建設現場における教師なし異常検知を用いたワイヤーロープ素線切れ検出*

藤　田　雄　一**,*** ルイ笠原　純ユネス† 山　下　　淳†,††

Detection of Wire Breakage Using Unsupervised Anomaly Detection at Construction Sites

Yuichi FUJITA, Jun Younes LOUHI KASAHARA and Atsushi YAMASHITA

At construction sites, wire rope inspection for construction machinery is conducted manually by inspectors. However, such inspections are often constrained by work conditions, such as limited inspection time and restricted use of equipment. As a result, they tend to rely heavily on the inspector's experience and skill. These limitations highlight the need for an automated inspection system that is robust against environmental variability and human subjectivity. In this study, we propose a wire breakage detection method using an unsupervised anomaly detection model based on deep learning. The model is trained only on normal images to statistically model local visual features and detect anomalies as deviations from the learned distribution. This enables the detection of wire breakage without requiring predefined damage patterns or large amounts of labeled data. To verify the method's effectiveness under practical conditions, we constructed a dataset of wire rope images captured in diverse environments, including indoor and outdoor construction settings. Experimental results show that the proposed method can accurately localize wire breakage areas even under varying environments. Furthermore, application of the proposed method to in-service wire rope inspection at actual construction sites enabled the successful detection of subtle anomalies at an early stage prior to wire rope breakage. The results of this study suggest the feasibility of applying unsupervised deep learning-based anomaly detection techniques to support automated visual inspection of wire ropes in real-world construction environments.

Key words: construction site, wire rope, anomaly detection, unsupervised deep learning

1. 序　　論

ワイヤーロープは建設現場で使用するクレーンやエレベータなどの機械装置の主要部材として広く用いられている．これらの機械は非常に大型であり，ワイヤーロープの破断に起因した機械の倒壊や荷の落下などが発生した場合，重大かつ大規模な事故・災害に繋がる危険性がある．そのためこれらの機械装置を使用するにあたっては，ワイヤーロープを適切に管理する必要がある．建設現場で使用するクレーンにおいては，点検員が現場にてワイヤーロープの損傷状況を目視で点検するのが一般的である．その際には，日本クレーン協会が示す点検マニュアルや廃棄基準に基づいて点検を実施し，必要に応じてワイヤーロープの廃棄・交換を行う（**図 1**）[1]．特に「素線切れ（図 1–最上段）」は，ワイヤーロープの耐荷重能力を低下させる重大な損傷であるにも関わらず，非常に微小であるため，検出することは非常に困難である．さらに，点検作業は現場環境下で実施しなければならず，精緻な機器などを持ち込むことも困難であるため，通常では目視点検が選択されることから，点検結果が点検者の技能に依存してしまう．このような課題を解決するために，ワイヤーロープ点検の自動化が求められている．

ワイヤーロープの非破壊検査には，いくつかのアプローチが存在する[2]．最も一般的な方法として磁気探傷手法がある．この手法では，ワイヤーロープの周囲に磁気センサを配置し磁場を発生させる．このとき，ワイヤーロープに断線がある箇所では漏洩磁束が生じ，この特性を利用して素線切れを検出する．また，ワイヤーロープを通過する全磁束を測定することで，腐食による断面欠損の評価が可能となる．Li らは，磁気画像および赤外線画像から特徴ベクトルを抽出し，カーネルベースの Extreme Learning Machine ネットワークを用いて断線の分類問題を解決する手法を提案している[3]．Xu らは，斜張橋のワイヤーロープ検査用センサユニットを開発し，その有効性を実験室環境で検証している[4]．この手法における根本的な問題は，検出される信号強度がワイヤーロープとセンサとの距離および相対速度に依存する点にある．実運用では固定の閾値によって異常判定が行

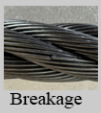
Check point	Discard criteria
 Breakage	The number of wire breaks: • ≥ 10% from 1 pitch • ≥ 20% from 5 pitches
 Abrasion	Diameter decrease exceeding 7% of nominal diameter
 Corrosion	Pitting on the surface of strands Loose strands due to internal corrosion
 Deformation	Kinking, Waviness, Flattening Protrusion of core steel, Large bending, etc.

