

鉄道一般
車両
施設
電気
運転・輸送
防災
環境
人間科学
浮上式鉄道

画像技術により 鉄道の運行を支援する



鵜飼 正人
Masato Ukai

信号・情報技術研究部
画像・IT研究室長

[専門分野] 画像処理, 画像認識, 情報処理

近年の画像技術の進歩には目を見張るものがあります。また、目覚ましい発展を見せている深層学習(☞参照)も、画像処理の代表的な用途である異常検知、分類、セグメンテーション、物体認識などで従来を上回る性能を示すことが報告されています。鉄道においても、設備の異常検知やメンテナンス、さらには安全監視の分野を中心に、人間の視覚に頼って行われてきた業務を省力化、高精度化する目的で画像技術の活用が進んでいます。ここでは、鉄道の運行を支援する画像技術の活用事例について、深層学習の適用内容とあわせて紹介します。

はじめに

ここ何年か「見える化」や「可視化」という言葉をよく耳にします。一般に画像データは「見る」ことができるわけですが、ここで言う「見える化」や「可視化」は、物理的に形をなすものを見えるというより、もう少し踏み込んで「見えにくいものを見やすい状態にする」、「これまで見えなかったものを見えるようにする」、「正常な状態と異常な状態を客観的に把握できるようにする」などの意味で使われています。鉄道においては、状態の判断や保全計画の策定などの場面で、主観的な判断や経験に頼るケースが少なくありません。ベテラン作業員の技術伝承が問題となっていますが、まさに「暗黙知の見える化」がポイントとなっています。

画像によるトンネル覆工面検査

(1) 深層学習によるひび割れ検出

鉄道総研ではトンネル覆工面に発生するひび割れを自動的に検出する画像処理手法の開発を進めています。トンネル覆工を撮影した画像の大部分はひび割れのないきれいな覆工面とケーブルや目地などの地物が映った部分になります。これら大部分の領域を背景として正しく認識できればひび割れの誤抽出を減らすことができます。ノイズ除去に深層学習を適用したところ、学習済みモデルの正解率は90%以上となりました。さらに、ひび割れありと判定された領域に対して、ひび割れの幅や長さなどを精度よく計測する実用的なひび割れ検出手法を開発しました¹⁾(図1)。

深層学習の学習モデル構築時にはGPU(☞参照)の活用が作業効率を高める上で有効です。GPUはCPUの何十倍、場合によっては何百倍もの速度で計算が完了するので、深層学習を使っていく上で、実質GPUは必要不可欠な部品といえます。ただし一般的にGPUは高価なため、実行するPCごとにGPUを用意するのは現実的ではありません。そこでひび割れ検知プログラムをWeb上から利用できるクラウドサービスを検討しています。学習モデル作成と認識実行はクラウド上のハイスペックなGPUで動作させます。サービス利用者はトンネル覆工面の画像をクラウドにアップロードすることで、1スパンあたり1分程度でひび割れを検出することができます(図2)。

☞ 深層学習

深層学習は、人間の脳の神経回路をモデルにしたニューラルネットワークを多層にした機械学習(☞参照)の一手法で、より複雑な分類や最適な予測を行うことができます。機械学習との違いは、コンピューターが自律的に法則やルールを見つけ出し、有用な特徴量を学習することです。一方で、正しく学習させるためには大量の学習データが必要で、学習に時間がかかるといった特徴があります。

☞ 機械学習

大量のデータを反復的に学習することでパターンやルールを発見し、高度な判別や予測を可能にする技術です。学習方法は、教師あり学習、教師なし学習、強化学習に大別されますが、ここで使用されるアルゴリズムにはさまざまなものがあります。機械学習では「色」や「形」のように着目すべき特徴は人間が指定する必要があります。

☞ AI

Artificial Intelligenceの略で、人工的に作られた人間のような知能、ないしは知的な振る舞いをさせようという取り組みやその技術です。究極には人を超えていくものも想像されています。またAIは、機械学習や深層学習を包括する概念です。

