

スペックルパターンの畳み込みニューラルネットワークによる 摩擦係数予測システムの提案

Development of a Friction Coefficient Prediction System using Convolutional Neural Network(CNN) and Speckle Patterns

東理大・工(学) *松田航 東理大院・工(学) 湯原 裕司 東理大院・工(学) 佐藤 魁星

東理大・工(正) 佐々木 信也

Wataru Matsuda*, Yuji Yuhara**, Kaisei Sato**, Shinya Sasaki*

*Tokyo University of Science, **Graduate School of Tokyo University of Science

1. 緒言

しゅう動部における摩擦係数のその場計測は、故障の事前検知や早期警告を可能にすることから、機械要素メンテナンスにおいて重要な役割を持つ。従来、摩擦係数の取得にはロードセルやひずみゲージなどのセンサーが用いられてきたが、センサーを物理的に接触させて設置する必要があり、しゅう動部によっては物理的な制約がある。そのため、しゅう動箇所に非接触かつ、摩擦状態を特徴づけるパラメータから、摩擦係数を予測する技術が求められている。しゅう動部の摩擦状態を特徴づけるパラメータ取得方法として、表面粗さを非接触で取得できるレーザスペックル法がある。レーザスペックル法はしゅう動表面にレーザを当て、スペックルパターンと呼ばれる反射散乱光を解析することで表面粗さを簡易的に取得することが可能である¹⁾。表面粗さは、二面間の接触状態に影響し、摩擦係数を決定づける因子であるため、表面粗さ情報から摩擦係数の予測が可能であると考えられる²⁾。また、摩擦係数の予測には、蓄積した膨大なデータを学習し、予測アルゴリズムを構築することが必要となる。

近年、摩擦係数を予測する情報処理として、機械学習が注目されている。機械学習は、膨大な量のデータを学習し、将来の値の予測、異なる要因間の関係の特定などを行うことができるため、複雑な摩擦特性においても有効な手法であると考えられている。数ある数理モデルのうち、本研究で用いた CNN (Convolutional Neural Network) は、演算において特徴抽出能力が高いという特徴があり、レーザスペックル法により取得した表面粗さ情報から、高精度に摩擦係数を予測可能であると考えられる³⁾。

本研究では、スペックルレーザ法と機械学習を組み合わせることで、新しい摩擦係数の予測手法を提案することを目的とする。本発表では、しゅう動表面のスペックルパターンと摩擦係数を同時取得可能な試験機を開発し、CNN を用いて摩擦係数とスペックルパターンに対して機械学習を行うことで、スペックルパターンによる摩擦係数の予測可能性について調査した結果を報告する。

2. 実験概要

2.1 実験装置

Figure 1 に本試験機のスペックルパターン取得光学系の概略図を示す。自作試験機は、ボールオンディスク式とし、ディスクが回転する機構とした。また、半回転後のしゅう動部からスペックルパターンを取得するため、ディスク側面にレーザを配し、レーザの散乱光を取得するハイスピードカメラ (MEMCAM Q1v, NAC, JP) をディスク上部に設置した。また、摩擦係数の計測には、ロードセルを使用した。Table 1 に実験条件を示す。しゅう動材料には、Φ46 mm の SUJ2 ディスクならびに Φ12.7 mm の SUJ2 ボール、潤滑油にはポリアルファオレフィン 4 (PAO 4) を用いた。

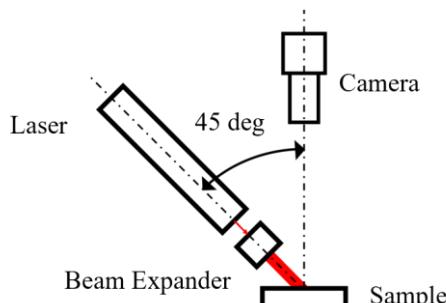


Fig. 1 Optical system for laser speckle observation

Table 1 Test condition

Disk size, mm	$\Phi 46 \times t 5$
Ball size, mm	$\Phi 12.7$
Normal load, N	10
Temperature, °C	25
Reciprocating speed, rpm	40
Sampling rate, Hz	1000, 100, 10
Acquisition Time, s	160

