

Deskripsi Teknis : Model Deteksi Wajah
dengan Cascade Classifier dan
Rekonstruksi **Multi-Stage Fast Super-
Resolution Convolutional Neural Network**
(FSRCNN)

AUTHOR :

TOMMY

ROSYIDAH SIREGAR

EDY RAHMAN SYAHPUTRA

Judul Invensi:

Model Deteksi Wajah dengan Cascade Classifier dan Rekonstruksi Multi-Stage Fast Super-Resolution Convolutional Neural Network (FSRCNN)

Latar Belakang Invensi:

Deteksi wajah pada citra resolusi rendah, seperti pada rekaman CCTV, seringkali terhambat oleh keterbatasan kualitas citra, noise, dan variasi pencahayaan. Hal ini mengakibatkan kesulitan dalam identifikasi dan pengenalan wajah yang andal. Teknologi yang ada saat ini sering kali tidak memadai untuk memberikan akurasi deteksi dan rekonstruksi yang memuaskan. Oleh karena itu, diperlukan suatu metode yang mampu meningkatkan kualitas deteksi dan rekonstruksi wajah pada citra resolusi rendah.

Tujuan Invensi:

Tujuan dari invensi ini adalah untuk menyediakan suatu metode yang menggabungkan deteksi wajah dengan Cascade Classifier dan rekonstruksi wajah secara bertahap menggunakan multi-stage FSRCNN, guna meningkatkan akurasi deteksi wajah pada citra beresolusi rendah.

Ruang Lingkup Invensi:

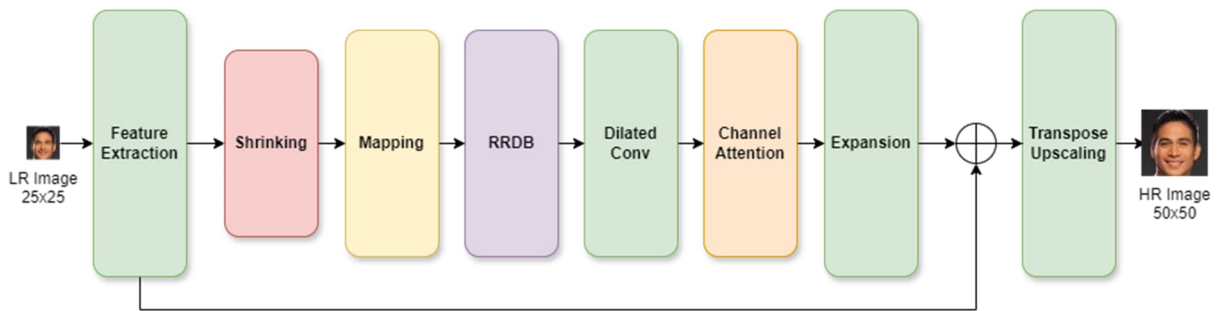
Invensi ini mencakup teknik deteksi dan rekonstruksi wajah yang terdiri dari dua komponen utama:

1. Cascade Classifier untuk deteksi ROI (Region of Interest) wajah pada citra resolusi rendah.
2. Multi-Stage FSRCNN untuk rekonstruksi ROI wajah yang telah terdeteksi secara bertahap hingga mencapai resolusi yang lebih tinggi dan lebih jelas.

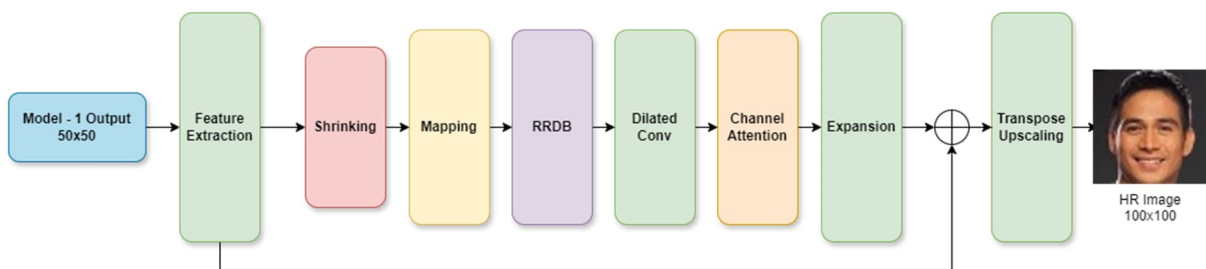
Detail Invensi:

