

撮影画像による摩擦係数の推定

Estimation of static friction coefficient using captured images

入江 俊十
Suguru Irie

田村 仁十
Hitoshi Tamura

1.はじめに

車輪型ロボットや二足歩行ロボットなどが移動する際に、床の摩擦係数は機動性や速度に大きく関係していると考えられる。摩擦係数が求められることで、それに適したモータの回転数などを選択することができる。しかし、摩擦係数を計測しながら運用することを考えた場合、計測器を設置する必要があるため計測しながらの運用は難しいと考えられる。ほかにも、予め摩擦係数を求める必要があるが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ような状況の時に、非接触による計測が必要になってくると考えられる。

これまで行われてきた先行研究では、撮影画像から摩擦係数を推定することができている。路面画像には人間の目から見てざらざらした印象やつるつるした印象の画像がある。この印象は小さな形状に起因するものと考えられる。ここから撮影画像に含まれている、せん、みぞ、つぶなどの小さな形状を特徴として抽出する形状通過型フィルタが考案され、形状通過型フィルタによって抽出された特徴量は R.M.S 値(二乗平均平方根)として計算され特徴量として出力される。この特徴量は実際に計測した静摩擦係数と相関関係にあることが先行研究により確認されている。先行研究では特徴量を重回帰分析によって推定式を構築し推定を行っていた。この特徴量のほかに水平方向から光源を当てた画像の明度差を特徴として追加するなどの方法で特徴量を増やし、推定の精度を上げる研究が行われてきた。

本実験の目的はこれまで提案されてきた、形状通過型フィルタによって取り出した特徴量を重回帰分析によって推定する手法のほかに、機械学習で用いられている手法の一つであるニューラルネットワーク並びに画像認識で使われている畳み込みニューラルネットワークを重回帰分析と入れ替えた場合に推定の精度が変化するかを確かめることとする。

2.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プログラミックフィルタである。




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(a) 形状通過型フィルタによる変換




図 2(b) 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、

†日本工業大学 機械システム工学専攻

カラー画像も一度グレースケール化を行う必要がある。画像中にある黒い点と白い点にはそれぞれ別の形状通過型フィルタが用いられる。出力されたグレースケール画像から特徴量として R.M.S 値を計算する。R.M.S 値は以下の式で表す。

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

ここで $X \times Y$ は画像サイズ、 y は明度である。これは、出力値の低い特徴点が多く、出力値の高い特徴点が存在するかを判別するために用いられる。

3.線形回帰

回帰問題は正解付きデータから、数値特徴を入力として数値を出力する関数を学習する問題と定義用いる。

$$f(x) = \sum_i w_i x_i$$

このとき誤差の二乗和は次のようになる。

$$E(w) = \sum_{i=1}^N (y_i - f(x_i))^2 = (y - Xw)^T (y - Xw)$$

ここから w は次のように表すことができる。

$$w = (X^T X)^{-1} X^T y$$

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。NN の学習には確率的勾配下降法を用いる。これは、誤差関数 $E(w)$ の勾配 $\nabla E(w)$ を求めて次のように重みの更新を行うものである。重みは次のような式で更新を行う。

$$w^{t+1} = w^{t,d} - \eta \nabla E(w)$$

また重みの更新には上記に加え Dropout 法を用いる。Dropout 法は各学習データに対して中間素子ランダムに一定確率だけ無視する方法で、過学習を防ぐ手法として用いられる。

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。

この出力された画像をまた入力として次の畳み込み層に入力する。これにより、より複雑な特徴を捉えることができる。




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 SAMSUNG 社の GALAXY S5 SCL23 のカメラ機能を用い画像サイズは 5312×2988 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 か所の路面を撮影し、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。路面の具体的な材質は、コンクリート、リノリウム、木材等である。以下にその例を示す。



図 4(a) 路面画像の例



図 4(b) 路面画像の例

図 4(a)はリノリウムの路面を撮影した路面画像であり、図 4(b)はコンクリートの路面を撮影した画像である。リノリウムの路面は線の形状が浮き出ていることが見て取れ、コンクリートの路面は粒の形状が見て取れる。また測定した静摩擦係数は $3.37E-01$ から $7.80E-01$ の値をとりそれらの値の標準偏差は $1.16E-01$ となった。