Fig. 1　Check point and discard criteria for wire rope inspection

* 原稿受付 令和 7 年 5 月 31 日
掲載決定 令和 7 年 8 月 19 日
** 正 会 員 鹿島建設株式会社 メカトロニクス・ソリューション部（東京都港区元赤坂 1-3-8）
*** 正 会 員 東京大学大学院（東京都文京区本郷 7-3-1）
† 正 会 員 東京大学大学院
†† 正 会 員 東京大学大学院（千葉県柏市柏の葉 5-1-5）

われること多いが，相対速度の変動が信号強度に与える影響を十分に考慮できていないという課題がある．その他の手法としては，アコースティックエミッション（AE）法，ガイド波超音波法などがある．Li らは，腐食した橋梁ケーブルに対して AE 技術を用いた疲労実験を行い，疲労損傷に関する AE 特性パラメータを示した[5]．Xu らは，プレストレス用ワイヤーの同一素線における複数の断線を検出するためにガイド波を用いた手法を提案している[6]．低周波および高周波を併用することにより，異なる位置に生じた 2 つの断線が同一素線内にあるか，あるいは別々の素線にあるかの判別が可能となることを示している．これらの例はいずれも構造用ワイヤーロープの点検を対象としている．その理由として，計測操作に関して高度な知識が必要なこと，センサ自体が高価であることが考えられ，建設現場への導入には技術的・経済的なハードルが存在する．

近年では，目視点検の代替手法として画像センサおよび画像処理技術の導入が注目されている．画像センサの高性能化および画像処理技術の進歩により，視覚情報に基づく損傷検出の研究が進められている．これらのアプローチは，機器の取り扱いが容易であり，比較的低コストでの実装が可能であるというメリットがある．さらには，計測結果が自然画像であることで，人手による二次的な確認が容易であり，また，記録にも活用可能であることから点検のトレーサビリティ確保にも寄与する．

本研究は，点検者の技能や作業環境に依存しないワイヤーロープ損傷検出手法の開発を目的としており，ワイヤーロープ損傷の 1 つである「素線切れ」を対象に，画像処理技術を用いてそれらを検出する手法を提案する．ワイヤーロープの素線切れは損傷の中でも非常に重大な損傷である一方で，その発生頻度は非常に少ないため，素線切れのサンプルを多数収集することは難しい．そのため，既知の損傷画像を用いたテンプレートマッチング手法や，教師あり学習に基づく画像分類手法を用いて将来発生する未知の損傷を検出することは困難である．本研究では，ワイヤーロープの正常状態の特徴を基準とし，その特徴と異なる状態を異常と定義することで，上記課題の解決を試みる．これにより，損傷の特徴をあらかじめ定義する必要がなくなり，未知の損傷に対しても頑健に対応可能となる．

2. 関 連 研 究

2.1 画像処理技術によるワイヤーロープ損傷検出手法

近年，画像処理技術をワイヤーロープの損傷検出に応用した研究が増加しており，さまざまなアプローチが提案されている．Li らは，エレベータ用の牽引ワイヤーロープに対して，テンプレートマッチングを用いた摩耗検出手法を提案し，繰り返しパターンの変化をもとに損傷を検出する手法を示している[7]．Wacker らは，ワイヤーロープの理論的な形状モデルと実画像を照合することにより，モデルベースで損傷部位を認識するアルゴリズムを開発した[8]．しかしこれらの手法はあらかじめ定義されたパターンやモデルに依存するため，損傷の多様性への対応に課題がある．より一般的な手法として深層学習を用いた物体検出・分類手法がある．Zhou らは，Local Binary Pattern と主成分分析を用いて画像の特徴抽出および次元削減を行い，分類器による損傷判別を行った[9]．このような手法は一定の精度を示すが，1 章で述べたように，教師あり学習に必要な大量の損傷データの収集は困難であり，未知の損傷への汎化性が課題となる．

これらの課題に対して，深層学習を用いた教師なし異常検知手法がある．教師なし異常検知では，主に正常データのみを学習に用いて特徴量を学習する．そして推論データの中に学習データに含まれない特徴量がある場合に，それらを異常として検出する．このような手法は，異常の定義が難しく，また異常が多様で予測困難な状況において特に有効である．深層学習をベースとした教師なし学習の 1 つである Autoencoder 手法は，生成モデルを用いる再構成ベースの手法であり，正常画像から再構成された画像との間の差異をもとに異常検出する手法である[10]．正常データのみで学習されたモデルは，正常なパターンをうまく再構成する一方で，異常部分については再構成誤差が大きくなる傾向があるため，その差をスコア化して異常検出を行う．この手法の利点は，モデル構築が比較的容易であり，特定の物体に依存しない汎用性の高さにある．一方で，正常と異常の境界が曖昧な場合や，異常部分が画像の目立たない領域に現れるような場合には誤検出のリスクが高くなる．また，モデルの再構成能力が高すぎる場合には，異常箇所まで正確に再構成してしまい，異常検出性能が低下するという問題もある．再構成に依存しない手法として，事前学習済みの深層学習モデルを利用して特徴量空間を構築し，その分布に基づいて異常検出する手法がある．代表的な手法としては，PaDiM[11]や SPADE[12]，PatchCore[13]などがある．これらの手法では，事前に正常画像の局所特徴ベクトルの分布を学習し，推論時にはその分布からの逸脱度を異常スコアとして計算する．これによって，構造が複雑で繰り返しパターンを持つ対象に含まれる異常の検出が可能となる．本研究では，産業分野の異常検知ベンチマークである MVTec AD[14]において優れた異常検知性能を有する PaDiM に着目した．これによって，ワイヤーロープが有する素線の規則的な配置を特徴量空間に反映することで，高精度に素線切れ検出が可能となることが期待される．

