

# Verifikasi Wajah Menggunakan *Deep Metric Learning* pada Data Wajah dengan Disparitas Umur yang Besar

Syauqi Sabili, Reza Fuad Rachmadi, dan Eko Mulyanto Yuniarno  
Departemen Teknik Komputer, Institut Teknologi Sepuluh Nopember (ITS)  
E-mail: fuad@te.its.ac.id

**Abstrak**—Penuaan wajah merupakan proses biologi yang kompleks yang ditandai dengan adanya perubahan fisik yang terjadi pada wajah, seperti perubahan warna kulit, adanya bercak hitam, timbulnya kerutan dan sebagainya seiring bertambahnya usia. Penuaan wajah menjadi salah satu faktor penting dalam proses pengenalan wajah atau biasa disebut dengan istilah *face recognition*. Untuk mengatasi hal ini, dibutuhkan suatu metode pengenalan atau verifikasi wajah yang dapat mengenali individu yang sama dengan perbedaan usia. Di tugas akhir ini digunakan sebuah metode bernama *Deep Metric Learning* yang menggabungkan *Deep Learning* dan *Metric Learning*. Sistem dibangun dengan menggunakan arsitektur *Siamese Neural Network* yang mengandung dua masukkan citra. Kedua citra ini terdiri dari foto wajah seseorang ketika masih muda (kanak-aknak atau remaja) dan dewasa. Sistem akan melakukan serangkaian proses verifikasi. Pada bagian akhir, kedua citra diprediksi apakah berasal dari individu yang sama atau tidak. Luaran dari sistem ini adalah skor kemiripan (*similarity score*) yang nantinya ditentukan batasan (*threshold*) terlebih dahulu agar bisa mendapatkan hasil akhir sebenarnya. Hasil prediksi direpresentasikan sebagai nilai biner, yaitu 0 bernilai salah dan 1 bernilai benar.

**Kata Kunci**—Penuaan Wajah, Pengenalan Wajah, *Deep Metric Learning*, *Siamese Neural Network*, *Deep Learning*.

## I. PENDAHULUAN

PENGENALAN wajah atau biasa dikenal dengan istilah *face recognition* merupakan topik yang menarik di bidang visi komputer. Teknologi ini biasanya diterapkan pada suatu sistem pengamanan dimana data wajah dijadikan sebagai kepemilikan akses dari sistem tersebut. Pengembangan teknologi ini terus dilakukan terutama mengenai akurasi dan kecepatan dalam pengenalan pola wajah. Terdapat 4 faktor yang mempengaruhi akurasi dalam pengenalan wajah seseorang, yaitu ekspresi wajah, pencahayaan, penuaan pada wajah, dan penempatan media dalam mengakuisisi citra [1].

Manusia normal akan mengalami pertumbuhan semasa hidupnya. Pertumbuhan manusia ditandai dengan adanya perubahan fisik pada manusia itu sendiri seperti bertambah besar atau tinggi, perubahan warna kulit, penuaan pada wajah, dan lain-lain. Perubahan fisik tersebut terjadi seiring bertambahnya usia dan kerena proses biologis. Selain dari pertumbuhan badan manusia, perubahan yang paling disadari yaitu perubahan pada wajah atau biasa disebut sebagai penuaan wajah yang juga merupakan faktor dalam mempengaruhi proses pengenalan wajah seseorang. Penelitian ini berfokus pada verifikasi wajah dengan perbedaan umur yang besar.

Salah satu kasus terjadi di China, seorang pria menjadi korban penculikan ketika berusia 2 tahun saat ayahnya

sedang tidak fokus menjaganya di luar. Hingga akhirnya 32 tahun kemudian, pria tersebut berhasil dipertemukan kembali dengan keluarganya karena menggunakan teknologi *face recognition*. Otoritas China membuat gambar tiruan dari pria tersebut ketika dewasa berdasarkan foto yang telah dikumpulkan dari orang tuanya sewaktu pria tersebut masih kanak-kanak.

