

# 自転車ユーザ参加型路面画像センシングによる 点字ブロック検出における性能向上方法の模索

松田 悠斗<sup>†</sup> 松田 裕貴<sup>†, ††</sup>

† 岡山大学 〒700-0082 岡山県岡山市北区津島中3丁目1-1

†† 理化学研究所革新知能統合研究センター 〒103-0027 東京都中央区日本橋1-4-1

E-mail: †yuto.matsuda@cocolab.jp, yukimat@okayama-u.ac.jp

あらまし 本研究では、小型カメラを搭載した自転車によるユーザ参加型センシングで取得した路面画像を対象として、物体検出モデル YOLO11 を用いた点字ブロック検出を行う。オリジナル画像に加え、グレースケール変換、および CLAHE によるコントラスト強調を施したデータセットを構築し、計 3 種類の点字ブロック検出モデルを作成・評価した。その結果、最大で Precision が 0.828, mAP<sub>50</sub> が 0.802 となり、自転車走行中に撮影された画像に対しても高い検出性能を示すことを確認した。さらに、検出結果に対して BBox 統合手法である NMW および WBF を適用し、多重検出の抑制ならびに 3 モデルのアンサンブルによる検出性能の向上を図った。その結果、最大で Precision が 0.894 (+8.0 %), mAP<sub>50</sub> が 0.844 (+5.2 %) となり、後処理による検出性能の向上を確認した。

**キーワード** 参加型センシング、自転車、点字ブロック、画像認識、都市環境

## Exploring Methods to Improve Performance in Tactile Paving Detection Based on Cyclist-Participatory Road Image Sensing

Yuto MATSUDA<sup>†</sup> and Yuki MATSUDA<sup>†, ††</sup>

† Okayama University Tsushima-naka 3-1-1, Kita-ku, Okayama, Okayama 700-0082, Japan

†† RIKEN Center for Advanced Intelligence Project Nihonbashi 1-4-1, Chuo-ku, Tokyo 103-0027, Japan

E-mail: †yuto.matsuda@cocolab.jp, yukimat@okayama-u.ac.jp

**Abstract** This study investigates tactile paving detection in road surface images acquired via bicycle-based participatory sensing using compact cameras and the YOLO11 object detection model. Three detection models were trained and evaluated using the original images as well as datasets preprocessed with grayscale conversion and CLAHE-based contrast enhancement. The proposed approach achieved a maximum Precision of 0.828 and an mAP<sub>50</sub> of 0.802, demonstrating robust detection performance for images captured during bicycle travel. Furthermore, applying Non-Maximum Weighted (NMW) and Weighted Boxes Fusion (WBF) for three-model ensemble post-processing suppressed multiple detections and improved accuracy, resulting in a maximum Precision of 0.894 (+8.0 %) and an mAP<sub>50</sub> of 0.844 (+5.2 %).

**Key words** Participatory Sensing, Bicycle, Tactile Paving, Image Recognition, Smart City

### 1. はじめに

視覚障害者の安全かつ円滑な移動を支えるため、街中の様々な場所に点字ブロックが敷設されている。令和4年度における日本の視覚障害者数は約27万3千人と報告されており[1]、現代において点字ブロックは極めて重要なバリアフリー設備であるといえる。しかし、敷設されている点字ブロックには摩耗や褪色等によって劣化したものが多く、これらは視覚障害者にとって認識が困難であり、重大な危険を引き起こしかねない。

点字ブロックの利便性と安全性を確保するためには定期的な点検と保守が必要不可欠であるが、総務省行政相談センターが公表した「視覚障害者誘導用ブロック等の適切な設置および維持管理について」[2]によると、341件もの不備が沖縄県内の一部区間ににおいて報告されており、現場での維持管理の難しさが明らかとなっている。不備が放置されている原因として、主流の点検手法である徒歩による巡回点検では人的・時間的コストが非常に高く、調査の頻度や範囲を十分に確保することが困難で

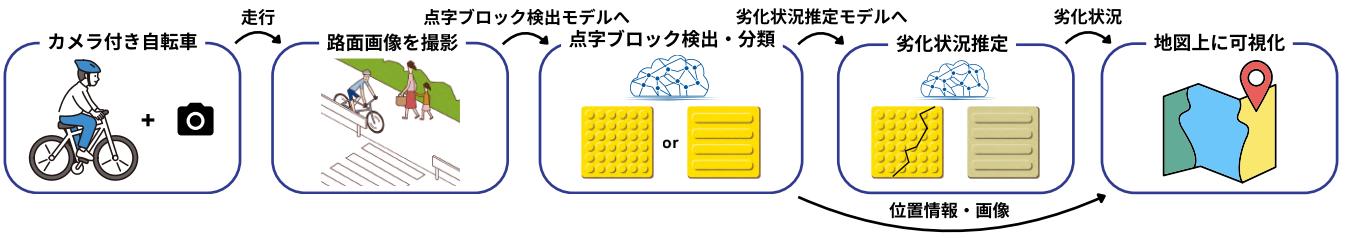


図 1: 本研究の概要

あることが挙げられる。例えば、総務省関東管区行政評価局の資料「視覚障害者誘導用ブロックの維持管理等に関する調査」[3]によると、大宮・東京・横浜の各国道事務所では 1 日から 2 日に 1 回の頻度で歩行点検を行っているが、その調査範囲は総延長約 164 km のうち 1 km と限定的である。また、年 1 回や不定期での点検にとどまっている地方公共団体も存在するため、全国的な点字ブロックの維持管理体制には課題が残っている。

