

方向性テクスチャ表面におけるスペックルパターンを用いた 機械学習による摩擦係数予測に関する研究

Research on Prediction of Friction Coefficient Using Machine Learning
With Speckle Patterns on Directional Textured Surfaces

理科大・工（学）*松井 杏太郎 理科大・工（学）松田 航

理科大・工（正）佐藤 魁星 理科大（正）佐々木 信也

Kyotaro Matsui*, Wataru Matsui*, Kaisei Sato*, Shinya Sasaki*

*Tokyo University of Science

1. 緒言

表面粗さは、しゅう動材料の摩耗、疲労寿命、耐食性など様々な機能に影響を与える。そのため、表面粗さの影響を考察することは、摩擦の科学的な基礎研究から工業的な応用研究に至るまで多くの分野において重要とされている。近年、機械部品の品質向上がより一層求められる中で、稼働中の機械の摩擦挙動を分析する様々な方法が開発されており、Acoustic Emission(AE)による摩耗挙動を推定する手法や、加速度センサによる振動のモニタリングによる手法⁽¹⁾などが提案されている。しかしながら、これらの手法には、環境ノイズとの信号分離の問題や、しゅう動表面から得られる粗さ情報を直接用いていないという問題点があり、従来の問題点を克服した新たなモニタリング手法が求められている。

非接触かつ高速に表面の形状情報を取得して摩擦や粗さのモニタリングを可能とする手段として、スペックルパターンを用いる手法が挙げられる。スペックルパターンとは、レーザ光が粗面で乱反射され、干渉することで生じる光学的な斑点模様であり、スペックルパターンの明暗から粗さの変化を観察することが可能である⁽²⁾。また、先行研究において松田らは、スペックルパターンと機械学習を組み合わせることで、摩擦予測が可能となることを示した⁽³⁾。しかしながら、表面テクスチャリングのような、規則的な粗さを持つ摩擦面におけるスペックルパターンおよび摩擦係数については十分な調査がなされていない、スペックルパターンによる摩擦係数予測の精度と効率は未だ限定的である。

本研究では、溝方向の連続的変化に伴うスペックルパターンと摩擦係数の変化を調査し、機械学習による摩擦係数の予測精度の向上を目的とした。本研究では、試作したスペックルパターンと摩擦係数を同時取得可能な装置を用い、規則性をもった一方向の粗さを付与した表面において、パターン角度と摩擦係数との関係をスペックルパターンを用いた機械学習により予測検証した結果を報告する。

2. 実験方法

2.1 摩擦試験

実験装置として、シリンドラオンディスク摩擦試験機とスペックルパターン測定装置を組み合わせた装置を用いた。Figure. 1に試験機の概要を示す。本試験機では、ステッピングモータにより回転させたSUJ2製ディスクに対し、SUJ2製シリンドラを押し付けてしゅう動を行い、この時の摩擦における反力をロードセルにより測定することで摩擦係数を算出する。また、ディスクしゅう動面上の、シリンドラとの接触点と180 deg反対の位置に波長632.8 nmのHe-Neレーザ光を照射し、その散乱光を高速度カメラにより取得することで摩擦力の取得と同時にスペックルパターンを得る。

表面テクスチャリングの粗さの方向性に関する先行研究においては、しゅう動方向に対して溝方向が垂直な場合に摩擦低減効果が生じることが報告されている⁽⁴⁾。そのため、本研究では、方向性を持つ粗さによる摩擦係数変化を調査することとした。使用するディスクには粗さの大きい紙やすりから徐々に粗さの小さな紙やすりに変えて研磨し、一度鏡面(Sa=0.037)とした。その後#80, #320, #1200の紙やすりを用い、一方向の粗さを付与した。それぞれのディスクにおける算術平均面粗さ(Sa)は0.769 μm, 0.466 μm, 0.375 μmであった。Figure. 2にディスクしゅう動面における粗さ方向を示す。0 deg, 180 degはしゅう動方向に対し平行、90 deg, 270 degはしゅう動方向に対し垂直となっている。これら3種類の粗さの異なるディスクを用い、しゅう動試験およびスペックルパターン測定を行った。Table 1に試験条件を示す。

