

台車部品の探傷データに対する機械学習に基づくきず検出手法

牧野 一成* 小笠原 柚*

A Machine-Learning-Based Flaw Detection Method for Inspection Data of Bogie Parts

Kazunari MAKINO Yu OGASAWARA

Nondestructive inspections such as magnetic particle testing and ultrasonic testing are used to inspect railway vehicle bogie parts. However, identifying flaws from images or waveforms requires significant experience. Therefore, we developed a machine-learning-based method to automatically detect flaws. In magnetic particle testing, false indications caused by surface roughness require discrimination. Our model extracts suspected regions and identifies connected ones as flaws, achieving an accuracy of about 70%. In ultrasonic testing, where surface-shape echoes are confused with flaw echoes, a model trained on simulated waveforms detected internal flaws with an accuracy exceeding 95%. These methods enable uniform identification and de-skilling of flaw detection.

キーワード：台車部品，磁粉探傷，超音波探傷，機械学習，畳み込みニューラルネットワーク

1. はじめに

鉄道車両の台車枠，輪軸などの台車部品に対しては，従来，磁粉探傷や超音波探傷などの非破壊検査が行われている¹⁾．台車部品の磁粉探傷で，特に台車枠に関しては，台車枠に起因した近年の重大インシデントの発生に伴って探傷検査箇所は増加傾向にある²⁾．一方で，検査業務の省力化，省人化や脱技能化が求められているが，磁粉探傷ではきず指示模様の判定に相応の経験，技能や知識を要し，技術継承における継続的な課題となっている．その対策の一つとして，台車枠の磁粉探傷検査の自動化が考えられる．具体的には，磁粉探傷で取得した画像に対して機械学習を適用し，きずを自動的に検出手法である．台車部品の超音波探傷に関しては，横軸を受信時刻に相当する距離（ビーム路程），縦軸をエコー高さとして表示した波形をもとに探傷する場合，ある時刻（距離）に現れたエコーの高さがしきい値を超えたときに「きず」と判定するのが一般的で，波形の解釈には経験を要する．このような時刻歴の波形データに対して機械学習を適用すれば，探傷の自動化が実現できる可能性がある．また，波形の画面をキャプチャした「画像」を用いれば，磁粉探傷と同様に画像に対して機械学習が適用可能となる．

非破壊検査においては近年，外観検査，磁粉探傷，赤外線サーモグラフィ等で得られた画像データや，超音波探傷で得られた波形や断面像に対して，AIや機械学習を適用する研究が活発に進められている³⁾．そこで本報告では，台車部品の探傷を人手に依らず自動化するための要素技術として，台車枠の磁粉探傷や超音波探傷で得られた結果に対して機械学習を適用し，磁粉模様あるいは超音波波形からきずを自動的に検出手法について述べる．磁粉探傷では，溶接試験片の磁粉探傷画像を分割して作成した多数の画像を畳み込みニューラルネットワーク（CNN：Convolutional Neural Network）⁴⁾で機械学習させ，きずの検出時には，きず疑いの箇所が複数つながっていれば「きず」と判定する手法を検討した．超音波探傷では，台車枠の探傷を想定した波形を「時刻歴データ」として機械学習させたモデル，および波形のキャプチャ画像をCNNで機械学習させたモデルを作成し，それらのきず検出性能を評価した．

* 車両技術研究部 車両強度研究室

2. 磁粉探傷画像の取得

2.1 試験片

磁粉探傷画像の取得には、溶接欠陥試験片（Sonaspection International Ltd.製：21 体，Flaw Tech Inc.製：10 体，計 31 体）を用いた。試験片形状の内訳は T 継手が 8 体，突合せ継手が 23 体である。各試験片には溶接内部のきずを含む複数のきずが設けられているが，磁粉探傷で検出可能な表面きずのみを対象とした。

2.2 画像の取得方法

磁粉探傷画像取得時の使用機材一覧を表 1 に，機材配置を図 1 に示す。カメラの画角を「引き」「標準」「寄り」の 3 通り，ブラックライトの照射の向きを「下から」「左から」の 2 通りとし，撮影条件を変えながら画像を取得した。きずがある部位の画像だけでなく，学習に必要な「きずなし画像」も取得した。