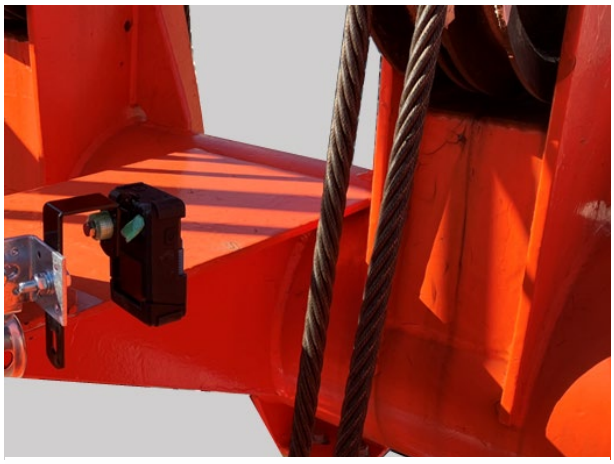


Fig. 2 Example of image sensor installation at construction site

2.2 データセット

画像処理技術を用いた異常検知手法の性能評価については，前述の MVTec AD などの公開されたベンチマークデータセットが広く用いられている．これらのデータセットには，金属部品，繊維，レザー製品などにおける様々な異常（キズ，欠損，汚れなど）が含まれており，さまざまなアルゴリズムの性能評価に利用されている．しかし，これらのデータセットは理想的な環境下で撮影されたものであり，実際の現場で生じる照明条件の変動，撮影角度の違い，対象物の個体差などを十分に反映していない．また，対象物のバリエーションも限られており，建設現場環境下で撮影されるワイヤーロープに含まれる損傷の検出に対し，その

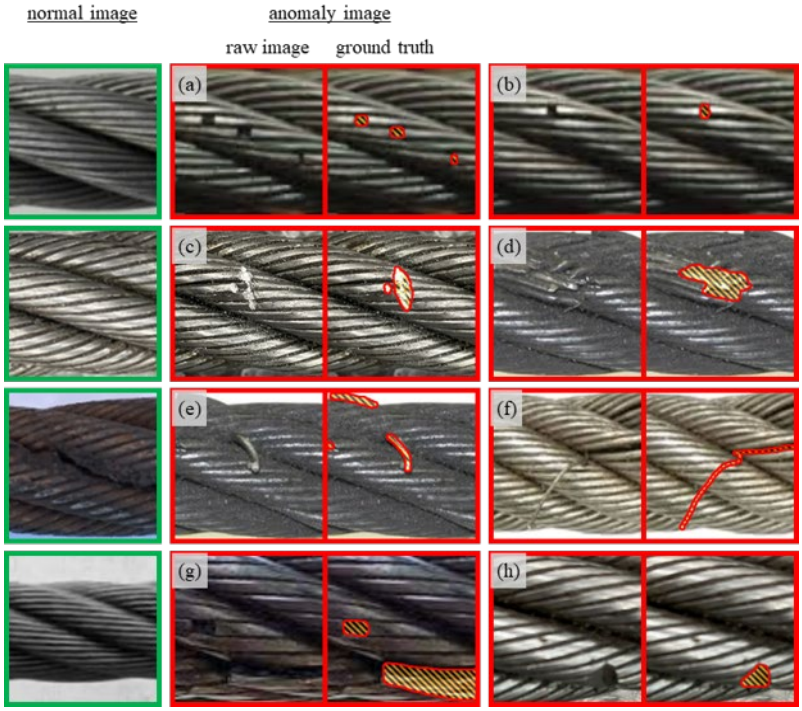


Fig. 3 Samples of wire rope images

まま適用することは困難であると予想される．このような背景から，より実環境に近いデータを用いた評価が求められる．

2.3 本論文の位置づけ

本研究では，建設現場で使用されているワイヤーロープの点検作業の高度化を目的に，建設現場環境およびそれに類する条件で撮影（**図 2**）された画像に対して，深層学習を用いた教師なし異常検知手法を適用する．そして，異常の定義が困難かつ発生頻度の低い「素線切れ」の検出可能性を示す．本論文は，実環境を反映したデータに基づき，既存手法では十分に扱われていない対象物・環境に対する異常検知を試みた点において，より実用性の高いアプローチを提供する．

