

# 舗装路面評価のためのAIによる 路面ひび割れ抽出精度向上に関する研究

江本 久雄<sup>1</sup>

<sup>1</sup>鳥取大学工学部 社会システム土木系学科

近年、路面性状評価の研究としては、スマートフォンやドライブレコーダ、モーションセンサーによる振動を利用した方法などがある。著者の研究グループでは、車輛の垂直加速度を利用した評価に取り組んでいる。振動のみの評価では、路面性状の基準として平坦性をよく表すものの、その他のひび割れ率やわだち掘れ量などは表現できていない。また、著者は路面状況を確認するため走行映像を録画している。そこで、AIによって画像から路面のひび割れ抽出を試みている。しかしながら、画像の質や量、AIのモデルによって検出精度に課題がある。本研究では、問題点を明確にするためにケーススタディを実施したものである。

キーワード：路面性状、ひび割れ、AI, YOLO, 物体検出

## 1. はじめに

本研究は、路面性状の評価方法に関して、効率化や定量化を目的として研究したものであり、近年のAI技術の発展により走行映像からひび割れを検出し路面性状の評価を試みたものである。路面性状の評価には、MCI<sup>1)</sup>やIRI<sup>2)</sup>といった手法が広く普及している。わが国の国道や県道、市町村道では、広くMCIが利用されている。MCIの評価は、平坦性やひび割れ率、わだち掘れ量から求める。これまで、著者の研究グループはモーションセンサーとビデオカメラを利用した路面性状システム<sup>3)</sup>を開発してきた。本システムは、走行映像、センサデータ、GPSデータ等を入力データとして、主に車の垂直方向の加速度（サンプリング周波数：100Hz）を1秒ごとの標準偏差によって路面性状を評価してきた。基準としては、MCIとの比較により3段階で評価をしている。これは、速度の違い、車種の違いなどは事前にキャリブレーションをすることで、正規化している。しかし、振動データのみでは、ひび割れの抽出は困難である。そこで、走行映像を利用して、ひび割れを検出することで、路面性状評価の精度向上を試みている。カメラの解像度の改善や設置位置の改善を行いAIに用いる学習データの増量やひび割れの質やリッチ化について検討し、精度改善を試みる。ひび割れの形状は、縦、横、亀甲状として分類して検討する。また、AIの物体検出手法のバージョンによっても検出精度が異なるので、過去のバージョンのものと同研究当時の最新のバージョンのものとも比較検討した。

## 2. 路面性状評価への適用の考え方

舗装の破損<sup>4)</sup>には、利用者の安全性や快適性が損なわれる機能的な性能低下と、舗装の構造が破壊して生じる構造破損がある。構造的な破損は、路盤や路床にもかかる各層の材料破壊である。代表的な変状としては、ひび割れ、路盤や路床に起因する永久変形である。この変状を調査する方法の中でMCIという指標が用いられており、平坦性、ひび割れ率、わだち掘れ量を基準としている。この基準は路面の性状をよく表している。振動による路面の評価では、主に平坦性のみとなることから、ひび割れ率を評価できる手法との組み合わせが重要となる。このことから、ひび割れを検出できることが重要なポイントとなる。ここでは、路面性状の評価方法についてまとめ、適用の考え方をまとめる。

### (1) MCI値による路面性状評価

舗装の劣化形態は様々なものがあり、例として、ひび割れ卓越型の劣化形態や、わだち掘れ卓越型の劣化形態が存在している。しかし、「ひび割れ率」や「わだち掘れ量」などの単独指標ではそれらと異なる舗装との比較は容易ではない。そこで、昭和56年に建設省土木研究所が、道路局、地方建設局が共同で、維持修繕を行う総合的な指標として開発したものがMCI<sup>1)</sup>である。

劣化の程度の評価は、「ひび割れ率」、「わだち掘れ量」、「平坦性」の3要素によって10点満点で総合評価される。MCI値は舗装の劣化に伴い低下し、判断基準は、

MCI値>5であれば「望ましい管理水準」、 $3 \leq \text{MCI値} \leq 4$ であれば「修繕が必要」、MCI値<3であれば「早急に修繕が必要」とされている。

