

機械学習による特徴量を用いた顔画像選択支援システム

日比野 友博^{1,a)} 謝 浩然¹ 宮田 一乗^{1,b)}

概要: 多数の画像の中から最も好ましいものを選び出すことは、その候補が大量である場合には選択者の負担になる。本研究では、販売されている 3D モデルを顔のイラスト画像から選ぶ状況を想定し、その選択を支援するシステムを開発した。機械学習によって全候補の特徴量を抽出した後、その特徴量を基に画像間の類似度を決定することにより、選択支援システムを作成した。システムは、ユーザがランダムな候補の中から選んだ初期候補または任意の画像を基に、特徴量が近い候補を呈示し、ユーザはまたその中から好ましい候補を選んでいく。実験の結果、ユーザが好みの画像を選択する手順を 1 ステップとして、おおよそ 3 ステップ以内で最終的な好みの絵を選択できるようになった。また、種類の推薦アルゴリズムを用意し、アンケート調査によってシステムの有用性および推薦アルゴリズムの妥当性を評価した。

キーワード: 画像解析, 機械学習, ユーザ支援

A Benchmark on Face Image Retrieval From Learning Attributes

Abstract: Choosing the most desirable image from many images can be a hard task for user when there are too many. In this study, we developed an image selection system assuming a situation where user chooses a 3D model for sale from its facial image. After extracting characteristics of all images by machine approach, the similarities among them were calculated based on the characteristics. The system presents candidates that are similar to the initial candidates selected by the user from random candidates or the image input from user, and the user can select the favorite one from candidates recommended by the system. User could decide the final selection within about 3 steps (1 step means that user selects the favorite one from candidates). In addition, we conducted a questionnaire survey after using the system, and compared the validity of the recommendation algorithm.

Keywords: Image Analysis, Machine Learning, User Support

1. 背景

インターネットと SNS の発達に伴い、直接会わずにまたは実際の肉体を明らかにせずに他者とコミュニケーションする機会は増加している。そのような場でユーザの「顔」となるのは主にアイコン等のイラストであるが、今後、CG 技術の発達に伴い、Live2D 等のモーフィングソフトで使えるイラストや、仮想／拡張現実空間上での分身となる 3D モデル（アバター）の割合が増えていくと予想される [1]。しかし、それらのデータは一般ユーザが簡単に作成できるものではなく、配布または販売されているものを手に入れ

るのが主な手段である。現状、アセットストアや仲介販売サービスを中心に 3D モデル販売が増加しているが、膨大な販売モデルの中から好みのものを選び出すのはユーザの負担となる。そこで、その負担を軽減し、ユーザの選択を補助するような仕組みが必要とされる。

2. 関連研究

2.1 画像による推薦システム

大量の商品の中からユーザに何らかの商品を勧めるような仕組みは、Amazon 等の EC サイトでは一般的である [2]。しかしそれらは過去の履歴や、他ユーザの行動データが必要であり、それらの付加情報なしでユーザに商品を勧めるには、商品情報から得られる情報のみを基にする必要がある。3D モデルの場合、商品紹介画像（サムネイル）に含まれる顔画像が有力な情報源となる。

¹ 北陸先端科学技術大学院大学
Japan Advanced Institute of Science and Technology
^{a)} t_hibino@jaist.ac.jp
^{b)} miyata@jaist.ac.jp

顔に対する画像解析は、顔認識 [3] や自動分類 [4] をはじめとして多くの研究例がある。近年は深層学習の応用も盛んであり、敵対的生成ネットワーク (GAN) を利用し、元画像から表情や眼鏡の有無といった要素を調節した画像を生成できる技術など [5]、その応用性は広がり続けている。こういった画像認識の技術は、監視カメラ等における産業上の需要も大きく、認識距離や精度の向上において研究が進んでいる [6]。しかし、これらの応用例は写実的な顔が対象であり、アニメ調の顔に対する研究例はそれらと比べてまだ進んでいない。

アニメ調の顔に特化した画像認識の研究は、顔認識の精度を高めた Takayama らの研究 [7] や、GAN によって顔を自動生成する Li らの研究 [8] があるが、分類や推薦モデルといった応用的な研究例はまだ少ない。

