

AIを用いた河川管理実務の 効率化・高度化に関する一考察

A STUDY ON EFFICIENCY AND SOPHISTICATION OF RIVER MANAGEMENT USING AI (ARTIFICIAL INTELLIGENCE)

小澤淳真¹・筒井胤雄²・山崎崇徳³・本田禎人⁴

Atsumasa OZAWA, Taneo TSUTSUI, Takanori YAMAZAKI and Yoshihito HONDA

¹株式会社パスコ 中央事業部 技術センター 流域水管理部 河川技術課 (〒153-0042 東京都目黒区東山1-1-2)

²株式会社パスコ 中央事業部 技術センター 流域水管理部 (〒153-0042 東京都目黒区東山1-1-2)

³正会員 株式会社パスコ 中央事業部 (現 株式会社建設技術研究所)

⁴正会員 株式会社パスコ 中央事業部 技術センター 流域水管理部 河川技術課 (〒153-0042 東京都目黒区東山1-1-2)

With the rapid development of laser measurement technology, it has been expected to take advantage of the technology to the rivers of the inspection work. By the advent of the UAV, it became possible for river managers themselves to capture images. It is expected that a large amount of image data will be accumulated in the future, and necessary to consider how to use these image data. In this study, we verified the applicability of AI to image data analysis, and considered the efficiency and sophistication of river management using AI.

Key Words : AI, UAV, image data analysis, efficiency and sophistication of river management

1. はじめに

近年の計測技術の発展に伴い、河川管理分野においても様々な新技術の活用検討が行われている。特に自動車やUAV等の移動体にセンサーを取り付け、短時間に大量の情報を取得する方法については、多くの試行実験が実施されている。

今後、このような計測が主流になり、大量なデータが蓄積されると予想される。しかし、これらの計測データから変状検出等を行うにあたっては、現状、人がデータを確認している場合が多く、判読時間や、検出度等で問題があり、効率化・高度化が急務である。

この問題に対し、本研究では、UAV、および後述する可搬型MMSで撮影された画像データを例に、AIを使った画像判読による変状検出の有効性について検証を行った。AIは、近年に注目されているDeep Learningのほか、これまで、リモートセンシングの分野において広く用いられてきた最尤法分類についても検証を行った。

最尤法分類については、比較的解像度の粗い衛星画像の判読に用いられている手法であるが、解像度の高い画像に関しての検証例は少ない¹⁾。近年は、UAVに代表されるように、だれでも簡単に高解像度な写真データを撮影できる環境になっていることを考慮し、今回は高解

像度画像に対しての最尤法分類の適用性を確認した。

さらに、これら検証により得られた結果から、河川管理実務の中で有効な活用方法について考察を行った。

2. AIを用いた画像判読

(1) 概要

AIを用いた画像判読の検証概要を表-1に示す。

表-1 AIを用いた画像判読の検証概要

検証したAI技術	最尤法	Deep Learning
a) 検証用データ	・ UAVで堤防部分を撮影した画像および動画 (撮影高度: 50m, 40m, 30m, 20m, 15m)	・ 可搬型MMSを船に搭載し、河道内から護岸を撮影した画像
b) 検証項目	・ 堤防植生の判読 ・ 特定の植物 (アカメガシワ) の判読	・ コンクリート護岸のひび割れ抽出
c) 検証内容	・ 解像度が異なる画像での判読精度, 検出特性 ・ 学習用データの汎用性 ・ アカメガシワの特定可否	・ 抽出精度, 抽出特性

a) 検証用データ

検証用データには、UAV撮影画像、および可搬型MMS撮影画像を用いた。

UAVについてはDJI製のPhantom4を使用した。解像度による違いを検証するために、5種類（50m、40m、30m、20m、15m）の異なる高度で撮影した画像、および動画（高度約15mで撮影）を検証用データとした。



図-1 Phantom4での撮影の様子

Phantom4に搭載されているカメラの画素数は2,000万画素であり、高高度からも比較的解像度の高い画像を取得できる。今回の検証に使用した画像の撮影概要を表-2に示す。

