

令和4年度 卒業研究

## 精神的ストレスを解消するアドバイス AI の開発

Development of an advisory AI to relieve mental stress

函館工業高等専門学校  
生産システム工学科 情報コース  
34 番 桃井 悠汰  
指導教員 東海林 智也

# 目次

1. 序論.....	3
1.1 和文.....	3
1.2 英文アブストラクト.....	3
1.3 研究背景.....	3
1.4 研究目的.....	4
1.5 開発環境.....	4
2. 関連技術.....	5
2.1 3層全結合型フィードフォワードニューラルネットワーク.....	5
2.2 使用ライブラリ.....	6
2.3 データ取得.....	6
3. モデル開発.....	7
3.1 学習データ.....	7
3.2 ニューラルネットワークの構築.....	8
4. 実験結果.....	9
4.1 実験方法.....	9
4.2 学習結果.....	9
4.3 テスト結果.....	10
5. 考察.....	11
6. 今後の課題.....	12
参考文献.....	13

# 1. 序論

## 1.1 和文

近年、ウェアラブル端末を使って心拍数や睡眠スコア、運動データなどの生体情報をモニタリングできるようになった。しかし、何が原因でストレスが発生しているのか、そしてストレスを解消するためにはどうすべきかを知ることはまだできない。そこで本研究では、ディープラーニングを用いてユーザーのストレスを解消することが可能かどうかを検討する。

## 1.2 英文アブストラクト

In recent years, there have been a variety of useful features that allow wearable devices to monitor biometric data such as heart rate, sleep scores, and exercise data. However, it is impossible to know what is causing stress and how to relieve it. Therefore, this study aims to investigate whether it is possible to relieve users' stress using deep learning. As a result, the learning model was completed, but it fell short of the expected value due to the small variety of biometric data. Therefore, it is necessary to increase the number of biometric data from now on.

## 1.3 研究背景

現代の情報化社会では生活習慣やスケジュール、生体データ等の情報を基に人々の生活を豊かにするための技術が様々な場面で活用されている。具体的な例としてはウェアラブルデバイスを用いて運動データや心拍数などの生体データを取得し、グラフや数値を表示して一日の生活を可視化させることで自分の生活を管理することができる。

この様にウェアラブルデバイスを用いて生体データを取得する技術は日常生活だけでなく、医療面においても活用できるため幅広い範囲で活用されている。ところが生体データを基にディープラーニングを用いて精神的ストレスを計測するという研究例は少ない。

## 1.4 研究目的

本研究はウェアラブルデバイスから生体データを取得し、そのデータから精神的ストレスの有無をディープラーニングによって判断し、精神的ストレスがあると判断した場合に精神的ストレスを解消するアドバイス AI 開発を目的とする。この AI が適切なアドバイスをすることで、日常面だけでなく、医療面や福祉面における問題を解決することができる。

## 1.5 開発環境

本研究における開発環境は以下のとおりである。

開発言語：

Python 3.9.7

依存ライブラリ：

keras 2.9.0

numpy 1.21.5

使用デバイス：

OS：macOS Monterey

ウェアラブルデバイス：Mi Smart band 6

学習データとテストデータ：

44 日分の自身の生体データ

## 2. 関連技術

### 2.1 3層全結合型フィードフォワードニューラルネットワーク

全結合型フィードフォワードニューラルネットワーク (FFNN) はソフトウェア的に生物の神経系をシミュレートするために、入力層、中間層、そして出力層を結合してネットワークとして構築した数理モデルである。今回は3層の全結合型フィードフォワードニューラルネットワークを使用する。3層全結合型フィードフォワードニューラルネットワークは回帰構造を持たず、隠れ層が1層のみであるニューラルネットワークである。

図1に今回使用した3層全結合型フィードフォワードニューラルネットワークの構造を示す。入力層に心拍数データ  $x[1] \sim x[4]$  と睡眠データ  $S$  を入力し、出力層の出力 ( $[1\ 0]$  か  $[0\ 1]$ ) を用いてストレスの有無を判断する。