2.2 画像解析と機械学習の関係

画像データはピクセル数と色データ (RGB または白黒 + 場合によりアルファ値) の数が固定されていることから、次元の揃ったベクトル群として数値解析しやすい。このようなデータの情報を集約する手段として一般的なものは主成分分析 (Principal Component Analysis, PCA) である。PCA は、データの分散共分散行列を固有値分解することで、データをより見やすい方向へ基底変換するものである。非負値行列因子分解 (Non-negative Matrix Factorization, NMF) も PCA と似た手段であるが、これは各因子が負の量を持たないという特徴を持ち、因子同士が直交性を持たない反面、成分がより解釈しやすい場合もある [9]。

しかし、これらの手法は線形的な変換しか行わないため、データが二次曲線などの非線形の分布を持つ場合適切な集約ができないというデメリットがあった。この点に対応する手法として、線形変換と活性化関数による非線形変換とが多重に設定されたニューラルネットワーク (NN) によってこれを解決する方法が効果的であり、正誤判定や異常検知等の用途で目覚ましい発展を遂げてきた [10]。

NN によって入力画像→圧縮→中間層→復元→出力画像というレイヤーを設定し、入力画像と出力画像の誤差が少なくなるような変換方式を学習した場合、圧縮 (encode) が完了した段階の中間層は、入力画像の特徴を少数の変数で復元できる変数になり、これは潜在空間 (Latent Space) と呼ばれる。潜在空間によって変数を圧縮する手法は自己符号化器 (Auto Encoder) と呼ばれ、教師なし学習による異常値検出等に利用される [11]。

Turk と Pentland は写実的な顔画像を PCA にかけて得られる固有ベクトルが顔認識や分類に応用できることを明らかにしたが [12]、同様に、PCA ほか機械学習を使うことによりアニメ調の顔に対して特徴量を検出し、それを基に推薦アルゴリズムを開発できると考えられる。




図 1 Web サイトの様子




図 2 得られたサムネイルと顔検出の様子

2.3 目的

本研究では、サムネイルの顔画像から機械学習により特徴量を抽出し、それを基にユーザが大量の画像の中から好みの顔を選びやすくなるシステムを開発した。特徴量の抽出手法としては、まず一般的な圧縮手法である PCA を行い、またより因子を解釈しやすい手法である NMF を行い、更に NN を利用した手法として AE を試みた。これら 3 種類の特徴量抽出と、特徴量抽出を行わないものとの計 4 種類の推薦方法を作成し、アンケートでそれらの選びやすさを評価した。加えて、本研究では任意の画像を入力することによる選択支援手法も提案した。既存画像から学習されたモデルを用いて、任意の画像から特徴量を抽出し類似した画像を推薦することを可能にした。

3. 方法

3.1 顔画像データの収集

顔画像データの収集は、pixiv 社が運営する Web 販売仲介サービス「BOOTH」[13] から、「3D モデル」のタグがついたサムネイルを自動収集することにより行った (図 1)。こうして得られた 11,375 枚のサムネイルから、顔を検出するスクリプトを作成し、最終的に 1,462 枚の顔画像 (200 * 200 px) を得た (図 2,3)。顔の検出は OpenCV ライブラリ [14] を用いて行った。また、写実的な顔ではなくアニメ調の顔を検出するため、nagadomi が作成したアニメ顔検出用のライブラリファイル [17] を用いた。



図 3 得られた顔画像




図 4 PCA による元画像の復元の様子。左：オリジナル画像，中央左，中央右，右はそれぞれ主成分数 5,30,200 での復元。

3.2 機械学習による特徴量の解析

得られた顔画像を PCA と NMF と AE とによって特徴量抽出を行った。PCA と NMF は scikit-learn ライブラリを用いて行った [15]。事前に PCA による主成分抽出と，抽出された主成分からの画像復元のテストを行い，抽出する要素数の検討を行った。多すぎると元画像に近くなり，少なすぎると情報量が小さくなりすぎるので，ある程度元画像の情報を保ったまま汎化性を持つ数量として，要素数を 30 と定めた (図 4)。AE は tensorflow ライブラリを用いて行い [16]，潜在変数の次元は 30 とした。計算はすべて PC (CPU i7-9700K, RAM 32GB, GPU RTX2080SUPER, VRAM 8GB) で行った。解析に要した時間を表 1 に示す。各手法によって得られた特徴量を基に，特徴量間でのユークリッド距離を計算することにより画像間の類似度を決定した。また，特徴量抽出を行わない元画像データでもユークリッド距離を計算し，計 4 種類の類似度を計算した。

