

視線停留時間を活用した顔魅力評価システム の効率的表現に関する研究

浅井, 和之 / Asai, Kazuyuki

(出版者 / Publisher)

法政大学大学院理工学研究科

(雑誌名 / Journal or Publication Title)

法政大学大学院紀要. 理工学研究科編

(巻 / Volume)

65

(開始ページ / Start Page)

1

(終了ページ / End Page)

6

(発行年 / Year)

2024-03-24

(URL)

<https://doi.org/10.15002/00030728>

視線停留時間を活用した顔魅力評価システムの 効率的表現に関する研究

A STUDY ON EFFICIENT REPRESENTATION
OF FACIAL ATTRACTIVENESS ASSESSEMENT SYSTEM
UTILIZING GAZE FIXATION TIME

浅井 和之
Asai Kazuyuki
指導教員 山岸昌夫

法政大学大学院理工学研究科応用情報工学専攻修士課程

In facial attractiveness assessment, there are significant individual differences in gaze behavior of evaluators. Thus, it is crucial to consider these individual differences in the machine learning models that assess facial attractiveness based on gaze fixation time. One of the simplest approach to construct this system is to construct individual softmax classifiers for each evaluator. However, this approach cannot utilize any insights from other evaluators for constructing individual softmax classifiers for new evaluators.

This study aims to achieve a model that can utilize insights from other evaluators while considering individual differences among evaluators. To accomplish this, we propose an efficient representation of all parameter matrices of individual softmax classifiers and reveal the geometric features common to all parameter matrices. First, we propose a model assuming that all the parameters of the individual softmax classifiers are given by the linear combination of a common set of basis matrices. Next, we apply this proposed model to real facial attractiveness assessment data and confirm numerically that it achieves high accuracy in estimating attractiveness ratings, exceeding 90%, even when using fewer basis matrices than the number of evaluators. The parameter matrices of the individual softmax classifier generated by the proposed model are localized in a narrow subspace spanned by a common set of few basis matrices. Based on this geometric insight, we propose a transfer learning method that utilizes pre-trained basis matrices for constructing softmax classifiers for new evaluators. Finally, through numerical experiments, we confirm that this transfer learning method is highly effective in reducing the time required to construct softmax classifiers.

Keywords : Machine Learning, Softmax Regression Model, Gaze Fixation Time, Facial Attractiveness

1 はじめに

魅力の知覚・判断は、人間にとって日常的な経験であり、半ば無意識的に行われている [1]。顔が魅力的な人物は、様々な社会的活動において利益を得ると言われており、例えば、配偶者選択において非魅力的な人物よりも有利であること [2] や、会社に雇用されやすいこと [3] が報告されている。顔魅力は社会生活と密接に関わる要素であり、人間による魅力評価のメカニズムの解明が重要な課題となっている [4]。ところが、同一の顔に対する魅力評価は評価者の間で個人差が大きいことが報告されている [5][6]。つまり、各評価者が備えている評価メカニズムが異なっていることを示唆しており、この課題の難しさの一端を表している。

一方、無意識下での評価メカニズムに強く関連する代表的なものとして、評価者の視線運動が知られている。例えば、顔から受ける印象（外向性、協調性、神経質、向上心、好奇心）の定量化のために、顔画像を呈示した際

の視線運動を活用する手法が提案されている [7]。この手法では、評価者の特性も考慮した視線行動のモデル化や評価者の特性・視線行動と印象評価値の関係のモデル化を試みている。

本研究では、評価者の特性と視線運動と顔魅力評価値の関連を調べるために、視線運動から顔魅力評価値を推定するシステムを検討している。評価者の特性を考慮したシステムを作る素朴な方法の一つは、各評価者の視線運動と顔魅力評価値のデータを収集し、評価者ごとに (Softmax 回帰モデルなどの) 分類器を作ることだと考えられる。特性が似ている複数の評価者に対しては、類似した分類器が構成できることが期待される。そのため、評価者ごとの分類器に対して、評価者を跨いだ、効率的な表現が存在することが予想される。この予想を検証するため、本研究では、評価者ごとの Softmax 回帰モデルのパラメータ行列を、評価者に寄らない共通の複数行列の線形結合で表現するモデルを提案している。さらに、実際に収集したデータに対して提案モデルを適用し、評価者の人数に比べ少数の共通複数行列を用いた場合にお

いても十分な分類精度が達成されることを確認している。言い換えると、上述の予想が正しいことを実証している。

2 準備：Softmax 回帰モデル

教師データ $(\tilde{\mathbf{x}}_i, y_i) \in \mathbb{R}^{P-1} \times \{1, 2, \dots, L\}$ (L はラベルの種類) が N 個あるとする。 y_i は i 番目のデータが属するクラスを表す。 y_i を one-hot ベクトルに変換したものを $\mathbf{y}^i = \mathbf{e}_{y_i} \in \{0, 1\}^L$ とする。

