

# 個体差を考慮した睡眠の質に関する考察

2016SE017 平野佑弥 2016SE062 丹賀澤優心

2016SE080 田森俊乃介 2016SE088 宇佐美龍

指導教員：野呂昌満

## 1 はじめに

近年、コンピュータの性能の向上、ならびに低価格化により、多量のデータを取得することが容易になり、かつ多量のデータ解析をクラウド上で行なうことが可能になってきた。ウェアラブルデバイス等を用いて日常的にバイタルデータを取得することができるようになり、これらのデータを知的ソフトウェアで処理することがモバイル端末上で可能になってきた。これらによって、健康管理を目的とした知的アプリケーションをモバイル端末上で実現できるようになってきた。

睡眠の質に影響を与える研究 [1] は多くあるが、個体差を考慮して、睡眠の質とこれに影響を与える要因との関係を明らかにする研究は少ない。我々は、睡眠の質に影響を与える要因には個人差があると考えた。個人の睡眠の質に影響を与える要因について特定することができれば、睡眠の質を改善、向上させることが期待できる。

本研究の目的は個体差を考慮して、睡眠の質とこれに影響を与える要因との関係を明らかにすることである。既存研究 [2] では、データサイエンスの観点から睡眠に影響を与える要因を明らかにしている。我々が取り扱う問題の構造は複雑なので、このような統計的な方法だけでは不十分であると考えた。本研究では深層学習の技術を用い、個体差を考慮して、睡眠の質とこれに影響を与える要因との関係を明らかにする。

本研究では睡眠の質に影響を与える要因として既存研究 [3] で明らかとなっており、バイタルデータとして取得できる以下の5つの要因を用いることとする。

1. 睡眠時間
2. 入眠からノンレム（深い）睡眠に入るまでの時間
3. 中途覚醒回数（睡眠途中で目覚めた回数）
4. 中途覚醒時間（睡眠途中で目覚めた時間）
5. 起床直後の睡眠ステージ

本研究では、主観的に睡眠の質を評価することができる OSA 睡眠感調査票 MA 版 [4] を教師データを作成するために用いることとする。入力データを睡眠の質に影響を与える要因、教師データを睡眠の質の良し悪しの分類結果として、ニューラルネットワークの技術を用いた学習モデルを試作する。入力データと教師データを学習器に与えて分類予測の学習を行なうことで、学習器は出力のクラスとクラスに属している入力データの間を明らかにすることができる。

## 2 背景技術

### 2.1 ニューラルネットワーク

ニューラルネットワークは人間の神経回路を模したコンピュータプログラムシステムであり、単純な機能を持ったユニットを多数連結させることで、高度な機能を実現する機械学習の技術である。学習モデルはハイパーパラメータを定義する。特に、ハイパーパラメータの損失関数、評価関数、最適化アルゴリズムを学習モデルに応じて決定する必要がある。

#### 1. 損失関数、評価関数

- 2 値交差エントロピー
- accuracy

#### 2. 最適化アルゴリズム

- SGD
- Adam

ニューラルネットワークは、ユニット間の結合の仕方の違いにより、以下の3種類に分類できる。

#### • FCN(fully-connected-neural-network)

隣接する2つの層のすべてのユニットが網羅的に結合しているニューラルネットワークである。ニューラルネットワークの一般的な構造として汎用的に用いられる。

#### • CNN(convolutional-neural-network)

ユニット間の結合を局所に限定した構造で、画像や音声などのデータに対して用いられる。

#### • RNN(recurrent-neural-network)

隠れ層の値を再び隠れ層に入力し、過去の情報を未来の予測に利用できる再帰構造をもつニューラルネットワークである。時系列データなどの可変長のデータを扱うことができる。

### 2.2 OSA 睡眠調査票

OSA 睡眠感調査票 MA 版は一般社団法人日本睡眠改善協議会理事長の白川修一郎氏が開発・標準化をおこなった起床時の睡眠内省を評価する心理尺度である。この調査票は16質問項目が5因子に分類されており、第1因子が起床時眠気、第2因子が入眠と睡眠維持、第3因子が夢み、第4因子が疲労回復、第5因子が睡眠時間で構成されている。OSA 睡眠調査票 MA 版は、標準化の手続きをすべて行っており、信頼性や再現性は高いものである。この調査票で得られる睡眠感とは、日々変動する睡眠感を統計的に尺度化したものである。各質問項目の選択は4肢選択式となっ

