

# 夜間運転時に不安感を誘発する要因の検出手法の提案とその定量的評価

高岡 晴玖<sup>†</sup> 服部 峻<sup>††</sup> 宮城 茂幸<sup>††</sup>

<sup>†</sup> 滋賀県立大学工学部電子システム工学科 〒522-8533 滋賀県彦根市八坂町 2500

<sup>††</sup> 滋賀県立大学先端工学研究院 〒522-8533 滋賀県彦根市八坂町 2500

E-mail: <sup>†††</sup>23htakaoka@ec.usp.ac.jp, <sup>††</sup>{hattori.s,miyagi.s}@e.usp.ac.jp

**あらまし** 夜間の運転は視界不良により、昼間に比べて事故の危険性が高い。このため多くの運転者は不安を感じやすい。本稿では、夜間路上で撮影された画像から運転時に運転者が抱く不安要素を検出する手法を提案する。提案手法では、YOLOv8を用いて「車」、「人」、「自転車」を検出し単眼深度推定モデルのMiDaSを組み合わせて不安要因であるかどうかを決定する。また「見通しの悪い場所」についても対象とし、検出されたカーブミラーの画像中での相対的な位置関係から不安要素となる見通しの悪い地点の推定も行う。これらの結果と、運転者へのアンケート調査を照合し提案手法が夜間運転時の不安状態をどの程度客観的に捉えられるかを検証する。

**キーワード** 画像処理, 物体検出, 深度推定, 感情, 夜間運転

## 1 はじめに

夜間は昼間よりも非常に危険であり、多くの人が夜間運転に対して怖い・不安と感じている。このように感じてしまう理由として、歩行者等の危険となりうる対象の発見が遅れてしまうこと、ドライバーから見えている範囲が狭まってしまうことが原因と考えられている [1]。

また、夜間走行時の快適性評価の関連研究として、保田ら [2] が実施した夜間走行性に関するアンケート調査がある。その研究では、「夜間の道路走行は昼間に比べて快適と感じるか」という質問において、快適でないと回答した人が全体の8割ほどであった。また、夜間走行時に快適でないと感じる要素を記述する質問では、「見通しが悪い」、「明るさが十分でない」といった回答が全体の8割以上を占めていた。つまり視界不良により視認範囲が狭まり、危険となり得る対象や場所の発見および状況予測が困難となり、多くの運転者は細心の注意を払いながら運転しなければならない。この精神的な負担が運転に対する快適性を妨げ、不安感情を誘発されやすくなる。

本稿では、運転者の主観的な不安感情と提案手法がどれくらい一致しているかを検証することを目的として、運転者が不安を抱く要因を検出する手法を提案する。具体的には、夜間道路画像を収集し、その道路画像に含まれる不安となり得る要因を検出する。また要因は不安を誘発する物体と場所に限定する。そこで、物体に関しては「車」、「人」、「自転車」とする。これらの物体をYOLOv8で検出し、さらに深度推定モデルMiDaSを用いて物体の相対的な奥行きから不安要因かどうかを決定する。また、「カーブミラー」を検出する新たな学習済みモデルを用いて、カーブミラーとの相対的な位置関係から見通しの悪い場所についても推定する。そして、それらの提案手法のパラメータを変化させ、手法の性能がどう変化しどのような結果となるかを調査し、最良となるパラメータの条件を探索することで定量的評価を行った。

本稿の構成として、2章では関連研究を紹介する。3章では提案手法を「車」、「人」、「自転車」に対する不安要因の検出方法、カーブミラー周辺の見通しの悪い地点の推定方法の2通りに分けて示す。4章では、アンケート調査および提案手法を用いた実験方法、5章では、アンケート調査結果をもとに評価実験の結果や考察を記述する。最後に6章で本稿のまとめと今後の課題や将来について説明する。

## 2 関連研究

本稿では関連研究を紹介する。2.1節ではYOLOv8に関する説明、2.2節ではMiDaSに関する説明、2.3節では実際に物体検出を用いた先行研究を2つ紹介する。その後、本研究の新規性を紹介する。

### 2.1 YOLOv8 について

YOLOv8は、2023年1月にUltralytics社から発表されたモデルである。Muhammad Hussain [3]は、産業用製造の観点から初代YOLOからYOLOv8までの技術的進化に関する詳細なレビューを提供した。Muhammadによると、YOLOv5や画像サイズが640の解像度で学習させたYOLOv6と同等のパラメータ数で比較した場合、YOLOv8の方がより高いスループットを出力することが示された。また、この結果からハードウェアの効率性とアーキテクチャの改良が示されたと述べた。これはYOLOv8が今までのYOLOシリーズの中でも特に高精度かつ迅速な物体検出ができ、計算資源が限られた制約のあるエッジデバイスへの展開にも可能であることを示唆している。さらに、YOLOv8には、アンカーフリーという技術が組み込まれている。従来のYOLOでは、画像の中の物体を検出する際にあらかじめ用意された予測用のバウンディングボックスと呼ばれるアンカーボックスを用いてその画像と同じサイズのアンカーボックスを選び検出している。アンカーフリーでは、このアンカーボックスの数を減らすことで、全体的な処理スピー

