

転移学習を用いた瞳孔径の対光反射補正方式に関する検討 A Consideration on Pupillary Light Reflex Compensation by Transfer Learning

加藤 敦士[†]
Atsushi Kato

菅沼 睦[‡]
Mutsumi Suganuma

亀山 渉[‡]
Wataru Kameyama

1. はじめに

瞳孔径変動から映像視聴者の興味度を推定する場合、画面輝度による影響を除外する対光反射補正が必要である。深層学習を用いた対光反射補正方式[3]が提案されているが、学習データ不足による補正精度の問題が残されている。本稿では、既提案の輝度に対する瞳孔径変動モデルを利用し、輝度変化に対する瞳孔径変動データを大量に生成して深層学習させ、転移学習によって個人に対応した学習を行う方式を提案する。

2. 実験

2.1 転移学習の手順

転移学習のために、精度は低くともよいが大量のデータが必要である。本研究では、Pamplona と Oliveira による以下の対光反射モデル[1]を用いた。

$$M(D) = \operatorname{atanh}\left(\frac{D-4.9}{3}\right) \quad (1)$$

$$\frac{dM}{dD} \frac{dD}{dt} + 2.3026 \operatorname{atanh}\left(\frac{D-4.9}{3}\right) = 5.2 - 0.45 \ln\left[\frac{\phi(t-\tau)}{\phi}\right] \quad (2)$$

ここで、 D は瞳孔径[mm]、 $\phi(t)$ は時間 t における目に入る光の量[lumens]、 ϕ は閾値[lumens]、 τ は対光反射の反応遅延時間[msec]である。

式(2)は平均的な人の対光反射モデルであり、瞳孔径の散大・縮小の幅や平常時の瞳孔径サイズは個人差が大きく、実測の瞳孔径と乖離が生じる。そこで式(2)で得られた瞳孔径 D を、定数 a 、 b を用いて個人ごとに最適化させる手法を提案する。

$$D_{\text{personalized}} = aD + b \quad (3)$$

$$\text{error} = \sqrt{\frac{\sum_{i=1}^n (D_{\text{personalized}_i} - D_{\text{measured}_i})^2}{n}} \quad (4)$$

ここで、 $D_{\text{personalized}}$ は個人ごとに最適化された瞳孔径の時系列データ、 D_{measured} は被験者の学習用の瞳孔径の時系列データ、 n は時系列データの長さで、式(4)を最小とする a と b をベイズ最適化[2]によって求める。ある被験者の最適化後の結果を図1に示す。

図1から輝度値の変化(灰色)に対し、実測の瞳孔径変動(赤)と、最適化された瞳孔径変動(緑)の値がおおよそ一致していることがわかる。

本実験では被験者ごとに最適化された式(3)を基に、輝度変化に対する瞳孔径変動データを大量に生成し、Deep Neural Network (以下、DNN) に転移学習する。




図1 被験者の瞳孔径変動と式(3)による瞳孔径変動

2.2 実験手順

先行研究[3]と同様に、被験者に画面全体の輝度値が 0~255 で変化する映像を提示する。

学習輝度パターンとして、矩形波型 α (輝度値が 0 と 255 で変化する) を用意する。これは、先行研究[3]で最も学習効果が高いと報告されている輝度パターンである。瞳孔径予測輝度パターンとして、一定時間 (300~3000[msec]) ごとに一定の輝度 (0~255) で変化する輝度パターン β と、輝度が徐々に変化する輝度パターン γ を用意する。 α は瞳孔径変化の学習用、 β と γ は瞳孔径予測実験で使用する。

まず、 α 、 β 、 γ を被験者に提示し、観測した瞳孔径から 2[Hz]以上を取り除くローパスフィルタを施す。次に、複数の測定結果の加算平均を行うことで測定の際に偶発的に生じた情動反応による瞳孔径変動を低減し、最大瞳孔径を 5[mm]として 0 から 1 に瞳孔径を正規化する。

その後、 α による瞳孔径変動データをソースに式(3)の a と b を求め、サンプリング周波数 40Hz で約 1500 秒の瞳孔径の変動データをランダムな輝度変化に対して生成し、DNN に学習させて、転移学習を行う。なお、DNN に学習させる際には、瞳孔径データの 90% を学習に用い、残りの 10% は学習の評価に用いる。

最後に、同一のハイパーパラメータを持つ、転移学習したモデルと転移学習していないモデルを生成し、DNN の予測による瞳孔径と実測の瞳孔径間の RMSE を取得する。ここで、DNN に乱数で与えられるパラメータ初期値の影響を低減するため、モデルを 10 個生成し、平均の RMSE を比較し評価を行う。さらに、予測精度に大きな影響を与えたハイパーパラメータの値を変更し、検討を行った。

2.3 実験装置

瞳孔径の計測は、Tobii Technology 社製アイトラッカー Tobii X60 (60[Hz]計測) を用い、PC 画面と被験者との距離を一定に保つために、簡易なあご固定装置を用いて顔の位置を固定した。

[†] 早稲田大学大学院基幹理工学研究科, Waseda Univ.

[‡] 早稲田大学理工学術院, Waseda Univ.