3. 手　　法

3.1 学習モデル

本研究では，画像に基づくワイヤーロープの素線切れ検出を目的として，既存の教師なし異常検知モデルである PaDiM を採用する．PaDiM は，正常画像から抽出した特徴のパッチ（小領域）単位の分布を多変量ガウス分布としてモデル化し，推論時には各パッチの分布との距離を異常スコアとして計算する手法である．本手法は，事前学習済みの画像分類モデルを用いて特徴抽出を行い，正常状態の特徴分布を記述することで，異常との乖離を検出する．PaDiM の利点として，教師なしでの学習が可能であり，かつ異常の位置をピクセルレベルで可視化できる点が挙げられる．また，異常を定義せずに検出可能であるという点でも，柔軟性が高い．PaDiM では，画像の特徴抽出に事前学習済みの CNN を用いて画像中の各パッチに対する特徴ベクトル（埋め込み）を抽出し，その分布を統計的にモデリングすることで正常状態の特徴を学習する．具体的には，CNN の複数の層から得られる特徴マップを連結し，空間的に対応する各パッチ位置に対して多変量ガウス分布を推定する．これにより，意味レベルの異なる特徴を統合しつつ，正常状態のばらつきを捉えることが可能となる．推論時には，入力画像の各パッチの特徴と学習済み分布とのマハラノビス距離を計算することで異常スコアマップを生成し，異常箇所とそのスコアの大きさを可視化する．

3.2 データセット

本研究の対象であるワイヤーロープについては，一般に公開されたベンチマークデータセットが存在しないため，**図 3** に示す独自のデータセットを作成した．緑色の枠で囲まれた画像は正常（損傷のない）画像を示しており，赤色の枠で囲まれた画像は異常（損傷を含む）画像を示す．異常画像は 2 枚 1 組で構成されており，左は撮影画像，右は損傷箇所を赤枠および橙色の斜線で強調した画像である．画像の撮影環境は，図 2 に示すような屋外の建設現場および室内環境の両方を含む．また，ワイヤーロープの線種については，構成，サイズ，および使用対象機械（クレーン，エレベータ等）にバリエーションを持たせて選定した．損傷のタイプとしては，現場で実際に発生したものと，正常なワイヤーロープに人為的に損傷を付与したものの両方が含まれている．具体的には，素線切れ・単線（a, b），素線切れ・複数線（c, d），素線の飛び出し（e, f）などがある．また，カメラと損傷の位置関係についても，損傷が正面に位置するものや，側面に生じているもの（g, h）など，さまざまなパターンを含んでいる．撮影環境としては，屋内／屋外，晴天／曇天など多様な条件を含んでおり，実際の建設現場において均一な条件で撮影することが困難である状況を反映している．このように，本データセットには多様な種類および撮影条件の画像が含まれており，統制された環境で撮影された既存データセットと比較して，実用性に優れていると考える．