### (2) モーションセンサによる評価

モーションセンサによる評価<sup>9)</sup>は、図-1に示すビデオデータ（走行映像）、センサデータ、GPSデータを入力とし、これらに関連付け、評価結果を出力させることで、舗装路面の良否判定を行うシステムである。出力データの舗装路面評価結果Excelファイルには、1秒単位で路面を評価し、「良好」、「要注意」、「要補修」の3段階で評価した結果が出力される。また、GPSデータによって得られた緯度・経度情報を世界測地系座標に変換することにより、道路台帳付図への出力が可能であり、地図上で結果を閲覧できる。

本計測でのデータ取得用機材の設置状況及び使用機材を図-2に示す。機材の走行映像及びひび割れデータは、市販のハイビジョンビデオカメラによる撮影で取得する。GPSデータおよびセンサデータは、XSSENS製の加速度・角速度計機能を有する3次元モーションセンサとGPSアンテナによって得られるデータを計測用PCで記録する。以上の記録したデータは、ハイビジョンビデオカメラに掲載されているGPSセンサによる時刻と3次元モーションセンサに付属するGPSアンテナによる時刻により同期を行う。本システムで出力される結果は図-3に示す路面評価結果Excelファイルと、図-4に示すWeb地図上への評価である。なお、対象の路線は鳥取県の鳥取空港布勢線である。路面の評価結果は、赤(要補修)、黄(要注意)、緑(良好)の三段階で評価され、三段階区分はMCIによる判定と同程度としている。

### (3) 画像による変状検出

線状・亀甲ひび割れの検出は、劣化の早期ステージでの発見に繋がり予防保全的な維持管理に寄与すると考える。また、本システムの路面評価結果とひび割れの抽出結果を組み合わせることで、路面性状評価の精度が向上すると考える。そこで、AI(YOLO<sup>9)</sup>)による物体検出を用いて走行映像中のひび割れ、伸縮装置、マンホール、補修跡の検出<sup>9)</sup>を試みた。YOLOの適用手順は、図-5に示す(a)環境構築、(b)教師データの作成、(c)学習、(d)物体検出となる。この手順で(b)教師データの作成では、データ抽出やアノテーションが重要となる。データ抽出では、画像のどの範囲を選択するか、という課題がある。アノテーションでは分類する項目(線状ひび割れ、亀甲状ひび割れ等やジョイントなど)やラベル付けをする範囲などの課題がある。これらもシミュレーション条件となる。ひび割れを抽出後、ひび割れ率を計算し性能評価に追加することで、路面性状の評価精度の向上につながると考える。本研究では、ひび割れの検出精度に課題があるため、検出精度向上に着目する。