ドを向上できる。

## 2.2 MiDaS について

Rene Ranftl ら [4] によって提案された MiDaS は、画像上の全画素分の視差を一度に推定（出力）することができるモデルである。また、従来の単眼深度推定の課題であるデータセットバイアスや異なる環境やシーンへのドメイン汎用性の低さという従来のモデルが抱えた課題を克服し、高いロバスト性と汎用性をも実現した。Rene らは、大量かつ多様な複数の深度データセットを統合させ、それらのデータセット間の学習バランスを最適にするため、マルチオブジェクト最適化を採用することで、データセットバイアスを打ち消し、異なるデータセットに対するロバスト性を向上させた。しかし、データセットが多様かつ多数であるために、各データセットの深度のスケール（奥行き単位）とシフト（カメラの基準点）の曖昧さが目立ってしまい、正確な絶対深度（カメラを基準とした物体の距離）を計ることが困難であった。そこでこれらの曖昧さを解決するために、スケールとシフトの曖昧さを調整し、最適に推測できるように損失関数を導入した。これにより、MiDaS は絶対的な物理距離ではなく、相対的な「視差」を推定するモデルとして構築された。視差は値が大きいほど物体は画像から近いことを表す。この関係性は逆深度に対応したものであり、実際に Rene らの論文でも視差と逆深度の関係性を示している。したがって、MiDaS が推測する出力値はスケールやシフトの影響を受けないデータの数学的解釈では「逆深度」に対応した視差である。本稿では、単眼深度推定モデルとして MiDaS を使用する。

## 2.3 物体認識を用いた予測に関する研究

徳丸ら [5] は、自転車事故における脇見運転や漫然運転によって引き起こされる前方不注意を防ぐために、物体認識・物体追跡を用いて障害物を認識し、移動先予測を経て衝突を予測するシステムを構築した。徳丸らの研究では、深度カメラに RealSense、物体認識のモデルで YOLO、物体追跡を可能とするモデルに DeepSORT を用いた。この研究の主なシステムは、まず RealSense により目の前の風景の RGB 画像と深度画像を取得する。次に小型 PC である Jeston を用いて YOLO を動作させ、YOLO の物体検出機能で障害物を検出する。その後 DeepSORT により障害物を追跡する。その中で、追跡している障害物がどこに移動するかを予測する。最後に、障害物の深度（奥行き）および移動先予測に基づき、あらかじめ設定された危険ゾーン内に障害物が存在する場合に警告する。この研究では MiDaS は用いられていないが、Realsense による深度画像と YOLO を用いた障害物認識という点では本稿と類似している。一方で、違いについては、研究対象や手法の違いである。徳丸らは自転車を対象として衝突予測システムを提案し、本稿では自動車、人、自転車を研究対象としている。また徳丸らはカメラを用いてリアルタイムに予測を行うが、本稿では、リアルタイムな処理を前提とせず、1 枚の夜間画像から運転者が不安を感じる物体を検出する。

小野ら [6] は、視界が悪い信号のない交差点での安全運転を

実現するために、車載カメラ映像からカーブミラー先の死角における交通状況を把握し、危険を予知する研究を行った。カーブミラーの検出器には AutoML、追従には IoUTracking、ミラー内の物体の検出には efficient-d7x を用いた。この研究の主な提案手法は、車載カメラ映像内のミラーを AutoML で検出し、efficient-7dx でミラー内の物体の特徴点を抽出し物体の有無を確認し、IoUTracking で物体を追従して危険の有無を確認した。小野らの研究と比較すると、カーブミラーを検出対象とする点で類似している。一方で、本稿ではカーブミラーを間接的に検出することで運転者が感じる不安要因を推定することができる点で異なる。これらの先行研究から、危険となる物体を検出して衝突や事故のリスクを予測するといった研究は多数存在する。しかし、不安感といった主観的感情と画像を用いた検出を組み合わせた研究は少ない。これを踏まえ、本稿の新規性は、危険となる物体や場所の検出ではなく、不安感という主観的感情を誘発させる要因を客観的な物体検出で見出す点である。

## 3 提案手法

本章では、YOLOv8 と MiDaS を用いた「車」、「人」、「自転車」に対する不安要因となり得る物体の検出手法とデータセットで学習させた新たなモデルとカーブミラーの相対的な位置を用いたカーブミラー周辺に存在する見通しの悪い地点の推定手法の 2 通りに分けて記述する。

### 3.1 「車」、「人」、「自転車」に対する不安要因となり得る物体の検出手法

まず、「車」、「人」、「自転車」に対する不安要因となり得る物体の検出手法の概要図を図 1 に示す。




図 1: 「車」、「人」、「自転車」に対する不安要因となり得る物体の検出手法

次に、YOLOv8 と MiDaS から得られた情報で不安要因を検出するタスクを 3 つに分けて説明する。また、提案手法の最終的な表示例として用いた入力画像のサンプルを図 2 に示す。

#### 3.1.1 タスク 1: YOLOv8 による検出

本稿では、物体検出モデルとして YOLOv8 を用いた。また、画像のみを使用するため、リアルタイム性よりも視界不良による検出精度を最優先に考慮し、精度と負荷のバランスを考えモデルサイズについては 2 番目に大きい m サイズをベースとし

た。実験方法について、まず YOLOv8m から、出力結果から検出した物体のクラスとバウンディングボックス座標 (BB 座標) を取得する。実際に YOLOv8m を用いた際の出力結果を図 3 に示す。図 3 では、確信度が 0.94 の車、確信度が 0.90 の人の検出に成功したので、車と人の BB 座標を取得する。

