

Optimasi LBP Menggunakan BPSO untuk Klasifikasi Jenis Kelamin

Tugas Akhir

diajukan untuk memenuhi salah satu syarat

memperoleh gelar sarjana

dari Program Studi Teknologi Informasi

Fakultas Informatika

Universitas Telkom

1301140381

Adam Geraldly Katab



Program Studi Sarjana Teknologi Informasi

Fakultas Informatika

Universitas Telkom

Bandung

2018

LEMBAR PENGESAHAN

Optimasi LBP Menggunakan BPSO untuk Klasifikasi Jenis Kelamin

Optimizing LBP with BPSO for Gender Classification

NIM: 1301140381

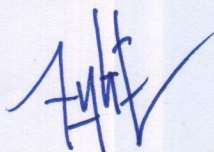
Adam Gerald Katab

Tugas akhir ini telah diterima dan disahkan untuk memenuhi sebagian syarat memperoleh gelar pada Program Studi Sarjana Teknologi Informasi
Fakultas Informatika
Universitas Telkom

Bandung, 16 Juni 2018

Menyetujui

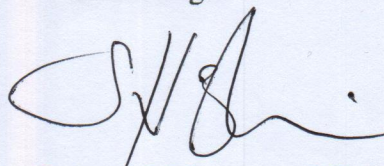
Pembimbing I



Anditya Arifianto, S.T., M.T.

NIP: 14890028

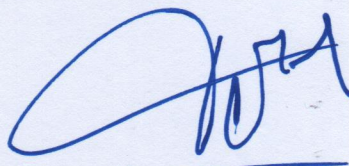
Pembimbing II



Febryanti Sthevanie, S.T., M.T.

NIP: 14880014

Ketua Program Studi
Sarjana Teknologi Informasi,



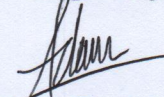
Said Al Faraby, S.T., M.Sc.

NIP: 15890019

Dengan ini saya, Adam Geraldly Katab, menyatakan sesungguhnya bahwa Tugas Akhir saya dengan judul "**Optimasi LBP Menggunakan BPSO untuk Klasifikasi Jenis Kelamin**" beserta dengan seluruh isinya adalah merupakan hasil karya sendiri, dan saya tidak melakukan penjiplakan yang tidak sesuai dengan etika keilmuan yang berlaku dalam masyarakat keilmuan. Saya siap menanggung resiko/sanksi yang diberikan jika dikemudian hari ditemukan pelanggaran terhadap etika keilmuan dalam buku TA atau jika ada klaim dari pihak lain terhadap keaslian karya.

Bandung, 16 Juni 2018

Yang Menyatakan,



Adam Geraldly Katab

Optimasi LBP Menggunakan BPSO untuk Klasifikasi Jenis Kelamin

Adam Gerald Katab¹, Anditya Arifianto², Febryanti Sthevanie³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹adamgeraldy@students.telkomuniversity.ac.id, ²anditya@telkomuniversity.ac.id,

³sthevanie@telkomuniversity.ac.id

Abstrak

Feature selection (seleksi fitur) adalah metode yang sangat penting dalam pemecahan permasalahan klasifikasi, karena metode ini mengambil bagian-bagian dari sebuah gambar yang dianggap penting atau relevan, untuk kemudian diklasifikasikan ke dalam kelasnya. Di tulisan ini, penulis mengajukan metode seleksi fitur menggunakan *grid-based Local Binary Patterns* (LBP), dimana sebuah gambar dipisah ke dalam beberapa blok grid untuk kemudian diekstrak histogram fiturnya, yang kemudian digabungkan menjadi satu histogram fitur. Penulis juga mengajukan metode optimasi seleksi fitur dengan menggunakan *Particle Swarm Optimization* (PSO). PSO mengurangi dimensi fitur yang sebelumnya sudah dipilih oleh LBP, untuk mengurangi waktu yang digunakan dalam proses klasifikasi. Dataset yang digunakan adalah *Color FERET Database*. Untuk proses klasifikasi, penulis menggunakan algoritma *k-Nearest Neighbor* (K-NN). Melalui penelitian ini, dapat disimpulkan bahwa PSO dapat mengurangi waktu *runtime* sampai dengan 50,1%.

Kata kunci: local binary patterns, klasifikasi jenis kelamin, seleksi fitur, particle swarm optimization, k-nearest neighbor, color feret database

Abstract

Feature selection is a very important method in solving classification problems, because it will take a subset of relevant features from an image to be sent to the classifier algorithm. In this paper, we propose a grid-based Local Binary Patterns (LBP) where images are separated into multiple grids, from which histograms are extracted and concatenated. We also propose using Particle Swarms Optimization (PSO) to optimize the selected features to reduce its dimension and therefore reducing the time needed to solve the classification problem. The dataset used in this paper is the Color FERET Database. K-Nearest Neighbor (K-NN) is used as the classification algorithm. Through this paper, PSO is proven to have the ability to reduce the runtime by 50,1%.

