

Kombinasi Fitur Global Dan Lokal Dalam Representasi Fitur Untuk Klasifikasi Data Demografi Berdasarkan Gambar Wajah (Studi Kasus: Gender, Kelompok Usia Dan Etnis)

RINGKASAN DISERTASI

Tjokorda Agung Budi Wirayuda

NIM: 33216025

(Program Studi Doktor Teknik Elektro dan Informatika)



Institut Teknologi Bandung
Juli 2023

Kombinasi Fitur Global Dan Lokal Dalam Representasi Fitur Untuk Klasifikasi Data Demografi Berdasarkan Gambar Wajah (Studi Kasus: Gender, Kelompok Usia Dan Etnis)

Disertasi ini dipertahankan pada Sidang Terbuka Sekolah Pascasarjana sebagai salah satu syarat untuk memperoleh gelar Doktor Institut Teknologi Bandung

Juli 2023

Tjokorda Agung Budi Wirayuda

NIM: 33216025

(Program Studi Doktor Teknik Elektro dan Informatika)



Promotor : Dr. Rinaldi Munir

Ko-promotor: Achmad Imam Kistijantoro, Ph.D

Institut Teknologi Bandung

Juli 2023

Kombinasi Fitur Global Dan Lokal Dalam Representasi Fitur Untuk Klasifikasi Data Demografi Berdasarkan Gambar Wajah (Studi Kasus: Gender, Kelompok Usia Dan Etnis)

Tjokorda Agung Budi Wirayuda
NIM: 33216025

1. Latar Belakang

Saat ini, data demografi, termasuk usia, jenis kelamin, dan etnis, memiliki peran penting untuk mendukung analisis terhadap suatu populasi untuk berbagai kebutuhan. Mulai dari pemanfaatan awal dalam bidang sosial, yaitu untuk memahami perilaku sosial manusia dan hubungannya dengan latar belakang demografi individu, sampai analisis demografi pembeli dari sebuah produk, yang digunakan untuk menyesuaikan strategi pemasaran dan iklan. Perkembangan teknologi dan media sosial memberikan peluang bagi para penyedia layanan untuk mengumpulkan data demografi menggunakan gambar wajah pada profil pengguna (Karkkainen dan Joo, 2021).

Data demografi dasar seperti usia, jenis kelamin, dan etnis dapat dikumpulkan secara otomatis melalui pemrosesan gambar wajah (Dantcheva dkk., 2016). Akuisisi data yang bersifat *seamless* merupakan kelebihan dari sistem klasifikasi yang memanfaatkan gambar wajah (Ding dan Tao, 2016; Jafri dan Arabnia, 2009; Xie dkk., 2023). Kelebihan lain dari klasifikasi berbasis wajah adalah kedekatan/kesesuaian dengan pengenalan identitas secara alami oleh manusia, pengenalan berbasis wajah merupakan bentuk pengenalan yang paling natural (Goldstein dkk., 1971). Oleh karena itu, otomatisasi tabulasi data demografi dengan menggunakan gambar wajah merupakan alternatif solusi yang efektif dan efisien. Namun, hal ini membutuhkan ketersediaan metode klasifikasi data demografi yang andal dan memberikan kinerja akurasi yang tinggi.

Ditinjau dari mekanisme representasi fitur dan metode klasifikasi, solusi klasifikasi data demografi dapat dibagi menjadi fitur dengan pendekatan konvensional dan fitur dengan pendekatan *deep learning*. Pada pendekatan konvensional, representasi fitur dihasilkan secara manual dengan menggunakan metode ekstraksi *handcrafted feature* untuk menghasilkan fitur berdimensi tinggi dan dilanjutkan dengan klasifikasi menggunakan metode pembelajaran mesin. Representasi fitur pada pendekatan konvensional pada umumnya adalah penggabungan dari beberapa fitur yang berbeda, misalnya: penggabungan antara *Local Binary Pattern* (LBP) dan *Histogram of Gradient* (HOG) oleh Mohammad dan Al-Ani (2017), filterbank dan

fitur geometri oleh Beccerra-Riera dkk. (2019), *Gray Level Cooccurrence Matrix* (GLCM) dan histogram warna oleh Putriany dkk. (2021). Namun penggabungan yang dilakukan tidak melakukan pengukuran tingkat kontribusi fitur dalam klasifikasi sehingga peningkatan akurasi diperoleh karena peningkatan variansi akibat penggabungan.

Ditinjau dari pemrosesan untuk kebutuhan analisis wajah, terdapat dua pendekatan umum, yaitu: analisis wajah secara global dan lokal. Pada analisis secara global, gambar wajah dipandang sebagai satu objek tunggal sehingga ekstraksi fitur dilakukan pada gambar wajah secara menyeluruh. Pendekatan analisis secara global memberikan tingkat generalisasi dan akurasi yang tinggi dalam berbagai kasus. Namun tidak adanya mekanisme pemisahan objek dengan *background* menjadi salah satu kelemahan dalam menyediakan tingkat kepercayaan bagi penggunaan.

Dalam pendekatan analisis secara lokal, terdapat tahapan untuk menentukan suatu *Region of Interest* (ROI) atau kumpulan *interest point* sebagai pedoman untuk melakukan ekstraksi fitur, dalam penelitian Disertasi, fitur yang dihasilkan disebut dengan fitur lokal. Oleh karena itu, analisis lokal dinilai dapat merepresentasikan cara kerja manusia dalam mengenali suatu objek dalam pengertian fokus pada karakteristik khusus sebagai pembeda antara satu objek dengan objek yang lainnya. Namun pendekatan analisis secara lokal sangat dipengaruhi oleh kualitas dari gambar yang diproses, karena kesalahan dalam menentukan ROI atau kumpulan *interest point* dapat menyebabkan fitur yang diekstraksi menjadi kurang relevan.

Penelitian (Bekhouche dkk., 2017), mengusulkan penggabungan fitur yang sama untuk klasifikasi gender, kelompok usia dan etnis. Penggabungan fitur dilakukan pada fitur tekstur lokal yaitu *Local Phase Quantization* (LPQ) dan *Binarized Statistical Image Features* (BSIF) yang diekstrak dengan *skema pyramid multi-level features*, Skema ini membagi gambar menjadi beberapa sub-blok kemudian melakukan penskalaan terhadap gambar, sehingga variasi ekstraksi fitur dilakukan pada area dan skala yang. Fitur berdimensi tinggi yang dihasilkan dari skema *pyramid multi-level features* direduksi menjadi 5% dengan pendekatan linear *discriminant* berbasis *Fisher's score*. Hasil penelitian Bekhouche dkk.(2017), menunjukkan hasil yang komparatif untuk tiga jenis klasifikasi. Representasi fitur yang digunakan oleh Bekhouche dkk.(2017) belum mewakili informasi warna dan bentuk yang merupakan fitur penting dalam klasifikasi berdasarkan persepsi manusia untuk data demografi.

Representasi fitur menjadi faktor penting dalam menghasilkan sebuah sistem klasifikasi data demografi dengan kinerja yang baik. Berdasarkan penelitian sebelumnya, maka penelitian Disertasi ini mengusulkan kombinasi fitur global dan lokal (fitur yang diekstraksi sama) untuk menghasilkan representasi fitur yang

komprehensif dalam klasifikasi data demografi sehingga menghasilkan peningkatan kinerja dibandingkan penggunaan fitur global atau lokal saja.

2. Tujuan dan Sasaran Penelitian

Penelitian Disertasi ini bertujuan untuk mengusulkan metode untuk menggabungkan fitur global dan lokal dalam representasi fitur untuk klasifikasi data demografi sehingga menghasilkan peningkatan kinerja dibandingkan dengan hanya menggunakan fitur global atau lokal. Peningkatan kinerja akurasi yang dimaksud dalam penelitian Disertasi ini dimaksudkan bahwa akurasi yang dihasilkan lebih baik dibandingkan dengan hanya menggunakan fitur global atau lokal saja, serta dapat mendekati solusi lain yang berbasiskan pada pendekatan *deep learning*.

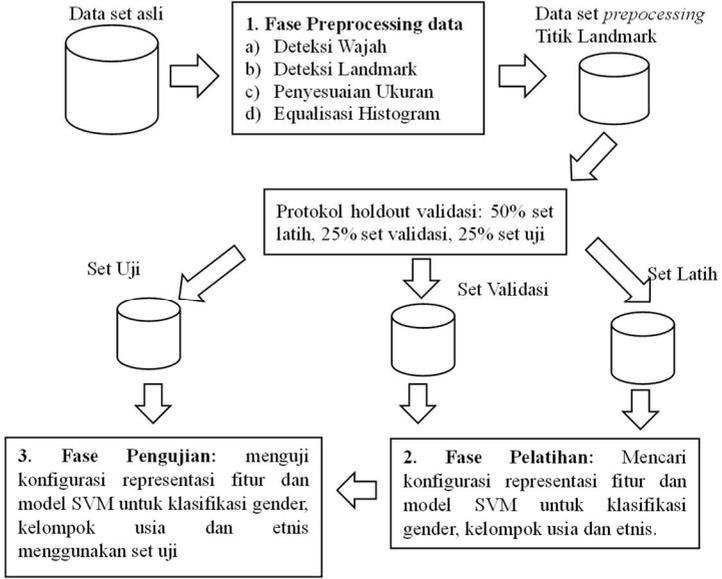
Persepsi manusia dalam melakukan klasifikasi data demografi dikaji dalam penelitian bersama oleh Bruce dkk. (1993) dan Burton dkk. (1993) melakukan tinjauan mengenai pengenalan gender melalui gambar wajah. Penelitian tersebut ditujukan untuk menjawab dua pertanyaan, yaitu: informasi apa pada wajah yang dapat digunakan untuk menentukan gender secara cepat (apa dimensi yang berbeda antara pria dan wanita pada wajah), apa informasi persepsi yang digunakan oleh manusia untuk membedakan pria dan wanita pada gambar wajah (Burton dkk., 1993). Untuk pertanyaan pertama, hasil penelitian memaparkan bahwa pengukuran jarak secara sederhana terhadap titik-titik tertentu (12 variabel) pada wajah dapat menjadi informasi diskriminasi yang baik dalam membedakan pria dan wanita. Sedangkan untuk pertanyaan kedua, hasil penelitian melaporkan bahwa akurasi pengenalan gender akurasi mengalami penurunan signifikan ketika area mata dan alis ditutup dan juga pada pengenalan dengan hasil pemindaian laser dalam bentuk 3-Dimensi yang tidak menyertakan tekstur kulit. Selain itu modifikasi pada bentuk hidung dan dagu pada data hasil pemindaian laser juga berpengaruh secara signifikan terhadap akurasi pengenalan gender.

Secara khusus pada penelitian Disertasi ini, representasi fitur berbasis *handcrafted features* untuk klasifikasi data demografi yang dirancang menggunakan pendekatan holistik dengan menggabungkan fitur global dan lokal serta menjaga agar ukuran fitur akhir relatif rendah namun dapat menghasilkan akurasi yang baik. Hal ini didasarkan pada tinjauan dari bidang *neuro science* oleh Bruce (1988), juga menemukan bahwa komponen wajah seperti rambut, bentuk wajah, mata dan mulut merupakan komponen yang penting dalam persepsi dan mengingat wajah oleh manusia. Hal ini diperkuat dengan kesimpulan mengenai bagian wajah yang memberikan informasi pembeda, dalam pengenalan oleh mesin, melalui paper oleh Xi dkk., (2015). yang melaporkan: “*Under the neutral expression, the main facial components: forehead, eyes, nose and mouth, contain more discriminative information than others for identity recognition.*” (Xi dkk., 2015).