図-1 モーションセンサのデータ処理手順



図-2 機材設置状況と解析の流れ

時刻	緯度	経度	加速度	角速度	GPS	モーションセンサ	評価結果	経緯度	経緯度
2022/9/13 14:04:59	35.52632	134.1674	4018037	690041.9	0	0	良好	0	0
2022/9/13 14:05:00	35.52631	134.1675	4018037	690041.9	0	0	良好	-0.31129	0.146773
2022/9/13 14:05:01	35.52631	134.1676	4018037	690041.9	0	0	良好	-0.60354	0.121044
2022/9/13 14:05:02	35.52630	134.1677	4018037	690041.9	0	0	良好	-0.94855	0.095205
2022/9/13 14:05:03	35.52629	134.1678	4018037	690041.9	0	0	良好	-1.07151	0.099994
2022/9/13 14:05:04	35.52629	134.1679	4018037	690041.9	0	0	良好	-1.22645	0.105204
2022/9/13 14:05:05	35.52629	134.1679	4018037	690041.9	0	0	良好	-1.46652	0.104599
2022/9/13 14:05:06	35.52629	134.1680	4018037	690041.9	0	0	良好	-1.55512	0.112126
2022/9/13 14:05:07	35.52627	134.1681	4018037	690104.2	0	0	良好	-1.59572	0.125744
2022/9/13 14:05:08	35.52626	134.1682	4018037	690112.2	0	0	良好	-1.6251	0.129537
2022/9/13 14:05:09	35.52626	134.1683	4018037	690119.9	0	0	良好	-1.40649	0.111399
2022/9/13 14:05:10	35.52625	134.1684	4018037	690127.2	0	0	良好	-1.54685	0.092581
2022/9/13 14:05:11	35.52625	134.1684	4018037	690130.4	0	0	良好	-1.32038	0.093142
2022/9/13 14:05:12	35.52625	134.1685	4018037	690139	0	0	良好	-1.35256	0.076716
2022/9/13 14:05:13	35.52624	134.1686	4018037	690144.6	0	0	良好	-1.05789	0.09752
2022/9/13 14:05:14	35.52624	134.1686	4018037	690151.2	0	0	良好	-1.25233	0.094528
2022/9/13 14:05:15	35.52624	134.1687	4018037	690158.6	0	0	良好	-1.40465	0.103554
2022/9/13 14:05:16	35.52623	134.1688	4018037	690166.4	0	0	良好	-1.659	0.113307
2022/9/13 14:05:17	35.52623	134.1689	4018037	690174.9	0	0	良好	-1.65574	0.113996
2022/9/13 14:05:18	35.52622	134.1689	4018038	690181.9	0	0	良好	-1.10993	0.124266
2022/9/13 14:05:19	35.52622	134.1691	4018038	690183.4	0	0	良好	-1.09205	0.128816
2022/9/13 14:05:20	35.52621	134.1692	4018038	69020.2	0	0	良好	-1.01289	0.092977
2022/9/13 14:05:21	35.52621	134.1693	4018038	690213.2	0	0	良好	-1.70075	0.048617
2022/9/13 14:05:22	35.52619	134.1694	4018038	69022.2	0	0	良好	-1.01929	0.048415
2022/9/13 14:05:23	35.52619	134.1695	4018038	690233.4	0	0	良好	-1.45544	0.100152

図-3 路面評価結果Excelファイルの出力例



図-4 Web地図上への評価結果のマッピング例

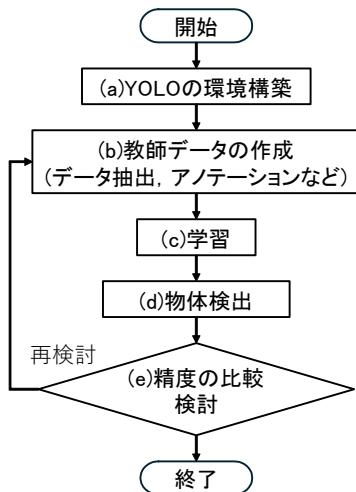


図-5 YOLOの適用手順

### 3. YOLOによる舗装変状の検出

#### (1) YOLOの概要

物体検出手法YOLO<sup>9)</sup>とは、DarknetやUltralytics社から提供されている物体検出アルゴリズムである。YOLO<sup>9)</sup>は2016年にJoseph Redmon氏が「You Only Look Once : Unified, Real-Time Object Detection」という論文を発表し、物体検出のリアルタイムでの処理を可能にした。YOLOの処理の流れは、最初に、画像をS×Sグリットセルに分割する。そして、各グリットセルはバウンディングボックスと信頼度を予測し、対応するグリットセルは検出対象が含まれているかどうかの条件付きのクラス確率を持つ。そして閾値を超える信頼度を持つバウンディングボックスと対応するグリットセルにおいて、最も確率の高いクラスを組み合わせることで最終的なバウンディングボックスを決定する。ここで、バウンディングボックス<sup>10,11)</sup>とは、画像や映像の中の物体を囲んだ部分領域のことである。物体検出では、バウンディングボックスを使って、画像内の物体の位置推定とクラスの実行する。バウンディングボックスの主な表現方法は、コーナー2点による表現と、中心点と幅・高さを使う表現の2種類がある。本研究では、前者の方法で表現する。

#### (2) 教師データの作成方法とパラメータ

まず、本研究での走行映像の撮影方法として、超小型アクションカメラを車両の後方に設置し、車内からスマートフォンで遠隔操作し撮影する。その後、一部感舗で用いられた走行映像や撮影してきた走行映像をアプリケーションVLC media Playerを用いて一定間隔のコマ送りの静止画として取り出す。使用する映像のFPS値に合わせて1秒ごとに1枚の静止画を取り出す設定を行い、動画を分割する。

