

厚生労働科学研究費補助金

分担研究報告書

機械学習を用いたデジタル技術活用の基礎的検討

研究者

研究分担者	山際謙太	(独) 労働者健康安全機構 労働安全衛生総合研究所 機械システム安全研究グループ・部長
研究協力者	濱島京子	(独) 労働者健康安全機構 労働安全衛生総合研究所 機械システム安全研究グループ・首席研究員
研究協力者	山口篤志	(独) 労働者健康安全機構 労働安全衛生総合研究所 機械システム安全研究グループ・上席研究員
研究協力者	緒方公俊	(独) 労働者健康安全機構 労働安全衛生総合研究所 機械システム安全研究グループ・主任研究員

研究要旨

本研究では、デジタル技術マップにおける機械学習技術の位置づけを具体化するため、ワイヤロープのU曲げ疲労試験中に取得したラインカメラ画像を対象として、畳み込みニューラルネットワークによる寿命消費率推定の基礎的検討を行った。ワイヤロープの点検では、素線切れ、摩耗、変形などを目視により確認することが基本であるが、観察条件や点検者の経験により評価がばらつく可能性がある。また、点検結果が画像として継続的に保存されていない場合、過去状態との比較や損傷進行の定量的把握は容易ではない。そこで、画像計測、データ蓄積、状態推定、点検支援を接続する技術要素として、機械学習を用いたワイヤロープ画像評価の有効性と限界を検討した。

U曲げ疲労試験中に取得したワイヤロープ画像から、ロープ軸方向に局所画像パッチを生成し、各観察時点の繰返し数を破断繰返し数で除した値を寿命消費率として学習ラベルに用いた。鋼ロープ高荷重条件を対象として、試験片単位の leave-one-specimen-out 交差検証を行い、未知試験片に対する推定性能を評価した。その結果、全検証データに対して MAE 0.1317, RMSE 0.1692, 相関係数 0.8680 を得た。fold 1 から fold 3 では MAE が 0.10 前後であり、未知試験片に対しても損傷進行度を一定程度推定できる可能性が示された。一方、fold 0 では予測値が全体的に高めとなり、寿命消費率の絶対値推定には試験片間差の影響が残ることが確認された。

以上の結果から、ラインカメラ画像と機械学習を組み合わせることで、ワイヤロープの損傷進行に伴う画像特徴の変化を一定程度捉えられることが示された。ただし、本技術は現段階では自動判定装置として単独で用いるものではなく、点検支援技術または状態監視技術として位置づけることが妥当である。画像と推定値を時系列的に保存することで、損傷進行の把握、点検対象の優先順位付け、点検記録の客観化、遠隔確認、および点検周期や交換判断の妥当性を検討するための基礎資料として活用できる可能性がある。今後は、より多様なロープ条件でデータを拡充し、ロープ張力、ロープ種別、撮影時の繰返し数、過去の推定履歴などの補助情報を組み込んだモデル化を進める必要がある。

1 研究目的

クレーン、ワイヤロープ、ボイラー、圧力容器等の機械設備に対して、画像計測、センサ、通信、データベース、機械学習などのデジタル技術を安全管理に活用することが期待されている。一方で、これらの技術はそれぞれ性質が異なり、単に新しい技術を列挙するだけでは、安全管理上どの工程に適用できるのか、どのような情報を得られるのか、またどのような限界や注意点があるのかを把握しにくい。そのため、本研究課題では、各種デジタル技術を点検、検査、監視、記録、判断支援などの観点から整理し、安全管理への適用可能性を示すデジタル技術マップを作成することを目的としている。

デジタル技術マップを実効性のあるものにするためには、技術の名称や一般的な機能を整理するだけでなく、実際の安全管理対象に対して、どのようなデータを取得でき、そのデータからどの程度の状態推定や判断支援が可能であるかを確認する必要がある。例えばワイヤロープの点検では、素線切れ、摩耗、変形などの損傷状態を人が目視により確認することが基本である [1] が、観察条件や点検者の経験によって評価にばらつきが生じる可能性がある。また、点検結果が画像として継続的に保存されていない場合、過去状態との比較や損傷進行の定量的な把握は容易ではない。