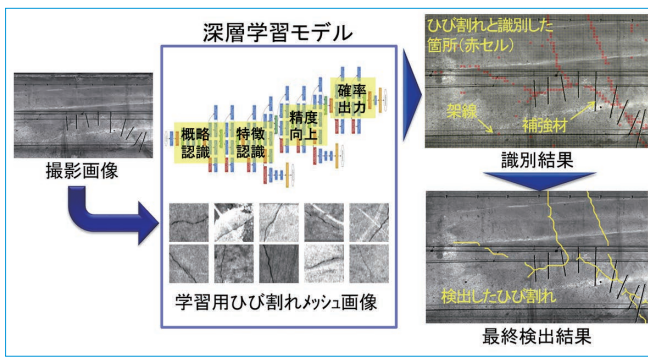


図1 深層学習によるひび割れ検出




図3 ひび割れありと判定された画像のGrad-CAM結果

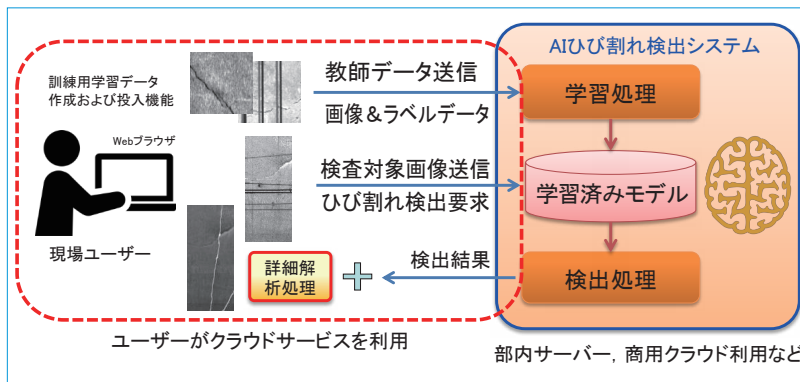


図2 クラウドサービスによるひび割れ検出の手順




図4 誤判定した時のGrad-CAM結果

(2) 深層学習を適用する上での課題

深層学習では、人間が処理の手順を考える代わりに、画像と教師データ(正解)をセットで与えることで、脳の神経細胞の結合強度に相当するニューラルネットワークの結合重みなどが自動的にチューニングされます。この何万何十万個にも及ぶパラメーターは取り出すことはできますが、なぜAI(☞参照)がそのような判断を下したかは説明できないため、ブラックボックスという表現が使われます。判断プロセスがブラックボックスの状態でききなり結論だけが出てくるというのでは、業務によっては適用を見送らざるを得な

くなります。「説明可能なAI」という判断根拠を明らかにする研究も進められていますが、「なぜそう判断したのか」が解明されるまでにはまだ時間がかかるものと思われます。そこで、実際の業務で深層学習を適用していく際には、「AIはどこを見て判断したのか」を説明できる機能が求められます。誤検知、誤判定が起こってしまった場合に、どの部分を見て判断したのかが可視化できれば、正しく学習できているかどうかを知ることができます。

(3) 判断箇所の可視化

深層学習が画像中のどこを見て判断しているかを可視化する方法にGrad-

CAM²⁾という手法があります。ひび割れ画像全体に微小変化を加えた時に、ひび割れ判定に与える影響が大きい画像箇所は確率スコアの微分係数も大きくなることに着目した手法です。まず、ひび割れありと判定された画像の可視化結果を図3に示します。上が入力画像、下がGrad-CAMによる可視化結果です。赤く色づいている部分が、スコアに強く影響を与えている領域です。背景と輝度差があるひび割れの中心とそのエッジ部分、さらにその周辺に着目していることがわかります。次に、ひび割れを背景と誤判定した画像の可視化結果を図4に示します。比較のためにひび割れありと背景の両方のヒートマップ(☞参照)を示しますが、ひび割れのヒートマップでは赤枠部分のひび割れ箇所はまったく色づいていないのに対し、背景のそれでは汚れやケーブルなどひび割れ以外の部分が色づいています。画像中のケーブルや黒っぽい汚れに反応して背景と判断したことがわかります。