そこで著者らは、図 1 に示すように、点検作業の効率化と人的コストの削減に向け、小型カメラと GPS モジュールを搭載した自転車を用いたユーザ参加型センシングにより点字ブロックの配置・劣化情報を収集する手法について研究している [4], [5]。

本稿では、自転車走行中に撮影した路面画像を用いて、物体検出モデル YOLO11 による点字ブロックの検出を行うとともに、収集した画像に対してグレースケール変換や CLAHE を施したデータセットを構築し、前処理前後における検出性能の比較を行った。また、BBox の統合手法である NMW (Non-Maximum Weighted) や WBF (Weighted Boxes Fusion) の複合適用を行い、3 モデルのアンサンブルによる検出性能の向上を図った。

## 2. 関連研究

### 2.1 都市環境におけるユーザ参加型センシング

ユーザ参加型センシングとは、市民が自身のスマートフォンやセンシングデバイスを用いて都市環境データを収集・共有する手法である [6]。このユーザ参加型センシングを活用して都市環境の状況を把握する取り組みは多岐にわたる。例えば、夜間の歩行安全性評価を目的とした街灯情報の収集 [7]、IoT トンネルによるポイ捨てゴミの情報収集 [8]、都市環境における参加型センシングを支援するプラットフォーム [9] などが挙げられる。また、自転車や自動車に搭載したスマートフォンの GPS と慣性センサを用いて段差や路面状態を計測する研究も進められており、広範囲を移動するモビリティにセンサを搭載することで、都市環境データの効率的な収集を実現している [10]～[13]。

### 2.2 点字ブロックに関する情報収集と画像認識による検出

点字ブロックに関する情報収集や、画像認識による点字ブロック検出に関して様々な方法が提案されている。Tokita ら [14] は、深層学習セグメンテーションモデル DeepLabV3+ を用いて線状・点状ブロックの 2 種類の点字ブロック領域を検出する手法を提案し、mIoU が  $0.937 \pm 0.005$  という非常に高い性能を報告している。Chengyi ら [15] は、物体検出モデル YOLOv7 にアテンション機構の CBAM (Convolutional Block Attention Module) を導入することで、元のモデルと比較して検出精度

を約 4.1% 向上させている。Takano ら [16] は、点字ブロックの直線性および黄色という視覚的特徴に着目し、多目的遺伝的最適化アルゴリズムの NSGA-II (Non-dominated Sorting Genetic Algorithm II) を用いた手法を提案しており、障害物や照度変化の大きい環境下でも高い検出精度を維持できることを示している。若松ら [17] は、頭部装着型カメラ画像に対し、FCN (Fully Convolutional Network) を用いて点字ブロック領域を抽出することで、再現率が 84% を超える安定した検出性能を示している。Wang ら [18] は、YOLOv8 に Lightweight Shared Detail Enhanced Oriented Bounding Box (LSDE-OBB) ヘッドを導入することで認識精度を大きく損なうことなくパラメータ数を約 25 % 削減した、魚眼カメラ搭載 UAV によるリアルタイム点検手法を提案している。

### 2.3 これまでの取り組み

著者らはこれまでに、図 1 に示す、小型カメラおよび GPS モジュールを搭載した自転車を用いたユーザ参加型センシングにより、点字ブロック画像および位置情報を効率的に収集し、物体検出モデル YOLO11 を用いて点字ブロックを検出する手法を提案している [4], [5]。提案手法により、自転車走行中に生じるブラーや歪みを含む画像に対しても、mAP<sub>50</sub> が 0.777 の点字ブロック検出性能を達成している。さらに、検出結果を入力として、線状ブロックおよび点状ブロックの種別を分類するモデルを CNN の ResNet18 により構築し、macro-F1 が 0.898 という高い分類性能を実現している。これにより、日常的な自転車移動を活用して点字ブロックの配置情報を効率的に収集するシステムを確立した。一方で、学習データの不足やモーションブラーに起因する誤検出および多重検出などの課題が残っており、学習データの拡充や後処理による誤検出抑制が必要である。