このような課題に対して、ラインカメラ等により取得したワイヤロープ画像を蓄積し、機械学習により損傷進行状態を推定する技術は、デジタル技術マップにおける画像計測、データ蓄積、状態推定、点検支援を結び付ける具体例となる。すなわち、機械学習は単に自動判定を行うための手法ではなく、画像データを安全管理上有用な情報へ変換し、点検者が確認すべき対象や損傷進行の傾向を把握するための支援技術として位置づけられる。

そこで本研究では、ワイヤロープの U 曲げ疲労試験中に取得したラインカメラ画像を対象として、畳み込みニューラルネットワークを用いた寿命消費率推定の基礎的検討を行う。具体的には、撮影画像から局所パッチを生成し、破断繰返し数に対する観察時点の繰返し数の割合を寿命消費率として与えることで、画像から損傷進行状態を連続値として推定できるかを検討する。また、試験片単位の評価により、未知試験片に対する推定性能や誤差の傾向を確認し、機械学習を用いたワイヤロープ検査技術の有効性と限界を明らかにする。これにより、デジタル技術マップにおける機械学習技術の位置づけ、安全管理への適用可能性、および今後必要となるデータ蓄積・運用上の課題を整理することを目的とする。

2 研究方法

本研究では、ワイヤロープの損傷進行状態を画像から推定するための基礎的検討として、疲労試験中に取得したワイヤロープ画像を用い、機械学習による寿命消費率の回帰推定を行った。ここで寿命消費率は、対象試験片における観察時点の繰返し数を破断繰返し数で除した値として扱い、0 から 1 の連続値として定義した。

2.1 ワイヤロープ U 曲げ疲労試験による対象データの取得

対象データは、U 曲げ疲労試験中に撮像したワイヤロープ (IWRC 6xFi(29)) および繊維ロープ (エースライン SUHD026B) の画像である。いずれのロープも直径は 16 mm である。図 1 に、本研究で対象としたワイヤロープおよび繊維ロープの外観を示す。各観察時点のラベルは、観察時点に対応する繰返し数を破断繰返し数で除すことにより算出した。

本研究で対象とした U 曲げ疲労試験の条件および破断繰返し数を表 1 および表 2 に示す。ワイヤロープ



図1 本研究で対象としたワイヤロープ (IWRC 6×Fi(29)) および繊維ロープ (エースライン SUHD026B) の外観




図2 ラインカメラ (Keyence 製) によるワイヤロープ撮影の様子

と繊維ロープでは材料、構造および表面性状が異なるため、画像上に現れる損傷の見え方にも差があると考えられる。鋼ロープについては、高荷重条件では 2000 cycles ごと、低荷重条件では 20000 cycles ごとにラインカメラ観察を行った。繊維ロープについては、高荷重条件では 300 cycles ごと、低荷重条件では 6000 cycles ごとに観察を行った。観察間隔は、筆者らのグループで行ったワイヤロープの曲げ疲労試験に関する検討 [2] を踏まえ、概ね破断寿命の 1/10 程度の繰返し数となるように設定した。

なお、試験時間の都合上、鋼製ワイヤロープの高荷重については機械学習を行う上で十分な試験本数を行うことができたが、他の条件については十分な本数を行うことができなかったため、こちらについては引き続き試験を行い来年度に報告することとする。

表 1 鋼ロープ (IWRC 6×Fi(29)) の U 曲げ疲労試験条件

符号	ロープ張力 (kN)	破断繰返し数
U_197	34.6	24617
U_201	34.6	23545
U_202	8.65	206377
U_203	34.6	24525
U_204	34.6	23988

表 2 繊維ロープ (エースライン SUHD026B) の U 曲げ疲労試験条件

符号	ロープ張力 (kN)	破断繰返し数
U-017	37.0	7783
U-018	9.25	94437

2.2 画像パッチの生成

撮像画像はラインカメラにより取得された画像であり、画像幅は同一であることを前提とした。学習に用いる前処理として、画像の中央付近からワイヤロープ領域を含む幅 1024 画素の領域を切り出した。次に、ロープ軸方向に対して 1024 画素高さのパッチを切り出し、隣接パッチ間に 25% の重なりを持たせた。これにより、一枚の元画像から複数の局所画像パッチを生成した。