4. 実　　験

4.1 学習条件

実験における学習条件を示す．画像からの特徴抽出には ImageNet で事前学習された WideResNet50-2[15]を用い，layer1，

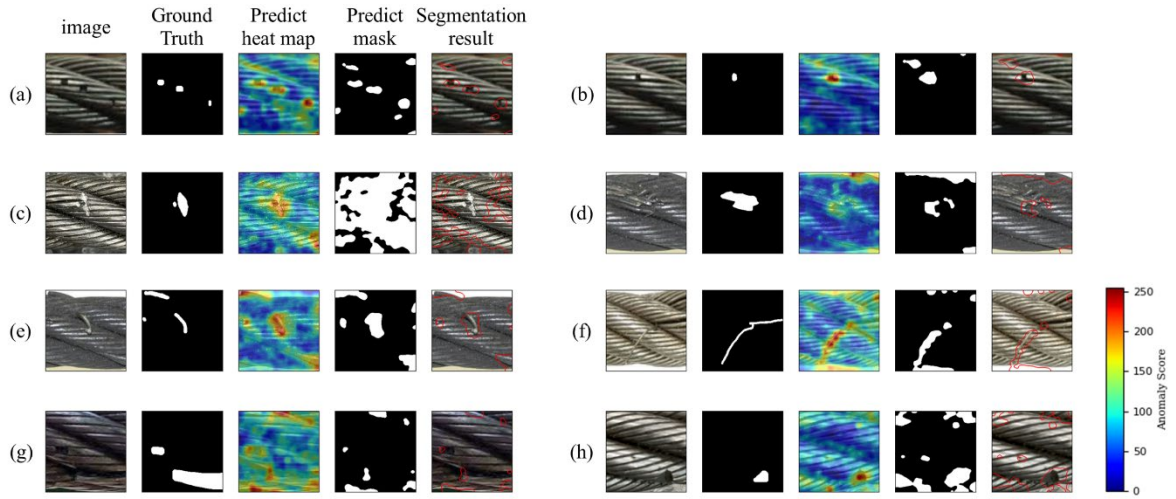


Fig. 4 Detection results of wire breakage

layer2 および layer3 の最終層から出力される特徴マップを空間的に対応づけて連結した．この連結後の 1792 次元の特徴ベクトルからランダムに 550 次元を抽出し，次元削減を行った．得られた特徴を用いて，各空間位置ごとに多変量ガウス分布を推定し，正常状態の特徴分布をモデル化した．このとき，共分散行列が非正則となるのを防ぐため，対角成分に正則化項ε=0.01 を加えた．推論時には，入力画像の各パッチ特徴と学習済み分布とのマハラノビス距離を異常スコアとし，異常箇所を可視化した．

4.2 データセット

本実験では，学習用に正常画像 209 枚，推論用に正常画像 105 枚および異常画像 87 枚を使用した．また，推論用のそれぞれの異常画像に対応するマスク画像（正常部：0，損傷部：1 の二値画像）を作成し，損傷検出結果と比較することで検出精度評価を行った．使用した画像枚数は，MVTec AD の 1 クラスに含まれる画像の枚数と同程度とした．また入力画像のサイズは PaDiM での学習・推論に用いるため，224×224 とした．オリジナルの PaDiM モデルでは，入力画像を 256×256 にリサイズし，その中央部を切り出して 224×224 の画像を作成し学習・推論を行っているが，本実験では，中心切り出しの際に画像内のワイヤーロープ領域が切り取られることを防止するため，この処理を省略した．

4.3 実験結果

本実験では，図 3 で示した素線切れ画像を入力画像として，PaDiM による素線切れ検出を行った．実験結果を**図 4** に示す．左からそれぞれ「image：入力画像」，「Ground Truth：損傷個所を明示したマスク画像」，「Predict heat map：異常スコアマップ」，「Predict mask：異常スコアを適切な閾値で二値化し生成した予測マスク画像（正常部：0，損傷部：1）」，「Segmentation result：予測された損傷箇所を明示した画像」を表している．ここで Predict heat map から Predict mask を生成する際には，異常スコアマップを二値化するために，適切な閾値の設定が必要である．本実験では，この閾値の決定に F1 score を用いた最適化を行った．具体的には，推論画像ごとに推定された異常スコアマップを正規化し，すべての画像の各ピクセルの異常スコアと対応する Ground Truth マスクを用いて閾値を変化させながら Precision（適合率）および Recall（再現率）を算出し，そこから F1 score を算出した．Precision, Recall, F1 score は以下の式で定義される．

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}, \tag{1}$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}, \tag{2}$$

$$\text{F1 score} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}, \tag{3}$$

式(1), (2)において，TP は True Positive（損傷箇所を損傷として正しく判定），FP は False Positive（正常箇所を損傷と誤判定），FN は False Negative（損傷個所を正常と見逃し）を示す．F1 score が最大となる閾値を用いて異常スコアマップを二値化し，Predict mask を生成した．この手法により，異常検出において適合率と再現率のバランスが取れた分類性能を目指した．本実験で得られた F1 score は 0.409 であり，これを閾値として Predict mask を生成し，素線切れ箇所を特定した．結果として図 4 に示すように，多くの損傷画像において，Ground Truth に示された損傷箇所を検出することができた．(a)や(b)では，最も微小な損傷である素線切れ・単線を，その位置を含めて異常と判定している．また(d)や(g)のように損傷領域が広がっているパターンについてはその一部，具体的には切断した素線端部を異常と判定している．具体的には(g)において，切れた素線の端部に見られる輝度の差を異常と判定している一方で，素線が浮いた箇所については，ground truth では浮き部分も異常ラベルとしているが，素線が線状に存在していることから正常判定したと考えられる．(e)や(f)のように素線が大きく飛び出しているパターンについては，その大部分を異常と判定している．一方で(c)や(h)では多くの誤検出が発生しており，特に(c)では画像の大部分が異常と判定された．これについては，ワイヤーロープに当たる照明によってできた陰影や模様を素線の切れ目として異常と判定していると考えられ，この傾向は(c), (h)と同じ環境で撮影されたその他の推論画像でも共通して見られた．また(a)や(b)ではワイヤーロープ表面の一部が，(d)や(f)では背景（非ワイヤーロープ）領域が異常と判定されていた．

