

INTISARI

PERHITUNGAN ORANG PADA VIDEO SURVEILLANCE MENGGUNAKAN METODE *ORIENTED FAST ROTATED BRIEF* DAN *SUPPORT VECTOR MACHINE*

Oleh

Canggih Gelar Setyo Adhi

18/433767/PPA/05582

Salah satu hasil perkembangan ilmu pengetahuan yang dapat diterapkan pada sistem CCTV adalah Perhitungan Orang. Perhitungan orang dapat dilakukan dengan deteksi orang, klasifikasi orang atau non manusia, kemudian lakukan perhitungan. Model penghitung orang yang menggunakan metode region detector seperti HOG dan Viola Jones sebagai teknik deteksi objek, tidak bisa mendeteksi objek yang berhimpitan karena fiturnya bersifat global. Hal ini dapat diatasi dengan penggunaan metode yang fiturnya bersifat lokal. ORB merupakan salah satu metode dengan fitur bersifat local. Oleh karena itu, penerapan ORB diharapkan dapat mengatasi permasalahan deteksi objek tertutup sebagian yang tidak dapat dideteksi oleh metode-metode fitur global.

Penelitian yang dilakukan adalah pembuatan program perhitungan orang sebagai fitur pada CCTV dengan mengkombinasikan metode ORB dan klasifier SVM sebagai upaya mengatasi masalah deteksi objek tertutup sebagian. Tahapan proses perhitungan orang adalah prapemrosesan *grayscale*, deteksi objek, ekstraksi fitur clustering kemudian klasifikasi. Hasil *grayscale* dilakukan deteksi objek dengan menggunakan *background subtraction* MOG, metode ekstraksi fitur ORB dilakukan pada objek yang terdeteksi yang berada didalam area *Region of Interest*. Fitur yang diekstrak dikelompokkan kedalam beberapa kluster sebagai kandidat objek dengan menggunakan *clustering* berdasarkan posisi koordinatnya. Kumpulan fitur pada masing-masing kandidat objek diklasifikasikan dengan menggunakan model yang terbentuk dengan pelatihan menggunakan metode SVM.

Penggunaan *background subtraction* MOG mendapatkan hasil penghitungan orang yang terbaik dengan nilai f-measure 0.56. Tahap ekstraksi fitur menggunakan ORB, jumlah fitur 7000 mendapatkan performa yang lebih baik daripada jumlah fitur 3000 maupun jumlah fitur 5000. Hasil f-measure berturut-turut untuk banyak fitur 3000, 5000 dan 7000 adalah 0.535, 0.535 dan 0.559. Sistem berhasil mendeteksi orang yang tertutup sebagian dengan performa terbaik nilai f-measure 0.582 untuk nilai quantile 0.18. Pengujian dengan banyak orang 1, nilai quantile 0,26 menghasilkan performa terbaik yaitu nilai f-measure 0,571. Sedangkan untuk banyak orang 4, nilai quantile 0,18 menghasilkan nilai f-measure terbaik yaitu 0,603.

Kata Kunci: *People Counting*, ORB, SVM, CCTV, Oklusi.

ABSTRACT

COUNTING PEOPLE ON SURVEILLANCE VIDEO USING ORIENTED FAST ROTATED BRIEF METHOD AND SUPPORT VECTOR MACHINE

By

Canggih Gelar Setyo Adhi

18/433767/PPA/05582

One of the results of scientific developments that can be applied to CCTV systems is people counting. Counting people can be done by detecting people, classifying objek as people or non-humans, then doing the calculations. People counter models that use region detector methods such as HOG and Viola Jones as object detection techniques, cannot detect objects that are close together because their features are global. This can be overcome by using methods whose features are local. ORB is a method with local features. Therefore, the application of ORB is expected to overcome the problem of partially closed object

The research conducted is the creation of a program for people counting as a feature on CCTV by combining the ORB method and the SVM classifier as an effort to overcome the problem of partially closed object detection. The stages are grayscale preprocessing, object detection, feature extraction clustering and then classification. The results of grayscale are object detection using MOG background subtraction, the ORB feature extraction method is carried out on detected objects that are in the Region of Interest area. The extracted features are grouped into several clusters as candidate objects by using clustering based on their coordinate positions. The feature set in each candidate object is classified by using a model formed by training using the SVM method.

The use of MOG background subtraction gets the best people count results with f-measure 0.559. Then at the feature extraction stage using ORB, the number of features 7000 gets better performance than the number of features 3000 and the number of features 5000. The f-measure for 3000, 5000 and 7000 features are 0.535, 0.535 and 0.559 respectively. The system succeeded in detecting partially closed people with the best f-measure value of 0.582 for a quantile value of 0.18. Testing result for 1 people per frame, the quantile value of 0.26 produced the best performance with the f value of 0.571. Whereas for the number of people per frame is 4, the quantile value of 0.18 produced the best performance with the f value of 0.603.

Keyword: People Counting, ORB, SVM, CCTV, Occlusion.

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Teknologi pengolahan citra digital kini telah berkembang dengan pesat. Perkembangan ini mendukung pengembangan teknologi yang berkaitan dengan citra. CCTV (Closed Circuit Television) merupakan salah satu sistem untuk menangkap atau merekam video. Kemampuan jaringan kamera CCTV semakin berkembang seiring dengan perkembangan teknologi pengolahan citra. Dahulu, kamera CCTV hanya berfungsi untuk mengambil dan merekam file video dari suatu area. Rekaman dari CCTV dibuka dan dianalisa untuk membantu proses penyelidikan jika pada area tersebut terjadi kasus. Rekaman dianalisa secara manual oleh manusia untuk dapat diambil kesimpulan. Perkembangan ilmu pengetahuan dalam bidang pemrosesan citra dapat membantu proses analisa tersebut. Beberapa perkembangan ilmu pengetahuan yang dapat diterapkan pada sistem CCTV adalah Deteksi Kebakaran, Deteksi Asap, Deteksi parkir illegal, Deteksi Barang ditinggalkan, Perhitungan Orang dan Monitoring Area Steril (Filonenko dkk., 2016).