Akurasi yang baik dalam penelitian Disertasi ini dimaksudkan bahwa akurasi yang dihasilkan dapat mendekati solusi lain yang berbasis pada pendekatan *deep learning*. Tersedianya solusi klasifikasi data demografi dengan akurasi yang baik dan menggunakan sumber daya komputasi yang rendah berpotensi untuk diterapkan atau ditanamkan pada perangkat khusus. Penelitian Disertasi ini membatasi jenis data demografi yang digunakan, terbatas pada gender, kelompok usia dan etnis

3. Metode Pengembangan Representasi Fitur Klasifikasi Data Demografi

Pada penelitian Disertasi, proses klasifikasi data demografi dilakukan dengan cara memecah proses klasifikasi menjadi tiga proses, yaitu: klasifikasi gender, klasifikasi kelompok usia dan klasifikasi etnis. Hal ini dilakukan dengan mempertimbangkan tingkat kompleksitas apabila klasifikasi data demografi dilakukan sebagai satu proses tunggal. Representasi fitur yang digunakan pada tiga proses klasifikasi mengadopsi solusi *deep learning* berbasis *joint-task* yang menggunakan mekanisme ekstraksi fitur yang sama untuk beberapa jenis klasifikasi (satu representasi fitur untuk beberapa jenis klasifikasi). Secara garis besar, penelitian Disertasi dilakukan melalui tiga tahapan yaitu: pemrosesan data set, fase pelatihan, dan fase pengujian, seperti yang terlihat pada Gambar 1.



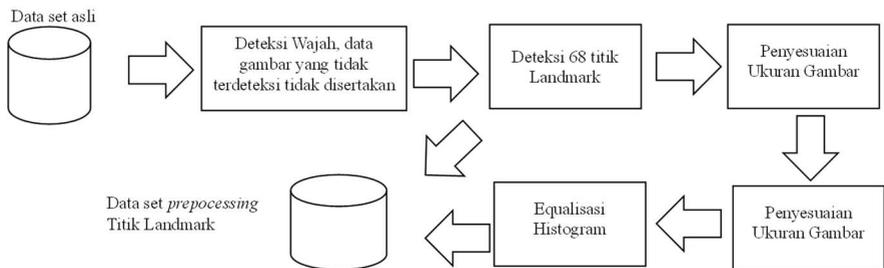
Gambar 1. Gambaran Umum Sistem Klasifikasi Data Demografi

Berdasarkan Gambar 1, posisi dari tahapan pembentukan representasi fitur usulan penelitian Disertasi berada pada fase pelatihan dengan mencari konfigurasi representasi fitur yang memberikan kinerja akurasi terbaik.

Untuk setiap jenis data demografi dilakukan proses pencarian representasi fitur dengan menggunakan tahapan adalah sebagai berikut: data gambar, pada area yang ditentukan, diekstrak dan diproses untuk mendapatkan beberapa variasi fitur tunggal, kemudian dilakukan pemilihan untuk mendapatkan fitur tunggal terbaik. Selanjutnya, fitur tunggal terbaik diproses dengan reduksi fitur untuk menghasilkan fitur tunggal kompak, dari fitur tunggal kompak dihasilkan dilakukan penggabungan untuk menghasilkan fitur kompak gabungan. Kompak menandakan bahwa ukuran fitur dibuat menjadi minimal, sedangkan gabungan menandakan bahwa fitur yang digunakan bersifat multi fitur sehingga dapat memberikan kemampuan diskriminasi yang lebih baik dalam klasifikasi.

3.1 Tahap *Preprocessing*/Pemrosesan Awal

Proses pemrosesan awal dilakukan dengan menerapkan proses pendeteksian wajah, pencarian *landmark* untuk mengekstraksi komponen wajah dan melakukan penyeragaman ukuran gambar. Proses pendeteksian wajah dan pencarian *landmark* merupakan proses filter terhadap data yang digunakan dalam penelitian, apabila ada data gambar yang gagal maka data tersebut tidak diikutsertakan, seperti yang terlihat pada Gambar.2.

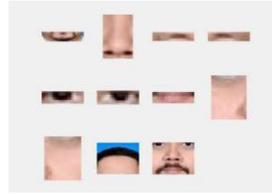


Gambar 2. Tahap Pemrosesan Awal Data

Proses deteksi wajah ditujukan untuk memastikan validitas ketersediaan gambar wajah sesuai dengan kebutuhan yaitu pada posisi dominan menghadap tegak ke depan. Tahap pemrosesan awal pada data set gambar diawali dengan menerapkan proses deteksi wajah serta pencarian 68 titik *landmark*, (dengan *library* berbasis *dlib*), dapat dilihat pada Gambar 3. Titik *landmark* yang berhasil dideteksi, digunakan untuk melakukan analisa lokal pada 11 sub area yang meliputi: alis, mata, hidung, mulut, pipi, area dagu, area atas wajah dan area wajah dalam (yang dibentuk dari mata, hidung dan mulut). Setelah keberadaan wajah pada gambar dideteksi, dilakukan proses penyeragaman ukuran gambar menjadi ukuran 200 x 200 piksel serta proses ekualisasi histogram. Data hasil dari proses pemrosesan awal disebut dengan data set *preprocessing*



(a)

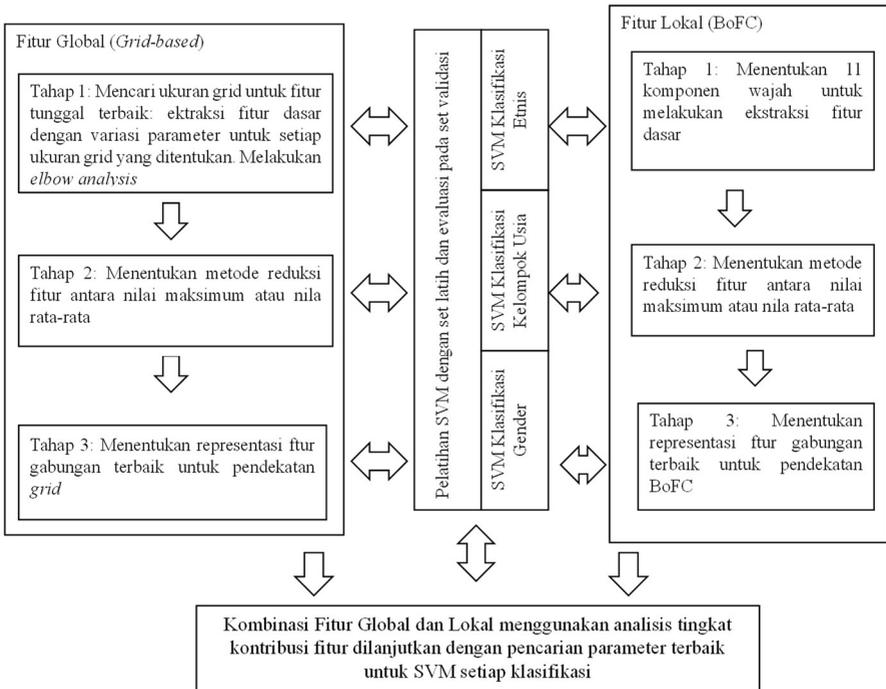


(b)

Gambar 3. (a) Deteksi 68 titik *landmark*; (b) Ekstraksi Komponen Wajah Tahap Pemrosesan Awal

3.2 Tahap Pelatihan

Fase pelatihan merupakan proses inti dari menghasilkan representasi yang terdiri atas 3 tahapan yang dilakukan secara berurutan, dapat dilihat pada Gambar 4, yaitu: penentuan parameter ekstraksi fitur, strategi menghasilkan fitur tunggal kompak dan penggabungan fitur. Pada setiap tahapan dilakukan evaluasi untuk mendapatkan konfigurasi representasi fitur terbaik dan model SVM sebagai luaran dari tahapan pelatihan. Setiap jenis klasifikasi dilatih dievaluasi dengan menggunakan SVM tersendiri sehingga dihasilkan 3 Model SVM, yaitu SVM Gender, SVM Kelompok Umur dan SVM Etnis.



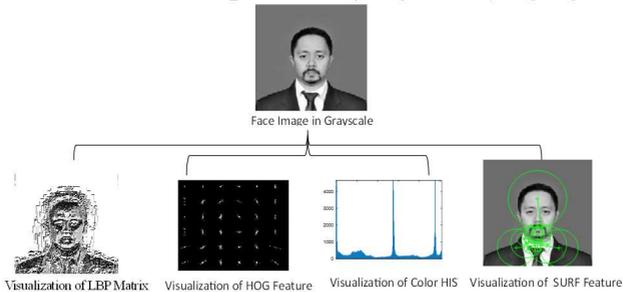
Gambar 4 Fase Pelatihan untuk Klasifikasi Data Demografi

Ditinjau dari luaran untuk setiap tahapan, maka perubahan data awal adalah sebagai berikut: data gambar diekstrak dan diproses untuk mendapatkan fitur tunggal terbaik, kemudian dari fitur tunggal terbaik dihasilkan fitur kompak, dari fitur tunggal kompak dihasilkan fitur gabungan kompak.

Proses utama pada tahap pelatihan meliputi:

1. Penentuan Konfigurasi Ekstraksi Fitur

Pada penelitian Disertasi ini mekanisme menghasilkan sub-area dilakukan dengan pendekatan global yaitu pembagian yang seimbang (*grid-based*) dan pendekatan lokal yaitu pembagian sub-area menjadi komponen wajah, untuk selanjutnya dapat disebut dengan *Bag Of Facial Component* (BoFC). Sedangkan pemilihan *handcrafted feature* berdasarkan hasil studi literatur yaitu variasi dari fitur LBP (Nguyen dkk., 2015; Mohammad dan Al-Ani, 2017), fitur HOG (Al-Azani dkk., 2019), *Color Histogram* (Color HIST) (Putiany dkk., 2021; Ridzuan dkk., 2023), dan fitur CAP menggunakan descriptor SURF (Boumedine dkk., 2022; Sikder dkk., 2022; Thapar dkk., 2022). Gambar 5 menunjukkan ilustrasi dari empat *handcrafted feature* yang digunakan



Gambar 5 Ilustrasi Visual dari MLBP, HOG, Color HIST dan CAP

Pada metode ekstraksi fitur MLBP dan CAP, proses ekstraksi fitur dilakukan pada citra *grayscale*. Sementara itu, ekstraksi fitur HOG dan Color HIST diterapkan pada kanal RGB + *grayscale*. Proses penentuan parameter independen dilakukan untuk setiap metode ekstraksi fitur, yang ditujukan untuk menemukan konfigurasi parameter optimal. Variasi konfigurasi untuk setiap metode ekstraksi fitur yang dapat dilihat pada Tabel.1, variasi meliputi variasi kanal data dan parameter metode.