本実験における素線切れ検出性能について，画像単位および画素単位の 2 つの AUROC を用いて定量的に評価した．**図 5** に評価結果を示す．image AUROC は各画像に対して算出された異常スコアの最大値をもとにその画像が異常を含むか否かを判定する二値分類性能を評価するものである．一方 pixel AUROC は異常スコアマップと対応する Ground Truth マスクとの画素単位

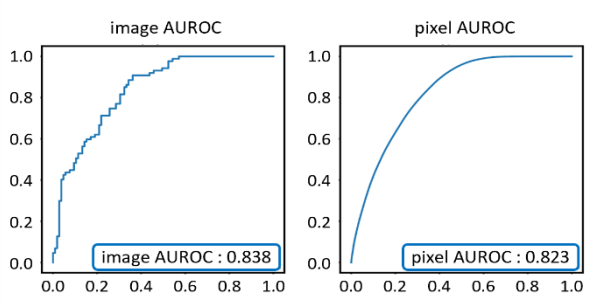


Fig. 5 AUROC (left) image-level, (right) pixel-wise

の一致度を評価するものであり，異常領域の局所化性能を示す指標である．本実験の結果は，image AUROC:0.838，pixel AUROC:0.823 となった．これは AUROC の一般的な評価基準において良好な性能であり，PaDiM モデルによる素線切れ検出の有用性を示している．特に，pixel AUROC は損傷箇所の空間的特定性能を反映しており，本研究で対象としている素線切れのような微小な損傷に対しても良好な検出性能が得られる可能性を示唆している．

4.4 現場適用

4.1 節で得られた学習済モデルおよび 4.3 節で得られた閾値を用いて，屋外建設現場で使用されているタワークレーンの巻上ワイヤーロープ（IWRC 6×P・WS(31)T 種, S より, 公称径 20mm）について点検を実施した．画像センサには IV4-600C を使用し，**図 6** に示すようにボックスに収めて計測を行った．計測はワイヤーロープの走行速度 30m/min で実施した．

提案手法を用いた点検の結果，本研究の主対象である素線切れは検出されなかった．なお，当該ワイヤーロープに素線切れが発生していないことは，別途目視により確認しており，見逃しが無かったことも確認されている．一方で，点検結果として**図 7** に示す異常を 1 箇所検出した．異常検出箇所の実物を目視確認したところ，図中の赤丸で示すように，素線と素線の間に金属片が挟まっている状態が確認された．この事象についてワイヤーロープメーカーにヒアリングを行ったが，これまでに同様の経験は無いとの回答であり，非常に稀な事象であったと考えられる．それにもかかわらず，当該事象を検出できたのは，本研究がワイヤーロープ点検作業に対して教師なし異常検知を適用したことによるものであり，モデルベース手法や教師あり学習を用いる従来の手法では検出が困難であったと考えられる．なお，今回検出された異常は廃棄基準には達しておらず，当該ワイヤーロープは継続して使用可能である．しかし，このような異常を軽微な段階で検出できたことにより，将来的な重大事故を未然に防げた可能性がある．また，点検結果に基づいて現場の施工管理担当者および機械整備担当者に当該箇所の経過観察を促すことができ，現場の安全性向上に大きく貢献した．

5. 考　　察

現場適用では，4.3 節の実験結果で得られた閾値を暫定的に用いたが，この閾値が他の現場・環境でも有効であるかは不明であり，実運用時には再検証が必要である．今回の F1 score を基づく閾値を用いた場合，その算出方法の性質上，一定数の誤検出および見逃しが発生する可能性がある．一般に，誤検出率と見逃し率はトレードオフの関係にある．そのうえで，本研究が対象としているワイヤーロープの素線切れ検出や，より広く機械の点検作業においては，異常の見逃しが少ないことが優先される場合が

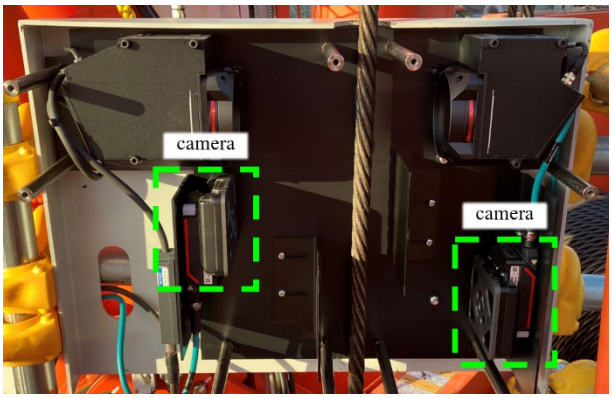


Fig. 6 Image Sensor (highlighted in green) Installation Overview



Fig. 7 Detected Wire Rope Anomaly

Table 1 Comparison of Wire Breakage Detection Performance with Similar Models

metric / model	SPADE	PatchCore	PaDiM
image AUROC	0.796	0.799	**0.838**
pixel AUROC	0.809	0.819	**0.823**