Sistem CCTV yang memiliki kemampuan untuk melakukan penghitungan orang yang terekam didalam rekaman sistem tersebut dapat membantu pemilik sistem dalam banyak hal. Dalam hal keamanan, sistem cctv yang mampu menghitung orang dapat membantu untuk memastikan area steril benar-benar steril jika diletakkan didalam ruangan tersebut. Jika sistem cctv diletakkan didalam ruangan berpendingin udara, maka sistem dapat diintegrasikan dengan sistem pengatur udara untuk mengatur kecepatan kipas dan mengatur kerja kompresor sesuai jumlah orang yang terdeteksi didalam ruangan. Dalam hal riset pemasaran, sistem ini dapat ditempatkan pada pusat perbelanjaan atau toko untuk dapat membantu analisa pemasaran. Bahkan jika diletakkan didalam kelas, sistem bisa digunakan untuk verifikasi jumlah presensi mahasiswa yang hadir dalam kuliah.

Perhitungan orang dapat dilakukan dengan menggunakan teknik pengolahan citra digital untuk mengidentifikasi objek, melakukan klasifikasi objek tersebut sebagai manusia atau bukan manusia, kemudian melakukan penghitungan jumlah manusia yang tertangkap dalam frame video. Proses perhitungan orang (people counting) pada kamera CCTV memiliki beberapa tahapan proses. Tahapan utama dalam perhitungan orang pada video adalah tahap deteksi objek kemudian dilanjutkan dengan tahapan ekstraksi fitur, tahap klasifikasi dan penghitungan objek. Tahap deteksi objek dilakukan dengan mendeteksi *interest point* dari sebuah citra dan memberikan *descriptor* pada titik tersebut. Beberapa teknik yang dapat dilakukan untuk melakukan deteksi objek adalah Background Subtraction, Optical Flow, Spatio-Temporal Filter, Histogram Oriented Gradient (HOG), Haarlike dan berbagai metode local descriptor seperti SIFT, SURF, FAST, BRIEF dan ORB. (Wahyuni dkk., 2017) melakukan penelitian dengan menggunakan HOG sebagai teknik deteksi objek. Hasil dari penelitian ini adalah teknik HOG memiliki kelemahan tidak bisa mendeteksi objek jika posisi objek berpotongan atau saling tumpang tindih. Prihambodo dkk., (2015) juga mendapatkan hasil yang kurang baik ketika menggunakan metode KLT dan Viola Jones untuk tracking object pada data oklusi. Hal ini tidak terjadi pada teknik *local descriptor*.

Li dkk., (2011) menggunakan *cascaded SURF* untuk melakukan deteksi wajah. Hasil dari penelitian tersebut yaitu *cascaded SURF* dapat dilatih dengan lebih cepat dan mendapatkan akurasi yang baik dibandingkan Viola Jones, HOG-SMV maupun *cascaded HOG*. (Karami dkk., t.t.) membandingkan metode SIFT, SURF dan ORB. Hasil dari penelitiannya yaitu SIFT adalah teknik yang memiliki akurasi terbaik diikuti ORB kemudian SURF. Dalam hal kecepatan, ORB adalah teknik tercepat diikuti SURF kemudian SIFT sehingga dapat disimpulkan bahwa ORB adalah teknik tercepat dengan akurasi yang cukup baik diantara ketiga teknik yang dibandingkan.

Tahap berikutnya adalah tahap Klasifikasi. Pada tahap ini, objek yang telah dideteksi pada tahap deteksi objek akan diklasifikasikan sebagai manusia atau bukan manusia. Beberapa metode klasifikasi yaitu K-Nearest Neighbours (KNN), decision tree, Naïve Bayes dan SVM. Hasil dari tahapan deteksi objek adalah

berupa vector sehingga SVM lebih cocok digunakan untuk klasifikasi dibandingkan Naïve Bayes pada permasalahan penghitung orang.

Berdasarkan pemaparan di atas, pada penelitian ini diusulkan penggunaan metode ORB untuk metode identifikasi manusia yang dikombinasikan dengan metode SVM sebagai classifier untuk perhitungan orang. Kombinasi metode ini diharapkan dapat meningkatkan akurasi dari penghitungan orang.

1.2 Rumusan Masalah

Berdasarkan latar belakang masalah yang telah diuraikan, maka dalam penelitian ini permasalahan yang di rumuskan adalah model penghitung orang yang menggunakan metode region detector tidak bisa mendeteksi objek yang berhimpitan karena fiturnya bersifat global.

1.3 Batasan Masalah

Batasan masalah yang terdapat dalam penelitian ini untuk menghindari perluasan pembahasan adalah sebagai berikut :

1. Data yang digunakan adalah file rekaman video yang diambil di lorong lantai 4 gedung S2 Ilmu Komputer UGM.
2. Pengukuran performa sistem menggunakan *f-measure* yang dihitung dari jumlah objek manusia yang terdeteksi dibandingkan dengan jumlah objek manusia yang sebenarnya.
3. Data rekaman video CCTV dengan ukuran 30 fps.
4. Banyaknya orang yang lewat secara bersamaan pada ROI adalah 1 sampai dengan 4 orang.