Tabel.1 Konfigurasi *Handcrafted Feature Extraction*

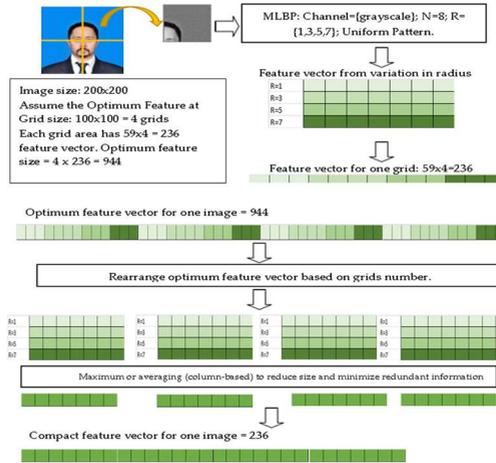
No.	Metode Ekstraksi <i>Handcrafted Feature</i>	Parameter Metode Ekstraksi
1	<i>Multi Local Binary Pattern (MLBP)</i>	Kanal={ <i>grayscale</i> }; R= {1,3,5,7}; Pola Uniform; Ukuran fitur pada setiap sub-area= $59 \times 4 = 236$
2	<i>Histogram of Gradient (HOG)</i>	Kanal= {[R, G, B, <i>grayscale</i>]}; bin= {9,18}; Ukuran Block = {1x1}; Non-Overlap; Orientasi= {[0,180], [-180, 180]}; Ukuran fitur pada setiap sub-area = $27 \times 8 = 216$
3	<i>Color Histogram (Color HIST)</i>	Kanal= {[R, G, B, <i>grayscale</i>]}; bin= {32}; <i>Color spatial info</i> = {[6x6]}; Ukuran fitur pada setiap sub-area = $32 \times 4 + 108 = 236$
4	<i>Center of Area Pattern (CAP)</i>	Kanal={ <i>grayscale</i> }; Point-based= {center of grid}; Scale= {1.6, 3.2, 4.8, 6.4}; Ukuran fitur pada setiap sub-area = $64 \times 4 = 256$

Berdasarkan Tabel.1, setiap metode ekstraksi fitur memiliki empat variasi parameter untuk memproses data gambar pada sebuah sub-area. Empat variasi akan menghasilkan fitur 2-dimensi yang kemudian diubah menjadi fitur 1-dimensi sebagai representasi fitur pada sebuah sub-area. Sebagai contoh, MLBP diterapkan pada gambar *grayscale* dengan variasi radius R=1,3,5,7, akan menghasilkan vektor fitur dengan ukuran 59×4 , kemudian diubah menjadi bentuk 1 dimensi dengan ukuran 1×256 .

Secara singkat, pada pendekatan *grid-based* variabel independen yang dicari pada tahap penentuan parameter konfigurasi ekstraksi fitur adalah ukuran grid untuk setiap *handcrafted feature* yang menghasilkan keseimbangan antara peningkatan ukuran fitur dan akurasi. Kondisi keseimbangan ini ditentukan dengan menggunakan *elbow analysis* secara manual. Fitur yang mengindikasikan kondisi keseimbangan disebut dengan fitur tunggal terbaik. Sedangkan pada pendekatan BoFC tidak dilakukan penentuan parameter independen karena hanya memiliki satu variasi sub-area.

2. Strategi Reduksi Fitur Untuk Fitur Kompak

Fitur tunggal terbaik yang dihasilkan pada tahap penentuan ukuran *grid* masih memiliki ukuran yang tinggi, sehingga diperlukan mekanisme reduksi ukuran dengan meminimalkan dampak penurunan akurasi. Dampak penurunan akurasi dapat diatasi dengan menghasilkan fitur kompak untuk kemudian dilakukan proses penggabungan. Strategi fitur kompak yang diusulkan berdasarkan pada metode pemrosesan data tunggal, yang hanya membutuhkan vektor fitur dari satu gambar yang diproses. Hal ini dilakukan dengan memilih atau menghasilkan representasi baru menggunakan hanya satu baris informasi vektor fitur dari fitur tunggal terbaik untuk setiap jenis metode ekstraksi fitur. Ilustrasi menghasilkan fitur tunggal kompak dari fitur tunggal terbaik dapat dilihat pada Gambar 6.



Gambar 6 Ilustrasi Visual Menghasilkan Fitur Tunggal Kompak dari Fitur Tunggal Terbaik dengan Menerapkan Reduksi Fitur

Strategi menghasilkan fitur tunggal kompak melalui metode reduksi fitur yang diusulkan dijelaskan sebagai berikut. Pertama, fitur tunggal terbaik diatur ulang berdasarkan lokasi spasial; hal ini dapat dilakukan karena pendekatan berbasis sub-area mendefinisikan ukuran fitur untuk setiap *handcrafted feature* dan memiliki ukuran fitur yang sama untuk setiap variasi internal pada *handcrafted feature*. Kemudian, metode reduksi fitur diterapkan pada fitur tunggal terbaik yang diatur ulang. Strategi metode reduksi fitur menggunakan metode nilai maksimum, yang diadaptasi dari studi oleh Porebski dkk., (2018), Nguyen dkk., (2021), dan Lu dkk., (2022) dengan menggunakan rumus yang didefinisikan dalam persamaan (1) Sementara itu, representasi fitur dengan nilai baru dihasilkan dengan menghitung rata-rata vektor fitur, yang diadaptasi dari studi oleh Becerra-Riera dkk., (2019) berdasarkan persamaan yang ditentukan dalam persamaan(2). Fitur tunggal kompak dari sebuah gambar adalah gabungan dari fitur tunggal kompak pada setiap sub-area yang ditunjukkan oleh persamaan (3)..

$$\widehat{H}_r = \arg \max \sum_{i=1}^n H_{i_r} \quad (1)$$

$$\widehat{H}_r = \frac{\sum_{i=1}^n H_{i_r}}{n} \quad (2)$$

$$\widehat{H} = \bigcup_{r=1}^k \widehat{H}_r \quad (3)$$

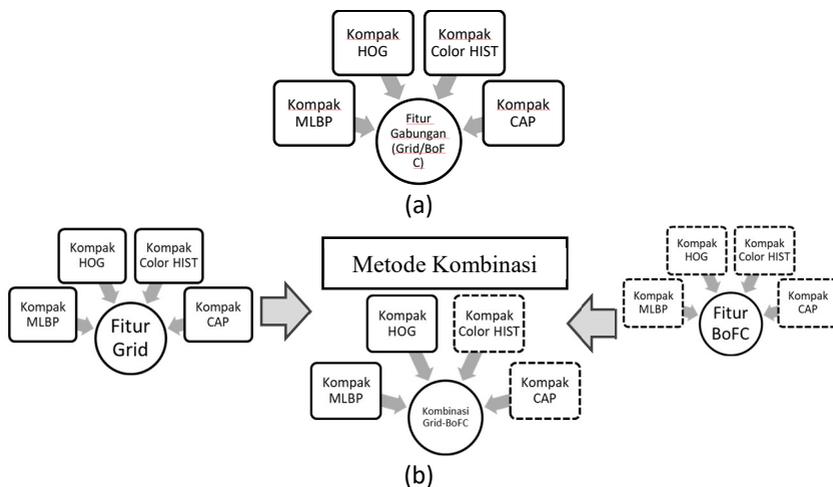
Dengan, \widehat{H}_{x_r} adalah fitur kompak pada sub-area r , n adalah jumlah konfigurasi ekstraksi fitur yang dilakukan, H_{i_r} adalah vektor fitur untuk konfigurasi i pada

sub-area r. Pemilihan nilai maksimum dilakukan dengan pertimbangan bahwa nilai fitur yang tinggi menyediakan kemampuan diskriminasi yang baik, sedangkan pendekatan rata-rata bertujuan untuk mengakumulasi informasi dari beberapa variasi fitur. Dari kandidat fitur tunggal terbaik dihasilkan fitur kompak, kemudian dilakukan analisis akurasi untuk memilih strategi fitur tunggal kompak terbaik yang digunakan untuk seluruh handcrafted feature apakah nilai maksimum, nilai rata-rata.

3. Penggabungan Fitur

Hasil akhir dari strategi menghasilkan fitur kompak menyediakan kandidat fitur kompak yang memiliki ukuran yang lebih kecil daripada fitur optimum tetapi mengalami penurunan kinerja akurasi klasifikasi. Perlu diingat bahwa tahap penentuan parameter independen dan strategi menghasilkan fitur kompak, tahapan dilakukan pada MLBP, HOG, *Color* HIST, dan CAP dievaluasi secara independen (sebagai fitur tunggal). Penggabungan fitur kompak dari MLBP, HOG, *Color* HIST, dan CAP dari kandidat fitur kompak akan mengatasi permasalahan penurunan akurasi (Becerra-Riera dkk., 2019; Mohammad dan Al-Ani, 2017; Putriany dkk., 2021).

Terdapat dua jenis penggabungan fitur, yaitu penggabungan pada masing-masing tahap fitur global (*grid-based*) dan lokal (BoFC), serta penggabungan antara fitur global dan lokal, ilustrasi penggabungan pada Gambar 7.



Gambar.7 Ilustrasi Penggabungan Fitur: (a) Pada Pembentuka Fitur Global (*grid-based*) atau Lokal (BoFC), (b) Kombinasi Fitur Global dan Lokal

Penggabungan fitur pada masing-masing pendekatan *grid-based* dan BoFC dilakukan dengan strategi serial menggunakan dua skema pembobotan yaitu pembobotan seragam dan pembobotan berbasis akurasi dari penggunaan fitur secara independen. Dengan menggunakan strategi serial, maka fitur hasil penggabungan didefinisikan dengan persamaan (4)-(8) (Yang dkk., 2021).

$$FG = [w_1 f_1 \quad w_2 f_2 \quad w_3 f_3 \quad w_4 f_4] \quad (4)$$

$$w_1 = \frac{A_1}{A_1 + A_2 + A_3 + A_4} \quad (5)$$

$$w_2 = \frac{A_2}{A_1 + A_2 + A_3 + A_4} \quad (6)$$

$$w_3 = \frac{A_3}{A_1 + A_2 + A_3 + A_4} \quad (7)$$

$$w_4 = \frac{A_4}{A_1 + A_2 + A_3 + A_4} \quad (8)$$

Dengan f_1 adalah fitur MLBP, f_2 adalah fitur HOG, f_3 adalah fitur *Color HIST* dan f_4 adalah fitur CAP. Dengan A_1, A_2, A_3 dan A_4 adalah akurasi (dihitung dengan menggunakan Persamaan 2.15) dari klasifikasi dengan menggunakan f_1, f_2, f_3 , dan f_4 . Sedangkan w_1, w_2, w_3, w_4 adalah bobot dari setiap fitur yang diberikan nilai = 1 pada skema pembobotan seragam, dan menggunakan persamaan 3.5 - 3.8 untuk pembobotan berbasis akurasi. Jika n_1, n_2, n_3 , dan n_4 adalah dimensi dari f_1, f_2, f_3 , dan f_4 , maka dimensi dari FG adalah $(n_1 + n_2 + n_3 + n_4)$.

Pada penggabungan kombinasi antara fitur *grid-based* dan BoFC dilakukan proses pemilihan jenis fitur yang digunakan dengan melihat tingkat kontribusi fitur dalam proses klasifikasi secara menyeluruh. Perhitungan tingkat kontribusi fitur dilakukan dengan menghilangkan satu fitur dalam proses klasifikasi data demografi, kemudian dilakukan perhitungan selisih akurasi dibandingkan dengan penggunaan fitur lengkap. Selisih akurasi menggambarkan tingkat kontribusi fitur pada setiap jenis klasifikasi. Tingkat kontribusi total adalah gabungan dari selisih akurasi dari sebuah fitur ketika tidak dilibatkan dalam proses klasifikasi. Persamaan yang digunakan untuk menghitung kontribusi fitur didefinisikan pada persamaan (9) – (11).

$$ACC_k = evaluate\ SVM_k \left(\bigcup_{i=1}^n w_i f_i \right) \quad (9)$$

$$TK_{f_j,k} = evaluate\ SVM_k \left(\bigcup_{i=1}^n w_i f_i \right); i \neq j \quad (10)$$

$$TKF_{f_j} = \sum_{k=i}^c ACC_k - TK_{f_j,k} \quad (11)$$

Dengan ACC_k adalah akurasi klasifikasi untuk data demografi k {gender, kelompok umur, etnis} dengan SVM_k menggunakan seluruh fitur, sedangkan n adalah indeks tipe fitur, yaitu MLBP, HOG, *Color HIST*, dan CAP. Selanjutnya simbol $TK_{f_j,k}$ adalah akurasi klasifikasi untuk data demografi k dengan tidak melibatkan fitur f_j . Yang terakhir adalah simbol TKF_{f_j} yang menyatakan tingkat kontribusi dari fitur f_j dalam klasifikasi data demografi secara keseluruhan.

