エッジ検出やHOG等の特徴抽出を加えた手法を提案している。

Zakeriらによるアスファルト舗装を対象とした画像認識によるひび割れ検出技術についてのレビュー論文¹³⁾では、技術を「画像取得技術」、「画像セグメンテーションに関する前処理技術」、「特徴抽出技術」、「疲労や変状の検出技術」、「判別や分類の技術」毎に、複数の既往研究を一覧表で対比し整理している。

また、Hadjidemetriouら¹⁴⁾は、舗装を対象とし、複数のSVC(Support Vector Classification)処理結果を統合し、パッチングの検出を行った研究を報告している。SVMを用いた変状検出に関する研究は多く見られ、Çevikらによる構造工学分野におけるSVM活用に関するレビュー論文¹⁵⁾の中で、Rankovićら¹⁶⁾によるコンクリートダム劣化変位へのSVM等の変状検出研究を紹介している。

コンクリート橋表面のひび割れ検出については、例えば、Chenら¹⁷⁾は、SOM(Self Organization Map)を用いたひび割れ検出を提案している。また、Prasannaら¹⁸⁾は、前処理を行った画像データに対して、SVMやAdaboost、ランダムフォレスト(RF: Random Forest)など複数の手法を用いて、ひび割れ検出を試行している。

8.2.2 構造物の総合評価

維持管理の対象となる構造物毎の状態を「総合的」に評価した指標や、その指標を判定するモデルを構築する研究事例について紹介する。

構造物に関する個別変状の程度や発生箇所、進行状況などを総合的に加味し、構造物の健全性、あるいは劣化度、老朽化年齢、リスク、といった総合的な指標を算出する。ここで得られる指標やモデルは、点検や診断の後の「措置」で行う維持管理の緊急性や優先度に関する判断における参考指標となり得る。従って、診断の次の段階である措置における意思決定に繋がる管理単位により、構造物状態を評価するなど、業務に直接結びつく単位で指標を算出するといった点が特徴的である。

構造物の総合的な指標を求める既往研究について、先行研究を紹介する。大竹ら^{19),20)}は、鋼橋 RC 床版を対象とし、橋梁点検データを用いて橋梁部材の総合的な健全度値の推定を行っている。分析手法には、主成分分析とクラスター分析を組み合わせた手法を用いて、多数の細目項目の判定結果を用い、複合的な主成分を抽出し、これを健全度として定義している。

また、Galvan-Nunez ら²¹⁾は、PSO(Particle Swarm Optimization)に k-Means 法を組み合わせたクラスタリング手法を提案し、FHWA(the U.S. Federal Highway Administration)の NBI(National Bridge Inventory)データベースの資産情報を対象に、橋梁のクラスタリングを試行している。

広兼ら²²⁾は、コンクリート床版を対象とし、撮影された写真データを用いて、ひび割れ形状に着目した構造物変状程度の推定を行っている。ひび割れを含む床版のデジタルカメラ画像に対して画像処理を行い、ひび割れの集中性・連続性、亀甲状・線状の種別に着目し、画像特徴量を抽出している。抽出した画像特徴量に対して SVM とニューラルネットワークを用いた学習を行い、両者の手法の結果を比較している。

Lu ら²³⁾は、SVR(Support Vector Regression)を有限要素法の代替処理に用い、鋼床版の疲労耐久性評価手法を提案している。

全ら²⁴⁾は、多点同時計測と機械学習を用いた変状同定手法の I 型断面はり部材への適用を行っている。

森ら²⁵⁾は、橋梁の健全度について、橋梁の構造物としての機能的評価と物理的評価の二面に分け、数理化理論を用いた分析を行っている。分析における目的変数（外的基準）については、構造物の機能的評価として「機能的点検表」という記入シートによるアンケート調査結果を用いている。

橋梁維持管理における構造物に対する評価指標として、リスクスコアの算出を行った研究も存在する。Cheng ら²⁶⁾は、ファジー理論(Fuzzy Logic)と LSSVM(Least Squares Support Vector Machine)を組み合わせ、橋梁リスクスコアの推定手法を提案している。

そのほか、中川ら²⁷⁾は、栈橋 RC 上部工の目視点検データを対象に、マルコフモデルに基づく劣化度判定基準の推定を行っている。また、篠田ら²⁸⁾は、法面（鉄道もたれ壁）を

計測した速度計およびひずみ計データを対象に、周波数解析を適用し鉄道もたれ壁の健全度と相関のある指標導出を試みている。宮下ら²⁹⁾は、供用済みの実橋梁の床版に対して、加振した際の振動計測結果を周波数解析に基づく振動モード分析を行い、橋梁床版の健全性と振動データに見られる動的特性との相関関係を把握する試みを行っている。

水谷ら³⁰⁾は、混合マルコフ劣化ハザードモデルとその階層ベイズ法を用い、床版個々に対して補修前後の劣化過程に介在する異質性を考慮した劣化予測を行っている。さらに、補修前後の劣化速度に対する相対評価を通し、過去に実施された補修効果の事後評価を行っている。

また、西尾ら³¹⁾は、既設橋梁の数値モデル構築において、ベイズ推定を活用し定量的評価を実施している。

橋梁などの構造物以外にも、直接観測できない地下構造物として、Harveyら³²⁾は、下水パイプの状態推定をランダムフォレストを用いて行っている。また、野村ら³³⁾は、深層学習の一種である畳込みニューラルネットワークを用い、錆びつき固着に関する配管バルブの健全性の識別を行っている。

そのほか、舗装の健全性の評価を行った例もある。Tabatabaeeら³⁴⁾は、SVCとRNN(Recurrent Neural Network)を組み合わせ、舗装のパフォーマンスモデリングを行っている。処理の前段では、舗装や基層の諸元を元にSVCで舗装をいくつかのクラスに分類し、その後段で、経過年、交通量や天候等の情報を説明変数として加えた上でRNNを適用し、舗装の性能推定を行っている。

舗装工学にニューラルネットワークを適用した既往研究は多数報告されているが、これらについて、Ceylanら³⁵⁾は、次の7つのカテゴリに分類できると報告している：(1)舗装状態と性能の推定、(2)舗装の維持管理戦略、(3)舗装疲労の予測、(4)舗装システムの構造的評価、(5)舗装の画像解析と判別、(6)舗装材質のモデリング、(7)その他の交通インフラ応用。

8.2.3 要因分析/データ構造理解

前述の健全度や劣化変状に対して、関心のある事象に対して、「要因になっている潜在的な情報が何か」といったことを調べる研究事例について紹介する。

維持管理においては、劣化要因により、今後の進行性の判断を行った上での措置が求められる為³⁶⁾、要因の特定は、対策検討のための重要な診断作業となる。従って、変状要因分析やデータに関する構造理解を進める研究については、現場ニーズも高く、事例報告も多い。

佐藤ら³⁷⁾は、RC床版の疲労劣化について、特にひび、剥離、鉄筋露出、遊離石灰といった変状事象の情報を対象に、データの関係性の調査や劣化因子の推定を行っている。例えば、ひび割れの程度(ランクと呼んでいる)に対して、供用日数×大型車交通量、積雪、塩害、凍結防止剤散布量、示方書がどのような相関を見せるのか、相関係数を算出し調べている。データ数値の正負の関係から、表中の値が負であるほど、相関が高いという結果と

示しており、この例では、ひび割れによる劣化に対しては、大型車交通量と塩害が大きく影響している（相関している）と論じている。相関係数による評価は、基本的な統計評価であるが、データ間の関係を簡便に調べる際には便利な手法である。また、主成分分析を行って、劣化に対する複合的な影響因子の調査も行っている。例えば、ひび割れに対して、影響因子の複合として表現される主成分1～4までを算出して、グラフで可視化している。分析結果から、関心のある事象（ここでは劣化としてのひび割れランク）に対して、複合的に相関の高いデータを影響因子として抽出することで、データの構造理解に繋がるとしている。

吉田ら³⁸⁾は、RC床版の点検データを対象に、経過年数に応じた構造物健全性の低下に対する要因の抽出において、主成分分析と回帰分析を組み合わせた手法で取り組んでいる。まず、10項目ある点検項目（鉄筋露出、剥離、ひびわれ、等）のデータに対して、主成分分析を行い、得られる主成分に対して、劣化要因と考えられる解釈を与えている。主成分は、複数のデータ項目を複合的にふまえた新しいデータ指標としてとらえることができるため、元のデータ項目の寄与度を参照しながら、例えば、剥離・鉄筋露出関連、や、ひび割れ関連、といった具体的に、複合的な主成分として意味を与える。このようにして得た主成分を変数に持つ回帰式によって、構造物の経年劣化を回帰（予測）し、主成分による回帰の違い、すなわち、劣化要因による回帰の違いを調べている。

そのほか、データ分析やマイニング手法を積極的に利用した論文では無いものの、張³⁹⁾らは、コンクリート床版を対象に、潜在的な劣化要因となりうるデータ項目について、調査・整理を行っている。具体的には、劣化に寄与するリスクとして、施工年代に起因するリスクや、使用環境に起因するリスクなどをまとめ、その上で、点検の結果みられた事象と劣化機構との関係を整理している。

矢吹ら⁴⁰⁾は、センサデータモデルと知識モデルとを統合化し、膨大なセンサデータより建物状態に関する知識発見を行うデータマイニング手法を開発している。

石田ら⁴¹⁾は、橋梁点検データに対して生存時間解析を適用し、東北地方特有の厳しい環境に置かれる橋梁コンクリート部材の劣化予測を行いながら、予測に対する劣化要因の影響度分析を行っている。

8.2.4 予測

インフラ維持管理において、将来の構造物状態を見据えた管理計画の立案は重要な課題である。措置のコストと構造物の状態との関係を眺みながらの維持管理においては、構造物の状態が、将来のどの段階で、どのような状態に発展していくのか、といったことを予測（時間的な推定）することは、現場からのニーズも高い。

構造物健全度の将来予測に関する研究は、履歴も厚く、例えば、構造物供試体を用いた負荷実験によって、構造物のS-N線図を描き、将来予測を行う為の基本的な特性を把握するといった研究は報告例も多い。例えば、阿部ら⁴²⁾⁴⁴⁾は、RC床版の供試体実験を元に、輪

荷重走行疲労実験データによって S-N 線図を描くことで補強を行った構造物についての余寿命推定モデルとし、構造物健全度の将来予測を行っている。

また、三上ら⁴⁵⁾⁴⁸⁾は、RC床版の点検データ、実橋梁から測定した実測データを用いて、S-N線図を描画し、マイナー則に基づく劣化予測を行っている。

小川ら⁴⁹⁾は、鋼橋 RC床版の劣化を対象に、点検データや諸元データを用い、西日本高速道路 関西支社管内の RC床版の約 3,250 径間を対象に、統計分析による劣化要因の分析と劣化予測を行っている。特に、上面増厚の補修前後に関し、補修効果の予測を行っている。

宮川ら⁵⁰⁾は、点検データと補修データとを双方用いて、ニューラルネットワークを適用した劣化予測を行い、構造物の目標残存耐用期間を設定することで、補修後の構造物の維持管理も視野に入れた維持管理計画立案に繋がれるとしている。

そのほか、吉田ら⁵¹⁾は、構造物健全性の劣化について、経過年による劣化二次曲線に対して、劣化機構に関する特性指標を説明変数として加えた回帰式を求めている。この回帰式の推定において、EMアルゴリズム(Expectation–Maximization algorithm)と PSO を組み合わせた手法を提案している。

中津ら⁵²⁾は、遺伝的アルゴリズム(GA: Genetic Algorithm)を用いて予防保全を考慮し、補修年度を前倒した橋梁維持管理計画の策定を提案している。

また、小林、貝戸ら⁵³⁾は、橋梁床版の目視点検データを対象に、健全性の劣化をマルコフモデルであるとした劣化ハザードモデルを提案している。すなわち、橋梁部材の健全度については、将来状態を確定的に予測はできないとしながら、ある時点 t_A の状態から次の時点 t_B の状態に推移する際には、推移前の時点 t_A の状態のみに依存するという性質(マルコフ性)を仮定している。ここで時点 t_A 以前を含む過去の履歴とは独立である(依存しない)とする立場である。

また、彼らは、この考え方にに基づきながら、初期施工状態等が異なる構造物について、異質性を仮定することで劣化過程の違いを表現し、劣化予測のモデル化の精度向上を行っている⁵⁴⁾。実際に米国ニューヨーク市の橋梁 1,481 橋に対し、異なる劣化パターンを異質性パラメータを定義することで表現し、劣化予測モデルをベンチマーキングとして提示している。彼らは、このハザードモデルについて、ベイズ推定と組み合わせた確率的予測モデルや⁵⁵⁾、個々の施設毎の異質性やより上位となる個々の施設を包括したグループ間の異質性など異質性に階層性をもたせたベイズ推定を提示するなど⁵⁶⁾⁵⁷⁾、様々な試行により構造物の将来状態の予測を行っている。

その他の事例としては、Linら⁵⁸⁾は、SVMを用いた雨量推定を行うとともに、雨量の推定結果と河川流量の実測値とを統合し、河川流量変動の短時間将来予測を行っている。一言ら⁵⁹⁾は、深層学習を用いた河川水位の予測を行っている。また、Kitsikoudisら⁶⁰⁾は、河床材料の移動を ANN(Artificial Neural Networks), SR(Symbolic Regression), 遺伝的プログラミング(GP: Genetic Programming)を用いて個別のモデル構築を行い、結果の比較評価を行っ

ている。

8.2.5 モニタリング

関心のある事象に対して状態を観測する方法について、リアルタイム性（常時性）を担保したり、遠隔監視を行うことでデータを活用するモニタリングに関連する既往研究について紹介する。

センサを設置して常時監視を行う場合や、路面性状調査車両など、移動型の計測機器によって、広範囲の構造物を常時では無いものの、定期的に観測するといった方法がある。

小林ら⁶¹⁾は、橋梁に設置した温度センサとひずみセンサのデータを対象に、データ間の時系列相関調査やグラフによる視覚的な分析を適用し、データ変動や温度差の年変動を調べている。年単位での長期的かつ連続的なデータを収集して可視化できることも、大きな特徴と言える。また、星埜ら⁶²⁾は、10径間の橋梁を対象に3年間のデータ計測を行って、床版の乾燥収縮の長期観測を行っている。服部、野村ら⁶³⁾は、振動データに対するAdaBoostを用いた橋梁変状の検知と橋梁ヘルスマニタリングを行っている。

センサデータの前処理にAIを活用した例として、宮本ら⁶⁴⁾は、深層学習を用いた常時自動記録からの解析区間の自動抽出を試みている。

モニタリングに関しては、長大な橋梁を対象とした例も多い。例えば、遠山ら⁶⁵⁾の研究では、明石海峡大橋を対象に、加速度計、地震計、GPSなどのセンサを用いて橋梁の動態観測を行っている。

O'Connorら⁶⁶⁾は道路橋を対象としてワイヤレスネットワークを介して2年間観測したひずみセンサ値に対して、SVMや遺伝的プログラミングを組み合わせ、橋梁の変形や振動に関する状態変化のモニタリングを行っている。Santosら⁶⁷⁾は、斜張橋を対象とする計測データに関して、PCA（主成分分析）とクラスター分析を用いて、振動に基づいた変状検出を行い、剛性低下状態の判別について検証を行っている。

Khoaら⁶⁸⁾は、道路橋を観測した加速度データに対し、PCAとSVM等を組み合わせた手法を提案している。ここでのPCAの利用は、センサデータから抽出した高次元の特徴量に対するデータ次元の縮退に対して活用している。

Silvaら⁶⁹⁾は、遺伝的アルゴリズムを用いた橋梁の変状検出を試行している。

Crémonaら⁷⁰⁾は、ニューラルネットワークをベースとしたクラスタリング手法を提案し、一年半観測したデータに対する検証にて、橋梁の状態変化の検出が可能であることを示している。また、センサデータ統合（センサフュージョン）による変状検出についても報告している⁷¹⁾。

リアルタイムデータ取得の研究事例としては、光ファイバセンサを用いた例も存在し、篠田ら⁷²⁾は、光ファイバ加速度センサのデータによって橋梁の振動を観測できるという報告を行っている。また、光ファイバセンサも複数の計測原理が存在することから、センサ毎の感度や計測に要する時間等の特徴についても整理している。

そのほか、横山ら⁷³⁾は、加速度センサによって計測される振動データを対象に、地震発生時を想定して、ニューラルネットワークによる分析でリアルタイムに変状判定を行うといったシステムを提案している。

金ら⁷⁴⁾は、外部因子（環境温度）を考慮したベイズ推定を適用し、長期橋梁振動解析によるモニタリングを行っている。

Laoryら⁷⁵⁾は、SVRやランダムフォレスト等の複数の機械学習手法を統合した方式を提案し、鉄道橋の変状モニタリングを行っている。

リアルタイムなデータ計測に基づき、遠隔で構造物の健全性を評価するなど、具体的な目的を持ったシステム構築に関する研究開発も行われている⁷⁶⁻⁷⁸⁾。

そのほか、車両走行時の橋梁振動データを用いて橋梁健全度を推定する方法等もあるが⁷⁹⁾、これも、データの継続的（あるいは断続的な）取得に基づくモニタリングの一形態だと言えよう。また、自動車等の移動体から、道路や橋梁の状態を取得する手法も研究されている。Chenら⁸⁰⁾は、トラック等を想定した移動体による加速度計測に基づいた橋梁状態の判別について提案しており、Yinら⁸¹⁾は、鉄道車両に搭載したセンサにより軌道等の変状を検出するシステム VOBes(Vehicle On-Board Equipments)を開発しており、データ処理に深層学習を適用している。

これらの研究では、センサネットワークとしての枠組みでセンサとネットワークの双方の発展・浸透に伴って研究と展開例が提案されている。近年では、ユビキタスという概念がIoTとなり、より手軽にセンサや通信が利用できるようになったことで、現地でデータを前処理して遠隔地に送信するなど、データの取得とリアルタイムな通知がより高度に、より広範囲になってきている⁸²⁾。

また、センサネットワークとは異なるが、リモートセンシングの取組みにおいても、AI活用の報告が見られ、齋藤ら⁸³⁾は、ドローン撮影画像に対するCNNを用いた河川植生の自動判別手法の開発と業務応用を行っている。また、Baiら⁸⁴⁾は、SAR(Synthetic Aperture Radar)データに対するKNN(K-NearestNeighbors)手法を用いた被災建物のクラスタリングを試行している。

8.2.6 建設マネジメント

維持管理以外に、建設マネジメントにおけるAIや機械学習(ML: Machine Learning)の活用事例も多く見られる。Bilalら⁸⁵⁾は、建設業におけるビッグデータ活用研究事例についてレビューを行っている。論文の中で、機械学習技術を次の4種類に分類している：(1)分類（教師有り学習）、(2)クラスタリング（教師無し学習）、(3)関連性分析、(4)数値の推定。その中でも特に、教師有り学習とした分類について、建設業界でのビッグデータの使い道を整理している。また、建設業界でのビッグデータ活用については、「資源と無駄の最適化」や「性能予測」、「資産管理」、「BIM」などを含む13のサブドメインに分類している。

AIの活用事例について、矢吹ら⁸⁶⁾は、建設現場や災害地において撮影される数多くの写真の分類や管理の効率化を目的に、写真内にあるバックホウ、ブルドーザなどの建設機械、建設作業員、黒板などの表示板を識別するシステムを深層学習を用いて開発した。開発に当たっては既存のCNNであるSSD (Single Shot Multibox Detector)に転移学習を適用させることにより、小規模のトレーニングデータを対象とした学習において、高い認識率を得ている。

労働者の行動分析をベイズ推定により行った例⁸⁷⁾や労働者の生産性評価に決定木(DT: Decision Tree)を用いた例⁸⁸⁾のほか、遺伝的アルゴリズムによる従業員の割り当てとスケジューリングを行った例^{89),90)}がある。その他、建設生産性向上を目指し、ニューラルネットワークとファジー理論とを組み合わせた手法の提案⁹¹⁾もなされている。

PSOによるプロジェクト進捗管理と最適化に関する手法⁹²⁾や、労働者の行動をモデリングした事例⁹³⁾がある。最適化手法を用いた事例には、PSOの他にも、蟻の行動にヒントを得た最適化手法であるACO(Ant Colony Optimization)を用い、複数の目標による制約の中で、最適なプロジェクト管理の実現に適用した事例⁹⁴⁾がある。これらの最適化手法の他にも、ニューラルネットワーク等のAIを土木工学において活用した研究事例について、レビュー論文⁹⁵⁾で報告されている。

また、Akhavianら⁹⁶⁾は、スマートフォンを用い、ニューラルネットワークにより労働者行動認識を行っている。また、Gerassisら⁹⁷⁾は、ベイジアンネットワークを用いた、労働災害発生時の解析を行っている事例もある。

そのほか、建設に関する文書分類についての事例^{98),99)}や、画像やスケジュール等の非構造化データの分類を行った事例¹⁰⁰⁾がある。

その他、ANNを用いた構造上の不良の検出¹⁰¹⁾や、遺伝的アルゴリズムとANNを組み合わせた不良分類システムの提案¹⁰²⁾がある。

参考文献

- 1) 海洋架橋・橋梁調査会，橋梁マネジメント研究会：道路橋マネジメントの手引き，海洋架橋・橋梁調査会，2004.
- 2) Rahman, H. S., Alireza, K. and Reza, G.: Application of artificial neural network, kriging, and inverse distance weighting models for estimation of scour depth around bridge pier with bed sill, *Journal of Software Engineering and Applications*, Vol. 3, No. 10, pp. 944, 2010.
- 3) 山口 哲夫, 森濱 和正, 笠井 芳夫：コンクリート床版の裏面のひび割れの検出(非破壊試験)，*コンクリート工学年次論文報告集*，第19巻，第1号，pp. 1345-1350，1997.
- 4) 小濱 健吾, 貝戸 清之, 小林 潔司：混合ポアソン劣化モデル: コンクリートの剥離・剥落発生事象への適用，*土木学会論文集F4 (建設マネジメント)*，第69巻，第4号，pp. I_27-I_37，2013.