表-2 UAV撮影の概要

撮影日時	2018年9月28日
撮影場所	堤防天端付近の上空から地表を撮影（垂直撮影）
撮影高度 （地上解像度）	約50m (1.2cm/pix)
	約40m (0.9cm/pix)
	約30m (0.7cm/pix)
	約20m (0.5cm/pix)
	約15m (0.4cm/pix)

可搬型MMSは、これまで主に車に固定していたセンサーを取り外し可能な可搬型に改良した機器である。今回の検証では、Leica Geosystems社製のLeica Pegasus:Twoを使用した。



図-2 Leica Pegasus:Twoの外観

Leica Pegasus:Twoは、レーザ計測と写真撮影が可能である。カメラは、図-2右下の矢印に示す通り、周囲6箇所および上方に1箇所設置されており、広範囲の画像を取得することが可能である。

Leica Pegasus:Twoに搭載されているカメラ画素数は、400万画素である。カメラ位置から護岸までの距離が10m～20mと仮定すると、解像度は0.7cm/pix～1.4cm/pixとなる。今回の検証に使用した画像の撮影概要を表-3に示す。

表-3 可搬型MMS撮影の概要

撮影日時	2018年2月23日
撮影場所	河道内から護岸を撮影
撮影距離 （地上解像度）	カメラから護岸までは約10m～20m（解像度：0.7cm/pix～1.4cm/pix）

b) 検証項目

AIによる検証項目は、UAV撮影画像に対しては、堤防植生の判読、特定の植物に着目した判読、可搬型MMS撮影画像に対しては、コンクリート護岸に発生したひび割れ検出とした。

堤防植生の判読については、これまで点検や巡視による状態把握、あるいは航空写真画像を使った判読により実施してきた。しかし、これらの問題点として、点検・巡視では、広く面的な状態把握を行うことが困難であること、また、航空写真を使った判読については、主にコスト面から撮影頻度が限られること、さらに判読作業にも時間とコストを要することなどが挙げられる。この問題に対して、UAVによる撮影を行い、撮影した画像データに対してAI技術を用いた植生判読を基本とする状態把握を行うことで、解決につながる可能性があると考え、本研究での検証候補とした。

また、コンクリート護岸等に発生するひび割れは、護岸全体の一部の範囲に線状に発生していることが多いため、目視点検では見逃す可能性がある。この問題に対しても、可搬型MMSにより連続撮影された画像をもとに、AI技術を使ったひび割れ抽出が可能となれば、効率化、高度化された点検につながると考え、本研究での検証対象とした。

c) 検証内容

最尤法により画像判読を行う場合は、画像解像度が重要な要素となる。さらに、画像判読による実務の効率化を考えると、最尤法、Deep Learningとも、学習用データには汎用性があり、多くの画像に適用できることが望ましい、これらを踏まえ、本研究では、以下の内容について検証を行った。

検証1：解像度の違いによる分類特性の把握

UAVにおいて、異なる撮影高度で撮影した解像度の異なる複数の画像に対し、最尤法を適用し、堤防の植生判読に適切な解像度の検討を行った。

検証2：学習用データの汎用性の把握

同じ高度で連続撮影した複数の画像のうち、1枚の画像から最尤法に用いる学習用データを作成し、そのデータが他の画像にどの程度適用性があるかを検証した。

検証3：特性植物の抽出

最尤法を用いた画像判読は、撮影データに写っている全体を対象にすることが多い。堤防の植生管理において

は、撮影範囲全体に着目する場合もあるが、数種類の植物に注目する場合も多い（例えば、堤防に適している芝や茅の分布状態）。本研究では、堤防護岸に悪影響を及ぼすアカメガシワに着目し、UAVで撮影された画像からアカメガシワの抽出の可能性について検証した。

検証4：ひび割れ抽出

面的な分布に対しては最尤法は適しているが、ひび割れ等の線状、あるいは点状に分布している変状に対しては、最尤法の適用は難しい。そこで、本研究では、ひび割れの把握にDeep Learningを用い、その有効性について検証を行った。