Tingkat kontribusi fitur MLBP, HOG, *Color HIST*, dan CAP dihitung masing-masing dalam pendekatan *grid-based* dan BoFC. Kemudian dilakukan pemilihan fitur dengan mengambil fitur yang memiliki tingkat kontribusi paling tinggi antara pendekatan *grid-based* dan BoFC dengan persamaan (12).

$$FC = \bigcup_{i=1}^n \operatorname{argmax}(TKG_{f_i}, TKB_{f_i}) \quad (12)$$

Dengan FC adalah fitur hasil penggabungan dari pemilihan fitur f_i berdasarkan nilai maksimal tingkat kontribusi antara pendekatan *grid-based* (TKG_{f_i}) dengan pendekatan BoFC (TKB_{f_i}), dan n adalah indeks tipe fitur, yaitu MLBP, HOG, *Color HIST*, dan CAP

3.3 Rancangan Eksperimen dan Evaluasi

Eksperimen yang dilakukan dalam penelitian Disertasi ini secara garis besar dilakukan untuk menemukan konfigurasi representasi fitur global, lokal dan kombinasi antara fitur lokal dan global untuk klasifikasi data demografi. Parameter pengukuran pada eksperimen disesuaikan dengan kebutuhan analisis, yang meliputi: akurasi klasifikasi, penurunan akurasi, rasio reduksi fitur dan ukuran fitur.

Eksperimen dilakukan dengan menggunakan protokol validasi *holdout* yang membagi data set menjadi set latih, validasi, dan uji, dengan proporsi masing-masing 50%, 25%, dan 25%. Proses pembagian menggunakan sampel acak terstratifikasi untuk memastikan setiap sub-set memiliki variasi sampel yang serupa. Eksperimen menggunakan set latih untuk konfigurasi ekstraksi fitur dan pembelajaran model klasifikasi. Selanjutnya, penyesuaian konfigurasi dan model klasifikasi menggunakan set validasi dengan melihat nilai akurasi yang dicapai. Tujuan dari eksperimen adalah mendapatkan konfigurasi terbaik representasi fitur dan model klasifikasi yang nantinya digunakan pada pengujian untuk mengevaluasi kemampuan generalisasi dari ekstraksi fitur dan model klasifikasi.

Pencarian konfigurasi representasi fitur dimulai pada fitur global yang direpresentasikan oleh pendekatan *grid-based* dan fitur lokal yang direpresentasikan oleh pendekatan BoFC. Untuk setiap pendekatan, pencarian konfigurasi dimulai

dengan mengevaluasi kinerja *handcrafted feature* tunggal untuk mencari fitur optimum; pada pendekatan *grid-based* hal ini ditujukan untuk menemukan parameter ukuran sub-area yang optimum. Fitur optimum berdimensi tinggi masih mengandung informasi yang berlebih akibat variasi parameter dalam proses ekstraksi fitur. Selanjutnya, fitur kompak diekstraksi dari fitur optimum menggunakan beberapa metode. Hasilnya, fitur kompak akan lebih kecil daripada fitur optimum tetapi memiliki kemampuan diskriminasi yang lebih rendah. Setelah itu, strategi penggabungan fitur diterapkan untuk menemukan keseimbangan antara ukuran fitur dan akurasi klasifikasi etnis. Penggabungan fitur pada eksperimen diawali menggunakan skema pembobotan yang seragam, kemudian dilakukan analisis skema pembobotan untuk menentukan apakah setiap jenis fitur perlu dilakukan pembobotan dengan persamaan (5)–(8).

Kombinasi fitur global dan lokal dilakukan dengan eksperimen untuk mengukur tingkat kontribusi *handcrafted feature* tunggal dalam klasifikasi data demografi. Tingkat kontribusi diukur pada pendekatan fitur global dan lokal, untuk kemudian dilakukan pemilihan sumber *handcrafted feature* tunggal untuk representasi fitur kombinasi dengan memilih sumber dengan tingkat kontribusi yang lebih tinggi. Secara umum keberhasilan dari usulan kombinasi fitur global dan lokal dalam klasifikasi data demografi adalah akurasi yang lebih tinggi dibandingkan dengan hanya menggunakan fitur global atau fitur lokal saja.

Klasifikasi dalam eksperimen menggunakan SVM Multi-kelas dan menerapkan skema OVA (*One Versus All*). Parameter SVM dalam eksperimen menggunakan *kernel polynomial* dengan urutan 3, $C=1$, dan skala *kernel* diatur otomatis (menggunakan prosedur heuristik untuk memilih nilai skala dengan angka acak diatur menjadi 5); parameter ini didasarkan pada observasi awal menggunakan beberapa *kernel* yang berbeda yaitu: ;linear, kuadratik, *polynomial*, dan *Radial Basis Function* (RBF).

Setelah konfigurasi representasi fitur ditemukan, selanjutnya dilakukan pengujian pada set uji untuk melihat kemampuan generalisasi dari konfigurasi representasi fitur dan model klasifikasi. Dalam penelitian Disertasi ini, kemampuan generalisasi dari usulan solusi selain diujikan pada set uji juga diujikan secara *cross-dataset* sehingga diperlukan pemrosesan awal agar data set yang digunakan dapat mengakomodasi proses pengujian *cross-dataset*. Dilakukan juga pengujian untuk membandingkan kinerja akurasi usulan metode reduksi fitur dengan PCA.

Untuk memastikan bahwa model klasifikasi yang digunakan merupakan model terbaik dari beberapa konfigurasi, dilakukan eksperimen dan pengujian pada parameter SVM yang meliputi perubahan jenis kernel, skema multi-kelas dan nilai C. Untuk memberikan gambaran posisi dari usulan solusi terhadap solusi lain maka

dilakukan perbandingan pengujian dengan solusi yang menjadi *state of the art* dalam klasifikasi data demografi.

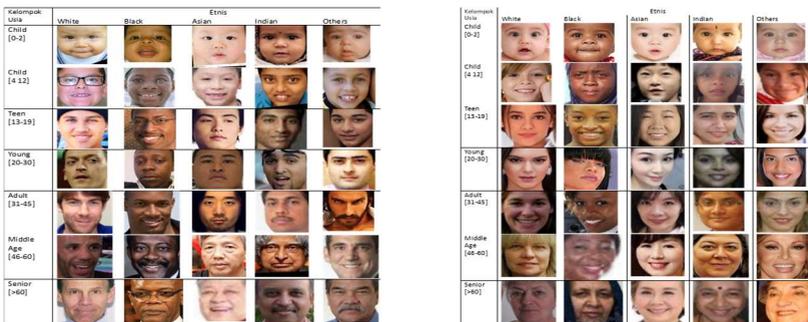
4. Eksperimen dan Evaluasi Hasil

Eksperimen pada penelitian Disertasi terdiri atas delapan tahapan, yaitu: (1) persiapan data set dan konfigurasi SVM, (2) eksperimen pada representasi fitur yang meliputi *grid-based*, BoFC dan kombinasi, (3) analisis skema pembobotan untuk penggabungan, (4) pengujian pada set uji dan perbandingan dengan penggunaan PCA, (5) eksperimen dan pengujian parameter SVM, (6) analisis kesalahan dan uji hipotesis, (7) pengujian *cross-dataset* dan (8) perbandingan dengan pendekatan *state-of-the-art* pada klasifikasi data demografi.

4.1 Data Set dan Persiapan Eksperimen

Penelitian ini menggunakan data set UTKFace (2017) dan data set Fair Face (2021). Pemilihan data set tersebut mempertimbangkan jumlah gambar, ketersediaan publik, jumlah kelompok etnis, variasi kualitas gambar, distribusi data, dan ketersediaan hasil penelitian lainnya. Data set UTKFace digunakan untuk eksperimen awal untuk mencari parameter pada metode yang diusulkan. Sementara itu, data set Fair Face digunakan pada eksperimen *Cross-Dataset* untuk menganalisis generalisasi parameter metode yang diusulkan.

Data set UTKFace bersifat publik dan dapat diakses atau diunduh melalui tautan <https://susanqq.github.io/UTKFace/> dan terdiri dari lebih dari 20.000 gambar wajah dengan anotasi usia, jenis kelamin, dan etnis. Selain itu, data set ini mencakup variasi yang signifikan dalam pose, ekspresi wajah, pencahayaan, penutupan, dan resolusi seperti yang dapat dilihat pada Gambar 8.



Gambar 8 Contoh Variasi Gambar Wajah Gender-Kelompok Usia-Etnis pada data set UTKFace (<https://susanqq.github.io/UTKFace/>)

Data set Fair Face terdiri dari 108.501 gambar dari 7 ras: White, Black, Indian, East Asian, Southeast Asian, Middle Eastern, dan Latino dengan distribusi data yang

seimbang, Data set Fair Face dapat diakses melalui tautan <https://github.com/joojs/fairface/> dan berisi variasi tampilan, pencahayaan, dan pose yang menantang karena gambar-gambar tersebut diambil dari sudut yang buruk dalam lingkungan yang tidak terbatas. Studi yang dilakukan oleh (Belcar dkk., 2022) melaporkan bahwa pemrosesan awal untuk mendeteksi titik *landmark* gagal untuk sejumlah besar data gambar pada data set Fair Face. Hal ini mengindikasikan bahwa terdapat sejumlah besar gambar wajah non-frontal dalam data set Fair Face.

Data set UTKFace mengalami proses pemrosesan awal yang meliputi proses pendeteksian wajah, pencarian *landmark* untuk mengekstraksi komponen wajah dan melakukan penyeragaman ukuran gambar, dengan hasil akhir disebut dengan data set UTKFace *Preprocessing*. Setelah melewati pemrosesan awal, jumlah data yang awalnya 23.705 berkurang menjadi 22.332 data. Meskipun terjadi penurunan jumlah, namun distribusi data demografi pada gender, kelompok usia maupun etnis tidak mengalami perubahan signifikan. Oleh karena itu, UTKFace *Preprocessing* data set dapat digunakan dalam penelitian ini dan dapat dibandingkan dengan penelitian lain yang menggunakan UTKFace.

Pengujian *cross-dataset* bertujuan untuk mengevaluasi kinerja konfigurasi terbaik dari kombinasi fitur global dan lokal serta generalisasi model klasifikasi pada data set lain. Dataset yang digunakan dalam eksperimen *cross-dataset* adalah sub set dari data set Fair Face. Data set Fair Face merupakan data set yang seimbang berdasarkan gender, kelompok umur dan etnis yang terdiri dari 108.501 gambar dari dua label gender, 9 label kelompok umur [0-2, 3-9, 10-19, 20-29, 30-39, 40-49, 50-59, 60-69, 70+] , dan 7 label etnis: White, Black, Indian, East Asian, Southeast Asian, Middle Eastern, dan Latino (Karkkainen dan Joo, 2021). Karakteristik dari data set Fair Face dan ketersediaan label untuk gender, kelompok usia dan etnis yang relatif sama dengan UTKFace membuat data set Fair Face sesuai untuk pengujian *cross-dataset* .