### 3.1.2 タスク 2: MiDaS による推定

関連研究から単眼深度推定モデル MiDaS の推測する視差とはスケールとシフトの影響を受けない逆深度に対応した相対的な値である。本稿では物体の相対的な距離間 (画像からの物体の近さ) を重視するため、本稿では特記がない限り、MiDaS から得られた相対的な値を逆深度値として解釈し扱うこととする。よって提案手法や評価実験では、評価指標として MiDaS の出力値は逆深度値と表現する。そこで、タスク 2 では、1 枚の入力画像から MiDaS を用いて推測を行い、逆深度値を出力する。その際に使う画像は図 2 のような入力画像である。実際に図 2 から MiDaS により推測した際の出力結果を図 4 (深度マップ) に示す。この深度マップは予測された出力値 (逆深度値) を 0 から 255 の範囲で正規化しグレースケール画像として可視化されたものである。図 4 から、出力値が大きいかほど明るい色で示され、値が小さいほど暗い色で示されることとなる。これは「値が大きいかほど物体が近くなる」という逆深度の性質を表し、この性質を生かし次節の不安要因の検出を行う。

### 3.1.3 タスク 3: 不安要因となり得る物体の検出

最後に、タスク 1 とタスク 2 で得られた情報から、サンプル画像中の不安要因検出を行う。

まずタスク 2 で得られた逆深度値と図 3 の車と人の座標 (位置) を使用する。具体的には、それぞれの車や人の BB 座標内に存在するすべての逆深度値を平均化した値を取得する。これを平均逆深度値と呼び、各平均逆深度値を持つ物体の中から最も手前に存在する物体が持つ平均逆深度値を最大平均逆深度値と呼ぶ。ただし「車」、「人」、「自転車」それぞれのクラスで独立して最大逆深度値を持っていることとする。

例えば図 2 なら、同じ走行方向に路上駐車している車と目の前に人が存在している。これらの平均逆深度値をとるとき、値は画像から近ければ近いほど値が大きくなるので、最大平均逆深度値を持つ車は路上駐車した車と目の前にいる人となる。

最後に、最大平均逆深度値と平均逆深度値を用いて検出を行う。具体的に、車を対象として不安要因となり得る物体の検出を行うとする。このとき最大平均逆深度値を持つ車の検出を行う際、最も手前にある物体は不安要因であると仮定したうえで必ず検出するものとする。さらに、その他の同じクラスに所属する物体 (車) が存在すれば検出方法は先ほどとは異なり、逆深度率を用いて検出を行う。逆深度率とは、各平均逆深度値を最大平均逆深度値を除いた値であり、各物体が最大平均逆深度値をもつ物体からどの程度離れているかを表す。逆深度率が高いほど物体は近いと判定し、低いほど遠いと判定する。さらに、判定する際手法では不安要因となり得る物体の検出に限定するために逆深度率の閾値を設ける。よって逆深度率がその閾値以上であれば検出し、閾値未満であれば検出しないものとする。車の検出が終了し、人や自転車についても検出する必要がある



図 2: サンプル画像



図 3: 出力結果




図 4: MiDaS による出力結果 (深度マップ)



図 5: 最終出力結果



図 6: 最終出力結果 (複数検出)

ば、次にそれらの検出も行う。今回はサンプル画像には人と車それぞれ 1 人、1 台ずつしか映っていないため、それぞれのクラス別で最大平均逆深度値を用いて検出するだけで終了した。検出のつけ方について、車は赤色、人は青色、自転車は緑色で囲んだ。そのときの最終的な出力結果を図 5 に示す。また、サンプル画像とは異なる画像を用いて、複数の人と複数台の車を検出した際の最終出力結果を図 6 に示す。

## 3.2 カーブミラー周辺の見通しの悪い地点の推定

カーブミラー周辺に存在する見通しの悪い地点 (遮蔽領域) の推定手法の概要図を図 7 に示す。図 7 を用いてデータセット作成、学習、推定の 3 つのタスクに分けて説明する。

### 3.2.1 タスク 1: データセット作成

まず、最初のタスクで既存の物体検出モデルをベースとした新モデルを生成するためのデータセットを作成する。本稿で使用するデータセットの中身はカーブミラーを映した画像データセット 241 枚とそれらの画像を拡張させたデータセットとの合計約 600 枚である。また本稿では、物体検出モデルの学習に用いる画像データセットとして、自身で独自に収集・アノテーションを行った画像群に加え、Roboflow 上で公開されている

他者作成のデータセット [7,8] を併用した。これにより、データの多様性と量を確保し、モデルの汎化性能向上を図った。

### 3.2.2 タスク 2: 学習

次に、タスク 1 で作成されたデータセットを用いて学習を行う。学習対象はカーブミラーとして、学習用、評価用、検証用のデータセットの比率を 8:1:1 とし、エポック数は 50、バッチは 16、画像サイズは  $1280 \times 1280$  と設定する。

### 3.2.3 タスク 3: 見通しの悪い地点の推定

最後に、タスク 2 で学習させた新モデルを使いカーブミラー周辺に存在する見通しの悪い地点の推定を行う。

まず、入力画像の中心点を取得する。なお、本稿では画像の原点を左上と定義しているため、下方向へ移動するほど  $y$  座標の値は大きくなるとしている。次に、画像内における真ん中の範囲を中央領域として定義する。定義方法として、画像の左端を基準 (0%) としたうえで右方向への水平移動距離を割合で指定した際に  $L$  (左境界) と  $R$  (右境界) により囲まれた領域を設定する。これが中央領域である。そして、カーブミラーの BB 座標  $(x_1, y_1), (x_2, y_2)$  に基づき、BB 座標の左右端である  $x_1$  と  $x_2$  が同時に中央領域内に含まれたときの推定方法と  $x_1$  と  $x_2$  のいずれかおよび両方が中央領域外に外れたときの推定方法の 2 通りに分けて説明する。  $x_1$  と  $x_2$  の両方が中央領域内に存在する場合、カーブミラーは画像中央付近に位置しているとみなし、画像の左右両端の場所を見通しの悪い場所として推定する。具体的には、画像幅を  $W$ 、画像高さを  $H$  としたとき、左右それぞれの推定位置の中心座標を  $(0.9W, 0.6H)$  (左寄り) および  $(0.1W, 0.6H)$  (右寄り) とし、BB 座標の横  $(x_2 - x_1)$  の長さの 3 倍を半径とした円で囲む。円の中心の  $y$  座標について、円の長さを考慮すると路面付近の死角となる場所を重点的に推定することができるため、 $0.6H$  と設定した。