### 2.4 本研究の位置付け

点字ブロック検出には様々な画像認識手法が提案されているが、文献 [14]～[16] で用いられる学習画像はブレが少なく鮮明であり、文献 [17] の歩行時撮影画像でもブレは比較的軽微である。また、UAV を用いた手法 [18] は広範囲のリアルタイム点検が可能だが、操作に専門性が求められるという課題がある。

これに対し、著者らは自転車を用いたユーザ参加型センシングによる簡便かつ効率的な点字ブロック検出手法を提案してきたが、2.3 節に示したように、誤検出や多重検出といった課題が残されている。そこで本稿では、自転車走行中に撮影された画像を対象とした点字ブロック検出において、前処理の違いによる誤検出傾向の差異を分析し、複数モデルの出力特性を活用した後処理アンサンブル手法による検出性能向上の有効性を示す。

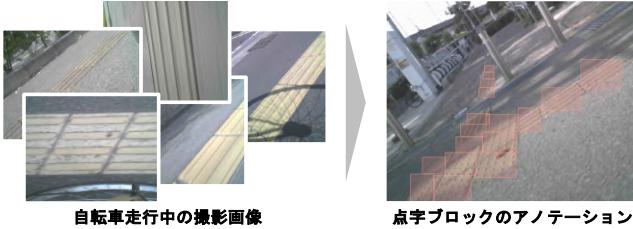


図 2: 自転車走行中の撮影画像とアノテーション例

表 1: データセット構成

データセット種別	画像枚数	インスタンス数	
		線状ブロック	点状ブロック
学習用	441	1019	240
テスト用	334	453	74

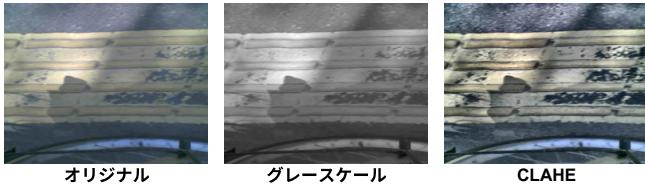


図 3: 画像処理前後のデータセット

### 3. 点字ブロック検出手法と後処理アルゴリズム

本章では、物体検出モデル YOLO11 [19] を用いた点字ブロック検出手法と、その検出性能の向上手法について述べる。まず、グレースケール変換および CLAHE によるコントラスト強調を施したデータセットを構築し、3種類の点字ブロック検出モデルを作成・評価する。続いて、検出結果に対して BBox 統合手法である NMW や WBF を適用し、3モデルのアンサンブルによる検出性能の向上を試みる。

#### 3.1 入力画像の前処理の違いによる検出性能の比較評価

まず、著者らの先行手法により、物体検出モデル YOLO11 を用いて点字ブロック検出モデルを構築する。自転車走行中に撮影した画像とアノテーション例を図 2 に、データセットの構成を表 1 に示す。なお、学習用データセット 441 枚のうち 40 枚(約 10%) は点字ブロックを含まない背景画像である。

このデータセットに加えて画像処理による前処理を施した 2種類のデータセットを作成し、3つの検出モデルを比較する。1つ目はグレースケール変換を施したモデルで、点字ブロックの色に依存しない学習を意図したものである。2つ目は CLAHE (Contrast Limited Adaptive Histogram Equalization) によるコントラスト強調を施したモデルで、ブロックの輪郭や細部を強調することを目的としている。画像処理前後の例を図 3 に示す。

次に、作成した 3 モデルに対して画像処理前後のテストデータを入力し、学習時の前処理(3種類)と推論時の前処理(3種類)の組み合せの計 9通りについて検出性能評価を行った。評価指標には、適合率(Precision)、再現率(Recall)、および平均適合率(mAP<sub>50</sub>)を用いる。表 2 に示す評価結果より、いずれのモデルも学習に施した画像処理と同じ前処理を推論時に行つた場合に mAP<sub>50</sub> が最大となり、前処理の一貫性が検出性能向