表 1 学習方法による計算時間		
method	device	time(s)
PCA	CPU	5
NMF	CPU	85
AE	GPU	200,000

3.3 推薦システム

ユーザが好むアバターを選びやすくするシステムを開発した。ユーザは初期選択として，1,432 枚の顔画像からランダムに 9 枚が表示され，ユーザはそこから最も好ましいものを選ぶ。次に，システムはアルゴリズムに従って，選んだ画像およびそれに類似した画像 8 枚の計 9 枚を表示する。ユーザはその中から更に最も好ましいものを選び，それで決定するかまた類似候補を出すかを選択する。




図 5 システムのフロー

このようなステップを続けていくことで，最終的な好みが決まり，Web ブラウザで実際の販売サイトを開くことで推薦を完了する。

また，初期候補の選択は，ランダムな候補だけではなく，ユーザが用意した任意の画像から特徴量を抽出して類似候補を呈示できるようにした。特徴量の抽出及び元画像の復元は，計算量の少ない，PCA で得られた固有ベクトルを用いた。システムのフローを図 5 に示す。

本研究では 4 種類の類似度計算によるアルゴリズムを用意したが，ユーザには初期候補選択から最終候補選択までの流れを，アルゴリズムごとに計 4 回使用させた。

3.4 実験手法

システムの評価実験を行った。被験者は，3D モデルを購入することを体験したことのない 18 名を選択した。スタンドアロン型 VR ヘッドセットである Oculus Quest を用いて，被験者に VR 空間でアバターになることを体感させた後に (図 6)，実際の販売サイトの様子を見せた。その後，システムを操作させ，好みの顔画像を選択させた。

類似候補を呈示するアルゴリズムの順番は無作為にして，4 種類のアルゴリズムの操作が終わった段階で，被験者にアンケート調査をした。アンケート項目は以下の通りである。

Q1, アルゴリズムによって選びやすさに差がありまし



図 6 VRSNS「VRChat」上でアバターになっている様子。画像中の人物も、アバターとして販売されている 3D モデルの 1 つである。

たか？

Q2, 良かったアルゴリズムと悪かったアルゴリズムを教えてください。

Q3, 本研究のシステムを使って、アバターを選択しやすくなったと思いますか？

Q4, 初期選択は、ランダム選択か画像入力かどちらがよいですか？

Q1, Q3 は 5 段階評価とし、「1: まったく思わなかった〜5: 非常にそう思った」とした。被験者が差を感じられなかった場合、つまり Q1 で「2」以下であった場合、Q2 は回答不要とした。Q2 は何番目のアルゴリズムが良く、何番目のものが悪かったかを回答させた。Q4 は 5 段階評価とし、「1: ランダム選択だけでよい」〜「3: どちらともいえない (併用したい)」〜「5: 画像入力だけでよい」とした。

4. 結果

4.1 特徴量の復元

特徴量を基にした類似候補の結果を示す (図 7)。入力された画像に対し各アルゴリズムが推薦する候補を並べたが、中には候補が重複するものもあった。特に PCA と NMF との間ではその傾向が強かったが、システム全体としては推薦候補に幅が見られた。

この類似候補の提示は任意の画像に対して可能であり、例えば立体感のないイラスト (素材サイトのイラストを例示) や人以外の顔画像 (Nintendo 社が開発した家庭用ゲームのキャラクターをサンプルとして例示) からでも可能である。特徴量の復元画像及び類似候補の結果を図 8 に示す。復元画像とは、ある画像に対して学習されたモデルに従って次元圧縮を行い、30 次元まで集約した特徴量に対して、その逆変換により 200 * 200 px のデータにすることにより、元画像を復元したものを指す。

4.2 実験の結果

アンケートの結果を図 9 に示す。被験者の内、アルゴリズムによる選びやすさに差があると感じた者の割合は 66.7%であった。Q1 で「3」以上を選んだ被験者 12 名による Q2 の結果を表 2 に示す。良い回答が多かったアルゴリ




図 7 左から順に、入力画像 (input) と、特徴量間の類似度を基に近い順に 3 つ並べたもの。段の違いは特徴量の抽出手法の違いであり、上から元画像, PCA, NMF, AE である。