- 5) 貝戸 清之, 起塚 亮輔, 伊藤 哲男, 橋爪 謙治, 出口 宗浩: 床版かぶりコンクリートの剥離・剥落発生リスクと最適点検政策, *土木学会論文集 F4 (建設マネジメント)*, 第 68 巻, 第 1 号, pp. 11-27, 2012.
- 6) Koch, C., Georgieva, K., Kasireddy, V., Akinci, B. and Fieguth, P.: A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure, *Advanced Engineering Informatics*, Vol. 29, No. 2, pp. 196-210, 2015.
- 7) Paar, G., Caballo-Perucha, M. d. P., Kontrus, H. and Sidla, O.: Optical crack following on tunnel surfaces, *Optics East 2006*, Vol. 6382, No. 638207, pp. 1-8, 2006.
- 8) Yamaguchi, T. and Hashimoto, S.: Fast crack detection method for large-size concrete surface images using percolation-based image processing, *Machine Vision and Applications*, Vol. 21, No. 5, pp. 797-809, 2010.
- 9) Liu, Z., Suandi, S. A., Ohashi, T. and Ejima, T.: Tunnel crack detection and classification system based on image processing, *Electronic Imaging 2002*, pp. 145-152, 2002.
- 10) Maeda, K., Takahashi, S., Ogawa, T. and Haseyama, M.: Distress classification of road structures via decision level fusion, *2016 IEEE International Conference on Digital Signal Processing (DSP2016)*, pp. 589-593, 2016.
- 11) Dawood, T., Zhu, Z. and Zayed, T.: Automated Recognition of Surface Defects in Subway Systems, *The Fourth International Conference on Soft Computing Technology in Civil, Structural and Environmental Engineering*, 2015.
- 12) Makantasis, K., Protopapadakis, E., Doulamis, A., Doulamis, N. and Loupos, C.: Deep convolutional neural networks for efficient vision based tunnel inspection, *Intelligent Computer Communication and Processing (ICCP), 2015 IEEE International Conference on*, pp. 335-342, 2015.
- 13) Zakeri, H., Nejad, F. M. and Fahimifar, A.: Image Based Techniques for Crack Detection, Classification and Quantification in Asphalt Pavement: A Review, *Archives of Computational Methods in Engineering*, pp. 1-43, 2016.
- 14) Hadjidemetriou, G. M., Christodoulou, S. E. and Vela, P. A.: Automated detection of pavement patches utilizing support vector machine classification, *Electrotechnical Conference (MELECON), 2016 18th Mediterranean*, pp. 1-5, 2016.
- 15) Çevik, A., Kurtoğlu, A. E., Bilgehan, M., Gülşan, M. E. and Albegmprli, H. M.: Support vector machines in structural engineering: a review, *Journal of Civil Engineering and Management*, Vol. 21, No. 3, pp. 261-281, 2015.
- 16) Ranković, V., Grujović, N., Divac, D. and Milivojević, N.: Development of support vector regression identification model for prediction of dam structural behaviour, *Structural Safety*, Vol. 48, pp. 33-39, 2014.

- 17) Chen, J.-H., Su, M.-C., Cao, R., Hsu, S.-C. and Lu, J.-C.: A self organizing map optimization based image recognition and processing model for bridge crack inspection, *Automation in Construction*, 2016.
- 18) Prasanna, P., Dana, K. J., Gucunski, N., Basily, B. B., La, H. M., Lim, R. S. and Parvardeh, H.: Automated crack detection on concrete bridges, *IEEE Transactions on Automation Science and Engineering*, Vol. 13, No. 2, pp. 591-599, 2016.
- 19) 大竹 雄, 流石 堯, 小林 孝一, 本城 勇介: 橋梁点検データベースの統計解析に基づく劣化機構を考慮した鋼橋 RC 床版の健全度評価, *土木学会論文集 A1 (構造・地震工学)*, 第 68 巻, 第 3 号, pp. 683-695, 2012.
- 20) 本城 勇介, 大竹 雄, 佐藤 敦: 岐阜県橋梁点検データベースの統計解析に基づく簡易橋梁健全度評価指標, *構造工学論文集 A 日本学術会議土木工学・建築学委員会 [監修]*, 第 60 巻, pp. 462-474, 2014.
- 21) Galvan-Nunez, S. and Attoh-Okine, N.: Hybrid Particle Swarm Optimization and K-Means Analysis for Bridge Clustering Based on National Bridge Inventory Data, *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering*, F4016001, pp. 1-6, 2016.
- 22) 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*, 第 64 巻, 第 4 号, pp. 739-749, 2008.
- 23) Lu, N., Noori, M. and Liu, Y.: Fatigue Reliability Assessment of Welded Steel Bridge Decks under Stochastic Truck Loads via Machine Learning, *Journal of Bridge Engineering*, 04016105, 2016.
- 24) 全 邦釘, 蔵本 直弥, 熊岡 幸司: 多点同時計測と機械学習を用いた損傷同定手法の I 型断面はり部材への適用, *土木学会論文集 A2 (応用力学)*, 第 72 巻, 第 2 号, pp. I_623-I_631, 2016.
- 25) 森 弘, 大島 俊之, 三上 修一, 天野 政一, 井上 実: コンピュータ・グラフィクスと数量化理論を応用した橋梁の維持点検評価法, *土木学会論文集*, 第 501 号, pp. 113-121, 1994.
- 26) Cheng, M.-Y. and Hoang, N.-D.: Risk score inference for bridge maintenance project using evolutionary fuzzy least squares support vector machine, *Journal of Computing in Civil Engineering*, Vol. 28, No. 3, 04014003, 2012.
- 27) 中川 将秀, 中村 亮太, 内藤 英晴, 濱田 秀則: 1296 栈橋 RC 上部工における劣化の実態と評価方法に関する考察(維持管理), *コンクリート工学年次論文集*, 第 25 巻, 第 1 号, pp. 1811-1816, 2003.
- 28) 篠田 昌弘, 中島 進, 阿部 慶太: 鉄道もたれ壁の安定性に係わる健全度診断法の開発, *土木学会論文集 C (地圏工学)*, 第 68 巻, 第 2 号, pp. 433-450, 2012.
- 29) 宮下 剛, 玉田 和也, 劉 翠平, 岩崎 英徳, 長井 正嗣: 振動を利用した健全性診断に向けた実橋梁の損傷と動特性変化, *土木学会論文集 A1 (構造・地震工学)*, 第 68 巻, 第 2 号, pp. 367-383, 2012.

- 30) 水谷 大二郎, 貝戸 清之, 小林 潔司: 階層ベイズ法による補修効果の事後評価, *土木学会論文集 F4 (建設マネジメント)*, 第 69 巻, 第 3 号, pp. 204-221, 2013.
- 31) 西尾 真由子, 藤野 陽三: ベイズ推定による既存構造物数値モデルの不確定性定量化とキャリブレーション, *土木学会論文集 A2 (応用力学)*, 第 69 巻, 第 2 号, pp. I_711-I_718, 2013.
- 32) Harvey, R. R. and McBean, E. A.: Predicting the structural condition of individual sanitary sewer pipes with random forests, *Canadian Journal of Civil Engineering*, Vol. 41, No. 4, pp. 294-303, 2014.
- 33) 野村 泰稔, 井田 一晟, 宮地 翼, 宮本 学, 菅 真人: 深層学習に基づく配管バルブの健全性モニタリング, *土木学会論文集 F6 (安全問題)*, 第 72 巻, 第 2 号, pp. I_183-I_190, 2016.
- 34) Tabatabaee, N., Ziyadi, M. and Shafahi, Y.: Two-Stage Support Vector Classifier and Recurrent Neural Network Predictor for Pavement Performance Modeling, *Journal of Infrastructure Systems*, Vol. 19, No. 3, pp. 266-274, 2012.
- 35) Ceylan, H., Bayrak, M. B. and Gopalakrishnan, K.: Neural Networks Applications in Pavement Engineering: A Recent Survey, *International Journal of Pavement Research and Technology*, Vol. 7, No. 6, pp. 434-444, 2014.
- 36) 土木学会コンクリート委員会コンクリート標準示方書改訂小委員会: コンクリート標準示方書維持管理編 2013 年制定, 土木学会, 2013.
- 37) 佐藤 誠, 大島 俊之, 三上 修一, 樋口 匡: 点検データに基づく床版劣化の推定と BMS への応用, 第 51 巻, pp. 1147-1155, 2005.
- 38) 吉田 郁政, 本城 勇介, 大竹 雄: EM アルゴリズムを用いた劣化曲線群の同定法, *土木学会論文集 A1 (構造・地震工学)*, 第 69 巻, 第 2 号, pp. 174-185, 2013.
- 39) 張 青, 野崎 真司, 広瀬 道夫, 森本 博昭: コンクリート橋梁の劣化リスクの評価について, *土木情報利用技術論文集*, 第 14 巻, pp. 41-46, 2005.
- 40) 矢吹 信喜, 塚本 祥太, 中山 一希, 福田 知弘, 道川 隆士: 建物のエネルギー消費の改善のためのデータマイニング手法と知識システム, *土木学会論文集 F3 (土木情報学)*, 第 70 巻, 第 2 号, pp. I_26-I_33, 2014.
- 41) 山崎 崇央, 石田 哲也: 生存時間解析を用いた東北地方における橋梁コンクリート部材の劣化定量分析, *土木学会論文集 F4 (建設マネジメント)*, 第 71 巻, 第 4 号, pp. I_11-I_22, 2015.
- 42) 元 燦豪, 阿部 忠, 木田 哲量, 小森 篤也: CFS・CFSS 格子接着補強した RC 床版の耐疲労性の評価および S-N 曲線式の提案, *セメント・コンクリート論文集*, 第 66 巻, 第 1 号, pp. 576-583, 2012.

- 43) 阿部 忠, 木田 哲量, 勝呂 翔平, 伊藤 清志: ひび割れ損傷を受けた RC 床版の一次・二次補強法における破壊状況および耐疲労性の評価, *セメント・コンクリート論文集*, 第 66 巻, 第 1 号, pp. 560-567, 2012.
- 44) 阿部 忠: 道路橋 RC 床版の疲労寿命予測および健全度評価に関する一考察, *構造工学論文集 A 日本学術会議土木工学・建築学委員会 [監修]*, 第 61 巻, pp. 1050-1061, 2015.
- 45) 竹田 俊明, 三上 修一, 大島 俊之, 鈴木 広大: 寒冷地における橋梁の劣化環境と RC 床版の劣化予測に関する研究, *構造工学論文集 A*, 第 53 巻, pp. 674-685, 2007.
- 46) 鈴木 広大, 大島 俊之, 三上 修一, 山崎 智之, 佐藤 誠, 竹田 俊明: 床版の圧縮強度分布と簡易疲労劣化予測手法の研究, *土木学会北海道支部論文報告集*, 第 62 号, pp. 85-88, 2005.
- 47) 樋口 匡, 大島 俊之, 三上 修一, 山崎 智之, 佐藤 誠, 竹田 俊明: RC 床版ひび割れの劣化因子の分析と劣化予測の検討, *土木学会北海道支部論文報告集*, 第 61 号, pp. 88-91, 2005.
- 48) 樋口 匡, 大島 俊之, 三上 修一, 山崎 智之, 佐藤 誠, 竹田 俊明: BMS に用いる RC 床版の疲労劣化予測手法について, 第 60 巻, pp. 224-227, 2004.
- 49) 小川 篤生, 縦山 好幸, 緒方 辰男: 鋼橋 RC 床版の劣化要因と上面増厚効果の分析, *構造工学論文集 A 日本学術会議土木工学・建築学委員会 [監修]*, 第 60 巻, pp. 1085-1094, 2014.
- 50) 本荘 清司, 上東 泰, 井手上文雄, 丸屋 剛, 谷口 秀明, 宮川 豊章: 内部塩分と凍結防止剤により劣化した RC 中空床版橋への劣化予測に基づく計画的維持管理の適用, *土木学会論文集*, 第 774 号, pp. 99-110, 2004.
- 51) 吉田 郁政, 蔵谷 湧介, 大竹 雄, 本城 勇介: インフラ構造物の劣化予測のための多目的曲線群の同定法, *土木学会論文集 A2 (応用力学)*, 第 70 巻, 第 2 号, pp. I_33-I_42, 2014.
- 52) 中津 功一朗, 古田 均, 野村 泰稔, 高橋 亨輔, 石橋 健, 三好 紀晶: GA による実用化を目指した長期的な橋梁維持管理計画策定, *知能と情報*, 第 23 巻, 第 4 号, pp. 469-479, 2011.
- 53) 津田 尚胤, 貝戸 清之, 青木 一也, 小林 潔司: 橋梁劣化予測のためのマルコフ推移確率の推定, *土木学会論文集*, 第 801 号, pp. 69-82, 2005.
- 54) 小濱 健吾, 岡田 貢一, 貝戸 清之, 小林 潔司: 劣化ハザード率評価とベンチマーキング, *土木学会論文集 A*, 第 64 巻, 第 4 号, pp. 857-874, 2008.
- 55) 貝戸 清之, 小林 潔司: マルコフ劣化ハザードモデルのベイズ推定, *土木学会論文集 A*, 第 63 巻, 第 2 号, pp. 336-355, 2007.
- 56) 貝戸 清之, 小林 潔司, 青木 一也, 松岡 弘大: 混合マルコフ劣化ハザードモデルの階層ベイズ推計, *土木学会論文集 D3 (土木計画学)*, 第 68 巻, 第 4 号, pp. 255-271, 2012.

- 57) 水谷 大二郎, 小濱 健吾, 貝戸 清之, 小林 潔司: 社会基盤施設の多元的劣化過程モデル, *土木学会論文集 D3 (土木計画学)*, 第 72 卷, 第 1 号, pp. 34-51, 2016.
- 58) Lin, G.-F., Chou, Y.-C. and Wu, M.-C.: Typhoon flood forecasting using integrated two-stage support vector machine approach, *Journal of Hydrology*, Vol. 486, pp. 334-342, 2013.
- 59) 一言 正之, 櫻庭 雅明, 清 雄一: 深層学習を用いた河川水位予測手法の開発, *土木学会論文集 B1 (水工学)*, 第 72 卷, 第 4 号, pp. I_187-I_192, 2016.
- 60) Kitsikoudis, V., Sidiropoulos, E. and Hrissanthou, V.: Machine learning utilization for bed load transport in gravel-bed rivers, *Water resources management*, Vol. 28, No. 11, pp. 3727-3743, 2014.
- 61) 小林 裕介, 三木 千壽, 田辺 篤史: 鋼床版箱桁橋梁の温度変形挙動を利用した健全度評価モニタリング, *土木学会論文集*, 第 62 卷, 第 4 号, pp. 794-807, 2007.
- 62) 星埜 正明, 内田 道雄: RC10 径間連続床版橋における長期測定解析結果, *土木学会論文報告集*, 第 323 号, pp. p165-178, 1982.
- 63) 服部 洋, 古田 均, 野村 泰稔, 中津 功一郎, 石橋 健: AdaBoost による振動予測を用いた橋梁ヘルスマニタリングシステムの構築に関する実験的研究, *土木学会論文集 A2 (応用力学)*, 第 67 卷, 第 2 号, pp. I_825-I_832, 2011.
- 64) 宮本 崇, 古屋 貴彦, 盛川 仁: 深層学習を用いた常時微動記録からの解析区間の自動抽出, *土木学会論文集 A2 (応用力学)*, 第 73 卷, 2017.
- 65) 遠山 直樹, 山田 郁夫, 楠原 栄樹: 長大橋動態観測データの分析, *風工学シンポジウム論文集*, 第 19 卷, pp. 495-500, 2006.
- 66) O'Connor, S. M., Zhang, Y., Lynch, J. P., Ettouney, M. M. and Jansson, P. O.: Long-term performance assessment of the Telegraph Road Bridge using a permanent wireless monitoring system and automated statistical process control analytics, *Structure and Infrastructure Engineering*, pp. 1-21, 2016.
- 67) Santos, J. P., Cremona, C., Orcesi, A. D., Silveira, P. and Calado, L.: Static-based early-damage detection using symbolic data analysis and unsupervised learning methods, *Frontiers of Structural and Civil Engineering*, Vol. 9, No. 1, pp. 1-16, 2015.
- 68) Khoa, N. L., Zhang, B., Wang, Y., Chen, F. and Mustapha, S.: Robust dimensionality reduction and damage detection approaches in structural health monitoring, *Structural Health Monitoring*, 1475921714532989, 2014.
- 69) Silva, M., Santos, A., Figueiredo, E., Santos, R., Sales, C. and Costa, J. C.: A novel unsupervised approach based on a genetic algorithm for structural damage detection in bridges, *Engineering Applications of Artificial Intelligence*, Vol. 52, pp. 168-180, 2016.
- 70) Crémona, C., da Silveira, A. P. C. and de Oliveira Martins, L. C.: Real - time damage detection based on pattern recognition, *Structural Concrete*, 2016.
- 71) Santos, J. P., Cremona, C., Orcesi, A. D. and Silveira, P.: Early Damage Detection Based on Pattern Recognition and Data Fusion, *Journal of Structural Engineering*, 04016162, 2016.

- 72) 篠田 昌弘, 真井 哲生, 江原 季映, 中島 進, 阿部 慶太, 藤田 圭一, 土屋 宗典: 小型起振器と光ファイバセンサを用いた鉄道橋梁下部構造物の振動計測, *土木学会論文集 A1 (構造・地震工学)*, 第 69 巻, 第 1 号, pp. 40-56, 2013.
- 73) 横山 功一, 原田 隆郎, 黒田 聡: ニューラルネットワークを用いた橋脚の地震時リアルタイム損傷判定法に関する検討, *日本地震工学会論文集*, 第 7 巻, 第 5 号, pp. 31-44, 2007.
- 74) 金 哲佑, 森田 知明, 杉浦 邦征: 温度および通行車両の影響を考慮した長期橋梁振動ヘルスマonitoringのためのベイズ的アプローチ, *土木学会論文集 A2 (応用力学)*, 第 70 巻, 第 2 号, pp. I_73-I_80, 2014.
- 75) Laory, I., Trinh, T. N., Posenato, D. and Smith, I. F.: Combined model-free data-interpretation methodologies for damage detection during continuous monitoring of structures, *Journal of Computing in Civil Engineering*, Vol. 27, No. 6, pp. 657-666, 2013.
- 76) 奥松 俊博, 岡林 隆敏, 田代 大樹, 要谷 貴則: 橋梁遠隔モニタリングシステムによる鋼ランガートラス橋の固有振動数の推移観測, *構造工学論文集 A*, 第 53 巻, pp. 844-852, 2007.
- 77) 三木 千壽, 水ノ上 俊雄, 小林 裕介: 光通信網を使用した鋼橋梁の健全度評価モニタリングシステムの開発, *土木学会論文集*, 第 686 巻, pp. 31-40, 2001.
- 78) 豊田 晋也, 宮崎 早苗, 魚本 健人: 遠隔モニタリングによる RC 橋の健全性に関する長期的変動解析 (<特集>安全で快適な都市システムの実現をめざして(ICUS)), *生産研究*, 第 60 巻, 第 3 号, pp. 66-68, 2008.
- 79) 金 哲佑, 川谷 充郎: 単一車両走行による橋梁振動データを用いた橋梁の健全度評価, *鋼構造論文集*, 第 15 巻, 第 58 号, pp. 37-46, 2008.
- 80) Chen, S., Cerda, F., Rizzo, P., Bielak, J., Garrett, J. H. and Kovačević, J.: Semi-supervised multiresolution classification using adaptive graph filtering with application to indirect bridge structural health monitoring, *IEEE Transactions on Signal Processing*, Vol. 62, No. 11, pp. 2879-2893, 2014.
- 81) Yin, J. and Zhao, W.: Fault diagnosis network design for vehicle on-board equipments of high-speed railway: A deep learning approach, *Engineering Applications of Artificial Intelligence*, Vol. 56, pp. 250-259, 2016.
- 82) Kwon, D., Hodkiewicz, M. R., Fan, J., Shibutani, T. and Pecht, M. G.: IoT-Based Prognostics and Systems Health Management for Industrial Applications, *IEEE Access*, Vol. 4, pp. 3659-3670, 2016.
- 83) 齋藤 正徳, 湧田 雄基, 市川 健, 天谷 香織, 那須野 新, 大石 哲也, 池内 幸司, and 石川 雄章: UAV 及び深層学習を用いた植生の自動判別による河道維持管理手法の開発, *to be published in 水工学論文集第 62 巻 (土木学会論文集 B1(水工学))*, 第 74 巻, 第 4 号, 2017.

- 84) Bai, Y., Adriano, B., Mas, E. and Koshimura, S.: Machine Learning Based Building Damage Mapping from the ALOS-2/PALSAR-2 SAR Imagery: Case Study of 2016 Kumamoto Earthquake, *Journal of Disaster Research*, Vol. 12, No. sp, pp. 646-655, 2017.
- 85) Bilal, M., Oyedele, L. O., Qadir, J., Munir, K., Ajayi, S. O., Akinade, O. O., Owolabi, H. A., Alaka, H. A. and Pasha, M.: Big Data in the construction industry: A review of present status, opportunities, and future trends, *Advanced Engineering Informatics*, Vol. 30, No. 3, pp. 500-521, 2016.
- 86) Yabuki, N., Nishimura, N. and Fukuda, T.: Automatic Object Detection from Digital Images by Deep Learning with Transfer Learning, pp. 3-15, 2018.
- 87) Gong, J., Caldas, C. H. and Gordon, C.: Learning and classifying actions of construction workers and equipment using Bag-of-Video-Feature-Words and Bayesian network models, *Advanced Engineering Informatics*, Vol. 25, No. 4, pp. 771-782, 2011.
- 88) Desai, V. S. and Joshi, S.: Application of decision tree technique to analyze construction project data, *International Conference on Information Systems, Technology and Management*, pp. 304-313, 2010.
- 89) Chen, Y.-J., Feng, C.-W., Wang, Y.-R. and Wu, H.-M.: Using BIM model and genetic algorithms to optimize the crew assignment for construction project planning, *International Journal of Technology*, No. 3, pp. 179-187, 2011.
- 90) Senouci, A. and Al-Derham, H. R.: Genetic algorithm-based multi-objective model for scheduling of linear construction projects, *Advances in Engineering Software*, Vol. 39, No. 12, pp. 1023-1028, 2008.
- 91) Cheng, M.-Y., Tsai, H.-C. and Sudjono, E.: Evaluating subcontractor performance using evolutionary fuzzy hybrid neural network, *International Journal of Project Management*, Vol. 29, No. 3, pp. 349-356, 2011.
- 92) Zheng, X. and Liu, Z.: The schedule control of engineering project based on particle swarm algorithm, *Communication Systems, Networks and Applications (ICCSNA), 2010 Second International Conference on*, Vol. 1, pp. 184-187, 2010.
- 93) Han, S., Lee, S. and Peña-Mora, F.: A machine-learning classification approach to automatic detection of workers' actions for behavior-based safety analysis, *Computing in Civil Engineering (2012)*, pp. 65-72, 2012.
- 94) Doerner, K., Gutjahr, W. J., Hartl, R. F., Strauss, C. and Stummer, C.: Pareto ant colony optimization: A metaheuristic approach to multiobjective portfolio selection, *Annals of operations research*, Vol. 131, No. 1-4, pp. 79-99, 2004.
- 95) Lu, P., Chen, S. and Zheng, Y.: Artificial intelligence in civil engineering, *Mathematical Problems in Engineering*, Vol. 2012, 145974, 2012.

- 96) Akhavian, R. and Behzadan, A. H.: Smartphone-based construction workers' activity recognition and classification, *Automation in Construction*, Vol. 71, pp. 198-209, 2016.
- 97) Gerassis, S., Martín, J., García, J. T., Saavedra, A. and Taboada, J.: Bayesian decision tool for the analysis of occupational accidents in the construction of embankments, *Journal of construction engineering and management*, 04016093, 2016.
- 98) Caldas, C. H., Soibelman, L. and Han, J.: Automated classification of construction project documents, *Journal of Computing in Civil Engineering*, Vol. 16, No. 4, pp. 234-243, 2002.
- 99) Ur-Rahman, N. and Harding, J. A.: Textual data mining for industrial knowledge management and text classification: A business oriented approach, *Expert Systems with Applications*, Vol. 39, No. 5, pp. 4729-4739, 2012.
- 100) Soibelman, L., Wu, J., Caldas, C., Brilakis, I. and Lin, K.-Y.: Management and analysis of unstructured construction data types, *Advanced Engineering Informatics*, Vol. 22, No. 1, pp. 15-27, 2008.
- 101) Chen, Q., Chan, Y. and Worden, K.: Structural fault diagnosis and isolation using neural networks based on response-only data, *Computers & Structures*, Vol. 81, No. 22, pp. 2165-2172, 2003.
- 102) Marwala, T. and Chakraverty, S.: Fault classification in structures with incomplete measured data using autoassociative neural networks and genetic algorithm, *CURRENT SCIENCE*, Vol. 90, No. 4, pp. 542-548, 2006.