Data set UTK Face dan Fair Face memiliki perbedaan jumlah label untuk kelompok usia dan etnis, sehingga perlu dilakukan penyamaan jumlah label. Pada penelitian Disertasi, kelompok usia yang digunakan terdiri atas 5 kelas, yaitu: Bayi [0 s/d 2 tahun], Remaja [3 s/d 19 tahun], Dewasa [20 s/d 39 tahun], Paruh Baya [40 s/d 59 tahun], Tua [>60 tahun]. Kelompok usia yang digunakan mempertimbangkan jumlah sampel data yang terdapat pada data set UTKFace dan Fair Face. Untuk perbedaan jumlah label etnis antara data set UTKFace dan Fair Face, pengujian ini menggunakan empat kelas etnis yang ada di kedua data set tersebut, yaitu White, Black, Asian, dan Indian.

Data set UTKFace *Preprocessing*, yang telah dikurangi hanya menjadi empat kelas, dinamai UTKFace-A dan terdiri dari 20.690 data yang terbagi menjadi 15.522 set latih dan 5.168 set uji. Sementara itu, data set Fair Face yang digunakan dalam pengujian ini adalah sub set yang disebut Fair Face-A, terdiri dari 17.199 data,

termasuk 12.909 set latih dan 4.290 set uji. pemrosesan awal telah dilakukan pada Fair Face-A untuk memastikan kehadiran wajah yang menghadap ke depan, ukuran gambar 200x200 piksel dan equalisasi histogram.

4.2 Eksperimen pada Pendekatan *Grid-Based*, BoFC dan Kombinasi

Eksperimen pada pendekatan *grid-based* terdiri atas penentuan ukuran *grid*, penentuan metode reduksi fitur dan pembentukan fitur gabungan. Tiga tahapan tersebut bertujuan untuk menyediakan konfigurasi terbaik dan model pembelajaran dengan menggunakan set latih dan validasi. Konfigurasi terbaik dan model pembelajaran dievaluasi pada set sebagai pedoman pengukuran kinerja akhir.

Eksperimen menentukan ukuran *grid* dilakukan secara terpisah dengan mengevaluasi kinerja dari setiap *handcrafted feature* (diperlakukan sebagai fitur tunggal). Untuk menentukan fitur tunggal terbaik melalui *elbow analysis*. Fitur tunggal terbaik menyediakan posisi keseimbangan, yang menunjukkan optimasi antara peningkatan ukuran fitur dan akurasi. Eksperimen ini menggunakan ukuran *grid*: 200x200, 100x100, 50x50, 40x40, dan 25x25 yang membagi gambar menjadi sebanyak R sub area, semakin kecil ukuran *grid* semakin banyak jumlah sub area yang membuat ukuran fitur menjadi semakin besar. Secara teori, semakin besar ukuran vektor fitur, semakin besar keragaman data, yang meningkatkan kemungkinan untuk memisahkan data dengan karakteristik yang berbeda. Namun, akan ada suatu titik jenuh ketika kenaikan jumlah fitur tidak mempengaruhi tingkat akurasi secara signifikan.

Berdasarkan hasil eksperimen, akurasi terbaik yang dicapai pada klasifikasi gender dari eksperimen penentuan ukuran *grid* adalah 91,49%, 89,91%, 89,30%, dan 89,99%, masing-masing untuk fitur MLBP, HOG, Color HIST, dan CAP dengan ukuran fitur 15.104, 13.824, 15.104, dan 4.096. Eksperimen pada klasifikasi kelompok usia dari penentuan ukuran *grid* adalah 60,73%, 58,85%, 56,80%, dan 58,81%, masing-masing untuk fitur MLBP, HOG, Color HIST, dan CAP dengan ukuran fitur 15.104, 13.824, 15.104, dan 4.096. Hasil eksperimen menunjukkan hubungan proporsional antara ukuran fitur dan akurasi, kecuali untuk fitur CAP yang mencapai akurasi puncak pada 4.096 fitur. Sedangkan pada klasifikasi etnis dari penentuan ukuran *grid* adalah 80,20%, 77,39%, 77,51%, dan 78,32%, masing-masing untuk fitur MLBP, HOG, Color HIST, dan CAP dengan ukuran fitur 15.104, 13.824, 15.104, dan 4.096

Untuk menentukan kandidat dari fitur tunggal terbaik dilakukan *elbow analysis* secara manual dengan melihat hubungan antara akurasi dan ukuran fitur untuk masing-masing klasifikasi gender, kelompok umur dan etnis. Fakta menarik yang diperoleh melalui *elbow analysis*, pada setiap tipe klasifikasi kandidat tunggal terbaik berada pada nilai sub-area yang sama, yaitu. MLBP [50x50] dan [40x40], HOG [40x40] dan [25x25], Color HIST [50x50] dan [40x40], CAP [100x100] dan

[50x50]. Dari hasil *elbow analysis*, maka dua kelompok kandidat fitur tunggal terbaik dipilih untuk investigasi dan analisis lebih lanjut mengenai hubungan antara ukuran fitur dan akurasi, yang diberi nama fitur Tunggal-1 dan Tunggal-2 dengan akurasi minimal yang dapat diterima sekitar ~70%.

Eksperimen terkait reduksi fitur belum dapat memilih metode yang akan digunakan, sehingga dua kandidat fitur tunggal kompak diproses pada eksperimen penggabungan. Pada eksperimen penggabungan fitur, terdapat dua skema penggabungan fitur yaitu: (1) menggabungkan konfigurasi fitur yang memiliki panjang minimum (Kompak-Tunggal-1), menghasilkan panjang fitur sebesar 4.790, yang terdiri dari MLBP [50x50], HOG [40x40], Color HIST [50x50], dan CAP [100x100], (2) menggabungkan konfigurasi fitur yang memiliki panjang maksimum (Kompak-Tunggal-2), menghasilkan panjang fitur sebesar 9.455, yang terdiri dari MLBP [40x40], HOG [25x25], Color HIST [40x40], dan CAP [50x50]. Untuk mempermudah penyebutan maka fitur penggabungan Kompak-Tunggal-1 selanjutnya disebut dengan Kompak-Gabungan-1 dan fitur penggabungan Kompak-Tunggal-2 selanjutnya disebut dengan Kompak-Gabungan-2.

Tabel 1 Hasil Eksperimen Pembentukan Fitur Gabungan Pada Klasifikasi Gender, Klasifikasi Kelompok Usia dan Klasifikasi Etnis (dalam %)

Gabungan dari	Strategi Fitur Kompak	Klasifikasi Gender		Klasifikasi Kelompok Usia		Klasifikasi Etnis	
		<i>Base-line</i>	Akurasi	<i>Base-line</i>	Akurasi	<i>Base-line</i>	Akurasi
Kompak-Gab-1	Nilai Rata-rata	92,07	91,67	61,83	60,71	81,28	81,19
Kompak-Gab-1	Nilai maksimum	92,07	91,55	61,83	61,49	81,28	80,85
	Rata-rata		91,61		61,10		81,02
Kompak-Gab-2	Nilai Rata-rata	92,16	92,28	62,38	61,43	81,91	81,66
Kompak-Gab-2	Nilai maksimum	92,16	91,60	62,38	61,00	81,91	81,55
	Rata-rata		91,94		61,22		81,60

Berdasarkan Tabel 1, dengan mempertimbangkan keseimbangan antara akurasi dan ukuran fitur, kelompok Kompak-Gabungan-1 dengan menggunakan nilai rata-rata dalam pembentukan fitur kompak dipilih sebagai konfigurasi terbaik. Untuk selanjutnya konfigurasi terbaik ini disebut dengan Kompak-Gabungan-Grid.

Hasil eksperimen dari representasi fitur menggunakan pendekatan BoFC sampai tahap pembentukan fitur tunggal kompak menunjukkan bahwa pendekatan sub area berbasis BoFC menghasilkan akurasi yang moderat dengan jumlah fitur terbatas. Tahap akhir pada eksperimen sub area berbasis BoFC adalah eksperimen pada fitur

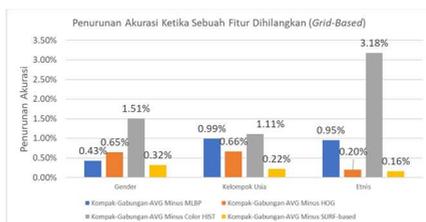
gabungan dari fitur kompak yang terdiri atas gabungan fitur kompak hasil dari metode rata-rata dan metode nilai maksimum, dengan ukuran fitur sebanyak 3.487. Fitur gabungan 11 BoFC tanpa proses kompak menjadi *base-line* akurasi, dengan ukuran fitur sebanyak 10.384. Rasio reduksi dari 11 BoFC Kompak Gabungan adalah sebesar 66,42% (dari 10.384 menjadi 3.487). Hasil akurasi klasifikasi dari eksperimen dengan fitur Kompak Gabungan dapat dilihat pada Tabel.2.

Tabel.2. Hasil Eksperimen Fitur Kompak Gabungan pada Sub Area berbasis BoFC untuk Klasifikasi Data Demografi (dalam %)

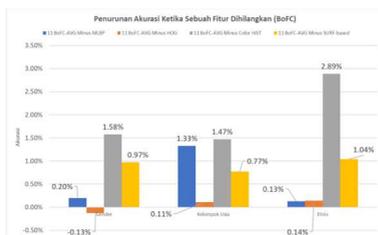
Gabungan dari	Strategi Fitur Kompak	Klasifikasi Gender		Klasifikasi Kelompok Usia		Klasifikasi Etnis	
		<i>Base-line</i>	Akurasi	<i>Base-line</i>	Akurasi	<i>Base-line</i>	Akurasi
[A] 11 BoFC	Nilai Rata-rata	90,87	91,24	61,74	60,88	82,66	82,34
[B] 11 BoFC	Nilai maksimum	90,87	90,90	61,74	60,36	82,66	82,30
[A]-[B]			0,34		0,52		0,04

Hasil eksperimen pada Tabel.2, menunjukkan bahwa pada setiap jenis klasifikasi data demografi, gabungan fitur kompak hasil metode nilai rata-rata menghasilkan akurasi yang lebih tinggi dibandingkan dengan metode nilai maksimal. Selisih antara metode nilai rata-rata berbanding nilai maksimum adalah sebesar 0,34%, 0,52% dan 0,04%, untuk klasifikasi gender, kelompok usia dan etnis. Berdasarkan hasil eksperimen maka pada sub area berbasis BoFC, konfigurasi representasi fitur adalah menggunakan fitur gabungan dari fitur kompak hasil metode nilai rata-rata, yang selanjutnya disebut dengan Kompak-Gabungan-BoFC.

Eksperimen tingkat kontribusi fitur gabungan ditujukan untuk melihat kontribusi dari fitur MLBP, HOG, Color HIST dan CAP terhadap akurasi klasifikasi data demografi sebagai dasar pemilihan penggabungan fitur *grid-based* dan BoFC. Pengujian ini dilakukan dengan menghitung selisih atau penurunan akurasi ketika sebuah tipe fitur tidak disertakan dalam representasi ciri dibandingkan dengan penggunaan seluruh fitur. Tingkat kontribusi dari tipe fitur diurutkan berdasarkan selisih perubahan akurasi, fitur dengan kontribusi terbesar adalah fitur dengan perubahan positif maksimum atau perubahan negatif minimum. Hasil pengujian tingkat kontribusi fitur pada fitur Kompak-Gabungan dan Kompak-Gabungan-BoFC dapat dilihat pada Gambar 8 dan Gambar 9.