図 8 上段: イラストからの復元の様子, 中上段: 類似候補, 中下段: 人以外の顔画像からの復元の様子, 下段: 類似候補

ズムは PCA, 悪い回答が多かったアルゴリズムは AE であった。Q3 で「3」以上を選んだ割合は 94.4%であった。Q4 では、「2」以下 (ランダム選択が望ましい) を選んだ者は 7 名, 「4」以上 (画像入力が望ましい) を選んだ者は 9 名であり、後者が多かった。

また、本実験では被験者別に各手法の選択決定までにかかったステップ数および一回あたりの平均選択時間を記録




図 9 アンケート Q1,3,4 の結果




図 10 選択決定までにかかったステップ数 (回)

した (図 10, 11). 最終決定までにかかったステップ数は、最小で 2 回 (システム上の最小), 最大で 5 回, 中央値は 3 回であった. 一回あたりの判断にかかった時間は最小で 0.8 s, 最大で 60.1 s, 中央値は 10.8 s であった. 被験者の傾向として, ステップ数が少なくかつ選択の速い者とならない者がいる一方で, アルゴリズムによるステップ数と選択時間の差はほとんど見られなかった.

さらに, 被験者ごとに「良い」と回答したアルゴリズムと「悪い」と回答したアルゴリズムについて, ステップ数と平均選択時間を記録した (表 3). 「良い」アルゴリズムのステップ数は平均して 2.7 回, 選択平均時間は 11.3 s, 「悪い」アルゴリズムのステップ数は平均して 2.6 回, 選択平均時間は 11.5 s であり, 有意差は無かった.

表 2 アンケート Q2 の結果

method	best	worst
original	3	4
PCA	7	1
NMF	2	2
AE	0	5

表 3 被験者ごとの良いアルゴリズムと悪いアルゴリズムとの比較

method	mean step	mean time(s)	S.D.(s)
best	2.7	11.3	7.1
worst	2.6	11.5	6.5




図 11 一回の選択ごとの平均時間 (s)

5. 考察

5.1 アルゴリズムの評価

システムを体験した被験者の 7 割弱が, アルゴリズムの選びやすさに差を感じた. 推薦アルゴリズムのうち, アンケートで最も評価が高かったものは PCA で, 高い評価が最も多く, 悪い評価は 1 つのみあった. 最も評価が低いのは AE で, 高い評価はなく, 悪い評価が最も多かった. オリジナル (特徴量抽出なし) と NMF は高い評価と低い評価が同程度だった. オリジナルは, 情報量が多い反面, ノイズとなる情報 (顔の位置のズレ, 全体的な明暗) を大きく拾ってしまう一方で, PCA は少数の特徴量を抽出することでそのようなノイズを捨象して頑健性を高めたことが, 高い評価につながったと考えられる.

5.2 PCA と NMF

NMF は, 手法としては PCA に近く, 呈示する類似候補も似通っていたため, 特徴量の分布も極めて近いものだったことがわかる. 各手法について, 30 次元の特徴量を元の画像に復元した物も (図 12) も PCA と NMF のものは酷似している. 両手法によって得られる特徴量を 5 つ抜き出し, それを画像に復元したものを図 13 に示す. 主成分は負の値を含むため, 平均がグレーとなるように調整した.

画像に含まれる各因子が明確な分離構造を持つ場合, PCA 等の教師なし学習によってそれらの要素は明確に分かれる傾向を持つ. PCA と NMF によって得られたデータは, ある程度部位と色の傾向は見取れるが, 各特徴量と実際の画像との明確な対応関係を見出すことは困難であった. NMF によって得られた因子は PC に比べて, 顔の部分は肌色に近くよりまとまっているなど, より解釈しやすい傾向があるが, これら 30 の特徴量により復元される画像の精度に確たる差は見られなかった. これは本研究のデータセットが, 髪型やアングル等において多大なバリエーションを持っているため情報を集約しにくいと推




図 12 左から順に、元画像 (original), PCA, NMF, AE によって抽出された特徴量から画像を復元したもの。




図 13 上段: PCA によって得られた主成分 1~5 を画像に復元したもの。下段: NMF によって得られた因子 1~5 を画像に復元したもの。

測される。より変異の少ない統一されたデータセットを対象にする場合、NMF は画像を少数の因子に圧縮し、なおかつそれを解釈容易なものにする良い手段になると考えられる。