Penelitian dilakukan dengan menggunakan metode *Deep Metric Learning* yang merupakan gabungan dari *Deep Learning* dan *Metric Learning* [2]. *Deep Learning* memiliki struktur *non-linear* yang menggunakan informasi label pada data untuk melakukan proses *training*, sedangkan *Metric Learning* memiliki struktur *linear* yang tidak menggunakan informasi label dalam proses *training* melainkan menghasilkan suatu nilai atau jarak (batasan) yang nantinya digunakan untuk mengukur kesamaan atau ketidaksamaan pada label tersebut pada proses testing. *Deep Metric Learning* berbasis pada prinsip nilai kemiripan antara sampel.


Beberapa penelitian sudah dilakukan terkait verifikasi wajah dengan perbedaan usia yang besar. Pada tahun 2016, penelitian yang dilakukan oleh Luoqi Liu, Chao Xiong, Hanwang Zhang, Zhiheng Niu, Meng Wang, dan Shuicheng Yan yang bertujuan untuk melakukan verifikasi wajah dengan sebuah framework yang bernama *Deep Aging Face Verification* (DAFV) [3]. DAFV terdiri dari dua modul atau tahap, yaitu *aging pattern synthesis* dan *aging face verification*.

Pada tahun 2017 dilakukan juga penelitian oleh Simone Bianco dari Department of Informatics, Systems and Communication (DISCo), University of Milan-Bicocca yang bertujuan memperkenalkan suatu metode dalam verifikasi wajah dengan perbedaan umur yang besar (*large age gaps*). Metode yang dikenalkan bernama *Deep Convolutional Ceural Network* (DCNN) [4]. Di tahun 2020 metode bernama *Multi-Task Deep Metric Learning with Boundary Discriminative* atau disingkat MDML-BDI diusulkan oleh Tongguang Ni, Xiaoqing Gu, Cong Zhang, Weibo Wang, dan Yiqing Fan. Metode ini sudah diimplementasikan pada dataset seperti FG-NET, CACD-VS dan CALFW [5].

## II. DESAIN DAN IMPLEMENTASI

Penelitian ini dilaksanakan sesuai dengan desain sistem berikut dengan implementasinya. Desain sistem merupakan konsep dari pembuatan dan perancangan infrastruktur kemudian diwujudkan dalam bentuk blok-blok alur yang harus dikerjakan.


Pada bagian implementasi merupakan pelaksanaan teknis untuk setiap blok pada desain sistem.



Gambar 1. Blok diagram kerja sistem.



Gambar 2. Beberapa contoh pasangan wajah dari lag database.



Gambar 3. Alur *preprocessing* menggunakan MTCNN.

**A. Desain Sistem**

Penelitian ini bertujuan untuk melakukan verifikasi wajah menggunakan *deep metric learning*. Sistem ini dibangun berdasarkan dua input citra wajah dengan perbedaan umur yang besar. Citra wajah didapat dari *Large Age-Gap Database* pada laman <http://www.ivl.disco.unimib.it/>. Gambar 1 yang menunjukkan blok diagram kerja sistem.

Dari Gambar 1, dapat dilihat bahwa desain kerja sistem dalam pengerjaan penelitian ini dimulai dengan pengambilan *dataset* citra wajah dengan perbedaan umur yang besar (*LAG database*) yang kemudian dilakukan pra-pemrosesan berupa ekstraksi wajah dengan menggunakan *Multi-task Cascaded*


*Convolutional Neural Networks* (MTCNN). Data wajah yang telah melewati tahap pra-pemrosesan akan dibagi menjadi tiga subset yaitu data untuk *training*, *validation*, dan *testing* dengan pemberian persentase untuk masing-masing subset. Setelah itu, data *training* dan *validation* akan dibuat menjadi pasangan citra yang terdiri dari citra wajah seseorang ketika masih muda (kanak-kanak atau remaja) dan Ketika dewasa, lalu dilatih untuk menghasilkan suatu model.