各パッチには、元画像、試験片 ID、観察時点、パッチ位置、寿命消費率ラベルを対応付け、これらの情報を CSV 形式のメタデータとして保存した。画像パッチの生成時には、画像サイズおよびファイルサイズを確認し、撮像条件から外れたデータや読み込み不能なデータを検出できるようにした。

2.3 学習データの構成

生成した画像パッチは、グレースケール画像として読み込み、所定の入力サイズにリサイズした後、画素値を 0 から 1 の範囲に正規化した。ニューラルネットワークへの入力では、グレースケール画像を 3 チャンネルに複製して用いた。これは、後続のモデル構造や一般的な画像処理フレームワークとの整合性を確保するためである。

学習ラベルは寿命消費率の連続値とした。試験初期では画像上に明瞭な損傷特徴が現れにくいことから、初期域の予測誤差については、画像情報から識別できる限界を考慮する必要がある。一方で、安全管理への応用を考えると、損傷進行に伴う相対的な変化を捉えられることが重要であるため、本検討では連続値回帰としてモデル化した。

2.4 回帰モデル

寿命消費率を推定するモデルとして、畳み込みニューラルネットワークを用いた。モデルは、複数の畳み込み層と最大値プーリング層により局所的な画像特徴を抽出し、Global Average Pooling 層および全結合層を介して 1 つの連続値を出力する構成とした。出力値は寿命消費率に対応するため、最終層の活性化関数




図3 鋼ロープのU曲げ疲労試験における撮影画像の例

には線形関数またはシグモイド関数を選択可能とした。シグモイド関数を用いる場合、出力は0から1の範囲に制限される。

CNNの概略構成を表3に示す。本表では、実装したネットワークの各層、出力形状およびパラメータ数を整理した。


2.5 評価方法

評価は、未知試験片に対する汎化性能を評価するため、試験片単位の leave-one-specimen-out 交差検証を行った。具体的には、4本の試験片のうち1本を検証用、残り3本を学習用とする分割を4通り作成し、各foldで学習および予測を行った。この交差検証により、同一試験片内の画像に対する推定性能だけでなく、未学習の試験片に対する推定性能を確認した。


評価指標として、平均絶対誤差 (MAE)、二乗平均平方根誤差 (RMSE)、予測値と正解ラベルの相関係数、および予測バイアスを用いた。MAEは、予測値と正解値の差の絶対値を平均した値であり、予測誤差の大きさを表す。一方、予測バイアスは、予測値から正解値を差し引いた値の平均であり、正の値であれば全体として過大評価、負の値であれば全体として過小評価であることを示す。また、寿命消費率を複数の区間に分け、区間ごとの誤差を集計することで、初期域、中間域、高損傷域における推定傾向を確認した。加えて、正解値と予測値の散布図および誤差ヒストグラムを作成し、モデルの系統的な過大評価または過小評価の有無を確認した。



撮影：0 cycles
寿命消費率：0.000



撮影：3900 cycles
寿命消費率：0.501



撮影：6900 cycles
寿命消費率：0.887

図4 繊維ロープの U 曲げ疲労試験における撮影画像の例

3 研究結果及び考察

3.1 鋼ロープ高荷重条件に対する推定結果

鋼ロープ高荷重条件の画像データを対象として、試験片単位の leave-one-specimen-out 4-fold 交差検証を行った。各 fold では、4 本の試験片のうち 1 本を検証用、残り 3 本を学習用として用いた。評価結果を表 4 に示す。