Keywords: local binary patterns, gender classification, feature selection, particle swarm optimization, k-nearest neighbor, color feret database

1. Pendahuluan

1.1 Latar Belakang

Studi wajah manusia merupakan bidang yang mulai aktif didalami di bidang *Computer Vision* [1], termasuk juga pengenalan jenis kelamin secara otomatis, berdasarkan wajah manusia. Pengenalan jenis kelamin dapat diaplikasikan ke dalam berbagai bidang, seperti untuk *customer oriented advertising*, interaksi manusia dan komputer, dan lainnya. Terdapat dua cara utama yang digunakan dalam proses ekstraksi fitur, yaitu metode *geometric based* dan metode *appearance based* [2].

Pada penelitian yang dilakukan Khan et al. [2] *Bees Algorithm* (BA) dibandingkan dengan *Particle Swarm Optimization* (PSO), dan BA memiliki performansi yang lebih buruk bila dibandingkan dengan PSO, dengan akurasi terbaik 84,6% menggunakan BA dan *K-Nearest Neighbor* KNN, dan akurasi terbaik 85,2% menggunakan PSO dan KNN. Oleh karena itu, penulis menggunakan PSO pada penelitian ini sebagai optimasinya. K-NN dipilih karena sifatnya yang merupakan lazy learning algorithm, sehingga tidak membutuhkan pembuatan model yang bila dilakukan bersamaan dengan PSO akan menyebabkan meningkatnya waktu *runtime*.

Pada tulisan ini penulis melakukan prosedur klasifikasi jenis kelamin berdasarkan wajah dengan metode *geometric based*, di mana fitur gambar wajah telah diekstraksi dari beberapa *grids* pada wajah menggunakan *Local*

Binary Patterns (LBP). Fitur yang diekstraksi kemudian dikirimkan ke algoritma klasifikasi K-NN untuk pemecahan masalah klasifikasi jenis kelamin. Namun, hasil fitur yang didapat dari LBP masih memiliki dimensi yang tinggi sehingga mempengaruhi waktu yang dibutuhkan untuk pemecahan masalah. Oleh karena itu, penulis mengajukan metode klasifikasi dengan fitur yang dioptimasi menggunakan PSO.

Di akhir tulisan ini, penulis mencantumkan observasi perbandingan hasil pemecahan masalah klasifikasi jenis kelamin dengan K-NN tanpa optimasi, dan pemecahan yang menggunakan PSO sebagai algoritma optimasi.

1.2 Topik dan Batasannya

Permasalahan klasifikasi merupakan permasalahan yang sering dihadapi dalam studi *machine learning*. Sesuai namanya, permasalahan ini menuntut algoritma untuk memisahkan data ke dalam kelasnya yang sesuai. Permasalahan klasifikasi dapat dibagi menjadi klasifikasi dua kelas (atau klasifikasi biner), dan klasifikasi multi kelas. Di penelitian ini, penulis mengajukan metode pemecahan permasalahan klasifikasi biner, dengan dua kelas yaitu jenis kelamin pria dan wanita.

Dalam penelitiannya, Brown et al. [3] menyatakan bahwa bagian-bagian wajah (seperti alis, mata, hidung, dan lainnya) membawa lebih banyak informasi bila dilihat secara terpisah dibandingkan ketika wajah dilihat secara keseluruhan, dan Khan et al. [4] mengajukan sistem berbasis grid untuk melakukan pemecahan klasifikasi jenis kelamin.

Tentu saja, semakin banyak grid yang digunakan maka akan bertambah besar dimensi fitur gambar yang akan digunakan untuk pemecahan masalah. Hal ini dikarenakan setiap grid yang memiliki histogram sendiri kemudian digabung menjadi satu (*concatenate*), sehingga panjang histogram pun meningkat sesuai dengan banyaknya jumlah grid. Maka PSO mempunyai peran yang sangat penting di sini untuk melakukan optimasi terhadap fitur yang didapat dari LBP, sebelum dikirimkan ke K-NN sebagai algoritma klasifikasi.

Oleh karena itu, pada penelitian ini, penulis mengangkat tiga rumusan masalah yaitu:

1. Bagaimana implementasi PSO untuk pemecahan permasalahan klasifikasi jenis kelamin?
2. Bagaimana pengaruh jumlah grid terhadap pemecahan permasalahan klasifikasi jenis kelamin?
3. Bagaimana pengaruh PSO terhadap pemecahan permasalahan klasifikasi jenis kelamin?