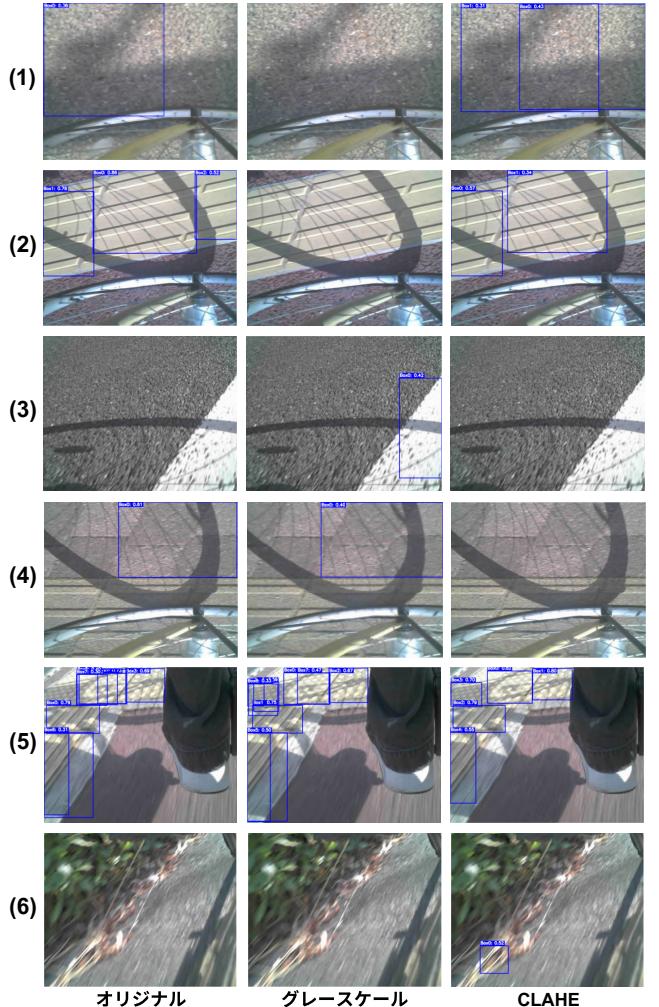


図 4: 各モデルの検出結果例

上に寄与することが明らかとなった。また、3 モデル間の比較では、オリジナルモデルが最も高い検出性能を示したが、他 2 つのモデルについても mAP<sub>50</sub> が 0.773, 0.774 と高い検出性能を維持している。

各モデルの検出結果例を図 4 に、モデルごとの系統別誤検出数を表 3 に示す。オリジナルモデルでは、アスファルト上の影やレンガ模様が線状ブロックに類似した特徴を持つことが原因と考えられる誤検出を起こす傾向が確認された。一方、グレースケールモデルではアスファルトに対する誤検出が、CLAHE モデルではレンガ模様に対する誤検出がそれぞれ低減している。グレースケールモデル特有の誤検出として、図 4(3) のような白線の誤検出が見られたが、これは色情報の消失により形状が点字ブロックと誤認されたためと考えられる。また、図 4(5) では 2 つのモデルが多重検出を起こしているものの、CLAHE モデルは点状ブロックの検出において高い性能を示した。これはコントラスト強調により点状ブロックの境界が強調され、識別しやすくなったためと考えられる。ただし、図 4(6) のように他のモデルでは生じない誤検出が発生する場合もあり、輪郭強調が逆効果となる例も確認された。以上より、各モデルには誤検出の傾向に固有の特徴があり、3 モデルの検出結果を組み合わせることで、誤検出の低減が期待できることが示唆された。

表 2: 点字ブロック検出モデルの評価結果

		モデルタイプ											
		オリジナルモデル			グレースケールモデル			CLAHE モデル					
		Precision	Recall	mAP <sub>50</sub>	Precision	Recall	mAP <sub>50</sub>	Precision	Recall	mAP <sub>50</sub>			
テストデータ タイプ	オリジナル	0.824	0.691	<b>0.802</b>	0.777	0.687	0.766	0.723	0.643	0.702			
	グレースケール	0.741	0.579	0.656	0.828	0.668	<b>0.773</b>	0.682	0.531	0.601			
	CLAHE	0.738	0.584	0.653	0.741	0.579	0.656	0.795	0.671	<b>0.774</b>			

表 3: モデルごとの系統別誤検出数

	アスファルト路面	白線	レンガ模様
オリジナルモデル	5	1	11
グレースケールモデル	1	4	10
CLAHE モデル	7	0	4

### 3.2 BBox 統合と 3 モデルアンサンブルによる検出性能向上

前節で構築したモデルにより、最大 mAP<sub>50</sub> が 0.802 での点字ブロック検出を達成したものの、多重検出や路面の誤検出等の課題が残っている。そこで本節では、BBox の統合アルゴリズムを用いた多重検出抑制、および 3 モデルアンサンブルによる検出性能向上手法について述べる。

#### 3.2.1 NMW の応用による多重検出除去

YOLOv1 では、検出結果に対して自動的に信頼度スコアフィルタ（閾値：検証時 0.001、推論時 0.25）および NMS（Non-Maximum Suppression）[20]（IoU 閾値：0.7）が適用される。しかし、点字ブロック検出タスクにおいては、BBox が大きく重なり合う状況は生じないため、閾値調整のみでは多重検出を十分に抑制できない場合がある。そこで、多重検出の除去手法として、BBox 統合アルゴリズムである NMW（Non-Maximum Weighted）[21] を用いた方法を提案する。