Gambar 9 Penurunan Tingkat Akurasi Ketika Satu Jenis Fitur Tidak disertakan untuk Klasifikasi Data Demografi berbasis Grid



Gambar 10 Penurunan Tingkat Akurasi Ketika Satu Jenis Fitur Tidak disertakan untuk Klasifikasi Data Demografi berbasis BoFC

Berdasarkan Gambar 2 dan Gambar 3, secara keseluruhan, fitur dengan ukuran paling kecil memiliki tingkat kontribusi yang paling rendah, yaitu: fitur CAP dengan ukuran 256 untuk pendekatan *grid-based* dan fitur HOG dengan ukuran 594 untuk pendekatan BoFC. Sedangkan fitur Color HIST dengan ukuran yang paling besar pada kedua pendekatan menunjukkan tingkat kontribusi yang secara umum paling tinggi. Pemilihan kombinasi fitur mempertimbangkan tingkat kontribusi keseluruhan yang ditunjukkan pada Tabel.3. Berdasarkan data pada Tabel 3, maka pada kombinasi pendekatan *grid-based* dan BoFC, untuk fitur MLBP dan HOG menggunakan fitur dari pendekatan *grid-based*, sedangkan fitur Color HIST dan CAP menggunakan fitur dari pendekatan BoFC. Perubahan dilakukan pada ekstraksi fitur HOG untuk meningkatkan kontribusi dari fitur HOG.

Tabel 3 Perbandingan Tingkat Kontribusi Fitur pada Pendekatan Grid dan BoFC pada Klasifikasi Data Demografi

Jenis Fitur	Grid-based		BoFC	
	Ukuran Fitur	Tingkat Kontribusi	Ukuran Fitur	Tingkat Kontribusi
MLBP	944	2,37%	649	1,65%
HOG	1.350	1,51%	594	0,13%
Color HIST	2.240	5,80%	1.540	5,94%
CAP	256	0,70%	704	2,78%

Sehingga representasi fitur baru hasil kombinasi dari pendekatan *grid* dan BoFC memiliki ukuran sebesar 4.532, yang terdiri atas: MLBP (944), HOG (1.344), Color HIST (1540) dan CAP (704). Untuk memudahkan dalam penyebutan, fitur kombinasi ini disebut dengan Kompak-Gabungan-Grid-BoFC. Perbandingan kinerja dari fitur baru dengan dua fitur awal dalam klasifikasi data demografi dapat dilihat pada Tabel IV-13.

Tabel.4 Perbandingan Akurasi Klasifikasi Data Demografi untuk Tiga Variasi Representasi Fitur

Tipe Fitur	Gender	Kelompok Usia	Etnis
Kompak-Gabungan-agarid	91,67%	60,71%	81,19%
Kompak-Gabungan-BoFC	91,24%	60,88%	82,34%
Kompak-Gabungan-Grid-BoFC menggunakan fitur HOG awal	92,48%	61,70%	82,30%
Kompak-Gabungan-Grid-BoFC	92,53%	62,08%	82,88%

Representasi fitur baru hasil kombinasi, yaitu Kompak-Gabungan-Grid-BoFC, menghasilkan akurasi paling tinggi pada setiap klasifikasi data demografi, yaitu sebesar 92,53%, 62,08% dan 82,88% untuk klasifikasi gender, kelompok usia dan etnis. Kompak-Gabungan-Grid-BoFC mewarisi tingkat diskriminasi dari Kompak-Gabungan dan Kompak-Gabungan-BoFC sehingga memiliki kinerja akurasi yang tinggi untuk setiap jenis klasifikasi data demografi.

4.3 Analisis Skema Pembobotan

Pada eksperimen ini dilakukan analisis pembobotan dalam proses penggabungan, dengan pedoman bobot adalah akurasi ketika sebuah fitur digunakan secara mandiri dalam proses klasifikasi. Nilai bobot untuk setiap fitur dan skema representasi fitur dapat dilihat pada Tabel 5.

Tabel 5 Hasil Perhitungan Bobot untuk setiap Fitur pada Tiga Variasi Representasi Fitur Berdasarkan Akurasi Klasifikasi Fitur Tunggal

Tipe fitur	Grid-Based			BoFC			Grid-BoFC		
	Gender	Kelompok Usia	Etnis	Gender	Kelompok Usia	Etnis	Gender	Kelompok Usia	Etnis
MLBP	0,25	0,25	0,24	0,25	0,25	0,25	0,24	0,24	0,24
HOG	0,24	0,24	0,23	0,24	0,24	0,23	0,25	0,25	0,25
Color Hist	0,25	0,25	0,26	0,25	0,24	0,25	0,25	0,24	0,25
CAP	0,24	0,24	0,25	0,24	0,24	0,25	0,24	0,24	0,25

Dari Tabel 5, terlihat bahwa bobot untuk setiap fitur dalam klasifikasi gender, kelompok usia dan etnis relatif sama karena kinerja akurasi dari setiap fitur tidak memiliki selisih yang signifikan. Berdasarkan kondisi ini dan mempertimbangkan aspek komputasi, maka dalam skema pembobotan yang digunakan adalah skema pembobotan seragam dengan setiap jenis fitur dinilai memiliki tingkat kepentingan yang sama.

4.4 Pengujian Pada Set Uji dan Perbandingan Dengan Penggunaan PCA

E Pengujian pada set uji bertujuan untuk melihat kemampuan generalisasi dari Kompak-Gabungan-untuk data yang belum diketahui (*unseen data*). Berdasarkan hasil pengujian pada Tabel IV.15, terlihat bahwa kemampuan generalisasi dari model SVM dan representasi fitur dapat dinyatakan baik, karena hasil akurasi pada set uji dan set validasi tidak terdapat perbedaan yang signifikan untuk klasifikasi gender, kelompok usia dan etnis.

Untuk memberikan pandangan yang komprehensif, dalam pengujian ini dilakukan perbandingan kinerja akurasi antara klasifikasi menggunakan usulan representasi fitur dengan hanya menggunakan satu *handcrafted feature* dan menggunakan gabungan fitur tanpa proses kompak, hasil pengujian dapat dilihat pada Tabel 6.

Tabel 6 Perbandingan Tiga Usulan Representasi Fitur dengan *single handcrafted feature* dan Gabungan Fitur Optimum pada Data Uji Klasifikasi Data Demografi

No	Representasi Fitur	Ukuran Fitur	Akurasi		
			Gender	Kelompok Usia	Etnis.
1	Kompak-Gabungan-AVG	4.790	91,03%	60,64%	82,11%
2	Kompak-Gabungan-BoFC-AVG	3.487	90,41%	61,63%	81,80%
3	Kompak-Gabungan-Grid-BoFC-AVG	4.532	91,55%	61,70%	83,32%
3	MLBP [25x25]	15.104	90,69%	61,59%	80,96%
4	HOG [25x25]	13.824	90,05%	59,15%	78,79%
5	Color HIST [25x25]	15.104	88,49%	56,97%	78,36%
6	CAP [50x50]	4.049	89,01%	58,87%	79,20%
7	Gabungan-Optimum-1	13.976	91,14%	60,61%	82,32%
8	Gabungan -Optimum-2	29.720	91,61%	62,97%	83,15%

Hasil pengujian dalam Tabel 6 menunjukkan, secara umum penggunaan multi-fitur baik melalui mekanisme reduksi fitur ataupun melakukan penggabungan langsung terbukti meningkatkan akurasi klasifikasi data demografi. Namun, perlu dipertimbangkan peningkatan akurasi dengan peningkatan jumlah ciri. Dari hasil eksperimen, menunjukkan bahwa tiga variasi representasi fitur yang meliputi Kompak-Gabungan-AVG, Kompak-Gabungan-BoFC-AVG dan Kompak-

Gabungan-Grid-BoFC-AVG memberikan kinerja akurasi yang bersifat moderat dari sisi peningkatan akurasi dan ukuran fitur.

Efektivitas strategi representasi fitur kompak-gabungan dibandingkan dengan algoritma pengurangan fitur konvensional yang terbukti yaitu PCA. Pada pengujian ini, metode PCA digunakan untuk menghasilkan fitur kompak yang sebanding dengan tiga representasi fitur, yaitu:

1. Dilakukan proses reduksi dimensi dengan PCA pada Gabungan-AVG sehingga ukuran fitur menjadi 4.790 dan disebut dengan Gabungan-AVG+PCA,
2. Dilakukan proses reduksi dimensi dengan PCA pada Gabungan-BoFC-AVG sehingga ukuran fitur menjadi 3.487 dan disebut dengan Gabungan-BoFC-AVG+PCA.
3. Dilakukan proses reduksi dimensi dengan PCA pada Gabungan-Grid-BoFC-AVG sehingga ukuran fitur menjadi 4.532 dan disebut dengan Gabungan-Grid-BoFC-AVG+PCA,

Tiga fitur hasil reduksi dengan PCA digunakan untuk melatih model klasifikasi SVM untuk klasifikasi data demografi dan diujikan pada set uji. Hasil perbandingan akurasi klasifikasi dari tiga representasi fitur menggunakan pendekatan kompak usulan dengan PCA dapat dilihat pada Tabel 7.

Tabel 7 Perbandingan Akurasi Klasifikasi Data Demografi untuk Tiga Variasi Representasi Fitur dengan PCA dalam %

ID	Tipe Fitur	Gender	Kelompok Usia	Etnis
[A]	Kompak-Gabungan-AVG	91,03	60,64	82,11
[B]	Gabungan-AVG + PCA	90,52	60,07	81,24
Selisih [A]-[B]		0,52	0,57	0,86
[C]	[C] Kompak-Gabungan-BoFC-AVG	90,41	61,63	81,80
[D]	[D]Gabungan-BoFC-AVG + PCA	90,69	60,86	82,09
Selisih [C]-[D]		-0,29	0,77	-0,29
[E]	Kompak-Gabungan-Grid-BoFC-AVG	91,55	61,70	83,32
[F]	Gabungan-Grid-BoFC-AVG +PCA	91,72	61,72	83,31
Selisih [E]-[F]		-0,16	-0,02	0,01

Data pada Tabel 7, menunjukkan bahwa strategi menghasilkan fitur kompak yang diusulkan pada penelitian Disertasi ini dapat menghasilkan akurasi klasifikasi yang dapat dikatakan sebanding dengan metode reduksi dimensi PCA; ini menunjukkan bahwa fitur kompak-gabungan memiliki informasi diskriminatif yang sebanding dengan hasil dari PCA. Selain itu, metode menghasilkan fitur kompak usulan

dilakukan dengan menggunakan pemrosesan data tunggal sehingga memberikan pemahaman yang lebih mudah tentang proses generasi data.

4.5 Eksperimen dan Pengujian parameter SVM

Metode klasifikasi yang digunakan dalam eksperimen sebelumnya adalah SVM Multi-kelas dengan skema OVA (One Versus All). Parameter pembelajaran SVM yang digunakan adalah *kernel polynomial* dengan orde 3, $C=1$, dan skala *kernel* diatur sebagai otomatis (menggunakan prosedur heuristik untuk memilih nilai skala dengan angka acak diatur menjadi 5). Untuk menyediakan analisis komprehensif terkait konfigurasi model klasifikasi SVM, dilakukan pengamatan terhadap jenis skema, *kernel* dan nilai C. Jenis skema yang diujikan meliputi OVA dan OVO, sedangkan untuk jenis *kernel* yang diujikan meliputi *kernel polynomial* orde=3, dan *Radial Basis Function* (RBF). Untuk nilai C yang diujikan yaitu: 0.5, 1, 1,5, 2 dan 2.5. Data yang digunakan untuk pelatihan adalah set latih dan evaluasi pada set validasi.