次に、アプリケーションLabelimgを用いてアノテーションを実施し、教師データを作成する。物体検出では、バウンディングボックスを使って、画像内の物体の位置推定とクラスの実行する。ここで、アノテーションとは、物体検出したい領域を画像毎に矩形で囲みラベリングしていく作業である。また、バウンディングボックスとは、画像や映像の中の物体を囲んだ部分領域のことである。本研究では、Modelの「YOLOv8l」で学習条件を指定する。dataには作成したyamlファイルのパスを与える。epochは学習の繰り返し回数であり適宜変更する。batchはミニバッチ数、workersはデータの取り出し数、degreesはデータ拡張であり、画像をランダムに0から90度回転させる設定にしている。

#### (3) 物体検出の評価指標

物体検出の評価指標について以下にまとめる。mAP(mean Average Precision)は、物体検出モデルで使用される評価指標である。この指標を算出するには、IoU、適合率(Precision)、再現率(Recall)、APを求める必要がある。しかし、本研究ではひび割れの精度の向上が目的であるため、APを評価指標とする。以下にそれぞれの指標について示す。<sup>12)</sup>

##### a)IoU(Intersection over Union)

IoUは、モデルが推測したバウンディングボックスが、真のバウンディングボックスとどれくらい重なっているかを評価する指標である。算出式と概念図を図-6に示す。

##### b)混同行列(Confusion Matrix)

混同行列とは、表-1に示すとおり陽性(positive)/陰性(Negative)のどちらかに分類する二値分類の問題に対する評価指標の計算式で2行×2列の分割表(マトリクス)のことである。1行目と2行目の行項目に「真値×(陽性 | 陰性)」を1列目と2列目の列項目に「予測値×(陽性 | 陰性)」をとる。

表-1 Confusion Matrix(混同行列)

		予測値	
		陽性(Positive)	陰性(Negative)
真値	陽性(Positive)	真陽性(TP)	偽陽性(FN)
	陰性(Negative)	偽陰性(FP)	真陰性(TN)

$$IOU = \frac{\text{area of overlap}}{\text{area of union}} = \frac{\text{図-6の図}}{\text{図-6の図}}$$

図-6 の算出式概念図

### c) 適合率(Precision)

適合率(Precision)は、検出したバウンディングボックスが正しい比率を示す。算出式は式(1)であり、間違っただけバウンディングボックスを過剰に検出してしまふ過検出がなければ適合率は1.0になる。

$$Precision = \frac{TP}{TP+FP} = \frac{TP}{all\ detections} \quad (1)$$

### d) 再現率(Recall)

再現率 (Recall) は、検出すべきバウンディングボックスを検出できている比率を示す。算出式は式(2)であり、検出すべきバウンディングボックスが検出できていない未検出がなければ再現率は1.0になる。

$$Recall = \frac{TP}{TP+FN} = \frac{TP}{all\ ground\ truths} \quad (2)$$

### e) AP(Average Precision)

AP(Average Precision)は適合率(Precision)と再現率(Recall)を合わせた指標であり、これをグラフで表したものがPR曲線である。AP(Average Precision)はPR曲線を積分することで算出できる。このPR曲線の下領域が広いほど適合率も再現率も高く、モデルの精度が良いということが分かる。このことから、PR曲線の面積が大きいほどモデル精度が良い。

### f) mAP (mean Average Precision)

APはクラスごとに算出される値であり、APを平均したものをmAPという。

### g) PR曲線 (Precision-Recall Curve)

PR曲線とは、適合率(Precision)に対する再現率(Recall)を曲線グラフにしたものである。つまり、適合率が高い状態でありながら再現率もできるだけ高い場合、AUC(PR曲線の下側面積)が大きいほど精度がよい。

## 4. 精度検証のためのシミュレーション

### (1) 実験ケース

本研究のシミュレーションでは、5つの学習ケースで既往研究の検出結果などと比較することによってひび割れの検出精度の向上を検討する。以下にケースごとの実験目的をまとめる。

