

# 機械学習による座圧センサを利用した着席者の疲労状態の解析

Li Yuchuan<sup>†</sup> 平石広典<sup>‡</sup>

足利大学 大学院 工学研究科 情報・生産工学専攻<sup>†‡</sup>

## 1. はじめに

一般的に、座ったときの姿勢は、その人の性格や疲労の状態、集中の状態などを反映するものであり、着席時の利用者の状態を把握することで、その利用者の状況に合わせたサービスの実現が可能となる[1]

本研究では、座圧センサーを利用することで、着席者の疲労状態の解析を行った。授業を受けている時の状況、レポート作成時の状況、コンピュータゲームを実行している状況の三つの状態でデータを収集し、そのデータに対して、サポートベクターマシン(SVM)、ランダムフォレスト、また、LSTM による解析を実施した。

## 2. データ収集

本研究での座圧の測定には住友理工社製の圧力センサシート SR ソフトビジョン[2]を使用した。座圧測定画面の一例を図1に示した。センサは16x16の計256箇所の圧力分布を測定できる。図1で X 座標は着席時の横方向を示しており、Y 座標は縦方向を示している。

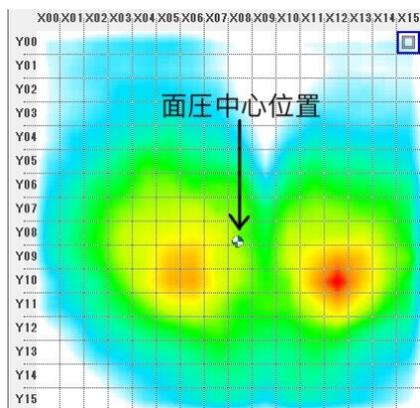


図1: 座圧測定画面

また、座圧を測定した際の重心位置である面圧中心位置も測定可能である。今回の実験では、この面圧中心位置の座標(X,Y)に着目し、比較的、精神的な負荷が大きいと考えられる授業時やレポート作成時と、負荷の少ないと思われるコンピュータゲーム時の3パターンを二人の被験者に対して測定を行った。データは5秒間隔で測定して、それぞれ60分のデータを収集した。

図2と図3には、二人の被験者 A, B のゲーム時の測定結果を示した。それぞれ1分間の重心座標の標準偏差の変化の様子を示している。

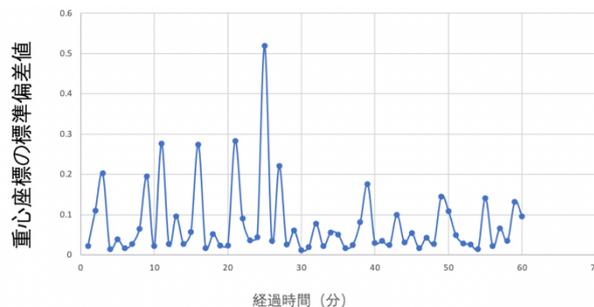


図2: 被験者 A のゲーム時の標準偏差

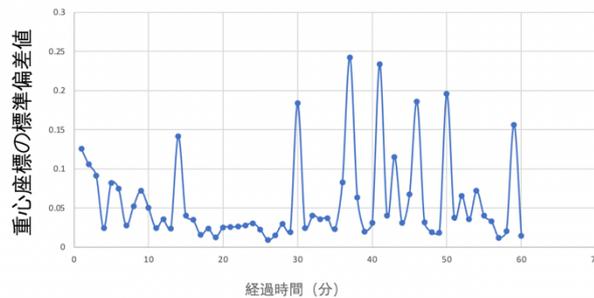


図3: 被験者 B のゲーム時の標準偏差

まず被験者 A の結果に着目する。それぞれのグラフで、30分までと、その後で特徴が変化していることがわかる。ゲーム時の結果では、前半に極端に大きな値が現れている。これは被験者 A は、ゆっくりと集中するタイプであり、ゲームをする時にすぐに集中状態に入ることができなく、一定の時間を必要とすること