(2) AI技術の適用性検証

以下では、前項で述べた検証1～検証4の具体的な方法を述べる。

検証1：解像度の違いによる分類特性の把握

検証に用いた画像（解像度1.2cm, 0.9cm, 0.7cm, 0.5cm）のうち、一例として、最も解像度の高い画像（解像度0.5cm）を図-3に示す。撮影した場所は堤防の表水面である。撮影した時期は9月下旬であったが、人が入るのが困難なほど植物が繁茂していた。撮影画像の範囲1Aは、茎が長く、葉が細い植物（植生1A）が優勢であり、範囲1Bは葉が丸いツル系の植物（植生1B）が優勢である。範囲1Cは、一部に葉が落ち、枝や茎だけ（植生1C）になっており、また、範囲1Dは、完全に葉が茶色（植生1D）になっている。今回は、上記、範囲1A～範囲1Dを適切に判読できる解像度について検証を行う。

範囲1A～範囲1Dの学習用データは、TR-1A～TR-1Dの範囲とし、各4種類の解像度の画像で設定した。なお、今回の最尤法は、RGB画像のみに適用する。衛星データを使う場合は、RGB画像以外に、近赤外データ等の波長帯を使うが、本研究では、画像の撮影から解析まで特別な専門知識がなくても実施できることを目的としており、一般的なカラー画像データを適用することとした。学習用データを決定するにあたっては、範囲1A～1Dの特徴を良くとらえている場所に設定した。具体的には、学習用データの範囲が、判読対象とする植物のみで覆われていること、日影の影響が少ない箇所とした。




図-3 検証対象画像の概要（検証1）

検証2：学習用データの汎用性の把握

検証に用いた画像を図-4に示す。以下の3枚の画像は高度15m（解像度0.4cm）で連続的に撮影した3枚の写真である。撮影範囲の植生は検証1の時と同様で、下図の範囲2Aは、茎が長く葉が細い植物（植生2A）が優勢であり、範囲2Bは葉が丸いツル系の植物（植生2B）が優勢である。範囲2Cは葉が落ち、枝や茎だけ（植生2C）になった箇所、範囲2Dは完全に葉が茶色（植生2D）になっている。

本検証では、検証1で対象とした範囲と植生構成が類似しており、写真解像度もほぼ同じことから、検証1でを使用した撮影高度20m（解像度0.5cm）の画像で作成した学習用データを適用し、汎用性の確認を行った。




図-4 検証対象画像の概要（検証2）

検証3：特性植物の抽出

検証に用いた画像（高度約15mで動画撮影）を図-5に示す。図中に実線で示した箇所がアカメガシワである。点線で示した箇所は、学習用データとして採用した部分で、アカメガシワ（TR-ア）、水部（TR-水）、護岸（TR-護）、アカメガシワ以外の樹木（TR-樹）、草地（TR-草）の5箇所を設定した。




図-5 検証対象画像の概要（検証3）

検証4：ひび割れ抽出

Deep Learningで用いるひび割れ抽出の学習用データは、可搬型MMSで撮影された画像（図-6）から、ひび割れが含まれる正例を595箇所、ひび割れの無い負例を569箇所選んだ（図-7）。学習用画像の大きさは64×64画素とし、正例画像は、学習用画像全体にひび割れが確認でき

る画像とした。これは、画像の一部にひび割れがあるデータを使った場合、過剰抽出する可能性があるためである。また、学習用データは特定の画像からではなく、多くの画像から作成することで、汎用性のある学習用データ群とした。




図-6 可搬型MMSで撮影された画像の一例
(左：右前方カメラ写真、右：右後方カメラ写真)



図-7 学習用データの一例 (左2枚：正例、右2枚：負例)

(3) 検証結果と考察

前項の検証結果、及び考察を以下に示す。

検証1：解像度の違いによる分類特性の把握

解像度の異なる画像に最尤法を適用した分類結果を図-8に示す。いずれの解像度画像でも、範囲1Aと範囲1Bの植生の違いが分類できており、さらに植物の葉がない範囲1C、葉が枯れている範囲1Dについても概ね分類できていることが確認できる。





図-8 最尤法による分類結果 (異なる解像度画像)

また、各解像度別の分類結果において、範囲1A（画像右側）に注目すると、解像度が低くなるにつれて、分類結果の解像度も低くなる傾向にあることが分かるが、解像度0.5cmと解像度1.2cmの分類結果を比較すると、解像度1.2cmでも植生分布の傾向を十分に捉えていることが確認できる。