5.3 AE の評価

AE は、本実験では最低の評価となった。本研究の条件では、特徴量の数にあたる潜在変数の次元は、PCA と NMF に合わせて 30 とした。この次元を増やしたり、または隠れ層の数を増やすことによって、また違った結果を得られることが予想される。今回は全結合層によるネットワーク (FNN) を設定したが、畳み込みを用いたネットワーク (CNN) を用いることにより精度を上げられる。また本研究では、実際の Web サイトを対象にその中のデータを推薦するシステムを作るという観点から、データソースは 1,400 枚程度に留まったが、数万枚を超える規模のデータセットの場合、比較結果が異なる可能性もある。

AE のような NN を使う手法は、PCA や AE に比べてかなりの計算量を要する。本実験での条件では、AE の学習は PCA, NMF のそれと比べて 2,000~40,000 倍近い計算時間を要したが、学習パラメータの増加や CNN への変更は、これを更に増大させる。データセットを用意して新たに学習をさせる場合、この差は大きなデメリットとなる。事前に学習を済ませる場合、学習時間の差は問題にならないが、学習結果を利用した復元においても、PCA や NMF の方が高速である。例えばユーザーの入力 (スケッチ等) に合わせてリアルタイムに類似度を計算する場合など、極めて短い計算時間を要する場合、PCA の方が優位であると言える。

5.4 システムの有用性

9 割以上の被験者が、このシステムによって 3D モデルを選びやすくなったと回答していることから、本研究の選択支援システムは確かな効果を持つと推測される。ステップ数は 2 から 5 の範囲内であり、ほとんどの被験者がいずれのアルゴリズムにおいても約 3 ステップで最終的な好みを見つけられた。

初期選択については、ランダム選択の方が良いという被験者と、任意の画像入力の方が良いという被験者に分かれる結果となったが、ユーザの志向 (最初からイメージを持っているか、既存のものから選びたいか) が明確に分かれていることが示唆される。どちらか一方だけで良いという回答 (Q4 で「1」の回答) をした者も少数いたが、全体的には、どちらかが好みだが、補助的にもう片方の選択手法も使いたいという回答が多数派であったため、これら 2 つの選択手法は両方とも必要である。全体的には画像入力を好む回答の方が多かったことから、本研究で提案した手法が、任意の画像から類似画像を推薦する手段として妥当性を持っていると言える。これらの結果から、今後推薦システムを発展させていく場合は任意の画像から何かを推薦していくような機能を中心に進化させていく方向が望ましいと考えられる。

5.5 展望

本研究により、任意の画像から特徴量を効率的に抽出できることがわかったため、それをより発展させてユーザの入力に応じてリアルタイムに候補を変化させていく手法が考えられる。例えば、靴や車といった大量の商品画像についてユーザの入力 (スケッチ) を基にインタラクティブに推薦候補を変化させる Zhu らの研究 [18] があるが、アニメ調の顔についてもこのようなシステムを実装することで、よりユーザのイメージに近い候補を選択しやすくなることが予想される。

推薦の精度も発展の余地がある。例えば、画像を選ぶ際にアイトラッキングの情報を活用した Laohakangvalvit らの研究 [19] もあるが、そのような生体情報も本研究のような推薦システムに活かせる所は多いと考えられる。画面操作においてはマウスポインタの履歴などが付加情報として利用ができる。また、将来的に VR 空間で候補を選ぶシステムを作成する場合、視線のトラッキングだけではなく頭の位置情報・角度のトラッキングもユーザの興味を示す重要な情報になりえる。

また、EC サイトの推薦システムがそうであるように、ユーザの閲覧履歴、属性の付加情報を加味することにより精度の良い推薦ができるであろう。

6. 結論

本研究では、大量のアニメ調のサムネイルから顔画像を

抽出し、それらから機械学習により特徴量を抽出することで、うまく類似候補を呈示できることを、実験を交えて確認した。

特徴量の抽出は、本研究の実験の結果ではPCA, NMF, AEの中でPCAが最も効率的であった。PCAは計算時間も少ないため、大量の顔画像を教師なしで学習する場合において有効な手段となることがわかった。またPCAを用いた特徴量による類似候補は、人間の目から見て選びやすい候補を呈示することも明らかにした。これらのことから、大量のデータをその場で学習する状況、また学習結果を利用してリアルタイムに結果を反映させるような状況において、計算速度の速いPCAは大きなメリットを持つことを示した。