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah menerapkan program penghitung orang sebagai fitur pada sistem CCTV dengan mengkombinasikan metode ORB dan klasifier SVM dalam upaya mengatasi masalah deteksi objek yang tertutup sebagian.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut :

1. Bagi masyarakat, penelitian ini diharapkan dapat menjadi pilihan tambahan fitur keamanan sistem CCTV.
2. Bagi pemilik atau pengelola mall, hypermarket atau supermarket, penelitian ini dapat dikembangkan lagi untuk mendeteksi jumlah pengunjung atau antrian didalam toko.
3. Bagi pengembang IoT, penelitian ini dapat dikombinasikan dengan microcontroller untuk mengatur nyala lampu atau kecepatan kompresor AC.
4. Penelitian ini diharapkan dapat memberikan pemahaman yang lebih baik terhadap teknologi perhitungan orang pada surveillance video.

1.6 Kontribusi Penelitian

Penelitian ini memiliki kontribusi dalam pengembangan fitur perhitungan orang pada sistem CCTV. Teknik ORB untuk metode identifikasi manusia yang dikombinasikan dengan metode SVM sebagai weak classifier untuk fitur perhitungan orang dapat menangani masalah data oklusi dari penelitian sebelumnya.

BAB II

KAJIAN PUSTAKA

Teknik perhitungan orang sebagai fitur dari sistem CCTV sudah dikembangkan dalam beberapa tahun terakhir. Beberapa metode sudah dikembangkan untuk melakukan perhitungan orang. Beberapa penelitian yang melakukan penerapan perhitungan orang diantaranya seperti penghitung orang sebagai objek bergerak oleh Conte dkk. (2010), Penerapan perhitungan orang didalam ruangan oleh (Wahyuni dkk., 2017), perhitungan orang crowd counting oleh (Zeng dan Ma, 2010) dan juga oleh Prihambodo dkk. (2015).

Tahapan utama dalam penerapan perhitungan orang yaitu deteksi objek dan klasifikasi objek. Tahap pertama yaitu deteksi objek dengan menerapkan deteksi tepi, menerapkan deteksi interest point dan descriptor. (Wahyuni dkk., 2017) menerapkan deteksi tepi yaitu HOG untuk melakukan deteksi objek. Hasil dari deteksi tepi HOG kemudian diolah dengan klasifikasi SVM untuk menggolongkan orang dengan bukan orang. Jika hasilnya orang, maka ditambahkan ke penghitung. Penerapan HOG rentan dengan error jika terdapat data oklusi. Zeng dan Ma (2010) juga menggunakan teknik HOG. Tetapi pada penerapannya dikombinasikan dengan Local Binary Pattern untuk mengatasi data oklusi. Penggabungan metode ini dapat menambah fitur yang harus diolah oleh classifier. Penerapan local descriptor juga dapat menanggulangi data oklusi dengan jumlah fitur yang lebih sedikit.

Prihambodo dkk (2015) melakukan perhitungan orang dengan menggunakan teknik deteksi fitur Viola Jones dan tracking menggunakan Kanade Lucas Tomasi (KLT). Teknik ini dilakukan dengan membandingkan image dengan template (haarlike). Semakin banyak fitur haar, semakin akurat tetapi juga memerlukan waktu pengolahan yang lebih lama. Penerapan Haar juga belum dapat menanggulangi data oklusi.

(Wahyono dkk., 2016) melakukan identifikasi terhadap objek yang ditinggalkan menggunakan metode *Dual Background Difference*. Deteksi objek dilakukan dengan menggunakan metode *Sequence of Dual Background Difference*. Metode diuji dengan berbagai dataset dan diuji kecepatan komputasinya. Hasil dari

penelitian adalah metode yang diusulkan menghasilkan nilai $f = 1.0$ untuk setiap dataset dengan kecepatan komputasi rata-rata 66ms.

Conte dkk. (2010) menerapkan deteksi objek SURF dikombinasikan dengan klasifikasi SVM. SURF memiliki kecepatan pengolahan yang baik, tetapi tingkat deteksi yang kurang baik jika dibandingkan dengan SIFT maupun ORB. Li dkk (2011) melakukan penerapan cascaded SURF untuk meningkatkan kecepatan pengolahan SURF. Cascaded SURF digunakan untuk melakukan deteksi wajah. Hal ini dapat ditingkatkan lagi untuk deteksi objek yang lebih kompleks misalkan manusia. Li dan Zhang (2013) juga menerapkan cascaded SURF untuk deteksi beberapa objek seperti mobil dan wajah yang dilihat dari berbagai view kemudian membandingkannya dengan Viola Jones. Kriteria yang digunakan sebagai optimasi cascade adalah AUC.

Azad dkk. (2009) melakukan penelitian untuk meningkatkan kecepatan dari algoritme SIFT. Penelitian ini mengkombinasikan algoritme SIFT dengan Harris Corner Detector. Hasil yang didapatkan adalah waktu pengolahan 20ms atau setara dengan 30fps untuk resolusi 640 x 480. Karami dkk. () membandingkan metode SIFT, SURF dan ORB pada image matching. Penelitian ini menggunakan beberapa tantangan seperti scaling, noise, fish eye distorsion dan shearing. Untuk penerapan perhitungan orang didalam ruangan, tidak banyak perubahan terhadap fish eye distorsion, shearing dan scaling. Hasil dari penelitian ini untuk tantangan noise adalah ORB mendapatkan tingkat kecocokan yang tertinggi dengan kecepatan tercepat diikuti SURF kemudian SIFT. Xie dkk (2013) juga membandingkan algoritme SIFT, SURF dan ORB untuk mendeteksi objek bergerak pada background bergerak. Hasil yang didapatkan adalah kecepatan ORB 40 kali lebih cepat dibandingkan dengan SIFT dan 20 kali lebih cepat dibandingkan dengan kecepatan SURF.