Softmax 回帰モデルの分類器 $\tilde{h}_{\mathbf{W}} : \mathbb{R}^{P-1} \rightarrow \mathbb{R}^L$ は

$$\tilde{h}_{\mathbf{W}}(\tilde{\mathbf{x}}) := \left(\frac{\exp(\langle (\tilde{\mathbf{x}}, 1), \mathbf{w}_j \rangle)}{\sum_{l=1}^L \exp(\langle (\tilde{\mathbf{x}}, 1), \mathbf{w}_l \rangle)} \right)_{j=1}^L$$

によって定義され、バイアスを含めたパラメータ行列 $\mathbf{W} := [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_L] \in \mathbb{R}^{P \times L}$ を学習によって決定する。ここで、 $\langle \cdot, \cdot \rangle$ は、 \mathbb{R}^P の標準内積である*1。全く同一の分類器ではあるが、より簡易な表現として、拡張された特徴ベクトル $\mathbf{x}_i := (\tilde{\mathbf{x}}_i, 1) \in \mathbb{R}^P$ を用いて、 $\{(\mathbf{x}_i, y_i)\}_{i=1}^N$ を教師データとし、分類器を $\tilde{h}_{\mathbf{W}} : \mathbb{R}^P \rightarrow \mathbb{R}^L$

$$\tilde{h}_{\mathbf{W}}(\mathbf{x}) := \left(\frac{\exp(\langle \mathbf{x}, \mathbf{w}_j \rangle)}{\sum_{l=1}^L \exp(\langle \mathbf{x}, \mathbf{w}_l \rangle)} \right)_{j=1}^L \quad (1)$$

と表現することもできる。本稿では、後者の表現を用いる。

学習では、 $\tilde{h}_{\mathbf{W}}$ の出力する分布により、教師データ (\mathbf{x}_i, y_i) のラベル y_i の one-hot ベクトル \mathbf{y}^i を近似することを目指し、対数尤度の最大化と等価な「負の対数尤度の最小化」

$$\underset{\mathbf{W} \in \mathbb{R}^{P \times L}}{\text{Minimize}} - \sum_{i=1}^N \log \tilde{\ell}_i(\mathbf{W}) \quad (2)$$

を行う。ここで、

$$\tilde{\ell}_i(\mathbf{W}) := \left(\tilde{h}_{\mathbf{W}}(\mathbf{x}_i) \right)_{y_i} \quad \left(= \tilde{h}_{\mathbf{W}}(\mathbf{x}_i) \text{ の第 } y_i \text{ 成分} \right)$$

は i 番目のデータサンプルに対する尤度を表す。最小化問題 (2) の目的関数は微分可能であるため、最急降下法を適用し求解することが出来る（詳細は、修論本体を参照されたい）。

3 提案法

3.1 問題設定

本研究における顔魅力評定推定システムは、顔画像が呈示された際の顔の各部位に対する総視線停留時間を入力データとし、魅力の評定値の確率を出力するものとする。総視線停留時間は、評価者ごとの特性の影響を強く受けるため（具体的には 4.3 参照）、個人の特性を考慮することが顔魅力評定推定システムの実現に必要不可欠となる。

評価者の特性を考慮する素朴な方法の一つとして、評価者ごとに収集したデータを用いて Softmax 回帰モデルなどの機械学習モデルの学習を行い、評価者ごとに適切な分類器を構成する方法である。具体的には、 K 人の評価者がいる状況を想定し、各評価者に顔画像を呈示し、顔の各部位に対する総視線停留時間を測定すると共に、魅力度を L 段階で評定してもらうことで、教師データを収集し、評価者ごとに適切な分類器を構成する。つまり、

- 評価者 $k \in \{1, 2, \dots, K\}$ による総視線停留時間（で決まる拡張された特徴ベクトル）と魅力度評定値の対の集合（評価者 k の教師データセット）を $\{(\mathbf{x}_i, y_i)\}_{i \in \mathcal{I}_k} \subset \mathbb{R}^P \times \{1, 2, \dots, L\}$ とし、全体のデータサンプルの数を $N := \sum_{k=1}^K |\mathcal{I}_k|$ とする。
- 評価者 k の教師データセット $\{(\mathbf{x}_i, y_i)\}_{i \in \mathcal{I}_k}$ を用いて、Softmax 回帰モデルの学習を行い、パラメータ行列 $\mathbf{W}^{(k)} \in \mathbb{R}^{P \times L}$ を決定する。