Selain itu, terdapat beberapa batasan-batasan masalah pada penelitian ini untuk menyesuaikan kebutuhan penulis, yaitu:

1. Dataset yang digunakan adalah Color FERET database [5], yang merupakan dataset yang umum digunakan dalam penelitian terkait gambar wajah manusia.
2. Data yang digunakan adalah gambar wajah manusia yang menghadap depan.

1.3 Tujuan

Berdasarkan topik, rumusan masalah, dan batasan masalah di atas, penulis menetapkan tujuan penelitian ini sebagai berikut:

1. Implementasi PSO untuk melakukan optimasi terhadap LBP, dalam pemecahan permasalahan klasifikasi jenis kelamin.
2. Menganalisis pengaruh jumlah grid dalam permasalahan pemecahan jenis kelamin.
3. Menganalisis pengaruh PSO terhadap pemecahan permasalahan klasifikasi jenis kelamin.

1.4 Organisasi Tulisan

Penyusunan tulisan ini dilakukan sebagai berikut:

1. Pendahuluan: Pada bagian ini dijelaskan latar belakang, topik permasalahan, rumusan dan batasan masalah, serta tujuan penelitian.
2. Studi Terkait: Pada bagian ini dijelaskan studi-studi terkait yang membantu pengerjaan penelitian ini.
3. Sistem yang Dibangun: Pada bagian ini dijelaskan sistem yang dibangun untuk menyelesaikan penelitian ini.

4. Evaluasi: Pada bagian ini dijelaskan skenario-skenario pengujian yang disiapkan penulis untuk melakukan evaluasi terhadap penelitian yang dilakukan, beserta analisis terhadap evaluasi tersebut.
5. Kesimpulan: Pada bagian ini terdapat kesimpulan dan saran yang penulis sampaikan terkait penelitian ini.

2. Studi Terkait

Ojala, et al. [6] pertama kali memperkenalkan LBP pada tahun 1994. LBP versi pertama ini menggunakan *binary version* (0 dan 1) dalam sebuah 3×3 unit pixel untuk melakukan ekstraksi fitur. Satu blok LBP yang berukuran 3×3 akan dibandingkan dengan pixel tengahnya, untuk kemudian dirubah menjadi nilai biner 0 atau 1. Oleh karena itu, LBP hanya memiliki $2^8 = 256$ kemungkinan tekstur, dan merupakan metode yang *computationally simple*. Kelemahan utama pada versi LBP pertama ini adalah unit teksturnya yang tidak *circularly symmetric*.

Ojala, et al. [7] kemudian mengajukan ekstensi dari LBP, yaitu *Circular Local Binary Patterns*. Pada versi LBP ini, nilai pixel yang posisinya diagonal dari pixel di tengah akan diinterpolasi, sehingga blok LBP tidak akan berbentuk persegi, melainkan melingkar, sehingga tekstur unit LBP versi ini berbentuk lingkaran simetris. Hal ini memungkinkan ekstensi LBP lainnya yaitu LBP yang *rotation invariant*. Kelebihan utama Circular LBP adalah jarak setiap titik yang diambil dari pixel tengah selalu sama.

PSO merupakan teknik optimasi yang diperkenalkan oleh Kennedy dan Eberhart [8] pada tahun 1995. Pada prinsipnya, PSO dibuat berdasarkan perilaku hewan yang bergerak secara berkelompok, contohnya burung atau ikan: burung dapat terbang ke satu tujuan bersama-sama tanpa bertabrakan dikarenakan adanya kecerdasan kolektif, dan hal serupa juga ada pada ikan yang berenang bersama-sama. Kelebihan PSO dibandingkan algoritma optimasi lainnya adalah kemampuan partikelnya untuk bergerak dalam sebuah ruang solusi menuju solusi optimal, dan terkadang bergerak melebihi targetnya untuk mengeksplor ruang yang belum tersentuh oleh swarm tersebut.

Binary PSO [9] merupakan ekstensi PSO yang diajukan oleh Kennedy dan Eberhart pada tahun 1997, sebagai algoritma optimasi untuk permasalahan yang bersifat diskrit. Pada binary PSO, partikel menempati ruang biner (1 dan 0), di mana posisi yang dianggap kurang relevan dieliminasi.

Brown, et al. [3] menyimpulkan bahwa bagian-bagian wajah (alis, mata, hidung, dahi, dan dagu) membawa informasi yang dibutuhkan untuk membedakan jenis kelamin bila dilihat secara terpisah.