一方、 $x_1$  または  $x_2$  のいずれかもしくは両方の座標が中央領域外に存在する場合は、カーブミラーの位置関係に基づいて見通しの悪い場所を推定する。具体的には、BB 内の中心座標を取得する。そして BB 内の中心点の  $y$  座標が画像中心点の  $y$  座標より小さい場合、取得した座標を用いて画像中心点を基準とした点対称移動を行う。逆に、画像中心点の  $y$  座標以上である場合には、画像中心点の  $x$  座標を軸とした線対称移動を行う。これらの対称移動によって得られた座標を、見通しの悪い場所の中心座標として設定する。その際、見通しの悪い場所の座標を中心点とし BB 座標の横  $(x_2 - x_1)$  の長さの 3 倍を半径とした円で囲む。また円のサイズについて、3 倍未満の場合画像によっては推定範囲が小さくなる可能性があり、3 倍より大きくなると推定範囲が大きすぎて視覚的に見にくくなる可能性があるため 3 倍とした。

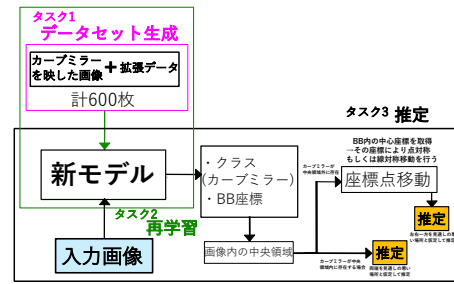


図 7: カーブミラー周辺の見通しの悪い地点の推定手法

## 4 評価実験

本章では、4.1 節で実際に人が不安だと感じる要因を明らかにすることを目的に実施したアンケート調査の概要とその結果、さらに 4.2 節では人が実際に不安だと感じた要因を提案手法がどの程度捉えることができるかを検証し、そのうえでパラメータの最良条件を求めめるために実施した評価実験を説明する。

### 4.1 アンケート調査

まず、アンケート調査の概要と実際の調査結果を示す。

#### 4.1.1 目的

夜間に運転をする人が夜間運転を想定して画像からどのような要因を不安に感じるかについて明らかにし、提案手法の正解データセットを作成させるための土台を作ることを目的とする。

#### 4.1.2 概要

次に、アンケート調査の概要について説明する。今回の調査では、運転者を対象とした研究であるため、運転免許証を所持した大学生および社会人の計 25 名を対象とした。次に、調査方法について説明する。25 名の協力者に 17 枚の夜間路上で撮影された画像を提示し、不安に感じる場所や物体を指摘し、マークをしていただいた。その後回答済みの結果を収集し、マークされた「車」、「人」、「自転車」、「見通しの悪い地点」に限定し、番号を振り分け、それぞれの番号で分けられた対象の不安認識率 (アンケート回答者のうち指摘した人の割合) を求めた。実際にアンケート調査で用いた画像を図 8 に示す。

#### 4.1.3 調査結果

アンケートの調査結果を図 9 に示す。

実際に分析した調査結果の集計を表 1 に示す。

### 4.2 実験方法

本稿では 2 種類の評価実験方法を説明する。

#### 4.2.1 評価実験 1

評価実験 1 では、「車」、「人」、「自転車」に対する不安要因となり得る物体の検出手法の評価実験を行う。扱う画像は図 8 の画像 1~11 である。また、「不安認識率の閾値」、パラメータとして「逆深度率の閾値」の 2 種類を使用し、これらの閾値を組み合わせて評価する。

- 不安認識率の閾値：100 %、75 %、50 % の 3 通り
- 逆深度率の閾値：40 %、50 %、60 % の 3 通り

表 1: アンケート調査結果

画像番号	項目番号	参加人数 (人)	指摘人数 (人)	認識率 (%)
画像 1	1	25	25	100
	2	25	2	8.00
画像 2	3	25	5	20.0
	4	25	13	52.0
	5	25	7	28.0
	6	25	10	40.0
	7	25	5	20.0
画像 3	8	25	24	96.0
	9	25	2	8.00
	10	25	8	32.0
画像 4	11	25	12	48.0
	12	25	22	88.0
画像 5	13	25	21	84.0
	14	25	18	72.0
	15	25	9	36.0
画像 6	16	25	23	92.0
	17	25	3	12.0
	18	25	11	44.0
画像 7	19	25	25	100
画像 8	20	25	17	68.0
	21	25	20	80.0
	22	25	5	20.0
画像 9	23	25	7	28.0
	24	25	22	88.0
	25	25	2	8.00
画像 10	26	25	21	84.0
	27	25	5	20.0
	28	25	2	8.00
画像 11	29	25	24	96.0
	30	25	2	8.00
	31	25	25	100
画像 12	32	25	18	72.0
	33	25	19	76.0
画像 13	34	25	4	16.0
	35	25	21	84.0
画像 14	36	25	14	56.0
	37	25	16	64.0
画像 15	38	25	22	88.0
	39	25	3	12.0
画像 16	40	25	16	64.0
	41	25	19	76.0
画像 17	42	25	12	48.0
	43	25	23	92.0