☞ CPU / GPU

CPU (Central Processing Unit) はコンピュータのメモリー、ハードディスクなどあらゆる装置からデータを受け取り、その動きを制御しています。一方GPU (Graphics Processing Unit) は、画面表示や画像処理に特化した装置で、行列演算を非常に高速に実行できます。深層学習に必要な計算は、行列計算を多用する画像処理の計算と似ていることから、GPUの活用が注目されています。

☞ ヒートマップ

深層学習によるひび割れの判定において、画像のどの領域が認識に影響を与えるかを計算して可視化する手法で、濃い赤色から濃い青色までサーモグラフィのような色のグラデーションで表示されます。赤色の場所が着目している(よく参照されている)箇所になります。

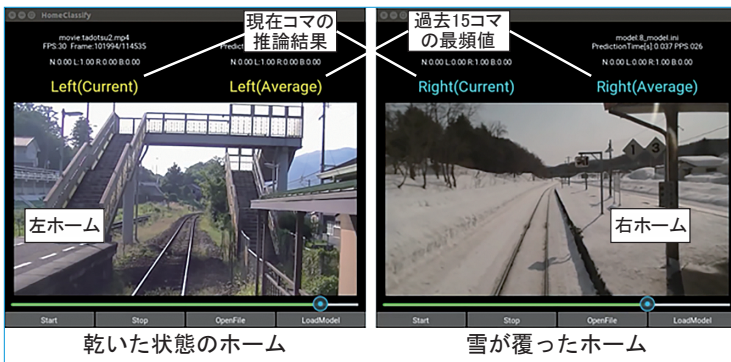


図5 深層学習を用いた画像によるホーム側判定結果




図6 ホーム画像に対するGrad-CAM結果

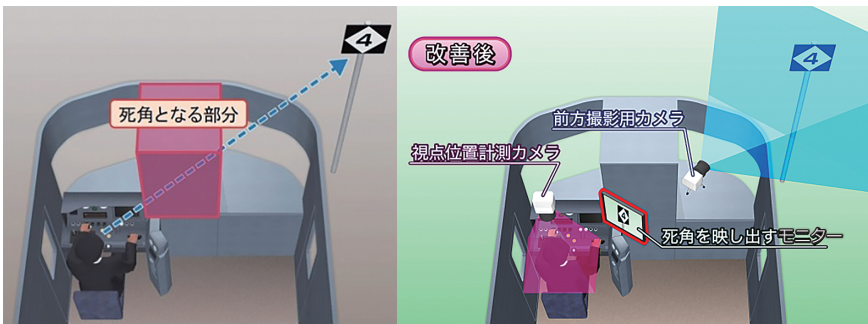


図7 死角となる運転台部材が透明化したイメージ



図8 シースルーモニターのイメージ



図9 死角部分を自然な見え方でモニターに表示した例

画像によるホーム検知

(1) 深層学習によるホーム側判定

駅停車時に乗務員が誤ってホームと反対側のドアを開扉することを防止する目的で、車両に搭載された超音波センサーによるホーム検知装置が実用化されていますが、ホーム端部の状態に左右されることから、課題も残されています。ホームの形状や輝度などの特徴に着目してホーム側を判定する画像処理手法も検討しましたが、環境光の影響を受けやすく、検知性能に問題がありました。そこで、ホームなし、左ホーム、右ホーム、両側ホームの4クラスに分類する識別器を深層学習を用いて作成しました。突発的な誤検知を

防ぐために、前後の画像でホーム側が急激に変わることはないので、ある画像の一コマで判定するのではなく、過去15コマの判定値の最頻値を最終的な判定結果としました。その結果、どちらにホームがあるかを正しく判別する正解率は99%と、深層学習適用の有効性が示されました³⁾(図5)。