Lian, et al. [10] mengajukan metode klasifikasi jenis kelamin dengan menggabungkan informasi wajah dengan informasi eksternal yaitu rambut dan pakaian. Menggunakan gabungan pakaian, rambut, dan wajah, pada dataset FERET, Lian et al. mendapatkan akurasi $92,7\% \pm 0,5$, dan akurasi sebesar $95,1\% \pm 0,5$ dengan menggabungkan pakaian, rambut, dan lima komponen wajah (dahi, mata, hidung, mulut, dan dagu).

Khan, et al. [4] menggunakan LBP berbasis grid untuk pemecahan masalah klasifikasi jenis kelamin, dengan menggunakan *Support Vector Machine* (SVM) sebagai algoritma klasifikasinya. Penelitian ini menghasilkan akurasi terbaik $95,5\%$.

Pada tulisannya yang lain, Khan, et al. [2] menggunakan LBP dari lima komponen wajah yang sudah di-crop, yaitu alis, mata, hidung, bibir, dan dagu. Di penelitian ini, Khan, et al. menggunakan *ensemble classifier* yang juga dioptimasi menggunakan *Genetic Algorithm* (GA). Ensemble classifier menggunakan *weighted majority voting* yang kombinasi beratnya dioptimasi oleh GA. Algoritma klasifikasi yang digunakan pada ensemble classifier ini adalah K-NN, SVM, dan *Back Propagation Neural Network*. Akurasi terbaik dengan metode ini adalah $97,5\%$.

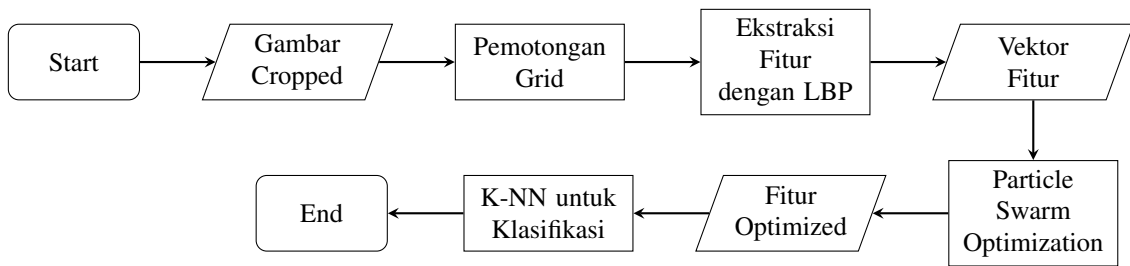
3. Sistem yang Dibangun

3.1 Rancangan Sistem

Ada tiga tahap utama yang dilakukan sistem saat melakukan pemecahan masalah, yaitu tahap ekstraksi fitur, tahap optimasi, dan tahap klasifikasi.

- **Ekstraksi Fitur:** Sistem akan membagi gambar masukan ke blok $M \times N$, lalu mengaplikasikan LBP ke masing-masing blok tersebut, untuk kemudian digabungkan (*concatenate*). Histogram yang telah digabung kemudian dikirim ke PSO untuk dioptimasi.
- **Optimasi:** Fitur yang sudah diekstraksi dengan LBP akan dioptimasi menggunakan PSO, di mana fitur-fitur yang kurang penting akan dieliminasi, sebelum dikirim ke algoritma klasifikasi.
- **Klasifikasi:** Fitur yang sudah dioptimasi akan melalui algoritma K-NN untuk diklasifikasi jenis kelaminnya.

Secara rinci, sistem dapat digambarkan dengan *flowchart* berikut:




Gambar 1. Rancangan sistem yang dibangun

3.2 Dataset

Dataset yang digunakan adalah Color FERET database, dengan batasan gambar yang digunakan yaitu gambar subjek yang menghadap ke depan. Secara keseluruhan, data yang digunakan berjumlah 2.409 data. Pembagian data dilakukan dua kali, pertama data 20% dari keseluruhan data untuk data uji, 20% dari sisa data untuk validasi, dan sisanya digunakan untuk data latih. Jadi, 482 gambar digunakan sebagai data uji, 385 gambar untuk validasi, dan 1.542 gambar untuk data latih.

3.3 Ekstraksi Fitur

Proses pertama yang dilakukan sistem adalah ekstraksi fitur. Namun, sebelum fitur diekstraksi, setiap gambar dalam dataset akan dibagi menjadi grid $M \times N$ [4], kemudian LBP akan diaplikasikan ke setiap grid gambar tersebut. Histogram fitur setiap grid kemudian digabungkan untuk dikirim ke PSO.