表 1 磁粉探傷画像取得時の使用機材一覧

実施項目	種別	名称
磁粉探傷試験	磁化装置	携帯型交流極間式磁化器 NC-21 (日本電磁測器株式会社製)
	ブラックライト	LB-104 (電子磁気工業株式会社製)
	磁粉液	蛍光磁粉液 SY-8000 (栄進化学株式会社製)
画像取得	デジタルカメラ	PowerShot G10 (キヤノン製, 記録画素数 1600×1200px, Y2 フィルタ装着)




図 1 磁粉探傷画像取得時の機材配置

2.3 取得した画像

T 継手のきずあり箇所において，画角およびブラックライトの照射の向きを変化させて撮影した画像の例を図 2 に示す。きずによる磁粉模様のほかに，溶接ビードの凹凸での磁粉の付着による疑似模様が確認できる。2.2 節に示した方法で，きずを含む画像を約 600 枚，含まない画像を約 700 枚取得した。




図 2 T 継手のきずあり箇所撮影した画像の例

3. 磁粉探傷画像の機械学習によるきず検出

3.1 機械学習によるきず検出の手順

3.1.1 全体の流れ

本章では、磁粉探傷画像の機械学習によるきず検出の概要と、それを用いたきず検出結果について述べる。本研究では、画像におけるきずの有無の分類問題に対して、CNN による教師あり学習を行った。CNN は 2 次元的な構造を有するデータをそのまま学習に用いることができる手法であり、画像を用いた機械学習に適している。

磁粉探傷画像に対する機械学習によるきず検出の手順を、図 3 および以下に箇条書きで示す。

- ① 磁粉探傷画像を学習用画像とテスト用画像に分ける。
- ② 学習用画像から分割画像を作成し、各分割画像にきず有無の情報を付与する。
- ③ 分割画像ときず有無の情報を機械学習プログラムに入力する。
- ④ 機械学習プログラムを実行し、学習済みモデルを生成する。
- ⑤ 学習済みモデルを用いて、テスト用画像に対して分割領域ごとのきず検出を行う。
- ⑥ 分割領域ごとのきず検出結果から、画像全体におけるきずあり／きずなしの判定を行う。

3.1.2 画像の準備

手順①では、2.3 節で述べた約 1300 枚の画像のうち、極端な白飛びやボケがある画像を除外し、658 枚を学習用画像、198 枚をテスト用画像として、両者が重複しないようにランダムに選択した。

手順②では、学習用画像（1600×1200px）を 100×100px で 192 分割（16×12 分割）し、 $658 \times 192 = 126336$ 枚の分割画像を作成した。各分割画像を目視で確認し、教師あり学習に必要なきず有無の情報（きずあり=1、きずなし=0）を付与した。分割画像の作成ときず情報の付与について図 4 に示す。




図3 磁粉探傷画像に対するきず検出の手順




図4 分割画像の作成ときず情報の付与

3.1.3 学習過程

学習用画像から作成した上述の 126336 枚の分割画像は、その大半がきずなし画像で、きずありの画像は限られている。そこで、きずあり画像の枚数を基準として、きずあり／きずなしの比率を確保しつつラン

ダムに選択し、「訓練データ」と「検証データ」の2種類に両者が重複しないように分類した。学習に用いた分割画像の枚数の内訳を表2に示す。検証データとは、訓練データを用いた学習の途中できず検出を試行し、学習モデルの精度の確認および向上のために用いるデータのことをいう。

手順③、④で用いた学習モデルの構成を図5に示す。訓練データ、検証データ両方の画像に対してグレースケール化および輝度値の正規化の前処理を行ったうえで、畳み込み層が5層、プーリング層が4層で構成される自作のCNNモデルに入力した。各畳み込み層における活性化関数にはReLU関数を用い、過学習を防止する目的でドロップアウトを設けた。その後、平坦化、全結合層を経て、最終的にSoftmax関数によりきず有無の判定（きずあり／きずなし）が得られる。CNNにおけるエポック数（学習の繰返し回数）を50、バッチサイズ（一度に入力する画像の枚数）を16として学習プログラムを実行し、判定結果が実際のきず有無の情報に合致するように学習を進め、学習済みモデルを生成した。