NMW は、重なり合う BBox 集合から 1 つの BBox を生成するアルゴリズムであり、式(1)のように IoU と信頼度スコアを重みとする加重平均によって出力座標を算出する。そのため、信頼度スコアの高い BBox の特徴をより強く反映できる。ここで、式(1)における  $\mathbf{b}$  は BBox、 $c$  は信頼度スコア、 $n$  は同一クラスタ内の BBox 数を表す。

$$\begin{aligned} \mathbf{b}_{new} &= \frac{\sum_{i=1}^n c_i \mathbf{b}_i}{\sum_{i=1}^n c_i}, \\ \omega_i &= c_i \cdot \text{IoU}(\mathbf{b}_i, \mathbf{b}_{\arg \max_i c_i}) \\ c_{new} &= c_{\arg \max_i c_i} \end{aligned} \quad (1)$$

多重検出が発生した画像に NMW を適用した結果を図 5 (b) に示す。ここでは、信頼度スコアフィルタ閾値を 0.3、統合時の IoU 閾値を 0.4 とした。結果を見ると、BBox 数は減少したもの、統合後の BBox 間に依然として重なりが残ることが確認できる。

この問題を解決するため、BBox 数が収束するまで NMW を反復適用するアルゴリズム（以下、M-NMW: Multiplex NMW）を作成した。適用結果を図 5 (c) に示す。このように、IoU 閾値を上回る BBox がなくなるまで反復することで、多重検出

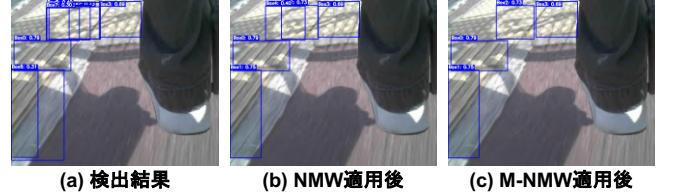


図 5: NMW, M-NMW の適用結果

を完全に抑制できている。元の検出精度には依存するものの、M-NMW により各点字ブロックを一意に検出可能となった。

#### 3.2.2 WBF の応用による 3 モデルアンサンブル

3.1 節では、構築した 3 つの点字ブロック検出モデルの出力傾向がそれぞれ異なることが確認された。したがって、複数モデルの出力を統合することで検出性能の向上が期待できる。本節では、BBox 統合アルゴリズムである WBF（Weighted Boxes Fusion）[22] を用いた 3 モデルアンサンブル手法を提案する。

WBF は、NMW と同様に重なり合う BBox 集合から 1 つの BBox を生成するが、式(2)に示すように、信頼度スコアのみを重みとする加重平均によって座標を算出する点が異なる。また、統合後の信頼度スコアはモデル数に基づいて計算されるため、アンサンブル推論に特化した手法といえる。ここで、式(2)における  $m$  はモデル数である。

$$\begin{aligned} \mathbf{b}_{new} &= \frac{\sum_{i=1}^n c_i \mathbf{b}_i}{\sum_{i=1}^n c_i}, \\ c_{new} &= \frac{\min(m, n) \cdot \sum_{i=1}^n c_i}{mn} \end{aligned} \quad (2)$$

3 モデルの検出結果（M-NMW 適用済み）に WBF を適用した例を図 6 (a) に示す。ここで、BBox を統合する際の IoU の閾値は 0.4 としている。3 モデルの結果が統合されている一方で、統合後の BBox の重なりが多く、いずれか 1 モデルが誤検出した場合にアンサンブル結果がその影響を受けることが分かる。

この問題に対しては、WBF 適用後に 3.2.1 項で構築した M-NMW を適用することで重なりを抑制できると考えられる。また、誤検出の影響を低減するため、WBF で再計算される信頼度スコアに対して閾値を設定し、低スコアの BBox を削除する戦略が有効である。そこで、WBF 適用後に信頼度スコア閾値 0.3 のフィルタリングと M-NMW の適用を行うアルゴリズム（以下、FF-WBF: Filtered and Fused WBF）を作成した。FF-WBF の適用結果を図 6 (b) に示す。追加の後処理により、BBox の重なりを抑えるとともに誤検出の影響を軽減できている。

