

リカレントニューラルネットワークを用いた満足度推定システムの検討

那須 大晃
Hiroaki NASU

1 はじめに

我々の研究室ではオフィスの照明環境に着目し、執務者ごとに照度を提供する知的照明システムの研究を行ってきた¹⁾。しかし、知的照明システムにおいて隣接する執務者が大きく異なる目標照度を設定した場合、照明の物理的特性により目標照度が実現できないことがある。そのような場合に筆者らは執務者ごとの照度に対する満足度という尺度を導入し、執務者の満足度を最大化するように照明を制御する新たな知的照明システムを提案した。しかし、満足度を用いる知的照明システムは事前に執務者ごとの満足度を知る必要があるが、照度を変化させながら満足度の計測を行う方法は時間が掛かり執務者の負担が大きいため、簡易的な方法による満足度計測の手法が必要となる。

そこで、操作する速度(調光速度)を出力する調光インタフェースの試作を行い、その出力結果を Recurrent Neural Networks (RNN) を用いて学習することで 9 種類の満足度クラスに分類するシステムを作成した。

2 満足度分類システム

2.1 満足度分類システムの概要

提案する満足度分類システムは、(1) 調光インタフェース (Fig. 1 を参照) を用いて選好照度に調整するまでの調光速度の変化を記録する、(2) 調光速度の変化を RNN で学習、の 2 つのフェーズで構成される。以下では (1) の実験を「調光速度取得実験」、(2) の機械学習の実験を「RNN による学習」と表記する。

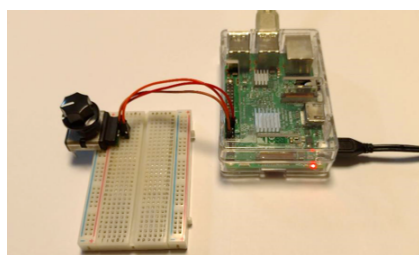


Fig.1 調光インタフェース

2.2 調光速度取得実験

執務者が調光用インタフェースを用いて好みの照度に調光する際、目標の照度に近づき満足度が高くなれば、調光速度を緩めて慎重に調光すると考えられる。このため、仮説として調光速度から満足度を推定できる可能性があると考えられる。そこで、ダイヤル式の調光インタフェースにロータリーエンコーダを使用して、調光速度を計測する機能を付加した実験装置を作成した。

なお、ロータリーエンコーダは一周 24 クリックの BOURNS 社製 ECW1J-B24-AC0024L を使用した。また、調光速度取得の被験者実験は 256 段階で調光可能な三菱電機社製 LED 照明 9 台を使用し、机上照度を約 0 ~ 1200 lx の範囲で制御可能な KC101 にて行った。

実験にはロータリーエンコーダを回転させるほど増光する回転角調光方式を使用しており、ロータリーエンコーダの 1 クリックにつき照度を約 5 lx 増光するよう設定した。被験者は消灯した実験室に入室後、インターフェースを利用して選好照度に調光する。このとき、ロータリーエンコーダの 1 クリック毎に実験開始時点から経過時間および各時点の照度値を出力する。

RNN による学習ではこれらの値を用いて学習を行う。

2.3 RNN による調光速度変化の学習

RNN とはニューラルネットワークの一種であり、ノードの結合にフィードバック結合が含まれる。フィードバック結合を持つことにより時系列データの過去の入力を踏まえた学習が可能となる。このような特徴から調光速度データの時系列を考慮して執務者の調光制御の特徴を学習し、満足度の分類に利用できると考えられる。

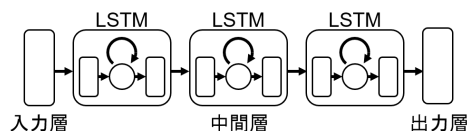


Fig.2 LSTM の構成

実験では、ニューラルネットワークで調光速度データを学習させる前処理として、調光速度データの整形を行う必要がある。調光速度データは選好照度になるまでの調光の変化量を表しているため、時系列の長さにばらつきがある。そのため、RNN への入力データにするには、調光速度データの長さを統一する必要がある。また、調光時の調光インタフェース操作は被験者が行うため、ロータリーエンコーダの回転速度(クリック間の時間間隔)にばらつきがある。そのため、元の調光速度データの形状で RNN に入力すると、時系列間の時間間隔を無視してしまうことになる。そこで、調光速度データを補間および近似し、一定の時間間隔でサンプリングを行うことで、等間隔データへ変形を行った。

補間および近似を行うことで、RNN 学習の効率化を行うためのデータ拡張 (Data Augmentation)²⁾ に利用している。近似には 2 次、3 次および 4 次関数近似を利用し、補間は 1 次、2 次および 3 次ラグランジュ補間を利用している。

実験に利用したニューラルネットワークでは、RNN の一種である Long Short Term Memory (LSTM) を利用した。LSTM とは標準的な RNN を改良することで、RNN より遠隔な長時間データを意識する学習を行えるようにしたニューラルネットワークである。

実験に用いる LSTM の構成は Fig. 2 のようになっている。Fig. 2 の構成のニューラルネットワークを TensorFlow により構築し学習を行った。(学習率:0.1)