最後に、作成した評価者ごとの Softmax 回帰モデルを用いることで、教師データの収集に際して呈示していない顔画像も含めて、顔画像が呈示された際の総視線停留時間を測定することで、評価者が魅力度評定を行うことなく、魅力の評定値の推定を行うことが出来る。

この素朴なシステムでは、評価者ごとに異なるデータセットを用いて独立に学習を行うため、特性が似ている評価者に対して、類似したパラメータ行列が学習されることを保証できない。一方で、特性が似ている評価者に対しては、類似したパラメータ行列を持つ学習器が十分な推定精度を達成することが予想される。すなわち、各評価者に対する適切なパラメータ行列は、空間 $\mathbb{R}^{P \times L}$ 全体に広く分布しているわけではなく、局在していることが予想される。このことから、適切なパラメータ行列が低次元の部分空間の近傍に局在していることが期待でき、全てのパラメータ行列 $\{\mathbf{W}^{(k)}\}_{k=1}^K$ を、より少数 ($M < L$) の複数行列 $\mathbf{W}^{(1)}, \mathbf{W}^{(2)}, \dots, \mathbf{W}^{(M)} \in \mathbb{R}^{P \times L}$ (以降、この複数行列を基底と呼ぶ) の線形結合を用いて、

$$\mathbf{W}^{(k)} = \sum_{j=1}^M \omega_k^{(j)} \mathbf{W}^{(j)} \quad (k = 1, 2, \dots, K) \quad (3)$$

と表現することが予想される。ここで、 $\omega_k := (\omega_k^{(1)}, \omega_k^{(2)}, \dots, \omega_k^{(M)})^\top \in \mathbb{R}^M$ は線形結合の係数である。

本研究では、この予想を検証するため、線形結合を用いたパラメータ行列の表現 (3) を直接用いたモデルを提案する。

3.2 提案モデル

表現 (3) を直接用いたモデルとして

$$h_{\mathcal{W}}^{(\omega_k)}(\mathbf{x}) := \left(\frac{\exp\left(\left\langle \mathbf{x}, \sum_{l=1}^M \omega_k^{(l)} \mathbf{w}_j^{(l)} \right\rangle\right)}{\sum_{l=1}^L \exp\left(\left\langle \mathbf{x}, \sum_{l=1}^M \omega_k^{(l)} \mathbf{w}_l^{(l)} \right\rangle\right)} \right)_{j=1}^L \quad (4)$$

*1 つまり、 $\langle \cdot, \cdot \rangle : \mathbb{R}^P \times \mathbb{R}^P \rightarrow \mathbb{R} : (\mathbf{v}, \mathbf{w}) \mapsto \mathbf{v}^\top \mathbf{w}$ である。 $(\cdot)^\top$ は転置を表す。

を提案する. ここで, 基底 $\mathbf{W}^{(1)}, \mathbf{W}^{(2)}, \dots, \mathbf{W}^{(M)}$ を並べてできる 3 階テンソルを $\mathcal{W} \in \mathbb{R}^{P \times L \times M} =: \mathcal{H}$ とし, 基底の j 番目の行列の第 l 列を $\mathbf{w}_j^{(l)}$ または $[\mathcal{W}]_{:,j,l}$ と表記する. このモデルでは, 3 階テンソル \mathcal{W} と行列 $\Omega = [\omega_1, \omega_2, \dots, \omega_K] \in \mathbb{R}^{M \times K} =: \mathcal{K}$ を学習によって決定する. 学習では, 負の対数尤度の最小化

$$\text{Minimize} - \sum_{k=1}^K \sum_{i \in \mathcal{I}_k} \log \ell_i(\mathcal{W}, \omega_k) \quad (5)$$

を行う. ここで, $\ell_i(\mathcal{W}, \omega_k) := \left(h_{\mathcal{W}}^{(\omega_k)}(\mathbf{x}_i) \right)_{y_i}$ は尤度を表し, \mathcal{I}_k は k 人目のデータセットのデータ番号の集合を表す.

この最適化問題 (5) に対する反復アルゴリズムとして交互最急降下法が考えられる (詳細は, 修論本体を参照されたい).

3.3 提案モデルの応用例: 転移学習

提案モデルは, 被験者全体に依存して作られた \mathcal{W} と, 被験者ごとに作られる結合係数 ω_k とによって作られる. ここで, 新しい被験者 $K+1$ に対して, Softmax 回帰モデルを作成したいとする. \mathcal{W} は, 大多数の被験者にとって重要な情報が詰まったものであると考えられるので, 新しい被験者にとって必要とされる情報も含まれていると予想される. そのため, \mathcal{W} を更新することなく, 新しい被験者の $\omega_{K+1} \in \mathbb{R}^M$ のみを学習することで, 新しい被験者に適した Softmax 回帰モデルを効率的に作成できると考えられる.