図 6 (1) に着目すると、グレースケールモデル以外はアスファルト路面を誤検出しているが、各モデルの誤検出位置が異なる

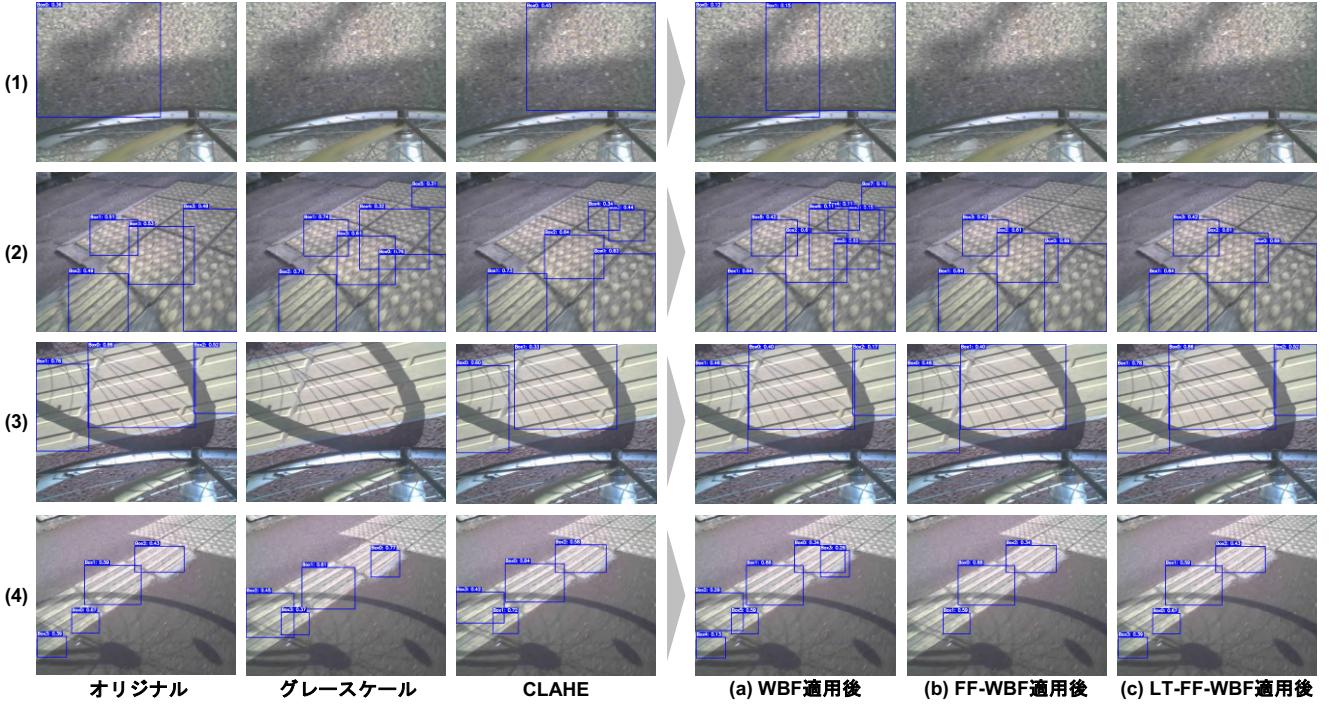


図 6: WBF, FF-WBF, LT-FF-WBF の適用結果

こと、およびグレースケールモデルが誤検出を起こしていないことにより、WBF 適用後の信頼度スコアが低くなり、フィルタリングによって誤検出を削除できている。このことから、FF-WBF には「誤検出を含まないモデルが存在し、かつ誤検出のスコアが低い場合、アンサンブル結果への誤検出の影響を抑制する」という特徴があるといえる。

FF-WBF により 3 モデルアンサンブルの誤検出抑制が可能となった一方で、図 6(3) に示すように、正しい検出結果が削除される場合がある。この例ではオリジナルモデルのみが正しく検出しておらず、その結果を採用するのが最適である。そこで、FF-WBF の派生手法として、点字ブロック配置の直線性に基づく LT-FF-WBF (Linearity-triggered FF-WBF) を提案する。LT-FF-WBF では、検出結果が直線的である場合は信頼度が高いと仮定し、最も性能の高いモデル（今回の場合は mAP<sub>50</sub> が最も高いオリジナルモデル）の出力を採用する。一方、直線性が低い場合には FF-WBF を適用する。ただし、本手法は点字ブロックの直線的配置に依存するため、点状ブロックなどの非線形配置には適用できない。直線性は BBox 重心の回帰直線に対する RMSE (Root Squared Mean Error) として定量化し、閾値を 100 とした。RMSE が 0 (検出が 0~1 個) の場合は直線性を判定できないため、FF-WBF を適用する。LT-FF-WBF の適用例を図 6(c) に示す。図 6(3) では、FF-WBF が正しい検出を抑制していたのに対し、LT-FF-WBF ではオリジナルモデルの検出結果を採用することで検出性能が向上している。一方、図 6(4) では断片的な誤検出が残り、FF-WBF の方が良好な結果となっている。なお、このような誤検出は NMW や WBF では抑制できず、別の後処理手法が必要である。このように、LT-FF-WBF は性能が向上する場合と低下する場合が存在するため、定量的な性能評価による FF-WBF との比較検討が必要である。

### 3.2.3 後処理アルゴリズムの性能評価

最後に、3.2.1 項、および 3.2.2 項で提案した後処理アルゴリズムについて定量的評価を行う。各モデルの学習時と同様の前処理を施したテストデータを用い、3 モデルに対して Precision, Recall, および mAP<sub>50</sub> を算出した評価結果を表 4 に示す。なお、WBF, FF-WBF, および LT-FF-WBF は 3 モデルを統合したアンサンブル手法であるため、これらの評価値は全モデルタイプで共通となる。