**B. Dataset**

*Dataset* yang digunakan dalam proses penelitian ini yaitu *Large Age-Gap Database*. *Database* ini terdiri dari 1010 selebriti (kelas) yang berisi 3828 citra wajah (Gambar 2).



Gambar 4. Beberapa contoh dari pembuatan pasangan citra.



Gambar 5. Susunan arsitektur pada metode *deep metric learning*.

Setiap kelas disusun atas dua folder, yaitu *folder* pertama berisi satu atau lebih citra wajah ketika masih muda (kanak-kanak atau remaja) dan *folder* kedua berisi satu atau lebih citra wajah ketika dewasa. Dengan ini, setiap kelas memiliki perbedaan jumlah citra terhadap kelas lainnya. Resolusi citra pada *dataset* ini tersedia dua pilihan, yaitu berukuran 100x100 dan 200x200. Gambar 2 merupakan beberapa contoh pasangan wajah dengan perbedaan usia dari *Large Age-Gap Database*.

C. *Preprocessing*

Tahap ini merupakan pemrosesan awal agar *dataset* siap digunakan pada tahap selanjutnya. Proses ini berjalan dengan melakukan ekstraksi wajah pada citra menggunakan *Multi-task Cascaded Convolutional Neural Networks* (MTCNN). MTCNN digunakan untuk mendeteksi wajah dan membuat *landmark* pada citra wajah. MTCNN dipublikasikan pada tahun 2016 oleh Zhang et Al [6]. Metode ini sangat populer dan akurat dalam mendeteksi wajah. Gambar 3 menjelaskan bagaimana *Preprocessing* berjalan.

*Dataset* yang sudah dikumpulkan dilakukan deteksi wajah pada citra dengan menggambarkan *bounding box* di sekitar wajah dengan menggunakan MTCNN. Setelah itu, citra baru dihasilkan dari proses ekstraksi wajah pada *bounding box* yang digambarkan saat proses sebelumnya. Proses ini bertujuan untuk menghilangkan informasi yang tidak penting pada citra dalam proses *training*, *validation*, dan *testing*.

D. *Pembagian Dataset*

*Dataset* terlebih dahulu dibagi menjadi tiga subset yaitu data untuk *training set*, *validation set*, dan *testing set* seperti di bawah ini.

1) *Training set*

*Training set* merupakan bagian dari *dataset* yang digunakan pada proses *training* untuk melatih model dari sebuah algoritma *Machine Learning*. Pada penelitian ini, persentase yang digunakan pada *training set*, yaitu 85%.

2) *Validation set*

*Validation set* merupakan bagian dari *training set* yang digunakan pada pengujian tahap awal. Pada penelitian ini, persentase yang digunakan pada *validation set*, yaitu 10%.

3) *Testing set*

*Testing set* merupakan bagian dari *dataset* yang digunakan pada proses *testing* untuk menguji sebuah model. Pada tugas akhir ini, persentase yang digunakan pada *testing set*, yaitu 5%.

Pembagian *dataset* pada penelitian ini dilakukan berdasarkan kelas *dataset*. Dimana setiap kelas memiliki dua *folder* yang masing-masing *folder* berisi satu atau beberapa citra ketika muda ataupun tua. Setelah itu, *subset* pada *validation* menyalin sebesar 20% dari *subset training*. Tujuan dilakukannya ini, yaitu untuk menghindari *overfitting* pada

Tabel 1.

Pembagian data untuk *subset training, validation, dan testing*

Subset	Jumlah Kelas
Training	857
Validation	101+172
Testing	52

Tabel 2.

Pembagian pasangan citra untuk *subset training, validation, dan testing*

Subset	Jumlah Pasangan Citra
Training	8460
Validation	2640
Testing	438

Tabel 3.

Spesifikasi komputer pribadi

Spesifikasi	Keterangan
Processor	Intel(R) Core (TM) i5-2430M CPU @ 2.40GHz
RAM	4 GB SODIMM DDR3
Storage	HDD 596 GB
Graphic Card	NVIDIA GeForce GT 540M 2GB
Operating System	Windows 10 Pro 64-bit

Tabel 4.