2.4 被験者

被験者は、実験の参加に同意を得た大学院生 1 人 (年齢 24 歳) である。

2.5 DNN のハイパーパラメータ

DNN のハイパーパラメータを表 1 に示す。本実験では、特に結果に影響を与えた学習率と patience で比較を行った。

表 1 DNN のハイパーパラメータ

中間層 (ノード数)	[100, 100, 100]
活性化関数	Sigmoid
学習率	0.01, 0.001, 0.0001, 0.00001
バッチサイズ	10
最適化関数	Adam
損失関数	MSE
ドロップアウト	0.1
patience※1	0, 2, 4, 16
min_delta※2	1.0E-6

※1: patience は、値が改善しなくなり、学習の終了判定が出てからも続ける学習回数。

※2: min_delta は、値が改善としたとみなされる最小変化値。

2.6 実験結果

被験者の式(3)の係数は、 $a = 1.9435$ と $b = -0.62394$ となった。この a と b の値を元に転移学習を行う。

まず、実測瞳孔径変動と、転移学習の有無による予測瞳孔径間の RMSE を表 2 に示す。 β と γ の RMSE 平均を外挿 RMSE と呼び、太字は転移学習の有無それぞれにおける最も高精度な結果を示している。

表 2 転移学習の有無による RMSE 比較表

学習率	patience	α の RMSE 転移学習 有/無	外挿 RMSE 転移学習 有/無
0.01	0	0.0202 / 0.0247	0.0570 / 0.0640
0.01	2	0.0164 / 0.0129	0.0560 / 0.0615
0.01	4	0.0150 / 0.0135	0.0550 / 0.0558
0.01	16	0.0144 / 0.0117	0.0608 / 0.0615
0.001	0	0.0157 / 0.0224	0.0574 / 0.0575
0.001	2	0.0127 / 0.0145	0.0559 / 0.0573
0.001	4	0.0145 / 0.0124	0.0534 / 0.0563
0.001	16	0.0102 / 0.0100	0.0593 / 0.0558
0.0001	0	0.0112 / 0.0158	0.0610 / 0.0647
0.0001	2	0.0134 / 0.0219	0.0609 / 0.0661
0.0001	4	0.0112 / 0.0114	0.0562 / 0.0587
0.0001	16	0.0105 / 0.0105	0.0552 / 0.0551
0.00001	0	0.0181 / 0.0500	0.0625 / 0.0857
0.00001	2	0.0183 / 0.0296	0.0622 / 0.0725
0.00001	4	0.0136 / 0.0454	0.0596 / 0.0778
0.00001	16	0.0120 / 0.0132	0.0566 / 0.0571

次に、転移学習を用いた提案手法による被験者の実験結果の一例を図 2 に示す。式(3)と実測値間の RMSE は 0.0815、DNN (転移学習有) の予測値と実測値間の RMSE は 0.0659 であった。




図 2 γ による瞳孔径変動と式(3)と DNN (転移学習有) による瞳孔径変動

3. 考察

図 2 と表 2 から、式(3)による最適化 (緑) より、転移学習した DNN による予測 (青) の方が実測の瞳孔径変動 (赤) に接近しており、また、RMSE の値からも、転移学習により精度が向上していることがわかる。表 2 から、ハイパーパラメータの値によらず、ほぼ転移学習の結果が優れた理由は、事前に瞳孔径応答モデルを構築しておくことで、過学習の防止の実現や、DNN が局所解に陥る可能性が下ったためと考えられる。

また、patience 値が高いと提案手法の精度は下がり、従来手法の精度は上がる傾向があり、転移学習の普遍的な優位性は示せなかった。提案手法では、転移学習の高い学習速度が逆に作用し、patience による学習が長引くことで過学習に陥り、従来手法では、patience の十分な長さによって局所解から抜け出せるようになったからだと考える。

4. まとめと今後の課題

長時間のグレースケール提示による被験者の瞳孔径変動の取得は現実的に難しく、少ないデータで学習を行える転移学習は対光反射補正方式において有効なアプローチと考える。しかし、今回の実験において対光反射補正方式の精度の大幅な向上は実現できなかった。これは、少ない学習データでも DNN は最適解を導きだし、転移学習とおおよそ等しい結果を出せることを示唆している。

つまり、対光反射補正方式の精度は学習データに大きく依存しているということであり、対光反射補正方式の精度向上のために、より最適な学習輝度パターンの検討が必要だと考えられる。

また、安定的に精度の高い対光反射補正モデルを実現できる一方で、ハイパーパラメータの組み合わせによって精度の相対的低下が起こるため、グリッドサーチなどハイパーパラメータの最適化の併用も必要だと考えられる。

5. 謝辞

本研究は JSPS 科研費 15H01684 の助成を受けたものです。

参考文献

- [1] Vitor F., Pamplona, Manuel M. Oliveira, Gladimir Valerio Guimaraes Baranoski, "Photorealistic models for pupil light reflex and iridal pattern deformation", ACM Transactions on Graphics (TOG), Volume 28, Issue 4, August 2009
- [2] J. Snoek, H. Larochelle, R. P. Adams, "Practical bayesian optimization of machine learning algorithms", Proc. of NIPS-12, 2012
- [3] 加藤敦士, 菅沼睦, 亀山涉, "ディープラーニングによる瞳孔径の対光反射補正方式に関する検討", 電子情報通信学会, 2017 年総合大会, H-2-12, 2017 年 3 月