

将来の自動運転に向けた列車前方監視用AIにおける判断ミスの要因推定手法



長峯 望
Nozomi Nagamine
情報通信技術研究部
画像解析研究室長



合田 航
Wataru Goda
情報通信技術研究部
画像解析研究室
研究員

はじめに

鉄道業界においてもAI（人工知能）の活用が進んできています。AIとは、人間が行うような判断や認識をコンピューターに行わせる技術のことです。例えば、列車の前方をカメラなどで監視して障害物などを検知できれば、列車運行の安全性向上につながりますが、画像処理技術だけでなく、AIを活用すると、検知性能を格段に向上させることができます。

しかし、AIには「ブラックボックス性」という課題があります。これは、AIがどのように判断したのかが外からわかりにくいという特性

のことです。例えば、AIが誤って障害物を見逃した場合、そのようなミスが起きた要因を推定することは簡単ではありません。そこで、この課題に対応するため、AIの判断ミスを「入力画像」「AIの構造[※]」「学習データ」の3つの観点から調査する方法を開発しました¹⁾。この手

※ AIの構造

AIは構成するニューラルネットワークの層の種類や深さ、幅の違いによってさまざまな種類があります。それらを称してここではAIの構造と呼んでいます。




図1 列車前方監視システムの例

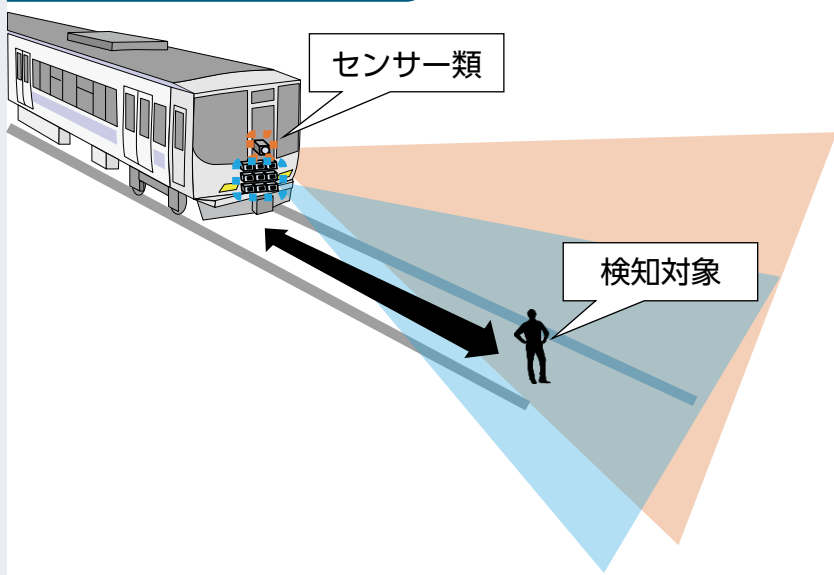
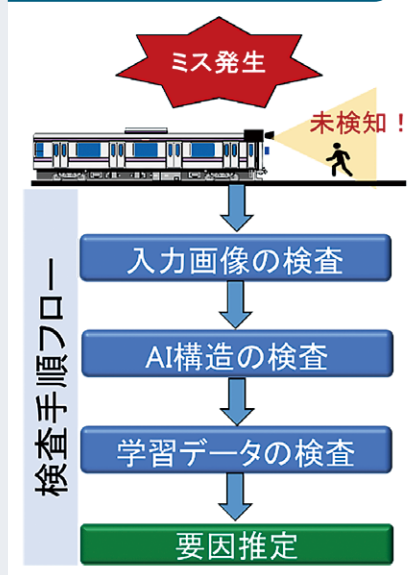


図2 判断ミスのトレース手順



法は、列車の自動運転における列車前方監視システムなど、安全性が特に重要視される分野へのAI導入に役立つと期待されます。

前方監視におけるAIの判断ミスの要因推定手法の概要

AIを使っている列車前方監視システムは、カメラやセンサーで前方の状況をセンシング（撮影）し、その情報をAIが判断します（図1）。AI判断を誤る例として、障害物がないのに障害物をありとしてしまう「誤検知」と、障害物があるのに障害物をなしとしてしまう「未検知」がありますが、ここでは安全により影響を及ぼす可能性が高い未検知を対象とします。AIがなんらかの理由によって、誤って障害物を見逃してしまう場合に、事態を未然に防いだり、見逃しが発生した際の要因を推定するために、本研究ではAIの判断ミスの要因を推定する手法を開発しました。