全検証データを統合した場合、MAE は 0.1317、RMSE は 0.1692、相関係数は 0.8680 であった。fold 1 から fold 3 では MAE がおおむね 0.09 から 0.10 程度であり、未知試験片に対しても寿命消費率を一定の精度で推定できた。一方、STEEL_HIGH_01 を検証試験片とした fold 0 では MAE が 0.2056、Bias が 0.1978 となり、他の fold と比較して予測値が全体に高めとなる傾向が認められた。ただし、fold 0 の相関係数は 0.9349 であり、損傷進行に伴う相対的な変化はよく捉えられていた。

fold 0 では、相関係数は高いものの MAE および Bias が大きく、絶対値としては高めに推定される傾向があった。このことから、単一の回帰モデルにより損傷進行の相対的な傾向を捉えることは可能である一方、未知試験片に対して寿命消費率の絶対値を高精度に推定するためには、試験片間のばらつきや損傷発現時期の違いを考慮する必要があると考えられる。

表 3 CNN 回帰モデルの構成

Layer (type)	Output Shape	Param #
input_layer (InputLayer)	(None, 512, 512, 3)	0
conv2d (Conv2D)	(None, 512, 512, 32)	896
max_pooling2d (MaxPooling2D)	(None, 256, 256, 32)	0
conv2d_1 (Conv2D)	(None, 256, 256, 64)	18,496
max_pooling2d_1 (MaxPooling2D)	(None, 128, 128, 64)	0
conv2d_2 (Conv2D)	(None, 128, 128, 128)	73,856
max_pooling2d_2 (MaxPooling2D)	(None, 64, 64, 128)	0
conv2d_3 (Conv2D)	(None, 64, 64, 256)	295,168
global_average_pooling2d (GlobalAveragePooling2D)	(None, 256)	0
dense (Dense)	(None, 256)	65,792
dropout (Dropout)	(None, 256)	0
dense_1 (Dense)	(None, 64)	16,448
dense_2 (Dense)	(None, 1)	65
Total params		470,721
Trainable params		470,721
Non-trainable params		0

表 4 鋼ロープ高荷重条件に対する試験片単位 4-fold 評価結果

fold	検証試験片	データ数	MAE	RMSE	Bias	相関係数
0	STEEL_HIGH_01	13984	0.2056	0.2368	0.1978	0.9349
1	STEEL_HIGH_02	7712	0.0929	0.1136	0.0335	0.8931
2	STEEL_HIGH_03	12912	0.1033	0.1423	0.0571	0.8863
3	STEEL_HIGH_04	12880	0.1031	0.1288	0.0337	0.9252
全検証データ		47488	0.1317	0.1692	0.0884	0.8680

3.2 寿命消費率区間ごとの推定傾向

寿命消費率を複数の区間に分けた場合の誤差傾向を図 6 に示す予定である。試験初期では画像上に明瞭な損傷特徴が現れにくく、低寿命消費率域では予測値が高めに出る傾向が見られた。一方、高寿命消費率域では誤差が比較的小さく、損傷が顕在化した後の画像特徴はモデルにより捉えやすいと考えられる。

低寿命消費率域における過大評価は、試験初期にワイヤロープ表面の画像に明瞭な変化が現れにくいことに起因すると考えられる。この領域では、画像から連続的な寿命消費率を厳密に推定することには限界がある。一方で、安全管理への応用を考えると、低損傷域を厳密な連続値として評価するだけでなく、損傷が顕在化する段階や高損傷域を見逃さないことも重要である。

3.3 考察

本検討により、ラインカメラ画像を用いた畳み込みニューラルネットワークにより、ワイヤロープの損傷進行に伴う画像特徴の変化を一定程度捉えられることが確認された。特に、fold 1 から fold 3 では未知試験片に対しても MAE が 0.10 前後であり、損傷進行度の推定に有効である可能性が示された。一方で、fold




図5 鋼ロープ高荷重条件における 4-fold 検証データの正解値と予測値の関係

0のように予測値が全体的に高めとなる試験片も存在した。この結果は、画像特徴と寿命消費率の対応関係が試験片間で完全には一致しないことを示している。

3.3.1 機械学習モデルとしての技術的考察

技術的な観点からは、本手法は、ワイヤロープ表面の局所画像から損傷進行に関連する特徴を抽出し、寿命消費率という連続値へ対応付ける回帰問題として構成できることを示した点に意義がある。ワイヤロープの損傷は、素線切れ、摩耗、変形、表面状態の変化などが局所的に現れるため、一枚の長尺画像全体をそのまま扱うよりも、パッチ単位で局所特徴を学習する構成は妥当であると考えられる。また、ラインカメラ画像は撮像幅や照明条件を比較的そろえやすく、機械学習に投入する画像データとして扱いやすい利点がある。