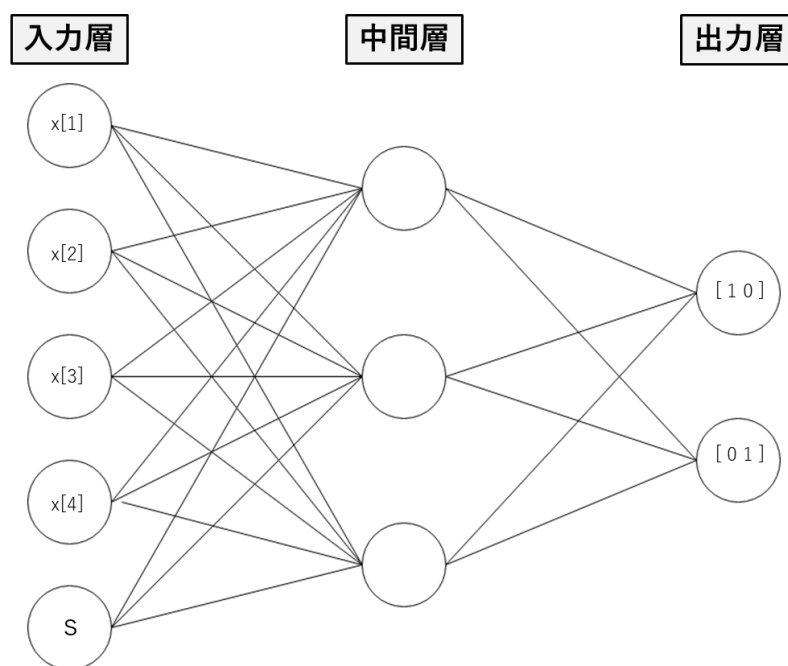


図1 ニューラルネットワークの構造

## 2.2 使用ライブラリ

TensorFlow :

Goggle が開発してオープンソースとして公開しているディープラーニング用プラットフォームである。

Keras :

Keras は TensorFlow の高水準 API であり、構造がシンプルかつエラーの修正も TensorFlow に比べ容易にできる[1]。そこで本研究では精神的ストレスの有無をディープラーニングで判断するため、Keras を利用した。

## 2.3 データ取得

Mi Smart Band 6 :

Mi Smart Band 6 は生体データを取得するためのウェアラブルデバイスである[2]。本機は Xiaomi 社から発売されており 3 軸加速度計と 3 軸ジャイロセンサー、PPG 心拍センサーを搭載している。価格が安く、24 時間心拍数をモニタリングでき、睡眠モニタリングもすることができるため、本研究では本機を採用した。

Zepp Life :

Zepp Life は Mi Smart band 6 で取得した生体データをより扱いやすくしたアプリケーションである。Mi Smart Band 6 で取得したデータをデータストアに保存することができ、さらに Zepp Life を使うことで指定した期間の生体データを csv ファイルとしてエクスポートできるため、本研究ではこの API を採用した。

### 3. モデル開発

#### 3.1 学習データ

取得データ：

本研究ではMi Smart Band 6から「心拍数」、「睡眠データ(深い眠り、浅い眠り)」のデータを取得する。なお今回は自分を被験者とし、学習用に34日、テスト用に10日の計44日分のデータを取得した。

心拍数データ：

Mi Smart Band 6により心拍数を5分おきに計測した。計測した24時間分の心拍数を0時～6時、6時～12時、12時～18時、18時～24時と6時間おきにグループ分けし、その平均データを求めて計4個の心拍数データ  $x[1]$  (0時～6時の平均)、 $x[2]$  (6時～12時の平均)、 $x[3]$  (12時～18時の平均)、 $x[4]$  (18時～24時の平均)を作成した(表1)。

表1 作成した心拍数データ(一部抜粋)