Berdasarkan hasil eksperimen hasil kinerja akurasi terbaik untuk setiap representasi fitur dan jenis klasifikasi berbeda-beda, parameter terbaik SVM untuk setiap representasi fitur kemudian diterapkan pada set uji, dengan hasil dapat dilihat pada Tabel 8.

Tabel 8 Perbandingan Tiga Usulan Representasi Fitur pada Data Uji Klasifikasi Data Demografi

No	Jenis Klasifikasi	Parameter SVM	Waktu Pelatihan (detik)*	Waktu Pengujian (detik)*	Akurasi
1	Gender	SVM OVA Poly=3, C= 0,5	37,68	17,03	91,54%
2	Kelompok Usia	SVM OVO Poly=3, C= 1	90,77	80,91	63,21%
3	Etnis	SVM OVA Poly=3, C= 0,5	171,34	73,73	83,20%
*menggunakan processor Intel(R) Core(TM) i7-9700F CPU @ 3.00GHz 3.00 GHz dengan RAM 16GB. hasil rata-rata dari 5 kali pengulangan, fitur telah diekstrak dan siap digunakan					

Berdasarkan hasil pengujian parameter SVM pada Tabel 8, waktu pengujian dengan menggunakan set uji sebanyak 5.577 untuk klasifikasi gender, kelompok usia dan etnis masing-masing adalah 17,03 detik (327 data per-detik) , 80,91 detik (69 data per-detik) dan 73,73 detik (76 data per-detik). Jika proses klasifikasi dilakukan secara serial maka kecepatan pemrosesan berkisar pada 32 data/detik. Hasil ini menunjukkan bahwa solusi yang diusulkan memiliki kecepatan pemrosesan yang cepat untuk menghasilkan tiga label klasifikasi data demografi.

Berdasarkan hasil pengujian parameter SVM, representasi fitur dengan *grid-based* dan *grid-BoFC* menghasilkan kinerja terbaik dengan menggunakan parameter SVM yang sama untuk setiap jenis klasifikasi. Jika dilihat dari fitur pembentuk *grid-BoFC* dengan total fitur 4.532, sebanyak 2.288 fitur berasal dari pendekatan *grid-based* yaitu fitur MLBP (944) dan HOG (1.344), dan sebanyak 2.244 berasal dari pendekatan BoFC, yaitu: Color HIST (1.540) dan CAP (704). Perbedaan jumlah proporsi fitur pembentuk *grid-BoFC* tidak berbeda secara signifikan, yaitu sebanyak 44 dari 4.532. Namun dari hasil percobaan terkait parameter SVM fitur *grid-BoFC* cenderung lebih dekat ke fitur pendekatan *grid-based*. Hal ini perlu dikaji lebih lanjut khususnya terkait skema pembobotan dalam penggabungan fitur.

4.6 Analisis Kesalahan Dan Uji Hipotesis

Dalam penelitian ini, analisis kesalahan pengujian dilakukan dengan menggunakan *confusion matrix* serta nilai *Precision*, *Recall*, dan *F1-Score* untuk setiap kelas pada setiap jenis klasifikasi. Analisis dilakukan pada hasil prediksi dari set data uji dengan representasi fitur kombinasi *grid-BoFC* menggunakan parameter SVM terbaik hasil eksperimen sebelumnya.

Hasil eksperimen menunjukkan bahwa kinerja klasifikasi gender dinyatakan sangat baik dengan nilai *F1-Score* 0,9152 (>0.9) dengan tingkat kesalahan antara kelas ‘male’ dan ‘female’ relatif seimbang. Oleh karena itu, dilakukan pemeriksaan kesalahan yang ditinjau dari nilai atribut demografi yang lain, yaitu kelompok usia dan etnis. Ditemukan bahwa proporsi kesalahan terbesar pada klasifikasi gender dilihat dari kelompok usia berada pada kelompok ‘baby’. Hasil ini menunjukkan bahwa pada kelompok ‘baby’ tingkat kesulitan dalam melakukan klasifikasi gender menjadi lebih tinggi, karena pada umumnya gambar terkadang ambigu sehingga tidak dapat memberikan kepastian dalam klasifikasi gender (Karkkainen dan Joo, 2021). Ditinjau dari label etnis, kesalahan klasifikasi gender terbesar adalah pada data dengan etnis ‘White’. Hal ini dikarenakan jumlah data etnis ‘White’ yang lebih banyak, namun jika jumlah kesalahan dilihat dari jumlah kesalahan berbanding dengan jumlah data label etnis, maka data dengan label etnis ‘others’ memiliki kontribusi terbesar.

Pada kelompok usia, kelompok usia “baby” memiliki persentase akurasi tertinggi dengan *F1-Score* 0,6250 (dapat diterima). hal ini dikarenakan perbedaan signifikan antara fitur kelompok usia “baby” dibandingkan dengan kelompok usia yang lain. Kelompok ‘teenager’ memiliki performa yang buruk dengan *F1-Score* 0,3877, hal ini dikarenakan terjadi pergeseran prediksi menuju ke 1-kelas tetangga, dengan proporsi kesalahan dari kelas ‘teenager’ ke kelas ‘young’ sebesar 43%. Hal ini diperkirakan terjadi karena ketidakseimbangan data dan sejalan dengan teori perubahan wajah berdasarkan usia yaitu terdapat perubahan yang sangat minimal setelah fase “teenager” ke atas sehingga informasi diskriminasi menjadi minimal.

Hasil analisis kesalahan pada klasifikasi etnis menunjukkan bahwa kombinasi fitur global dan lokal yang diusulkan memiliki nilai F1-Score rata-rata sebesar 0,7332 (baik). Namun, metode yang diusulkan memiliki performa yang buruk untuk kelas 'Others'; alasan utama dari kekurangan ini adalah ketidakseimbangan data dan label yang ambigu. Label yang ambigu, seperti yang disebutkan dalam deskripsi data set, bahwa kelas 'Others' berisi beberapa etnis, yaitu 'Hispanic,' 'Latino,' dan 'Middle Eastern'.

Untuk mengkonfirmasi tercapainya hipotesis dalam penelitian Disertasi, dilakukan uji hipotesis dilakukan terhadap kinerja akurasi pada set data uji dengan mid-p-value McNemar's Test dengan nilai $\alpha = 0,05$. Adapun hipotesis dalam penelitian disertasi ini adalah sebagai berikut:

- Hipotesis Awal (H0): Model klasifikasi dengan representasi fitur kombinasi memiliki kinerja akurasi yang lebih besar atau sama dengan model klasifikasi dengan representasi grid-based (global fitur) dan representasi BoFC (lokal fitur). pada klasifikasi data demografi.
- Hipotesis Alternatif (H1): Model klasifikasi dengan representasi fitur kombinasi memiliki kinerja akurasi kurang dari model klasifikasi dengan representasi grid-based (global fitur) dan representasi BoFC (lokal fitur). pada klasifikasi data demografi.

Hasil uji hipotesis menghasilkan nilai p-value lebih besar dibandingkan dengan level signifikan $\alpha = 0,05$, sehingga hipotesis penelitian bahwa model klasifikasi data demografi dengan representasi fitur kombinasi memiliki kinerja akurasi yang lebih besar atau sama dengan model klasifikasi dengan representasi grid-based (global fitur) ataupun representasi BoFC (lokal fitur) diterima.

4.7 Pengujian *Cross-Dataset*

Pada pengujian *cross-dataset*, empat model dilatih dan diuji secara berpasangan. Model_1 dilatih dan diuji pada UTKFace *Preprocessing-A*, Model_2 dilatih pada UTKFace *Preprocessing-A* dan diuji pada Fair Face Subset-A, Model_3 dilatih dan diuji pada Fair Face Subset-A, dan Model_4 dilatih pada Fair Face Subset-A dan diuji pada UTKFace *Preprocessing-A*. Pengujian dilakukan dengan menggunakan konfigurasi fitur Kompak-Gabungan- Grid-BoFC-AVG. Hasil eksperimen *cross-dataset* dapat dilihat pada Tabel 9.

Tabel 9 menunjukkan bahwa model yang dilatih dengan data set yang sama dengan data set pengujian mencapai akurasi terbaik. Misalnya, untuk pengujian dengan data uji dari data set UTKFace-A: Model_1 (dilatih dengan UTKFace-A) menghasilkan akurasi pengenalan gender, kelompok umur dan etnis adalah 92,09%, 77,84% dan 89,61%, jauh melebihi Model_4 (dilatih Fair Face-A) yang mencapai 89,30%, 64,88% dan 78,77%. Demikian juga ketika data uji yang digunakan adalah data uji dari data

set Fair Face-A, maka Model_3 (dilatih dengan Fair Face -A) menghasilkan akurasi pengenalan gender, kelompok usia dan etnis adalah 81,25%, 63,95%, dan 78,00%, jauh melebihi Model_2 (dilatih pada UTKFace-A) yang mencapai 74,56%, 51,33%, dan 60,34%. Selain itu, eksperimen *cross-dataset* menunjukkan bahwa akurasi dari model yang dilatih dengan UTKFace-A menunjukkan kinerja yang buruk ketika diuji pada data set yang berbeda dibandingkan dengan model yang dilatih dengan Fair Face-A.

Tabel 9 Hasil Pengujian *Cross-Dataset* untuk Klasifikasi Data Demografi

Model	Keterangan	Akurasi Klasifikasi		
		Gender	Klmpk Usia	Etnis
Model_1	Latih: UTK dan Uji: UTK	92,09%	77,84%	89,61%
Model_2	Latih: UTK dan Uji: Fair Face	74,56%	51,33%	60,34%
Model_3	Latih: Fair Face dan Uji: Fair Face	81,25%	63,95%	78,00%
Model_4	Latih: Fair Face dan Uji: UTK	89,30%	64,88%	78,77%

Secara keseluruhan, generalisasi data set dievaluasi dari akurasi rata-rata model yang dilatih dengan data set tersebut. Seperti yang terlihat pada Tabel 9, akurasi rata-rata untuk dua penggunaan data uji pengenalan gender kelompok usia dan etnis pada model yang dilatih dengan UTKFace-A adalah 83,32%, 64,59%, dan 74,97% sedangkan untuk model dengan Fair Face -A adalah 85,28%, 64,42%, dan 78,39%. Hasil ini menunjukkan bahwa data set Fair Face -A memiliki generalisasi yang lebih baik daripada UTKFace-A ketika digunakan dalam *cross-dataset*. Namun, investigasi lebih lanjut perlu dilakukan untuk mengukur generalisasi data set yang digunakan untuk evaluasi *cross-dataset*.

Konfigurasi dari fitur Kompak-Gabungan- Grid-BoFC-AVG yang diperoleh melalui pengujian awal menunjukkan generalisasi yang baik, hal ini dapat dilihat dari akurasi Model_3, yang menggunakan konfigurasi fitur Kompak-Gabungan- Grid-BoFC-AVG yang diperoleh dari UTKFace, mencapai akurasi klasifikasi etnis sebesar 78,00%, lebih tinggi daripada akurasi yang dilaporkan sebesar 75,40% oleh Karkkainen dan Joo, (2021) yang dievaluasi pada seluruh data set. Kondisi ini perlu dikaji lebih lanjut karena kami membatasi jumlah data yang digunakan sebanyak yang ada di UTKFace, yang membuat data untuk membangun model memiliki sampel yang tidak mencukupi untuk mengatasi variasi dalam data set Fair Face.