4 実験

まず, 顔魅力評価実験により, 被験者 (評価者) に顔画像を呈示し, その際の視覚動作を計測するとともに, 顔画像の魅力度の評価してもらった (4.1 節). 次に, 顔魅力評価実験により得られた視覚動作の情報と魅力度評価をもとにデータセットを作成した (4.2 節). さらに, 作成したデータセットにおいて, 視覚動作に評価者の特性や個人差があるかを主成分分析を用いて調査した (4.3 節). この調査により, 評価者の特性や個人差が確認できたため, 作成したデータセットに提案モデルを適用し, その性能を評価した (4.4 節). 最後に, 提案モデルを用いた転移学習についても, その効果を検証した (4.5 節).

4.1 顔魅力評価実験

被験者は正常な視力もしくは矯正視力を有する大学生及び大学院生, 計 29 名 (男性 29 名, 平均年齢 21.3, SD=0.70) に協力してもらい, 被験者に顔画像の魅力度評価実験であることを伝えた上で実験を行った. 視覚刺激として, Face Research Lab London Set[8] の女性の顔画像を 21 枚選定し, モノクロ化後に正規化処理を行ったものを用いた (図 1 参照).

視線動作の計測には Tobii Pro nano (スウェーデン Tobii technology 社製) を用いた. 計測時のサンプリング周波数は 60Hz であった. 視覚刺激の呈示には解像度 1920×1080 pixel の 15 インチの液晶ディスプレイを使用した.

実験開始前に, 被験者の顔の位置を顎台によって固定



図 1 正規化した画像の一例

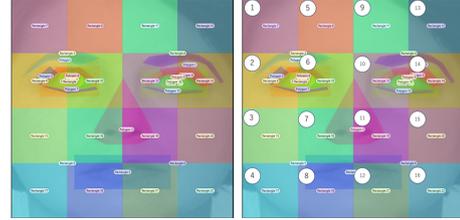


図 2 ROI 画像

し, 目元からディスプレイまでの視距離を 65cm とした.

実験では, まず画面中央に顔画像と同じサイズの真っ白のニュートラル画像を 3 秒間呈示し*2, 次に画面中央に顔画像を 7 秒間呈示した. その後, 魅力度を 7 段階 (1 に近づく程低魅力, 4 がニュートラル, 7 に近づく程高魅力) で評定した. この一連の作業を, 最初に 4 枚の顔画像に対して練習として行った. そして残りの 17 枚の顔画像を同様の処理で呈示させ, 評定して貰った.

4.2 データセットの作成

評価者に顔画像を呈示した際の視線動作から, 顔画像の各部位に視線が停留していたかの時間を測定し, その情報をもとに特徴ベクトルを作成した.

まず, 顔画像を 16 分割した正方領域を興味領域 (Region of Interest: ROI) とし, それぞれ 1~16 の番号を振った. 次に, 顔画像ごとに右眉毛, 左眉毛, 鼻, 右眼, 左眼, 口の 6 部位をそれぞれ興味領域とした. 尚, 被験者が 6 部位のどれかを見ている時にはそれに重複した正方領域上にも視線があることになるが, 6 部位を見ているものとして取り扱うこととした. 設定後の画像の例を図 2 左に示す. 図 2 右に正方領域に番号を振った画像を示す.

各被験者と各顔画像に対して, 設定した興味領域ごとに, 顔画像呈示中の視線停留時間の合計を算出し, 拡張された特徴ベクトル

$$\mathbf{x} := (x_1, x_2, \dots, x_{10}, 1)^\top \in \mathbb{R}^{11} \quad (6)$$

を作成した. そして (6) の第 1~第 6 成分 x_1, x_2, \dots, x_6 は, それぞれ, 右眉毛, 左眉毛, 鼻, 右眼, 左眼, 口の視線停留時間の合計であり, 第 7,8,9 成分 x_7, x_8, x_9 は, それぞれ「6 番の正方領域 (以下, 目鼻周辺 (右) と呼ぶ)」*3, 「10 番の正方領域 (以下, 目鼻周辺 (左) と呼

*2 ニュートラル画像を見せる理由は, 顔画像に比べディスプレイのサイズが大きいため, 顔画像の外側の領域に視線が行かないよう, 視線誘導するためである.