学習には LSTM 用に Back Propagation を拡張した Back Propagation Through Time (BPTT) を利用した。学習に用いる正解ラベルは選好照度範囲(高・中・低)および満足度の広がり(広・中・狭)の組み合わせの計9種類に分類されるように設定した。

3 調光速度取得実験および RNN による学習の結果

3.1 調光速度取得実験の結果

調光速度取得実験を10日間行い、その時の調光速度データの一例を Fig. 3 および Fig. 4 に示す。

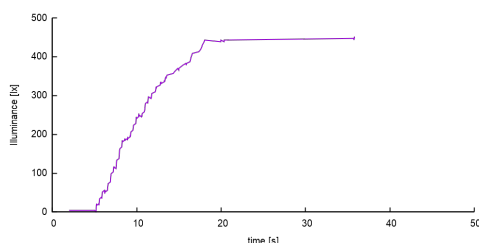


Fig.3 調光速度データ一例 (1)

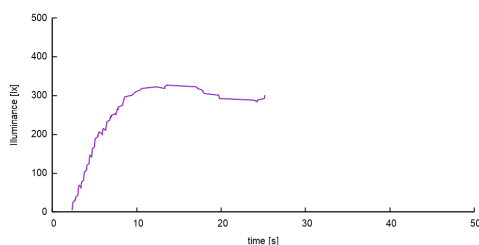


Fig.4 調光速度データ一例 (2)

Fig. 3 は開始 20 秒辺りからインタフェースの操作を中断している時間があるが、実験開始から 20 秒までの間に弧を描くように増光している様子がわかる。さらに、選好する照度 (Fig. 3 の場合 447 lx) に近い照度が得られた開始 12 秒あたりで調光の速度を緩め慎重な操作になっている様子もわかる。以上のことから、RNN では調光速度データの最後の点を選好する照度とし、調光速度を緩める始める時点为满足度の広がり を推定する特徴量として学習することが望ましいと考えられる。

一方、Fig. 4 は選好照度に辿り着く前に、一度減光している様子がわかる。インタフェースを用いて増光したものの真の選好照度を超えて操作してしまったため減光することで調整を行っている。このような、データを RNN で学習させた場合、時系列データが小さくなっていることを理

解して推定を行わなければならない。

3.2 RNN による学習の結果および考察

調光速度取得実験の結果を上記したようにサンプリングすることによって 364 個のデータを作成し、Fig. 2 に示す RNN で学習させた。このときの、精度 (Accuracy) および誤差 (Loss) を Fig. 5 に示す。

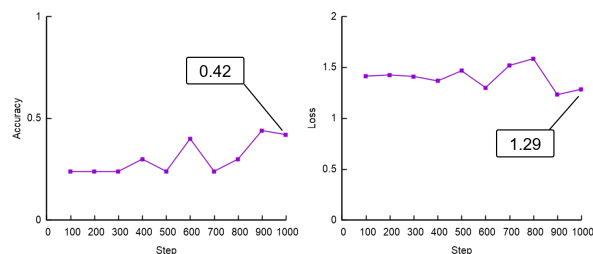


Fig.5 精度 (Accuracy) および誤差 (Loss)

RNN 構築に利用した TensorFlow の精度出力は最大値で 1.0 であるが、今回の検証で最終的に満足度推定の精度は 42% になった。結果としては高くない精度であるが、Fig. 5 の精度は徐々にではあるが向上している。一方で、誤差の値も減少傾向にあり、RNN の学習によって判別を行えていると考えることができる。以上から、今回学習に用いた調光速度データは機械学習の入力に使用可能であることがわかった。

ニューラルネットワークの学習フェーズにおける層間の重み更新には入力データのクラス分け結果と正解ラベルの交差エントロピー誤差を利用しているため、交差エントロピーの計算方法により正解ラベルに対応する出力結果しか考慮されず正しい推論結果でなければ誤差が大きくなる。しかし、本研究の目的である満足度推定では、出力結果に高い精度を求めなくても良いものと考えられる。例えば、正しい推論が満足度「5」である入力に対して、出力結果が「4」だとしても本質的に問題はない。本実験で利用したニューラルネットワークを改良する際には、満足度推定において正解ラベルと出力結果が近ければ近いほど誤差が小さくなる計算方式が適していると考えられる。

4 今後の研究方針

満足度推定に向けて、調光インタフェースによる調光速度から RNN での学習を行ったが、精度の向上が必要であることが分かった。調光速度取得実験により得られた結果では、機械学習の入力とするには全体的にデータが少ないため過学習を引き起こしやすくなる。そこで、さらに調光速度取得実験を行うことで認識精度の向上を目指す。

また、ニューラルネットワークの学習フェーズにおいて満足度推定に適した誤差関数の考案を行う。

参考文献

- 1) 三木光範, 知的照明システムと知的オフィス環境コンソーシアム, 人工知能学会誌, Vol.22, No.3 (2007), pp.399-410.
- 2) 新村 拓也 (2018). TensorFlow ではじめる DeepLearning 実装入門. 株式会社インプレス.