9. インフラ維持管理への AI 活用ビジョン

9.1 はじめに

人間に代わって何かをしてくれる機械は、科学技術の発展とともに実用化され、我々の生活にあふれており、これからも加速度的に増えていくと考えられる。炊飯器や洗濯機に搭載され、銘柄に合わせたご飯の炊き方や洗濯物に合わせた多様な洗濯を命令通りに機械を動作させるマイコンは現在では人工知能とは呼ばれない。決まった時間に家の中をぐるぐる回りながら移動して掃除をしてくれる機械のうち自律走行のための地図を内部で生成するものは発売当初は AI 搭載とうたわれながらも、しばらく時間がたつと珍しくもなくなり、今では勝手に掃除をしてくれるちょっと高価な掃除機くらいの感覚であろう。これらは AI 効果¹⁾と呼ばれる人工知能を実現するための途中段階で、人工知能の1つと言っても構わないはずの何物かであるにもかかわらず、ただの自動化で人工知能ではないと思ってしまう心理効果である。第3次 AI ブームの最中である現時点では人工知能と言えばほぼ深層学習技術を指すが、社会に浸透するに従い、将来、現在の人工知能は単なる自動化技術と呼ばれる可能性がある。このように、科学技術の進歩と共に人工知能と呼ばれるものの実体は変わっていくと考えられる。

本章では以上を踏まえ、人工知能の実現を目指した理論や技術を広義の人工知能として AI (Artificial Intelligence : 人工知能) と呼ぶこととし、インフラ維持管理で AI を活用するビジョンの提示を試みる。本章で使用する AI という用語は、第8章で紹介された研究で使用されている単なる統計処理を含んだ理論や技術、第10章で想定している深層学習等の機械学習技術、および、将来出てくると予想される新しい理論や技術もすべて含んだ広義の概念として扱う。

9.1.1 プロジェクトチームでの基本的な意見

AI を活用したインフラ維持管理を推進することにより、管理者や技術者の負担軽減や大量の老朽化施設の管理の高度化などが期待されている。2010年代半ば以降の第3次 AI ブームはインターネットから得られるテキストや画像といった膨大なデータによるところが大きい。大量のデータの通信や処理が必要となる IoT (Internet of Things, 以下, IoT) の実用化においては、送信前データの処理や収集したデータの分析、人が日常生活で IoT を使用するための AI スピーカのようなインタフェースなどに AI の活用が検討または適用されている。第1次と第2次の AI ブームは社会に広く適用されることなく終わってしまったが、ドローンや打音ロボットなどで取得されるデータを活用するためには、AI はインフラ維持管理に有効な基盤技術として継続的に研究開発から社会実装まで取り組むべき技術だと考えられる。そこで、本プロジェクトチームでは、将来のあるべき AI 活用の姿とそれに向けて必要な取り組みについて提言を行うべく検討を進めた。AI が活用されたインフラ維持管理の実現に向けて取り組むべき課題等について参加メンバーから出された意見の概要を図9.1.1に示す。

- AI 活用方針
 - AIと技術者の配置にメリハリを付ける
 - 維持管理費低減へのシナリオ
- AIを活用した構造物管理のフレームワーク
 - 点検・モニタリング, 3次元計測, 構造解析, アセットマネジメント
 - SIP 開発技術 (ノウハウ, データモデル) とIoT, ビッグデータの活用
 - マルチモーダル解析による現状把握, 将来予測
- AIを前提とした社会制度の設計
 - 説明責任
 - 他分野 (防災, 都市計画など) との協働
- 社会実装に必要な要素
 - 投資判断技術, 補修技術
 - 劣化予測技術
 - 人材育成, 裾野の拡大
- 継続的な技術モニタリングと開発サイクル
 - 土木構造物の維持管理サイクルとデータ分析 (データサイエンス) サイクルの連携
- 物理現象の解明と計測
- AI 活用の方向性
 - 個別タスクの効率化からAIを前提としたマネジメントサイクルへの変化
 - 人が見てもわからなかったことの解決
 - データのもつ次元に時間軸を追加した時系列分析, 変化抽出

図 9.1.1 取り組むべき課題等に関する意見の概要

9.1.2 短期ビジョンと長期ビジョンの考え方

インフラ維持管理への AI 活用のビジョンを示すに当たり、想定する時期により社会状況が大きく変化していることは容易に想像される。そこで、AI の適用は段階的に行われると考え、AI 活用ビジョンを短期ビジョンと長期ビジョンの二つに分けた。短期ビジョンは想像しやすい未来として位置づけ、直近から 2030 年頃を想定し、現在取り組んでいる研究や開発を実用化に向けて着実に進め、適用すれば実現できる技術や社会とした。長期ビジョンは理想とする未来と位置づけ、2040-2050 年頃の正確な予測が難しい中で専門家が考える未来像とした(図 9.1.2)。

短期ビジョンでは、現在の各種取り組みが進められるが、その多くは現行の維持管理フローにおける各工程のほんの一部を AI に置き換えたものと考えられる。さらに、次第にデータやデータ分析手法、利用に関するノウハウなどが蓄積され、前後工程との連携や工程の見直しが部分的に進むと考えられる。

その後に起こると予想される大きなブレークスルーは、AI 活用が当然となった社会の中で、多くの技術者の発想の転換が起きるか、あるいは全く新しい技術が普及するといった、AI 活用の効果が表に大きく出るきっかけを指す。振り返れば、Windows95 は 1995 年に登場し、パソコンの普及に貢献したと言われ、日本の世帯パソコン保有率は 2000 年に 5 割を超えた。Google は 1998 年に創業し、今では情報収集をインターネット検索から始めるのが一般化している。初代 iPhone

は 2007 年に発売されて物理キーボードがないスマートフォンやタブレットのブームを作ったと言われており、2017 年には日本の世帯スマートフォン保有率は 75%を超えた。20 年、30 年前には現在のような情報化社会になることは想像できなかった。まさに大きなブレークスルーの好例である。

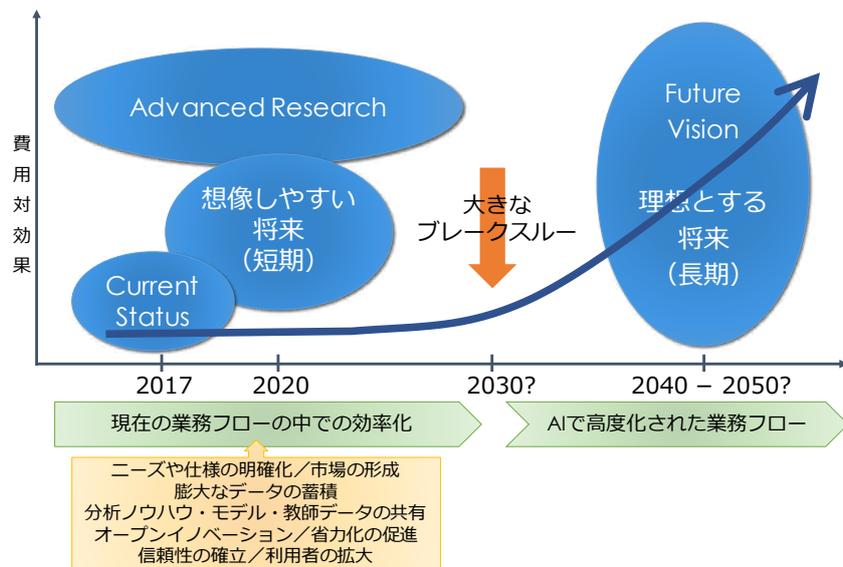


図 9.1.2 AI 活用の効果の想定される時間的な変化

土木学会では、1990 年に「AI で描く未来—土木 AI 進化論—」を刊行している。1990 年代のはじめ日本はインターネットがほとんど普及しておらず、この時代に予測された 2010 年の未来像として FAX を中心とした情報配信がなされる社会が語られている²⁾。総務省の調査によれば、1996 年の商品情報の配信で使用されるメディアは FAX が 30.0%で、インターネットは 3.2%であったが、2005 年ではホームページが 56.9%、FAX は 23.2%となり、FAX よりもインターネットがより利用されるようになった³⁾。このように、これから数 10 年後の新しい技術が普及した社会で AI がどのように維持管理サイクルで活用されているのか具体的な姿を想像することは難しい。

長期ビジョンでは、大きなブレークスルーにより加速度的に AI 活用が進められ、AI 同士が連携して動作している社会を想定した。そこでは、膨大なデータと AI による解析技術の活用を前提とした多様な業務フローが実現されていると考えられる。例えば、全国一律の点検要領を使うのでは無く、構造物の種類や周辺の気候などによって使用する点検要領を変え、100 年壊れないための手厚い維持管理手法と 20 年後には更新することを前提とした設計と簡易な維持管理手法を使い分ける等、今では考えられないような考え方も取り入れられた個別の構造物や立地に適した合理的な維持管理に変わっていく可能性も考えられる。

9.1.3 AI活用の方向性

1つの大きな流れは、膨大なデータが蓄積され、それを解析するアルゴリズムやモデルなどが多数提案される技術シーズの変化であろう。多くのシーズとニーズのマッチングが進み、実務レベルで活用されビジネスとして成立させるための要件が整えば、AI活用は促進される。また、それを使用する技術者の育成や利用環境の整備、倫理的問題への解決策など社会受容が進めば大きなブレークスルーにつながる。ブレークスルーの前に起こると考えられる変化を表9.1.1に示す。本項では、AI活用にあたり、留意すべき方向性について述べる。

表 9.1.1 AI活用の方向性

技術シーズの変化	
データ	<p>データが多い、複雑度の少ない分野からAI活用が進む</p> <ul style="list-style-type: none"> 蓄積された橋梁点検のデータや自動運転で得られたデータからAI適用が進む 構造物の劣化状況把握は点検（損傷検出）から一部モニタリング（異常検出）へ移行 ノウハウ蓄積は損傷度判定から始まり、工法判定から劣化予測へ拡大 類似案件抽出、技術者教育、判断支援などへ順次活用が進む AIと現場ニーズとのマッチングが進み、適用範囲が広がる
技術の融合	<p>AIとその他ICTのコラボで維持管理が高度化</p> <ul style="list-style-type: none"> AIによる異常検出とIoT（新センサ・新通信規格） → 一部の点検がモニタリングへ移行 AIによるマルチモーダル解析とビッグデータ技術 → 予測精度の向上 AIによる物体認識と可視化技術（AR/VR/MR）とGNSS補正情報 → 現場確認から遠隔操作へ
ビジネス判断の変化	
投資	<p>投資額の小さい技術や潜在市場の大きい分野からAI活用が進む</p> <ul style="list-style-type: none"> 室内から現場へ：室内での判読や劣化予測 → 現場でのスクリーニングなど 画像から音声や点群へ：画像からの変状抽出 → 音声による異常検知、形状変化抽出など
省力化	<p>簡単な現場作業から省力化・無人化が進む</p> <ul style="list-style-type: none"> AIの異常検出とIoTにより、現場での施設管理作業は室内での監視作業に変わる AIのエッジ化/フог化により、従来室内で実施していた損傷判定などを現場で実施 自動運転やロボットの実用化により、無人で行う点検や補修工事の監督を室内で実施
社会環境の変化	
教育	<p>知識ベースの蓄積とカスタマイズされた教材や環境によって技術者育成の効率が上がる</p> <ul style="list-style-type: none"> 知識型AIにより、研究論文や業務報告書、事例などが効率的にデータベース化される 生徒の学習進捗や短所長所に合わせた教材がリアルタイムでカスタマイズされる 教師の成績評価の自動化や推奨学習リソースの提案がされる AIにより最適化された体験型教育環境が一般化される
利用者	<p>UXの向上によって適用範囲や利用者層が広がる</p> <ul style="list-style-type: none"> 土木技術者にとって有用性や効果があり、ニーズが満たされるようになる 信頼性や理解しやすさなどの向上により、利活用が進む 手順の簡略化や操作性が改良された環境やアプリの登場により、利活用の数居が低くなる <p>*UX: User Experience、ユーザーが得られる体験や経験</p>
ELSI	<p>AIの倫理的、法的、社会的問題の解決により社会受容が進む</p> <ul style="list-style-type: none"> 悪意のあるデータベース構築、差別的判断をするモデルの構築などは倫理的に許されない AIによる判断で起きた事故の責任の所在、学習モデルの知的財産権の所在などの明確化により、AIビジネスが加速する AIにより職を失った労働者の生活保障と再教育やAI導入により生じる経済格差などの社会問題は避けられない <p>*ELSI: Ethical, Legal and Social Issues、倫理的、法的、社会的問題</p>

(1) AI を活用したメリハリのある管理方針

技術シーズの変化において、膨大なデータ・モデル・AI 活用ノウハウを十分に蓄積し、インフラの種類や予算規模にあった使い分けをするべきだと考えられる。

AI は重要インフラを高度に管理するだけでなく、地方公共団体が管理するような日常インフラの低コスト化省力化の効果も期待できる。ただし、重要インフラ向けの AI が日常インフラへの維持管理へそのまま適用できないため、日常インフラの維持管理のあるべき姿に適した AI が開発適用されるのが望ましい。

施工データや点検データなどの建設生産サイクルの中で蓄積される大量のデータおよびデータ分析ノウハウから管理方法の適切な簡素化を検討することにより、一部点検のモニタリング置き換えによる省人化、遠隔操作や計画設計支援などの省人化などの効果が期待できる。

地方公共団体が管理する約 95%（橋梁の場合）の日常インフラは予算不足および技術者不足が課題であり、各種データやデータ分析ノウハウの蓄積を重点的に推進する必要がある。

重要インフラだけでなく、予算措置の厳しい日常インフラも含めて管理するために AI をどう使い分けるかの基本的考え方を図 9.1.3 に示した。

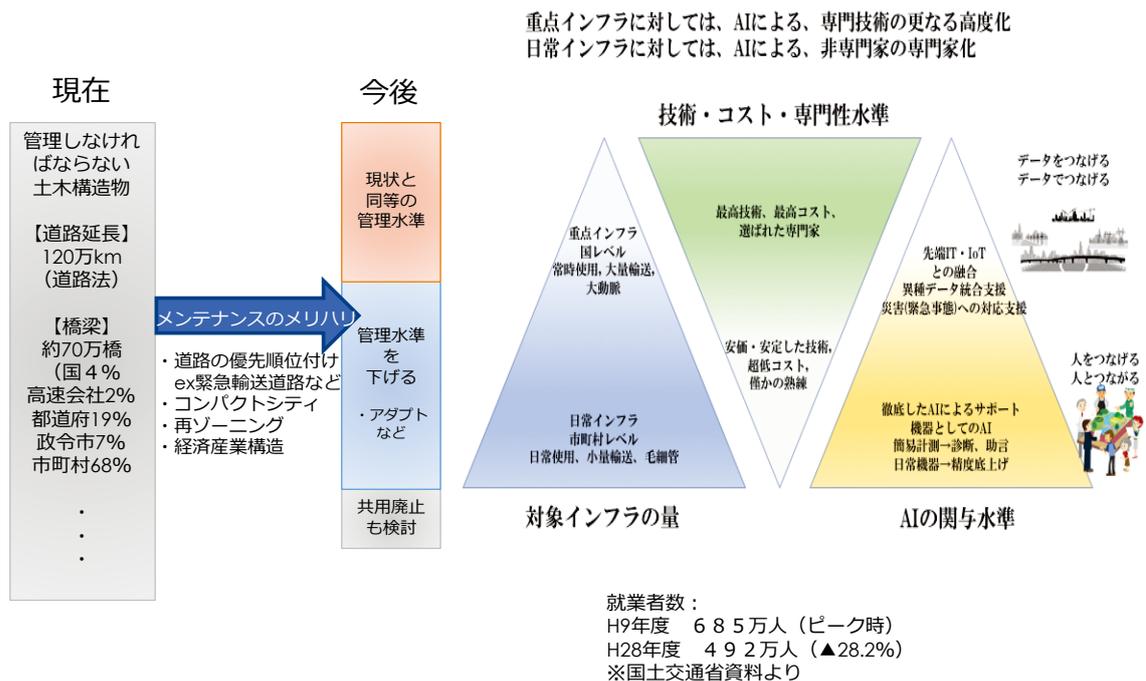


図 9.1.3 メリハリのある AI 適用

また、具体例として、橋梁のセンサによるモニタリング事業を想定して重点インフラと日常インフラの管理の違いを例示する（図 9.1.4）。

重点インフラの場合には、多種多様なセンサでモニタリングを行うため、複雑なデータ分析な

どに AI 活用が行われる。その一方で、日常インフラは 1 件あたりのコストを抑えるために多くの橋梁を一括管理する方法がある。この場合、1 つの橋梁に 1 つの加速度センサを設置し、その値から異常検出をするなど単純な分析を大量に行うことに AI を適用する。

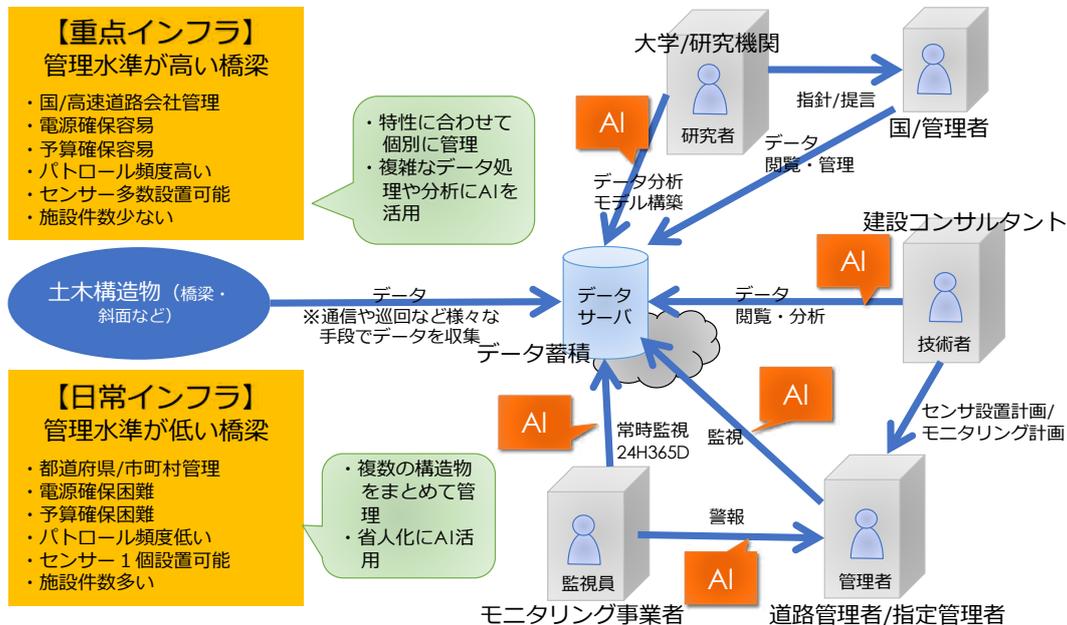


図 9.1.4 重点インフラと日常インフラのモニタリングの違い

(2) インフラ維持管理での AI の段階的な適用拡大

初期の AI 活用では、現地で得られる画像データや打音データ、各種センサによるモニタリングデータに対する変状検出および判定あるいは異常検出などが実用化されるであろう。

画像データは大量に取得・蓄積されており、そのため AI 分析手法も豊富である。可視光で撮影された画像データが一番多く、ひび割れやサビ、エフロレッセンスなどの変状箇所を抽出し、その後の損傷程度の評価が行われる。音声データは、打音点検の波形分析や漏水音を検出することにより、変状箇所を特定できるようになる。

さらに、3 次元計測技術との連携によって変状箇所抽出と同時に位置座標の取得ができるようになり、熱赤外線によるコンクリートの浮きや剥離の抽出ができるようになる。また、GPR(Ground Penetrating Radar: 地中探査レーダー)による路面化空洞や床版の土砂化の抽出といった可視光領域外の周波数によるセンシング技術で得られたデータの AI 適用へ進む。

図 9.1.5 では、大量にデータが取得されるようになった後、AI はオフィス内で学習済みモデルや学習用データの蓄積によりデータ分析の適用範囲が広がる例を示している。また、その他 ICT は個別の機能がより洗練され充実していき、同時に土木技術者の間でもこれら ICT 技術を前提とした維持管理技術が蓄積されていく。その後、AI のエッジ化などにより現場でのリアルタイム利

用が拡大する。それと同時にロボットや CIM などの高度化された技術群との連携が進む。

また、事業を行う企業の立場からは、技術開発費が小さい部分または潜在市場（ニーズ）が大きい事業から取り組みが進む。AI はインフラ維持管理事業に携わる企業の利益につながってはじめて活用や適用が進む。

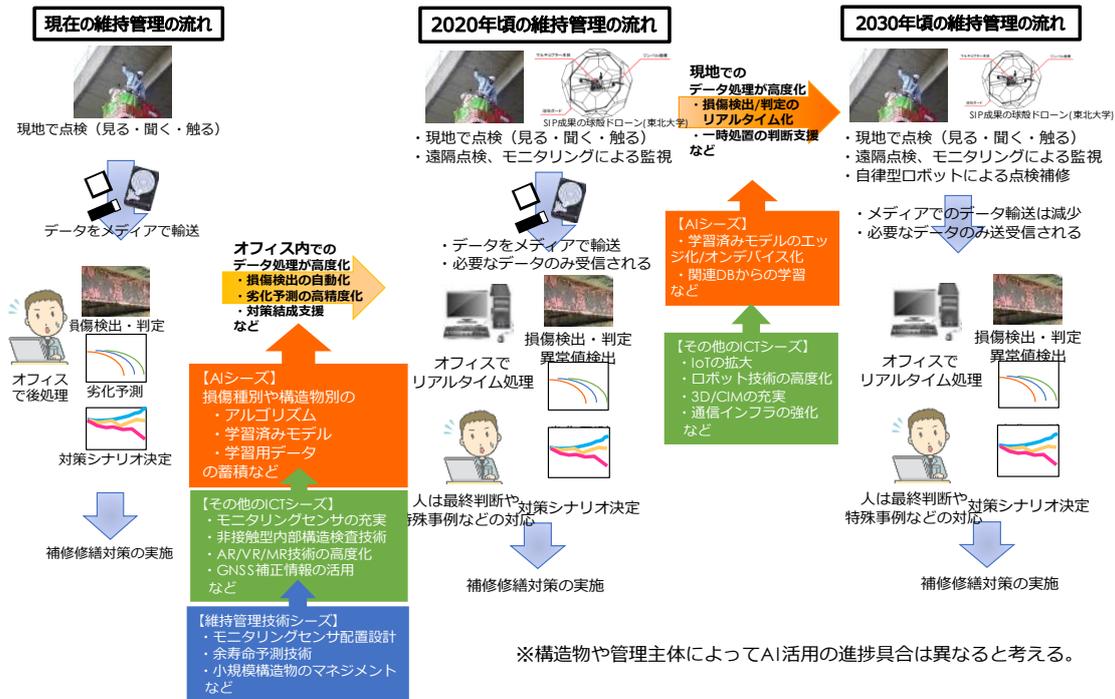


図 9.1.5 現在から短期的な視点で見た AI 点検モニタリングの適用例

(3) 技術者の育成と AI 利用者の拡大

技術者教育の面では、文献や事例のデータベース化が進むことによって、AI によって教材のカスタマイズや評価の自動化などが可能となる。また、類似事例の検索へ AI が適用されることにより、より効率的に対策工法や判断を行えるようになる。これは、既存の知見を学ぶ良い機会となる。