*3 顔の 6 部位が優先されるルールとしたため, 目鼻周辺 (右) には,

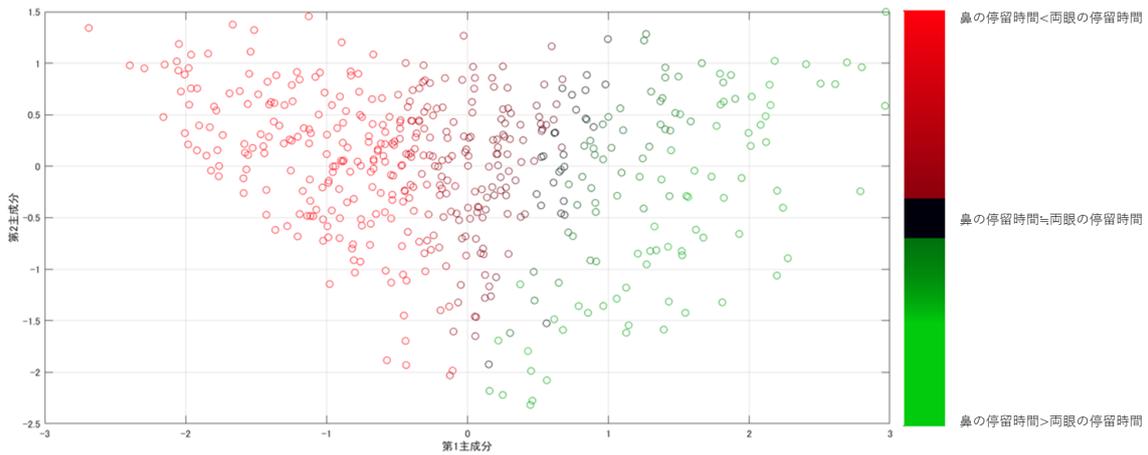


図3 第1,2主成分得点の散布図. 鼻と両眼の視線停留時間において、鼻の停留時間の比率が大きい程鮮やかな緑色に、両眼の停留時間の比率が大きい程鮮やかな赤色に、比率が同程度の場合は黒色に配色した。

ぶ)」、「6番10番以外の正方領域」の視線停留時間の合計である。第10成分 x_{10} は視線が移動した時間の合計である。第11成分は、バイアスのための1となっている。

また、魅力評定値に基づきラベルを決定した。魅力度1のデータが極端に少なかったため、魅力の評定値ラベルは、以下の2パターンで決定した。

評定値ラベルが5種類 ($L = 5$) の場合: 魅力度1と2のサンプルのラベルを1, 同様に、魅力度3を2, 魅力度4を3, 魅力度5を4, 魅力度6と7を5とした。

評定値ラベルが3種類 ($L = 3$) の場合: 魅力度1-3のサンプルのラベルを1, 魅力度4を2, 魅力度5-7を3とした。

以上により、1人の評価者に1枚の顔画像を呈示して得られた結果に対応するデータサンプルとして、11次元の拡張された特徴ベクトルとラベルの対を作成した。それらを実験者29人、本番の顔画像17枚について集めた $\{(\mathbf{x}_i, y_i)\}_{i=1}^{493} \subset \mathbb{R}^{11} \times \{1, 2, \dots, L\}$ をデータセットとした。なお、各評価者の教師データセット $\{(\mathbf{x}_i, y_i)\}_{i \in I_k}$ は $I_k = \{17(k-1), 17(k-1)+1, \dots, 17k\}$ ($k = 1, 2, \dots, 29$) である。

4.3 視覚動作における評価者の特性・個人差の検証

特徴ベクトル $\tilde{\mathbf{x}}_i$ (つまり、 \mathbf{x}_i から第11成分を除いたもの) を並べてできる行列 $\tilde{\mathbf{X}} := [\tilde{\mathbf{x}}_1, \tilde{\mathbf{x}}_2, \dots, \tilde{\mathbf{x}}_{493}] \in \mathbb{R}^{10 \times 493}$ に対して主成分分析を適用した。第1,2主成分の係数を表1に示す。また、横軸を第1主成分得点、縦軸を第2主成分得点とした散布図を図3に示す。

表1より、鼻と右眼・左眼に対応する係数の絶対値が大きいため、被験者の視線停留時間の個人差は、鼻と右眼・左眼に大きく現れることが分かった。

視線停留時間の鼻と両眼の比率を観察したところ以下のことが分かった。(i) 両眼の停留時間が長く、両眼に比べて鼻の停留時間が短い被験者が4人いた。また、(ii) 鼻