図 8: アンケート調査で用いた画像群

計 9 通りの 2 種類の閾値の組み合わせを作成し、各条件下での検出性能を評価する。評価を行うにあたり、アンケート調査結果と実験結果を照合して以下の 5 種類の指標を用いる。

- 検出成功率 (Recall / 再現率): 不安認識率が閾値以上の要因を正しく検出できた割合。
- 検出失敗率: 不安認識率が閾値以上の要因を検出できなかった割合。
- 過剰検出率: 不安認識率が閾値未満、または対象外の要因を過剰に検出した割合。
- 適合率 (Precision): システムが検出した全要素のうち、実際に不安認識率が閾値以上であった要因の割合。
- F1 値: 適合率と再現率により検出性能を総合的に評価する指標。

これらの指標を用いて、検出性能の変化を調べ、各不安認識率の閾値に対して最も検出性能が良い時の逆深度率の閾値を求め、さらに、全 9 通りの中から最も性能が高いときの組み合わせを決定し、その組み合わせで固定された際の画像 1 枚ごとの F1 値を算出する。

#### 4.2.2 評価実験 2

評価実験 2 では、カーブミラー周辺に存在する見通しの悪い地点の推定手法についての評価実験を行う。扱う画像は図 8 の画像 12~17 である。また、「不安認識率の閾値」、パラメータとして「中央領域の閾値」の 2 種類を使用し、これらの閾値を組み合わせで評価する。

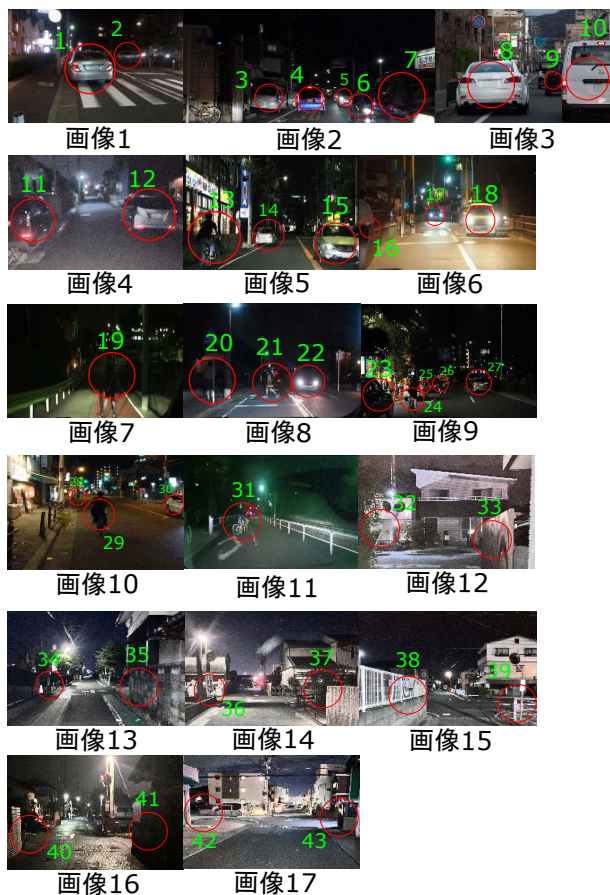


図 9: 調査結果

- 中央領域の閾値 ( $L, R$ ): (35, 65), (40, 60), (45, 55), (50, 50) の 4 パターン
- 不安認識率の閾値: 100%, 75%, 50% の 3 通り  
計 12 通りの 2 種類の閾値の組み合わせを作成し、各条件下での推定性能を評価するまた、評価を行うにあたりアンケート調査結果と実験結果を照合して 5 種類の指標を用いる。
- 推定成功率 (Recall / 再現率): 不安認識率が閾値以上の地点を正しく推定できた割合。
- 推定失敗率: 不安認識率が閾値以上の地点を推定できなかった割合。
- 過剰推定率: 不安認識率が閾値未満、または対象外の地点を過剰に推定した割合。
- 適合率 (Precision): システムが推定した全要素のうち、実際に不安認識率が閾値以上であった地点の割合。
- F1 値: 適合率と再現率により推定性能を総合的に評価する指標。

これらの指標を用いて、推定性能の変化を調べ、各不安認識率の閾値に対して最も推定性能が良いときの中央領域の閾値を求める。さらに、全 12 通りの中から最も性能が高い時の閾値の組み合わせを決定し、その組み合わせで固定された際の画像 1 枚ごとの F1 値を算出する。

ここで評価実験 1, 2 に共通して、不安認識率が閾値以上である要素を検出した回数  $TP$ 、不安認識率が閾値未満であるまたは振り分けられた番号以外の要素を検出した回数  $FP$ 、不安

認識率が閾値以上である要素を検出できなかった回数  $FN$  と定義し、適合率と再現率は式 (1), (2) で表される。

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

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

さらに、F1 値は式 (3) で表される。

$$F1 = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall} \quad (3)$$

また本稿では、不安要因でない物体 (アンケートで指摘されたが閾値未満の不安認識率を持つ物体と指摘されなかったが実際に検出された物体) を正解データと定義しないこととする。