利用者拡大の側面では、AI の UX（User Experience：ユーザーが得られる体験や経験）の向上により利用者が拡大する。使いやすい AI アプリの登場で利用者が増加し、スマートフォン、タブレット、パソコンなどの複数のデバイスで屋内屋外場所を問わず使用することができ、また、異なるデバイスで登録した損傷記録も一元管理される。転記漏れや転記ミスがなくなり、エラー対応や手戻り作業などに使用していた時間は別の作業に当てられる。また、信頼性の向上や要領等維持管理マニュアルの内容へ反映されることによって、より AI 活用が拡大する。

(4) 社会受容に向けた AI 活用の信頼性の確立

社会受容性における重要な要素の1つは、AI技術の信頼性の確立である（表9.1.2）。ディープラーニングに代表されるAI技術はブラックボックスであるため論理的説明が難しい。そのため、土木技術者がAIの長所と短所を理解し、土木技術の一部としてAI技術が受け入れられるためには、継続的に物理現象の解釈をAIへ入れ込みブラッシュアップしていくことが必要となる。図9.1.6に示すように、データサイエンティストのデータ分析サイクルと維持管理技術者の相互連携により、物理検証による解釈と現場の暗黙知のAIへの導入を進めることが重要である。

表 9.1.2 信頼性の確立

インフラ維持管理AIの信頼性の確立
AIの得意なところを知る
<ul style="list-style-type: none"> • 定量的で網羅的な処理 • 膨大なデータからルールなどの発見
AIの限界を知る
<ul style="list-style-type: none"> • データ化された現象は扱えるがデータ化されていない物理現象は扱えない
物理現象による解釈と現場の暗黙知のAIへの導入
<ul style="list-style-type: none"> • 物理現象から説明できるような指標と分析手法の構築 • データサイエンティストと維持管理技術者の連携

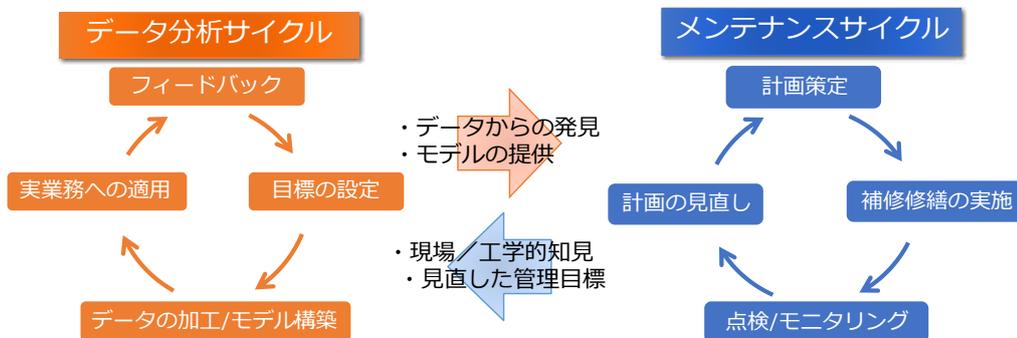


図 9.1.6 AI 分析サイクルと維持管理サイクルの連携

(5) AI の倫理的, 法的, 社会的問題

AI の ELSI (Ethical, Legal and Social Issues : 倫理的, 法的, 社会的問題) については、スティーブン・ホーキング、ビル・ゲイツ、イーロン・マスクなど世界のリーダーたちが急激に発達するAIの危険性について懸念を表明している。2016年3月にMicrosoftが公開した人工知能「Tay」は、twitterなどでフォロワーと対話することにより賢くなるものだったが、公開数時間で人種差別や暴力的な発言が多くなったため、公開を停止することになった。倫理的に問題のある単語を知っていても使わないという判断はできなかったのである。あくまでもAIはモデルを設計・学習さ

せる人間の意図や認識に従って学習が進むことを示しており、悪意を持って学習させればそのように動作するであろうことを示した。

日本では、人工知能学会倫理委員会が2017年2月28日に「人工知能学会 倫理指針」⁴⁾を公開した。また、科学技術振興機構では2013年から継続的にワークショップを開催し、2016年度からは新規研究領域「人と情報のエコシステム」にて取り組んでいる。

法整備に関しては、インフラ維持管理においては、管理者やモニタリング事業者などの責任の範囲に関する考え方を明確にしておく必要がある。経済産業省は2018年6月15日に「AI・データの活用に関する契約ガイドライン」⁵⁾を発表した。その中のAI編ではAIソフトウェアの特性を踏まえた上で、開発・利用契約を作成するにあたってのトラブル予防等を目的としている。AIに詳しい技術者の確保が可能な直轄国道事務所や高速道路会社などは、AIが選んだ候補から適切な工法を人間が選定するといった体制を組むことが可能であると推測される。その一方で、技術者や予算等が常に不足している地方公共団体では、無理解のままAIを利用することで想定以上の要詳細点検箇所の見逃しが発生するなどのトラブルを招く危険性があると考えられる。AI提供者はトラブルの原因になるような誤解を無くすためにAIの動作特性に基づく長所と短所について丁寧に説明し、範囲外の適用によって生じたトラブルへの対応方針等について、AI利用者から同意を得ることが求められる。契約に際しては、これらの内容について特記仕様書等の契約図書の中で明文化する必要があると考える。また、AIの診断モデルを構築した場合の知的財産権の取り扱いも整理される必要があると考える。機械学習の場合、学習アルゴリズムの考案者、学習データ所有者、学習実施者、学習モデルの使用者の権利範囲について議論が必要である。権利の範囲が明確になれば、学習データやモデル、アルゴリズムを流通させやすくなり、インフラAIビジネスも加速すると考える。

社会的問題については、AIにより職を失う労働者の存在がある。インフラ維持管理においてはもともと少ない技能者や技術者の不足を補う策の1つとしてAI活用が検討されているという経緯があるが、技能者や技術者は研修などの再教育を継続的に受け、AIでは代替できない、より複雑な工程に携わることができるようにする必要がある。

9.2 短期ビジョン：早期に実現すべきAI活用の姿

近年のAIブームの要因の一つとして、豊富なデータとデータ収集の容易さおよびそれを利用する人たちの増大があげられている⁶⁾。AIを活用したインフラ維持管理の効率化や生産性向上には、構造物の維持管理に関わるデータを継続的に大量に収集する仕組みを作り上げ、AIを使いたいと思う管理者や技術者を増やすことが鍵となる。

本節では、インフラ維持管理に関わる技術者や企業、研究者が早期に実現すべきAI活用の姿を、インフラ維持管理に携わってAIを使用する側と、AI開発・データ分析を得意とするAIを提供する側から説明する。



図 9.2.1 AIを活用した点検・モニタリングの候補 ①



図 9.2.1 AI を活用した点検・モニタリングの候補 ②

9.2.1 あらゆる点検・モニタリングへAIを適用する【インフラ側】

インフラ維持管理におけるデータの収集源は点検およびセンサモニタリングである。

SIP のインフラ維持管理⁷⁾では点検の効率化やモニタリング技術のプロジェクトが多く、センシングプラットフォームは、人工衛星、車両、ドローンや壁面吸着型ロボットなど多様である。ここで、ドローンは、マルチコプタ、UAV (Unmanned Aerial Vehicles)、UAS (Unmanned Aerial System) など複数の呼び方があるが、本節ではプロペラによって飛行する無人航空機をドローンと呼ぶことにする。ドローンによる異常診断技術に関するプロジェクトを紹介すると、開発しているドローンはコンクリート橋の点検において1自由度のマジックハンドのようなもので床版や橋脚への接触が可能で、カメラモジュールと打音モジュールを装備している⁷⁾。

原理的には、ドローンに搭載したカメラを使えば構造物の写真を多方向から大量に撮影することが可能であり、取得した画像から SfM (Structure from Motion) で少なくとも外形の3次元形状を取得することが可能となる⁸⁾。さらに、AI技術の1つである深層学習による変状の検出⁹⁾や3次元位置の特定、調書の自動作成あるいは目視点検の要不要を推定するスクリーニングを行うといった活用が考えられる⁷⁾。

このように、あらゆる点検・モニタリングにおいて機械可読な状態でデータを取得蓄積し、AIを適用することで、時間短縮や効率的な点検・モニタリングが期待できる。さらに、維持管理全体の工程見直しや、詳細点検や対策工の検討といった後工程でのAI活用といった波及効果も期待できる。

図9.2.1に直近で実現されるべき点検・モニタリングのAIの活用候補を示した。道路施設、砂防関連施設、河川管理施設、ダム、鉄道施設、港湾の施設、空港内の施設、農業利水施設について活用像を描いている。ドローンやMMS (Mobile Mapping System、車両など可搬型の陸上のセンシングシステム)、ROV (Remotely Operated Vehicle、遠隔操作する水中無人探査機) から出ている青い電波はセンシングによるデータ取得を表し、写真撮影やレーザ計測、打音検査、内部非破壊検査、音波探査などが該当する。取得されたデータはリアルタイムまたはサーバに蓄積された後にAIに適用される。ドローンやMMSだけでなく、橋梁など構造物から出ている黄色い電波は通信を表す。振動計や水位計など施設や地盤等に設置されたセンサから取得された情報は、近くを通過する車両や通信施設を介してサーバに接続し、蓄積され、AIを適用される。AIを活用した点検・モニタリングはあらゆる土木施設を様々な手段でセンシング・モニタリングし、通信で接続可能な状態でもあることが分かる。

ここで留意したいのは、個別施設の特長や維持管理計画の方針に適したメリハリのあるAI活用を行う点である。大量の土木構造物を一律に同じ基準や手法で維持管理をするのは現実的では無いからである。例えば、緊急輸送道路にかかる橋梁や重要な橋梁は「信頼性」の高いAIを使いたい、が、「信頼性」の違いは、使えるデータに依存し、PCやモバイル端末などの機器に依存しない。重要な橋梁等の構造物にはお金と労力をかけて多項目で取得頻度の高い大量データを取得し、一方で、迂回路のある交通量が少ない橋梁は単独センサによる低頻度のデータ取得を行い、異常が検知されたときだけ現地へ行くといった運用である。また、インフラ維持管理は安全の確保が

目的の一つであるが、AIは正答率を100%にすることはできない。そのため、インフラ維持管理に携わる技術者はAIの出した予測結果等をそのまま採用するのではなく、一般的な技術的背景に照らし合わせて最終判断をするようなワークフローを構築する必要がある。

9.2.2 AIの機能および動作を理解する情報を提供する【AI側】

AIが社会一般に受け入れられて使われるようになるには、一般的なICTと同様に、利用者と供給者または開発者（以下、供給者）の間で品質について共通の認識と理解を持つことが鍵となると考える。AIはスマートフォンのアプリやPCソフトウェアおよびそれらを含むシステムとして機能やサービスが提供される。AIに固有でないICTの一種としての品質評価についてはJIS X 25010システム及びソフトウェア品質モデル¹⁰⁾などの枠組みを参考にすると良いであろう。

深層学習に代表される近年のAIは大量のデータでニューラルネットワークを学習させるため、出力結果の根拠を示すことが難しく、学習時の正答率が高くても信頼性を適切に評価することは難しい。近年では、深層学習技術とナレッジグラフ技術を融合させることにより、結果の理由や根拠を論理的に説明する技術の研究開発¹¹⁾などが行われている。学習の結果得られるモデル（以下、学習済みモデル）の挙動は、学習アルゴリズムと学習データおよび学習済みモデルに入力されたデータに依存する。仮に学習済みモデルの性能を正答率だけで評価することを考えた場合、同じ学習済みモデルを利用しても入力するデータが異なれば正答率は通常異なるため、正答率だけでは適切な評価基準にすることはできない。

そこで、供給者がAI機能をソフトウェアやサービスとして利用者に提供する場合には、多くの利用者にAIを使ってもらうための学習済みモデルに関する情報を補足情報として提供することを提案する。ただし、供給者が秘匿したい内容や詳細についての記載は求めない。

① アルゴリズムの概要

- ・モデルの目的、分析手法の種類、インフラ維持管理フローにおける対象業務、目標
- ・ベースとした公開モデルや特許、ネットワーク構成や処理フローの概要など

② 学習データの概要

- ・画像や音響といった学習に用いたデータの型
- ・施工時に取得したデータや供用中の構造物の点検で取得した実データ、実験室や屋外暴露試験などで得た実験データ、数値シミュレーションや生成モデルで得た仮想データといった、データの収集方法および加工レベルなどのデータの種類に関する情報
- ・取得時期や時間帯、対象物の範囲や立地、発信周波数や受信周波数帯またはそれらが分かるような使用センサの名称、照度や気象条件といった、データの取得条件や取得環境に関する情報
- ・一部データの図示

③ 学習済みモデルの学習時の指標

- ・正解率 (Accuracy)

学習済みモデルの評価

ここでは、2クラス分類の学習済みモデルを例にとって、よく使われる評価指標を説明する。構造物を撮影した画像にひび割れが写っていれば陽性（Positive）、写っていなければ陰性（Negative）という判定を行う学習済みモデルの予測結果は下表に示す4つに分けられる。

表 混同行列（Confusion Matrix）

		正解	
		正(Positive) ひび割れがある	負(Negative) ひび割れは無い
予測	正(Positive) ひび割れがある	真陽性 (True Positive) TP ひび割れがあると判定したが、 本当にひび割れがあった。	偽陽性 (False Positive) FP ひび割れがあると判定したが、 本当はひび割れは無かった。
	負(Negative) ひび割れは無い	偽陰性 (False Negative) FN ひび割れは無いと判定したが、 本当はひび割れがあった。	真陰性 (True Negative) TN ひび割れは無いと判定したが、 本当にひび割れは無かった。

この表は混同行列ともいい、第9.2.3項に示した指標のうち3つを算出することができる。正解率は、全体の予測に対して答えがどのくらい合っているかを表す。

$$\text{正解率 (Accuracy)} = \frac{TP + TN}{TP + FP + FN + TN}$$

適合率は、正しいと予測したもののうちどれくらい正しく予測できたかを表す。この場合、ひび割れがあると予測した画像のうち、本当にひび割れが写っている画像が存在する率を表す。

$$\text{適合率 (Precision)} = \frac{TP}{TP + FP}$$

再現率は、正しいもののうち、どれくらい正しく予測できたかを表す。この場合、本当にひび割れが写っている画像のうち、ひび割れがあると予測した画像の率を表す。

$$\text{再現率 (Recall)} = \frac{TP}{TP + FN}$$

インフラの点検においては、ひび割れなどの損傷や変状はできるだけきちんと見つけたい。

例えば、ひび割れがあると判定して本当にひび割れがあった場合（TP）とひび割れは無いと判定して本当にひび割れは無かった場合（TN）の合計件数が同じであれば、正解率（Accuracy）は同じになる。しかし、ひび割れは無いと判定したが本当はひび割れがある場合（FN）の件数が多いと、再現率（Recall）は低くなる。正解率が同じなら、損傷や変状があるのに無いと誤判定をするモデルはなるべく使いたくないので、再現率や適合率もモデルの評価指標としては重要である。

- ・適合率 (Precision)
 - ・再現率 (Recall)
 - ・AUC (Area under an ROC curve) や異常値に対する動作の結果など。
- ④共通データによるベンチマーク
- ・適用したデータセット名
 - ・公開された共通データ適用時の指標
 - ・正解率 (Accuracy)
 - ・適合率 (Precision)
 - ・再現率 (Recall)

これら情報から利用者は目的に合ったモデルを選定・比較評価することができ、ひいては目的外データや不適切なデータを適用したことで結果が芳しく無くても信頼性を著しく下げることが無いと考える。モデルのリピーターが増えれば結果として AI の社会受容性は広がることが期待される。ベンチマークを得るために適用する共通データについては、第 10 章の教師データに記載されている内容を参照して欲しい。

9.3 長期ビジョン：理想とする将来での AI 活用の姿

本節では、AI 活用の維持管理の内側と維持管理を取り巻く周辺領域との関係の 2 つの視点で長期ビジョンを示す。

9.3.1 AI を中心としたインフラ維持管理

将来は、センサ類からデータを取得し、AI 等によるデータ処理を経て、データセンターにデータが蓄積され、さらに、構造工学的な知識と照らし合わせて、AI を中心としたアセットマネジメントを実施するようになると予測される。そのイメージを図 9.3.1 に示す。

センサ類は、3 次元計測機器やドローンや点検ロボットなどの移動する機械に取り付けられたセンサ、構造物や地盤などに設置されて振動や水位などの定点観測をする固定センサで構成される。3 次元データは AI による自動セグメンテーションで処理され、3 次元構造モデルが作成される。橋梁をレーザスキャナで計測する場合を考えると、計測点群は単なる 3 次元座標の集まりであるが、自動セグメンテーションによって橋脚や床版といった構造化された部材情報が付加され、同じ部材に当たっている点群を一つのまとまりにする。点群から作成された部材の 3 次元形状モデルを集めると部材に分割可能な橋梁の 3 次元形状モデルができあがる。点検ロボットから得られた各種データは AI によって変状検出や自動セグメンテーションなどの処理を経て、変状の 3 次元モデルを得る。このように構造化されたオブジェクト 3D モデルはデータセンターへ蓄積される。固定センサから得たデータは AI によってノイズ除去や正規化などのデータクレンジングを行い、常時観測データを得る。

ただし、データ準備において自動処理に AI 等を適用する場合は、その後の予測や得られる結

論にバイアスがかかってしまっても途中経過や修正箇所が明確に判別可能なアルゴリズムを採用する必要がある。

蓄積されたデータは 3DFEM など構造解析ソフトウェアで分析され、メンテナンスや材料に関する構造工学的な専門知識のデータベース等に照会をかけられる。分析結果や照会結果は蓄積され、学習データとしてインフラ維持管理用の AI 学習に活用される。学習済みモデルは個別の構造物が危険状態に及んだことを知らせるアラームの発信やその後の補修指示、アセットマネジメントの中では余寿命の予測やその後の補修工法候補の提示といった意思決定支援などで活用される。センサから新しいデータが追加されれば、新旧データが自動的に処理・学習され、AI は常に更新される。

さらに、データは核となるデータセンターに蓄積されるだけではない。例えば、固定センサのデータを分析することにより得られた新たな知見は構造モデルや構造工学の専門知識へフィードバックされるなど、相互にデータが活用される。

以上のように、AI を活用してデータが蓄積され、データと構造工学的な知識が相互に活用されることで、AI と AI に支援されたアセットマネジメントがより高度になっていくべきだと考えられる。

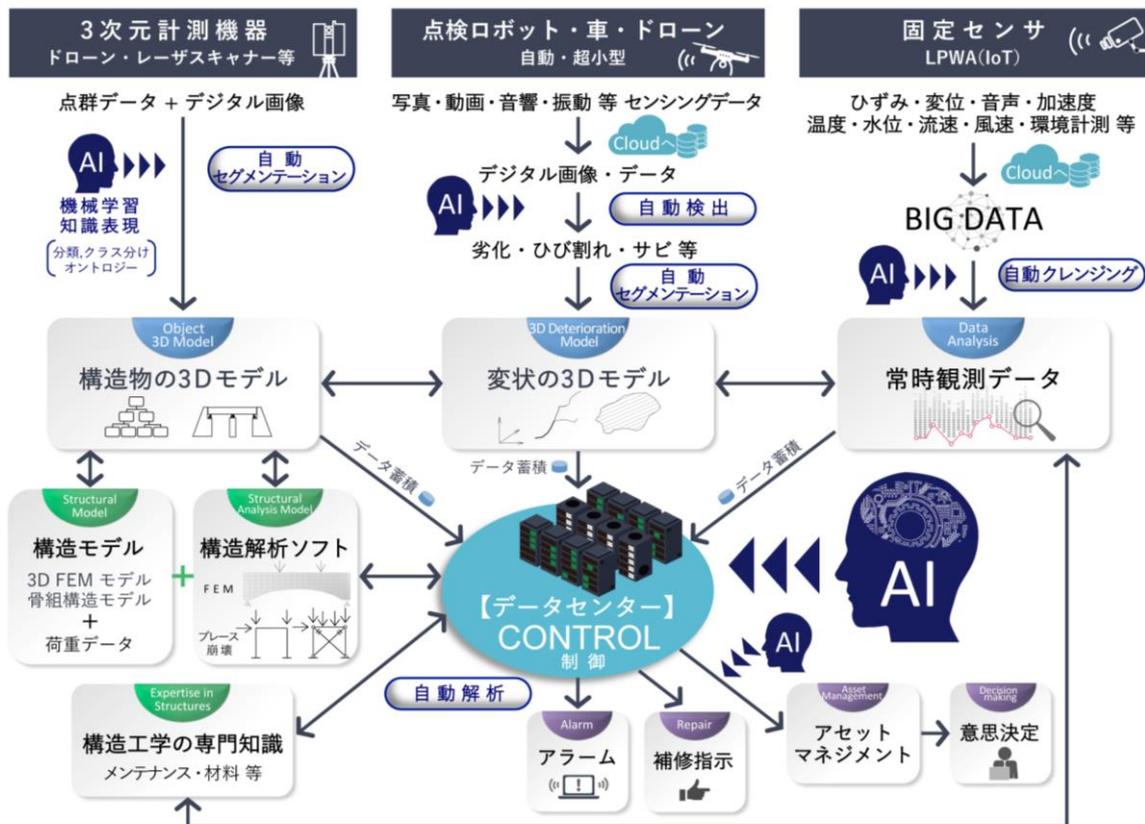


図 9.3.1 AI を中心としたインフラ維持管理のデータ流通イメージ

9.3.2 インフラ維持管理における価値創造

短期ビジョンで見たとおり、AIを活用したインフラ維持管理が実現した社会は、モニタリングセンサや構造物が通信ネットワークで繋がっている。通信ネットワークを介して、構造物に関する情報だけでなく、水位や土壌の水分量、気温や雨量などの気象データ、あるいは施設を利用する人や車両に関する情報など、構造物の損傷に影響する事柄の情報も収集される。これら収集データや構造工学的な知識は、周辺領域の1つである防災分野でも有効である。例えば、通信ネットワークや収集データを一部共有するなどして、インフラ維持管理と周辺領域が一体的に取り組むことで最適化や効率化などの相乗効果が期待できる。また、この相乗効果によって新しいサービスや価値が創造されるような、AIを活用したインフラ維持管理であれば継続的な予算獲得や大規模な投資が期待できる。

AI活用に取り組み始めた際の目的が効率化・省力化であっても、新たな維持管理ビジネスの創出を常に意識していることが重要である。インフラ維持管理へのAI適用が将来の理想像に向けて、建設分野の情報化の流れの中で新しい価値を想像する概念図を図9.3.2に示す。