一方で、今回の結果は、画像特徴から寿命消費率の絶対値を推定することの難しさも示している。寿命消費率は破断繰返し数に対する割合で定義されるが、同じ寿命消費率であっても、試験片ごとに表面に現れる損傷の見え方が同一とは限らない。fold 0で予測値が全体に高めとなったことは、学習に用いた試験片群と検証試験片との間で、画像上の損傷特徴と寿命消費率の対応関係にずれがあったことを示唆する。したがって、本モデルは損傷進行の相対的な傾向を捉える能力を有する一方で、未知試験片に対する絶対値推定には試験片間ばらつきの影響が残ると考えられる。

また、低寿命消費率域では予測値が高めに出る傾向が見られた。試験初期には画像上に明瞭な損傷特徴が現れにくく、健全状態に近い画像同士の差が小さいため、連続値回帰として細かな寿命消費率差を識別することは難しい。この領域では、寿命消費率を厳密な連続値として推定するよりも、健全域、損傷発現域、高損傷域のような段階的な分類問題として扱う方法も考えられる。あるいは、回帰値そのものではなく、同一




図6 寿命消費率区間ごとの推定誤差

ロープに対する推定値の時系列変化を利用することで、初期状態からの相対的な変化を検出する方法が有効である可能性がある。

今後の技術的課題としては、第一に、試験片数およびロープ条件を増やし、モデルが試験片間ばらつきを学習できるようにすることが挙げられる。第二に、画像のみではなく、ロープ張力、ロープ種別、撮影時の繰返し数、過去の推定履歴などの補助情報を入力に加えることで、画像特徴と寿命消費率の対応を補正できる可能性がある。第三に、パッチ単位の推定結果を単純に平均するだけでなく、ロープ全体における高損傷パッチの割合や、推定値の空間分布を利用する集約方法を検討する必要がある。これにより、局所的な素線切れや摩耗の発生をより直接的に評価できる可能性がある。

3.3.2 点検支援技術としての位置づけ

以上を踏まえると、機械学習を用いたワイヤロープ検査は、モデルの変更等により精度が向上したとしても、現段階では「自動判定装置」としてではなく、「点検支援技術」または「状態監視技術」として活用することが妥当である。具体的には、画像の定期取得、推定値の時系列表示、急激な変化の検出、点検者への注意喚起、および点検記録の保存といった用途が考えられる。このような使い方であれば、デジタル技術の利点である継続的記録性、定量性、遠隔性を活かしつつ、最終判断を人が行う安全管理体系と整合させることができる。

3.3.3 データ蓄積による安全管理への波及効果

また、機械学習を用いた検査技術の導入は、推定モデルを構築することにとどまらず、安全管理に利用可能なデータを継続的に蓄積する契機となる。画像、使用条件、点検結果、破断寿命などを対応付けて保存することで、従来は点検者の経験や一時的な判断に依存していた情報を、後から比較・検証可能な形で記録できる。これにより、過去画像との比較による損傷進行の把握、点検対象の優先順位付け、熟練者の判断の形

式知化、および教育訓練用データとしての活用が可能となる。

さらに、多数の事例が蓄積されれば、損傷の進行速度、使用条件と劣化傾向の関係、点検周期や交換判断の妥当性を検討するための基礎資料となる。これは、機械学習モデルによる自動判定そのものよりも広い意味で、デジタル技術が安全管理にもたらす重要な効果である。ただし、蓄積されたデータを安全管理に利用するには、撮影条件、ラベル付け方法、対象設備の使用条件などを併せて記録し、データの意味を後から解釈できる形で管理することが必要である。