ており、得点が高いほど睡眠が良好であることを示している。本研究では、OSA 睡眠感調査票 MA 版で定義されている起床時の睡眠内省を評価する心理尺度を天下り的に受け入れることとする。今回の学習モデルでは、OSA 睡眠感調査票 MA 版で得られる各因子の総合得点を睡眠の質と定義し、学習における教師データ作成のために用いることとする。

### 3 学習モデルの設計

#### 3.1 学習データ

本研究では、ニューラルネットワークの機械学習を用いて、睡眠の質とこれに影響を与える要因との関係を明らかにするための学習モデルを提案する。機械学習を適用する上で、用いる学習データについて以下に考察する。

本研究の学習モデルにおける入力データは、睡眠の質に影響を与える要因であり、第 1 章の箇条書きで示した。箇条書きの第 5 項である睡眠ステージは名義尺度であるので One-hot ベクトル化を行なう。そのため、入力層のユニットは 8 つとなる。

教師データの作成には、OSA 睡眠感調査票を用いる。本研究における睡眠の質は、OSA 睡眠感調査票 MA 版で得られる各因子の総合得点と定義した。各因子の総合得点は、100 点に換算して用いることとする。睡眠の質の良し悪しを、各因子の総合得点が 50 点以上の場合は、「良い」、50 点未満の場合は「悪い」と評価することとし、2 クラスに分類する。

本研究の学習モデルにおける出力データは、睡眠の質である。出力データは入力データとモデルの重みから睡眠の質が「良い」か「悪い」かの 2 クラス分類を行い、いずれかのクラスラベルを出力したものである。すなわち、出力層のユニットの数は 2 つである。

#### 3.2 設計したニューラルネットワークの概要

本研究で設計したニューラルネットワークの構造を図 1 に示す。本研究では、入力データが時系列データではなく、




図 1 : 本研究でのニューラルネットワークの構造

さらに局所特徴を抽出可能であるかどうか不明であるので、全結合型のニューラルネットワークである FCN を用いる。初期値として設定する中間層のユニット数は、(入力層のユニット数 + 出力層のユニット数) \* 2/3 が最適であるとされている。中間層の層数については、学習モデルによって適切な値が異なる。本研究では、層数の初期値を 1 層とし、層数を 1 層ずつ実験的に増やすことで最適な値を考察していく。このことから、本研究における中間層の構造は、ユニット数 6、層数 1 を初期値として設定する。

#### 3.3 ハイパーパラメータの最適な組み合わせの定義

本研究では、最適なハイパーパラメータの組み合わせを定めるためにグリッドサーチ手法を用いて実験的に決定する。本研究での各ハイパーパラメータの指定範囲を以下の表 1、表 2 に示す。

表 1 実測データ各パラメータの指定範囲

最適化アルゴリズム	adam,SGD
ユニット数	6, 15, 30
エポック数	100
バッチサイズ	16, 32
ドロップアウト率	0.2,0.5

表 2 シミュレーションデータでの各パラメータの指定範囲

最適化アルゴリズム	adam,SGD
ユニット数	30, 50, 100
エポック数	100
バッチサイズ	32, 64, 128
ドロップアウト率	0.2,0.5

#### 3.4 ニューラルネットワークの実現

時間効率よくモデルの実装を行なうために、機械学習のライブラリが豊富な Python を用いた。また、この学習モデルの実現にあたり、深層学習のライブラリである Keras を用いた。Keras には、ニューラルネットワークの構築、評価関数や損失関数などの様々なメソッドが定義されており、これらを用いることで容易に実装することが可能となった。本モデルの最適なハイパーパラメータの組み合わせを定めるために Python のライブラリの 1 つである sickit-learn で定義されているメソッドのグリッドサーチを実装した。本研究では学習データとして本学生の 4 年生 4 名から fitbit と睡眠感調査票を用いて収集した実測データとこのデータを元に作成したシミュレーションデータを用いる。

## 4 実験と評価

本研究では、ニューラルネットワークの技術を用いて、睡眠の質とこれに影響を与える要因との関係を明らかにするモデルの試作を3章の学習モデルの設計に基づいて行ない、このモデルの妥当性を評価する。