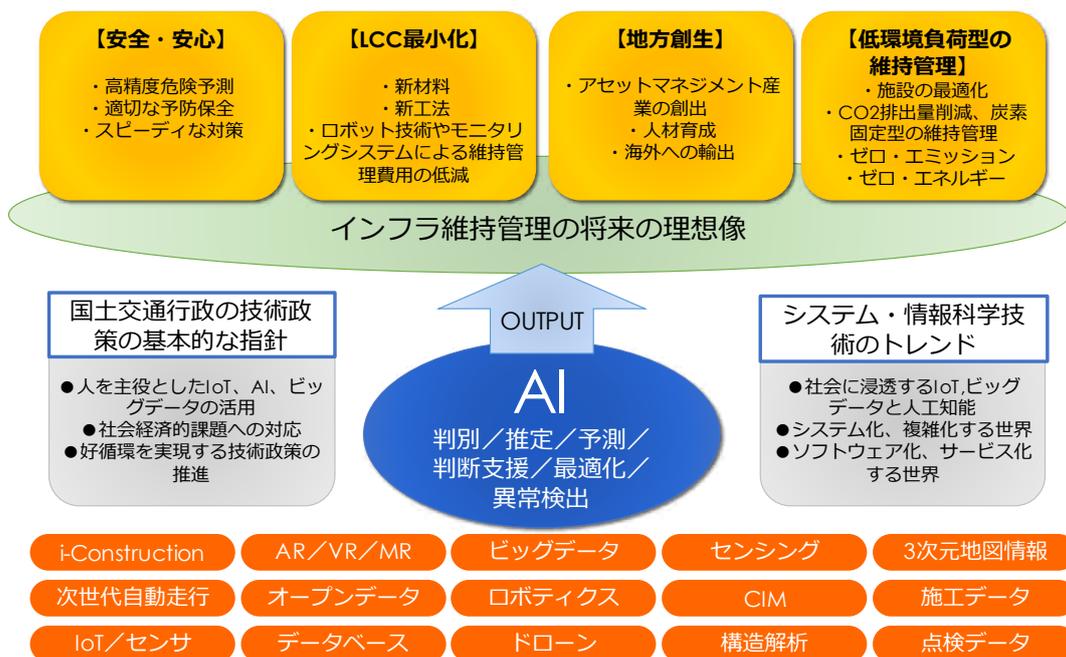


図 9.3.2 インフラ維持管理 AI の価値創造のイメージ図

9.3.3 インフラ維持管理における将来の AI のあり方

AIは人間に代わって何かをしてくれる機械における頭脳に相当する。AI活用ビジョンでは、ロボットによる自動化も考慮する必要があると考える。本節では主に人型ロボットを想定して述べている部分があるが、ロボットが人型である必要はないと考える。

1966年に発表された短編小説「工事中止命令」¹²⁾では、ジャングルの奥地で全自動で進む工事に中止命令を言い渡しにやってきた主人公が契約に従って工事を続けるロボットを力尽くで止めようとする姿が描かれている。大友克洋によってアニメにもなっている¹³⁾が、たった一人の監督員以外は全く人の存在しない鬱蒼としたジャングルの狂気とも言える建設現場で働くロボットの姿には、その状態を作り出した人間の欲望と無責任さへの危機感が見てとれる。

現在、建設現場での自動施工への取り組みだけでなく、維持管理分野においてもロボット開発だけでなく自己治癒材料⁷⁾など人の介在を減らすための技術開発が進められている。我々は経験的に、専門的知識のDBやコンピュータシミュレーション等による判断支援の仕組みを構築した際には、利用者はその根拠や内容を理解する努力を怠り、出力された結果を検討せずに使用する傾向があることを知っている。人の介在が減れば減るほど、その長所と短所を正しく理解する人が極端に減る可能性がある。

我々が目指すべきなのは、人間が失ってしまった技術をAIだけが知っている未来ではなく、鉄腕アトムやドラえもんで描かれるような、人間と人間の友人であるロボット（AIと言い換えてもいいだろう）と一緒に生活し、技術の継続的な発展と人間らしさを同時に享受できる明るい未来¹⁴⁾であるという考え方もあろう。この異なって見える2つの未来は、AIは道具であり、使う人間次第で生活を脅かす存在にも快適な生活を提供する存在にもなるという点においては人の使用目的に依存して殺人の道具にも便利な道具へも変わりうるし、同時に存在することが想定できる。

その一方で、技術者の教育や育成に必要なのは現場での多様な経験であるが、システム化することによる長期にわたって建設技術を継承している例として伊勢神宮の式年遷宮が挙げられる¹⁵⁾。1300年続くこのシステムは、20年ごとに社殿を更新し続けることで、社殿作りの技術だけでなく、祭祀そのものや建設に必要な木材を産出する林業の育成など関連する産業等の継承にも貢献している。また、視点を変えてみると、式年遷宮は1つの建設物に関する技術等を1300年に渡って全く形を変えずに継承するシステムと言えるが、形を変えて継承されている技術もある。卑近な例ではお湯を沸かす技術が挙げられる。最初に人類がどうやって火を起こしていたかは正確には分からないし、現代では乾燥した草木やマッチなどを使って火を起こすことはあまりない。しかし、自分で火を起こしてお湯を沸かす技術は使えなくても、ガスや電気のスイッチを入れればお湯を沸かすことができる。加えて言うなら、発電の方法やガスや電気が供給される仕組みを全て良く分かった上で使っている人は極めて少ないであろう。技術が便利になるにつれて、仕組み自体も複雑になって分業化が進み、関係者が相互に協力あるいは競争することによって暖かいお湯が自由に使えるようになっていく。

インフラの維持管理でこの技術継承を考えてみると、AIの活用は、後者の実現技術の多様化によって目的とするインフラの維持管理の技術継承が進んでいる状態だと考えられる。本章で述べたAI活用ビジョンは技術革新を促すものではあるが、AIの扱い方によっては技術継承を脅かす存在にもなりうる。周辺技術を取り込み、柔軟にやり方を変える事によって、インフラ維持管理の目的である「インフラを安全で快適な状態に保つ」ための技術が継承され、高度化されていく

べきだと考える。そうやって作り上げられていく柔軟なインフラ維持管理には、当然のように、もう人工知能と呼ばれなくなった AI が組み込まれているのではないだろうか。

参考文献

- 1) McCorduck, P. : Machines who think : a personal inquiry into the history and prospects of artificial intelligence, AK Peters, 2004.
- 2) 土木学会 土木学会人工知能小委員会 : AI で描く未来 : 土木 AI 進化論, 土木学会, 1990.
- 3) 総務省 : 通信利用動向調査.
- 4) 人工知能学会 : 一般社団法人 人工知能学会設立趣意書, 1990.
- 5) 経済産業省 : AI・データの利用に関する契約ガイドライン, 2018.
- 6) 松尾 豊:人工知能は人間を超えるか : ディープラーニングの先にあるもの, KADOKAWA, 2015.
- 7) 内閣府 : 戦略的イノベーション創造プログラム (SIP) インフラ維持管理・更新・マネジメント技術 プロジェクト紹介 ー開発技術の概要ー, 2017.
- 8) 大石 哲, 白谷 栄作, 桐 博英, 高橋 順二, 水上 幸治, 村木 広和 : UAVを使った低空画像解析による海岸堤防の劣化状態の検出, 海岸工学論文集, Vol.71, No.2, 2015.
- 9) 全 邦釘, 嶋本 ゆり, 大窪 和明, 三輪 知寛, 大賀 水田生 : ディープラーニングおよび Random Forest によるコンクリートのひび割れ自動検出手法, 土木学会論文集F 3, Vol.73, No.2, 2017.
- 10) 日本工業規格 : JIS X 25010:2013 システム及びソフトウェア製品の品質要求及び評価 (SQuaRE) ーシステム及びソフトウェア品質モデル.
- 11) 富士 秀, 森田 一, 後藤 啓介, 丸橋 弘治, 穴井 宏和, 井形 伸之 : Deep Tensor とナレッジグラフを融合した説明可能な AI, FUJITSU, Vol.69, pp.90-96, 2018.
- 12) 眉村 卓 : 産業士官候補生, 角川書店, 1978.
- 13) りんたろう, 川尻 善昭, 大友 克洋 : 迷宮物語, 角川映画, 1986.
- 14) 米沢 嘉博 : ロボットマンガは実現するか : ロボットマンガ名作アンソロジー : ロボット開発最前線報告, 実業之日本社, 2002.
- 15) 神宮司庁 : 式年遷宮, <<http://www.isejingu.or.jp/sengu/index.html>>, (入手 2018.11.14).

9.4 短期ビジョン早期実現のために取り組むべき事項

9.4.1 オープンな環境の整備と活用：学習用データ整備とアルゴリズム適用結果の共有

AI活用の短期ビジョンとして上述した、点検・モニタリングにおけるAI技術適用の拡大のためには、研究者や実務者が広く参照・利用することのできるデータセットの整備やユースケースの蓄積は今後重要になると考えられる。

AI技術の活用が進む諸分野において、分野内で共有されるデータセットは、AIモデルの学習やモデル間の性能を比較するベンチマークテストのための利用など、様々な用途に用いられている。インフラ維持管理におけるAI活用においても同様に、オープンなデータの整備と共有はAI技術の発展において大きな役割を果たすものと期待される。

また、AI技術を実際に適用したユースケースを蓄積し、その情報を分野内で共有することもまた重要であると考えられる。情報共有の方法として、学術論文や技術報告といった従来の形式に加え、近年ではウェブサービスやコンペティションを活用した形式も広く見られるようになってきている。このような様々な媒体を通して、データ分析のための技術・具体的なツール・ユースケースに関する情報が共有されることは、研究開発を加速させることにつながると期待される。

9.4.2 AI・データサイエンススキル

データに対してAIを高度に駆使し、様々な分野の課題を解決する「データサイエンティスト」は、米国の職業ランキングにおいて3年連続で第1位¹⁾（年俸を含む職業評価による）となっている。そのデータサイエンティストに必要とされるデータサイエンススキルについて、Conwayが2010年に示したデータサイエンスベン図（図9.4.1）では、「Hacking Skills（コンピュータやデータを扱うスキル）」、「Math & Statistics Knowledge（数学や統計学の知識）」、「Substantive Expertise（実質的な専門知識）」の3つが示されている。

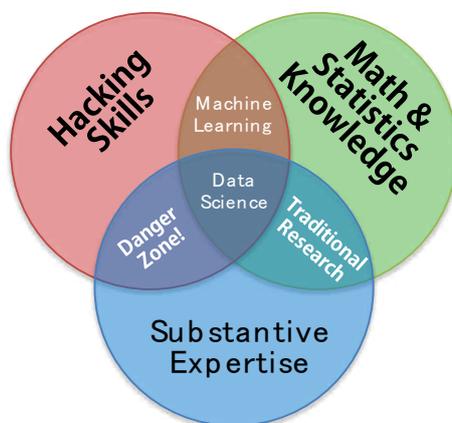


図 9.4.1 データサイエンスベン図（Conway²⁾による）

一方で、我が国のデータサイエンティスト協会が2014年に示した定義³⁾によれば、データサイエンティストには、「データエンジニアリング力」、「データサイエンス力」、「ビジネス力」の3つのスキルセットが要求され、それぞれのスキルレベルとしては、「見習いレベル」から「業界を代表するレベル」まで4段階のレベルが定義されている。ここで、スキルセットのうち「データサイエンス力」は、情報処理や人工知能等の情報科学系の知恵を理解し使う力であり、「データエンジニアリング力」とは、データサイエンスを活用できるよう実装・運用を可能とする力とされている。これらは、それぞれ、Conwayが示唆した「Math & Statistics Knowledge」および「Hacking Skills」に対応すると考えられる。また、第三番目のスキル「ビジネス力」については、課題背景を理解した上でビジネス課題を整理し解決する力と定義されている。Conwayによる「Substantive Expertise」を「実質的な専門知識を基盤として成果の実用を目指す力」と解釈すれば、データサイエンティスト協会が定義する「ビジネス力」への繋がりも捉えることができる。ただし、データサイエンティスト協会が提示するスキルは、やや経営等の課題への対応に寄った定義といった印象があり、インフラ維持管理分野においては、Conwayが示す「Substantive Expertise (実質的な専門知識)」の方が、データサイエンスに必要な第三番目のスキルとして捉えやすい。

9.4.3 AI への理解を深める：長所と短所を把握して信頼できる活用体制を構築する

膨大なデータが蓄積され流通することが見込まれるこれからの社会において、インフラ維持管理においてもさまざまなデータを取り扱って AI 技術を活用し、実務における問題解決や新しい価値を生み出すアプローチは必須となる。その中では、土木技術者が専門知識を基盤としてデータサイエンス技術者と協働することがもとめられていくであろう。このためには、最低限のデータサイエンスリテラシーを、土木技術者側が身につけていく必要がある。本項では、これからの土木技術者のデータサイエンスリテラシーとして考えられるいくつかの項目を、Conwayより示されたデータサイエンススキル「Substantive Expertise」「Math & Statistics Knowledge」「Hacking Skills」に沿ってまとめた。

(1) Substantive Expertise

① 専門知識に基づくデータ前処理・クレンジングの力

例えばインフラ構造物の計測データを取得した際に、対象構造物に関する専門的知識や経験から有意な応答とノイズを見分ける力、そして見分けられたノイズを除去するデジタル信号処理の技術が必要である。これには、計測手法や誤差論、偏り・ばらつきへの理解や認識向上といった、データ取得に関する知識を高めることも必要と考えられる。

② 土木技術者自身がビッグデータを可視化して観察する力

これからは、計測や実験、調査等で得られるデータとは異なり、不特定に集まってくる大量データを、観察目的に応じて可視化する力が必要となる。これにはまず、特定のソフトウェアに依存しない、データファイルの形式・読み込み・書き出し・変換に関する知識の共通化

を進めることは有効である。さらに、GitHub や OpenCV などオープンソースの取り組みが進むプログラミング言語（MATLAB, Python など）でのデータ可視化手法の習得は、土木技術者が自らデータを観察して判断するために必要となるであろう。

③ 土木技術者が主体的にデータを蓄積して管理し流通させる力

社会インフラに関するさまざまなデータをどのように運用していくかを土木技術者が主体的に検討して判断するには、データベースやクラウドに関する最低限の知識を身に付け、そのうえで、セキュリティやプライバシーに配慮して適切な相手に適切な方法で流通させる必要がある。また、そのデータを流通相手に応じて説明する力も求められる。特にデータサイエンス技術者と協働する場合には、土木分野の知識に基づいてデータ取得や解釈を説明する力が必須となると考えられる。

(2) Math & Statistics Knowledge

① データサイエンス技術者とコミュニケーションをとるための数学（確率・統計）基礎

多くの土木工学を専攻する高等専門教育（高等専門学校・大学・大学院）では、理工系の基礎科目として数学（解析学・微積分学・線形代数・確率統計）を習得させるカリキュラムとなっている。しかし、これから AI 技術を活用しデータサイエンス技術者と協働していくためには、特にコンピュータによる数学、特に確率・統計の取扱いを意識した離散数学での学習体系を検討していくことが、アプローチの1つとして考えられる⁴⁾。また、既に実務に携わる土木技術者には、この確率・統計基礎の学びなおしの機会は有効と考えられる。

② AI・機械学習によって構築された AI システムを評価する力

これには、高等専門教育や学びなおしの機会に「最小二乗法」や「線形回帰」といった基礎項目を、ランダム誤差をもつ単純なデータセットなどを用いて、コンピュータで演習を実施する機会が有効である。この中で、誤差論を含むデータ取得の基礎や「過学習」など AI システムの評価で考慮しなければならない事項の基礎を、把握することができる。

(3) Hacking Skills

① 最先端のデータサイエンス技術に関する情報収集力

最近ではインターネット上でさまざまなデータが共有され、またデータサイエンス分野では最新または汎用性の高いアルゴリズムのプログラムコードが GitHub などのウェブサイトでも無償にて公開されている。データサイエンス分野の理論や技術の最新トレンドや概要を、土木技術者がインターネット上などで情報収集したり、またその適用を受容できたりすることが、今後 AI 技術を活用していくために重要であると考えられる。また、このためのコンピュータセキュリティに関する最低限の知識も、習得しておく必要がある。

9.4.4 データサイエンスリテラシー向上：土木工学教育での情報系カリキュラム強化

これからのインフラ運用分野で活躍する土木技術者のデータサイエンスリテラシーの向上には、主に土木工学を専攻する高等教育機関、すなわち大学・大学院や高等専門学校での教育において、それを見越した人材を育成する視点も今後必要となると考える。前項にも述べたように、データサイエンスリテラシーには数学、特に離散数学での確率統計や、コンピュータおよび情報系のリテラシー教育が必要となるであろう。

国内外（主に日本、欧米諸国、中国）の土木工学専攻の大学・大学院⁵⁾におけるカリキュラムをシラバスで概観すると（いずれの大学も 2018 年 10 月 2 日閲覧）、特に「人工知能 (Artificial Intelligence)」や「機械学習 (Machine learning)」といった AI 技術に直接つながるキーワードを含む講義を教育カリキュラムの中で提供している大学は、ほとんど見当たらなかった。ただし情報系の科目のシラバスの中には、「機械学習 (Machine learning)」や関連するキーワード（例えば「回帰」「分類」「推定」）が、特に大学院講義にみられることが多かった。これは、土木工学分野においても既に研究活動等においては、AI・機械学習の手法を用いている大学教員や研究者が増えているためと考えられる。このように、ある程度専門的な学習が進んでおり研究にも従事する大学院レベルの教育では、多かれ少なかれ、AI・機械学習に触れる経験を得てから社会にでていくことも多くなっていると考えられる。

一方で欧米諸国のいくつかの大学では、土木工学科の学部教育においてデータサイエンスリテラシーに関連するような内容を講義で提供している場合がみられた（表 9.4.1）。例えばマサチューセッツ工科大学では、学部 1 年・2 年での「コンピュータプログラミング」や「確率・統計」の講義で、データの可視化や統計処理を学び演習する講義となっていることが、シラバスから把握できた。またカリフォルニア大学バークレー校やニューヨーク市立大学では、学部で Data Analysis をトピックとした講義を開講しており、ここでも、データの読み込みや可視化、そして線形回帰のプログラミング、推定問題も取り扱われていた。また Imperial College London では、学部 1 年次の Computer Method の講義にて、ランダムデータの可視化や基本的な確率統計分析（線形回帰まで）を実際に扱う演習、そして特に機械学習の手法に必須となる線形代数や微積分学の演算を、プログラミング言語で演習する講義が行われている。これらの講義では、プログラミング言語に Matlab がよく採用されているようである。Matlab は学生ライセンスでも有償であるが、Python は無償でダウンロードして活用することができる。また近年では、学生個人がノート PC を所有していることがほとんどであり、上記のカリフォルニア大学バークレー校の講義では、学生の私物のノート PC を持参させ、所有していない場合はクラスメートでシェアをさせて、演習を実施することをアナウンスしていた。このような状況を鑑みると、特別な投資がなくても既存の数学科目や情報系の講義科目に、まずはデータサイエンスを意識した内容を少しずつ取り入れることも可能であると考えられる。

その上で、国内においては、大学・大学院での工学系教育改革の流れが始まっている。その中で、2017 年 6 月に文部科学省より公表された「大学における工学系教育の在り方について（中間まとめ）⁶⁾」によると、第 4 次産業革命や Society 5.0 がうたわれる中で戦略的に強化すべき基盤技術

として、AI, IoT, ビッグデータ解析技術などが示されている。そして、図 9.4.2 の中でもみられるように情報関連分野以外の工学分野であっても情報分野は関わるものであり、基礎教育としての情報科学技術教育の強化が工学教育構造の柱の1つとして提言されている。そのうえで、文部科学省より 2018 年 3 月に公表された「工学系教育改革制度設計等に関する懇談会とりまとめ」では、工学系教育改革の実現に向けて重点的に講ずるべき具体的な制度設計の中に、「学部段階における工学基礎教育の強化」を掲げ、その中のモデル・コア・カリキュラムの中に「情報科学技術（情報セキュリティを含む）」と「数理・データサイエンス（確率・統計を含む）」が明記されており、いずれも工学全体必修科目としての導入が可能とされている。土木工学分野においても、この流れに沿った教育体系を考えていくことが、近い将来にもとめられていくであろう。その中で、データサイエンスリテラシーを身に着けた土木工学人材が輩出され、AI 技術の実装でインフラ維持管理に貢献できることが期待される。

表 9.4.1 海外大学の土木工学科（学部）でデータサイエンスに関する項目を扱う講義科目

大学名	講義名
Massachusetts Institute of Technology (米)	Engineering Computation and Data Science, Computer programming for Engineering Applications, Introduction to Probability and Statistics in Engineering
University of California, Berkeley (米)	Engineering Data Analysis
City University of New York (米)	Data Analysis for Civil Engineering Applications
Imperial College London (英)	Computational Method I



図 9.4.2 工学系教育システムの改革(案) <改革後のシステム> (「大学における工学系教育の在り方について(中間まとめ)」⁶⁾)

9.4.5 データサイエンスリテラシー向上：インフラ維持管理技術者学び直しの強化

内閣総理大臣の指示により産学官の叡智を集め縦割りを排し創設された「人工知能技術戦略会議」⁸⁾では、総務省・文部科学省・経済産業省が所管する5つの国立研究開発法人を束ね、人工知能(AI)技術の研究開発を進めるとともに、AIを利用する側の産業の関係府省と連携し、AI技術の社会実装が推進されている。その人工知能技術戦略実行計画の中では、AI時代の到来を踏まえたAI人材基盤の確保⁹⁾として、国の施策等によるAI人材の追加育成の試算が示されている。試算人数については、「新卒者」による供給を300人/年とする一方で、「社会人学び直し」による人材育成を2500人/年としており、社会人を対象としたAI人材育成が、人材規模の面より重要な割合を占めている。

また、未来投資会議におけるIT人材・AI人材育成¹⁰⁾でも、学校教育において「全学的な数理・データサイエンス教育の強化により、我が国全体のリテラシーの醸成を加速する」とした上で、社会と連携する高度なデータサイエンススキルを有した人材の育成や社会人学び直しの取組の展開が示されている。

インフラ維持管理分野は、これからのAI・データサイエンスの適用が大きく期待される分野の一つであると考えられるが、他方、数理・統計やデータ活用のスキルを有する人材は、まだまだ少ない。インフラ維持管理分野において、現場や工学知識を獲得している者が、新たに数学や統計学の知識やデータを扱うスキルを修得し、AIの正しい活用に近づける事などにより、早期

に AI・データサイエンス活用を可能にするための「社会人の学び直し」による AI 人材育成は、当分野に効率的に AI・データサイエンスの社会実装をもたらすと考えられる。