(2) 判断箇所の可視化

ひび割れ検出と同様に、Grad-CAMを用いてホーム側判定に影響の大きい箇所を可視化しました(図6)。ホーム端のエッジ部分、ホーム側面、さらに^{かさいし}笠石の端(白線部分)が赤く色づいていることから、これら部位の特徴を総合的に見て判定しているものと思われる

ます。またレールにも反応しており、ホームとレールとの位置関係も判定に影響していると推測されます。

運転士の視認支援装置

車両運転台や貫通路に大きな部材があると、運転士の視界が狭められます。そこで運転士の死角を減少させることを目的として、最新の画像処理技術により、死角となって見えない車両外部の映像を運転士から見て自然な見え方でモニターなどに表示する視点変換手法を開発しました(図7)。“運転席の向こうが透けて見える”をイメージできる室内実験の様子を図8に示します。筆者はモニター越しの後方に立っていますので、モニターに遮られた部分は本来見えないはずですが、あたかもここがないかのように透けて見えています。とくにポイントは、運転士の頭の位置によらず自然な見え方で見通せるという点です。実車に搭載したカメラ・モニター装置により、運転士から自然に見える視界が再現されることを現車試験で確認しました(図9)。本装置を視認支援装置として活用することにより、停止時に停止位置目標などの一部が死角で遮られることがなくなり、運転士の負担軽減に寄与します。