Spesifikasi google colab

Spesifikasi	Keterangan
Processor	Intel(R) Core (TM) Xeon CPU @ 2.20GHz
RAM	13 GB
Storage	15 GB
Graphic Card	Tesla T4

proses *training*. Tabel 1 yang menunjukkan hasil akhir dari pembagian *dataset*.

### E. Pasangan Citra

Pembuatan pasangan citra dilakukan setelah pembagian *dataset*. Pasangan citra terdiri dari citra wajah seseorang ketika masih muda (kanak-kanak atau remaja) dan ketika dewasa. Kedua citra ini memiliki perbedaan umur yang relatif besar. Pembuatan pasangan citra dilakukan secara acak dimana salah satu citra dari suatu kelas dipasangkan dengan citra yang serupa (berlabel benar) dan tidak serupa (berlabel salah) seperti pada Gambar 4 yang menunjukkan contoh beberapa hasil pasangan citra beserta labelnya.

Hasil dari pembuatan pasangan citra berjumlah 11718 pasang citra wajah. Tabel 2 yang menunjukkan jumlah pasang citra wajah yang berdasarkan pembagian tiga subset.

### F. Arsitektur

Arsitektur pada tugas akhir ini dirancang dengan dua masukkan citra wajah yang setelah itu akan melalui proses *data augmentation* atau biasa disebut dengan *preprocessing layer* yang terdiri dari tahap *scaling, rotation, dan flip*. Proses selanjutnya, masukkan akan masuk ke dalam sebuah model yang disebut sebagai *base model*.

Beberapa *base model* yang digunakan pada tugas akhir ini, yaitu InceptionV3, ResNet50V2, VGG19, dan Xception [7-10]. Keempat *base model* tersebut merupakan beberapa contoh model dari sekian banyak model yang disediakan oleh

Tabel 5.

Spesifikasi *large age-gap database*

Spesifikasi	Keterangan
Nama	Large Age-Gap Database
Pengembang	Simone Bianco
Jumlah Kelas	1010
Jumlah Citra	3828

Tabel 6.

Hasil *training dan validation* menggunakan *deep metric learning*

Base Model	Akurasi		Loss	
	Training	Validation	Training	Validation
InceptionV3	62.96%	61.40%	0.64	0.65
ResNet50V2	64.26%	62.73%	0.62	0.63
VGG19	65.40%	60.91%	0.62	0.65
Xception	67.60%	64.36%	0.59	0.62

Tabel 7.

Hasil *training dan validation* menggunakan *deep learning*

Base Model	Akurasi		Loss	
	Training	Validation	Training	Validation
InceptionV3	62.48%	60.95%	0.64	0.64
ResNet50V2	65.30%	63.75%	0.61	0.62
VGG19	62.62%	61.97%	0.63	0.64
Xception	63.33%	63.45%	0.63	0.64

Tabel 8.

Hasil *testing* menggunakan *deep metric learning*

Base Model	Recall	Precision	F1-Score	Accuracy
InceptionV3	60%	65%	62%	63%
ResNet50V2	71%	62%	66%	64%
VGG19	57%	60%	58%	60%
Xception	70%	65%	67%	66%

Tabel 9.

Hasil *testing* menggunakan *deep learning*

Base Model	Recall	Precision	F1-Score	Accuracy
InceptionV3	60%	71%	65%	68%
ResNet50V2	69%	67%	68%	68%
VGG19	67%	56%	61%	57%
Xception	86%	67%	75%	71%

Keras pada bagian Keras *Applications*. Gambar 5 merupakan susunan arsitektur sistem dengan menggunakan metode *deep metric learning*.

Penerapan metode *deep metric learning*, arsitektur disusun menggunakan *Siamese Neural Network* yang memiliki dua masukkan (sub-jaringan) identik yang hanya menggunakan sedikit *layer* setelah *base model*. Setelah proses yang terjadi pada sub-jaringan adalah proses penggabungan dua sub-jaringan menjadi satu jaringan.