Case1では、YOLOv8の事前トレーニング用の重みを用いて、教師データを学習させる。

Case2では、YOLOv8の事前トレーニング用の重みを用いて、教師データをリッチ化したものを学習させる。

Case3では、得た重みをさらに学習させ、学習回数を増やす。本研究では、Case2で用いた教師データをCase3-1でCase1の重みを用いて50回、Case3-2でさらに100回、

表-2 YOLOv5の検出精度評価

クラス	亀甲状ひび割れ	線状ひび割れ	区画線状のひび割れ	補修跡	マンホール	伸縮装置
ラベル名	kikkou_crack	sen_crack	crack_line	repair	manhole	joint
AP	0.419	0.453	0.332	0.451	0.894	0.592
mAP	0.523					

Case3-3でさらに90回、計290回を学習させる。

Case4では、Case3-3で得られた検出精度とYOLOv3で得た検出精度を比較し評価する。

Case5では、別の路線のデータを用いた検出精度と比較し評価する。

次に、比較対象としてYOLOv5<sup>13)</sup>を用いた検出結果を用いる。その精度を表-2に示すとおりYOLOv5の事前トレーニング用の重みを用いた、学習枚数1089枚、学習回数50回の検出精度の結果を採用する。学習では画像データを学習データ(train)：検証データ(val)=8：2程度の割合に分け学習を行った。Case1では、教師データの画像サイズは1920×1080、解像度は2.7K、学習枚数は1089枚であり、エポックス数50である。Case2からCase4では、教師データの画像サイズは3840×2160、解像度は4K、学習枚数は1062枚であり、リッチ化後アノテーションを行ったものである。Case2のエポックス数50である。Case3のエポックス数は50,100,90である。Case3のエポックス数は290である。バッチサイズは8と共通である。

### (2) 結果

#### a) Case1：YOLOのバージョンによる差異

YOLOのバージョンをv5からv8に変更し、学習には1089枚の画像を用いた学習データを使用し、同じ条件でひび割れ等の検出を行った。この学習データではひび割れのクラスを亀甲状ひび割れ、線状ひび割れ、区画線状のひび割れの3種類に細分化している。検出精度結果を亀甲状のひび割れのAPが0.2程度、線状ひび割れが0.5程度、区画線状のひび割れが0.3程度となり、v5の検出精度評価と比べると線状ひび割れのみ向上した。図-7に示すCase1のPR曲線は、各ひび割れは左下に偏っていることから、精度が低いことがわかる。

#### b) Case2：教師データのリッチ化による差異

Case1と同様にYOLOv8の事前トレーニング用の重みを用いたが、教師データはリッチ化したものでひび割れ等の検出を行った。また、リッチ化した際にCase1のようにひび割れのクラスは細分化せず、「ひび割れ」として1つにまとめた。以下の3つの結果から、検出精度が低いことがわかる。まず、検出精度結果をv5の既往の検出精度であるひび割れのAPが0.4~0.6と比べて、ひび割れのAPが0.3程度、区画線状のひび割れのAPが0.2程度となった。図-8では、Case2のPR曲線を示し、各ひび割れは左下に分布している。

#### c) Case3：検出精度が高いケースで得られた重みを加えた重み付け

Case3は、さらに、学習データの追加の仕方でも3ケース追加した。

(1) Case3-1: Case1の重みを追加した教師データで学習  
学習回数を50回とし、Case1で得られた重みをさらに追加した教師データで学習させた。検出精度結果は、ひび割れのAPが0.4程度、区画線状のひび割れのAPが0.7程度とv5の検出精度と同程度となった。図-9はCase3-1のPR曲線を表しており、Case1, 2に比べ、グラフの分布が右上に上がっており、精度が向上していることがわかる。

(2) Case3-2: Case3-1の重みをさらに教師データで学習  
学習回数を100回に変更し、Case3-1で得られた重みを、本研究の教師データで合計150回学習させた。以下の結果から検出精度が向上したことがわかる。まず、検出精度結果は、ひび割れのAPが0.6程度、区画線状のひび割れのAPが0.8程度となった。図-10はCase3-2のPR曲線を表しており、Case1, 2, 3-1に比べ、グラフが右上に分布している。