### 4.1 実験の概要

本研究での実験1として前章で述べたグリッドサーチ手法を用いて実装を行ない、実測データでは中間層が1層と2層、シミュレーションデータでは中間層が1層から10層での表1、表2で指定したハイパーパラメータの指定範囲の中で最適なハイパーパラメータを定める。実験2では実験1で定めたハイパーパラメータを用いてニューラルネットワークを構築し、実測データとシミュレーションデータで学習を行なう。そしてテストデータを用いて学習後のモデルの評価関数の精度と損失関数の値を出力し、本モデルの汎化性能を評価する。

### 4.2 実験結果

表3に実験1の結果である最適な組み合わせでの結果を示し、図2,3,4,5に実験2で行なった最適な組み合わせでの学習結果を示す。また、テストデータで分類予測を行ないこの学習モデルの汎化性能を評価した結果を表4に示す。

表3 グリッドサーチにおける各層の最適なハイパーパラメータ

学習データ	実測	シミュレーション
中間層	1層	9層
パッチサイズ	16	128
ドロップアウト率	0.2	0.2
エポック数	30	100
最適化アルゴリズム	adam	adam
ユニット数	30	30

表4 最適な組み合わせでの学習結果

学習データ	データセット	正解率	損失値
実測データ	テストデータ	0.76	0.52
シミュレーションデータ	テストデータ	0.81	0.38




図2 実測データ 正解率




図4 シミュレーション データ 正解率

## 5 評価

本研究での実験結果に対する評価を行なう。4から実測データでの学習モデルの正答率は76%、損失値は0.52という結果になった。しかし、シミュレーションデータでの学習モデルの正答率は81%、損失値は0.38であり実測データでの学習モデルより正解率が上がり、損失値が下がった。そのため、実測データを多く収集することと中間層の数を増やすことでモデルの性能を向上させることができると考えられる。しかし、多くのデータを用いることで損失は下がったが、良い数値とは言えない。損失値が大きく下がらなかった要因として4人分の同世代での異なった被験者でのデータを用いたことが考えられる。

## 6 考察

### 6.1 学習モデルの運用

前章で最適なハイパーパラメータを定め学習を行ない、FCNモデルを試作した。試作したFCNモデルを用いて入力データから睡眠の質を分類し、このモデルの妥当性を検証した。この時、妥当性検証で用いた入力データは学習時に利用しなかった14個のデータを用いた。学習時に140程度のデータを用いたので妥当性検証では $\frac{1}{10}$ のデータ数を使用した。このデータを用いて分類を行なった結果92%程度の高い精度であった。アルコール摂取や日中に激しい運動をした日などの特殊な行動をとった日のバイタルデータは含まれていない。このようなデータを含めて学習をした場合、精度が下がる可能性が考えられる。表5,6より1層の学習モデルでは起床時の睡眠ステージの重みの数値が最も大きいので、睡眠ステージがより影響を与える要因だと考えられる。また、2層の学習モデルでも睡眠ステージの重みの値が最も大きいのでこの要因が睡眠の質に影響を与える要因だと考えられる。これらのことより、学習モデルから睡眠の質とこれに影響を与える要因との関係性を得ることができた。しかし、1層と2層では睡眠ステージが最も睡眠の質に影響を与える要因であるという結果が出たが3層以上ではどうなるかの検証が必要であると考えられる。

### 6.2 他分野への応用

我々は、本研究で提案したニューラルネットワークを用いた学習モデルの入力データ、教師データ、出力データを変更することによって、他分野に応用することができると

表 5 各入力における重み (1 層)

睡眠時間	-1.17
目覚めていた時間	-1.64
目覚めた回数	-1.42
入眠からノンレム睡眠に入るまでの時間	-0.94
起床時の睡眠ステージ	-0.29

表 6 各入力における重み (2 層)