Gambar 2. Contoh pembagian gambar

Gambar 2 menampilkan contoh pembagian gambar wajah ke dalam blok grid.

3.4 List Kelas

Kelas terdiri dari dua jenis kelamin (Pria dan Wanita), yang datanya disediakan dalam bentuk XML bersamaan dengan dataset gambar di Color FERET database. Sistem membaca file XML yang disediakan, kemudian membandingkan subject ID tersebut dengan dataset gambar, bila subject ID ada di dalam dataset gambar yang digunakan maka kelas akan disimpan ke dalam sebuah vektor.

3.5 Particle Swarm Optimization

PSO diinstansiasi dengan jumlah partikel 10, nilai konstanta satu 0.4, nilai konstanta dua 0.4, dan nilai konstanta *weight* 0.4. Setiap partikel memiliki dimensi sesuai persamaan berikut:

$$D = M \times N \times B \quad (1)$$

Di mana D adalah ukuran dimensi partikel, M dan N merupakan jumlah blok grid yang digunakan, dan B adalah jumlah bin yang digunakan.

Setelah swarm dibuat, optimasi dilakukan selama iterasi yang sudah ditentukan: pada iterasi pertama, posisi swarm didapatkan secara acak, kemudian pada iterasi selanjutnya setiap partikel dalam swarm akan terus bergerak ke nilai cost terkecil, yang mana pada penelitian ini cost didapatkan dari nilai error prediksi *K-Nearest Neighbor*.

PSO akan terus berjalan sampai iterasi terakhir, di mana posisi (index fitur yang aktif) yang dianggap optimal akan digunakan sebagai histogram fitur dalam proses klasifikasi data uji.

3.6 K-Nearest Neighbor

K-NN memiliki peran sangat penting dalam penelitian ini, selain sebagai algoritma yang digunakan untuk menghitung akurasi data uji, juga sebagai algoritma yang digunakan untuk menghitung cost partikel PSO, untuk menemukan partikel yang paling baik. K-NN dipilih karena sifatnya yang merupakan *lazy learning algorithm*, sehingga K-NN tidak membutuhkan pembuatan model tambahan yang bila digabungkan dengan PSO akan membuat *runtime* semakin lama.

Histogram fitur yang sudah dioptimasi didapatkan dari PSO, kemudian digunakan saat melakukan prediksi terhadap data uji, sehingga mengurangi waktu yang diperlukan untuk melakukan prediksi secara signifikan.

3.7 Perhitungan Evaluasi

Evaluasi yang digunakan yaitu waktu yang digunakan untuk klasifikasi tanpa optimasi PSO, waktu yang digunakan untuk klasifikasi dengan optimasi PSO, serta akurasi yang didapatkan untuk kedua prosedur tersebut.

4. Evaluasi

4.1 Skenario Pengujian

Dalam penelitian ini, dilakukan tiga buah skenario pengujian sistem, yaitu:

1. Skenario 1: Observasi pengaruh jumlah grid terhadap LBP

Pada skenario ini dilakukan pengujian terhadap berbagai jumlah grid, dan jumlah bin histogram yang di-*output* LBP, terhadap akurasi prediksi menggunakan K-NN. Grid yang akan diuji yaitu 1×1 , 3×3 , 5×5 , 7×7 , dan 9×9 .

2. Skenario 2: Observasi nilai K dan jumlah bins

Pada skenario ini dilakukan pengujian terhadap berbagai nilai K untuk K-NN, untuk menemukan nilai K yang optimal. Nilai K yang diuji yaitu 1, 3, dan 5. Sedangkan jumlah bin yang diuji yaitu 5, 10, dan 15 bins. *neighbors*.


3. Skenario 3: Observasi perbandingan kinerja sistem dengan dan tanpa optimasi

Pada skenario ini dilakukan pengujian pengaruh PSO terhadap kinerja sistem secara keseluruhan, dan perbandingan kinerja sistem klasifikasi yang menggunakan PSO dan yang tidak menggunakan PSO.