## 5 実験結果と考察

本章では評価実験 1, 2 で得られた実験結果と考察を示す。

### 5.1 評価実験 1

#### 5.1.1 実験結果

逆深度率と不安認識率の閾値の組み合わせを変えたときの性能結果を表 2、逆深度率の閾値を変化させた際の実験結果を図 10 に示す。表 2 の実験結果から、100%, 75%, 50% のときのすべての不安認識率の閾値に対して逆深度率を変化させた際、100% のときは検出成功率は 100% のまま変化しなかったが、75% と 50% のときは検出成功率が下がることが確認できた。同時に過剰検出率と F1 値については、過剰検出率は逆深度率を上げると減少し、F1 値は増加することが示された。この結果から、100%, 75%, 50% のときのどの不安認識率に対しても、パラメータの最良条件は 60% であることが確認できた。さらに表 2 から、不安認識率と逆深度率をセットした全 9 通りの組み合わせの中から、最も性能が良いとき (検出成功率が高く、過剰検出率を抑え、さらに F1 値が最大するとき) の閾値の組み合わせは不安認識率が 50%、逆深度率が 60% のときであることが示された。そこで、不安認識率を 50%、逆深度率を 60% で固定し、画像 1 から 11 までのそれぞれの画像に対する適合率、再現率、F1 値を算出した。その結果を表 3 に示す。表 3 の結果から、画像 1, 7, 11 に関しては値は 1.00 となり、逆に画像 2, 9 に関しては F1 値が顕著に低くなることが確認できた。表 3 から、適合率の低さが F1 値を大きく下げる原因となった。

#### 5.1.2 考察

表 2 の結果から、それぞれの不安認識率ごとに結果を見てみると、逆深度率を上げるほど検出成功率は下がるが過剰検出率も下がることが分かり、F1 値は増加することが確認できた。また逆深度率が 60% のときがパラメータの最良条件であることも示された。このような結果から、どの不安認識率の閾値に対しても、画像から距離が近い物体に絞ったときの検出方法が検出性能が良くなると考えられる。しかし、どの不安認識率の閾値でも最良条件を含め逆深度率を変化させたところで、過剰検出率は依然として高いことが確認できた。原因としては、モデ



図 10: 逆深度率変化に伴う検出結果の比較 (左: 40%, 中央: 50%, 右: 60%)



図 11: 中央領域変化に伴う推定結果 (左上: (35, 65), 右上: (40, 60), 左下: (45, 55), 右下: (50, 50))

表 2: 実験結果 (評価実験 1)

不安認識率 (%)	逆深度率 (%)	検出成功率 (再現率)	検出失敗率 (%)	過剰検出率 (%)	適合率 (%)	F1 値
100	40	100	0	89	9	0.16
	50	100	0	85	10	0.18
	60	100	0	72	12	0.21
75	40	91	9	89	28	0.43
	50	82	18	88	29	0.43
	60	82	18	71	35	0.49
50	40	93	7	88	37	0.53
	50	86	14	86	39	0.53
	60	79	21	71	42	0.55

表 3: 画像 1~11 に対する適合率, 再現率, F1 値の結果

画像番号	適合率 (%)	再現率 (%)	F1 値
画像 1	100	100	1.00
画像 2	17	100	0.29
画像 3	33	100	0.50
画像 4	50	100	0.67
画像 5	50	50	0.50
画像 6	33	100	0.50
画像 7	100	100	1.00
画像 8	50	50	0.50
画像 9	33	50	0.40
画像 10	50	100	0.67
画像 11	100	100	1.00

ルが不必要な物体 (不安認識率が閾値未満の物体と番号以外の物体) を多数検出してしまっているためであると考えられる。実際に図 10 の検出結果から, 画像 2 ではほとんどの物体は不安認識率が 50% 未満なのに関わらず検出し, 番号が振り分けられていない右の自転車や画像 3 における右の白い車に乗車している人を (a), (b), (c) の全パターンで検出した。このような過剰に検出した結果が検出性能を阻害する原因となったと推察する。また表 3 から, 図 10 の画像 1, 7, 11 のような情報量が少ないもしくは視覚的占有率が強い画像の場合, 不安要因の候補

となる物体を比較的容易に絞り込むことができるため, F1 値が高くなる一方, 逆に画像 2, 9 のような情報量が多い画像の場合は不安要因の候補となる物体が 1 枚の画像に多数存在するため, 手法が不安要因となる物体を絞り込むことが難しく過剰に検出するケースが多くなる。そのため, F1 値が低くなると考える。したがって, これらの結果および考察から, 本稿の提案手法は不安要因でない物体の過剰検出や情報量が多く複雑な画像に対する検出精度の低さが課題であり, これらの課題に対する対策を打つ必要がある。具体的な対策として, 最大平均逆

深度値もしくは逆深度率から検出された物体について、その物体が真の不安要因であるかどうかを判断する機械学習により生成されたモデルを利用する。具体的な学習としては、アンケート調査で得られた各物体の「不安認識率」をラベルとし、その物体の種類や位置、状況そして距離感をデータ化したものを特徴量としてデータセットで扱う。つまり、提案手法により不安要因となり得る物体を1度検出し、さらに学習済みのモデルにより真の不安要因かどうかを決める2段階検出で検出精度を上げることが可能であると考えられる。また今回は「車」、「人」、「自転車」のすべてを検出するような手法だったため、夜間でも比較的に見やすい物体でそこまで不安要因にならない物体までも検出していたことが実験結果で明確になった。したがって他の対策として、例えば「黒色の服を着た人」や「黒い車」のような夜間では発見しづらい物体に限定して検出するといった手法を用いて比較実験を行うことで検出精度が改善する傾向がみられると考える。さらに、今回は不安認識率の閾値の下限を50%に、逆深度率の閾値の上限は60%に限定して実験を行ったため、それぞれの閾値を50%未満及び60%以上にしたときの結果についても考察する。実際に不安認識率の閾値を50%未満に下げると、それまで不安要因でなかった物体が正解データとして扱われるため、そのデータ数が増える。つまり、不安認識率の閾値を50%未満に下げたときにTPが大きくなる。一方で、逆深度率の閾値を60%以上に引き上げることで過剰検出率を下げるのが期待できる。これらの根拠から、不安認識率及び逆深度率の閾値を変えた場合、検出成功率や過剰検出率、さらにF1値といった各検出性能、パラメータの最良条件が変化すると考えられる。

