

ウェアラブルセンサーを用いた LSTM ネットワークによる ストレス管理に関する研究

A study of Stress Management by LSTM Network using Wearable Sensor

眞弓卓也[†]
Takuya Mayumi

荒井秀一[†]
Shuichi Arai

1. まえがき

現代はストレス社会とも言われるように、多くの人がストレスにさらされながら生活を送っている。人はストレスを受けると身体面、心理面、行動面に様々な反応が生じる。このことをストレス反応と呼び、過度なストレスによりストレス反応が続くことが健康障害に繋がることから、ストレスと上手く付き合うためにストレスマネジメントを行うことが呼びかけられている。[1]

ストレスマネジメントとは、第一にストレス反応に対する気づきを良くし、第二にストレス反応を解消するための具体的な行動を起こすことを指す。ストレスマネジメントを行う上ではストレスを自覚することが大切だが、無自覚ストレスに対して人は鈍感になりがちである。ストレスの検知を行うことで、ストレスを自覚させ、ストレスマネジメントを行う上でのヘルパーになりえるのではないかと考えた。

本研究では、ウェアラブルデバイスから得られた装着者のライフログとストレスの関係を取得することで、ウェアラブルデバイスの装着者のライフログからストレス上昇を検知するためのモデルを構築し、本手法を適用したアプリをウェアラブルデバイス上で動作させ、検証を行うことで、リアルタイムにストレスの検知を行った。

2. Long Short Term Memory(LSTM)

Recurrent Neural Network(RNN)とは音声や言語、動画画像といった系列データを扱うニューラルネットワークである。その中でも Long Short Term Memory[2]はより長期に渡る記憶を実現したニューラルネットワークである。LSTM ユニットの構造を図??に示す。LSTM ユニットには、メモリセルと忘却ゲート、入力ゲート、出力ゲートの3つの乗算ユニットが含まれ、それぞれメモリセルのリセット、書き込みおよび出力に使用される。隠れ層の状態を次時刻の入力とすることで、過去の入力を考慮した時系列解析を行うことができる。

3. LSTM ネットワーク

先行研究でウェアラブルデバイスから得られた生体データからストレスの上昇を検知するための深層学習モデルが報告されている。[3]

本研究では先行研究と同様に3つの LSTM ユニットにフルコネクションのパーセプトロンを繋げた構成をとった。(以下 LSTM ネットワークとする。)




図 1: LSTM ユニットの構造

LSTM ネットワークの構成を図 2 に示す。1 層目は、4 時間分のデータを入力長とする 3 つの LSTM ユニットで構成される。各 LSTM ユニット間で 2 時間分オーバーラップするように配置しており、入力データ長は合計で 8 時間とした。2 層目は、フルコネクションのパーセプトロンであり、各 LSTM ユニットの出力を入力とする。パーセプトロンの中間層には活性化関数として Sigmoid 関数を、出力層には Softmax を採用し、各クラスの最大値をとったものを認識クラスとした。

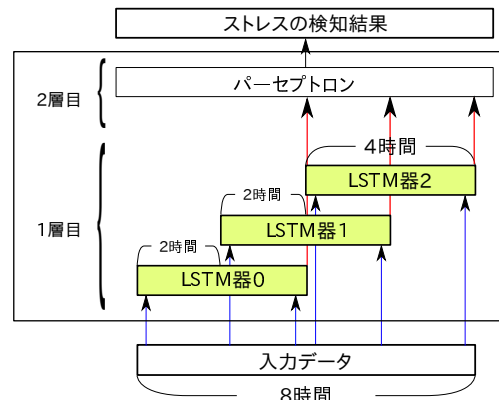


図 2: LSTM ネットワークの構成

4. 実験

本研究では検証用ウェアラブルデバイスとして、腕時計型ウェアラブルデバイスである AndroidWear を採用した。被験者を二名 (A, B) を決定し、データセットの作成、検証を行った。

4.1. データセットの作成

LSTM ネットワークに入力するライフログは実験で使用した AndroidWear に搭載されているウェアラブルセンサーを使用して消費カロリー、歩数、歩行距離、上った階数、心拍数を 1 分ごとに収集するライフログ