参考文献

- 1) Glassdoor: 50 Best Jobs in America, <https://www.glassdoor.com/List/Best-Jobs-in-America-LST_KQ0,20.htm>, (入手2018.12.24) .
- 2) Drew Conway: The Data Science Venn Diagram, <<http://www.dataists.com/2010/09/the-data-science-venn-diagram>>, (入手2018.11.11) .
- 3) データサイエンティスト協会: データサイエンティストスキルチェックリスト ver2.00, <https://www.slideshare.net/DataScientist_JP/2017-81179087>, (入手2018.11.11) .
- 4) 矢吹信喜. (2013). 土木情報学の提唱と土木建築情報学国際会議の設立 (特集 建設情報の国際化). JACIC 情報, 28(2), 5-12.
- 5) QS World University Rankings by Subject 2018: Engineering -Civil & Structural <<https://www.topuniversities.com/university-rankings/university-subject-rankings/2018/engineering-civil-structural>>より主要な大学を抜粋 (2018.10.02)
- 6) 文部科学省「大学における工学系教育の在り方について (中間まとめ)」について <http://www.mext.go.jp/b_menu/shingi/chousa/koutou/081/gaiyou/1387267.htm>, (入手2019.1.9)
- 7) 文部科学省 工学系教育改革精度設計等に関する懇談会とりまとめについて <http://www.mext.go.jp/b_menu/shingi/chousa/koutou/088/gaiyou/1403191.htm>, (入手2019.1.9)
- 8) NEDO: AI ポータル, <https://www.nedo.go.jp/activities/ZZJP2_100064.html>, (入手 2018.12.24)
- 9) 人工知能技術戦略会議: 人工知能技術戦略実行計画 (案) 概要, <<https://www8.cao.go.jp/cstp/tyousakai/jinkochino/7kai/siryu2.pdf>>, (入手 2018.12.24)
- 10) 未来投資会議: A I 人材育成について, 平成 30 年 4 月 4 日 (第 5 回) 構造改革徹底推進会合「企業関連制度・産業構造改革・イノベーション」会合 (雇用・人材), 資料 4, <<https://www.kantei.go.jp/jp/singi/keizaisaisei/miraitoshikaigi/suishinkaigo2018/koyou/dai5/siryu4.pdf>>, (入手 2018.12.24)

10. データセット

10.1 はじめに

近年における深層学習を例とした AI 技術の隆盛は目覚ましく、各種の学術・産業分野における応用がここ数年で急速に進んでいる、医学における画像診断の支援、自動車の自動運転における走行環境の認識、音声アシスタントシステムや機械翻訳の機能の高度化、ロボットや機械の動作制御といった分野では既に大きな成果が挙げられており、今後も基礎技術の革新と適用領域の拡大が予想されている¹⁾。

AI が実現する画像認識などの技術は、土木工学分野においても構造物の劣化個所の検出、災害時における都市被害の把握など、様々な場面での利用が検討されている^{2),3)}。また、AI 技術を利用した情報処理の自動化は、日本における i-Construction 推進の潮流の中で、CIM の導入などによりデジタル化された情報や各種のセンサーにより取得されるデータを効率的に処理し、有益な情報を生成する上で今後大きな役割を果たすことが期待される。このような、土木工学上のビッグデータの創出と情報学的アプローチによる情報処理を従来の土木工学技術と融合させた技術領域は、土木情報学やインフラ・インフォマティクスと総称される。土木情報学やインフラ・インフォマティクスの高度化は土木工学分野における今後の重要な取り組みと認識されており⁴⁾、AI 技術の応用はこのための有力なアプローチの 1 つとみなすことができる。

深層学習手法に代表される、近年に活用の進む AI 技術の多くは、人間がこなすような様々な知的作業（タスク）を計算機に実行させるためのアプローチである、機械学習モデルの 1 種に分類される。機械学習モデルの構築には、既存のデータを元にタスク処理の性能を向上させる「学習」と呼ばれるプロセスを採ることが一般的であり、学習に用いられる既存データは教師データや訓練データと呼ばれる。高いタスク処理性能を有する機械学習モデルの構築には適切な学習を経る必要があり、そのためには質・量の良好なデータの準備が重要となる。特に、深層学習モデルは多量のデータの存在を前提としていることから、今後の AI 技術の発展のためには目的やタスクに応じたデータの整備が大きな役割を果たすと考えられる。

そこで本章は、AI 技術研究におけるデータの役割と様々な分野におけるデータの活用事例を概観し、土木工学分野における AI 技術活用のためのデータの整備・構築に向けた考察を行う。なお、本章の以降では、機械学習モデルの学習のために整備されたこのようなデータの集合をデータセットと称する。

参考文献

- 1) 情報処理推進機構：AI 白書 2017，角川アスキー総合研究所，2017.
- 2) 全邦釘，井後敦史，南免羅裕治，黒木航汰，大窪和明：車載カメラにより撮影された舗装画像からのディープラーニングによるひび割れ率評価土木学会論文集 E1, Vol.73, No.3, pp. I_97-I_105, 2017.

- 3) 利根川 凜, 飯塚 博幸, 山本 雅人, 古川 正志, 大内 東, : 被災がれき量推定に向けた畳み込みニューラルネットワークを用いた倒壊建造物の自動抽出, 情報処理学会論文誌, Vol.57, No.6, pp. 1565-1575, 2016.
- 4) 日本経済団体連合会 : Society5.0 実現による日本再興
<http://www.keidanren.or.jp/policy/2017/010.html>
- 5) 内閣府 次世代インフラ戦略協議会 第12回資料
http://www8.cao.go.jp/cstp/tyousakai/juyoukadai/infra_fukkou/12kai/siryo4-1.pdf
- 6) 国土交通省 国土交通技術行政の基本政策懇談会 第1回配布資料
<http://www.mlit.go.jp/common/001239117.pdf>

10.2 機械学習研究におけるデータセット

10.2.1 データセットの利用

機械学習モデルが実行することのできるタスクには、ある画像が何を表したものを判別するなど、データをいくつかのカテゴリに仕分ける「分類」と呼ばれるものや、過去数日の気象情報から次の日の気温を予測するなど、連続的な数値を予測する「回帰」と呼ばれるものなどがある(図 10.2.1)。こうしたタスクの多くは、モデルに入力されるデータを x 、出力されるデータを y とおいたときに、 $y=f(x)$ として x から適切な y を求める問題として形式的に記述することが出来る。このとき、教師データとして予め x と y のペアを複数用意しておき、教師データの入出力関係が再現されるように $f(\cdot)$ を決定することが機械学習モデルの学習であり、このような入出力関係の学習は教師あり学習と総称される。前述のように、機械学習のタスクの多くは教師あり学習であり、応用上の様々な問題もまた教師あり学習の枠組みの中で捉えることができる。教師あり学習に用いるデータセットは、入力データに加えて個々のデータに対する望ましい出力値(例えば、画像 A は「犬」の画像、画像 B は「猫」の画像、といったような分類結果)がペアとして準備される(表 10.2.1)。

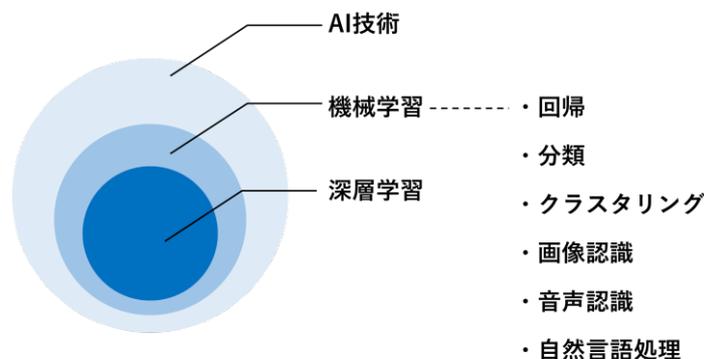


図 10.2.1 AI 技術, 機械学習, 深層学習の関係と, 機械学習が対象とするタスクの例

表 10.2.1 教師あり学習におけるタスクと教師データの例。

タスク	事例	教師データ	
		入力データ	出力データ
データの回帰	気温の予測	(実) 数値	(実) 数値
画像認識	ひび割れの検出	画像/ピクセル値	分類ラベル
音声認識	打音検査	時系列の音声データ	分類ラベル
自然言語処理	SNS上の投稿に基づく被害分析	テキストデータ	分類ラベル

教師あり学習のために、ある種のラベル付けがなされたデータセットを対象の問題に応じて用意することは大きなコストを要するものの、いくつかの分野では特定の問題に対するデータセットが研究開発のための基礎資料として大規模に整備され、オープンデータとして広く公開されることがある。こうしたデータセットは、実際に当該分野での各種の機械学習モデルの学習に用いられるほか、複数の機械学習モデルの性能を比較するベンチマークテストに利用されることもある。また、多数の教師データが必要となる深層学習モデルが多用される近年では、規模の大きな一般的なデータセットを用いて予めモデルを事前に学習させた後、対象としている問題に応じたデータセットを改めて学習させる、転移学習や Fine-tuning と呼ばれる技法のために利用されることも多い。

特定の分野における AI 技術の発展においては、上記のようなデータセットの整備は大きな役割を果たしている。以下に、いくつかの分野におけるデータセットの整備・活用事例を示す。

10.2.2 研究分野におけるデータセット活用の事例

(1) 情報学分野

画像処理や自然言語処理などの基礎技術を扱う情報学分野では AI 技術が広く研究されており、研究を支えるデータセットの構築が進んでいる。下記に挙げたデータセットの多くは研究者グループが独自に構築したものである他、一部のデータセットは利用者からのデータ提供を受けながら現在も整備が進んでいる。

UCL Machine Learning Repository²⁾は、様々なタスクやデータ種別、学術分野に応じた多様なデータセットを提供しており、1987年から現在に至るまでデータの整備と追加が進められている。MNIST³⁾は手書きの数字をデジタル化したデータセットであり、文字認識の分野だけでなく機械学習一般の例題にも用いられるなど広く知られたものとなっている。ImageNet⁴⁾は、1,000万を越える数の画像と、各画像に写る事物の名称をラベル付けした結果から構成されたデータセットで、画像認識を行う機械学習モデルの学習やベンチマークテストなどに活用されている。自然言語処理分野では、文章資料を体系的に収集・構造化し言語学的な情報を付記したコーパスと呼ばれるデータセットが言語ごとに構築され^{例えば5),6)}、研究に活用されている。音声認識分野や行

動認識分野においても、それぞれ発話コーパス⁷⁾・行動認識コーパス⁸⁾と呼ばれる、分野ごとの基礎データに情報を付記したデータセットが構築され、広く用いられている。

(2) 医学・バイオインフォマティクス分野

医学分野においては、画像診断や予後予測、治療機器の自動制御といった領域においてAI技術の活用の可能性が検討されている⁹⁾。また、DNA配列などの生物学上のデータを情報科学的手法によって分析するバイオインフォマティクス分野¹⁰⁾においても、機械学習手法を用いた分析技術の高度化が進んでいる¹¹⁾。こうした技術を発展させていくうえで大規模なデータセットの構築は不可欠なものであると認識されており、構築に当たってはデータの標準化や匿名化に加え、データ規模の確保とそのための仕組みづくりが課題として挙げられている^{9),12)}。

具体的なデータセットの事例として、以下のものが挙げられる。MedPixは米国国立医学図書館が提供する、診断結果がラベル付けされた医療診断画像約60,000枚から構成されるデータセットであり、利用者からのデータ提供を受けながら現在も情報収集が続けられている¹³⁾。放射線医学領域では、治療のために投与された放射線量分布と治療結果（臨床成績）の関係が7年に渡って収集され、大規模なデータ解析を実現させている¹⁴⁾。日本国内においては、医療分野における複数の学会が主導して全国から画像診断結果などを収集することにより、AI研究への利活用を見据えた大規模な診断画像等のデータベースの構築が進んでいる¹⁵⁾。また、バイオインフォマティクス分野では、日本DNAデータバンク¹⁶⁾や米国生物工学情報センター¹⁷⁾といった組織が国際的に情報を提供しあいながら、DNA配列とその解析結果を組み合わせたデータセットを継続的に整備している。

(3) 工学分野

工学分野においてAI技術の導入の効果が注目されている事例の一つとして、マテリアルズインフォマティクスが挙げられる。マテリアルズインフォマティクスは、計算科学的手法やデータ科学手法の応用によって、新材料の開発などの材料研究開発を効率的に行おうとする研究分野である。同分野では、データ解析手法の開発とともに大規模なデータセットの蓄積が重要視されており、世界各国で研究開発のためのデータセットの構築が進められながらも、現在でもデータ量の不足やデータ共有のためのデータ形式・プラットフォームの整備が課題として指摘されている¹⁸⁾。データセット構築の取り組みの例として、米国国立標準技術研究所（NIST）が運用するMaterials Data Repositoryは、NISTや他の研究機関が実施した実験データや材料開発データを集積し、公開している¹⁹⁾。日本においても、物質・材料研究機構が様々な材料に対するデータの蓄積と公開を行っている²⁰⁾。更に、今後の研究開発の発展に向けて、研究機関間や国際的な協調によるデータセット整備の必要性と、実現のための課題が議論されている。

AI技術の工学的な応用が進む分野のもう一つの事例として、自動車の自動運転技術の研究が挙げられる。自動車の運転に必要なとされる認知・判断・操作の各タスクを実行するAIの開発に向けて、日本を含む各国や主要な自動車メーカーは大規模に研究開発を実施している²¹⁾。運転

状況の認知や、危険予測などの判断を行う AI の研究開発においては、様々な状況下での走行シーンを撮影した映像と、各シーンにおける事物の位置などをラベル付けした、膨大な教師データが必要とされており、Google 社や Mobileye 社といった企業が独自にデータ収集を行っている他、企業間のデータ提供などの連携も模索されている²²⁾。また、国内外での研究開発機関においても、同様に走行映像データセットの整備が進められている。こうした動向を踏まえ、組織間での連携や各企業のメリットを維持した企業間のデータ共有のための体制を将来的に整えることの必要性が日本において議論されている²²⁾。

10.2.3 教育におけるデータセット活用の事例

以上で述べたデータセットは、研究におけるベンチマークとしての目的で提供されているものが多いが、AI・データサイエンス教育の目的においても収集・利用が行われている。ここではそのような事例として、我が国の数理・データサイエンス教育強化拠点コンソーシアムによる取り組みにより、データサイエンス教育向けのデータセットの検討について紹介する。

(1) データサイエンス教育用データ

全国 6 大学で構成される数理・データサイエンス教育強化拠点コンソーシアムでは、コンソーシアムのミッション達成のため、次の 3 つの分科会を設置し、活動を行っている。

- ・カリキュラム分科会

全国的なモデルとなる標準カリキュラムを協働して作成・普及に取り組む

- ・教材分科会

全国的なモデルとなる教材を協働して作成・普及に取り組む

- ・教育用データベース分科会

教育用のデータを収集し、各大学が使用できる環境を整備する

以上の分科会のうち、教育用データベース分科会²³⁾は、北海道大学 数理・データサイエンス教育研究センター（センター長 長谷山美紀）²⁴⁾が主査の役割を担っており¹⁾、データサイエンス教育に有用なデータの調査を行い、データの選定と共有に向けた取組みを進めている。

現在までに、100 を超えるデータを対象として、データの可用性や内容、規模等を精査し、その中から、データサイエンス教育用データとして適切なデータの選定を進めている。対象となるデータは、次のようなデータ種類毎に整理し、各データについてバランスよく集まるよう配慮している。

¹⁾ 2018 年度は、センター特任准教授高橋翔（現在、北海道大学工学研究院准教授）が DB 分科会主査を務め、現在は、本節筆者の湧田が務めている。

<データの種類>

- ・ 表形式：数値や文字列の CSV 等データ
- ・ Linked Data：意味構造を持つデータ等
- ・ 文書形式：文書, PDF, xml 等のデータ等
- ・ IoT データ：IoT/センサデータ, 時系列データ等
- ・ 音声：音声データ
- ・ 画像：写真等の画像データ
- ・ 動画：動画データ
- ・ その他データ：CAD データ, GIS 形式, 専門的形式のデータ

また、データ種類以外にも、データ整理の情報をタグとして付与し、教育用データの一覧として整理を進めている。例えば、データの分野に関するタグ情報として、「学問分野」、「産業分野」の二通りの情報により整理を行い、学生がデータを利用する際に、学びたい分野や学んだ後の出口となる応用分野が見えるよう配慮している。さらに、他の分科会にて検討中の「カリキュラム」および「教材」との対応についてもタグ付けによるデータの整理を行い、教育現場にて活用可能なデータを円滑に選択できるものとしている。

これまでに教育用データの候補として整理しているデータ例は、次のとおりである。例えば、「表形式データ」は、独立行政法人 統計センターが提供する教育用標準データセット²⁵⁾、総務省提供の人口総数：総務省『国勢調査』²⁶⁾や、経産省が提供する全産業活動指数 時系列データ²⁷⁾など、Data.go.jp²⁸⁾にて公開されているデータを中心に登録を行っている。「LoD データ」は、人文学オープンデータ共同利用センターが提供する日本古典籍データセット²⁹⁾等を検討している。「文書形式データ」については、ヤフー（株）とNIIが提供するYahoo!知恵袋データセット³⁰⁾を対象として検討している。また、「リアルタイムデータ」としては、時系列データとして、文部科学省研究開発局が提供する地震データ³¹⁾の利用を検討している。「音声データ」には、文部科学省が提供する UME-ERJ³²⁾、UME-JRF³³⁾、「画像データ」には Adam Coates らの STL-10 dataset³⁴⁾、Krizhevsky らの CIFAR-10³⁵⁾、Yann LeCun らの MNIST³⁾の利用を検討している。「動画データ」には、KIT が提供するモーションキャプチャデータ the KIT Whole-Body Human Motion Database³⁶⁾の利用を検討している。

これらのデータは、いずれも無料で提供されているデータであるが、教育用データとしての活用にあたっては、利用規約等を確認した上で、実用を進めていく必要がある。

(2) 教育用データ提供システム

データサイエンス6大学コンソーシアム データベース分科会では、分科会主査となる北海道大学が、データ共有のための仕組み「教育用データ提供システム」の構築を実施している。教育用データ提供システムの機能は、次のとおりである。

<教育用データ提供システムの提供機能(案)>

- ・ データ共有・参照機能
- ・ Open data 方式で、外部データを参照するポータルサイト機能
- ・ 各データについて、データ種類や分野等のタグを付与できる「タグ付け」機能
- ・ 利用実績をログとして記録する機能
- ・ 利用実績に基づくタグ付けと逆引き機能
- ・ 利用実績のログから、逆引きを可能とする機能

データに対するタグ付け機能では、上で述べたタグを個々のデータに対して付与する機能であり、これを用いて、各種のタグから、対応するデータを探すことができる。例えば、カリキュラムにおける特定の手法において、どのようなデータが利用できるのか、対応するデータを検索可能となる。

以上のような機能を有するデータ共有の仕組みとしては、open data の取組みが最も近いと考えられ、open data において多く用いられるデータ共有プラットフォームを活用し、開発を進めている。共有用データについては、サーバに固定的に登録するのではなく、他のサーバに格納されているデータのリンクを示す「ポータル」の役目を担う。また、上で挙げたタグによるデータのフィルタリング機能やデータに対する説明を付記する機能も提供することが可能である。

(3) 情報共有のプラットフォーム

AI 技術の研究においては、上記のような各種のデータセットの存在に加えて、データ分析のための技術や具体的なツールの多くが広く公開され容易に利用できることもまた、研究開発を加速させる要因となっている。arXiv³⁷⁾は査読前の論文を投稿・共有可能なウェブサービスであり、機械学習モデルに関する近年の最新技術は、学術誌に公開される前に arXiv 上で発表される動向が見られる。また、機械学習モデルを実装したソフトウェアやプログラムコードを共有するウェブサービスである GitHub³⁸⁾の活用も進んでいる。更に、ウェブサービス Kaggle³⁹⁾では、様々な分野の企業や研究者が所有するデータとデータに関わる課題を自由に投稿し、当該の課題に対する機械学習モデルをコンペティション形式で募集する仕組みが提供されている。

データセットを含む、機械学習技術に関わる各種の情報や技術を公開・共有し、当該分野に人材を集めるこうした動向は、「集合知のプラットフォーム形成」と称されている。日本においても、データチャレンジと呼ばれるコンペティションの開催による人材・アイデアの集積や、データの共有プラットフォームを提供するコンソーシアムの設立が進んでおり、土木工学分野においてもこのような潮流が見られる⁴⁰⁾⁴²⁾。

参考文献

- 1) 中山英樹：深層畳み込みニューラルネットワークによる画像特徴抽出と転移学習．信号処理学会技術研究報告，Vol.115，No.146，pp.55-59，2015.
- 2) Dua, D. and Efi, K. T.: UCI Machine Learning Repository
<http://archive.ics.uci.edu/ml>
- 3) LeCun, Y.: THE MNIST DATABASE of handwritten digits
<http://yann.lecun.com/exdb/mnist/>
- 4) Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K. and Fei-Fei, L.: ImageNet: A Large-Scale Hierarchical Image Database. In CVPR09, 2009.
- 5) 国立国語研究所：コーパス一覧
<https://www.ninjal.ac.jp/database/type/corpora/>
- 6) Corpus of Contemporary American English
<https://corpus.byu.edu/coca/>
- 7) Fisher, W. M.: The DARPA Speech Recognition Research Database: Specifications and Status, Proceedings of DARPA Workshop on Speech Recognition, pp. 93-99, 1986.
- 8) Kawaguchi, N., Ogawa, N., Iwasaki, Y., Kaji, K., Terada, T., Murao, K., Inoue, S., Kawahara, Y., Sumi, Y. and Nishio, N.: HASC Challenge: Gathering Large Scale Human Activity Corpus for the Real-World Activity Understandings, Proceedings of the 2nd Augmented Human International Conference, 27. ACM, 2011.
- 9) 大江和彦：これからの医療における AI の活用と課題，医薬品情報学，Vol.19，No.3，pp.N1-N3，2017.
- 10) 乃木篤，香月祥太郎：バイオインフォマティクスの技術動向，科学技術動向，No.22，pp.15-21，2003.
- 11) 山西芳裕：バイオインフォマティクスやケモインフォマティクスにおける機械学習，人工知能，Vol.30，No.2，pp.224-229，2015.
- 12) 馬込大貴：医療データベースを用いた機械学習，医学物理，Vol.36，No.1，pp.39-41，2016.
- 13) United States The National Library of Medicine: MedPix
<https://medpix.nlm.nih.gov/home>
- 14) Robertson, S. P., Quon, H., Kiess, A. P., Moore, J. A., Yang, W., Cheng, Z., Afonso, S., Allen, M., Richardson, M., Choflet, A., Sharabi, A. and McNutt, T. R.: A data-mining framework for large scale analysis of dose-outcome relationships in a database of irradiated head and neck cancer patients, Medical Physics, Vol. 42, Issue 7, pp.4329-4337, 2015.
- 15) 末松誠：AIによる画像診断支援に向けた研究の進捗状況について
<https://www.mhlw.go.jp/content/10601000/000337598.pdf>