この手法は、①入力画像の検査、②AI構造の検査、③学習データの検査という3つの段階で判断ミスの要因を調べます（図2）。たとえば、入力画像の検査ではカメラの設定や撮影環境に問題があるかもしれません。AI構造の検

査では、AIの設計や仕組みに要因がある可能性があります。そして、学習データの検査では、AIが学習したデータが偏っていることが影響していることがあります。

これらを検査することで、問題点を特定し、適切な改善策を講じることが可能になります。

入力画像の検査手法

AIが正しい判断をするためには、カメラで撮影した画像の品質が非常に重要です。しかし、撮影環境やカメラの設定によっては画像の質が適切ではなく、AIが間違った結果を出すことがあります。こうした問題に対応するために、画像の品質を変化させながらAIの動作を確認する手法を開発しました。

具体的には、カメラ設定に関わる明るさやコントラスト（画像の色の濃淡の差）、ホワイトバランス（色の調整）、ピンボケ（焦点が合っていない状態）など、10種類の要因を検査します。例えば、撮影した画像が暗すぎる場合に、明るさを調整してAIが正しく障害物を検知するかを確認します。このようにして、カメラ設定が判断ミスの要因かどうかを突き止めることができます（図3）。

図3 入力画像の検査の例



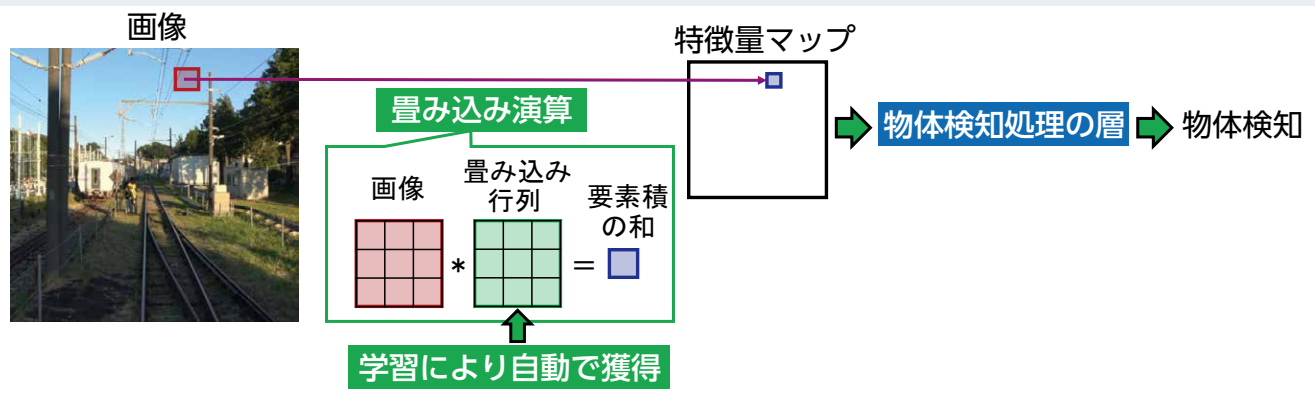