7.路面画像の撮影および実静摩擦係数の測定

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

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(45 次元)と元画像の各ピクセルの明度(4096 次元)を用いた。NN を用いた推定では各層のユニットを 20, 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。畳み込み層のフィルタ数は 9 枚と 18 枚の 2 種類を用意した。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。

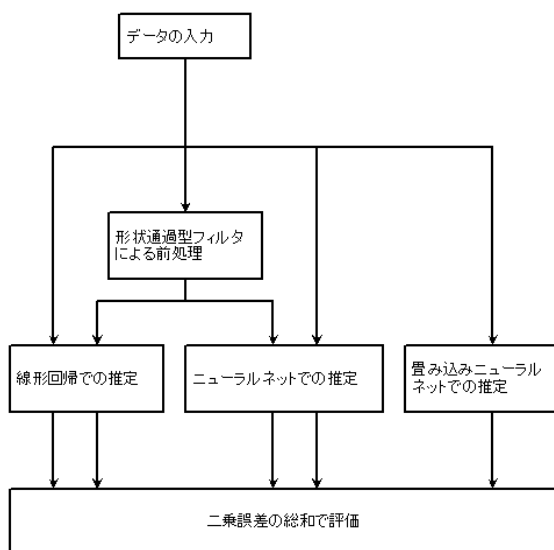


図 5 推定手順

8.実験結果

以下の表 1 に線形回帰, 世代数 40 の時の 2 層と 8 層の NN および CNN のモデルの二乗誤差を, 図 6 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 7 に各 NN のモデルにおける誤差の変化を示す。in45 は NN(フィルタあり 2 層), in4096 は NN(フィルタなし 2 層), incnn9 は畳み込みフィルタの枚数が 9 枚, 畳み込み層 2 枚の時の CNN, incnn18 は畳み込みフィルタの枚数が 18 枚, 畳み込み層 2 枚の時の CNN である。

表 1 二乗誤差一覧

使用したモデル	平均二乗誤差
線形回帰(フィルタなし)	$8.02E-02$
線形回帰(フィルタあり)	$2.69E-02$
NN(フィルタなし 2 層)	$1.65E-02$
NN(フィルタなし 8 層)	$1.69E-02$
NN(フィルタあり 2 層)	$1.98E-02$
NN(フィルタあり 8 層)	$1.65E-02$
CNN(2 層, 畳み込み 9 枚)	$1.58E-02$
CNN(8 層, 畳み込み 18 枚)	$1.71E-02$




図 6 二乗誤差の変化

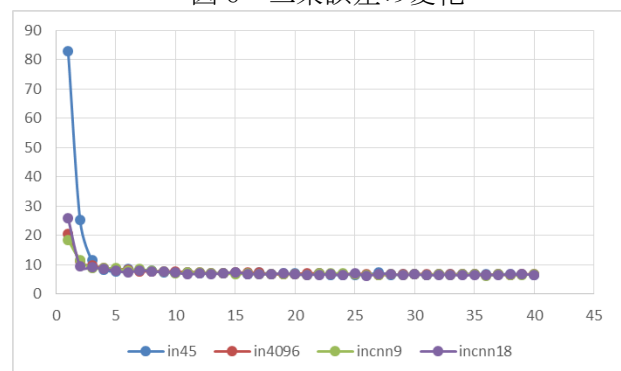


図 7 各 NN における誤差の変化

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ぜられる.

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.

10.追加実験

また, 以下の点に注目して追加実験を行った. 追加実験では改めて学習データの取り直しをしている.

- 1) 学習に用いた画像を撮影した環境の変化によって形状特徴が変化してしまう問題
- 2) NN, CNN での学習で深いモデルを使用した時の誤差の変化
- 3) 形状通過型フィルタを用いない場合での推定に用いる特徴

これらを確認するため次の手順で実験を行った.

- 1) 撮影画像並びに実摩擦係数の測定

撮影画像並びに実摩擦係数は同じデータを用いずに新しく撮影, 計測したデータを用いる. 撮影に使用した機材は Sony 社デジタル HD ビデオカメラレコーダー アクションカム HDR-AS200V 実摩擦係数の計測に用いた機材は前の実験と同じものを用いる.

撮影環境は高さ 0.1 メートルのところから路面に対して水平な角度, 1920×1080 ピクセル, 120fps の動画を約 10 秒移動しながら撮影し, 80×45 ピクセルまで縮小しフレーム毎に分割した. さらにそこから平均値除去を施したものをを用いる. この画像群に対して, 実摩擦係数を前の実験と同様に計測し, ラベル付けを行

った.