## 5.2 評価実験2

### 5.2.1 実験結果

中央領域と不安認識率の閾値の組み合わせを変えたときの性能結果を表4、中央領域を変化させた際の出力結果を図11に示す。表4から、不安認識率の閾値が100%の場合は、すべての画像において不安認識率100%の場所が存在しなかったため中央領域を変化させても推定成功率が0%であることが確認できた。そのため、最良条件といえるパラメータは存在しない。次に不安認識率の閾値が75%と50%のとき、中央領域の範囲を広めると、過剰検出率は増加するが値は抑えつつ、推定成功率やF1値は増えていくことが確認できた。またF1値については、不安認識率が75%のときの最大値は0.77、50%のときの最大値0.83であるため、不安認識率の閾値が75%、50%のときの最良条件となるパラメータは $(L, R) = (35, 65)$ のときであると示された。

そして、不安認識率の閾値と中央領域の閾値の全12通りの組み合わせの中で、F1値が最大であり、過剰推定率が低く、推定成功率を高く維持している組み合わせは不安認識率が50%、 $(L, R) = (35, 65)$ のときであった。そこでこれらの組み合わせを用いて、画像12~17までのそれぞれの画像に対する適合率、再現率、F1値を算出した。その結果を表5に示す。表5から、それぞれの画像に対して、F1値は高い場合が多いことが示さ

表4: 実験結果 (評価実験2)

不安認識率 (%)	中央領域 (L,R)	推定成功率 (再現率)	推定失敗率 (%)	過剰推定率 (%)	適合率 (%)	F1 値
100	35,65	0	0	67	0	0.00
	40,60	0	0	58	0	0.00
	45,55	0	0	50	0	0.00
	50,50	0	0	33	0	0.00
75	35,65	100	0	43	63	0.77
	40,60	80	20	43	57	0.67
	45,55	80	20	29	67	0.73
	50,50	60	40	33	60	0.55
50	35,65	78	22	33	88	0.83
	40,60	67	33	33	86	0.75
	45,55	67	22	0	100	0.80
	50,50	44	56	40	67	0.53

表5: 画像12~17に対する適合率、再現率、F1値の結果

画像番号	適合率 (%)	再現率 (%)	F1 値
画像12	100	50	0.67
画像13	100	100	1.00
画像14	100	50	0.67
画像15	100	100	1.00
画像16	100	100	1.00
画像17	50	100	0.67

れたため大きな課題点は特に見られなかった。しかし、所々適合率や再現率が50%になるところは確認できた。

### 5.2.2 考察

提案手法では、運転者が不安に感じている見通しの悪い場所を比較的推定できたと考えられる。その中で $(L, R) = (50, 50)$ は中央領域を設定しないのと同義である。中央領域の有無に関して比較すると、領域なしより領域ありのほうが過剰検出率を抑えつつ、推定成功率とF1値を比較的高く維持できる。したがって、100%以外のどの不安認識率の閾値に対しても、中央領域は範囲を広く設定することで性能が良くなると考えられる。実際に図11の画像16、17に関して、他の中央領域((a)、(b)、(c))では両端もしくははづれかの端の場所を推定したのに対し、(d)の時の中央領域では失敗しており、何もない路上を推定したことが分かる。これが推定成功率を下げ、失敗率を上げている原因であると考えられる。評価実験2に対して、75%、50%の時点でF1値が比較的高いため、不安認識率の閾値を50%未満に下げた際、正解データは少し増えると考えられるため、F1値は微増すると考える。

次に表5から、適合率と再現率が所々50%と低い箇所が見られた。提案手法はカーブミラーが左右どちらかに存在する場合その反対側の見通しの悪い場所のみしか推定できない。このような提案手法の限界により、図9の画像12、13、14、15の番号32、34、36、39のようなカーブミラーの位置関係に依存しない場所が推定できず、適合率または再現率を下げる原因となったと考える。つまり、カーブミラーの位置関係に依存した場所しか推定できないことが評価実験2の結果で得られた課題

である。この課題について、カーブミラーの位置関係に依存しない場所を推定することができれば手法の性能や F1 値は上がると考える。しかし、それぞれの場所がもつ不安認識率は異なり定められた閾値により不安要因かどうかが変わるため、この変動性にもしっかり対応した手法を考えなければならない。具体的な対策として、セグメンテーションと機械学習により生成されるモデルの 2 段階判定を用いることで性能が高まると考えられる。例えば、表 1 の画像番号 12 から項目番号 32 については、不安認識率が 72 % と比較的の不安認識率が高い場所を現在の手法では推定できない。そのため、今の手法では推定できない場所についてはセグメンテーションにより抽出し、その抽出した位置が真の不安要因かどうかを学習済みモデルで判定することで課題を克服できると考える。具体的に、見通しの悪い場所に関して運転者がその場所に関してどう感じており、どうい影響を及ぼすのかといった特徴量をデータセットして機械学習させ、モデルを生成する。そのモデルの判断で最終的な不安要因となる見通しの悪い場所のみの検出を行う。