右眼と鼻は含まれてないことに注意されたい。同様に、目鼻周辺(左)には左眼と鼻は含まれない。

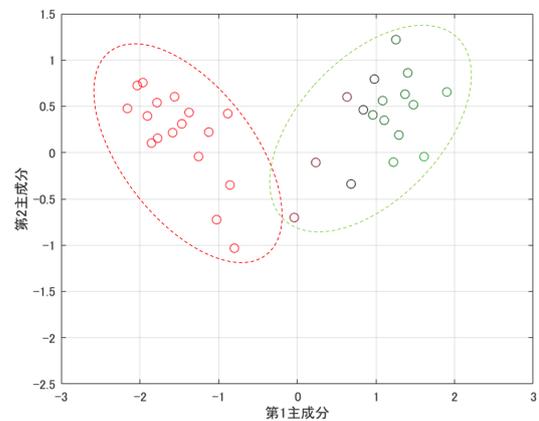


図4 被験者A,Bの第1,2主成分得点の散布図. Aのデータ群を赤の点線で囲み、Bのデータ群を緑の点線で囲んだ。

の停留時間が長く、鼻に比べて両眼の停留時間が短い被験者が4人いた。

(i) に該当する被験者Aと(ii) に該当する被験者Bに着目する。図4は、図3の散布図の中から被験者Aと被

表1 第1,2主成分の係数

	第1主成分	第2主成分
右眉毛	-0.00361	-0.01706
左眉毛	-0.00782	-0.02430
鼻	0.79894	0.54126
右眼	-0.41886	0.46245
左眼	-0.41722	0.50978
口	0.00028	-0.04630
目鼻周辺(右)	-0.05272	-0.04735
目鼻周辺(左)	-0.03153	-0.08196
6番10番以外の正方領域	0.09012	-0.28817
視線が移動した時間	0.01451	-0.37184

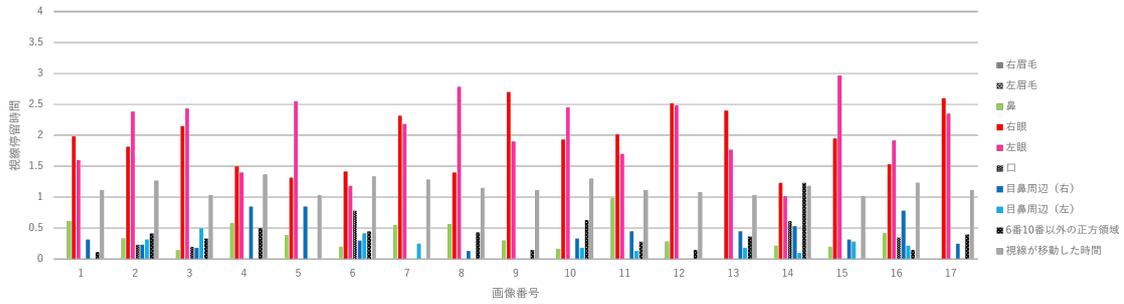


図5 被験者 A の視線停留時間のプロット

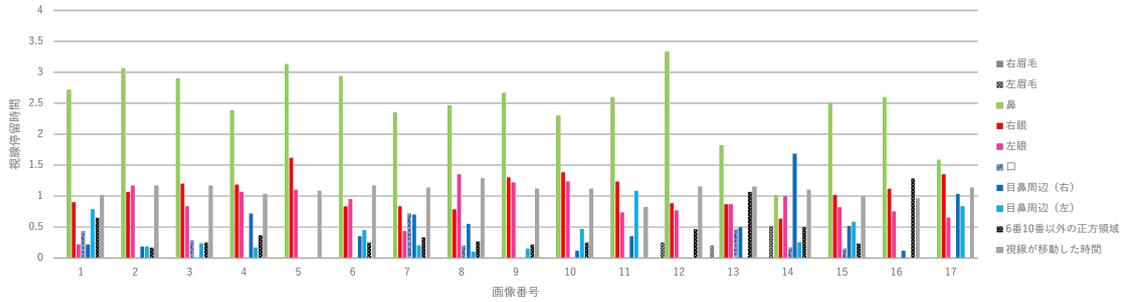


図6 被験者 B の視線停留時間のプロット

験者 B のデータ点のみを抜き出して示したものである。顔画像に依らず、被験者 A は視線が両眼に長時間停滞しており、被験者 B は視線が鼻に長時間停滞していることが分かる。

図5と図6は被験者 A と被験者 B の特徴ベクトル (6) を各画像について棒グラフとして示したものである。図5より被験者 A は、どの画像においても、鼻の停留時間が右眼や左眼に比べて長いことが分かる。また、図6より被験者 B は、どの画像においても、右眼と左眼の停留時間が鼻に比べて長いことが分かる。

これらの結果より、以下のような知見を得られた。

- (i) 一部の評価者群が、顔画像に依らず、両眼に長く視線が停留する傾向を持つ。
- (ii) 一部の評価者群が、顔画像に依らず、鼻に長く視線が停留する傾向を持つ。