- 2) NN モデルの作製

NN のモデルは次のようなモデルを用いた. 入力層 100 ユニット, 隠れ層 4 層 20 ユニット, 出力層 1 ユニット, Dropout 率 50%, 前処理として入力画像を隠れ層 100 ユニットの自己符号化器で学習し, 隠れ層の出力を NN の入力に用いた. また, CNN のモデルは入力層が RGB 画像 3 枚, 隠れ層に畳み込み層(フィルタサイズ 3×3, パディング 1 画素)と最大プーリング層を 4 層, 出力層 1 ユニットのモデルを用いた.

- 3) 誤差の評価

誤差の評価は推定した摩擦係数と, 実摩擦係数の平均二乗誤差によって評価を行う. 誤差が小さいほど推定ができていると評価する. また, 前の実験での平均二乗誤差との比較を行い評価した.

11.追加実験の結果

以下に示すものは, 追加実験での NN モデルの誤差の推移を表した図, CNN モデルでの誤差の推移を表した図, 前の実験も含めた上での各モデルの平均二乗誤差の表である.

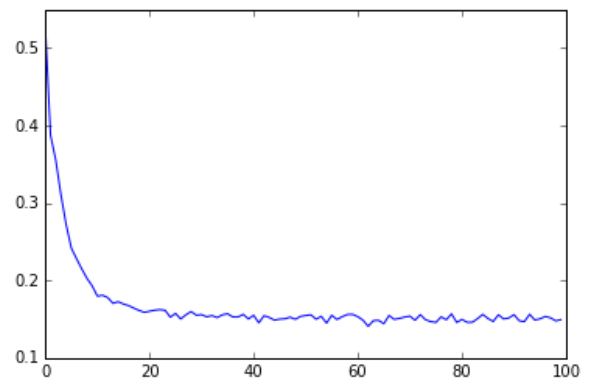


図 8 NN での誤差の推移




図 9 CNN での誤差の推移

表 2 各モデルの平均二乗誤差

使用モデル	平均二乗誤差
前実験線形回帰	2.69E-02
前実験 NN	1.98E-02
前実験 CNN	1.58E-02
追加実験 NN	1.49E-01
追加実験 CNN	1.46E-01

情報処理学会第 76 回全国大会講演文集(分冊 2), pp.235-236, 2014

[5]金谷潤, 陳君, 「移動体用に撮影画像による前方路面の摩擦係数推定システム」

卒業研究論文 日本工業大学 工学部 情報工学科 2011

[6]亀田修司, 島田知季, 「撮影画像による摩擦係数の推定」

卒業研究論文 日本工業大学 工学部 情報工学科 2009

12. 追加実験の考察

以上の結果から次のことが考えられる.

- 1) 前の実験と追加実験では撮影する距離が違ったが, これが推定に大きな影響を与えることが考えられる.
- 2) モデルを深くすることにより汎化性能が上がると考えていたが, 実際には余分な要素が多くなり誤差が大きくなってしまったと考えられる.
- 3) 前の実験では形状通過型フィルタが特徴を抽出するところを畳み込み層が代わりに作用すると結論付けてしまったが, 追加実験では前の実験よりも誤差が大きくなり, それぞれが別の作用をしていたということが考えられる.
- 4) 追加実験での誤差よりも前の実験での線形回帰モデルの誤差が小さいことから, 推定に線形回帰モデルを用いることが有用であると考えられる.

13. 終わりに

本研究では推定モデルを線形回帰, ニューラルネットワークなど変えながら静摩擦係数の推定に有用なモデルを探してきた. しかしモデルを変えることによる推定精度の大幅な上昇は見込めず, 逆に精度を下げてしまう結果となった. 本研究は画像処理を行うことが少なく, これが推定精度を下げる要因になったとも考えられる. 以降の研究ではこの前処理部分の選定などが課題になると考えられる.

参考文献

- [1]田村仁, 阿刀田央一, 自然なテクスチャの特徴抽出用「形状通過型」非線形フィルタバンク
電子情報通信学会論文誌 D-II Vol.J82-D-II No.12
pp.2260-2270 1999 年 12 月
- [2]荒木雅弘著, フリーソフトではじめる機械学習入門
- [3]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
- [4]平井勝真, 田村仁, 撮影画像のよる床路面の方向別の摩擦係数の推定