評価結果より、いずれの後処理アルゴリズムにおいても mAP<sub>50</sub> は元の検出結果と比較して向上しており、後処理による検出性能の改善が定量的に確認できた。NMW と M-NMW を比較すると、M-NMW の方が mAP<sub>50</sub> はわずかに高いものの、その差は 0.001 と極めて小さい。これは、本稿で用いたテストデータにおいては NMW の段階で多重検出が概ね除去されており、M-NMW との差がほとんど生じなかっただためであると考えられる（総検出数は NMW で 465 件、M-NMW で 464 件であった）。また、Recall、および mAP<sub>50</sub> が最大となった後処理アルゴリズムは WBF であった一方、Precision が最大となったのは FF-WBF であった。FF-WBF は WBF と比較して Recall が低下しているが、これは信頼度スコアフィルタ、および M-NMW により BBox が削除された結果、正解検出数も減少したためであると考えられる。一方で、BBox の削除により誤検出が抑制され、Precision の向上につながったと考えられる。

以上より、本稿で構築した検出モデルにおいては、誤検出と未検出のバランスを重視する場合には WBF を、誤検出の抑制を重視する場合には FF-WBF を選択することが適切である。本研究のデータ収集手法である自転車を用いたユーザ参加型センシングはデータ収集効率が高く、未検出については次回以降のデータ収集による補完が期待できる。この点を踏まえると誤検

表4: 後処理アルゴリズムの評価結果 (WBF, FF-WBF, LT-FF-WBF は全モデル共通)

		後処理アルゴリズム														
		NMW			M-NMW			WBF			FF-WBF			LT-FF-WBF		
		Precision	Recall	mAP <sub>50</sub>	Precision	Recall	mAP <sub>50</sub>	Precision	Recall	mAP <sub>50</sub>	Precision	Recall	mAP <sub>50</sub>	Precision	Recall	mAP <sub>50</sub>
モデル タイプ	オリジナル	0.823	0.721	0.808	0.824	0.721	0.809	0.844	<b>0.750</b>	<b>0.844</b>	<b>0.894</b>	0.708	0.825	0.868	0.712	0.817
	グレースケール	0.827	0.681	0.791	0.831	0.681	0.792									
	CLAHE	0.841	0.682	0.798	0.845	0.682	0.799									

出の抑制を重視することが望ましく、本稿で構築した検出モデルに適用する後処理アルゴリズムは FF-WBF が最適であると結論付けられる。

#### 4. おわりに

本稿では、小型カメラを搭載した自転車によって収集した路面画像を用い、物体検出モデル YOLO11 による点字ブロック検出手法、および検出性能の向上手法を提案した。オリジナル画像、グレースケール画像、および CLAHE によるコントラスト強調画像で検出モデルを構築した結果、最大で Precision が 0.828、mAP<sub>50</sub> が 0.802 となり、高い点字ブロック検出性能を確認した。さらに、NMW を応用した多重検出の除去、および WBF を応用した 3 モデルアンサンブルにより誤検出の抑制と検出性能の向上を実現し、最大で Precision が 0.894 (+8.0 %)、mAP<sub>50</sub> が 0.844 (+5.2 %) となった。

一方で、NMW や WBF では抑制不可能な誤検出が一部に残存するという課題も明らかとなった。今後はこの課題を解決するため、学習データの更なる拡充を図るとともに、点字ブロック配置の直線性を利用した新たな後処理アルゴリズムの開発などに取り組む予定である。