2.2 機械学習を用いた摩擦係数予測

本実験では、畳み込みニューラルネットワーク(CNN)での画像学習、CNNにより抽出したスペックルパターン画像の特徴量と計算により算出した5つの特徴量(平均輝度、標準偏差、スペックルコントラスト、エントロピー、ラクナリティ)を合わせた多層ペーセプトロン(MLP)による学習の2つのモデルを用いた。そして、摩擦係数予測を行い、精度比較を行った。MLPとは、ニューラルネットワークの基本的な形態の一種であり、あらゆるデータに対応しており、高精度なデータ学習が可能である。Table 2に本実験に用いたCNNモデル、および、CNNとMLPを結合させたモデル

について、それぞれの学習条件を示す。

Table 1 Test conditions

Lubricant Oil	[-]	PAO4
Load	[N]	50
Reciprocating Speed	[rpm]	40
Sliding Speed	[mm/s]	88
Temperature	[°C]	25
Test Time	[min]	30
Max. Hertzian Contact Surface Pressure	[MPa]	405

Table 2 Learning conditions

	CNN	CNN+MLP
Number of Training data	216000	
Optimization algorithm	Adam	
Learning rate	0.0005	0.001
Number of Epoch	50	130
Batch size	2048	
Activation Function	ReLU	
Loss Function	MSE	
Training : Test	7 : 3	

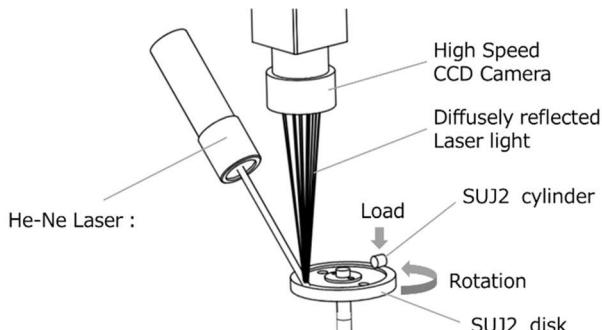


Fig. 1 Test equipment overview

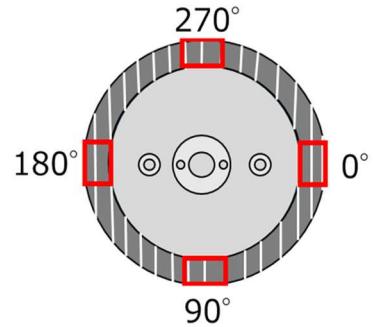


Fig. 2 Direction of disc roughness

3. 結果

3.1 摩擦係数とスペックルパターンの変化

Figure. 3 にディスク 1 回転における摩擦係数変化を示す。粗さに対し平行にしゅう動する際は高い摩擦係数が得られ、垂直にしゅう動する際は低い摩擦係数が得られた。この摩擦係数の傾向は先行研究⁽⁴⁾と合致しており、粗さの方向性と摩擦係数の変化を適切に取得できたことが確認された。粗さの方向性とスペックルパターンの変化の関係を調査するため、スペックルパターンの特徴量として、スペックルコントラストを算出した。スペックルコントラスト C は以下の式で表される。

$$C = \frac{\sigma}{I} \quad (1)$$

ここで、 C 、 σ 、 I はそれぞれスペックルコントラスト、輝度の標準偏差、平均輝度である。

Figure. 4 にディスク 1 回転におけるスペックルコントラストの変化を示す。Figure. 5 にしゅう動方向に対し平行な粗さならびに垂直な粗さのスペックルパターン画像を示す。実験結果より、本試験機の光学系を基に取得されたスペックルコントラストは平行な粗さでは小さくなり、垂直な粗さでは大きくなる傾向が得られた。また、スペックルパターンはしゅう動方向に対し平行な粗さでは暗く、垂直な粗さでは明るくなることが確認された。

次に、しゅう動方向に対する粗さ方向ごとの摩擦係数とスペックルコントラストの経時変化を調査した。Figure. 6, 7 に#80 の粗さが平行および垂直な時の摩擦係数とスペックルコントラスト変化をそれぞれ示す。スペックルコントラストは、摩擦係数が大きい平行溝の時に小さく、摩擦係数が小さい垂直溝の時に大きい結果を示した。これは、Fig. 3, 4 に示した結果と同様な傾向を示しており、30 分間の経時変化においても摩擦係数とスペックルコントラストの関係は維持されるものと考えられる。