	2022/12/10	2022/12/11	2022/12/12	2022/12/13	2022/12/14
0:00:00	66.8555556	71.3732591	65.0222222	70.4888268	71.4111111
6:00:00	63.063745	63.4608939	68.1466276	74.5702247	70.8641618
12:00:00	78.2332268	78.1558824	70.2777778	83.0545455	72.6694678
18:00:00	75.9550562	79.637883	76.3029412	78.6777778	82.6629526

睡眠データ：

Mi Smart Band 6により深い眠りと浅い眠りの2つのデータを計測した。さらにその日の睡眠の質の割合を数値化するため、睡眠データをS、深い眠りの値をA(deep)、浅い眠りの値をA(light)としたとき、次の式を用いて睡眠データSを作成した。

$$S = \frac{A(\text{deep})}{A(\text{deep}) + A(\text{light})}$$

入力データの正規化：

3 層全結合型フィードフォワードニューラルネットワークに学習させるには入力データ間の数値の差異を大きくし、判別をしやすくする必要がある。よって入力データ  $x[1] \sim x[4]$ 、 $S$  毎に標準偏差を求めてそれらの値を正規化する。ここで標準偏差の式は以下の通りである。

$$H = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2}$$

$n$ ：データ数

$X_i$ ：各データの値

$\bar{X}$ ：各データの平均

ラベルセット：

1 日の終わりにストレスが溜まっていると感じたら [1 0]、ストレスが溜まっていないと感じた場合 [0 1] として、学習用に 34 日、テスト用に 10 日分のラベルセットを自分の主観により作成した。

### 3.2 ニューラルネットワークの構築

ユニット数は入力層を 5、中間層を 70、出力層を 2 とした。入力層は心拍数データ  $x[1] \sim x[4]$ 、睡眠データ  $S$  の計 5 個のデータを入力データとした。中間層は  $\tanh$  (双曲線正接関数) 活性化関数を使用した。出力層は  $\text{softmax}$  (正規化指数関数) 活性化関数を使用した。最適化アルゴリズムは Adam、損失関数はカテゴリーカル・クロスエントロピー (categorical cross entropy) を使用した。



## 4. 実験結果

### 4.1 実験方法

最初に自身の生体データ(心拍数  $x[1] \sim x[4]$ 、睡眠スコア  $S$ )を 34 日分用意し、それを学習データとして学習させる。さらに 10 日分の生体データを使ってテストしてストレスの有無を判定できるかどうか評価する。

### 4.2 学習結果

今回は以下のような設定で学習を行った。

- 学習率 : 0.01
- エポック数 : 70
- パッチサイズ : 2

学習結果を図 2 に示す。学習前は正解率が 52%と低い値が出力されているため、ストレスの有無を判断できていないことがわかる。一方、学習後は正解率が 100%になっていることからストレスの有無が判断できていることがわかる。