#### 謝 辞

本研究の一部は、JSPS 科研費 (24K20763) の助成を受けて行われたものです。

#### 文 献

- [1] 厚生労働省，“令和4年生活のしづらさなどに関する調査（全国在宅障害児・者等実態調査）,” [https://www.mhlw.go.jp/stf/oukei/list/seikatsu\\_chousa\\_r04.html](https://www.mhlw.go.jp/stf/oukei/list/seikatsu_chousa_r04.html), 2022. Accessed on 05/07/2025.
- [2] 総務省行政相談センター，“視覚障害者誘導用ブロック等の適切な設置及び維持管理について,” [https://www.soumu.go.jp/main\\_content/000901010.pdf](https://www.soumu.go.jp/main_content/000901010.pdf), 2023. Accessed on 05/07/2025.
- [3] 総務省関東管区行政評価局，“視覚障害者誘導用ブロックの維持管理等に関する調査,” [https://www.soumu.go.jp/main\\_content/000547116.pdf](https://www.soumu.go.jp/main_content/000547116.pdf), 2018. Accessed on 05/07/2025.
- [4] 松田悠斗, 松田裕貴, “自転車ユーザ参加型路面画像センシングによる点字ブロック配置情報の収集手法の検討,” 2025 年度情報処理学会関西支部 支部大会 講演論文集, pp.1–8, 2025. <https://ipsj.ixsq.nii.ac.jp/records/2004479>
- [5] Y. Matsuda and Y. Matsuda, “Tactile Paving Detection and Classification Method Based on Cyclist-Participatory Road Image Sensing,” 27th International Conference on Distributed Computing and Networking (ICDCN ’26 Companion), vol.2026, pp.1–6, 2026.
- [6] J.A. Burke, D. Estrin, M. Hansen, A. Parker, N. Ramanathan, S. Reddy, and M.B. Srivastava, “Participatory Sensing,” Center for Embedded Network Sensing, pp.1–5, 2006.
- [7] 松田裕貴, 新井イスマイル, “スマートフォン搭載照度センサの集合知による網羅的な街灯情報収集システムの開発,” 情報処理学会論文誌, vol.55, no.2, pp.750–760, 2014.
- [8] 立花巧樹, 中岡 黎, 宮地篤士, 富田周作, 松田裕貴, 中村優吾,
- [9] Y. Matsuda, S. Kawanaka, H. Suwa, Y. Arakawa, and K. Yasumoto, “ParmoSense: Scenario-based Participatory Mobile Urban Sensing Platform with User Motivation Engine,” Sensors and Materials, vol.34, no.8, pp.3063–3091, 2022. <https://doi.org/10.18494/SAM3961>
- [10] X. Xiao, R. Gao, W. Xing, C. Li, and L. Liu, “How Many Bumps in Your City? Personalized Bump Seeker With Mobile Crowd-sensing,” IEEE Transactions on Instrumentation and Measurement, vol.71, pp.1–12, 2022.
- [11] D.E. Nunes and V.F. Mota, “A Participatory Sensing Framework to Classify Road Surface Quality,” Journal of Internet Services and Applications, vol.10, no.1, p.13, 2019.
- [12] Z. Xiao, H.B. Lim, and L. Ponnambalam, “Participatory Sensing for Smart Cities: A Case Study on Transport Trip Quality Measurement,” IEEE Transactions on Industrial Informatics, vol.13, no.2, pp.759–770, 2017.
- [13] J. Takahashi, Y. Kobana, N. Isoyama, Y. Tobe, and G. Lopez, “YKOB: Participatory Sensing-Based Road Condition Monitoring Using Smartphones Worn by Cyclist,” Electronics and Communications in Japan, vol.101, no.4, pp.3–14, 2018.
- [14] R. Tokita, Y. Ikeda, K. Go, E. Nakahara, and A. Miyata, “Segmentation-Based Approach Towards Detecting Improperly Installed Tactile Paving,” Proc. the 27th International ACM SIGACCESS Conference on Computers and Accessibility (ASSETS ’25), no.98, pp.1–5, Oct. 2025. <https://doi.org/10.1145/3663547.3759735>
- [15] C. Shi, Q. Zhao, N. Fang, and Y. Mao, “Tactile Paving Recognition Method Based on Improved YOLOv7,” Journal of Electronic Research and Application, pp.22–27, 2024.
- [16] T. Takano, T. Nakane, T. Akashi, and C. Zhang, “Braille Block Detection via Multi-Objective Optimization from an Egocentric Viewpoint,” Sensors, vol.21, no.8, pp.1–15, 2021. <https://www.mdpi.com/1424-8220/21/8/2775>
- [17] 若松直人, 中田裕一, 田中直樹, “点字ブロック領域・種別識別による視覚障がい者支援システムに関する研究,” 第82回全国大会講演論文集, vol.2020, no.1, pp.401–402, 2020. <https://cir.nii.ac.jp/crid/1050574047122723712>
- [18] T. Wang, H. Wu, A. Asignacion, Z. Zhou, W. Wang, and S. Suzuki, “Autonomous UAV-Based System for Scalable Tactile Paving Inspection,” Drones, vol.9, no.8, pp.1–30, 2025. <https://www.mdpi.com/2504-446X/9/8/554>
- [19] G. Jocher and J. Qiu, “Ultralytics YOLO11,” <https://github.com/ultralytics/ultralytics>, 2024. version 11.0.0.
- [20] A. Neubeck and L. Van Gool, “Efficient non-maximum suppression,” 18th International Conference on Pattern Recognition (ICPR’06), vol.3, pp.850–855, 2006.
- [21] H. Zhou, Z. Li, C. Ning, and J. Tang, “Cad: Scale invariant framework for real-time object detection,” 2017 IEEE International Conference on Computer Vision Workshops (ICCVW), pp.760–768, 2017.
- [22] R. Solovyev, W. Wang, and T. Gabruseva, “Weighted boxes fusion: Ensembling boxes from different object detection models,” Image and Vision Computing, vol.107, p.104117, 2021. <https://www.sciencedirect.com/science/article/pii/S0262885621000226>

諫訪博彦, “カメラ装着型トングを用いたポイ捨てごみの種別認識手法の提案と評価,” 第28回社会情報システム学シンポジウム (ISS28), pp.1–6, 2022.