3.3.4 デジタル技術マップ上の位置づけ

本検討で扱った機械学習技術は、デジタル技術マップにおいて、画像計測、データ蓄積、状態推定、点検支援を接続する技術要素として位置づけられる。すなわち、ラインカメラによりワイヤロープ表面の画像を取得し、画像と使用条件、観察時点、破断寿命などを対応付けて保存し、機械学習により損傷進行に関連する指標へ変換する一連の流れである。この整理により、機械学習は単独の自動判定技術ではなく、取得されたデジタルデータを安全管理上利用可能な情報へ変換する中間的な技術として位置づけられる。

安全管理への適用可能性としては、推定値を用いた即時の使用可否判定よりも、定期的に取得した画像および推定値を時系列的に比較し、損傷進行の傾向や通常と異なる変化を把握する用途が有効であると考えられる。また、推定結果を点検者に提示することで、重点的に確認すべき対象や部位を選定する支援にも利用できる。この意味で、本技術は、点検者の判断を置き換えるものではなく、点検記録の定量化、確認対象の優先順位付け、および遠隔確認を支援する技術として整理できる。

一方で、デジタル技術マップへ反映する際には、機械学習モデルの推定精度だけでなく、データの取得条件、ラベル付け方法、対象設備の使用条件、誤推定時の影響、および人による最終判断との役割分担を併せて整理する必要がある。

4 結論

本研究では、ワイヤロープの U 曲げ疲労試験中に取得したラインカメラ画像を対象として、畳み込みニューラルネットワークを用いた寿命消費率推定の基礎的検討を行った。撮影画像から局所パッチを生成し、破断繰返し数に対する観察時点の繰返し数の割合を寿命消費率として与えることで、画像から損傷進行状態を連続値として推定する回帰モデルを構築した。

鋼ロープ高荷重条件を対象とした試験片単位の 4-fold 評価では、全検証データに対して MAE 0.1317, RMSE 0.1692, 相関係数 0.8680 を得た。fold 1 から fold 3 では MAE が 0.10 前後であり、未知試験片に対しても損傷進行度を一定程度推定できる可能性が示された。一方、fold 0 では予測値が全体的に高めとなり、寿命消費率の絶対値推定には試験片間差の影響が残ることも確認された。このことから、本手法は損傷進行に伴う相対的な画像特徴の変化を捉える一方で、未知試験片に対して高精度な絶対値推定を行うには、より多様な条件のデータ蓄積とモデル改善が必要である。

安全管理への応用を考えると、本技術は現段階では自動判定装置として単独で用いるのではなく、点検支援技術または状態監視技術として位置づけることが妥当である。画像を定期的に取得し、推定値を時系列的に保存することで、損傷進行の把握、点検対象の優先順位付け、点検記録の客観化、および遠隔確認への活用が期待できる。また、機械学習に用いるための画像、使用条件、点検結果、破断寿命などのデータを継続的に蓄積することは、熟練者の判断の形式知化や、点検周期・交換判断の妥当性を検討するための基礎資料としても有用である。

今後は、鋼ロープおよび繊維ロープを含むより多様なロープ条件でデータを拡充し、ロープ張力、ロープ

種別，撮影時の繰返し数，過去の推定履歴などの補助情報を組み込んだモデル化を検討する必要がある。また，低寿命消費率域では画像上に明瞭な損傷特徴が現れにくいため，連続値回帰だけでなく，健全域，損傷発現域，高損傷域のような段階的の分類や，推定値の時系列変化を用いた異常検出も検討すべきである。これらの検討により，デジタル技術を活用したワイヤロープ検査の実用性と安全管理上の有効性をさらに明確化できると考えられる。

参考文献

- [1] JIS B 8836 クレーン－ワイヤロープ－取扱い，保守，点検及び廃棄, 2019.
- [2] Masatoshi Ogata, Atsushi Yamaguchi, Naoya Kurahashi, and Kenta Yamagiwa. Statistical modelling of wire breakage progression and rope fatigue life considering tension history. *Engineering Failure Analysis*, 186:110476, 2026.

研究発表

1. 論文発表

該当なし。

2. 学会発表

該当なし。

知的所有権の取得状況

1. 特許取得

該当なし。

2. 実用新案登録

該当なし。

3. その他

該当なし。