4.8 Perbandingan Pengujian dengan Solusi State of The Art

Pada penelitian Disertasi diusulkan penggabungan fitur global (*grid-based*) dengan fitur lokal (BoFC) untuk representasi fitur dalam klasifikasi data demografi yang

meliputi gender, kelompok usia dan etnis. Empat *handcrafted features* yaitu: MLBP, HOG, Color HIST, dan CAP menjadi dasar dari representasi fitur, dengan konfigurasi terbaik yang diperoleh yaitu fitur dengan dimensi sebesar 4.532, dengan 2.288 fitur berasal dari pendekatan *grid-based* yaitu fitur MLBP (944) dan HOG (1.344), dan sebanyak 2.244 berasal dari pendekatan BoFC, yaitu: Color HIST (1.540) dan CAP (704). Kelebihan dari sisi kebutuhan sumber daya komputasi dicapai dengan menggunakan ukuran representasi fitur minimal dengan hasil akurasi tinggi. Meskipun, perbandingan yang adil dan tepat dengan hasil penelitian lain sulit dicapai karena perbedaan protokol validasi, metode ekstraksi fitur, dan model pembelajaran yang berbeda. Tabel 7 memberikan gambaran posisi relatif dari metode yang diusulkan dengan hasil penelitian lain yang menggunakan data set UTKFace untuk klasifikasi. Hasil penelitian Disertasi menerapkan protokol *hold-out* 75% set latihan dan 25% set uji. Secara umum, metode usulan representasi fitur mencapai akurasi yang kompetitif untuk klasifikasi kelompok usia dan etnis dengan akurasi lebih dari 60%, 80%. Hal ini dapat menjadi solusi alternatif yang menjanjikan dengan sumber daya yang lebih terjangkau dibandingkan pendekatan *deep learning*.

Tabel.10 Perbandingan Komparatif Metode Usulan dengan Solusi *State of The-Art* untuk Klasifikasi Data Demografi pada Data Set UTKFace

Makalah	Metode	Ukuran Fitur	Akurasi dalam %		
			Gender	Kelompok Usia	Etnis
(Sundriyal dan Singh, 2020)	Multi-Task Leaning, pre-trained ResNet50	N/A	98,47	N/A	87,56
	Single Task ResNet50	N/A	93,55	N/A	80,61
(Savchenko, 2019)	Multi-Output ConvNet	N/A	91,95	62,74	N/A
(Hamdi dan Moussaoui, 2020)	CNN Based	8.192*	90.3	65.92	78,88
(Karkkainen dan Joo, 2021)	Res-Net34	N/A	92,50	61,70	83,09
(Das dkk., 2019)	FaceNet	N/A	91,20	56,90	85,10
	MTCNN	N/A	98,23	70,10	90,10
Usulan Representasi Fitur	Grid-Based	4.790	90,91 SVM OVA Poly=3, C=0.5	61,75 (7 kelas) SVM OVO Poly=3, C=1	82,07 (5 kelas)

Makalah	Metode	Ukuran Fitur	Akurasi dalam %		
			Gender	Kelompok Usia	Etnis
					SVM OVA Poly=3, C= 0,5
	BoFC SVM RBF, C=2,5	3.487	90,44 SVM OVA RBF, C=2,5	63,39 (7 kelas) SVM OVO RBF, C=2,5	82,11 (5 kelas) SVM OVA RBF, C=2,5
	Grid-BoFC	4.534	91,54 SVM OVA Poly=3, C= 0,5	63,21 (7 kelas) SVM OVO Poly=3, C= 1	83,20 (5 kelas) SVM OVA Poly=3, C= 0,5
			92,09**	77,84** (5 kelas)	89,61** (4 kelas)

*estimasi berdasarkan penjelasan di makalah, untuk *deep learning* adalah luaran dari *max pool layer* terakhir; ** hasil pengujian pada skenario *cross-dataset*

5. Kesimpulan atau Kontribusi Ilmiah

Kesimpulan yang dapat diambil dalam penelitian disertasi ini adalah: Representasi fitur dengan untuk menghasilkan fitur Kompak-Gabungan menyediakan fitur kompak dan informatif serta memiliki kinerja yang kompetitif. Penggabungan fitur global dan lokal yang didasarkan pada empat *handcrafted feature* MLBP, HOG, Color Histogram, dan CAP, menghasilkan peningkatan akurasi pada tiga klasifikasi data demografi dengan ukuran ciri yang jauh lebih kecil jika dibandingkan dengan penggunaan satu fitur *handcrafted*. Proses reduksi fitur dengan menggunakan nilai maksimal dan rata-rata menunjukkan hasil yang komparatif dibandingkan dengan reduksi fitur/dimensi yang banyak digunakan yaitu PCA. Kelebihan pendekatan reduksi fitur yang diusulkan adalah proses yang mudah dipahami dalam pemrosesan data serta dapat mempertahankan makna semantik yang dimiliki oleh *handcrafted feature* (jika ada). Namun, pendekatan reduksi fitur yang diusulkan belum memiliki parameter kontrol terhadap tingkat reduksi sehingga kurang fleksibel.

Penelitian Disertasi ini menyediakan tiga alternatif representasi fitur yang dapat digunakan dengan mempertimbangkan pose gambar wajah dan batasan ukuran fitur. Dari hasil percobaan apabila pose wajah yang diproses menghadap ke depan dan komponen wajah dapat terdeteksi, maka pendekatan holistik dengan menggabungkan analisis global (sub-area dengan *grid-based*) dan analisis lokal (sub-area dengan BoFC) menghasilkan representasi fitur dengan akurasi terbaik. Namun apabila komponen wajah tidak dapat terdeteksi dengan sempurna maka representasi fitur yang sebaiknya digunakan adalah sub area berbasis *grid*.

Dari hasil pengujian, menggunakan konfigurasi parameter ekstraksi fitur yang ditetapkan, fitur MLBP dan Color HIST memberikan kontribusi yang lebih tinggi dibandingkan dengan fitur HOG dan CAP. Namun perlu dilakukan kajian mendalam terkait konfigurasi parameter ekstraksi fitur untuk HOG dan CAP. Ditinjau dari tiga jenis klasifikasi data demografi, usulan representasi fitur menunjukkan potensi khususnya pada klasifikasi kelompok usia dan etnis. Namun, untuk klasifikasi gender, usulan representasi fitur masih belum dapat memberikan tingkat akurasi yang sepadan dengan pendekatan *deep learning*.

Hasil penelitian Disertasi ini menyediakan solusi yang kompetitif untuk melakukan klasifikasi terhadap tiga data demografi berbasis *handcrafted feature* yang membutuhkan sumber daya komputasi yang rendah sehingga dapat diterapkan atau ditanamkan pada perangkat khusus.

Penelitian ini menghasilkan kontribusi ilmiah, yaitu:

1. Mengusulkan peningkatan kinerja klasifikasi melalui strategi kombinasi antara fitur global dan lokal dengan melihat kontribusi fitur dalam klasifikasi data demografi. Fitur global dan lokal merupakan hasil penggabungan empat *handcrafted feature* yang mengadopsi persepsi manusia untuk klasifikasi data demografi
2. Menghasilkan usulan tahapan pembentukan penggabungan fitur, dengan fitur yang digabungkan merupakan hasil reduksi fitur dengan proses reduksi yang hanya memanfaatkan informasi dari data yang diproses, tidak memerlukan informasi dari data lainnya atau set data secara keseluruhan. .

6. Tindak Lanjut

Berdasarkan eksperimen, kinerja akurasi yang dicapai dalam penelitian Disertasi masih belum maksimal untuk klasifikasi multi-kelas yang mengandung unbalanced data yaitu: kelompok usia dan etnis. Pengembangan selanjutnya dapat dilakukan dengan menambahkan mekanisme untuk mengatasi *unbalanced* data seperti metode sampling dan augmentasi data, serta menggunakan model klasifier yang lebih sesuai untuk klasifikasi multi-kelas seperti jaringan syaraf tiruan.

Pada penelitian Disertasi ini, representasi fitur yang dihasilkan digunakan untuk tiga jenis klasifikasi. Pengembangan selanjutnya dapat dilakukan dengan menambahkan mekanisme pemilihan fitur yang disesuaikan dengan jenis klasifikasi. Untuk lebih mendapatkan analisis yang stabil serta pengujian generalisasi model, penelitian ke depan dapat menggunakan protokol *k-fold cross validation*.

Kinerja dari representasi fitur Kompak-Gabungan sangat bergantung pada kinerja *base-line* dari fitur yang digunakan, hal ini terlihat dari hasil akurasi berkisar $\pm 2\%$ dari akurasi *base line*. Untuk meningkatkan akurasi dapat dilakukan melalui eksplorasi konfigurasi parameter fitur dasar.

Riwayat Hidup



Tjokorda Agung Budi Wirayuda, S.T., M.T.

Kandidat Doktor lahir di Denpasar, 19 Mei 1983, putra ke-3 dari Bapak Tjokorda Bagus Budiana dan Ibu Tjokorda Istri Manik. Telah berkeluarga dengan istri bernama Cokorda Istri Anik Parasari dan memiliki 3 anak : Tjokorda Gde Avandhira Budi Prawira, Tjokorda Istri Andhira Divyagita Prawira, dan Tjokorda Istri Alindhira Gauridiva Prawira. Kandidat Doktor menyelesaikan pendidikan di SD No. 3 Dangin Puri kemudian melanjutkan ke SMP 1 Denpasar, SMAN 1 Denpasar dan SMAN 1 Yogyakarta. Kandidat Doktor memperoleh gelar Sarjana Teknik (S.T.) dalam program Teknik Informatika dari STT Telkom pada tahun 2006. Gelar Magister Teknik (M.T) Informatika diperoleh dari STEI-ITB pada tahun 2010. Kandidat Doktor bergabung menjadi Dosen pada Fakultas Informatika, Universitas Telkom sejak tahun 2006 sampai dengan sekarang. Bidang kajian keilmuan yang didalami meliputi: *Computer Vision System Recognition Biometric Watermarking and Data Hiding*

Daftar Publikasi Terkait Penelitian

Supriana, Iping & Kistijantoro, Achmad Imam & Wirayuda, Tjokorda Agung Budi & Niwanputri, Ginar. (2018). Bag of Facial Components: A Data Enrichment Approach for Face Image Processing. 10.1109/ICAICTA.2018.8541324.
Wirayuda, Tjokorda Agung Budi & Munir, Rinaldi & Kistijantoro, Achmad Imam. (2023). Compact-Fusion Feature Framework for Ethnicity Classification. Informatics. 10. 51. 10.3390/informatics10020051.

Ucapan Terima Kasih

Pertama-tama, penulis mengucapkan terima kasih kepada Prof. Iping Supriana S. (Alm.), Bapak Dr. Rinaldi Munir dan Bapak Achmad Imam Kistijantoro, Ph.D selaku pembimbing yang telah memberi bimbingan, nasihat, saran dan kritik dalam menyelesaikan penelitian Disertasi ini. Terima kasih kepada seluruh sivitas akademik ITB khususnya STEI, atas bantuan, dukungan, serta layanan yang prima selama penulis mengikuti program Doktor.

Menyelesaikan program Doktor merupakan langkah awal bagi Penulis untuk berkiprah sebagai Dosen dalam mengembangkan ilmu pengetahuan; Terima kasih kepada seluruh rekan-rekan Universitas Telkom atas dorongan dan semangat yang diberikan selama penulis menyelesaikan penelitian Disertasi ini.

Terima kasih kepada keluarga tersayang, Papah, Ibu, Istri serta anak-anak semua, atas dukungan, motivasi serta inspirasi dalam suka-duka menyelesaikan pendidikan Doktor