多く，そのような場合には誤検出をある程度許容せざるを得ない．したがって，実際の点検作業で本手法を用いる際には，これらの点を考慮して閾値を決定する必要がある．

本研究では，深層学習を用いた教師なし異常検知手法として PaDiM を採用した．これは PaDiM が，微小な異常の検出に優れていること，およびベンチマークである MVTec AD の texture クラスにおける異常検知において高い精度を示していることが理由であり，ワイヤーロープが持つ素線の集合からなる撚り線構造が，texture クラス画像が持つ規則的な構造に類似すると考えたためである．これを確認するために，2.1 節で示した類似の異常検知モデル（SPADE, PatchCore）との比較を実施した（**表 1**）．ここではモデル毎の image AUROC および pixel AUROC のスコアを比較している．この際，特徴抽出のための backbone は各モデル共通で WideResNet50-2 を使用し，学習／推論画像は 4.2 節で示したデータセットを用いた．結果として PaDiM を用いた場合が，image AUROC，pixel AUROC ともに最もスコアが高かった．また，SPADE，PatchCore においても同等のスコアであることから，教師なし異常検知モデルを用いたワイヤーロープ素線切れ検出可能性がより広い視点から確認された．一方で，今回作成したデータセットに対する素線切れ検出性能は各モデルとも AUROC：0.8 程度であり，MVTec AD の texture クラス画像に対する異常検出性能（AUROC: 0.9 以上）と比較して劣る結果とな

った．この要因は，本研究のデータセットの作成方針に起因していると考えられる．本研究では，汎化性能の高いモデルを構築するため，多様なドメイン（撮影環境やワイヤーロープ線種の多様性）を持つデータセットを作成した．その結果，一定の異常検出性能を達成したものの，MVTec AD のような特定のドメインを持つデータセットを用いた場合の性能には及ばなかった．このドメインの違いについては，例えば MVTec AD の texture クラス画像には背景領域が存在せず，画像全体が注目領域であるのに対し，本研究で作成したデータセットでは一部に背景が含まれ，また撮影環境によって色調や模様が多様であることが挙げられる．異常検出性能の差については，汎化性能と特化性能のトレードオフに起因していると考えられる，本研究ではデータセットに多様なドメインを含めることで汎化性能が向上した一方で，特定の条件やクラスに対する最適化が困難となり，性能が抑制されたと推察される．本実験結果により，今回作成したデータセットに対する異常検出性能は，汎化性能を重視したモデル構築アプローチの１つの指標となると考えられる．性能改善に向けては，データセットの多様性をさらに拡張することや，画像内の背景領域の削除による誤検出低減により，モデルの性能向上が期待できる．また，逆のアプローチとして， MVTec AD のような特定のドメインのみを学習した際に特化性能が得られるという特徴を活かしつつ，例えばドメインアダプテーション手法を取り入れることで，汎化性能を確保する方法も考えられる．いずれにせよ，手法の改善に際しては，単に「AUROC が改善した」という評価だけでなく，さまざまな建設現場の環境に適合容易であることが求められる．

Roth[13]らの研究では，PaDiM，SPADE，PatchCore における推論時間について述べられている．主な条件としては，画像の特徴抽出のための backbone は各モデル共通で WideResNet50-2 を使用，可能な限り GPU での計算処理を実施し，推論時間を算出している．これらの条件における推論時間は，PaDiM が画像 1 枚あたり 0.19 秒で，最も推論時間が速い結果であった．次いで PatchCore: 0.22 秒，SPADE: 0.66 秒となっており，いずれも画像１枚あたり 0.1 秒オーダーであった．しかしながら，実用化にあたっては現実的に設置可能な計算機が現場条件によって異なるため，推論時間を一律に示すことは難しい．「4.4 節 現場適用」での実績では，ワイヤーロープ計測長: 200m から取得する推論対象画像が約 16,000 枚なのに対して，画像データ前処理～PaDiM による推論～結果表示までを約 3 時間で完了しており，画像１枚あたりの処理時間は画像１枚あたり約 0.7 秒であった．今後実用化する際には，これらの学習モデルを点検システムに組み込むことが考えられるが，その場合，システムに求められる全体の処理完了時間を元に，推論時間への要求を明らかにし，それを実現する計算機などの機器を選定する必要がある．