表2 機械学習モデルの学習過程で使用した分割画像の枚数内訳

単位：枚		きずあり	きずなし	総枚数
学習用分割画像（7200）	訓練データ	720	5040	5760
	検証データ	160	1280	1440




図5 磁粉探傷画像の学習モデルの構成（CNNモデル）

3.1.4 テスト過程

手順⑤、⑥のテスト過程では、テスト用画像（1600×1200px）に対して、100×100pxの分割領域ごとに学習済みモデルを用いてきず検出を実施し、「分割領域内にきずが含まれる」と判定された場合に、テスト用画像の当該箇所を赤枠囲みで示すこととした。また、各分割領域の境界付近におけるきず検出精度を高めるため、最初の分割から縦・横方向に50pxずつずらした領域ごとのきず検出も同様に実施し、きずありと判定された箇所を青枠囲みで示すこととした。

3.1.5 学習済みモデルの精度評価

テスト用画像を用いたきず検出結果に基づき、学習済みモデルの精度評価を実施した。分割領域ごとのきず検出結果を、真陽性（TP：True-Positive）、偽陽性（FP：False-Positive）、真陰性（TN：True-Negative）、偽陰性（FN：False-Negative）の4種類に分類した混同行列を作成し、正解率、適合率、再現率、F1値を算出した。各評価指標の定義を図6に示す。正解率はきずの有無を正しく予測できた割合、適合率はきずの誤検出の少なさ、再現率はきずの見逃しの少なさ、F1値は適合率と再現率の調和平均（バランス）を表す指標で、いずれの指標も1に近いほどモデルの性能がよいことを表す。




図6 機械学習における成績（評価指標）の定義

3.2 磁粉探傷画像のきず検出結果

3.2.1 テスト用画像に対するきず検出の例

198 枚のテスト用画像に対して学習済みモデルを用いてきず検出を行った。きず検出結果の例を図 7 に示す。図 7(a)はきずを含む画像の例で、きずによる磁粉模様の箇所が赤枠または青枠で囲まれており、きずが正しく検出されている。一方、図 7(b)はきずを含まない画像の例で、正しく評価されれば枠囲いの箇所が生じないはずだが、溶接止端部や、溶接ビードの形状変化部での疑似模様がきずとして誤検出されていた。




図7 テスト用画像に対するきず検出の例

3.2.2 きず検出精度の確認

すべてのテスト用画像に対してきず検出を行い、分割領域ごとのきず検出結果を分類した混同行列を表 3 に、算出されたきず検出精度の評価指標を表 4 に示す。対象とした分割領域の総数は、198 枚のテスト用画像を 192 分割した $198 \times 192 = 38016$ 領域である。ここでは、赤枠の分割領域に対する結果を示すが、青枠に対する結果も同様であった。表 4 より正解率は 99%と高いが、表 3 の混同行列で、きずなし領域を「きずなし」と判定した件数が極端に多い (37206 件) ためである。一方、適合率は 50%であった。これは、「きずあり」と判定した領域のうち半数は正解だったが、残りは誤検出 (実際にはきずなし) であったことを意味する。再現率は 67%で、実際にきずがある領域に対して「きずあり」と判定できたのが 2/3 程度 (1/3 程度は見逃し) であったことを意味する。

表3 テスト用画像におけるきず検出結果の分類
(混同行列：赤枠囲みの場合)

領域総数：38016		学習済みモデルによるきず検出結果（予測）	
		きずなし	きずあり
磁粉探傷結果 (真値)	きずなし	37206	328
	きずあり	160	322

表4 学習済みモデルの精度評価結果


項目	精度 (%)
正解率 (Accuracy)	99
適合率 (Precision)	50
再現率 (Recall)	67
F1 値 (F-measure)	57

3.2.3 きず検出領域の連続性を考慮したきず判定

図 7(a)の赤・青枠で示したように、「きずあり」と判定された領域が実際にきずであった場合には、検出領域の枠が複数個連続している場合が多い。一方、図 7(b)で「誤検出」と示した箇所は、一部の例外はあるが、その多くは連続する枠の数が 2 個以内に収まっている。そこで、きずありと判定された分割領域が複数つながっていれば「きず」と判定することで、きずの誤検出を低減し、正解率および適合率を向上させる手法を検討した。ここでは、きず検出の枠が 3 個以上連続したときにきずと判定することとした。