ここから、被験者のデータには個人差があると同時に、そのタイプは、人数分よりも少なくなるという可能性が示唆された。

4.4 提案モデルの性能評価

提案モデルでの $L = 3, 5$ の全データから算出した精度*4 が、更新の中で最も高かった値を図 7, 8 に示

*4 提案モデル (4) の精度は、評価者ごとの正答率を平均したものと

$$\frac{1}{K} \sum_{k=1}^K \frac{(h_{\mathcal{V}}^{(\omega_k)}) \text{ の教師データ } \{(\mathbf{x}_i, y_i)\}_{i \in \mathcal{I}_k} \text{ での正解数}}{|\mathcal{I}_k|}$$

とした。なお、各評価者の教師データのサンプルの個数は同一 ($|\mathcal{I}_k| = 17$) である。同様に、評価者ごとに Softmax 回帰モデルを構成する素朴なモデルの精度を以下のように定義した。

$$\frac{1}{K} \sum_{k=1}^K \frac{(\text{評価者 } k \text{ に対する Softmax 回帰モデルの } \{(\mathbf{x}_i, y_i)\}_{i \in \mathcal{I}_k} \text{ での正解数})}{|\mathcal{I}_k|}$$

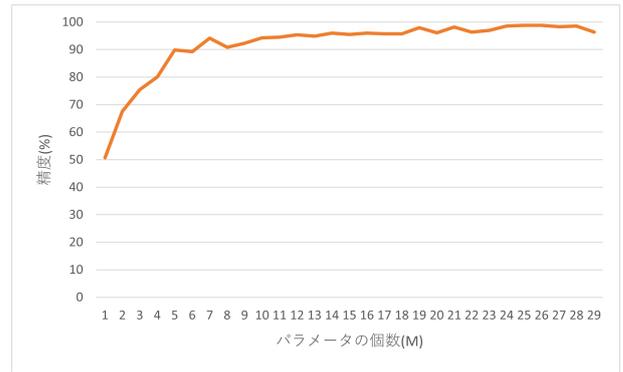


図7 $L = 3$ の精度

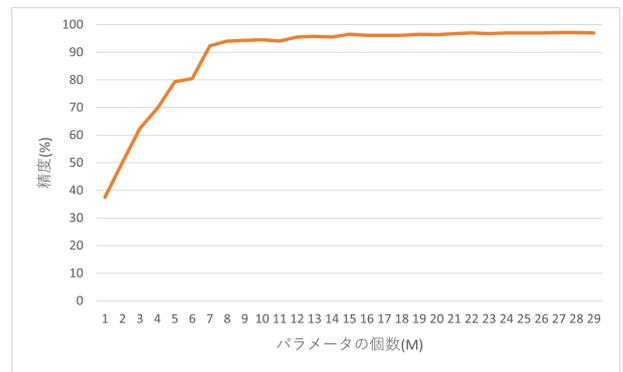


図8 $L = 5$ の精度

す。更新回数は全て 1000000 回とし、交互最急降下法のステップサイズは $\mu_1 = 0.0023$, $\mu_2 = 0.001$ とした。 $L = 3, L = 5$ 共に $M = 7$ 以上の時に、精度が 90% を越えていた。

一方で、 $L = 3, L = 5$ のそれぞれの場合に、評価

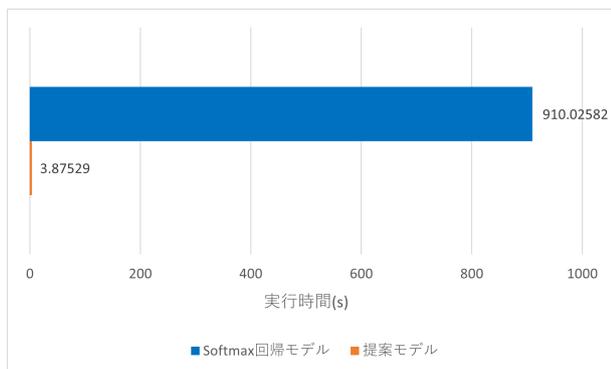


図9 被験者番号 k_{test} のデータでの、単一の Softmax 回帰モデルと提案モデルそれぞれで精度が 100% になるのにかかった時間 (s)

者ごとに 1000000 回の更新回数で Softmax 回帰モデルを実装し、各々の更新の中で最も高かった精度の値 (評価者 k の精度を accuracy_k とする) の平均値 ($= \frac{1}{K} \sum_{k=1}^K \text{accuracy}_k$) が約 98% となった。