6. 結　　論

本論文では，建設機械のワイヤーロープの素線切れ検出を対象として，深層学習を用いた教師なし異常検出手法による検出可能性を示した．ワイヤーロープ損傷の発生頻度が非常に低いという課題に対して，ワイヤーロープの正常状態の特徴を基準とし，その特徴と異なる状態を異常と定義することで解決を試みた．また，建設現場での点検・計測を考慮し，多様な種類，撮影条件で取得したワイヤーロープ画像データセットを作成することで，汎化性能の高いモデル構築を目指した．これらを用いた実験によって，深層学習を用いた教師なし異常検知手法によるワイヤーロープの素線切れ検出性能を確認した．結果として，image AUROC:0.838，pixel AUROC:0.823 と高い異常検出性能を有することを確認するとともに，複数の代表的な異常検知モデルとの比較により，汎化性能を重視したモデル構築アプローチの指標を示した．また，本手法と実験によって決定した閾値を用いて，屋外建設現場で使用中のワイヤーロープ点検を実施した．その結果，廃棄基準に至る前段階の軽微な異常の検出に成功し，本手法の有効性を示すと共に，現場の安全性向上に大きく貢献した．今後の課題は，汎化性能を確保しつつ，より異常検出性能の高いモデル構築アプローチの検討，現場適用時の適切な閾値決定方法を含む点検作業全体の運用方法の検討が挙げられる．

謝　　辞

本研究は，東京大学「i-Construction システム学寄付講座」のもと，東京大学と鹿島建設㈱との共同研究によるものである．

参 考 文 献

1) 日本クレーン協会 : JCA S 0501-1986 クレーン等に使用されるワイヤロープの保守・点検および廃棄基準，日本クレーン協会, (1986).
2) Shiwei Liu, Yanhua Sun, Xiaoyuan Jiang and Yihua Kang: A Review of Wire Rope Detection Methods, Sensors and Signal Processing Techniques, Journal of Nondestructive Evaluation, **39**, 85, (2020).
3) Xi Li, Juwei Zhang and Jingzhuo Shi: Quantitative Nondestructive Testing of Broken Wires for Wire Rope Based on Magnetic and Infrared Information, Journal of Sensors, **2020**, 1, (2020).
4) Fengyu Xu, Xingsong Wang and Hongtao Wu: Inspection Method of Cable-Stayed Bridge Using Magnetic Flux Leakage Detection Principle, Sensor Design, and Signal Processing, Journal of Mechanical Science and Technology, **26**, 3, (2012) 661.
5) Dongsheng Li, Jinping Ou, Chengming Lan and Hui Li: Monitoring and Failure Analysis of Corroded Bridge Cables under Fatigue Loading Using Acoustic Emission Sensors, Sensors, **12**, 4, (2012) 3901.
6) Jiang Xu, Xinjun Wu and Pengfei Sun: Detecting Broken-Wire Flaws at Multiple Locations in the Same Wire of Prestressing Strands Using Guided Waves, Ultrasonics, **53**, 1, (2013) 150.
7) Zehua Li, Zheng Chai and Chunhui Zhao: An Abrasion Detection Method for Elevator Traction Wire Rope Based on Template Matching, Proceedings of the IEEE 9th Data Driven Control and Learning Systems Conference (DDCLS'20), (2020) 1452.
8) Wacker, Esther-Sabrina and Joachim Denzler: Enhanced Anomaly Detection in Wire Ropes by Combining Structure and Appearance, Pattern Recognition Letters, **34**, 8, (2013) 942.
9) Ping Zhou, Gongbo Zhou, Shihao Wang, Hanyu Wang, Zhenzhi He and Xiaodong Yan: Visual Sensing Inspection for the Surface Damage of Steel Wire Ropes with Object Detection Method, IEEE Sensors Journal, **22**, 23, (2022) 22985.
10) Geoffrey Hinton and Ruslan Salakhutdinov: Reducing the Dimensionality of Data with Neural Networks, Science, **313**, 5786, (2006) 504.
11) Thomas Defard, Aleksandr Setkov, Angelique Loesch and Romaric Audigier: PaDiM: a Patch Distribution Modeling Framework for Anomaly Detection and Localization, arXiv preprint arXiv:2011.08785, (2020).
12) Niv Cohen and Yedid Hoshen: Sub-Image Anomaly Detection with Deep Pyramid Correspondences, arXiv preprint arXiv:2005.02357, (2021).
13) Karsten Roth, Latha Pemula, Joaquin Zepeda, Bernhard Schölkopf, Thomas Brox and Peter Gehler: Towards Total Recall in Industrial Anomaly Detection, arXiv preprint arXiv:2106.08265v2, (2022).
14) Paul Bergmann, Michael Fauser, David Sattlegger and Carsten Steger: MVTec AD— A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection, Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), (2019) 9592.
15) Sergey Zagoruyko and Nikos Komodakis: Wide Residual Networks, arXiv preprint arXiv:1605.07146v4, (2017).