この方法により誤検出が低減した例を図 8 に示す。図 8(a)では、溶接部の疑似模様によって「きずあり」と判定されていた枠が連続性判定により除外され、画像全体で正しく「きずあり」と判定された。図 8(b)（図 7(b)と同一箇所）も同様に、疑似模様による誤検出の枠の大半が連続性判定により除外された。ただし、この例では誤検出の枠が残っており、画像全体としては「きずあり」判定（誤検出）のままである。

きず検出領域の連続性を考慮したきず判定により、テスト用画像の画像単位できずの有無を判定した。きずなし画像 118 枚は、画像全体をそのまま 1 枚の画像として判定した。一方、きずあり画像 80 枚については、きずの有無が明確な領域ごとに評価を行うため、各画像からきず周辺の部分を切り出し、これを新たな「きずあり画像」、それ以外の部分を「きずなし画像」として定義した。すなわち、のべ枚数で 118 + 80 + 80 = 278 枚の画像に対して判定を行った。連続性判定による画像単位での判定結果（混同行列）を表 5 に、各評価指標を表 6 に示す。表 6 では比較のために、表 4 に示した分割領域ごとに判定したときの評価指標を再掲した。連続性判定により、きずの見逃しの少なさの指標である「再現率」が 67%→68%とほぼ維持されたまま、誤検出の少なさの指標である「適合率」が 50%から 70%に上昇し、連続性判定の有効性が示された。



(a) きずあり画像への適用例 (b) きずなし画像への適用例
図 8 きず検出領域の連続性の考慮による誤検出の低減

表5 テスト用画像の画像単位での
きずの有無の判定結果（混同行列）

画像の枚数：278 (のべ枚数)		学習モデル+連続性判定	
		きずなし	きずあり
磁粉探傷結果 (真値)	きずなし	175	23
	きずあり	26	54

表6 連続性判定によるきず検出精度
と分割領域のみでの結果との比較

項目	精度 (%)	
	分割領域のみ	連続性判定
正解率	99	82
適合率	50	70
再現率	67	68
F1 値	57	69


※赤いセルは、両者のうち精度が高いほうを示す。

4. 超音波探傷波形の機械学習によるきず検出

4.1 超音波探傷波形の準備

4.1.1 超音波探傷の解析モデル

本研究では、機械学習させるための超音波探傷データを、シミュレーションにより取得した。鉄道車両の台車枠などでの使用を想定した厚さ $t = 8\text{mm}$ の鋼板において、鋼板表面に存在する傾斜したきず、および種々の余盛形状を有する溶接ルート部に生じたきずの2種類を対象として、屈折角 $\theta = 70^\circ$ の横波を用いた一回反射法による斜角探傷のための2次元有限要素モデルを作成した。図9(a)に示す鋼板の表面傾斜きずモデル（以下、鋼板モデル）では、きず高さを $d = 1.76\text{mm}$ とし、表面に対する傾斜角 η を $-60^\circ \sim +60^\circ$ の範囲で変化させた。一方、図9(b)に示す溶接ルート部のきずモデル（以下、溶接モデル）は、厚さ $t = 8\text{mm}$ の鋼板表面に厚さ 15mm の部品をすみ肉溶接した構造を模している。きず高さ d は鋼板モデルと同じ 1.76mm とし、傾斜角 η は 0° で固定とした。すみ肉溶接の脚長は 8mm （等脚長）とし、溶接止端部の余盛接触角 ξ を $0^\circ \sim 90^\circ$ の範囲で15段階で変化させた。いずれの解析モデルでも、きず波形と比較するための「きずなし波形」の取得のために、きずがないモデルを作成した。モデルの要素サイズは 0.04mm 四方とした。モデルに用いた各要素の材料定数を表7に示す。



(a) 鋼板の表面傾斜きずモデル（鋼板モデル） (b) 溶接ルート部のきずモデル（溶接モデル）

図9 シミュレーションによる超音波探傷波形の取得のため2次元有限要素モデル

表7 超音波探傷の解析モデルに用いた各要素の材料定数

要素	材質	縦波音速 c_L (m/s)	横波音速 c_T (m/s)	密度 ρ (kg/m ³)
鋼板, 溶接部	鉄鋼	5900	3230	7800
探触子くさび	PMMA (アクリル)	2730	1430	1180