(3) Case3-3: Case3-2の重みをさらにCase2の教師データで学習

学習回数を90回に変更し、Case3-2で得られた重みを、合計240回ほど学習させた。検出精度結果はひび割れのAPが0.7程度、区画線状のひび割れのAPが0.9程度となった。次に、Case1, 2, 3-1, 3-2と異なり、ひび割れを含めすべてのクラスのTPがFNよりも高い。最後に、図-11はCase3-3のPR曲線を表しており、Case3-2よりもさらに、グラフが右上に分布している。

d) Case4: 学習枚数が多いYOLOv3の検出精度との比較

表-3に1062枚の教師データを学習させたCase3-3で得られた最も高い検出精度(表中の①)と、YOLOv3の研究で12,000枚程度のリッチ化を行った教師データを学習させた検出精度<sup>7)</sup>(表中の②)を比較する。ひび割れのAPは0.05程度、区画線状のひび割れは2倍程度、その他の変状のAPやmAPも上がっていることから、検出精度が向上したことがわかる。

e) Case5: 別路線での検出精度との比較

Case3-3の検出精度は教師データの作成に使用した路線と同路線で評価した結果であるため、汎用性を検討する必要がある。そこで、Case3-3で得られた最も高い検出精度と、Case1のYOLOv5の教師データの作成に用いた路線の画像で検出した精度を比較する。亀甲状ひび割れのAPは0.3程度、線状ひび割れのAPは0.5程度となり、ひび割れのクラスは細分化されているが、検出精度が下がったことがわかる。

表-3 Case3-3とYOLOv3の検出精度評価<sup>7)</sup>の比較

クラス		ひび割れ	区画線状のひび割れ	補修跡	マンホール
ラベル名		crack	crack line	repair	manhole
② YOLOv3	AP	0.634	0.410	0.913	0.870
	mAP	0.760			
① Case3-3	AP	0.682	0.863	0.953	0.995
	mAP	0.873			

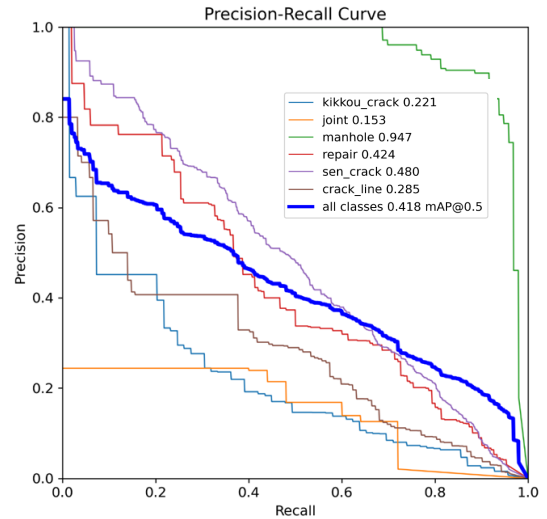


図-7 Case1のPR曲線 (Precision-Recall Curve)




図-8 Case2のPR曲線 (Precision-Recall Curve)




図-9 Case3-1のPR曲線 (Precision-Recall Curve)

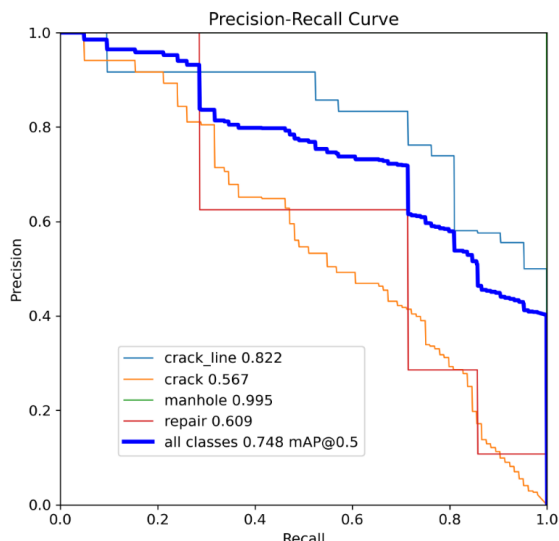


図-10 Case3-2のPR曲線 (Precision-Recall Curve)