検証2：学習用データの汎用性の把握

検証1で用いた解像度0.5cm（撮影高度20m）で作成した学習用データを、図-4の全3画像に適用した結果が図-9である。なお、学習用データ作成に用いた画像データには水部が映っていないため、水部の学習用データが存在しない。このため、撮影画像に水部のある2画像については、水部の無い範囲を切り出し、最尤法分類を行っている。

図-9に示す真ん中及び一番右側の分類結果によれば、図-4で設定した範囲2A、範囲2B、範囲2Cを識別できており、概ね分類が妥当であることが確認できる。

また、図-9の一番左側の画像をみると、範囲2A、範囲2Bのほか、範囲2Dも適切に識別できており、妥当な分類がされていることが分かる。

一方、範囲2Aと範囲2Bの分類結果と、検証1で行った範囲1Aと範囲1Bの分類結果（解像度：0.5cm）を比較すると、検証2の結果において、2つの範囲の違いが不明瞭になっている。このことは、最尤法分類において誤分類されている割合が増加していることを意味する。




図-9 最尤法による分類結果（学習用データの汎用性）

この原因として、学習用データで作成した画像と分類を行った画像との解像度の違いが考えられる。本検証では学習用データの解像度は0.5cmであるが、分類を行った画像の解像度はそれよりも細かい0.4cmである。この違いで、分類結果に若干の差が生じたと考えられる。

検証3：特性植物の抽出

最尤法を用いてアカメガシワ箇所を抽出した結果を図-10に示す。実線で囲まれた部分がアカメガシワが存在する箇所であるが、概ねアカメガシワの抽出に成功していることが分かる。

一方、実線で囲まれた箇所以外は、アカメガシワでない植物を抽出している可能性が高い。図-11は図-10の点線で囲まれた撮影画像を拡大した図である。図-11の点線で囲まれた範囲が誤抽出された部分であるが、目視で確認すると、周囲と大きな違いは見受けられず、アカメガシワである可能性は低い（アカメガシワの画像は図-5を参照）。この誤抽出の原因として、RGB情報のみの画像に最尤法を適用した植生判読では、使用する波長帯が少ないため、対象物の写真の写り方や、撮影時の日影の状態が抽出精度に大きく影響を及ぼす可能性があると考えられる。




図-10 最尤法による分類結果（アカメガシワの抽出）



図-11 最尤法による分類結果（図-10の点線分拡大）

検証4：ひび割れ抽出

Deep Learningを用いて護岸のひび割れ箇所を抽出した結果の一例を図-12に示す。実線枠で囲まれた範囲がDeep Learningでひび割れありと判定された箇所である。図-12上の点線で囲まれたCR-1の部分は、目視点検でひび割れが確認された箇所であるが、抽出漏れすることなく検出されている。

CR-1以外については、目視点検ではひび割れ無しと判断されたにも関わらず、ひび割れ有と判断された箇所である。誤抽出された箇所は、色が急激に変化している箇所であり、これが原因の1つと考えられる。

図-12下は、可搬型MMSにより連続して撮影された3枚の画像に対してDeep Learningでひび割れ抽出を行った結果である。ひび割れCR-2は3枚の画像に共通して写っているが、その部分の解像度は画像①が最も低く、画像③が最も高い。判定結果では、画像①、②では対象部分が検知率が低い、画像③では対象部をほぼ検知している。この原因としては、ひび割れ部の解像度が低いこと、使用した学習用データに解像度の粗いデータが少ないことが考えられる。カメラの性能や撮影環境の問題から、高解像度な写真データの取得が困難な場合は、低解像度でも検知可能な学習用データ群を構築する必要がある。




図-12 Deep Learningによるひび割れ抽出結果

3. 河川管理実務での活用方法

以上の結果から、河川管理実務への活用方法について考察を行った。

検証1では、UAVで撮影した画像において、解像度の違いに着目し、最尤法を用いた堤防植生判読の特性について検証を行った。その結果、今回撮影した範囲では、4種類の解像度の異なる撮影画像全てにおいて、概ね正確に判読されることが確認できた。また、判読される画像の解像度は、撮影された画像の解像度に影響されることも確認できた。また、今回の検証では、解像度1.2cm（Phantom4であれば撮影高度を50m程度）でも堤防植生の状態把握を行う上では、十分な解像度を満たしていると考えられる。