4.1.2 探傷波形の取得

一回反射法による斜角探傷のために、斜角探触子の入射点からきずまでの距離が1スキップ ($= 2t \tan \theta =$ 約 44.0mm) の位置を基準として、基準位置から $\pm 15\text{mm}$ の範囲で探触子を走査させながら周波数 5MHz の超音波を送信したときに、各位置における「きずあり」および「きずなし」の受信波形を取得した。計算には、伊藤忠テクノソリューションズ(株)製の超音波シミュレーションソフトウェア ComWAVE Ver. 11.0.0 を用いた。取得した波形の内訳を表8に示す。波形の総数は2173で、きずなし波形が636、きずあり波形が1537である。各波形は、送信から受信完了までの時刻 $0 \sim 50\mu\text{s}$ の間の9218点（約 5.424ns 間隔）における受信波振幅が収納された、 $9218\text{点} \times 2\text{次元}$ （時刻、振幅）の数値データとして取得した。数値データを波形（散布図）として描画した例を図10に示す。これらは鋼板モデルの波形の例であるが、溶接モデルでは、余盛形状によってはきずエコーとの区別が難しい妨害エコーが現れる場合があった。

表 8 各解析モデルで取得した波形の内訳

	きずなし	きずあり	合計
鋼板モデル	21	922	943
溶接モデル	615	615	1230
合計	636	1537	2173




図 10 超音波シミュレーションで取得した探傷波形の例（鋼板モデル）

4.2 きず検出の手順および検出結果

4.2.1 波形の前処理

4.1.2 項で述べた総数 2173 の各波形の数値データに対して、「きずなし：0」または「きずあり：1」の正解ラベルを付した。波形データを正規化したうえで、ラベルデータとともに（学習データ）：（テストデータ）=4:1 の割合で分割し、それぞれ、機械学習モデルの学習とテストに用いた。学習データおよびテストデータは、全データにおける「きずなし」「きずあり」データの比率（636:1537）を維持したまま、鋼板モデルと溶接モデルのデータを区別せず、ランダムに分割した。

4.2.2 学習アルゴリズムの選択とモデルの最適化

Python の機械学習ライブラリである scikit-learn のユーザーガイドに示されている「アルゴリズム・チートシート⁵⁾」のうち、本研究のような「きずなし」「きずあり」の分類問題に対応可能なアルゴリズムとして、リニア SVC、 k -近傍法、決定木、ランダムフォレストなどが挙げられる。各アルゴリズムを用いて学習モデルの性能を事前に評価した結果、本研究で用いた波形データに対してはランダムフォレストが最適と判断された。さらに、層化 5 分割交差検証の手法により、ランダムフォレストモデルに用いるパラメータを最適化し、各パラメータの値を、決定木の数 150、特徴量の数 14、木の最大深さ 13 に設定した。

4.2.3 最適化モデルによるきず検出結果

交差検証で最適化されたパラメータのうち、決定木の数と特徴量の数を維持したまま、木の最大深さを変化させたときに、テストデータにおけるきずの有無を判定したときの各評価指標の推移を図 11 に示す。ここでは参考のため、学習モデルの性能の目安となる交差検証での正解率を併せて示した。木の深さが 8 程度で各指標は概ね収束し、いずれも 97%を超える良好な成績が得られた。特に、テストデータでのきず検出の再現率は 100%を達成した。




図 11 ランダムフォレストの最適パラメータで波形を学習させたときの評価指標の推移

5. 超音波探傷画像の機械学習によるきず検出

5.1 はじめに

前章では、超音波探傷の波形を数値データとして扱ったときの機械学習について述べたが、自動探傷装置や一般的なポータブル超音波探傷器を用いて取得したデータは、全波検波後の波形をキャプチャした「画像」として保存されている場合も多い。本章では、4章で用いたものと同じデータをもとに、全波検波波形として画像化したデータを学習させたモデルを用いてテストデータを判定させたときの成績を評価した。

5.2 きず検出の手順および検出結果

5.2.1 画像の作成と前処理

4.1.2 項で述べた各波形の数値データをもとに、図 12 に示すような全波検波画像を 2173 枚作成した。全波検波波形とは、波形の振幅が負の部分の折り返して（絶対値で）示した波形である。ただし、画像としての学習に不要な、縦軸、横軸の表示は省略した。超音波探傷画像の学習では、3章の磁粉探傷画像のときと同様に CNN ベースのモデルを用いるが、CNN を利用するためのプログラムの一つである Python の TensorFlow への入力に適したデータ形式に変換する必要がある。詳細は割愛するが、最終的に、画像サイズが $200 \times 200\text{px}$ で、0~1 の浮動小数点数に正規化された、 $(2173, 200, 200, 1)$ 次元（画像 2173 枚 × 縦 200px × 横 200px × 1ch（グレースケール））の 4 階テンソルの入力データを作成した。