1. Metode Deteksi Wajah Menggunakan Cascade Classifier:
 - o Cascade Classifier dirancang dan dilatih menggunakan data wajah yang diperoleh dari rekaman CCTV dan dataset wajah standar seperti CelebA.
 - o Proses pelatihan melibatkan data wajah dari berbagai kondisi pencahayaan (pagi, siang, sore) dan lokasi pengawasan yang spesifik (gerbang masuk).
 - o Classifier ini digunakan untuk mendeteksi ROI yang berpotensi mengandung wajah pada citra resolusi rendah.
2. **Metode Rekonstruksi Wajah Menggunakan Multi-Stage FSRCNN:**
 - o Tahap Pertama: FSRCNN digunakan untuk meningkatkan resolusi ROI wajah dari 25x25 piksel menjadi 50x50 piksel. Model FSRCNN tahap pertama memiliki arsitektur yang terdiri dari lapisan konvolusi untuk ekstraksi fitur, shrinking, mapping dengan residual blocks, dan ekspansi.
 - o Tahap Kedua: Hasil rekonstruksi dari tahap pertama digunakan sebagai input untuk tahap kedua, di mana ROI ditingkatkan dari 50x50 piksel menjadi 100x100 piksel. Proses ini melibatkan integrasi residual dari tahap pertama untuk mempertajam detail wajah.

- o FSRCNN ini dirancang untuk efisiensi komputasi dan memanfaatkan sisa rekonstruksi (residual) untuk mengoptimalkan hasil akhir.



Gambar 1. Arsitektur Model Tahap Pertama



Gambar 2. Arsitektur Model Tahap Kedua

Tabel 1. Spesifikasi Model Tahap Pertama

Layer Type	Details
Input Layer	Shape: (25, 25, 3)
Feature Extraction	1. SeparableConv2D: 64 filters, (3x3), ReLU, padding='same' 2. SeparableConv2D: 128 filters, (3x3), ReLU, padding='same' 3. BatchNormalization
Shrinking	1. SeparableConv2D: 64 filters, (3x3), ReLU, padding='same' 2. SeparableConv2D: 32 filters, (3x3), ReLU, padding='same' 3. BatchNormalization
Mapping with Dilated Conv	4. Dropout: 0.2 1. SeparableConv2D: 64 filters, (3x3), ReLU, padding='same', dilation_rate=2 2. BatchNormalization 3. Dropout: 0.2 4. SeparableConv2D: 64 filters, (3x3), ReLU, padding='same', dilation_rate=2 5. BatchNormalization 6. Dropout: 0.2
Residual Blocks (RRDB)	4 Residual-in-Residual Dense Blocks with 64 filters
Delay Layer	Delay: 0.3 seconds
Additional Dilated Convs	4 SeparableConv2D layers: 64 filters, (3x3), ReLU, padding='same', dilation_rate=2

	BatchNormalization
	Dropout: 0.3
Channel Attention (SE Block)	1. GlobalAveragePooling2D
	2. Dense: 64 units, ReLU
	3. Dense: 64 units, Sigmoid
	4. Multiply
Expansion	1. SeparableConv2D: 16 filters, (3x3), ReLU, padding='same'
	2. SeparableConv2D: 32 filters, (3x3), ReLU, padding='same'
	3. SeparableConv2D: 64 filters, (3x3), ReLU, padding='same'
	4. SeparableConv2D: 128 filters, (3x3), ReLU, padding='same'
	5. Add (Skip connection with input features)
Upscaling (Deconvolution)	Conv2DTranspose: 3 filters, (6x6), strides=(2,2), padding='same'
Output Layer	Output Shape: (50, 50, 3)

Tabel 2. Spesifikasi Model Tahap Kedua

Layer Type	Details
Input Layer	Shape: (50, 50, 3)
Feature Extraction	1. SeparableConv2D: 128 filters, (5x5), ReLU, padding='same'
	2. SeparableConv2D: 128 filters, (5x5), ReLU, padding='same'
	3. BatchNormalization
Shrinking	1. SeparableConv2D: 128 filters, (5x5), ReLU, padding='same'
	2. SeparableConv2D: 64 filters, (5x5), ReLU, padding='same'
	3. BatchNormalization
	4. Dropout: 0.2
Mapping with Dilated Conv	1. SeparableConv2D: 64 filters, (5x5), ReLU, padding='same', dilation_rate=2
	2. BatchNormalization
	3. Dropout: 0.2
	4. SeparableConv2D: 128 filters, (5x5), ReLU, padding='same', dilation_rate=2
	5. BatchNormalization
	6. Dropout: 0.2
	7. SeparableConv2D: 128 filters, (5x5), ReLU, padding='same', dilation_rate=2
	8. BatchNormalization
	9. Dropout: 0.2
	10. SeparableConv2D: 64 filters, (5x5), ReLU, padding='same', dilation_rate=2
	11. BatchNormalization
	12. Dropout: 0.2
Residual Blocks (RRDB)	8 Residual-in-Residual Dense Blocks with 64 filters
Delay Layer	Delay: 0.5 seconds
Additional Dilated Convs	8 SeparableConv2D layers: 64 filters, (5x5), ReLU, padding='same', dilation_rate=2
	BatchNormalization
	Dropout: 0.3