Nilai dari proses akhir sub-jaringan pertama dan kedua menjadi masukkan dalam perhitungan jarak (*metric learning*). *Metric learning* yang digunakan dalam proses penggabungan sub-jaringan, yaitu dengan menggunakan formula *euclidean distance* seperti pada persamaan berikut.

$$d = \sqrt{(Sn_1 - Sn_2)^2}$$

### G. Training

Sebelum melakukan proses *training*, perlu dilakukan penentuan jumlah *batch size* dan *epoch*. Sedangkan jumlah *iteration* tidak ditetukan, melainkan tergantung dari jumlah *batch size* dan data *training*. Berikut adalah penjelasan

Tabel 10.

Hasil *testing* menggunakan citra *grayscale* pada *deep metric learning*

Base Model	Recall	Precision	F1-Score	Accuracy
InceptionV3	83%	58%	68%	62%
ResNet50V2	63%	56%	59%	57%
VGG19	41%	51%	46%	51%
Xception	69%	55%	61%	56%

masing-masing parameter yang ditentukan sebelum proses *training*.

#### 1) Batch size

*Batch size* merupakan jumlah sampel yang disebar ke *neural network* dalam sekali iterasi. Pada proses *training*, penentuan *batch size* sebesar 64.

#### 2) Iteration

*Iteration* merupakan jumlah *batch* yang diperlukan untuk menyelesaikan satu *epoch*.

#### 3) Epoch

*Epoch* merupakan suatu ketika seluruh dataset sudah melewati proses *training* pada *neural network* sampai dikembalikan ke awal (*Backpropagation*) untuk sekali putaran. Beberapa *epoch* diperlukan pada proses *training* agar mendapatkan kesalahan (*loss*) minimum. Pada proses ini, *epoch* yang digunakan sebanyak 50 kali.

Pada proses *training* ditambahkan fungsi *callback*, yaitu *ReduceLROnPlateau*. *Callback* ini berfungsi untuk mengurangi *learning rate* ketika sebuah *metric* yang sedang dimonitor berhenti melakukan perubahan (perbaikan) menuju yang lebih baik.

### H. Validation

*Validation* merupakan suatu proses yang berjalan bersamaan dengan proses *training*. *Validation* dilakukan untuk mencegah *overfitting* pada model. *Training* dan *validation* dilakukan secara berurutan setiap *epoch*.

### I. Testing

Setelah proses *training* dan *validation* dilakukan, proses selanjutnya adalah *testing*. Proses ini merupakan suatu proses apa yang diharapkan dari arsitektur yang telah dibuat dengan melakukan analisa performa. Analisa performa akan digunakan beberapa seperti *Confusion Matrix* agar dapat memetakan berdasarkan pengelompokan data prediksi menjadi *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN). Selain itu terdapat parameter lain, seperti *Accuracy*, *Recall*, *Precision*, dan *F1-Score*.

## III. PENGUJIAN DAN ANALISA

Pada bab ini dipaparkan hasil pengujian serta analisa dari desain sistem dan implementasi. Pengujian dilakukan guna mengetahui tingkat kesalahan dan menarik kesimpulan dari sistem yang telah dibuat. Penelitian ini menggunakan komputer pribadi dan komputer (*machine*) milik Google yang bernama Google Colab dengan spesifikasi seperti pada Tabel 3 dan Tabel 4.

### A. Hasil Pengambilan Dataset

*Dataset* yang digunakan dalam proses pengerjaan tugas akhir ini yaitu *Large Age-Gap database*. Database ini terdiri

Tabel 11.

