

機械学習による車シートの体圧分布測定値の解析手法

ーディープラーニングと一般線形化モデルを用いてー

Analysis of Body Pressure Distribution on Car Seat by Machine Learning

-Using the Deep Learning and General Linearization Model-

1w143083-7 土橋 央暉 指導教員 河合 隆史 教授

DOBASHI Hiroki

Prof. KAWAI Takashi

概要： 近年、人々は車に対して、乗り心地の良さ、つまり「快適性」を求めている。そこで、本研究は、「快適性」と深い関係のあるシートの体圧分布と官能評価との関係を明らかにするために解析を行った。具体的には、過去の研究で行った教師ありディープラーニングの水増しデータ作成による精度向上、教師なしディープラーニングによる体圧マップの特徴抽出、一般化線形モデルによる実験参加者の官能評価の予測を行った。その結果、教師ありディープラーニングにより体圧分布データから、体型やシートの種類、官能評価を極めて高い精度で分類でき、また、教師なしディープラーニングによる特徴量抽出、一般化線形モデルによる官能評価の予測に関しても、可能であることが示唆された。これらの結果を踏まえて、シート開発現場での本研究の応用が期待される。

キーワード：自動車シート、機械学習、ディープラーニング、一般化線形モデル、体圧分布

Keywords: Car Seat, Machine learning, Deep learning, General Linearization Model, Body pressure distribution

1. はじめに

近年、人々は車に対して、乗り心地の良さ、つまり「快適性」を求めている。そこで、森田 (2017) をはじめ、筆者らの過去の研究において、「快適性」と深い関係のある体圧分布の生データを実験参加者の体型、車種、官能評価によって分類することを目的として解析を行い、教師ありディープラーニングが特に有用であることが分かった。ただ、ディープラーニングにおいて、対象とするデータ数の少なさが問題点として、挙げられていた。本研究では、その解決策のひとつとして、水増しデータを作成し、更なる精度向上を図るとともに、教師なしディープラーニングによる体圧マップの特徴抽出、一般化線形モデル(以下 GLM と称する)による実験参加者の官能評価の予測を目的に解析を行った。

2. 実験方法

本実験では、実車に用いられるシートを 19 種用意し、実験参加者 18 名に対して全てのシートの体圧分布を測定し、着座時のシートについて 7 件法を用いた主観評価を行った。また、背面 48×48、座面 40×40 のデータ 1 行のベクトルに変換し、1 行 3904 次元のベクトルとし、342 データを作成後、水増し加工を行い、計 17100 データを解析に用いた。

3. 解析について

3.1 解析手法

入力とラベル(出力)をセットにして入力データとして与える教師あり学習の手法と、体圧データのみ

を入力データとして与える教師なし学習、そして GLM を用いた。

本解析は R3.3.2 のパッケージ h2o とパッケージ glm により行われた。h2o パッケージ中のディープラーニングはフィードフォワード型のニューラルネットワークにより構成されるものである。

教師ありディープラーニングにおいて、交差検証の結果、最も汎化性能が高かった以下の設計を採用した。まず、隠れ層は 3 層、そして各隠れ層におけるユニット数は 200 に設定した。活性化関数は tanh を採用し、学習回数は 20 回とした。17100 の解析データのうち、R のサンプル関数により、ランダム抽出した 15390 データを訓練データ、残る 1710 データを検証データとした。検証データの正解率をもって学習結果の妥当性を検証した。

教師なしディープラーニングは、今回体圧マップのどの部分が、重要な部分なのかを判断するための解析手法として用いた。h2o パッケージ内の h2o.deeplearning の引数を autoencoder=T, variable importance=T にすることで、予測因子の影響の度合いを重要度として得ることができ、重要なセルがどの部分であるかを判断することができる。

GLM は、確率分布・link 関数・線形予測子指定して特定できる統計モデルで、今回の解析においては、モデルの性能の確認を行うために、実際に予測された評点と実際の評点の相関をとり、モデルの評価を行うために用いた。

3.2 ラベルの定義

体型、シートの種類、官能評価 9 項目、計 11 項目をラベルとしてそれぞれ学習させた。各ラベルの定義を表 1 に示す。

表 1 ラベルの定義

ラベル	定義
体型	人体計測データベースを元に身長, 体重の女性 5%ile 以下を S, 男性 95%ile 以上を L, 中間を M として S, M, L の 3 つに設定
シートの種類	19 種類あるシートをそれぞれ 1 つの項目として, 19 に設定
官能評価 (9 項目)	回答における評価(しない~する)をラベル (low1~2, middle1~3, high1~2) に再設定

4. 結果及び考察

各ラベルについて、検証データの正解率、および交差検証によるエラー率を表 2 に示す。

表 2 各ラベルの学習結果

ラベル	正解率 (%)	交差検証平均エラー率 (%)
体型	100	0.117
シートの種類	99.9	0.455
深く沈みこむ感じ	99.2	0.946
ソフトな感じ	99.6	1.06
跳ね返る感じ	99.8	1.20
食い込む感じ	99.5	0.88
冷たい感じ	99.3	1.23
蒸れる感じ	99.2	1.05
心地良い感じ	99.3	1.41
不快な感じ	99.0	1.45
総合評価	99.3	1.21

各ラベルにおいて、極めて高い正解率を得ることができた。これは、水増しデータを作成することによって、シートに関する特性、快適性を判別することが可能になっていると考えられる。

次に、教師なしディープラーニングによって、重要だと判断された一例を図 1 に示す。




図 1 重要なセルの一例

体圧マットの重要なセルが、座面後部と坐骨結節部に集中していることが分かった。

次に、GLM による予測値と実測値の相関係数の値を表 3 に示す。

表 3 各ラベルの相関係数

ラベル	相関係数
深く沈みこむ感じ	0.759
ソフトな感じ	0.751
跳ね返る感じ	0.651
食い込む感じ	0.719
冷たい感じ	0.723
蒸れる感じ	0.663
心地良い感じ	0.628
不快な感じ	0.621
総合評価	0.650

全ての項目で相関係数が 0.6 以上となり、相関がある結果が得られた。この結果から、官能評価を予測する場合においても、体圧分布データと何らかの対応関係があることが示唆された。

5. まとめ

本研究は、実験参加者の体型, 着座したシートの種類、実験参加者の官能評価といった特性を分類・予測することを目的に解析を行ったものである。その結果、教師ありディープラーニングにより体圧分布データから、各ラベルについて極めて高い精度で分類でき、教師なしディープラーニングによる特徴量抽出、一般化線形モデルによる官能評価の予測に関しても、可能であることが示唆された。これらの結果を踏まえて、シート開発現場での本研究の応用が期待される。

参考文献：

- [1]. 森田隼司 他：機械学習を用いた車シートの体圧分布の解析，学位論文，2017.