4.2 Analisis dan Hasil Pengujian

Sesuai dengan skenario pengujian di atas, berikut disajikan hasil pengujianya, beserta analisis hasil pengujian setiap skenario:

4.2.1 Skenario 1



Gambar 3. Hasil Uji Skenario 1

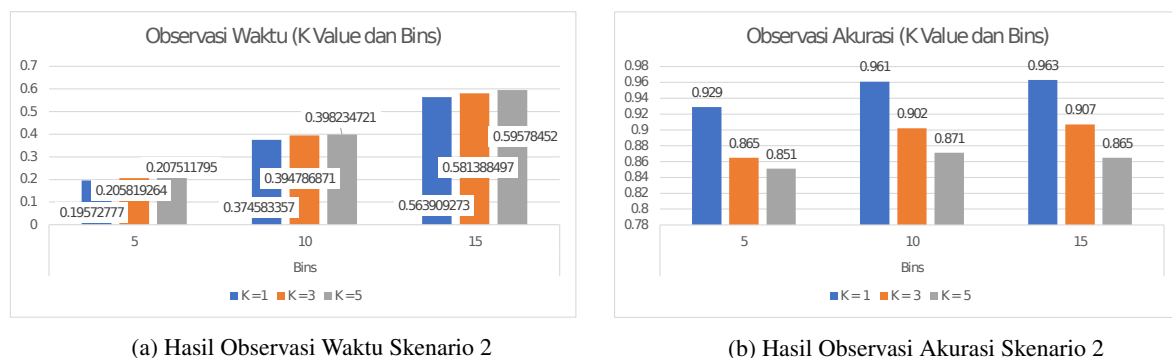
Pada skenario ini, pengujian dilakukan dengan 5 macam grid yaitu 1×1 , 3×3 , 5×5 , 7×7 , dan 9×9 ; dan dengan nilai $K = 3$. Kemudian setiap jenis grid juga akan diuji menggunakan 3 macam bin histogram, yaitu 5 bin, 10 bin, dan 15 bin.

Secara keseluruhan, skenario pengujian ini menghasilkan kesimpulan bahwa dengan menggunakan seluruh gambar wajah (tanpa membagi gambar ke dalam beberapa blok grid), akan ada informasi spasial yang penting untuk proses klasifikasi yang hilang. Namun skenario ini juga membuktikan bahwa setelah titik tertentu (dalam kasus ini 5×5 grid), akurasi yang didapatkan tidak bertambah, karena semakin banyaknya jumlah grid, maka semakin kecil ukuran satu blok grid sehingga berkurangnya informasi penting yang dapat diberikan oleh satu blok grid tersebut.

Oleh karena itu, berdasarkan observasi sesuai gambar 3, grid 5×5 disimpulkan sebagai jumlah grid yang paling optimal.

4.2.2 Skenario 2

Setelah observasi pada skenario satu menunjukkan bahwa grid 5×5 merupakan grid yang paling optimal, pengujian skenario kedua ini akan menggunakan jumlah grid tersebut sebagai batasan pengujian.



Gambar 4. Hasil Observasi Waktu dan Akurasi Skenario 2


Berdasarkan hasil observasi pada gambar 4a, dapat disimpulkan bahwa jumlah bin adalah faktor utama yang mempengaruhi durasi berjalannya proses klasifikasi. Hal ini dikarenakan dengan meningkatnya jumlah bin maka jumlah dimensi fitur yang akan diproses oleh algoritma klasifikasi pun turut bertambah. Namun, perlu dicatat juga bahwa berdasarkan observasi ini jumlah K turut memiliki dampak terhadap waktu proses klasifikasi data, walaupun perbedaan waktu tidak signifikan, terutama untuk nilai $K = 3$, dan nilai $K = 5$.

Berdasarkan hasil observasi pada gambar 4b, dapat disimpulkan bahwa nilai $K = 1$ merupakan nilai paling optimal di keseluruhan jumlah bin yang diuji. Terdapat perbedaan yang signifikan pada nilai $K = 1$, bila dibandingkan dengan nilai K lainnya, di seluruh jumlah bin yang diuji. Nilai $K = 1$ cukup digunakan karena posisi data yang tidak terlalu tersebar jauh, sehingga tidak membutuhkan nilai tetangga lebih besar dari satu. Oleh karena itu dapat disimpulkan bahwa nilai $K = 1$ merupakan nilai K yang paling optimal.

4.2.3 Skenario 3

Pada skenario ini, pengujian akan melakukan observasi dampak PSO terhadap proses klasifikasi: baik dari waktu maupun akurasi. Parameter PSO yang digunakan adalah: $c1 = 0.4$, $c2 = 0.4$, dan $W = 0.4$. PSO akan berjalan selama 15 iterasi, dan dimensi partikel berdasarkan persamaan 1.

Pertama, observasi dilakukan dengan tiga jenis ukuran bin histogram: 5, 10, dan 15, untuk mendapatkan jenis bin terbaik dengan PSO. Jumlah blok grid yang digunakan adalah 5×5 , sesuai dengan hasil observasi Skenario 1. Nilai K yang digunakan adalah $K = 1$.