Channel Attention (SE Block)	1. GlobalAveragePooling2D
	2. Dense: 64 units, ReLU
	3. Dense: 64 units, Sigmoid
	4. Multiply
Expansion	1. SeparableConv2D: 64 filters, (5x5), ReLU, padding='same'
	2. SeparableConv2D: 80 filters, (5x5), ReLU, padding='same'
	3. SeparableConv2D: 96 filters, (5x5), ReLU, padding='same'
	4. SeparableConv2D: 102 filters, (5x5), ReLU, padding='same'
	5. SeparableConv2D: 128 filters, (5x5), ReLU, padding='same'
	6. Add (Skip connection with input features)
Upscaling (Deconvolution)	Conv2DTranspose: 3 filters, (10x10), strides=(2,2), padding='same'
Output Layer	Output Shape: (100, 100, 3)

3. Proses Validasi ROI Wajah:

- Untuk memastikan keakuratan deteksi dan rekonstruksi, ROI yang telah direkonstruksi divalidasi menggunakan dua pendekatan:
 - Validasi dengan FSRCNN: ROI yang direkonstruksi ke resolusi 100x100 piksel diperiksa secara visual untuk mengevaluasi akurasi deteksi wajah.
 - Validasi dengan Dlib: Dlib digunakan sebagai alat validasi tambahan untuk memastikan bahwa area ROI merupakan wajah yang valid.



Gambar 3. Sample Pengujian Model

Spesifikasi Lingkungan dan Implementasi:

- Bahasa Pemrograman: Python 3.x
- Library Utama:
 - OpenCV: Digunakan untuk pengolahan gambar, deteksi wajah dengan Cascade Classifier, dan manipulasi ROI.
 - TensorFlow (Versi 2.13.0): Digunakan untuk membangun dan melatih model FSRCNN multi-stage. Versi ini dipilih karena dukungannya terhadap model deep learning modern dan efisiensi komputasi.

- NumPy: Digunakan untuk manipulasi array dan operasi matematika yang diperlukan dalam pengolahan data gambar.
- Dlib: Digunakan untuk validasi deteksi wajah pada tahap akhir dengan memanfaatkan algoritma deteksi wajah tambahan.
- Matplotlib: Digunakan untuk visualisasi hasil deteksi dan rekonstruksi sebagai bagian dari evaluasi kinerja model.
- Lingkungan Pengembangan:
 - Sistem operasi: Windows
 - Platform: Python environment yang diatur menggunakan virtual environment (venv) atau conda untuk pengelolaan dependensi.
 - Hardware: Model ini dapat berjalan pada CPU, tetapi untuk efisiensi, disarankan menggunakan GPU dengan CUDA support untuk mempercepat proses pelatihan dan inferensi model.
- Dataset yang Digunakan:
 - CCTV Footage: Digunakan untuk melatih Cascade Classifier dengan berbagai kondisi pencahayaan dan lokasi pengambilan yang spesifik.
 - CelebA: Digunakan sebagai data pelatihan FSRCNN untuk meningkatkan resolusi wajah dari ROI yang terdeteksi.
 -

Keunggulan Invensi:

- Peningkatan Deteksi pada Resolusi Rendah: Menggunakan Cascade Classifier yang terlatih khusus pada kondisi rekaman CCTV, invensi ini mampu mendeteksi wajah dengan lebih baik dibandingkan teknik konvensional.
- Rekonstruksi Bertahap yang Terintegrasi: Proses rekonstruksi menggunakan multi-stage FSRCNN memungkinkan peningkatan resolusi wajah secara bertahap, sehingga menghasilkan citra wajah yang lebih tajam dan detail.
- Validasi Ganda untuk Keakuratan: Proses validasi ganda dengan FSRCNN dan Dlib memberikan lapisan tambahan untuk memastikan bahwa ROI yang terdeteksi benar-benar merupakan wajah, sehingga mengurangi tingkat kesalahan.

Potensi Aplikasi:

Metode ini dapat diterapkan pada sistem pengawasan keamanan, identifikasi wajah di area publik, dan aplikasi lain yang memerlukan deteksi dan rekonstruksi wajah pada citra beresolusi rendah.

Klaim Invensi:

Invensi ini mengklaim metode deteksi dan rekonstruksi wajah yang menggabungkan Cascade Classifier dan multi-stage FSRCNN untuk meningkatkan akurasi dan kualitas deteksi wajah

pada citra resolusi rendah, dengan proses validasi ganda untuk memastikan keakuratan deteksi.