Hasil *testing* menggunakan *dataset* di luar *large age-gap database* pada *deep metric learning*

Base Model	Recall	Precision	F1-Score	Accuracy
InceptionV3	60%	71%	65%	68%
ResNet50V2	69%	67%	68%	68%
VGG19	67%	56%	61%	57%
Xception	86%	67%	75%	71%

dari 1010 selebriti (kelas) yang berisi 3828 citra wajah. Setiap kelas berisi satu atau lebih citra wajah ketika masih muda (kanak-kanak atau remaja) dan satu atau lebih citra wajah ketika dewasa. Dengan ini, setiap kelas memiliki perbedaan jumlah citra dengan kelas lainnya. Tabel 5 adalah spesifikasi dari *dataset* yang digunakan pada penelitian ini.

Setelah *dataset* dikumpulkan, *dataset* akan melalui tahap deteksi dan ekstraksi wajah. Ekstraksi wajah bertujuan untuk menghilangkan informasi yang tidak dibutuhkan. Beberapa informasi yang tidak dibutuhkan seperti latar belakang citra, pakaian yang digunakan, dan daerah lain yang berada diluar wajah yang sekiranya dapat mengganggu proses *training*, *validation*, dan *testing*. Setelah itu, pembuatan pasangan citra yang terdiri dari label *true* dan *false* yang direpresentasikan sebagai nilai biner 1 dan 0. Pembuatan pasangan citra menghasilkan tiga *subset training*, *validation*, dan *testing* menjadi lebih banyak dengan total subset sebesar 11594 pasang citra.

### B. Hasil Training dan Validation

Proses *training* dan *validation* yang dilakukan dalam penelitian ini menggunakan *batch size* sebanyak 64 dan *epoch* sebanyak 50. Proses *training* dan *validation* dilakukan sebanyak delapan kali. Dimana pengujian ini dilakukan dengan penerapan metode *Deep Metric Learning* dan *Deep Learning* yang keduanya menggunakan *base model* InceptionV3, ResNet50V2, VGG19, dan Xception.

#### 1) Deep Metric Learning

Pada penerapan *deep metric learning*, terdapat *metric learning* pada arsitekturnya. *Metric learning* terletak diawal ketika penggabungan kedua sub-jaringan. *Metric learning* disini bertugas untuk mengukur suatu nilai kemiripan dari kedua sub jaringan yang nantinya akan menentukan apakah kedua citra yang menjadi masukkan berasal dari individu yang sama. Tabel 6 yang menyajikan hasil *training dan validation* menggunakan *Deep Metric Learning*.

#### 2) Deep Learning

Selain *Deep Metric Learning*, penerapan *Deep Learning* juga dilakukan sebagai pembanding metode. *Deep learning* tidak menambahkan unsur *Metric Learning* pada susunan arsitekturnya, melainkan menggunakan *concat*. Tabel 7 yang menyajikan hasil *training dan validation* menggunakan *Deep Metric Learning*.

### C. Hasil Testing

Proses *testing* dilakukan dengan menggunakan hasil bobot dari proses *training* pada tahap pengujian sebelumnya. Data *testing* yang digunakan berjumlah 438 pasangan citra. Sebelum proses *testing* dimulai, terlebih dahulu menentukan batasan (*threshold*) karena hasil dari prediksi berupa angka antara 0 sampai 1. Untuk merepresentasikan menjadi nilai biner (0 dan 1), perlu diberi nilai batasan. Batasan yang

digunakan pada pengujian ini yaitu 0.5 karena nilai ini paling umum digunakan. Sama halnya dengan proses *training* dan *validation*, pengujian ini dilakukan dengan penerapan metode *deep metric learning* dan *deep learning*. Tabel 8 dan Tabel 9 yang menyajikan hasil *testing* menggunakan *Deep Metric Learning* dan *Deep Learning*.

#### D. Hasil Testing Menggunakan Citra Grayscale

Berbeda dengan pengujian sebelumnya, pengujian ini melibatkan proses konversi citra yang awalnya RGB menjadi citra *grayscale*. Karena *input* dari keempat model ini diharuskan memiliki tiga *channel* layaknya RGB, sedangkan citra *grayscale* hanya memiliki satu *channel*. Setelah dikonversi, citra *grayscale* akan ditumpuk (*stacked*) sebanyak tiga buah supaya memenuhi syarat sebagai input model-model tersebut. Tabel 10 adalah hasil dari pengujian ini yang menggunakan citra *grayscale* pada *Deep Metric Learning*.