図4 CNNによる物体検知のイメージ

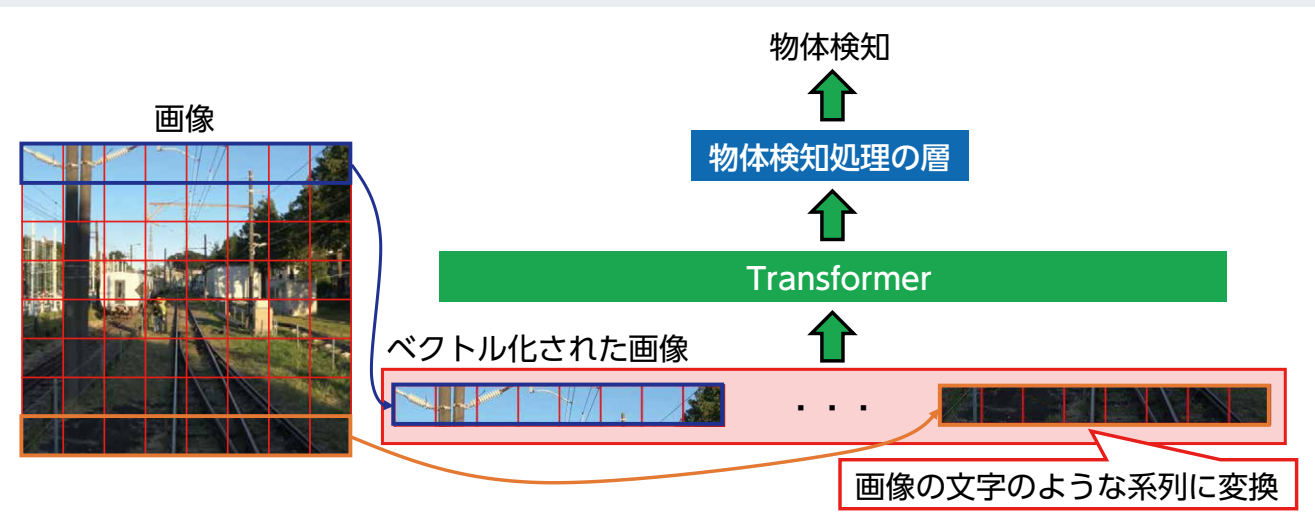


図5 Transformerによる物体検知のイメージ

この方法によって特定できる要因は、カメラ設定を変更するだけで問題が解決できる場合が多く、迅速な対応が可能です。

AI構造の検査手法

AIの判断には、その設計や仕組み（構造）が大きな影響を与えます。そこで、代表的なAI構造である「CNN（畳み込みニューラルネットワーク）」^④（図4）」と「Transformer」^⑤（図5）」の特性を比較し、それぞれの判断ミスの要因を推

定する手法を開発しました。この違いによって、特定の条件下ではどちらのAI構造が適しているかが変わる場合があります。そこで、同じ画像を異なる構造のAIで解析し、どちらが正解の結果を出せるかを確認します。この比較により、適切な構造を選び出すことが可能となります。これにより、AIの設計を見直すことで、判断ミス（見逃し）のリスクを大幅に減らすことが期待されます。

学習データの検査手法

AIが正しく判定するためには、十分な質と量の学習データが必要です。しかし、学習データが偏っていると、AIは一部の状況下では正しく判断できなくなることがあります。そこで、学習データに偏りや不足がないかを検査する手