- 16) DNA Data Bank of Japan
<https://www.ddbj.nig.ac.jp/index-e.html>
- 17) Benson, D. A., Cavanaugh, M., Clark, K., Karsch-Mizrachi, I., Lipman, D. J., Ostell, J. and Sayers, E. W.: GenBank, Nucleic Acids Research, Vol. 41, Issue D1, pp.D36-D42, 2012.
- 18) 知京豊裕：マテリアルズインフォマティクスの現状と課題，情報知識学会誌，Vol.27, No.4, pp.297-304, 2017.
- 19) NIST Materials Data Repository
<https://materialsdata.nist.gov/>
- 20) NIMS 物質・材料データベース
<http://mits.nims.go.jp/>
- 21) 我妻広明：人工知能による運転支援・自動運転技術の現状と課題，計測と制御，Vol.54, No.11, pp.808-815, 2015.
- 22) 内閣官房 IT 総合戦略室：自動運転の実現に向けたデータ基盤整備の方向（案），2017。
（内閣官房 IT 総合戦略本部 データ活用基盤・課題解決分科会 道路交通ワーキングチーム第3回会合資料）
https://www.kantei.go.jp/jp/singi/it2/senmon_bunka/detakatsuyokiban/dorokotsu_dai3/siryoku4.pdf
- 23) 数理・データサイエンス教育強化拠点コンソーシアム 教育用データベース分科会
<http://www.mi.u-tokyo.ac.jp/consortium/activities3.html>
- 24) 北海道大学, 数理・データサイエンス教育研究センター(Education and Research Center for Mathematical and Data Science): <<https://www.mdsc.hokudai.ac.jp/>>, (入手 2019.01.4)
- 25) 独立行政法人 統計センター：教育用標準データセット
<https://www.jishin.go.jp/database/portal/>.
- 26) 総務省：人口総数：『国勢調査』
http://www.data.go.jp/data/dataset/cao_20150109_0014
- 27) 経済産業省：全産業活動指数 時系列データ
http://www.data.go.jp/data/dataset/reti_20140901_1053
- 28) Data.go.jp
<http://www.data.go.jp/>
- 29) 人文学オープンデータ共同利用センター：日本古典籍データセット
<http://codh.rois.ac.jp/pmjt/>
- 30) ヤフー（株），NII：Yahoo!知恵袋データセット
http://www.nii.ac.jp/dsc/idr/yahoo/chiebukr2/Y_chiebukuro.html
- 31) 文部科学省研究開発局：地震データ
<https://www.jishin.go.jp/database/portal/>
- 32) 文部科学省：UME-ERJ
<http://research.nii.ac.jp/src/UME-ERJ.html>

- 33) 文部科学省 : UME-JRF
<http://research.nii.ac.jp/src/UME-JRF.html>
- 34) Coates, A. et. al.: STL-10 dataset
<http://ai.stanford.edu/~acoates/stl10/>.
- 35) Krizhevsky et. al.: CIFAR-10
<http://www.cs.utoronto.ca/~kriz/cifar.html>
- 36) KIT : the KIT Whole-Body Human Motion Database
<https://motion-database.humanoids.kit.edu/>.
- 37) arXiv
<https://arxiv.org>
- 38) GitHub
<https://github.com/>
- 39) Kaggle
<https://www.kaggle.com/>
- 40) 土木学会 : インフラデータチャレンジ
<http://jsce-idc.jp/>
- 41) 公共交通オープンデータ協議会
<http://www.odpt.org/>
- 42) 気象災害軽減コンソーシアム
<http://www.bosai.go.jp/ihub/conso/index.html>

10.3 土木工学分野におけるデータセット構築に向けた考察

10.3.1 応用が想定される分野例

前述の諸分野に加え、土木工学においても AI 技術は急速に利用が進んでいる傾向にある。以前から機械学習技術が活用されている領域を含む様々な分野において、専門技術者が行ってきた人的な判断を AI による自動判断に置き換える手法や、様々なデータに基づいて判断や予測を高精度化させる手法の研究が進んでいる。また、深層学習を代表とした近年の技術革新により、これまでは機械学習が適用されてこなかった分野での新たな応用も徐々に進みつつある。以下では、データセットの整備が有効と考えられる土木工学内の研究分野について、具体的な研究事例を示しながら述べる。

維持管理分野においては、構造物の撮影画像や打音検査結果といったセンシング結果から、コンクリート中のひび割れなど、構造物に生じた変状を自動検出する技術の開発が近年に至るまで多くなされてきている^{例えば 1)-3)}。技術者の不足と劣化構造物の増大が進む現代において、構造物の検査を効率化するこうした研究を促進させることは極めて重要であり、研究のための基礎データとして、また各研究成果の客観的な評価に用いるベンチマークとして、対象とする変状やセン

シング手法に応じたデータセットを整備することは大きな役割を果たすと期待される。

防災分野では、自然災害による被災状況を把握する技術として、人工衛星や UAV 等から取得されるリモートセンシングデータから、地震時や土砂災害時における被災状況を検知する手法の開発が進んでいる^{例えは 4),5)}。また、特に気象災害に関しては、現状の把握だけでなく災害の発生を機械学習手法によって予測する試みも行われており、深層学習などの近年の手法が有する高いタスク処理性能の活用が進んでいる^{6),9)}。こうした研究においては、これまでに蓄積された被災地域のセンシングデータや、過去における気象条件のデータが本質的な役割を果たすことから、様々な主体が有しているこうしたデータの公開や整備が進むことは重要である。また、災害時のデータは平常時のデータに比較してその数に限りがあることから、平常時のデータのみでの学習から異常を検知する、異常検知などの教師なし学習手法¹⁰⁾の適用を想定したデータセットの整備を行うこともまた、新たな研究の創発を推進すると考えられる。

交通・計画分野では、広く自動運転技術の実現において AI 技術が活用されている他²⁶⁾、交通流のマクロな推定におけるデータ同化手法の利用¹¹⁾など、交通情報に関する大規模なデータを活用した研究が行われている^{例えは 12),13)}。また、公共交通に関するデータがオープン化されることによる新たなサービス展開の現状や可能性が論じられており¹⁴⁾、交通ビッグデータとも称される多様な交通情報に関するデータの整備と活用は、今後もこうした研究の潮流を支えていくものと考えられる。

環境分野においては、前述のように気象予測において AI 技術の活用が進んでいる他、リモートセンシングデータから森林の植生分布などの地球環境状態を推定する手法へも AI 技術の応用がなされている^{例えは 15)}。リモートセンシング技術に対する AI の活用は強く有力視されており^{16),17)}、環境リモートセンシングにおいても今後の研究の発展と必要なデータの整備が期待される。

10.3.2 土木工学におけるデータセットの事例

上記のように、土木工学上の様々な分野において AI 技術の活用が進んでおり、対応したデータセットの構築や公開も進んでいる。維持管理分野では、Maeda らは複数の地方公共団体の協力の下で、舗装道路の変状に関する撮影画像のデータセットを構築・公開し、深層学習の教師データとしての有効性を検証している¹⁸⁾。また、米国では全土の高速道路橋に関する点検結果を毎年整理・公開しており¹⁹⁾、研究開発に活用されている^{例えは 20),21)}。また、防災分野では、気象庁や防災科学技術研究所をそれぞれ中心としたコンソーシアムが過去の気象データに関する情報の整理・公開を行っている^{22),23)}。交通計画分野では、公共交通に関する種々のデータをオープン化すると共に、API 等を整備することで利用性の高いデータベースの基盤の構築が図られている²⁴⁾。環境分野では、人工衛星から取得されたリモートセンシングデータや分析結果が徐々に公開される潮流にある²⁵⁾。また、土木学会では維持管理や防災に関わるデータを広く公開・共有し、課題解決のアイデアを競うコンペティションを開催することにより人材・アイデアの集積を図る、インフラデータチャレンジと称する取り組みが行われている²⁶⁾。

10.3.3 データセットの整備方策

前述のような研究分野でAI技術の活用が進むうえでは、他の学術分野と同様に機械学習に用いられるデータセットの整備は不可欠であると考えられる。このようなデータセットに求められる性質として、十分な規模での学習を実現するデータの大規模性や、機械可読であり取り扱いの容易な一定のフォーマットであること、データ品質が客観的に担保されていることはいずれも重要なものである。そこで、このような性質を有したデータセットを今後整備していくに当たり、データ規模の確保、データフォーマットの整備、データ品質の担保という3つの観点から、データ整備の方策を考察する。

(1) データ規模の確保

機械学習モデルの学習に用いられるデータセットには、一般に十分な数のデータが含まれていることが求められる。これは、少ない数のデータに対して学習を行った場合、学習したデータに対して過剰に適合してしまうために、未知のデータに対する適合性能が失われる過学習（過剰適合）と呼ばれる現象が生じるためである（図 10.3.1）。また、近年に応用の進む深層学習は大規模なデータの存在を前提とした技術であり、適切な機械学習モデルの構築においては現状では多くの場合においてデータの大規模性が求められる。

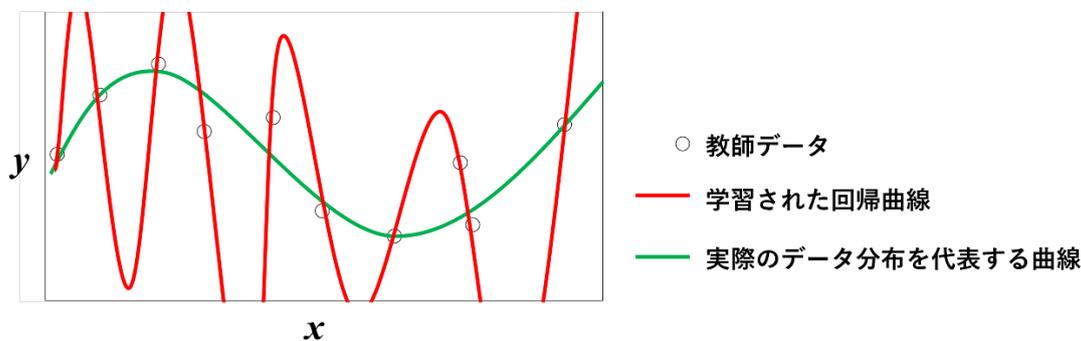


図 10.3.1 データ集合への回帰を例とした場合の過学習のイメージ。教師データに対して過剰に適合した結果、実際のデータ分布から乖離した回帰曲線が得られる（文献²⁷⁾を元に作成）

大規模なデータセットの構築のためには、研究者や研究グループが個別にデータを収集するだけでなく、それらのデータを統合する仕組みを作ることは重要である。そのような仕組みの例として、UCL Machine Learning Repository²⁸⁾や MedPix²⁹⁾は、大学などの公共研究機関が主体となってオンライン上でデータを収集、公開している。また、日本国内の複数の医療関係の学会の協働により、画像診断結果が大規模に収集されたデータベースの構築が進んでいる³⁰⁾。データ収集の際は、同じ目的のデータであっても画像の解像度などの属性が提供先ごとに異なる可能性があるため、そうしたメタデータを含めた管理が必要である。また、データ提供者にとってメリッ

トがあるような仕組みとすることによってデータの提供数を増やした取り組みの例として、HASC Challenge ではデータの提供者に対してのみ、限定的に全体のデータベースを配布する仕組みを一定期間続けた後、数年後に構築されたデータセットを公開している³¹⁾。一方で、他分野におけるデータセットの構築事例においては、収集されたデータに対する、アノテーションと称されるラベル付与の作業が大きなボトルネックとなっており³⁰⁾、専用の支援ツールの開発などによる効率化を図ることも必要になることが考えられる。

また、近年では数値シミュレーションから得られたデータを教師データとして機械学習モデルの学習を行う研究事例も見られる。数値シミュレーションからは、ラベルの付記されたデータを大規模に獲得することが容易であるため、現実のデータと比較しても十分に妥当性のあるデータが得られる分野であれば、このアプローチは非常に有効であると考えられる。そのような研究事例として、維持管理分野では疑似的に作成したコンクリートのひび割れ図を教師データに利用した機械学習モデルを用いて、実際のひび割れ状態からコンクリート部材の余寿命を予測する手法が提案されている³²⁾。防災分野では、地球シミュレータを用いて仮想的に作成した台風の発生・発達的气象条件を学習させることにより、台風の発生する前段階を高精度に検知する手法が開発されている³³⁾。

構造物の変状や都市の被害など、正常時に比較したときの何らかの異常を検知しようとする応用事例においては、正常時のデータに対して異常時のデータが本質的に得られにくいという問題がある。このような事例に対しては、正常時のデータは比較的大規模に獲得しやすいことを踏まえ、正常時のデータのみからモデルを構築して異常を検知する、異常検知などの教師なし学習手法³⁴⁾や半教師学習手法の適用を想定したデータセットの整備を行うことにも大きな検討の余地がある。

(2) データフォーマットの整備

機械学習モデルの構築に用いられるデータセットは上記のように大規模なものも多く、そのようなデータの取り扱いにおいては機械可読なフォーマットでデータセットが提供されることは必須である。そのような目的において、csv や xml などのフォーマットや、メタデータを含む画像であれば tiff フォーマットを利用するなど、一般的に広く用いられるフォーマットを利用するほか、当該のデータセットに特化したデータフォーマットを新たに策定することも有効である³¹⁾。また、個々のデータのフォーマットに配慮することに加え、データ名に通し番号を付記するなど、統一的なルールの下でデータ名が設定されていることは、データセットの可読性を向上させるものである。

一方で、様々な主体から提供されるデータを元にデータセットを構築する際は、前述のように各データのフォーマットが統一されないことも多い。このような場合においては、データ数が少ない場合はデータの管理主体がフォーマットを統一することもできるが、データが増え続けるような場合にはフォーマットの異なる部分をメタデータとして提供する仕組みを設けることにより解決する方が望ましいと考えられる。

(3) データ品質の担保

機械学習モデルの適切な学習においては、教師データそのものが正当なものであることは前提とされるべき重要な条件である。教師あり学習であれば、データの入出力関係に誤りや不明確な点のないことが重要となるが、そのようなデータの品質が実質的に確保されるように、データセットの構築時には十分に注意が払われる必要があることに加えて、特に分野内で広く用いられるデータセットである場合は、専門家や専門機関によってデータ品質が客観的にオーソライズされていることも重要であると考えられる。そのためには、後述するようにデータの管理方法についても留意される必要がある。

また、特定の重要構造物に関する維持管理データや個人単位の交通移動情報などについては、データの匿名化が求められることが予想される。データの匿名化には、個体の特定が不可能であるようにデータの値を削除、あるいは変換する必要があるが、一方で固有の情報はタスク処理において重要な場合もある。例として、コンクリート構造物の経年劣化状況を推定する際は、海岸からの距離などの位置情報は大きな情報となる一方で構造物の特定につながる恐れがある。一般にデータの匿名化において汎用的な手法はないとされており、データの特徴や用途に応じてどの値をどのように操作して匿名化するかは、事例に応じた判断が必要である（図 10.3.2）。

橋梁名	建設年	架橋位置	撮影位置座標	撮影画像	分析結果
〇〇跨線橋	1973年	東京都〇〇区 ××	lat. 35.712743 lon. 139.759137		
↓					
橋梁名	建設年	架橋位置	撮影位置座標	撮影画像	分析結果
削除	1970年代	- 海岸線からの 距離△km - 平地部	削除		

図 10.3.2 橋梁床版の撮影画像に対する匿名化処理事例のイメージ

参考文献

- 1) 山口哲夫, 森濱和正, 笠井芳夫: コンクリート床版の裏面のひび割れの検出, コンクリート工学年次論文報告集, Vol.19, No.1, pp.1345-1350, 1997.
- 2) 岡田賢, 上條哲平, 石川稜威男: ニューラルネットワークを用いた打音の特徴抽出, 電子情報通信学会技術研究報告, 応用音響, pp.1-6, 2002.
- 3) Christian, K., Kristina, G., Varun, K., Burch, A. and Paul, F.: A review on computer vision based defect detection and condition assessment of concrete and asphalt civil infrastructure, Advanced Engineering Informatics, Vol.29, No.2, pp.196-210, 2015.

- 4) Mansouri, B. and Hamednia, Y.: A Soft Computing Method for Damage Mapping Using VHR Optical Satellite Imagery, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote sensing*, Vol. 8, No.10, pp.4935-4941, 2015.
- 5) Kamilaris, A. and Prenafeta-Boldu, F. X.: Disaster Monitoring using Unmanned Aerial Vehicles and Deep Learning, *arXiv*, 2018.
- 6) 一言正之, 櫻庭雅明, 清雄一: 深層学習を用いた河川水位予測手法の開発, *土木学会論文集 B1 (水工学)*, Vol.72, No.4, pp.I_187-I_192, 2016.
- 7) 白山晋, 柴田亮: 深層学習を用いた竜巻発生予測に関する研究, *計算力学講演会講演論文集*, Vol.29, 213, 2016.
- 8) Shi, X., Chen, Z., Wang, H., Yeung, D.Y., Wong, W.-K. and Woo, W.C.: Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting, *arXiv*, 2015.
- 9) 林政行, Rafik Hadfi, 伊藤孝行: 深層学習を用いたマルチモーダル学習による降水量予測, *情報処理学会第 78 回全国大会講演論文集*, pp.369-370, 2016.
- 10) 井出剛, 杉山将: 異常検知と変化検知, *講談社*, 2015.
- 11) 澤田茜, 川辺拓哉, 白須瑛紀, 佐々木邦明: パーティクルフィルタを援用した観測 OD とシミュレーションを融合した OD 推計手法, *土木学会論文集 D3 (土木計画学)*, Vol.73, No.5, pp.I_579-I_588, 2017.
- 12) 野津直樹: ビッグデータによる観光動態分析, *人工知能*, Vol.31, No.6, pp.850-857, 2016.
- 13) 細江美欧, 桑野将司, 谷本圭志: 非負値テンソル因子分解を用いた交通系 IC カードデータからの移動パターンの抽出に関する研究, *都市計画論文集*, Vol.53, No.3, pp.1320-1326, 2018.
- 14) 伊藤昌毅, 瀬崎薫: 公共交通オープンデータムーブメントを作る, *情報処理学会デジタルプラクティス*, Vol.9, No.1, 2018.
- 15) 村上拓彦, 望月翔太: リモートセンシングによる植生マッピング, *日本生態学会誌*, Vol.64, No.3, pp.233-242, 2014.
- 16) 奥村俊夫: リモートセンシング技術における AI 活用に向けた取り組み
https://www.restec.or.jp/ja/wp-content/uploads/2018/06/R_20180613-05.pdf
- 17) Zhu, X.X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F. and Fraundorfer, F.: Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources, *IEEE Geoscience and Remote Sensing Magazine*, Vol.5, No.4, pp.8-36, 2017.
- 18) Maeda, H., Sekimoto, Y., Seto, T., Kashiya, T. and Omata, H.: Road Damage Detection and Classification Using Deep Neural Networks with Smartphone Images, *Computer-Aided Civil and Infrastructure Engineering*, Early View(online), 2018.
<https://doi.org/10.1111/mice.12387>

- 19) National Bridge Inventory
<https://www.fhwa.dot.gov/bridge/nbi.cfm>
- 20) Al-Radaideh, A., Al-Ali, A. R., Bheiry, S. and Alawnah, S.: A Wireless Sensor Network Monitoring System for Highway Bridges, 2015 International Conference on Electrical and Information Technologies, pp.119-124, 2015.
- 21) Alipour, M., Gheitasi, A., Harris, D.K., Ozbulut, O.E. and Barnes, L.E.: A data-driven approach for automated operational safety evaluation of the National Inventory of Reinforced Concrete Slab Bridges, Transportation research board 95th annual meeting, 2016.
- 22) 気象ビジネス推進コンソーシアム
<https://www.wxbc.jp/>
- 23) 気象災害軽減コンソーシアム
<http://www.bosai.go.jp/ihub/conso/index.html>
- 24) 公共交通オープンデータ協議会
<http://www.odpt.org/>
- 25) 宇宙航空研究開発機構 ALOS-2・ALOS データセット
https://www.eorc.jasdfaxa.jp/ALOS/dataset/dataset_jindex.htm
- 26) 土木学会：インフラデータチャレンジ
<http://jsce-idc.jp/>
- 27) Bishop, C. M.: Pattern Recognition and Machine Learning, Springer, 2010.
- 28) Dua, D. and Efi, K. T.: UCI Machine Learning Repository
<http://archive.ics.uci.edu/ml>
- 29) United States The National Library of Medicine: MedPix
<https://medpix.nlm.nih.gov/home>
- 30) 末松誠：AIによる画像診断支援に向けた研究の進捗状況について
<https://www.mhlw.go.jp/content/10601000/000337598.pdf>
- 31) Kawaguchi, N., Ogawa, N., Iwasaki, Y., Kaji, K., Terada, T., Murao, K., Inoue, S., Kawahara, Y., Sumi, Y. and Nishio, N.: HASC Challenge: Gathering Large Scale Human Activity Corpus for the Real-World Activity Understandings, Proceedings of the 2nd Augmented Human International Conference, 27. ACM, 2011.
- 32) 櫻井彰人, 田中泰司：AI活用によるコンクリート床版の余寿命予測技術
https://www.jst.go.jp/sip/event/k07/pdf/k07_event20180719_2-3.pdf
- 33) Matsuoka, D., Nakano, M., Sugiyama, D. and Uchida, S.: Detecting the Precursor of Tropical Cyclone using Deep Neural Networks, Proceedings of the 7th International Workshop on Climate Informatics, pp. 73-76, 2017.
- 34) 井出剛, 杉山将：異常検知と変化検知, 講談社, 2015.