2.2 学習方法ならびに予測精度の評価

Table 2 に、CNN で用いた学習条件を示す。入力データは自作の試験機により得られたスペックルパターンとし、同試験機にて測定された摩擦係数を出力するように CNN にて学習させる。Fig. 2 に用いた CNN の構造を示す。本研究では CNN の学習において重要であるバッチサイズと学習率、ならびに摩擦係数を取得する際のサンプリング周波数を変えた場合の学習精度を検証した。サンプリング周波数に関しては、100 Hz の際に 156200 枚のスペックルパターンデータと同数の摩擦係数データを用いて学習を行っており、100 Hz および 10 Hz においては、ダウンサンプリングを行って検証した。また、全体のデータの 8 割を学習データ、2 割を評価データとして用い、平均二乗誤差 (MSE) および決定係数 (R^2) を精度の指標パラメータとして用いることとした。

3. 実験結果

3.1 摩擦係数測定

Figure 3 に、自作摩擦試験により得られた摩擦係数の時間変化を示す。摩擦係数は ± 0.1 程度の振れがあるものの、開始時から終了時にかけて、安定的に摩擦係数が取得できていることが確認された。このことから、自作した摩擦試験機により得られた摩擦係数のデータを、学習に用いるデータとして用いた。

3.2 スペックルパターン測定

Figure 4 に本摩擦試験機により得られたスペックルパターン画像を示す。接触部を赤枠で示す。スペックルパターンと呼ばれる反射散乱光は斑点模様とし検出されることが知られており、取得画像から同様の傾向が観察された。したがって、自作試験機においても、スペックルパターンは十分に検出できていると判断し、得られたスペックルパターンデータを学習データとして用いた。

3.3 予測精度の確認

Table 3 に、学習率および、バッチサイズ、サンプリング周波数を変更した場合の MSE および R^2 を示す。Table 3 より、サンプリング周波数変化のみに着目すると、サンプリング周波数が大きくなるにつれて MSE が小さくなることから、予測精度が向上することが確認された。またサンプリング周波数を 1000 Hz に固定し、バッチサイズならびに、学習率を変更した際、いずれのバッチサイズにおいても、学習率が 0.01 の時に MSE が小さくなり、予測精度が向上することが確認された。

4. 考察

サンプリング周波数 1000 Hz の場合に、決定係数が 0.7 を超えた。このことから、PAO 4 潤滑下においては、機械学習を用いることで、スペックルパターン画像から摩擦係数の予測は可能であると考えられる。画像の取得のしやすさ、学習データ数による計算コストなどを考慮すると、今回の学習モデルの中では、サンプリング周波数 100 Hz、バッチサイズ 5、学習率 0.01 の条件が最適であると考えられる。ただし、決定係数は 0.8 程度が良好な回帰である⁽⁴⁾ので、実用化には精度がまだ不十分である。以上から、より最適な学習パラメータの探索や学習モデル、スペックルパターンの取得方法の変更などによる精度の検証を行っていく必要があると考えられる。

5. 結言

摩擦係数としゅう動表面のスペックルパターンを同時取得可能な試験機を開発し、摩擦係数とスペックルパターンを CNN で学習することにより、以下の知見を得た。

- (1) 自作した摩擦試験機により、安定した摩擦係数とスペックルパターンの同時取得が可能であることを確認した。
- (2) バッチサイズと学習率ならびにサンプリング周波数を変更させた際に、学習率に関しては、学習率が 0.001 の時と比較し、0.01 の時に MSE の低下が確認され、サンプリング周波数が大きいほど、損失関数の低下が確認された。
- (3) 学習精度の結果から、サンプリング周波数 1000 Hz、学習率 0.01、バッチサイズ 5 の時に、決定係数の値が 0.741 となることが確認された。このことから、摩擦面におけるスペックルパターン画像と摩擦係数との関連が示唆された。