Penerapan perhitungan orang pada data video CCTV membutuhkan algoritma yang cepat dan akurat. Teknik HOG dan Viola Jones memiliki kendala terhadap data oklusi atau data orang yang berdiri dibelakang objek lain dapat menurunkan akurasi dari algoritma. Oleh karena itu diperlukan teknik deteksi objek yang tahan terhadap oklusi. Kemudian jika dilihat dari kecepatan dan akurasi jika terdapat

kendala noise, teknik ORB sedikit lebih unggul dibandingkan dengan teknik SIFT dan memiliki banyak keunggulan dibandingkan teknik SIFT. Sistem cascade pada penerapan cascade SURF dapat membantu mempercepat waktu pengolahan sehingga dengan penerapan pada ORB juga diharapkan dapat mempersingkat waktu pengolahan. Oleh karena itu, untuk penerapan perhitungan orang pada data video CCTV, diperlukan deteksi objek ORB yang dikombinasikan dengan SVM sebagai klasifiernya.

Berikut ringkasan dari beberapa penelitian sebelumnya.

Tabel 2.1 Penelitian yang bersesuaian

Nama Peneliti	Judul Penelitian	Metode	Hasil
Conte dkk. (2010)	Penggunaan algoritma SURF untuk penghitung orang yang bergerak	SURF - SVM	MAE = 0,63% dan MRE = 18,8%
(Wahyuni dkk., 2017)	Penerapan penghitung orang didalam ruangan menggunakan HOG	HOG - SVM	HOG tidak dapat mendeteksi data oklusi
(Zeng dan Ma, 2010)	Penerapan HOG-LBP dan PCA untuk penghitung orang	HOG - LBP - PCA	tingkat deteksi HOG = 62% HOG - LBP = 74% HOG - LBP-PCA = 89%
(Li dan Zhang, 2013)	Penerapan cascaded SURF untuk deteksi objek yang lebih cepat dan akurat	Viola Jones Cascade SURF	Detection rate = 70% false positive = 9% Speed 56 fps
Prihambodo dkk. (2015)	Sistem perhitungan orang dengan menggunakan deteksi fitur KLT	Viola Jones + Kanade Lucas Tomasi	akurasi 86%
(Wahyono dkk., 2016)	Penerapan deteksi objek SODB untuk deteksi objek ditinggalkan	SODB - SVM	f-measure = 1.0 Speed = 66ms

Tabel 2.1 Penelitian yang bersesuaian (lanjutan)

(Li dan Zhang, 2013)	Penerapan cascaded SURF untuk deteksi wajah.	SURF Cascade – SURF	Speed : SURF 25fps Cascade SURF 30,1fps
(Xie dkk., 2013)	Penerapan detector untuk objek bergerak dan bakground bergerak menggunakan algoritma ORB	ORB	ORB 40 kali lebih cepat dari SIFT dan 20 kali lebih cepat dari SURF dengan akurasi yang lebih baik
(Azad dkk., 2009)	Penerapan algoritma SIFT dengan Harris Corner Detector	SIFT Detector dan Harris Corner Detector	Scale invariant dapat diatasi dengan efektif dengan waktu pengolahan fitur 20ms pada resolusi 640 x 480.
(Karami dkk., t.t.)	Perbandingan Performa SIFT SURF dan ORB pada Image Matching	SIFT SURF ORB	Time (%match): SIFT = 0,132 (59,09%) SURF = 0,059 (39,48%) ORB = 0,027 (54,48%)

BAB III

LANDASAN TEORI

3.1 Closed Circuit Television (CCTV)

Video juga dapat didefinisikan sebagai gabungan citra (frame) yang dibaca secara berurutan dalam suatu waktu dengan kecepatan tertentu (Tekalp, 1995). Kecepatan pembacaan gabungan citra disebut *frame rate* dengan satuan fps (*frame per second*). *Frame rate* mengindikasikan jumlah citra (*frame*) yang ditampilkan setiap detik.

CCTV merupakan sistem pengawasan elektronik yang menggunakan kamera video, yang terhubung dengan sirkuit tertutup untuk merekam, menangkap, mengumpulkan, dan menyampaikan informasi visual mengenai status kejadian pada suatu tempat dalam waktu tertentu (Deisman, 2003).

Pada tahun 1997, CCTV digital dirancang untuk memperbaiki kinerja CCTV analog. Sistem CCTV digital mengkonversi sinyal video analog menjadi data digital, dan kemudian menyimpannya ke media penyimpanan. Kemampuan video digital memungkinkan data dapat ditransmisi dan disimpan dengan biaya yang lebih murah dibandingkan dengan CCTV analog. CCTV digital juga dapat melakukan pengolahan data dalam jumlah besar secara efisien.

3.2 Analisis Video

Video mengandung beragam informasi yang ditampilkan secara visual tentang suatu adegan (*scene*). Analisis video dilakukan dengan menganalisis seluruh konten informasi yang terkandung dalam video. Terdapat dua tahap dalam menganalisis video, yaitu memecah video menjadi shot-shot dan memilih keyframe yang dapat mewakili setiap shot.


3.3 Segmentasi Video

Segmentasi video digunakan untuk mengidentifikasi perubahan frame pada tiap shot. Perubahan diantara dua frame atau kesenjangan antara shot sering disebut Cut (Sudha dan Priyadarshini, 2015). File video dipecah kedalam shot-shot yang masing-masing mempunyai keyframe yang berguna untuk proses identifikasi.