## 6 おわりに

本稿では、「車」、「人」、「自転車」に対する不安要因となり得る物体の検出とカーブミラーの相対的な位置を利用した見通しの悪い地点の推定手法を提案した。これらの手法を用いて、不安認識率の閾値ごとの性能評価を行いながらパラメータの最良条件を探索した。さらに、最良な不安認識率の閾値とパラメータの組み合わせを一組選び、画像別に手法の精度についても検証を行った。まず、物体の検出手法については、どの閾値でもパラメータ（逆深度率）を上げるほど徐々に検出性能が上がる事が確認できた。よって、画像から近い物体に絞って検出する方法が検出性能が高くなる事が示された。しかし、画像別の精度に関しては複雑な画像ほど適合率が悪くなり結果として F1 値が悪化することから、過剰検出が多いことが本手法の課題となった。次に、見通しの悪い地点の推定手法については、画像の中央領域を設定するほど推定性能が向上することが確認できた。しかし、本稿の推定方法はカーブミラーの位置関係を利用した推定のみで留まっており、位置関係に依存しない地点やカーブミラーが近くにない地点の推定は困難であるため今後の課題として残ることとなった。

したがって、「車」、「人」、「自転車」に対する不安要因となり得る物体の検出手法、カーブミラーとの相対的な位置関係を利用した見通しの悪い場所の推定手法は運転者が感じる不安要因を検出することが可能であると示された。今後の課題として、不安認識率の閾値やパラメータの範囲を変化させ、アンケート調査の規模を拡大させたときの性能変化やパラメータの最良条件の探索を検討する。特にアンケート調査に関しては、画像から不安要因となる物体に丸を付けるだけの作業だったため、今後は追加で物体に丸を付けた理由も回答してもらい、5 段階評価にして不安の度合いをもっと細かく明確にしていく。これにより物体の特徴量を抽出することができ、物体が不安要因かの有無に対して高性能なモデルを生成できると考える。そして

「車」、「人」、「自転車」を対象とした検出手法では、単眼深度推定モデルは MiDaS を用いたが、ほかにも Deep-Anything、Deep Pro などが存在する。そこで MiDaS 以外のモデルも採用し、実際に評価実験を行い、それぞれのモデルを用いることで提案手法の性能変化がどのようになるのかという比較実験も検討していく。

さらに、「車」、「人」、「自転車」に関する不安要因の検出手法はさらなる性能の改善が必要であると考えた。具体的に、検出方法を「最大平均逆深度値」・「逆深度率」および機械学習により生成された真の不安要因を決めるモデルで 2 段階検出をすることで提案手法の課題を解決し、より信頼性のある検出手法に改善していく。またその他に「黒色の服を着た人」や「黒い車」のように夜間では見にくくなる物体に限定して検出する手法を提案し、本稿の提案手法と比較実験を行い検出性能の改善見込みがあるかを評価していく。また、カーブミラーの位置関係を利用した推定手法については、カーブミラーの位置関係に依存しない場所をセグメンテーションにより抽出し、学習済みモデルで 2 段階判定をする手法も検討していく予定である。最後に、本稿の成果を社会に活用する具体的な技術的活用として、実際の走行環境で不安要素を検出し、その要素に対して運転者に適切な注意喚起を行う支援システムが構築可能となる。このシステムにより運転者の不安・怖いといった精神的な負担を軽減できると考えられる。このような技術的活用は、夜間走行に不安を抱く人や運転に慣れていないペーパードライバー等の夜間運転に対する苦手意識の克服に寄与する。その結果、ドライバー人口の維持や増加が期待でき、ひいては自動車産業の持続的な発展も期待できる。

## 文 献

- [1] CLUT, “夜の運転が怖いあなたへ！夜の危険を回避する安全運転の 4 つのポイントを解説,” <https://clutch-s.jp/p000833/> (参照 2025-11-23).
- [2] 保田 敬一, 白木 渡, 井面 仁志, “夜間車両走行時の快適性評価,” 特集「道路走行時の快適性に影響する要因と快適性向上策」, Vol.22, No.3, pp.138-143 (2024).
- [3] Muhammad Hussain, “YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection,” *Machines*, Vol.11, No.7, 677 (2023).
- [4] René Ranftl, Katrin Lasinger, David Hafner, Konrad Schindler, Vladlen Koltun, “Towards Robust Monocular Depth Estimation: Mixing Datasets for Zero-shot Cross-dataset Transfer,” arXiv:1907.01341 (2020).
- [5] 徳丸 拓希, 山口 暢彦, 福田 修, 奥村 浩, “物体認識を用いた自転車運転時の衝突予測システム,” 日本知能情報ファジィ学会 ファジィシステムシンポジウム 講演論文集, Vol.37, No.0, pp.211-214 (2021).
- [6] 小野 晋太郎, 日野 裕介, 須田 義大, 板垣 紀章, “走行中の車載カメラとカーブミラーによる死角の危険予知,” 生産研究 (Journal of Institute of Industrial Science, University of Tokyo, Vol.74, No.1, pp.123-128 (2022).
- [7] iniad, curve-mirror\_20241129 Computer Vision Model, Roboflow, [https://universe.roboflow.com/iniad/curve-mirror\\_20241129](https://universe.roboflow.com/iniad/curve-mirror_20241129) (参照 2025-10-15).
- [8] Murata Eri, mirror Computer Vision Dataset, Roboflow, <https://universe.roboflow.com/murata-eri/mirror-y19fz> (参照 2025-10-15).