#### E. Hasil Testing Menggunakan Dataset di luar Large Age (LAG) Database

Pengujian ini dilakukan dengan menggunakan *dataset* yang Sebagian berasal dari foto kerabat penulis dan *Cross Age Labeled Faces in the Wild (CALFW) database* [11]. *Dataset* ini terdiri 84 pasang citra yang berisi orang-orang keturunan arab (timur tengah), asia, dan orang berkulit hitam. Tabel 11 adalah hasil dari pengujian menggunakan *dataset* ini pada *Deep Metric Learning*.

## IV. KESIMPULAN

Penelitian ini dilakukan verifikasi wajah dengan disparitas umur yang besar dengan menggunakan metode *Deep Metric Learning* dan arsitektur *Siamese Neural Network*. Sistem terdiri dari dua masukkan citra dimana kedua citra ini merupakan foto wajah seseorang ketika masih muda (kanak-kanak atau remaja) dan dewasa. Sistem akan melakukan serangkaian proses verifikasi dengan hasil akhir direpresentasikan sebagai nilai biner, yaitu 0 (salah) dan 1 (benar). Dari hasil pengujian yang dilakukan pada bab

sebelumnya, didapatkan beberapa kesimpulan sebagai berikut: (1) Berdasarkan grafik akurasi dan *loss* dari hasil *training* dan *validation*, model yang telah dibuat mengalami *overfitting*, yaitu keadaan dimana data yang digunakan dalam proses *training* adalah yang terbaik. (2) Dari keempat model (InceptionV3, ResNet50V2, VGG19, dan Xception) yang digunakan pada penelitian ini, didapatkan nilai akurasi terbaik dari proses *testing*, yaitu pada model Xception. (3) Hasil *testing* yang menggunakan *dataset* RGB (tidak dikonversi menjadi *grayscale*) lebih baik dibanding dengan *dataset grayscale*.

## DAFTAR PUSTAKA

- [1] A. K. Jain, B. Klare, and U. Park, "Face matching and retrieval in forensics applications," *IEEE Multimed.*, vol. 19, no. 1, p. 20, 2012.
- [2] J. Lu, J. Hu, and J. Zhou, "Deep metric learning for visual understanding: An overview of recent advances," *IEEE Signal Process. Mag.*, vol. 34, no. 6, pp. 76–84, 2017.
- [3] L. Liu, C. Xiong, H. Zhang, Z. Niu, M. Wang, and S. Yan, "Deep aging face verification with large gaps," *IEEE Trans. Multimed.*, vol. 18, no. 1, pp. 64–75, 2015.
- [4] S. Bianco, "Large age-gap face verification by feature injection in deep networks," *Pattern Recognit. Lett.*, vol. 90, pp. 36–42, 2017.
- [5] T. Ni, X. Gu, C. Zhang, W. Wang, and Y. Fan, "Multi-task deep metric learning with boundary discriminative information for cross-age face verification," *J. Grid Comput.*, vol. 18, no. 2, pp. 197–210, 2020.
- [6] K. Zhang, Z. Zhang, Z. Li, and Y. Qiao, "Joint face detection and alignment using multitask cascaded convolutional networks," *IEEE Signal Process. Lett.*, vol. 23, no. 10, pp. 1499–1503, 2016.
- [7] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 2818–2826.
- [8] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [9] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," in *The International Conference on Learning Representations*, 2015, pp. 1–14.
- [10] F. Chollet, "Xception: Deep Learning with Depthwise Separable Convolutions," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 1251–1258.
- [11] T. Zheng, W. Deng, and J. Hu, "Cross-Age lfw: A Database for Studying Cross-Age Face Recognition in Unconstrained Environments," in *The International Conference on Learning Representations*, 2017, pp. 1–10.