Setelah dilakukan segmentasi, keyframe dilakukan perbandingan dengan frame lainnya untuk melihat tingkat kesamaan antar frame sehingga bisa dipilih keyframe yang paling tepat untuk mewakili shot. Secara umum pemilihan keyframe menggunakan frame pertama pada tiap scene, namun hal ini terkadang kurang tepat dalam mewakili sebuah scene

3.4 Citra Digital

Citra merupakan fungsi malar (kontinyu) dari intensitas cahaya pada bidang 2 dimensi (dwimatra). Secara matematis, fungsi intensitas cahaya pada bidang dwimatra disimbolkan dengan $f(x, y)$. Nilai (x, y) adalah koordinat pada bidang dwimatra. Nilai $f(x, y)$ adalah intensitas cahaya pada titik (x, y) . Jika x, y , dan nilai intensitas dari f tersebut berhingga, bernilai diskrit, citra tersebut disebut citra digital. Satuan terkecil dari citra digital disebut pixel atau *picture element*. Citra digital yang memiliki M baris dan N kolom memiliki $M \times N$ buah pixel. Umumnya citra dibentuk dari kotak kotak persegi empat yang teratur sehingga jarak horizontal dan vertikal antar pixel adalah sama pada seluruh bagian citra. Gambar 3.1 menunjukkan ilustrasi dari citra.



Gambar 3.1 Ilustrasi citra digital.(Gonzalez dkk., 2004)

Citra digital lazim dinyatakan dalam bentuk matriks yang berukuran M baris dan M kolom sebagai berikut.

$$f(x, y) \approx \begin{bmatrix} f(0,0) & f(0,1) & \cdots & f(0, N) \\ f(1,0) & f(1,1) & \cdots & f(1, N) \\ \vdots & \vdots & \vdots & \vdots \\ f(M-1,0) & f(M-1,1) & \cdots & f(M-1, N-1) \end{bmatrix}$$

3.4.1 Citra Berwarna

Warna yang dilihat oleh manusia dalam suatu objek ditentukan oleh sifat cahaya yang dipantulkan oleh objek tersebut. Benda berwarna biru akan memantulkan cahaya dengan panjang gelombang 500 – 570 nm dan menyerap sebagian besar energi dari panjang gelombang yang lain. Begitu juga dengan warna biru yang memantulkan cahaya dengan panjang gelombang 450 – 495 nm dan warna merah yang memantulkan cahaya dengan panjang gelombang 620 – 700 nm. Cahaya yang dipantulkan oleh sebuah objek akan diterima oleh retina mata. Karena sifat-sifat penyerapan dari mata manusia ini, maka warna dapat dilihat sebagai variasi kombinasi dari warna primer yaitu merah biru dan hijau.

Citra berwarna merupakan jenis citra yang menyajikan dalam bentuk 3 komponen warna yaitu Red (merah), Green (Hijau) dan Blue (Biru). Setiap komponen direpresentasikan dalam 8bit (bernilai 0 – 255) sehingga dengan kombinasi ketiga warna tersebut akan didapat 256 x 256 x 256 atau 16.581.375 varian warna. Berikut representasi citra berwarna.



Gambar 3.2 Representasi Citra Berwarna

3.4.2 Citra Grayscale

Grayscale adalah generalisasi multidimensi operasi biner. Objek yang dikenal sebagai foto hitam dan putih adalah gambar grayscale. Seringkali, intensitas grayscale disimpan sebagai 8-bit integer yang memberikan 256 kemungkinan warna abu-abu dari hitam sampai putih. Warna abu-abu adalah salah satu komponen warna merah, hijau dan biru yang semuanya memiliki intensitas yang sama dalam RGB, sehingga hanya diperlukan untuk menentukan nilai intensitas tunggal untuk setiap pixel (Gonzalez dan Woods, 2008). Formula yang digunakan untuk operasi grayscale sebagaimana persamaan (3.1). Contoh citra grayscale ditunjukkan pada Gambar 3.3.

$$Grayscale = w_R R + w_G G + w_B B \quad (3.1)$$

Dimana :

- w_R = Bobot elemen warna merah
- w_G = Bobot elemen warna hijau
- w_B = Bobot elemen warna biru
- R = Nilai intensitas warna merah pada *pixel*
- G = Nilai intensitas warna hijau pada *pixel*
- B = Nilai intensitas warna biru pada *pixel*



Gambar 3.3 Contoh citra *grayscale*

3.4.3 Citra Biner

Citra biner adalah citra yang hanya memiliki 2 nilai derajat keabuan yaitu hitam dan putih. Contoh aplikasi citra biner adalah citra logo instansi, citra kode batang (bar code), citra hasil pemindaian dokumen teks dan sebagainya. Citra biner hanya memiliki 2 derajat keabuan yaitu hitam atau putih saja sehingga masing-masing pixel objek hanya akan memiliki 1 bit. Pixel objek hanya akan bernilai 0 untuk putih atau 1 untuk hitam. Gambar 3.4 merupakan contoh gambar citra biner.



Gambar 3.4 Barcode adalah contoh gambar citra biner

Keunggulan dari citra biner adalah

- Kebutuhan memori kecil karena setiap pixel dapat direpresentasikan hanya dengan 1 bit.
- Waktu pemrosesan lebih cepat karena operasi pada citra biner dilakukan sebagai operasi logika (and, or xor dll) daripada operasi aritmatika bilangan bulat.

3.5 K-Nearest Neighbour


K-Nearest Neighbour adalah salah satu algoritma machine learning yang menggunakan semua data latih untuk klasifikasi. KNN merupakan metode klasifikasi *non-parametric* yang sederhana namun efektif untuk beberapa kasus. Ide dari algoritma KNN adalah mencari kecocokan terdekat dari data uji pada ruang fitur. Untuk sebuah data t yang diklasifikasikan, sebanyak k tetangga terdekat dari data t diambil. Penentuan tetangga terdekat dapat menggunakan salah satu dari

beberapa fungsi perhitungan jarak seperti Manhattan Distance, Euclidean Distance, Minkowsky Distance, Tchebychev Distance, Cosine Distance dan Correlation Distance. Suara terbanyak dari tetangga tersebut digunakan untuk menentukan kelas dari data t dengan atau tanpa pertimbangan bobot jarak. Penentuan nilai k pada penerapan KNN sangat mempengaruhi keberhasilan dari klasifikasi data t . Ada banyak cara untuk memilih nilai k , tetapi yang sederhana adalah menjalankan algoritme beberapa kali dengan nilai k yang berbeda dan pilih salah satu nilai k yang menghasilkan kinerja terbaik.