[†]東京都市大学大学院 工学研究科
Graduate School of Engineering, Tokyo City University

収集用アプリを開発し収集を行った。(図 3)

ストレスを判定する指標として、厚生労働省が実施している職業性ストレス調査票を採用した。[4] 全 29 問の質問に答えることで、精神的ストレスと身体的ストレスの度合いを算出する。被験者には毎日、心境の変化を感じた際に調査票に回答を行ってもらった。以下、調査票から得られたストレス度を表す点数をストレス得点とする。LSTM ネットワークの教師データにはストレス得点の時間あたりの変化率を標準化し、標準化後の値 >1 となるものをストレスが上昇したものとして 1 を、標準化後の値 ≤ 1 となるものをストレスの変化がなかったものとして 0 と変換した 2 値を与えた。

4.2.LSTM ネットワークの学習

ネットワークのパラメータとしては、LSTM の隠れ層 12, パーセプトロンのニューロン数 10, 学習率 0.03, epoch 数 100, 損失関数に負の対数尤度と設定した。被験者 A, B のデータセットを使用して LSTM ネットワークの学習を行った。LSTM ネットワークのパラメータとしては、LSTM の隠れ層 12, パーセプトロンのニューロン数 10, 学習率 0.03, epoch 数 100, 損失関数に負の対数尤度と設定した。データセットの 75% を学習用, 残り 25% をテスト用として学習し, 認識を行ったところ, 表 1 の結果になった。被験者 B は, 教師データに対して, 67% の正答率となる。

表 1: 教師データに対する LSTM ネットワークの認識率

被験者	学習データ	テストデータ
A	84%	49%
B	83%	67%

4.3. ストレス検知用アプリ

学習を行うことで得られた LSTM ネットワークを用いてストレス検知を行う, ストレス検知用のアプリを開発した。データ収集用アプリと同じ方法で, ライフログの収集を行い, 得られたライフログを学習済みの LSTM ネットワークに入力することで, ストレスの検知をリアルタイムに行った。図 4 はストレス検知時に表示される画面である。過去 8 時間のライフログを学習済みの LSTM ネットワークに入力し, ストレスの上昇を検知できると表示される。選択肢は, ストレスを感じている事を自覚している”はい”, ストレスを感じている事に”言われて気がついた”, ストレスを感じていない”いいえ”の 3 つの選択肢が存在する。各々の被験者のデータセットで学習を行った LSTM ネットワークを用いてストレス検知の検証を行った。又, ストレスの検知は 2 時間おきにストレスの検知を行う。

4.4. 結果

図 5 に被験者 A の 1 日のストレスの推移を示す。ストレスの検知結果に対する被験者の回答は, 0, 8, 16 時の検知に対してははいを, 18, 20 時の検知に対してはいいえを回答し, 2, 4 時の検知に対しては被験者が就寝中のため未回答であった。



図 3: データ収集時



図 4: ストレス検知時




図 5: 1 日のストレス検知結果

5. 結論

本研究では, 被験者から収集したデータセットを使用して LSTM ネットワークの学習を行い, ウェアラブルデバイス上で認識を行うことで, 被験者のストレスの検知をリアルタイムに行った。リアルタイムに被験者からフィードバックを得られることから, 学習データを収集できる。このデータを用いれば新たに学習を行うことができ, 更に被験者にあったストレスの検知を行うことができると期待できる。

参考文献

- [1] 厚生労働省, ”15 分でわかるセルフケア” : <http://kokoro.mhlw.go.jp/selfcare>
- [2] Gers, Felix A., Jrgen Schmidhuber, and Fred Cummins. ”Learning to forget: Continual prediction with LSTM.” (1999): 850-855.
- [3] 阿久津朋宏, ”ウェアラブルデバイスから得られる生体データから装着者のストレスを検知する深層学習モデルの一考察”, 電子情報通信学会, 2017
- [4] 厚生労働省, ”労働安全衛生法に基づくストレスチェック制度実施マニュアル”, 厚生労働省基準局安全衛生部 労働衛生課産業保健支援室, 2016