睡眠時間	-1.05
目覚めていた時間	0.78
目覚めた回数	-1.84
入眠からノンレム睡眠に入るまでの時間	-0.06
起床時の睡眠ステージ	0.96

考えた。今回は他分野への応用の一例として、個人差を考慮して、アルコールと睡眠の質との関係について明らかにする学習モデルについて考察する。アルコールは摂取量の違いによって、睡眠の質に与える影響が異なるということが既存研究 [5] では明らかにされている。例えば、低用量の摂取では寝つきが悪くなり、睡眠時間が長くなる傾向が見られる。アルコールの分解速度には遺伝などにより、個人差があるということが既存研究 [6] で明らかにされているが、前述の既存研究 [5] では個人差について考慮されていない。以下、今回提案した学習モデルを用いることで、個体差を考慮して、アルコールと睡眠の質との関係を明らかにする学習モデルについて考察していく。

### 6.3 アルコール摂取と睡眠の質との関係について

本節では、本研究で提案した学習モデルの応用例について、アルコール摂取と睡眠の質との関係を例に挙げて説明する。本研究で提案した学習モデルの入力データを変更することによって、個体差を考慮して、アルコールと睡眠の質との関係を明らかにする。入力データには、アルコールと睡眠の質との関係について既存研究 [6] で明らかになっており、バイタルデータとして取得することができる以下の 5 つの要因を用いることとする。

1. アルコール摂取量
2. 睡眠時間
3. アルコール摂取から睡眠までの時間
4. 日中の消費カロリー
5. 水分摂取量

今回の学習は、アルコールと睡眠の質との関係を明らかにすることを目的としているので、教師データと出力データは、本研究で提案した学習モデルと同じデータを用いることとする。前述した入力データは、時系列データではなく、さらに局所特徴を抽出可能であるかどうか不明であるので、本研究で提案した学習モデルと同じ全結合型のニューラルネットワークである FCN を用いる。入力のユ

ニット数が 5 つであることから、中間層のユニット数は、本研究で提案した中間層の構造と同じユニット数 6 とする。中間層のユニット数以外の各ハイパーパラメータについては、本研究で提案した学習モデルと同じ構造を用いる。その他の分野の要因と睡眠の質との関係を明らかにする際には、本節で述べた例と同様に本研究で提案した学習モデルの学習データやハイパーパラメータを置き換えることで、その他の分野へ応用することができると考える。

## 7 おわりに

本研究では、既存研究 [1][2] で明らかにされてきた睡眠の質とこれに影響を与える要因との関係に、個人差が考慮されていないということを課題とした。この課題の解決にあたって、睡眠の質に影響を与える要因における睡眠の質の良し悪しを分類するモデルを実現し、このモデルから睡眠の質とこれに影響を与える要因の関係を考察した。その結果、このモデルから教師ラベルの付いた睡眠の質において、80 % 程度の精度と睡眠の質とこれに影響を与える要因の関係性が得られた。また、学習後のモデルの重みから睡眠の質とこれに影響を与える要因の関係を確認することができた今後の課題として、今回の学習では、個人では十分な訓練データを収集することができなかったため、同世代 4 人の訓練データを用いて学習を行ない、睡眠の質とこれに影響を与える要因を考察した。今後は個々人での訓練データを用いて学習を行ない、睡眠の質とこれに影響を与える要因の関係性を確認し、同世代や個々人でどのような変化が見られるかを検証する必要がある。

## 参考文献

- [1] 影山隆之, “騒音による睡眠への影響の評価について”, JSTAGE, vol 30., no. 6, pp. 435-441, 2006.
- [2] 山本隆一郎, 野村忍, “Pittsburgh Sleep Quality Index を用いた大学生の睡眠問題調査”, JSTAGE, vol. 49, no. 7, pp. 817-825, 2009.
- [3] 西野精治, スタンフォード式最高の睡眠, サンマーク出版, 2017.
- [4] 山本由華史, 田中秀樹, 高瀬美紀, 山崎勝男, 阿住一雄, 白川修一郎, “中高年・高齢者を対象とした OSA 睡眠感調査票 (MA 版) の開発と標準化”, 脳と精神の医学, vol 10, pp. 401-409, 1999.
- [5] 内村直尚, “アルコール依存症に関連する睡眠障害”, 精神神経学雑誌, vol.112, no.8, pp.787-792, 2010.
- [6] 井上昌次郎, 睡眠障害, 講談社, 2000.
- [7] 井原勇人, 今井朝太郎, 岩井青都, 巖良高, 岩本昌樹, 上田健太, 梅宮和真, 江口翔吾, “お酒と運動について”, 福島医学雑誌, vol.65, no.4, 2015.