

満足度を用いた新たな知的照明システムの制御方式およびニューラルネットワークを用いた照度に対する満足度判別方法の提案

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て隣接する執務者が大きく異なる目標照度を設定すると、照明の物理的特性により目標照度が実現できない。この場合、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、満足度を用いる制御手法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 ECWIJ-B24-AC0024L を使用した。また、調光速度取得実験は 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同志社大学実験室にて行った。

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 増光するように設定した。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、調光速度データを学習させる前処理を行った。調光速度データは選好照度になるまで調光を取得するため時系列の長さが一定でない。また、調光インタフェースの操作では、ロータリーエンコーダの回転(クリック間の時間間隔)にばらつきがある。そのため、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 60 点のサンプリングを行った等間隔データを入力とした。

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。補間・近似の前処理は学習の精度向上に有効なデータ拡張 (Data Augmentation) ²⁾ に利用している。

実験では、RNNの一種であるLong Short Term Memory (LSTM) を利用した。LSTMとは標準RNNを改良し、より長時間データを学習可能なNNである。

ところで、データ拡張による637個のデータの内、学習データ (587個) とテストデータ (50個) に分類し、学習データを用いて学習を実行した。

実験に用いるLSTMはTensorFlowを用いてFig. 2のように構成し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。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 (9種類) に分類されるように設定した。

今回の実験で利用した環境は以下の通りである。Windows 10, Core i5 7600K @ 3.08GHzのPC上に、NN構成をTensorFlow (バージョン: 1.8.0) で構築している。

3 調光速度取得実験の結果

調光速度取得実験を行った結果の一例をFig. 3に示す。




Fig. 3 調光速度データ (一例)

①で示すデータは操作が落ち着くまで5秒程度を要した。この結果は満足度が中照度に位置し狭い分布を持つ被験者のデータである。一方で②は満足度が中照度に位置し分布が中程度である被験者の結果で、操作が落ち着くまでに10秒程度の時間を要している。そのため、RNNでは調光速度データの最後の点を選好する照度とし、調光速度を緩める時点を満足度の広がりや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。

4 RNNによる学習の結果

NNによる調光速度データの満足度判別結果の検証のため、被験者の満足度と調光速度データの一例を示す。Fig.4 (左)にあるように、本被験者の満足度は「高照度側」に位置し、「広い分布」である。本被験者の調光速度データはFig.4 (右)で、本データをNNにより分類すると同じ特徴の「高照度」で「広い分布」のクラスに分類することができた。

また、NNの学習を通して出力した分類精度はFig.5のようになった。Fig.5は縦軸が精度、横軸は学習回数を示しており、100ステップ毎の分類精度を表している。




Fig. 4 ある被験者の満足度 (左) と調光速度データ (右)




Fig. 5 実験により出力した精度グラフ

3万回の学習を行った結果、78%の精度を実現することができた。本実験の結果から、調光速度データによって満足度の推定が可能であると言える。

5 考察

Fig.5では、NNによる学習を開始して、3万回の学習を行うまでに概して精度が向上している様子が見られる。一方で、一時的に精度が低下している部分が複数存在する。分類精度は100ステップ毎に50個のテストデータの満足度を推定し正解になった個数の割合を表しているが、前学習において不適切な特徴量を抽出してしまい一時的に精度が悪くなってしまったと考えられる。

分類精度を向上させるには、アンサンブル学習を行う方法が考えられる³⁾。アンサンブル学習とは、個別に学習を行ういくつかのNNを用意し、これらの多数決で分類結果を決定する方法である。これにより、一つのNNの結果に左右されずに、安定した分類精度を出すことが可能となる。

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, TensorFlowではじめるDeepLearning実装入門. 株式会社インプレス (2018).
- 3) 斎藤康毅: ゼロから作るDeep Learning—Pythonで学ぶディープラーニングの理論と実装, オーム社 (2017).