Tahapan dalam penerapan KNN adalah sebagai berikut :

1. Untuk setiap data testing, hitung jaraknya ke masing-masing data latih.
2. Tentukan k data latih yang memiliki jarak paling dekat dengan data test.
3. Hitung label dari masing-masing k data yang berjarak paling dekat.
4. Label dengan frekuensi kemunculan terbanyak merupakan kelas dari data tes.
5. Masukkan data tes kedalam kelas sesuai hasil tahap 4.

Gambar 3. Merupakan contoh penerapan K nearest neighbors. Gambar (a) menunjukkan 1 nearest neighbour sehingga kelas dari tetangga terdekat menjadi kelas data t . Gambar (c) menunjukkan 3 nearest neighbour sehingga kelas dari data t ditentukan berdasarkan kelas dari 3 tetangga terdekat dari t .



Gambar 3. Contoh penerapan Nearest Neighbors.

3.6 Mixture of Gaussian

Model Mixture of Gaussians (MoG) digunakan untuk merepresentasikan distribusi normal subpopulasi dari keseluruhan populasi. Model campuran secara

umum tidak perlu mengetahui dari subpopulasi mana suatu titik data, yang memungkinkan model mempelajari subpopulasi secara otomatis. Karena asal subpopulasi tidak diketahui, maka Mixture of Gaussian merupakan salah satu algoritme Unsupervised learning. Mixture model telah digunakan untuk ekstraksi fitur dari data *speech*, dan juga telah digunakan secara luas dalam pelacakan multiple objek, di mana jumlah komponen campuran dan nilai rata-ratanya memprediksi lokasi objek di setiap *frame* dalam urutan video.

MOG merupakan salah satu metode dalam *background subtraction*. Metode ini digunakan untuk mendeskripsikan piksel dari background. Model ini dapat menerima multimodal background, sehingga merupakan model yang robust terhadap gerakan berulang dalam elemen latar, objek yang bergerak lambat, dan memperkenalkan atau menghapus objek dari latar. MOG akan memberikan fungsi-fungsi komponen Gaussian untuk tiap piksel, dengan input adalah warna piksel dimana model-model MOG terbentuk berdasarkan waktu. Model akan membentuk 2 komponen utama, yakni model background dengan model non-background atau bisa disebut sebagai foreground (Hanzi Wang dan Suter, 2005). Model background adalah model yang mencerminkan latar dari area yang diamati, sedangkan model foreground merupakan model yang mencerminkan objek yang bisa diamati.

Setiap piksel memiliki Model Gaussian sendiri. Model Gaussian terbentuk dari nilai piksel dari nilai waktu tertentu (Stauffer dan Grimson, 1999). Pengukuran sebelumnya dari setiap piksel, $\{X_1, \dots, X_t\}$ dapat dimodelkan menggunakan distribusi campuran dari K Gaussian. Kemungkinan untuk mengamati background saat itu dari sebuah piksel X_t adalah jumlah bobot dari distribusi K:

$$P(X_t) = \sum_{i=1}^K \omega_{i,t} * \eta(X_t, \mu_{i,t}, \Sigma_{i,t}) \quad (3.2)$$

Dimana K adalah banyaknya distribusi Gaussian, $\omega_{i,t}$ adalah perkiraan bobot dari distribusi Gaussian ke i^{th} saat waktu t, $\mu_{i,t}$ adalah rata-rata dari nilai Gaussian ke i^{th} saat waktu t, $\Sigma_{i,t}$ adalah matriks kovariansi dari Gaussian ke i^{th} saat waktu t,

dimana adalah fungsi kemungkinan kepadatan dari Gaussian ke i^{th} , yang diberikan oleh:

$$\eta(X_t, \mu, \Sigma) = \frac{1}{(2\pi)^{\frac{n}{2}} |\Sigma|^{\frac{1}{2}}} e^{-\frac{1}{2}(X_t - \mu)^T \Sigma^{-1}(X_t - \mu)} \quad (3.3)$$

K dapat ditentukan oleh kekuatan komputasi dan ketersediaan memori. Contohnya terdapat tiga distribusi Gaussian untuk mendeskripsikan sebuah piksel. Untuk menghindari biaya komputasi diasumsikan variasi dari warna Red, Green, Blue Pada persamaan (3.3), x dan y merupakan koordinat pojok kiri atas dari kotak human region detection, dan w serta h merupakan lebar dan tinggi. (RGB) sama, sehingga kovariansi matriks dapat didefinisikan sebagai:

$$\Sigma_{k,t} = \sigma_k^2 E \quad (3.4)$$

Algoritma memasukkan satu GMM ke tiap piksel dari gambar dan memperbaharui parameter dari model (nilai rata-rata dan variansi) secara langsung. Setiap kali sebuah piksel baru didapatkan piksel tersebut dicek dengan distribusi Gaussian K yang sudah ada (Zhang dkk., 2012). Distribusi Gaussian cocok jika memenuhi persamaan (3.5):

$$M_{k,t} = \begin{cases} 1, & |X_t - \mu_{k,t}| < \sigma \\ 0 & \end{cases} \quad (3.5)$$

Dimana X_t merupakan vektor dari warna piksel (R,G,B) untuk waktu t , merupakan vektor nilai mean (R,G,B) dari Gaussian ke h , dan adalah standar deviasi dari Gaussian ke. Suatu piksel dianggap sebagai foreground apabila piksel tidak cocok dengan semua distribusi yang ada dan dibuat distribusi baru dengan menggantikan distribusi yang distribusi yang paling tidak mencerminkan background.