Analysis of User Fatigue on Sitting Pressure Sensor by Using Machine Learning

<sup>†</sup>Li Yuchuan, Ashikaga University

<sup>‡</sup>Hironori Hiraishi, Ashikaga University

がわかる。

次に被験者 B の結果に着目すると、ゲームの時では、30分程度まで座圧が安定している。30分程度で疲労が現れたことがわかる。ここで座圧測定中に立ち上がった場合には標準偏差の値が極端に大きくなる場合がある。そのため被験者 A のゲーム時の25分や、被験者 B のゲーム時の15分に現れた大きな値は、疲労からくるものではなく、そうした動作によるものであると判断することができる。

また、被験者 A では、授業時には、30分程度までは座圧が安定しているが、それ以降には座圧が乱れており、疲労が現れた結果が得られた。レポート時には、ゲーム時と同様に、最初の30分までは座圧が安定せず、ゆっくりと集中に入るといった結果がえられた。

また、被験者 B では、授業時には20分程度で座圧の乱れが生じており、20分程度で疲労が現れるといった結果が得られた。レポート時では、30分程度までは座圧が安定せず、被験者 A 同様に、集中に時間を要するといった結果が得られた。

### 3. データの解析

ここでは、機械学習の手法を利用して、被験者の疲労の状態を自動的に分類できるかどうかを検証した。ここで図2の被験者 A の前半30分のデータは、値の変動が大きいいため疲労状態(非集中状態)として分類し、後半30分のデータは変動が少ないため集中状態として分類した。このように二人の被験者の3状態のデータを全て、値の変動の様子にしたがって、集中状態と疲労状態の二つに、予じめ分類することで解析を実施した。

本研究でのデータの解析には機械学習ソフトウェアの weka [3]を使用した。データを3つのグループに分けて分析を行った。

- ケース1: 被験者 A のゲーム時と被験者 B のゲーム時のデータからモデルを作成し、それ以外のデータを予測
- ケース2: 被験者 A のゲーム時のデータからモデルを作成し、被験者 A のその他のデータを予測
- ケース3: 被験者 A の全データからモデルを作成し、被験者 B 全てのデータを予測。

表1: 解析の結果 (%)

	SVM (Linear)	Random Forest	LSTM
ケース1	50.2	71.7	78.5
ケース2	35.8	72.8	75.0
ケース3	70.0	67.8	72.9

この3つのケースに対して、サポートベクターマシン(SVM)、ランダムフォレスト、LSTM による解析を実施した。その結果を表1に示した。SVMの結果は最も精度の良かった線形カーネルの結果を示している。

まず SVMの結果では、ケース3では比較的良い結果が得られているが、それ以外のケースでは非常に悪い結果となっている。次に、Random Forest では、全体として安定した結果が得られているが、ケース3では、やや低い精度となっている。これは、被験者 A のデータから被験者 B のデータを予測するものであり、集中や疲労の表れ方に個人差があるためであると考えられる。また、LSTMは、それぞれのケースにおいて最も良い精度が得られた。しかしながら、ケース3においては、若干精度が悪くなっており、同様の理由によるものであると考えられる。

### 4. まとめと今後の課題

本研究では座圧センサーを利用して、2人の被験者の面圧中心位置の変化のデータを収集した。そのデータの変動の大きさから、集中状態と疲労状態を分類し、3種類の機械学習手法を利用して、それらの状態を自動的に分類できるかどうかを検証した。

その結果、LSTM を利用した場合には、70%以上の精度で、それらの状態を自動的に分類することが可能であるといった結果が得られた。

### 5. 参考文献

- 1) 茂林真羽, 平石広典, "座圧センサによる着席者の姿勢変化に関する研究", The 79th Information Processing Society of Japan, 2017.
- 2) SR ソフトビジョン:  
<http://www.fukoku-jp.net/srsoftvision/index.html>
- 3) weka-3-8-4-azul-zulu:  
<https://www.cs.waikato.ac.nz/~ml/weka/>