図-11 Case3-3のPR曲線 (Precision-Recall Curve)

## 5. まとめ

本研究で得られた結果を以下にまとめる。

- (1) 変状自動抽出の検討において、YOLOv8の環境で、教師データの解像度を2.7Kから4Kにすることで、明瞭な画像としリッチ化を行った結果、精度の改善が見られた。
- (2) 学習回数を増加させたCase3-3では、ひび割れのAPが0.682、区画線状のひび割れのAPが0.863となり、既往の検出精度に比べて検出精度は向上した。
- (3) ひび割れ抽出の精度を改善するには、高解像度の画像でリッチ化を行い、最新のバージョンで複数回学習を実施することで、よい抽出結果が得られた。ただし、汎化性の観点からより多くの変状データを教師データにする必要があることが分かった。

謝辞：本研究は、一般財団法人中国建設弘済会の2022年度技術開発支援事業のご支援により実施できましたことに感謝申し上げます。また、フィールド提供やMCIデータの提供を頂きました鳥取県県土整備部技術企画課 藤井優課長、他皆様の多大なご協力に感謝致します。最後に、令和5年度の小谷航平氏の卒業研究の一部をまとめたものであり、感謝します。

## 参考文献

- 1) 建設省道路局国道第一課，建設省土木研究所：舗装の維持修繕の計画に関する調査研究，第34回建設省技術研究会報告，1980.
- 2) 一般財団法人土木研究センター：MCI（舗装の維持管理指数）<[https://pwrc.or.jp/yougo\\_g/pdf\\_g/y1104-P053-054.pdf](https://pwrc.or.jp/yougo_g/pdf_g/y1104-P053-054.pdf)>
- 3) 一般財団法人土木研究センター：路面のIRI（国際ラフネス指数）を測定する各種測定方法の精度比較<[https://www.pwrc.or.jp/thesis\\_shouroku/thesis\\_pdf/1410-P056-059pwrc\\_ando.pdf](https://www.pwrc.or.jp/thesis_shouroku/thesis_pdf/1410-P056-059pwrc_ando.pdf)>
- 4) 東京都建設局：都道におけるIRI（国際ラフネス指数）に関する調査<<https://www.kensetsumetro.tokyo.lg.jp/content/000010074.pdf>>
- 5) 吉武俊章，溝部和広，安村成史，宮本文穂：走行映像と車内走行音および車両振動を用いた舗装路面簡易評価システムの開発，土木学会論文集 F4（建設マネジメント），Vol.69, No.1, 12-31, 2013.
- 6) 志賀純貴，江本久雄，馬場那仰，吉武俊章：AIによる変状抽出機能の舗装路面簡易評価システムへの適用，AI・データサイエンス論文集，Vol.1, No.11, pp.180-189, 2020.
- 7) 沼田美織，大田涼介，江本久雄，吉武俊章：変状自動抽出とマップシステムを用いた舗装路面簡易評価システムの実践的研究，インフラメンテナンス実践研究論文集，Vol.2, No.1, 66-75, 2023.
- 8) 公益社団法人 土木学会 舗装工学委員会 委員長西沢辰男：舗装工学ライブラリー7 舗装工学の基礎，第1章 舗装の構造と役割，pp.20, 2012.3.
- 9) Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi: You Only Look Once: Unified, Real-Time Object Detection, Computer Vision and Pattern Recognition, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- 10) 中井悦司：TensorFlow と Keras で動かしながら学ぶ ディープラーニングの仕組み ～畳み込みニューラルネットワーク徹底解説～，マイナビ出版，2019.
- 11) DXを推進するAIポータルメディア「AI smiley」：バウンディングボックスとは？AIによる物体検出の手法とできること，[https://aismiley.co.jp/ai\\_news/bounding-box/](https://aismiley.co.jp/ai_news/bounding-box/), 2023.
- 12) rafaelpadilla Rafael Padilla : rafaelpadilla/Object-Detection-Metrics, <https://github.com/rafaelpadilla/Object-Detection-Metrics>, 2023.
- 13) 江本久雄，太田隆夫，福井信気：路面性状評価のためのひび割れ抽出に関する検討，2023年中国支部研究発表会，土木学会，Vol.75, 2023.