Jika tidak ada nilai piksel yang cocok dengan distribusi K, distribusi yang paling mungkin digantikan dengan distribusi dengan nilai yang ada sekarang sebagai nilai rata-ratanya. Bobotnya diatur sebagai berikut:

$$\eta \omega_{k,t} = (1 - \alpha) \omega_{k,t-1} + \alpha(M_{k,t}) \quad (3.6)$$

Dimana α merupakan tingkat learning, M_k , adalah 1 jika ada kecocokan dan 0 jika kecocokan tidak ditemukan. Parameter μ dan σ untuk distribusi yang tidak cocok tetap sama. Untuk distribusi yang cocok parameter tersebut diperbaharui seperti berikut:

$$\mu_t = (1 - \rho) \mu_{t-1} + \rho X_t \quad (3.7)$$

$$\sigma_t^2 = (1 - \rho) \sigma_{t-1}^2 + \rho (X_t - \mu_t)^T (X_t - \mu_t) \quad (3.8)$$

$$\rho = \alpha \eta(X_t | \mu_t, \sigma_t) \quad (3.9)$$

Untuk menentukan Gaussian yang mana dari GMM yang merepresentasikan background, dilakukan penyortiran dengan menggunakan nilai ω / σ . Nilai ini semakin tinggi dengan semakin sedikitnya variansi dari distribusi dan semakin banyaknya distribusi yang digunakan. Hal ini mengarah ke Gaussian dari GMM dimana distribusi yang paling mencerminkan background tetap berada di atas dan distribusi yang kurang mencerminkan background semakin berada di bawah yang nantinya akan digantikan oleh distribusi yang baru. Distribusi B yang pertama dipilih sebagai model background, dimana:

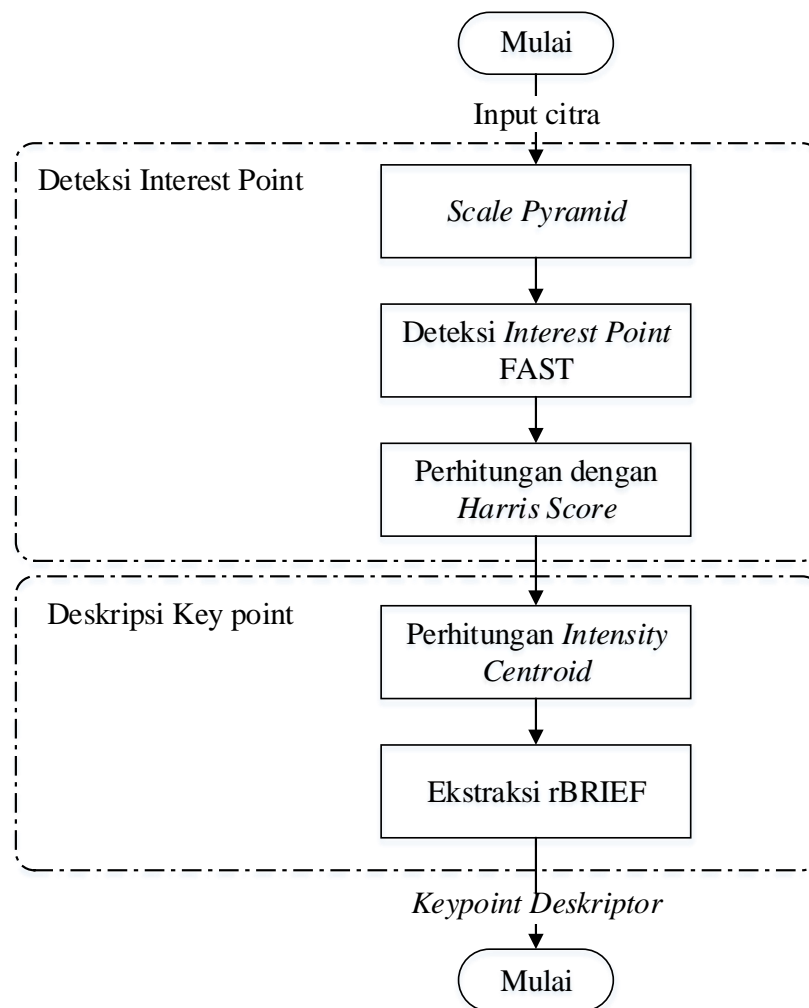
$$B = \underset{b}{\operatorname{argmin}} \left(\sum_{k=1}^b \omega_k > T \right) \quad (3.10)$$

3.7 Ekstraksi Fitur

Deteksi objek dapat dilakukan dengan banyak cara. Salah satu cara untuk melakukan deteksi objek adalah dengan melakukan deteksi interest point terlebih dahulu kemudian memberikan descriptor kepada interest point tersebut. Cara seperti ini akan menghasilkan fitur yang bersifat local. Beberapa Metode untuk yang menggunakan teknik fitur local ini seperti SIFT, SURF dan ORB. Conte dkk.(2010) telah membandingkan ketiga metode tersebut untuk melakukan deteksi objek. Hasilnya adalah ORB memiliki kecepatan 40 kali lebih cepat dari SIFT dan 20 kali lebih cepat dari SURF dengan akurasi yang lebih baik.

3.8 Oriented FAST Rotated BRIEF

Metode ORB merupakan metode yang dikembangkan dari metode FAST *keypoint detector* dan juga BRIEF *descriptor* (Calonder dkk., 2010). Kedua metode tersebut memiliki performa yang sangat baik namun memiliki kekurangan dalam *rotational invariance*, sehingga pada penggabungan dua metode tersebut dilakukan suatu proses untuk menangani hal tersebut. Gambar 3.5 menunjukkan tahapan algoritma ORB. ORB dikembangkan sebagai alternatif dari algoritma SIFT dan SURF. Tidak seperti SIFT dan SURF, ORB merupakan algoritma bebas lisensi (Rublee dkk., 2011).




