

眠り SCAN を用いた寝姿勢推定システムの構築

高原 優樹[†]

山形大学大学院理工学研究科[†]

椎野 俊秀[¶]

パラマウントベッド株式会社[¶]

近藤 栄太郎[‡]

パラマウントベッド株式会社[‡]

木暮 貴政^{||}

パラマウントベッド株式会社^{||}

豊田 彩織[§]

パラマウントベッド株式会社[§]

安田 宗樹^{**}

山形大学大学院理工学研究科^{**}

1. はじめに

医療・介護の現場において、患者・要介護者の睡眠時寝姿勢を把握することは重要な課題であり、その解決策が必要とされている。また、深層学習を含む機械学習の発展やデータ処理速度の向上に伴い、画像認識や音声認識等の様々な分野で活用されるようになった [1]。

本稿では、眠り SCAN [2] により得られた体動信号から深層学習を用いて寝姿勢の推定を行う。この際に使用するモデルはディープニューラルネットワーク (deep neural network (DNN)) [3] である。しかし、DNN のみでは体動信号に含まれるノイズの大きさや、学習に使用する訓練データの不均衡さが問題となる。そこでノイズ除去を目的に、DNN に加えて前処理としてガウシアン・ベルヌーイ制限ボルツマンマシン (Gaussian-Bernoulli restricted Boltzmann machine (GBRBM)) [4] を使用したモデルを提案する。また、データの不均衡さの影響を低減させるために cost sensitive (CS) 学習を導入する。提案法を用いた数値実験を行い性能を比較し、よりよい寝姿勢推定システムの構築を目指す。

2. データセット



図1 眠り SCAN とその使用方法。

本稿では、眠り SCAN によって得られた体動信号を用いる。眠り SCAN とは、図1の形状の非装着型の機器で、客観的睡眠評価を行うためにパラマウントベッド株式会社により開発された製品である。機器をマットレスの下に敷き、その上で被験者が横になることで使用できる。眠り SCAN は、機器の左右についてセンサーで体動を検出する。

得られた体動データに寝姿勢ラベルを付与し、全データを学習に使用する学習データと検証に使用するテストデータに一定の割合で分割した。寝姿勢ごとのデータセットの割合を表1に示す。

表1 データセットの内訳

	左向き	仰向け	右向き	うつ伏せ
訓練	20.7%	43.6%	26.1%	9.6%
テスト	18.5%	31.6%	40.7%	9.3%

表1より、寝姿勢によってデータ数が大きく異なることが分かる。このようなデータで学習を行った場合、推定がデータ数の多いクラスに偏ってしまう傾向があり、対策が必要となる。

寝姿勢認識システムへの入力として使う際に、データに含まれる推定に不要な情報 (ノイズ) を除去するために、離散フーリエ変換 (discrete Fourier transform (DFT)) を用いて、前処理の段階であらかじめ低周波・高周波成分を取り除いておく。

3. 寝姿勢推定システム




図2 提案システム。

寝姿勢推定システムは DFT 後のデータを用いた DNN によるクラス分類をベースとする。しかしそれだけではノイズの処理が十分ではなかった。そこで、本研究では入力データを GBRBM を通して特徴変換し、その変換されたデータを DNN の入力とするようなシステムを提案する。提案システムの概要を図2に示す。GBRBM の特徴変換を通すことで、DFT で取り除けないようなノイズの低減が期待される。




図3 GBRBM。

GBRBM は図3のような、可視変数 v からなる可視層 V と隠れ変数 h からなる隠れ層 H の2層構造の確率モデルで、確率分布 $P(v, h | \theta)$ をもつ。 θ はモデルの学習パラメータである。

Sleeping posture estimation based on NEMURI SCAN
[†] Yuki Kuzuhara; Graduate School of Science and Engineering, Yamagata University
[‡] Eitaro Kondo; PARAMOUNT BED CO., LTD
[§] Saori Toyota; PARAMOUNT BED CO., LTD
[¶] Toshihide Shiino; PARAMOUNT BED CO., LTD
^{||} Takamasa Kogure; PARAMOUNT BED CO., LTD
^{**} Muneki Yasuda; Graduate School of Science and Engineering, Yamagata University

訓練データの不均衡さの影響の軽減のためには CS 学習を行う。GBRBM の学習の際に、クラスのデータ数の割合の逆数 (inverse class frequency (ICF)) を尤度に重み掛けすることにより、疑似的にデータ数をバランスさせることができる。GBRBM の対数尤度関数 $l(\theta)$ は、隠れ層に対する周辺化処理によって \mathbf{h} を消去した周辺分布 $P(\mathbf{v} | \theta)$ と N 個の入力データ $D = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ を用いて

$$l(\theta) = \frac{1}{N} \sum_{\mu=1}^N \ln P(\mathbf{x}^{(\mu)} | \theta) \quad (1)$$

と定義される。それに対して GBRBM に ICF を適用した対数尤度関数 $l_{icf}(\theta)$ は次のように表すことができる。

$$l_{icf}(\theta) = \frac{1}{Z} \sum_{\mu=1}^N w^{(\mu)} \ln P(\mathbf{x}^{(\mu)} | \theta) \quad (2)$$