また本研究では、大量の画像データから好みのものを選び出す場合、初期候補から類似候補を示していくシステムを使うことで、選択にかかるユーザの負担を軽減できることを明らかにした。選択の初期候補は、ランダムに選ぶことも任意の画像を入力することもできるが、後者のような場合、データセットから学習されたモデルを使うことで任意の画像から類似候補を呈示できることを示した。

参考文献

- [1] Facebook wants to bring your entire body into virtual reality, 入手先 (<https://edition.cnn.com/2019/05/01/tech/facebook-vr-avatar/index.html>) (参照 2020-02-01).
- [2] Smith, B., & Linden, G. (2017). Two decades of recommender systems at amazon. com. *Ieee internet computing*, 21(3), 12-18.
- [3] Hsu, R. L., Abdel-Mottaleb, M., & Jain, A. K. (2002). Face detection in color images. *IEEE transactions on pattern analysis and machine intelligence*, 24(5), 696-706.
- [4] Lyons, M. J., Budynek, J., & Akamatsu, S. (1999). Automatic classification of single facial images. *IEEE transactions on pattern analysis and machine intelligence*, 21(12), 1357-1362.
- [5] Xiao, T., Hong, J., & Ma, J. (2018). Elegant: Exchanging latent encodings with gan for transferring multiple face attributes. In *Proceedings of the European conference on computer vision (ECCV)* (pp. 168-184).
- [6] Wheeler, F. W., Weiss, R. L., & Tu, P. H. (2010, September). Face recognition at a distance system for surveillance applications. In *2010 Fourth IEEE International Conference on Biometrics: Theory, Applications and Systems (BTAS)* (pp. 1-8). IEEE.
- [7] Takayama, K., Johan, H., & Nishita, T. (2012). Face detection and face recognition of cartoon characters using feature extraction. In *Image, Electronics and Visual Computing Workshop* (p. 48).
- [8] Li, H., & Han, T. (2019). Towards Diverse Anime Face Generation: Active Label Completion and Style Feature Network. In *Eurographics (Short Papers)* (pp. 65-68).
- [9] Lee, D. D., & Seung, H. S. (1999). Learning the parts of objects by non-negative matrix factorization. *Nature*, 401(6755), 788-791.
- [10] Luo, W., Liu, W., & Gao, S. (2017, July). Remembering history with convolutional lstm for anomaly detection. In *2017 IEEE International Conference on Multimedia and Expo (ICME)* (pp. 439-444). IEEE.
- [11] Hinton, G. E., & Zemel, R. S. (1994). Autoencoders, minimum description length and Helmholtz free energy. In *Advances in neural information processing systems* (pp. 3-10).
- [12] Turk, M., & Pentland, A. (1991, January). Face recognition using eigenfaces. In *Proceedings. 1991 IEEE computer society conference on computer vision and pattern recognition* (pp. 586-587).
- [13] BOOTH - 創作物の総合マーケット, 入手先 (<https://booth.pm/ja>) (参照 2020-02-01).
- [14] Open Source Computer Vision Library, 入手先 (<https://github.com/opencv/opencv>) (参照 2020-02-01).
- [15] scikit-learn, Machine Learning in Python, 入手先 (<https://scikit-learn.org/stable/>) (参照 2020-02-01).
- [16] TensorFlow, 入手先 (<https://www.tensorflow.org/>) (参照 2020-02-01).
- [17] A Face detector for anime/manga using OpenCV, 入手先 (https://github.com/nagadomi/lbpcascade_animeface) (参照 2020-02-01).
- [18] Zhu, J. Y., Lee, Y. J., & Efros, A. A. (2014). Average-explorer: Interactive exploration and alignment of visual data collections. *ACM Transactions on Graphics (TOG)*, 33(4), 1-11.
- [19] Laohakangvalvit, T., Iida, I., Charoenpit, S., & Ohkura, M. (2017). A study of Kawaii feeling using eye tracking. *International Journal of Affective Engineering, IJAE-D*.
- [20] Learn OpenCV 入手先 (<https://www.learnopencv.com/eigenface-using-opencv-c-python/>) (参照 2020-02-01).