10.4 維持管理分野におけるデータセット整備に関する考察

一般的に、インフラ管理者は、保有するアセット（施設）を管理するために台帳を作成するとともに、施設に対する点検を行った際には点検履歴を、補修や更新を行った際には補修・更新履歴をそれぞれ記録、蓄積している。近年では、アセットマネジメントに対する管理者の意識の向上や記録媒体に関する技術革新・低価格化などに起因して、台帳、点検履歴、補修・更新履歴が電子データなど機械判読可能な形式で保存されている場合も少なくない。これらのデータを用いて、統計モデルやAI技術により、過去の施設のパフォーマンス評価、将来の劣化予測などが可能となり、多くの研究が蓄積されている¹⁾。その際には、管理する施設群の劣化状態の統計量（例えば、健全度や変状度の期待値）の時間的推移をモデル化するようなマクロな視点でのアプローチも考え得るが、一般的には、個々の施設に対してその施設の劣化状態の時間的推移をモデル化するというミクロな視点でのアプローチが一般的であろう。その際には、図10.4.1に模式図として示すように、個々の施設における供用開始時点、点検において劣化・故障が確認できなかったという事象とその点検時点、点検において劣化・故障が確認されたという事象とその点検時点、劣化・故障に対して補修・更新を行った場合のその工法と時点、に関する情報が時系列的に整理され分析において利用可能である必要がある。すなわち、同図において、全ての施設で $\tau_{a,b}$ が観測・記録され分析に利用できる状態である必要がある。その際、補修履歴に関しては、当該補修履歴に掲載されている補修以外は実施されていない、すなわち、実施された補修が全て漏れなく補修履歴に記録されていることを保証できるような体制が必要となる。そうでなければ、実際には補修が実施された施設に対して、補修が実施されていないとすることに起因して、当該施設の寿命を過大評価してしまう可能性がある。当然のことながら、補修の際の工法や費用に関する情報も記録しておくことにより、例えば、予防保全の方が事後保全と比較してどの程度実際の補修費用が低いのか、などアセットマネジメントの改善、高度化に対して有用となる情報が獲得できることは言うまでもないが、この点はここでは詳細には言及しない。

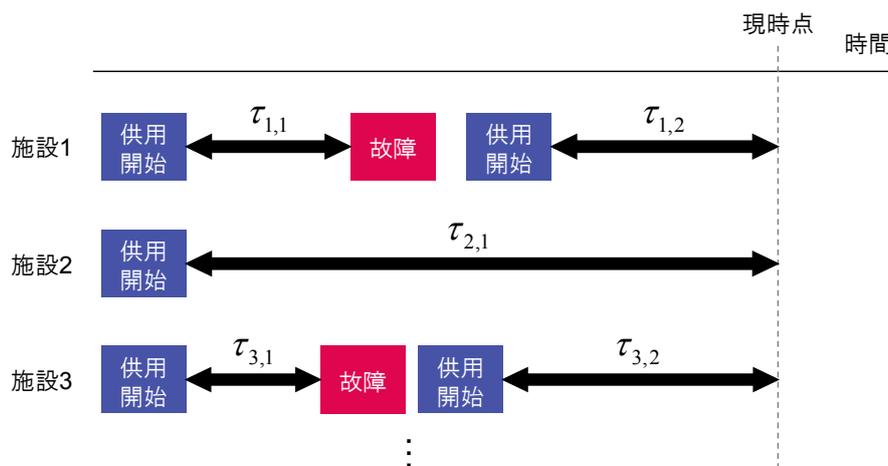


図 10.4.1 施設の劣化・故障の観測イメージ

AI技術は膨大なデータから劣化過程や変状形態に関する有益な情報を獲得するために有用となると考えられるが、それと同時に、AI技術はデータの持つ特性を視覚的に理解しやすい集約化された情報に変換しているに過ぎない点には留意すべきである。すなわち、データに系統的なバイアスが内在しているような場合では、当然のことながらAI技術による分析結果にもバイアスが生じる。このような状況を防止するには、i) 劣化している施設のみならず健全な施設に関するデータも網羅的に観測、蓄積する、ii) 補修や更新によるデータ欠損、構造的に観測が不可能な施設に関するデータの欠損などに対して、データ欠損構造を明示的にモデル化する^{2,3)}ようなシステムをAI技術に内包する、といった対応が必要となる。

インフラの中には、異なる種類の施設により複合的に構成され、そのパフォーマンスが発揮されているものも少なくない。例えば、道路橋は、舗装構造、床版、橋梁部材の複合的な施設であると考え得る。このような複合的なインフラに対するデータを収集する際に問題となるのが、個々の施設の位置をどのように管理、把握するかであろう。道路橋の例では、舗装構造の点検データはキロポストを用いて管理され、床版や橋梁部材は径間ごとに割り当てられたIDを用いて管理されているのが一般的である。しかしながら、例えば、舗装構造の劣化に起因した漏水が床版の劣化過程に与える影響といった異なる施設間の複合的な劣化事象を分析する際には、このような管理IDの相違により、異なる施設間の位置の対応関係を把握するのに極めて煩雑な作業が必要となる場合がある。それに対しては、別途、管理IDの対応関係を整理する、GISなどにより一元的に管理する、といった対策が必要となる。

インフラ管理者が、管理するインフラの劣化要因、劣化過程の分析を行う際には、コンサルタントなどに外部委託を行う場合も少なくない。また、近年では、PPP、PFI、コンセッション方式など、インフラの維持管理自体を民間委託する事例も増加してきている。当然のことながら、上述したようなデータは、インフラ管理者のみが理解可能な形式ではなく、第三者が見ても容易に理解可能なように記録、保存されておくことが望ましい。

このように、バイアスがなく、理解が容易で整理されたデータが利用可能であれば、インフラ維持管理における多様な工程においてAI技術が利用可能となるであろう。例えば、点検データから劣化過程を定量化することにより、重点監視施設の検出が可能となる。また、ライフサイクル費用最小化問題や社会的便益最大化問題を解くことにより、個々の施設に対する維持管理施策が決定できる。重点監視施設に対しては、施設の劣化を早期に検知するための常時モニタリングに近いような劣化検知システムがAI技術によって構築可能である。さらに、施設がある劣化状態を迎えた場合にはAI技術により重点監視を行うということを、維持管理施策として採用できる可能性もある。そのためには、個々のAI技術の高度化はもちろんのこと、それらのAI技術をどのように組み合わせてアセットマネジメントの目標を達成するかという観点に基づき、マネジメントサイクルを効率的に回すようなシステムを整備することも重要となる。

参考文献

- 1) 貝戸清之, 小林潔司: ビッグデータによるインフラマネジメント: アセットメトリクスにむけて, 土木学会論文集 D3 (土木計画学), Vol.70, No.5 (土木計画学研究・論文集第 31 巻), pp. I_21- I_30, 2014.
- 2) 小林潔司, 熊田一彦, 佐藤正和, 岩崎洋一郎, 青木一也: サンプル欠損を考慮した舗装劣化予測モデル, 土木学会論文集 F, Vol.63, No.1. pp.1-15, 2007.
- 3) 水谷大二郎: アセットマネジメントにおけるデータ欠損補完と多元的劣化評価に関する研究, 博士学位論文, 大阪大学, 2016.

11. AI 活用に向けた課題と道筋

11.1 手法とツールについて

本報告書に挙げられたように、深層学習を代表とする近年の AI 技術はインフラ維持管理における様々な応用事例に対する適用が進んでいる。こうした取り組みの成果は実務上での応用が期待されると共に、研究の観点からは AI モデルの深化による一層の性能向上や、解決される課題範囲の拡大などの潮流が想定される。インフラ維持管理における AI モデルの深化には、当該分野における先見的な知見を活用した発展的なモデルや、対象の事例固有の問題に特化したモデルの構築を行うことは、学術・実務の両面から重要であると考えられる。

一方で、深層学習は大規模なデータからその特性を学習・抽出することに長けているが、データ数が少ない場合に対する適用性や、学習・処理結果の説明性については課題とされている。深層学習の枠組みの中でこのような課題を解決する研究も進んでいる他、データの規模や質によっては、ベイズ推論や SVM 等、深層学習以外の機械学習モデルを検討することも不可欠であろう。こうした深層学習を含む種々の AI 技術は現在においても急速な発達が進んでおり、その中にはインフラ維持管理分野において応用が期待できるものも多い。こうした最新の研究動向を踏まえながら、インフラ維持管理に適した AI 手法の深化と応用事例の蓄積を重ねていくことは、今後の AI 活用に向けた重要な活動である。

11.2 データについて

AI 技術が適用される典型的なタスクの多くを含む、教師あり学習に対する AI モデルのための学習データとして、あるいは、様々なモデルの性能を客観的に比較評価するためのベンチマークデータとして、ラベルの付与されたデータセットを整備していくことも、重要性が増すものと考えられる。既に AI 応用の進む他分野と同様に、個人研究者や研究グループの他、学会や公共の研究機関などがデータを収集・整備して公開することにより、インフラ維持管理分野における AI 研究がより活性化すると期待される。

データセットの整備という点においては、大量のラベルを付与することのコストや、劣化状態などの異常に関するデータが正常データに比較して手に入りにくいというデータ不均衡の問題に対する取り組みもまた期待される。そのような取り組みとしては、ラベル付与の作業を単純化するプラットフォームの整備といった研究の他、ラベルの付与されていないデータを活用する半教師学習や多量の正常データを活用する教師なし学習の手法が研究されている。こうした手法の応用を想定すると、ラベルの付与されていないデータセットや、正常な例ばかりが収集されたデータセットであっても、今後は大きな価値を有するデータとして活用される可能性があり、そのようなデータセットの整備は有意義なものと考えられる。

11.3 異分野融合コラボレーションの場

9.4.1 で述べたとおり、AI・データサイエンスの実践に必要とされるスキル「コンピュータやデータを扱うスキル」、「数学や統計学の知識」、「実質的な専門知識」を持ち合わせる人材の育成と、その活躍には大きな期待がある。しかしながら、インフラ維持管理分野において、現場経験や工学知見に基づいた専門的な考察を行うためには、必要となる知識の幅も広く、修得まで長期間を要する場合が多い。また、データの取得やこれを活用する業務も、複数の人や機関がグループを構成し取り組む場合が多い。従って、当分野におけるAI・データサイエンスの活用においては、全てのスキルを兼ね備える一人の人物で取り組むのではなく、様々な分野の専門家がスキルを提供し、データや語彙を共有し、専門的なチームを構成することにより実践することが有効であると考えられる。

このようなチームによるデータサイエンスは、立場の異なる者同士の共同研究という形態での実施も可能であろう。また、こうした共同研究につながるための議論の場として、学会や専門的研究発表の場も活用され得る。異分野の専門家が交流し、議論を行い、異なる分野の語彙や先端的研究についての理解を相互に深め、融合領域における共同研究の開始が支援されることが期待される。

また、共同研究形式以外にも、データをオープンにし、様々な専門家がデータ活用に挑戦するコンペティション形式による取組も有効であると考えられる。ただし、Kaggle等の機械学習のコンペティションのように、性能による定量的評価だけでは、インフラ維持管理分野の実用を視野に入れた要求に応えられない事も考えられる。従って、性能を競う「性能部門」だけでなく、結果の解釈を競う「解釈部門」を設定するなど、コンペティションの実施結果を実用に繋げられる構成とすることも考慮すべきであろう。

データを提供する者とデータ解析に参加する者、さらには結果を解釈する者といった三者が参加するインセンティブを与えられるよう、ここで生まれた成果や参加した実績が表彰や認定を受けるなど、制度設計と連動した仕組みが必要となるだろう。

11.4 制度設計

また、AIを産官学の土木業界全体で活用していくには、技術者や研究者が適切にデータサイエンスを取り扱うための制度を整備していくことも必要である。

産官で実務に携わる技術者には、9.4.5で示した学び直しの機会を設ける上で、データサイエンススキルを持つことによるインセンティブを与える制度が有効である。例えば、国家資格である「技術士」において土木技術者は「建設部門」を取得するケースが多いが、「情報工学部門」の取得を推奨し、キャリアアップがはかれるような体制とすることが方策の1つとして考えられる。また、「土木学会認定土木技術者資格制度」の中で、「データ科学」や「情報工学」といった資格分野を設けることも考えられる。また土木分野では国土交通省登録資格の制度があり、維持

管理分野と計画・調査・設計分野で250にものぼる民間資格が登録されている。このような登録制度の中にデータサイエンスに関する資格が入ることも土木技術者がデータサイエンススキルを持つことへのインセンティブ付与として有効であり、さらにデータサイエンス分野の技術者が土木分野に関わるきっかけになることも考えられる。

また、このような取り組みは「学」とも連動することが有効である。土木工学を教育する高等教育機関(大学・高専)において、データサイエンス、リテラシー教育を取り入れていくことの必要性については9.4.4に述べたが、これを促進する制度として、例えばJABEE認定制度の分野別個別要件の中にデータサイエンスに関するキーワード(「確率・統計」など)を加えることもあり得る。

その上で、データサイエンスのスキル向上が広まれば、過度にAI・機械学習が適用されてしまう危険性もある。社会インフラのあり方の中で、またデータの整備状況によっては、AIの適用が適していない場合、時期尚早である場合もある。AI活用が期待される維持管理・設計・施工といった事項毎に、AI適用指針や要領を整備していくことも必要である。また、多種多様なビッグデータを扱う上での、個人個別情報保護に関する技術者倫理は必要であり、これはデータベース整備の取り組み段階など初期段階から、データ使用に関する指針などが必要となるであろう。

参考文献

- 1) 国交省：公共工事に関する調査及び設計等の品質確保に資する技術者資格について
http://www.mlit.go.jp/tec/tec_tk_000098.html (入手2018.11.1)

11.5 人とAIの役割分担と協働

11.5.1 AIが得意な処理

近年のAIの技術発展を受け、インフラ維持管理の様々な分野での研究や社会実装の試行が急速に進んでいる。AIの発展には、人の業務に取って代わり得る技術の登場にも大きな期待が集まっている。しかしそれは、現代ではまだ限定的であり、人の能力を全てAIで代替することは現実的ではない。遠い将来を見据え、少なくとも、シンギュラリティと呼ばれる転換点が到来するまでの間は、AIが得意とする分野や処理等を明確に把握し、「人とAIとの協働」によるデータ活用が必要になると考えられる。これが、AIをインフラ維持管理等の実業務で活用するための大きな条件となるだろう。

AIが得意とする作業内容は、例えば、「定量的でバラツキの無い評価」、「ミスの無い単純作業」、「網羅的な処理」などが挙げられる。

現在の維持管理業務では、定量的かつ十分なデータ量に裏付けされた意思決定は、必ずしも行われていない現場も多い。技術者固有の経験等、いわゆる暗黙知による現場の判断に依存する部分も存在する。それに対し、AIやデータサイエンス等による処理では、直感や主観によるこ

となく、「定量的でバラツキの無い評価」が可能になると期待できる。

また、人手による作業では、疲労やヒューマンエラーが生じる可能性を排除できないが、AI や機械では、規定した処理を緻密に実行可能であり、疲労や集中力の低下などは考慮する必要が無く、「ミスの無い単純な作業の長時間の実施」が可能である。

AI 活用時代の到来にあわせて、維持管理業務において検査や診断の記録や計測データ、写真等の大規模なデータの記録が進められているが、このような大規模なデータを対象に、人の目で網羅的な把握を徹底することは、作業の限界を向かえることは明らかである。AI やデータサイエンスを活用することにより、定量的な処理をビッグデータに対して「網羅的な処理」を適用し、データ可視化を組み合わせることにより、大規模データを対象とした異常検知や知識発掘が期待できる。このような知識発掘においては、データに基づく相関関係の抽出だけでなく、近年では、因果関係を把握するといった研究も行われている¹⁾。また、インフラ維持管理分野のデータを対象とするデータサイエンス活用の支援システムの研究開発²⁾も進められている。

11.5.2 人が得意な業務

一方で、人が得意なこととしては、例えば「暗黙知の活用」、「意思決定」、「人材評価」などが挙げられる。

データ化されている情報を分析し、ルールを抽出することはAIによる処理は得意と言えるが、そもそもデータ化されていない事象については扱うことができない。実際に、人による判断等では、データ化されていない「暗黙知」が活用されることも多い。例えば、構造物の施工時の具体的な情報については、設計情報と異なる情報もあり、それが構造物毎の個性に繋がっている場合もある。また、現場で体験した音や振動など、通常はデータ化していない情報から異常などに気づくという事もある。さらに、他分野の経験や知識と知識をつなぎあわせることで異常に気づくという直感的な能力も発揮することがある。

未観測の事象については、AIは予測することができないが、人には、未観測事象についても、他の知識をつなぎ合わせることにより想像力を発揮し、外挿にあたる予測や推測を行える場合もある。このような能力は、現代のAIによる代替は難しいと言えよう。

暗黙知の活用に共通することでもあるが、事業のゴールを見据えた「意思決定」についても、人でなければ行えない処理であると考えられる。事業目標にあわせた手法選定や、分析結果の性能などの到達目標の設定、結果の業務での活用方法の設計などについては、「人のための社会をどのように設計したいか」ということや、あるいは、「業務貢献の面で人が満足するかどうか」といった判断が関わるところが大きく、AIには把握できない価値基準を含む場合も多い。

また、人の働きを評価することや、人間関係を評価すること、また、人の好みや相性に係ることについては、一部で研究が行われているものの^{3)、4)}、完全な機械化が難しい業務であろう。

11.5.3 人とAIの協働による効果

これらの人とAIが得意とする作業・処理をふまえ、人とAIとが協働することにより、インフラ維持管理において次のような効果が得られると考えられる。

(1) 知見の形式化, 新たな知見の抽出と蓄積

AIにより抽出可能なデータ上の傾向と、技術者知見との対比によって、新たな知見の抽出や既存の知見の形式化が進む。これにより、分析結果の知見等が形式化され、異なる複数の維持管理者間で共有されることにより、これまで見ていなかった状態把握や、潜在リスクの検出に繋げることが期待できる。

(2) 効率化 (時間, コスト)

維持管理業務における効率向上について、時間やコストの側面での貢献が期待できる。

(3) 人の業務の質向上

前述のとおり、人は、少量の情報から想像力を働かせ、背後の事象に対する仮説的な考察を行うことや、意思決定などの業務が得意である。データの調査・集約・分析・評価などの単調な作業については、AI等にまかせることで、維持管理者は、高度な意思決定に時間を使え、業務の質を向上できることが、AI活用の大きな効果となるだろう。

このような、人とAIの協働を通じて、これに参加する人同士も、より多様な分野の専門家同士のコミュニケーションが生まれ、これまでに無い課題や仮説の設定と、それらの研究に基づく一層深い考察や議論を行うことで、新たな価値が創出されることが期待される。

参考文献

- 1) 清水 昌平：統計的因果探索，講談社，2017.
- 2) Wakuda, Y., Isobe, M. and Ishikawa, Y.: Data Science Support System for Infrastructure Maintenance on Cloud, 17th International Conference on Computing in Civil and Building EngineeringICCCBE 2018, 2018.
- 3) Akhavian, R. and Behzadan, A. H.: Smartphone-based construction workers' activity recognition and classification, Automation in Construction, Vol. 71, pp. 198-209, 2016.
- 4) Gong, J., Caldas, C. H. and Gordon, C.: Learning and classifying actions of construction workers and equipment using Bag-of-Video-Feature-Words and Bayesian network models, Advanced Engineering Informatics, Vol. 25, No. 4, pp. 771-782, 2011.

12. 執筆者・関係者一覧 (* : AI の SIP インフラ維持管理への活用検討プロジェクトチーム)

章. 節	氏名	所属	役職
	(SIP 研究テーマ、研究責任者、その他)		
1 章	矢吹信喜*	大阪大学 大学院工学研究科 環境・エネルギー工学専攻	教授
	阿部雅人*	JST イノベーション拠点推進部	フェロー
2 章 1 節	岡谷貴之	東北大学 理化学研究所	教授
	橋梁の打音検査ならびに近接目視を代替する飛行ロボットシステムの研究開発 (東北大学 大野和則)		
2 章 2 節	櫻井彰人*	横浜国立大学 先端科学高等研究院	特任教授
	道路インフラマネジメントサイクルの展開と国内外への実装を目指した統括的研究 (東京大学 石田哲也)		
2 章 3 節	田中正義	JIP テクノサイエンス株式会社 インフラソリューション事業部 大阪技術営業部 技術課	
	星野隼人	JIP テクノサイエンス株式会社 システム技術研究所	
	インフラ予防保全のための大規模センサ情報統合に基づく路面・橋梁スクリーニング技術の研究開発と社会実装 (JIP テクノサイエンス (株) 家入正隆)		
2 章 4 節	田辺圭一	超電導センシング技術研究組合 (SUSTERA)	理事長
	インフラ劣化評価と保全計画のための高感度磁気非破壊検査 (岡山大学 塚田啓二)		
3 章 1 節	村川正宏	産業技術総合研究所 情報・人間工学領域 人工知能研究戦略部	総括企画主幹
	学習型打音解析技術の研究開発 (産業技術総合研究所 村川正宏)		
3 章 2 節	島田義則	レーザー技術総合研究所	主任研究員
	錦野将元	量子科学技術研究開発機構	上席研究員
	北村俊幸	量子ビーム科学研究部門 関西光科学研究所	技術員
	レーザーを活用した高性能・非破壊劣化インフラ診断技術の研究開発 (理化学研究所 緑川克美)		
3 章 3 節	小池義昌	NTTアドバンステクノロジー (株)	主幹技師
	瀬下貴加子	クラウドIoT事業本部	主査
	目黒眞一		主席技師
	インフラセンシングデータの統合的データマネジメント基盤の研究開発 (日本電信電話 (株) 吉野修一)		

3章4節	中村 光	名古屋大学 大学院工学研究科 土木工学専攻	教授
	近接目視・打音検査等を用いた飛行ロボットによる点検システムの研究開発 (新日本非破壊検査(株) 和田秀樹)		
4章	土橋 浩	首都高速道路(株)	執行役員
	学習型打音解析技術の研究開発 (産業技術総合研究所 村川正宏) 高感度近赤外分光を用いたインフラの遠隔診断技術の研究開発 (首都高技術株式会社 津野和宏)		
5章1節	野村泰稔*	立命館大学 理工学部 都市システム工学科	講師
5章2節	矢吹信喜*	大阪大学 大学院工学研究科 環境・エネルギー工学専攻	教授
	電源開発(株)よりデータ提供		
5章3節	全邦釘*	愛媛大学 大学院理工学研究科	准教授
	SUSTERAよりデータ提供(2章4節)		
6章1節	広兼道幸*	関西大学 総合情報学部	教授
6章2節	宮森保紀*	北見工業大学 工学部 社会環境工学科	准教授
	量子科学技術研究開発機構よりデータ提供(3章2節)		
6章3節	広兼道幸*	関西大学 総合情報学部	教授
7章	湧田雄基*	北海道大学 数理・データサイエンス教育研究センター	特任准教授
8章	湧田雄基*	北海道大学 数理・データサイエンス教育研究センター	特任准教授
9章	矢吹信喜*	大阪大学 大学院工学研究科 環境・エネルギー工学専攻	教授
	西尾真由子*	横浜国立大学 都市イノベーション研究院	准教授
	湧田雄基*	北海道大学 数理・データサイエンス教育研究センター	特任准教授
	福士直子*	大阪大学 工学研究科 環境・エネルギー工学科 博士後期課程 国際航業(株)技術サービス本部	

10 章	宮本崇*	山梨大学 大学院医学工学総合研究部 工学部 土木環境工学科	助教
	長谷山美紀	北海道大学 大学院情報科学研究科/ 数理・データサイエンス教育研究センター	教授/ センター長
	湧田雄基*	北海道大学 数理・データサイエンス教育研究センター	特任准教授
	水谷大二郎*	東北大学 災害科学国際研究所	助教
11 章	矢吹信喜*	大阪大学 大学院工学研究科 環境・エネルギー工学専攻	教授
	湧田雄基*	北海道大学 数理・データサイエンス教育研究センター	特任准教授
	西尾真由子*	横浜国立大学 都市イノベーション研究院	准教授
	宮本崇*	山梨大学 大学院医学工学総合研究部 工学部 土木環境工学科	助教
	水谷大二郎*	東北大学 災害科学国際研究所	助教
	福士直子*	大阪大学 工学研究科 環境・エネルギー工学科 博士後期課程 国際航業(株) 技術サービス本部	
査読 その他	石田哲也*	東京大学 工学系研究科 社会基盤学専攻	教授
	小泉圭吾*	大阪大学 大学院工学研究科 地球総合工学専攻	助教
	北根安雄*	名古屋大学 大学院工学研究科 土木工学専攻	准教授
	田中泰司*	金沢工業大学 工学部 環境土木工学科	准教授
	西本吉伸*	開発電子技術(株)	執行役員
	尾留川剛*	電源開発(株) 茅ヶ崎研究所 土木技術研究室	リーダー
	金氏眞*	JST イノベーション拠点推進部	フェロー
	信田佳延*	JST イノベーション拠点推進部	技術主幹
	三浦悟*	JST イノベーション拠点推進部	フェロー
	和田祐二*	JST イノベーション拠点推進部	フェロー
	松村隆爾*	JST イノベーション拠点推進部	技術主幹

SIP インフラ連携委員会報告

インフラ維持管理への AI 技術適用のための調査研究報告書

平成 31 年 3 月 20 日 第 1 版発行

●編集・制作……………内閣府 戦略的イノベーション創造プログラム(SIP)
「インフラ維持管理・更新・マネジメント技術」

●発行……………公益社団法人土木学会

技術推進機構

SIP インフラ連携委員会

〒160-0004 東京都新宿区四谷 1 丁目 (外濠公園内)

TEL:03-3355-3502 FAX:03-5379-2769

・本報告書の内容を複写または転載する場合には、必ず土木学会の許可を得てください。

・問い合わせ先：土木学会 技術推進機構

ISBN978-4-8106-1009-3

本研究は、内閣府総合科学技術・イノベーション会議の戦略的イノベーション創造プログラム(SIP)「インフラ維持管理・更新・マネジメント技術」によって実施されました。

ISBN978-4-8106-1009-3