学習前	学習後
学習データセット : 損失=0.73, 正解率=0.52	学習データセット : 損失=0.09, 正解率=1.00
予測値	予測値
2/2 [=====] - 0s 2ms/step	2/2 [=====] - 0s 3ms/step
[ [ 0.570 0.430]	[ [ 0.044 0.956]
[ [ 0.460 0.540]	[ [ 0.986 0.014]
[ [ 0.445 0.555]	[ [ 0.002 0.998]
[ [ 0.599 0.401]	[ [ 0.052 0.948]
[ [ 0.485 0.515]	[ [ 0.024 0.976]
[ [ 0.409 0.591]	[ [ 0.803 0.197]
[ [ 0.381 0.619]	[ [ 0.032 0.968]
[ [ 0.569 0.431]	[ [ 0.934 0.066]
[ [ 0.602 0.398]	[ [ 0.003 0.997]
[ [ 0.493 0.507]	[ [ 0.240 0.760]
[ [ 0.354 0.646]	[ [ 0.991 0.009]
[ [ 0.570 0.430]	[ [ 0.161 0.839]
[ [ 0.487 0.513]	[ [ 0.071 0.929]
[ [ 0.502 0.498]	[ [ 0.017 0.983]
[ [ 0.450 0.550]	[ [ 0.006 0.994]
[ [ 0.390 0.610]	[ [ 0.011 0.989]
[ [ 0.729 0.271]	[ [ 0.012 0.988]
[ [ 0.434 0.566]	[ [ 0.154 0.846]
[ [ 0.531 0.469]	[ [ 0.693 0.307]
[ [ 0.468 0.532]	[ [ 0.001 0.999]
[ [ 0.437 0.563]	[ [ 0.000 1.000]
[ [ 0.525 0.475]	[ [ 0.963 0.037]
[ [ 0.568 0.432]	[ [ 0.545 0.455]
[ [ 0.441 0.559]	[ [ 0.007 0.993]
[ [ 0.526 0.474]	[ [ 0.003 0.997]
[ [ 0.359 0.641]	[ [ 0.976 0.024]
[ [ 0.569 0.431]	[ [ 0.329 0.671]
[ [ 0.553 0.447]	[ [ 0.020 0.980]
[ [ 0.401 0.599]	[ [ 0.000 1.000]
[ [ 0.558 0.442]	[ [ 0.071 0.929]
[ [ 0.538 0.462]	[ [ 0.014 0.986]
[ [ 0.560 0.440]	[ [ 0.772 0.228]
[ [ 0.550 0.450]	[ [ 0.006 0.994]

図 2 学習結果

### 4.3 テスト結果

次に10日分のテストデータを使ってストレスの有無を判定した結果を図3に示す。しかしテストデータの場合は正解率が70%と期待される値にはならなかった。

```
テストデータセット : 損失=1.06, 正解率=0.70
予 click to scroll output; double click to hide
1/1 [=====] - 0s 56ms/step
[[ 0.089 0.911]
 [ 0.156 0.844]
 [ 0.038 0.962]
 [ 0.064 0.936]
 [ 0.012 0.988]
 [ 0.080 0.920]
 [ 0.043 0.957]
 [ 0.702 0.298]
 [ 0.015 0.985]
 [ 0.954 0.046]]
```

図3 テスト結果

## 5. 考察

今回の実験ではテストデータの正解率が 70%ととても低い結果になってしまった。考えられる原因のひとつとして学習データが圧倒的に少なかったことが挙げられる。今回はたった一人の 34 日分の学習データしか使わなかったが、複数人の長期間のデータを学習させることで正解率が上がるのではないかと考えられる。

また今回は入力データとして心拍数データ  $x[1] \sim x[4]$  を使用したが、運動をしたことによって心拍数が上がっているだけで実は精神的ストレスには関係が無いというようなことも考えられる。よって運動データなどの生体データも入力データとし、精神的ストレスのみにフォーカスを当てられるようにする必要があると考えられる。

## 6. 今後の課題

今回は学習データ数が少なかつただけではなく、精神的ストレスを正確に判断するための生体データの種類も少なかつたと考えられる。そこで今後は学習データ数を増やし、入力データとして心拍数や睡眠の他にも運動データや日常の予定などのデータも追加する。さらに今回はデータをリアルタイムで取得していなかつたので、今後はデータをリアルタイムで取得するようにプログラムを改良する。

なお今回はストレスの有無だけを判定するニューラルネットワークモデルを構築したが、体調不良や睡眠不足のようにストレスの原因を特定し、それを解消するアドバイス AI の実装まで行うことは出来なかつた。そこで今後はストレスの原因を特定できるニューラルネットワークモデルを構築してアドバイス AI の実装も行う。

## 謝辞

本研究を進めるにあたり、ご指導いただきました卒業研究指導員の東海林智也准教授に感謝いたします。

## 参考文献

- [1] Keras Documentation <https://keras.io/ja/>
- [2] Mi smart band 6 <https://www.mi.com/jp/product/mi-smart-band-6/specs>