図 12 超音波探傷画像の機械学習に用いた全波検波画像の例（鋼板モデル）

5.2.2 機械学習の手順

超音波探傷画像の CNN による機械学習のため、磁粉探傷画像のときと同様に、画像データを学習用の訓練データと検証データ、およびテストデータの 3 種類にランダムに分割した。分割の割合は $64 : 16 : 20$ とし、各データにおける「きずなし」「きずあり」の比率は、データ数が整数の範囲で元の比率（ $636 : 1537$ ）を維持した。超音波探傷画像の学習に用いた CNN モデルの構成例を図 13 に示す。図 5 に示した磁粉探傷画像用のモデルよりもややシンプルで、この例では、畳み込み層（Cv）、プーリング層（Pl）が各 2 層（ $(Cv-Pl) \times 2$ と呼ぶ）で構成されている。これ以外に、 $(Cv-Pl) \times 3$ や $(Cv-Cv-Pl) \times 2$ のような構成の CNN モデルについても検討した。




図 13 超音波探傷画像の学習に用いた CNN モデルの構成例（ $(Cv-Pl) \times 2$ モデル）

5.2.3 学習結果およびテストデータでのきず検出結果

CNN モデルによる学習の例として、(Cv-Cv-PI)×2 で構成されたモデルでの学習結果を図 14 に示す。20 エポック程度まで学習が安定しなかったが、それ以降は安定に推移した。学習終了時の正解率は、訓練データ、検証データともに 100%で、誤差も十分小さな値であった。また、テストデータにおけるきずの有無を判定した結果、すべて正解（正解率 100%）であった。




図 14 超音波探傷画像の CNN モデル(Cv-Cv-PI)×2 による学習結果

6. まとめ

台車部品の探傷を人手に依らず自動化するための要素技術として、台車枠の磁粉探傷や超音波探傷で得られた結果に対して機械学習を適用し、磁粉探傷画像あるいは超音波探傷波形からきずを自動的に検出する手法について検討した。

磁粉探傷に関しては、溶接試験片の磁粉探傷画像を分割して作成した多数のきずありおよびきずなし画像を CNN で機械学習させた。テスト用画像の評価では、分割サイズに対応する領域ごとにきずの疑いがある箇所を学習済みモデルを用いて検出し、それらが複数つながっていれば「きず」と判定する手法を用いることで、溶接部の表面きずを概ね 70%の成績（再現率あるいは適合率）で検出できた。超音波探傷に関しては、台車枠の探傷を想定した波形を「時刻歴データ」として機械学習させたモデルを用いた場合、溶接部の内部きずを 95%以上の成績で検出できた。同じ波形を全波検波波形として画像化したデータを CNN で機械学習させたモデルを用いた場合でも、同等の成績できずを検出できた。

構築した機械学習モデルおよび手法を台車部品の検査に適用することで、まずは、磁粉探傷画像や超音波探傷波形からきずの有無を判断する際の補助的な用途として活用することが可能である。今後は、鉄道事業者の車両検修現場で取得した実データを学習させてきず検出精度の向上を図り、探傷装置のロボット化を含めた探傷プロセス全体の自動化につながるよう研究を進める。

文 献

- 1) 牧野一成：台車枠の表面きずを効率的に検査する，RRR，Vol.65，No.11，pp.18-21，2008
- 2) 北村未来登：台車枠磁粉探傷検査の改善，R&m，Vol.29，No.9，pp.24-26，2021
- 3) 日本非破壊検査協会：第 3 回 NDE4.0 シンポジウム講演概要集，2025
- 4) 例えば，斎藤康毅：ゼロから作る Deep Learning—Python で学ぶディープラーニングの理論と実装，オライリー・ジャパン，2016
- 5) Scikit-learn User Guide, "Choosing the right estimator", https://scikit-learn.org/stable/machine_learning_map.html（参照日：2026 年 5 月 19 日）