

撮影画像による摩擦係数の推定

入江俊† 田村仁†

日本工業大学工学部創造システム工学科†

1. はじめに

車輪型ロボットが移動する際に、床の摩擦係数は機動性や速度に大きく関係してくる。車輪型ロボットは接触部分にセンサを取り付けて計測することができない、もしくは機材をその場所に持ち込んで予め計測することができないなど、非接触による計測が必要になってくる。

本研究ではロボットなど移動する媒体に搭載することを想定し、撮影画像から摩擦係数の推定を行う。

2. 研究概要

撮影画像による摩擦係数の推定はこれまでも推定手法が提案されてきた。先行研究[1]では、形状通過型フィルタを用いて推定を行っていた。本研究では先行研究に示された形状通過型フィルタを用い、線形回帰で推定する場合のほかに順伝播型ニューラルネットワーク並びに畳み込みニューラルネットワークを用いた推定を行い、それらの比較実験を行う。

3. 形状通過型フィルタ

画像処理において画像にフィルタをかけることは、しばしば特徴の抽出や期待した画像の生成に使われ画像処理の基礎になっている。特定の特徴を抽出することで、画像の認識や分類を可能にしている。形状通過型フィルタはそれらのフィルタの一種であり、図1に示したような形状を抽出することができるフィルタである。




図1 形状特徴要素

かど、せん、みぞ、つぶ、だんのような形状の特徴を抽出することができ、このフィルタのサイズを変えることにより大きささまざまな形状特徴を抽出することができる。抽出された特徴はグレースケールの画像となって返される。




図2 形状通過型フィルタによる変換

図2に示したものは、路面画像を黒せんフィルタによって変換したものであり画像中に存在する黒い直線部分がフィルタによって白く出力されていることが確かめられる。また、形状通過型フィルタはグレースケール画像での特徴抽出を行うため、カラー画像も一度グレースケール化を行う必要がある。

4. 順伝播型ニューラルネットワーク

層状に並べたユニットが隣接層間でのみ結合した構造を持ち、情報が出力側に一方向にのみ伝播するニューラルネットワーク[2] (以下 NN) である。

5. 畳み込みニューラルネットワーク

畳み込みニューラルネットワーク (以下 CNN) は主に画像認識の分野で使われるニューラルネットワークであり、畳み込み層とプーリング層と呼ばれる層で処理を行う。畳み込み層はフィルタと入力画像による積和計算であり、フィルタの画素一つ一つが重みとして学習される[2]。プーリング層は畳み込みのように小さな範囲に注目し、その部分での最大値や平均値を出力するような処理である。これらの出力は画像の形で出力される。




図3 NN と CNN の違い(図は[2]より引用)

本実験ではこれらの NN を推定モデルとして使用する。

6. 路面画像の撮影および実静摩擦係数の測定

路面画像の撮影には SUMSUNG 社の GALAXY S5 SCL23 のカメラ機能を用い画像サイズは 5312×

Estimation method of coefficient of static friction by photographed image

†Irie Suguru, Tamura Hitoshi · Innovative Systems Engineering Nippon Institute of Technology

2988 ピクセル, 路面からの距離は 1 メートルで撮影を行った. また撮影した路面の静摩擦係数は, American slip meter 社の ASM725 を使用して測定した. 静摩擦係数は 7 回測り, 最大値と最小値を除き, 平均を取った値とした. 合計で 24 か所を撮影し, 各画像を 100 枚の 128×128 ピクセルの画像に分割しこのうち先頭から 2000 サンプルを推定に用い, 残りの 400 サンプルを評価用のデータとした.

7. 実験手順

摩擦係数の推定は次の手法を, 組み合わせを変えながら行った.

- 1) 形状通過型フィルタの有無
- 2) 線形回帰, NN, CNN の選択

ここで形状通過型フィルタは出力された画像を用いるのではなく, 出力された画像から平均二乗振幅値 r を用いた. r の式は以下のとおりである.

$$r = \sqrt{(\sum y^2)/XY}$$

$X \times Y$ は画像サイズ, y は明度である. さらに形状通過型フィルタは 9 種類, フィルタサイズは 3, 5, 9, 15, 21 ピクセルの 5 種類を用意し, 合計で 45 種類の特徴を入力として用いた. なお, CNN では入力に画像を使うため, 形状通過型フィルタでの前処理は行わない. NN での入力に用いるデータは形状通過型フィルタを用いた特徴値と元画像の明度を用いた. NN を用いた推定では層の数を 2, 4, 6, 8 と変化させ, 学習させる世代数を 20, 40 と変化させた. CNN では畳み込み層 2 層, プーリング層 1 層を一つの層とみなしその層の数を 2, 4, 6, 8 と変化させた. 学習させる世代数は NN と合わせ, 各層のユニット数はすべて 20 個に固定した. 線形回帰, 学習したモデルともに, 評価用のデータを用いて二乗誤差を算出し, 比較を行った.

8. 実験結果

以下の表 1 に線形回帰, 世代数 40 の時の 2, 8 層の NN および CNN のモデルの二乗誤差を, 図 3 に NN(フィルタなし 2 層)における学習による誤差の変化を, 図 4 に各 NN のモデルにおける誤差の変化を示す.

表 1 二乗誤差一覧

線形回帰(フィルタなし)	32.08
線形回帰(フィルタあり)	10.78
NN(フィルタなし 2 層)	6.63
NN(フィルタあり 2 層)	7.92
NN(フィルタなし 8 層)	6.75
NN(フィルタあり 8 層)	6.59
CNN(2 層)	6.34
CNN(8 層)	6.83




図 4 二乗誤差の変化




図 5 各 NN における誤差の変化

9. まとめ

以上の実験から, NN や CNN を用いた推定は線形回帰を行う場合よりも誤差が少なく有用な手段であることが確認できた. さらに NN においてだが, 層の数が増すことにより, 形状通過型フィルタを用いなくてもフィルタを用いた時に近い誤差となり, 形状の特徴をうまく抽出できていると考えられる. CNN では 2 層しか用いていない場合でも NN のフィルタあり 8 層と同じくらいの誤差になったため, 畳み込み層が特徴を抽出していることが見て取れる. NN の 8 層の場合では形状通過型フィルタを使用しなくても, 使用した時とほぼ同じ値の誤差になっている. これは層の数が増えたことにより汎化性能が高くなっているためだと考えられる. ただし今回の実験では撮影個所は 24 か所しか用意していなかったことに加え, ロボットに搭載することを念頭に置いていたため, 床以外の場所のサンプルがなく, 学習用データに偏りがあったと感じられる.

また, 線形回帰での推定においてもデータ数の少なさが二乗誤差の大きい原因ではないかと考えられる.

参考文献

- [1] 平井勝真, 田村仁, 撮影画像による床路面の方向別の摩擦係数の推定, 情報処理学会第 76 回全国大会講演文集(分冊 2), pp. 235-236, 2014
- [2] 岡谷貴之著, 機械学習プロフェッショナルシリーズ 深層学習