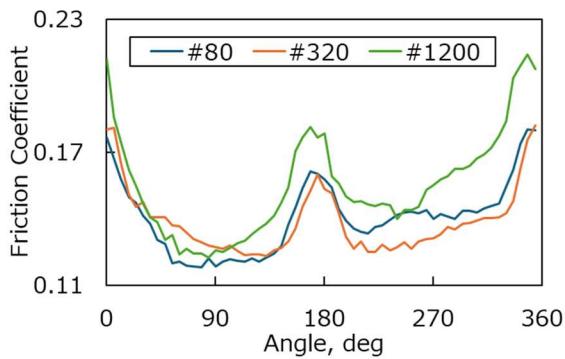


Fig. 3 Friction coefficient for one revolution

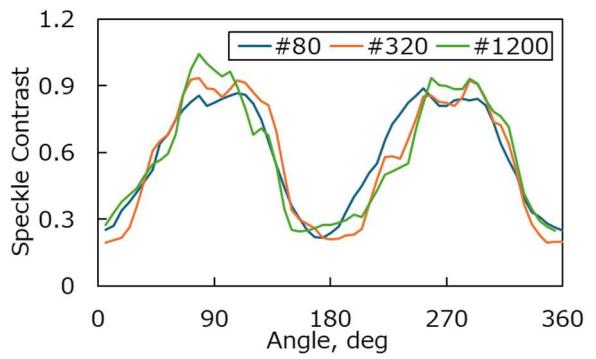


Fig. 4 Speckle contrast for one revolution

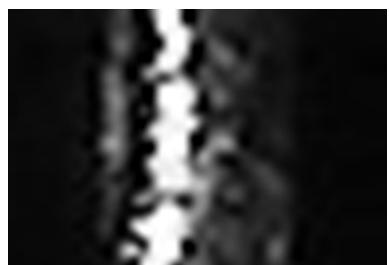


Fig. 5 Speckle patterns with parallel and perpendicular surface roughness (46×32 pix)

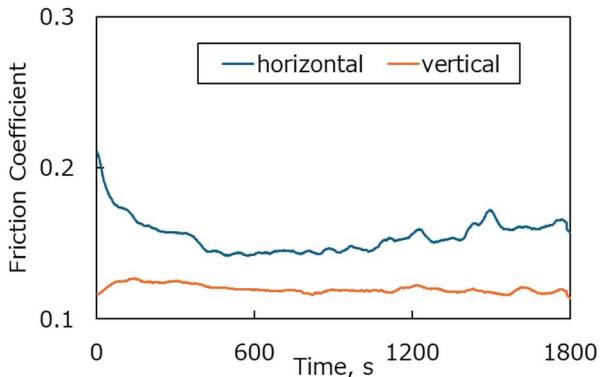


Fig. 6 Friction Coefficient for #80

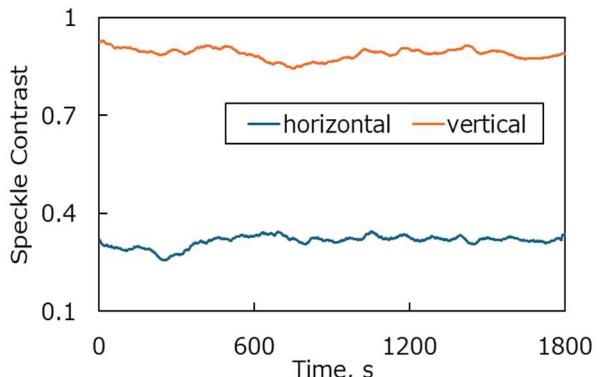


Fig. 7 Speckle Contrast for #80

3.2 機械学習を用いた摩擦係数予測結果

摩擦係数の予測に関して、CNNによる画像ベースの学習とCNNとMLPを結合させたモデルの2種類について比較を行った。Figure. 8, 9に各モデルにおける摩擦係数の予測値と実測値の関係を示す。Table 3に示す精度指標（平均二乗誤差MSE、平均絶対誤差MAE、決定係数R²）から、CNNとMLPを結合させたモデルの方が、CNNモデル単体と比較して高い予測精度を示すことが明らかとなった。