UAVの撮影においては、高い高度で撮影できれば、1枚の撮影画像でより広い範囲をカバーできるため、撮影枚数の低減、解析時間の短縮につながる。このため、運用時には、解像度とともに、1枚の画像の撮影範囲を確認し、効率的な撮影計画を立案することが望ましい。

検証2では、最尤法による植生判読を行う場合の、学習用データの汎用性に着目した検証を行った。

本検証では、同じ種類の植生が繁茂している範囲で撮影した3枚の画像について、別画像で作成した学習用データを適用し、植生判読を行った。その結果、概ね妥当な判読ができていたことが確認できた。ただし、学習用データと適用対象とする画像データの解像度の違いが、判読精度に影響を及ぼす可能性があることも示唆された。

これらの結果から、ある画像で作成した学習用データを他の画像に適用する場合の条件として、画像の解像度を同じにすることが必要であると考えられる。また、今回は検証を行っていないが、分布する植物の種類に大きな違いが生じないこと、日射の状況等により画像の明度、彩度に極端な変化が生じないことも必要であると考えられる。

このため、河川管理の実務へ適用するにあたっては、学習用データと解析用データは同じ解像度とすること、日射等により画質に変化が生じた場合は、その画質に応じて学習用データを設定することで、より精度の高い判読結果が得られると考えられる。

検証3では、特定の植物判読に対して、最尤法がどの程度適用性があるかを検証した。今回は、堤防護岸に悪影響を与える植物の1つであるアカメガシワに注目し、検証を行った。その結果、アカメガシワが存在している箇所を概ね判読できることが確認できた。

ただし、一部にアカメガシワでない植物を誤抽出するケースも見受けられた。最尤法を用いた画像判読では、誤抽出を完全に無くすことは難しく、河川管理の実務においては、このように誤抽出された情報をどのように活用していくかが課題となる。

今回の場合を例に、河川管理への活用方法を考えると、本研究でアカメガシワに着目した目的は、護岸への損傷について状態把握を行うことが目的となる。このため、最尤法により抽出された箇所のうち、護岸周辺の抽出箇所のみに着目するという利用方法が考えられる。

検証4では、コンクリート護岸のひび割れ箇所の検出について、Deep Learningの適用性を確認した。その結果、目視確認でひび割れありと判定された箇所は、ほぼDeep Learningにより検出されていることが確認できた。ただし、誤抽出も多く、特に、コンクリート護岸表面で極端に色が異なる部分を、ひび割れとして誤認識する傾向にあることが分かった。

今回の結果から、河川管理の実務に対しては、現地点検前のスクリーニングとしての活用方法が考えられる。すなわち、現地点検前に、船舶等で点検対象の護岸を連続的に写真撮影を行い、撮影された画像データに対してDeep Learningを用いたひび割れ検出を行う。検出された結果から、ひび割れに関して点検が必要な箇所をピックアップし、現地点検を実施する。このようにすることで、点検の効率化、点検漏れの低減につなげることが可能となる。

4. まとめ

本研究では、今後の河川管理で多くの活用が期待される高解像度画像データに対し、AI技術を適用することにより、河川管理実務の効率化・高度化の実現可能性について検証を行った。その結果、AIの適用により効率化・高度化の余地は十分にあることが確認できた。今後は、現行のAI技術を、河川管理に特化した内容へ進化させるとともに、巡視・点検をはじめとする実務の中で、AI技術を活用するための具体的な仕組みを構築することが必要であると考えられる。

謝辞：本研究を実施するにあたり、国土交通省中部地方整備局木曽川下流河川事務所の皆様には、「H30長良川下流部河川管理施設等監理検討業務」の中で、堤防植生に関する各種資料の提供や試行現場の許可等、多大なご協力を頂きました。ここに記して謝意を表します。

参考文献

- 1) 三富 創, 松岡昌志, 山崎文雄: 最尤法を用いた空撮画像からの建物被害抽出とその早期被害把握への応用, 土木学会論文集 No.717/1-61, pp.137-148, 2002.

(2019. 4. 2受付)