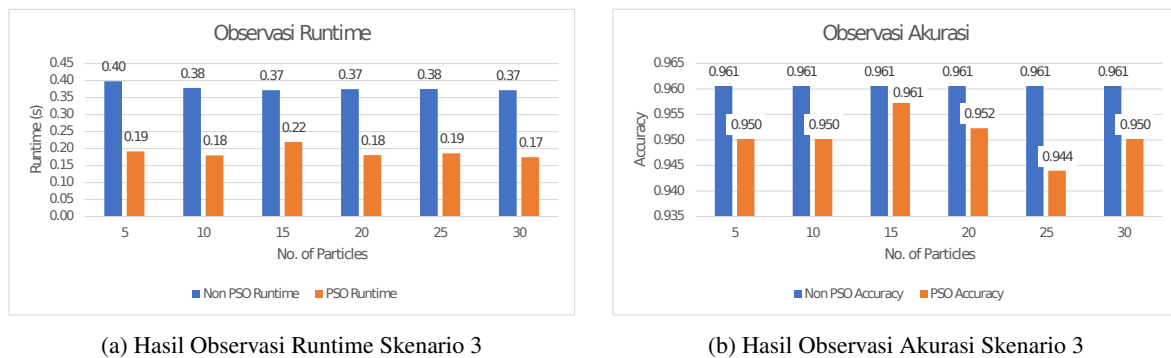
(a) Hasil Observasi Akurasi Per Jenis Bin

(b) Hasil Observasi Fitur Skenario 3

Gambar 5. Hasil Observasi Waktu dan Akurasi Skenario 2

5a menunjukkan perbandingan akurasi ketiga jenis bin sebelum melalui PSO, dan sesudah optimasi PSO. Dapat diobservasi bahwa konfigurasi LBP menggunakan 10 bin memiliki akurasi terbaik setelah optimasi PSO. Oleh karena itu, pada skenario ini, pengujian dilakukan dengan menggunakan konfigurasi histogram fitur sebanyak 10 bin.

Gambar 5b menampilkan perbandingan total fitur yang digunakan dalam proses klasifikasi, di mana dimensi asli dari gambar, sesuai dengan persamaan 1 adalah 250, kemudian direduksi sesuai dengan observasi yang ditampilkan pada gambar.




(a) Hasil Observasi Runtime Skenario 3

(b) Hasil Observasi Akurasi Skenario 3

Gambar 6. Hasil Observasi Runtime dan Akurasi Skenario 3

Gambar 6a menunjukkan bahwa *runtime* proses klasifikasi berbanding lurus dengan jumlah fitur yang diproses: semakin sedikit fitur yang diproses, semakin cepat K-NN memecahkan permasalahan klasifikasi.

Gambar 6b menunjukkan bahwa akurasi klasifikasi data tidak mengalami peningkatan ketika dioptimasi melalui PSO. Namun, dapat terlihat bahwa perbedaan akurasi tidak begitu signifikan (bahkan tidak mengalami perubahan pada observasi 15 partikel). Hal ini sesuai dengan sifat PSO yang merupakan algoritma *metaheuristic*, yang tidak memberikan garansi bahwa solusi akan global optimum. Dari sini dapat disimpulkan bahwa nilai akurasi yang ditampilkan pada observasi setelah optimasi menggunakan PSO merupakan nilai yang mendekati optimum.



Gambar 7. Hasil Observasi Total Time Skenario 3

Gambar 7 menunjukkan total waktu yang dibutuhkan sistem untuk menyelesaikan seluruh proses: dimulai dari ekstraksi fitur, proses optimasi, dan klasifikasi data. Dapat disimpulkan bahwa semakin banyak partikel yang

digunakan untuk proses optimasi PSO, semakin lama waktu yang dibutuhkan untuk menjalankan sistem.

5. Kesimpulan

Berdasarkan hasil pengujian dan analisis yang telah dilakukan, maka dapat ditarik kesimpulan sebagai berikut:

1. Ekstraksi fitur dengan LBP berbasis grid berpengaruh positif terhadap akurasi klasifikasi data. Proses yang tidak menggunakan grid memiliki nilai akurasi yang lebih rendah bila dibandingkan dengan proses ekstraksi fitur yang menggunakan grid.
2. Untuk dataset yang digunakan dalam penelitian ini, nilai $K = 1$ memberikan performa terbaik, baik dalam waktu ataupun dalam nilai akurasi. Nilai K yang semakin besar untuk dataset yang digunakan pada penelitian ini, justru membuat nilai akurasi turun.
3. Akurasi terbaik yang didapatkan adalah LBP dengan 5×5 grid, dan 15 bin histogram, sebesar 96,3%. Akurasi setelah PSO terbaik adalah 95,9% yaitu dengan menggunakan 10 bin histogram LBP.
4. Berdasarkan observasi pada penelitian ini, PSO rata-rata mereduksi fitur sebanyak 50,07%. Pengurangan dimensi fitur juga membuat waktu yang dibutuhkan untuk proses klasifikasi berkurang rata-rata 0.19 detik atau 50,1%.
5. Meskipun dapat mengurangi jumlah fitur yang diproses secara signifikan, berdasarkan hasil observasi dapat disimpulkan bahwa PSO memiliki efek kurang baik pada dataset yang digunakan penelitian ini. Rata-rata, akurasi klasifikasi yang melalui PSO mengalami penurunan sebanyak 0,009%.