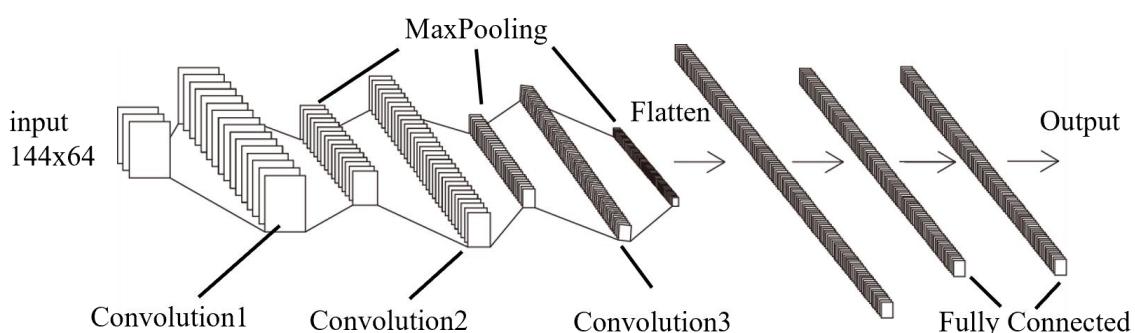


Fig. 2 The architecture of the proposed CNN

文献

- (1) 和田・児山・石澤：スペックルコントラスト法による表面粗さ検出に於ける簡便な検量線構築と表面粗さの検出, 照明学会誌, 103, 6 (2019)
- (2) D. Li, Y. Bin, J. Jin, D. Liu, J. She & D. Zhang: Friction Coefficients Calculation via Surface Roughness Characterization for Tight Sedimentary Rocks, ARABIAN JOURNAL FOR SCIENCE AND ENGINEERING, (2022)
- (3) A. Rosenkranz, M. Marian, F. J. Profito, N. Aragon & R. Shah, The use of artificial intelligence in tribology—A perspective, Lubricants, 9, 2 (2021)
- (4) D. Chicco, M. J. Warrens & G. Jurman, The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation, PeerJ Comput Sci, (2021)

Table 2 Parameters used in CNN Architecture training

Number of Training data	156200
Optimization algorithm	SGD
Learning rate	0.01, 0.001
Number of Epoch	100
Batch size	5, 16, 32
Loss Function	MSE

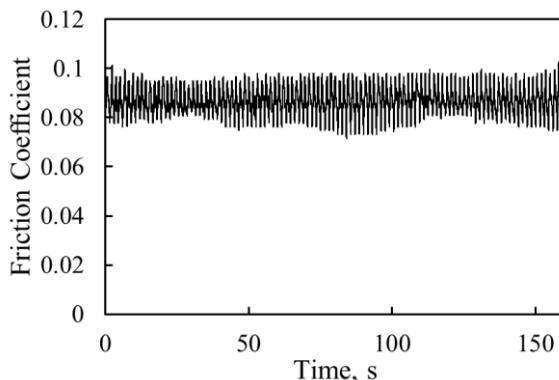


Fig. 3 Time Variation of Friction Coefficient

Table 3 Comparison of different analysis parameters

Sampling Rate, Hz	Learning Rate	Batch Size	MSE	R ²
1000	0.01	5	8.58E-06	0.723
		16	8.85E-06	0.714
		32	8.02E-06	0.741
	0.001	5	9.14E-06	0.705
		16	1.24E-05	0.601
		32	2.06E-05	0.336
100	0.01	5	1.23E-05	0.602
		16	2.08E-05	0.326
		32	3.95E-05	-0.277
	0.001	5	2.90E-05	0.062
		16	1.30E-04	-3.21
		32	2.52E-04	-7.15
10	0.01	5	9.39E-05	-1.75
		16	3.78E-04	-10.1
		32	3.16E-04	-8.24
	0.001	5	3.46E-04	-9.12
		16	9.00E-04	-25.4
		32	9.26E-04	-26.1

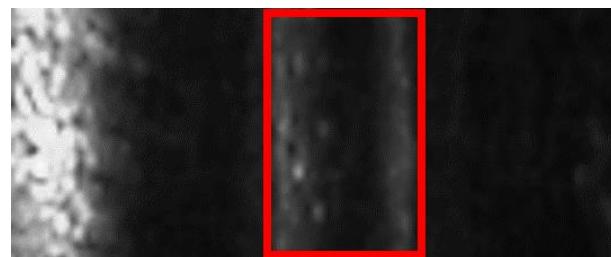


Fig. 4 Speckle Pattern