深層学習による戸挟み検知

車両側引戸の戸挟み事故減少に向けて、車両でもさまざまな対策がなされていますが、現用のシステムでは、幅

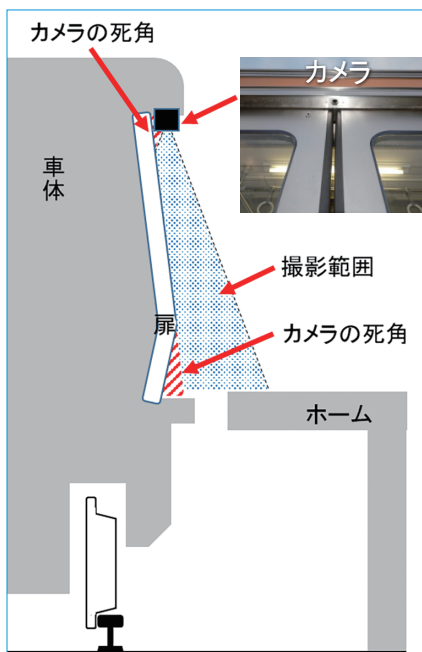


図10 戸先ゴム部の撮影環境

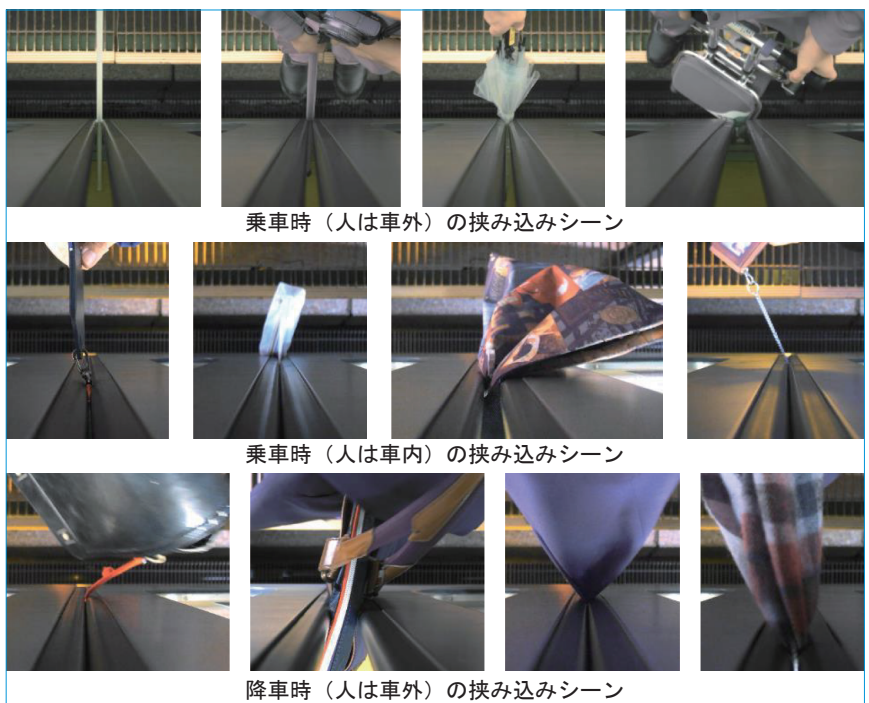


図11 挟み込みの学習用画像の例

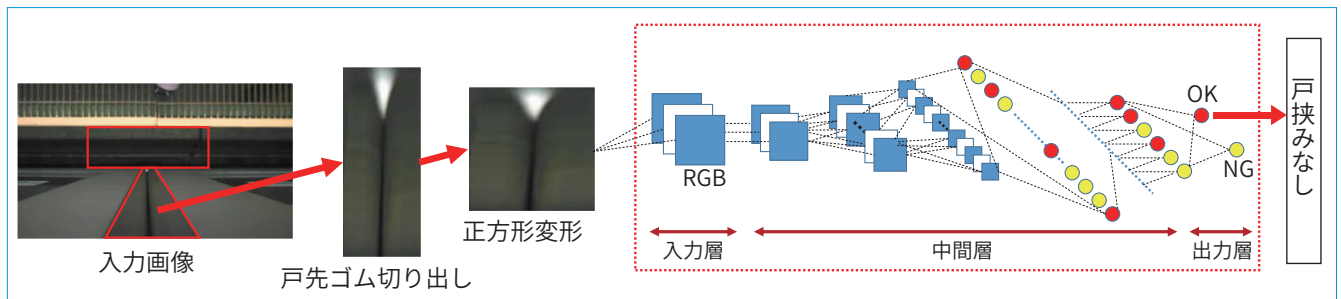


図12 判定に有効な領域を学習した識別モデル

15mm以下の異物の挟み込みや引きずりの検知が難しいという課題があります。そこで深層学習を用いた画像検知手法の開発を進めています。挟み込みの検知に用いる戸先ゴム部周辺の画像は、側引戸上部のカモイ内部に下向きに埋め込んだカメラにより撮影します(図10)。カメラの画像解像度は1920画素×1080画素です。撮影した画像から異物挟み込みあり／なしの画像を学習することで、挟み込みを判定する識別モデルを作成します。挟み込みの学習用画像の例を図11に示します。たとえば降車時にかばんのヒモが挟まるようなシーンでは、提げている袋が車内にとり残されると引き抜くことができません。そこでいろいろな素材、色のヒモの挟み込みを重点的に学

習しました。学習に有効な領域だけをマスクして、画像処理による前処理を適切に行った結果、90%以上の認識精度を得ることができました(図12)。今後は、さまざまな天候・季節における映像、ホーム照明などの外乱光下での映像といった実用的なデータを収集し、認識精度の評価と再学習を実施する予定です。

おわりに

鉄道の運行を支援するための画像技術について、最近の取り組みを紹介しました。あわせて、「深層学習はいつの画像のどこを見て判断しているのか」の答えを与える技術の一つとして、Grad-CAMという手法も紹介しました。近年、AIを実現する技術の代名

詞となっている深層学習は、画像認識や予測手法の分野で著しい進化を遂げています。安全で安定した列車運行を支援する設備管理システムや安全監視システムの実用性を高めるために、見える化・可視化技術の研究開発に取り組んでいきたいと考えています。RRR

文献

- 1) 鷓飼正人：深層学習を用いたトンネル覆工面のひび割れ検出手法の開発、鉄道総研報告, Vol.32, No.5, pp.5-10, 2018
- 2) R. R. Selvaraju, et al.: Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, In Proc. of ICCV 2017, 2017
- 3) 鷓飼正人, 田中斗志貴, 菅原章博, 安田光範：深層学習を用いたホーム検知方法の提案, J-RAIL2017, 2017