Daftar Pustaka

- [1] T. Ahonen, A. Hadid, and M. Pietikainen, "Face description with local binary patterns: Application to face recognition," *IEEE transactions on pattern analysis and machine intelligence*, vol. 28, no. 12, pp. 2037–2041, 2006.
- [2] S. A. Khan, M. Nazir, and N. Riaz, "Optimized features selection for gender classification using optimization algorithms," *Turkish Journal of Electrical Engineering & Computer Sciences*, vol. 21, no. 5, pp. 1479–1494, 2013.
- [3] E. Brown and D. I. Perrett, "What gives a face its gender?," *Perception*, vol. 22, no. 7, pp. 829–840, 1993.
- [4] S. A. Khan, M. Nazir, N. Riaz, M. Hussain, and N. Naveed, "Gender classification using local binary pattern and particle swarm optimization," *Emerging Trends and Applications in Information Communication Technologies*, pp. 73–80, 2012.
- [5] P. J. Phillips, H. Wesslesler, J. Huang, and P. Rauss, "The feret database and evaluation procedure for face recognition algorithms," *Image and Vision Computing*, vol. 16, pp. 295–306, 1998.
- [6] T. Ojala, M. Pietikainen, and D. Harwood, "Performance evaluation of texture measures with classification based on kullback discrimination of distributions," in *Pattern Recognition, 1994. Vol. 1-Conference A: Computer Vision & Image Processing., Proceedings of the 12th IAPR International Conference on*, vol. 1, pp. 582–585, IEEE, 1994.
- [7] T. Ojala, M. Pietikainen, and T. Maenpaa, "Multiresolution gray-scale and rotation invariant texture classification with local binary patterns," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 24, no. 7, pp. 971–987, 2002.
- [8] J. Kennedy and R. C. Eberhart, "Particle swarm optimization," in *Proceedings of IEEE International Conference on Neural Networks IV, pages*, vol. 1000, 1995.
- [9] J. Kennedy and R. C. Eberhart, "A discrete binary version of the particle swarm algorithm," in *Systems, Man, and Cybernetics, 1997. Computational Cybernetics and Simulation., 1997 IEEE International Conference on*, vol. 5, pp. 4104–4108, IEEE, 1997.
- [10] B. Li, X.-C. Lian, and B.-L. Lu, "Gender classification by combining clothing, hair and facial component classifiers," *Neurocomputing*, vol. 76, no. 1, pp. 18–27, 2012.

Lampiran

	5 bin	10 bin	15 bin	Average
1	0.728	0.772	0.793	0.764333
3	0.84	0.873	0.876	0.863
5	0.865	0.902	0.907	0.891333
7	0.865	0.89	0.873	0.876
9	0.859	0.878	0.88	0.872333

Gambar 8. Lampiran data skenario 1

		Bins		
		5	10	15
K =	1	0.195728	0.374583	0.563909
	3	0.205819	0.394787	0.581388
	5	0.207512	0.398235	0.595785

Gambar 9. Lampiran data skenario 2 - observasi waktu

		Bins		
		5	10	15
K =	1	0.929	0.961	0.963
	3	0.865	0.902	0.907
	5	0.851	0.871	0.865

Gambar 10. Lampiran data skenario 2 - observasi akurasi

Partide	Non PSO Time	Non PSO Accuracy	PSO Time	PSO Accuracy	Total Time
5	0.397972102	0.961	0.19155757	0.95021	42.73561439
10	0.378438718	0.961	0.17991723	0.95021	57.86832096
15	0.371426803	0.961	0.21967224	0.96058	72.95229308
20	0.374726741	0.961	0.18089435	0.95228	90.30507276
25	0.375350988	0.961	0.18601873	0.94398	102.6384621
30	0.371859067	0.961	0.1743956	0.95021	119.1799061

Partide	PSO Features
5	119
10	120
15	144
20	124
25	122
30	120

Gambar 11. Lampiran data skenario 3