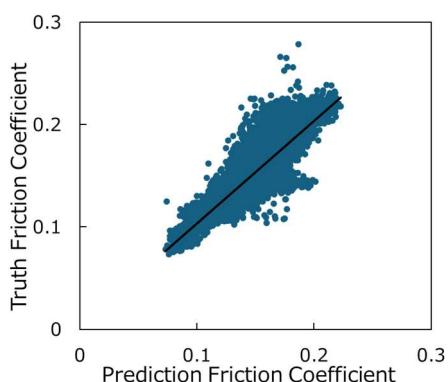


Fig. 8 Learning results for CNN

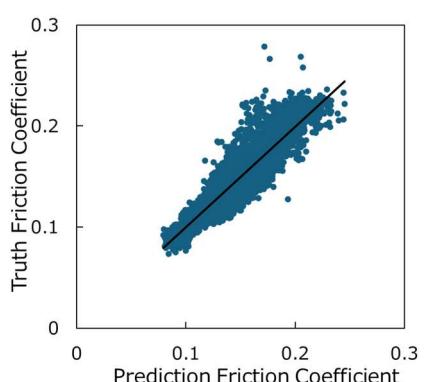


Fig. 9 Learning results for CNN+MLP

Table 3 Learning results

	CNN	CNN + MLP
MSE	7.40×10^{-5}	5.78×10^{-5}
MAE	6.18×10^{-3}	5.78×10^{-3}
R ²	0.776	0.824

4. 考察

Figure. 3, 4 より、表面粗さの方向により摩擦係数ならびにスペックルコントラストが対応し変化することが確認された。このことより、スペックルパターンを用いることで摩擦係数の予測が可能であると考えられる。また、Fig. 6, 7 より、平行溝では摩擦係数が大きく、スペックルコントラストは小さく、垂直溝では摩擦係数が小さく、スペックルコントラストが大きい傾向があった。また、この傾向は、しゅう動初期から摩擦試験終了時まで保たれており、スペックルパターン法を用いることで、表面テクスチャを付与した表面においても摩擦係数を経時変化的に予測可能になるものと考えられる。

最後に、機械学習による摩擦係数予測精度に関しては、CNN を用いた場合において、決定係数 0.776 であったものの、MLP と CNN を結合させたモデルでは、決定係数 0.824 とそのモデルの優位性が示された。この結果は、MLP に追加入力として用いた 5 つの特微量(平均輝度、標準偏差、スペックルコントラスト、エントロピー、ラクナリティ)が、摩擦係数予測に有用な変数群であり、CNN による特微量の抽出を効果的に補完したと考えられる。

5. 結言

粗さの大きさや溝方向を様々に付与したディスクを用い、シリンドロンディスク試験を行うと同時にスペックルパターン画像を取得し、機械学習による摩擦係数予測を行った結果、以下の知見を得た。

- (1) 摩擦係数は、粗さがしゅう動方向に平行な場合に高い値を示し、垂直な場合には低い値を示した。
- (2) スペックルコントラストは粗さがしゅう動方向に平行な場合に低い値を示し、垂直な場合には高い値を示した。
- (3) 摩擦係数とスペックルコントラストは、30 分間のしゅう動試験においても関係が維持されることが示された。
- (4) 機械学習を用いた摩擦係数予測において、CNN で抽出した特微量に 5 つの数値特微量を加え MLP に入力したものを併用することで、画像ベースの学習よりも高い予測精度が得られることを確認した。

文献

- 1) Ouahabi A, and Serra R, "Vibratory analysis for tool wear monitoring during machining (turning milling)" SURVEILLANCE 5 CETIM Senils (2004) pp. 11-13.
- 2) Takuya W, Syouhei K, and Hiroaki I, "Simple calibration curve construction and surface roughness detection using the speckle contrast method" J-STAGE, Vol. 103, No. 6 (2019)
- 3) Wataru M, and Yuji Y, Kaisei S, Shinya S, "A Study on Prediction Characteristics for Speckle Patterns of Friction Surfaces Using Machine Learning" Tribology Online, Vol. 19, No. 4 (2024) pp. 334-344.
- 4) Sihuan Y, Huang W, and Wang X, "Orientation effects of micro-grooves on sliding surfaces" Tribology International, Vol. 44, No. 9, (2011), pp. 1047-1054.