④ CNN（畳み込みニューラルネットワーク）

画像の細かい特徴（たとえば、線や形状）を重点的に分析するのに優れたAI構造です。

⑤ Transformer

画像全体を俯瞰的に捉え、広い範囲で特徴を見つけることに優れたAI構造です。

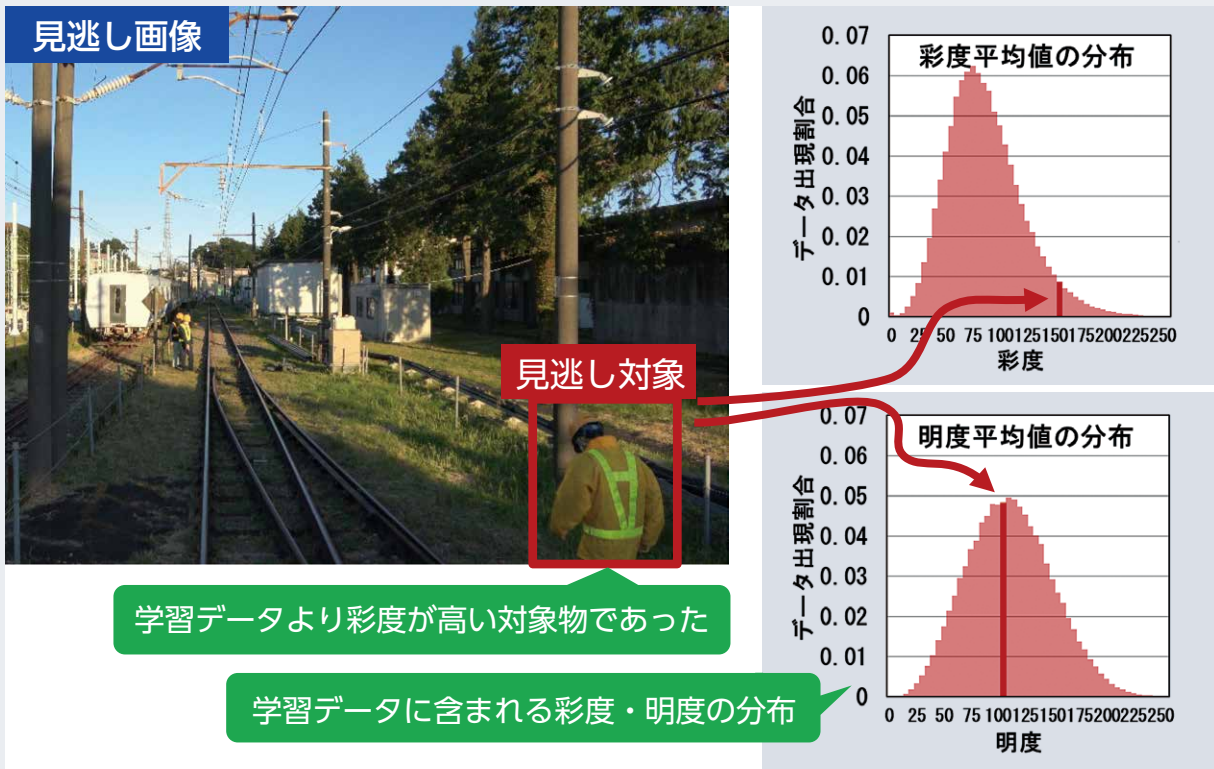


図6 特徴分布による学習データの検査の例

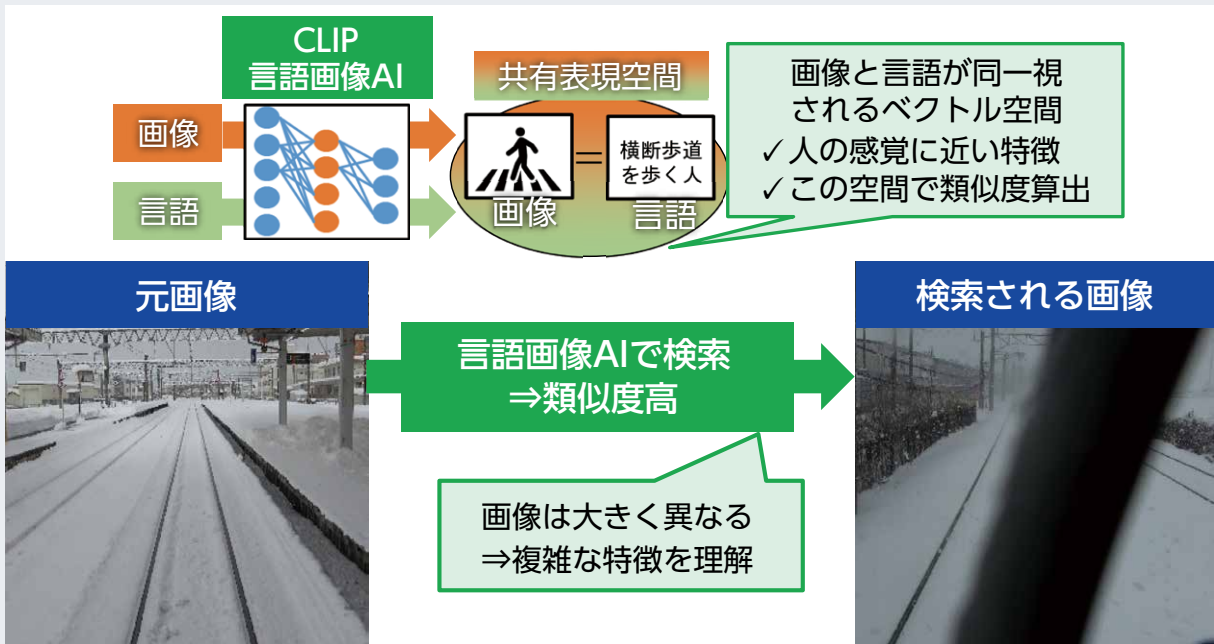


図7 言語画像AIによる類似画像検索の例

法を開発しました。

この方法では、まずAIが見逃した画像の特徴を抽出し、それを学習データの特徴分布と比較します。例えば、学習データに特定の色や形状のデータが少なかった場合、それが要因で判断ミスが起きていると推定できます(図6)。ま

た、「CLIP」と呼ばれる言語画像AIを使い、見逃した画像に似たデータが学習データ内にどの程度含まれているかを調べます。CLIPは、人間が感じるような「似ている」という感覚をAIが判断することを可能にする技術です(図7)。

これにより、どのようなデータが不足してい


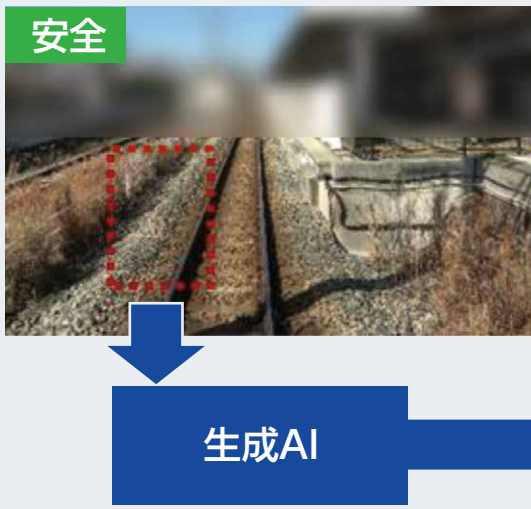


図8 生成AIによる危険画像生成の例


るのかを明確にし、新たなデータを追加するなどの対策が可能となります。

判断ミスの要因推定手法の評価

提案した要因推定手法の性能を確認するため

に実験を行いました。まず、列車前方の画像に対して画像生成AIを使って人物を描くことで危険な状況を模擬した画像を約75,000枚作成しました(図8)。その中で、AIが見逃した画像が2,668枚ありました。これらの画像に対し、