ここで、 $w^{(\mu)}$ は全データ中の $\mathbf{x}^{(\mu)}$ の ICF であり、 Z は $w^{(\mu)}$ の総和である。同様に、DNN の損失関数に対しても ICF を適用することで CS 学習を行うことができる。

テストデータ数が極端に多いクラスと少ないクラスが存在しているとすると、全データを極端に多いクラスであると推定すれば、少ないクラスをまったく当てなくても認識率は高くなってしまう。そこで、次で表わされる class balanced (CB) 認識率を定義する。

$$A_{CB} = \frac{1}{Z} \sum_{\mu=1}^N w^{(\mu)} \delta^{(\mu)} \quad (3)$$

$\delta^{(\mu)}$ は $\mathbf{x}^{(\mu)}$ の推定が正解ならば 1、そうでなければ 0 とするデルタ関数である。これにより、すべてのクラスをデータ数の偏りによらずに公平に評価することができる。

4. 数値実験

まず、DNN のみのモデルで実験を行う。使用した DNN は 4 層で、活性化関数は 2 層とも ReLU を用いた。120 回実験を行い、全体認識率、CB 認識率、kappa 係数 [5] の平均と標準偏差を求めた。kappa 係数とは、実際の一致率から偶然の一致率を除いたときの一致度を表す指標であり、1 に近いほど高い一致度を示す。CS 学習を行わなかった時と行った時の結果を表 2 に示す。比較すると、CS ありの方が期待通り CB 認識率が高くなっており、データの不均衡さの影響を低減できていることが確認できる。

表 2 DNN 実験結果.

	全体認識率	CB 認識率	kappa 係数
CS なし	71.8 ± 1.62%	64.4 ± 0.92%	0.59 ± 0.022
CS あり	70.9 ± 1.76%	66.9 ± 0.85%	0.59 ± 0.021

次に、DNN と GBRBM を組み合わせた提案モデル (GBRBM+DNN) で実験を行う。DNN は 3 層で、活性化関数は ReLU である。この実験では、GBRBM と DNN それぞれに対して CS 学習を行うかどうかの条件を変え、表 3 に示すような 4 通りの実験を行った。まず、DNN のみで CS 学習を行わなかった場合 (表 2 上段) と GBRBM+DNN においてどちらにも CS 学習を行わなかった場合 (表 3 最上段) を比較すると、GBRBM+DNN のほうが CB 認識率が約 2% 高く

なっており、GBRBM の特徴変換によるノイズ除去の効果が表れていると言える。さらに、CS 学習を行うことでより CB 認識率を高めることができています。特に、GBRBM+DNN において GBRBM のみ CS 学習を行ったものと、GBRBM と DNN 両方に CS 学習を行ったものが CB 認識率が最も高く、ともに約 70% となっている。

表 3 GBRBM+DNN 実験結果. それぞれ GBRBM CS 使用の有無 / DNN CS 使用の有無.

	全体認識率	CB 認識率	kappa 係数
CS なし/なし	70.8 ± 1.39%	66.5 ± 1.69%	0.58 ± 0.019
CS なし/あり	70.0 ± 1.39%	68.2 ± 1.24%	0.58 ± 0.017
CS あり/なし	72.1 ± 1.21%	69.6 ± 1.47%	0.60 ± 0.016
CS あり/あり	69.9 ± 1.41%	69.6 ± 0.97%	0.58 ± 0.017

5. まとめ




図 4 CB 認識率による性能比較. エラーバーは標準偏差を表す.

本稿では、DNN と GBRBM を用いて、眠り SCAN から得られた体動信号を入力とし、寝姿勢推定を高性能で行うシステムを提案した。さらに、DNN と GBRBM それぞれに対して CS 学習の使用・不使用のときの性能の差を調べた。その結果、GBRBM に対して CS 学習を適用した場合がもっとも高性能となることが分かった。図 4 は本研究の結果をまとめたものである。畳み込みニューラルネットワーク [3] やその他のモデルの適用可能性を検討すると共に、臨床実験による実用的な場面での性能検討を進めることが今後の課題である。

謝辞

本研究は科研費 (18K11459, 18H03303), JST-CREST (JPMJCE1312), JST COI プログラム (JPMJCE1312) 及びパラマウントベッド株式会社の助成を受けたものである。

文献

- [1] 麻生 英樹・安田 宗樹・前田 新一・岡野原 大輔・岡谷 貴之・久保 陽太郎・ボレガラ ダヌシカ: 深層学習, 近代科学社, 2015.
- [2] T. Kogure, S. Shirakawa, M. Shimokawa, and Y. Hosokawa: Automatic Sleep/Wake Scoring from Body Motion in Bed: Validation of a Newly Developed Sensor Placed under a Mattress. *Journal of Physiological Anthropology*, 30(3), pp.103–109, 2011.
- [3] I. Goodfellow, Y. Bengio, and A. Courville: *Deep Learning*, MIT Press, 2016.
- [4] K. Cho, A. Ilin and T. Raiko: Improved Learning of Gaussian-Bernoulli Restricted Boltzmann Machines, *ICANN2011*, pp.10–17, 2011.
- [5] R. Landies and G.G. Koch: The measurement of observer agreement for categorical data, *Biometrics*, 33(1), pp.59–174, 1977.