この結果より、評価者の人数に比べて少数の行列の線形結合を用いた提案モデル (例えば $M = 9$ 程度。これは評価者の人数 29 に比べて少数である) により評価者ごとに Softmax 回帰モデルを実装した場合と同等の性能を実現できることが確認できた。このことから、評価者ごとに Softmax 回帰モデルに対して、評価者を跨いだ、効率的な表現を与えられることが実証できた。

4.5 提案モデルを活用した転移学習の検証

3.3 節で述べた転移学習の性能を検証するために、以下の手順で実験を行った。

- (手順 1) 29 人の被験者の中から 1 人 (k_{test} 番目とする) のデータサンプルをテストデータとした。
- (手順 2) テストデータ以外の 28 人のデータを訓練データとして、提案手法によって学習を行い、事前学習された $W_{\text{pre}} \in \mathbb{R}^{P \times L \times M}$ を作成した。
- (手順 3) テストデータと事前学習された W_{pre} を用いて、結合係数 $\omega_{k_{\text{test}}} \in \mathbb{R}^M$ を学習して、被験者 C のための Softmax 回帰モデルを作成する。

手順 1 では、 $k_{\text{test}} = 2$ とした。手順 2 の事前学習では、 $\mu_1 = 0.0023$, $\mu_2 = 0.001$, $M = 11$, $L = 3$, 更新回数は 100000 回とした。この時の訓練データにおける精度は 97.26891% であった。

図 9 に、実行結果と単一の Softmax 回帰モデルでの結果を示す。このテストデータでは、単一の Softmax 回帰モデルで精度 100% を出すのにかかった時間が 910 秒であったのに対して、今回の学習にかかった時間は約 4 秒であったことから効率の良い学習であったと言える。

5 まとめ

視線停留時間の情報から魅力評定値を推定するシステムの実現を目指し、評価者ごとに Softmax 回帰モデルを構築する手法において、モデルのパラメータ行列を効率的に表現するためのモデルを提案した。その性能を確認

するため、顔魅力評定実験の実施結果から作成したデータセットに適用し、評価者ごとの Softmax 回帰モデルのパラメータ行列を効率的に表現できることを実証した。

この結果から、評価者に共通する情報である W を事前学習済み情報と捉えて、新しい評価者に対する Softmax 回帰モデルを作成する際に、 W を活用して、転移学習を行う方法を提案するとともに、それによって学習時間が大幅に短縮されることを確認した。この結果は、被験者が増えた際に、評価者の特性を考慮した推定システムを効率的に作成できる可能性を示唆している。

今後の展望としては、被験者の特徴を明確にするために、各被験者の結合係数 ω_k とデータセットとの関連性を調べたいと考えている。結合係数 ω_k から被験者の特徴が分かるようになれば、似ている特徴を持った被験者の判断に役立てることができ、人間の魅力評価メカニズムの個人差の解明に繋がると考えている。

参考文献

- [1] I. Aharon, N. Etcoff, D. Ariely, C. F. Chabris, E. O' Connor, and H. Breiter, "Beautiful faces have variable reward value: fMRI and behavioral evidence," *Neuron*, vol. 32, no. 3, pp. 537–551, 2001.
- [2] G. Rhodes, L. W. Simmons, and M. Peters, "Attractiveness and sexual behavior: Does attractiveness enhance mating success?," *Evolution and Human Behavior*, vol. 26, no. 2, pp. 186–201, 2005.
- [3] M. Agthe, M. Spörrle, and J. K. Maner, "Does being attractive always help? positive and negative effects of attractiveness on social decision making," *Personality and Social Psychology Bulletin*, vol. 37, no. 8, pp. 1042–1054, 2011.
- [4] C. C. Carbon, T. Grüter, and J. E. Weber, "Dissociation of facial attractiveness and distinctiveness processing in congenital prosopagnosia," *Visual Cognition*, vol. 18, no. 5, pp. 641–654, 2010.
- [5] J. Hönekopp, "Once more: is beauty in the eye of the beholder? relative contributions of private and shared taste to judgments of facial attractiveness," *Journal of Experimental Psychology: Human Perception and Performance*, vol. 32, no. 2, pp. 199–209, 2006.
- [6] H. Leder, J. Goller, T. Rigotti, and M. Forster, "Private and shared taste in art and face appreciation," *Frontiers in Human Neuroscience*, vol. 10, no. 2, p. 7, 2016.
- [7] 徐既哲, 川端良子, 松香敏彦, "モデル比較を用いた顔の印象評定における視線行動と性格特性の効果の検討," *日本顔学会誌*, vol. 17, no. 2, pp. 21–29, 2017.
- [8] L. M. Debruine and B. C. Jones, "Face research lab london set," 2017.