図9 入力画像の検査による判断ミスの推定の例



提案手法を適用しました。その結果、すべての画像で判断ミスの要因を推定できることが確認されました。たとえば、明るさやズームを調整した結果、AIが正しく検知できたものについてはカメラ設定に問題があったと判断されました(図9)。また、AI構造を変えることで認識ができるようになったものは、その構造が判断ミスの要因と推定できました(図10)。さらに、学習データの分布を調べた結果、特定の特徴を持つ画像が不足していることが判明しました。

この評価によって、提案手法が実用的であり、AIの判断ミスの推定と改善策を立てる上で効果的であることを確認しました。

おわりに

本研究では、列車前方監視AIが判断ミスをした際の要因を推定する手法を開発しました。この手法は、「入力画像の検査」「AI構造の検

査」「学習データの検査」の3段階で要因を分析するもので、すべての判断ミス画像について要因の推定が可能であることを確認しました。また、AI開発を支援する学習データ管理基盤システムを構築しました。テキストによるデータ検索や条件内訳の機能を実装し、学習データの管理や改良に役立つことを確認しました。このシステムは、AIの透明性を高め、鉄道業界におけるAIのさらなる活用を推進し、将来的には、自動運転やメンテナンスの分野におけるAI技術の発展に貢献することが期待されます。

RRR

文献

- 1) 合田航, 長峯望: 列車前方監視におけるAIの判断ミスの要因推定手法, 電気学会研究会資料, TER-83-85, pp.13-18, 2024

図10 AI構造の検査による判断ミスの推定の例