Gambar 3.5 Tahapan algoritma ORB

3.8.1 Scale Pyramid

Penerapan *scale pyramid* bertujuan untuk memberikan ketahanan terhadap masalah penskalaan. *Scale pyramid* adalah perulangan yang dilakukan diberbagai skala citra untuk mendapatkan keypoint dari citra untuk masing-masing skala. Sebuah fitur tidak akan dideteksi sebagai fitur baru dengan ukuran atau skala yang berbeda sekalipun. *Scale pyramid* dikombinasikan dengan metode-metode deteksi sudut. Algoritma ORB mengkombinasikan *scale pyramid* dengan deteksi sudut FAST dan Harris. Deteksi sudut FAST dan Harris dilakukan pada setiap skala dari citra asli. FAST digunakan untuk menentukan *interest point* dari citra. *Interest point* dihitung nilai *Harris*-nya. Apabila nilai *Harris* lebih dari batas tertentu, maka *Interest point* dianggap sebagai *keypoint*. Lakukan penskalaan dengan mengalikan panjang citra dengan skala dan lebar citra dengan skala.

Langkah-langkah *Scale Pyramid* adalah :

1. Deteksi keypoint dari citra asli menggunakan metode FAST.
2. Hitung nilai Harris Corner dari masing-masing keypoint.
3. Tentukan N keypoint yang terpilih berdasarkan nilai Harris Corner-nya.
4. Lakukan penskalaan seperti pada gambar 3.6.
5. Ulangi langkah 1 sampai dengan 3 sampai banyaknya iterasi telah tercapai.



Gambar 3.6 Struktur piramida (Bay dkk, 2006)

3.8.2 FAST

Features from Accelerated Segment Test atau FAST adalah salah satu metode untuk menemukan keypoint dalam sistem real-time yang mencocokkan fitur visual. Kelemahan dari FAST adalah tidak menghasilkan fitur *multiscale* dan tidak

memiliki operator orientasi. Oleh karena itu, perlu digunakan *scale pyramid* terhadap citra untuk menghasilkan fitur FAST (berdasar *Harris filter*) disetiap tingkat piramida. *Scale pyramid* digunakan agar perbedaan skala atau ukuran dari citra data latih dan citra frame video tidak menimbulkan masalah sebagaimana ditunjukkan pada Gambar 3.7. FAST harus dilanjutkan dengan *Intensity Centroid* agar memiliki operator orientasi.




Gambar 3.7 *Scale pyramid* data latih dan *frame* video

3.8.3 oFAST


Algoritma ini merupakan pengembangan dari algoritma *Features from Accelerated Segment Test* (FAST). FAST memiliki kelemahan terhadap *multiscale* dan orientasi oleh karena itu perlu dikombinasikan dengan *scale pyramid* dan *intensity centroid*. Penggabungan ini menghasilkan teknik oFAST atau FAST dengan orientasi.

Tahapan algoritma FAST dalam menemukan *keypoint*, pertama melakukan pengecekan pada suatu titik secara acak. Titik tersebut disebut titik pusat. Kemudian beri label pada 16 *pixel* yang membentuk lingkaran yang mengitari *pixel* pusat dengan angka 0 sampai F searah jarum jam sebagaimana ditunjukkan Gambar 3.8.



Gambar 3.8 Ilustrasi *pixel* pusat dan 16 *pixel* disekitarnya pada *detector* FAST

Penentuan titik kandidat fitur dengan cara membandingkan secara biner intensitas warna pada *pixel* pusat dengan intensitas warna yang terdapat pada 16 lingkaran disekitarnya. Jika terdapat lebih dari 8 *pixel* yang lebih gelap atau lebih terang dari *pixel* pusat q , maka q menjadi *keypoint*. Gambar 3.9 merupakan contoh hasil penentuan *keypoint* citra yang diberi tanda bulatan hijau.




Gambar 3.9 Ilustrasi hasil deteksi *keypoint* dengan *detector* FAST.

Langkah-langkah deteksi *keypoint* dengan FAST adalah :

1. Pilih titik p dengan koordinat (x, y) secara random.
2. Tentukan 16 titik di sekitar titik $p(x, y)$.

3. Bandingkan titik p dengan 16 titik disekitar titik p.
4. Hitung jumlah titik yang :
 - a. Lebih cerah dari titik p
 - b. Lebih gelap dari titik p
5. Jika jumlah titik yang lebih cerah dari titik p lebih dari 8 titik, atau jika jumlah titik yang lebih gelap dari titik p lebih dari 8 titik, maka titik p adalah keypoint.

Seperti telah disampaikan, FAST tidak mendukung adanya variasi orientasi. Oleh karena itu dikembangkan oFAST. Pada oFAST, setelah ditemukan *keypoint-keypointnya*, tahapan dilanjutkan dengan menentukan sebanyak N titik terbaik menggunakan *Harris corner*. Gambar 3.10 menunjukkan hasil penerapan *Harris corner* yang memfilter *keypoint* hanya pada posisi sudut.



Gambar 3.10 Hasil penerapan *Harris corner*

$$M = \sum_{x,y} w(x,y) \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix} \quad (3.11)$$

$$R = \det M - k (\text{trace } M)^2$$

Dimana :

M : Matriks 2x2 dari turunan citra (operasi operator Sobel)

W : Ukuran *window*

I_x : Nilai intensitas *pixel* terhadap turunan x

I_y : Nilai intensitas *pixel* terhadap turunan y

R : Nilai *Harris corner*

K : [0.04, 0.06]

Nilai kurang dari 0 menunjukkan daerah tepi, nilai $|R|$ kecil menunjukkan daerah datar, sedangkan nilai R besar menunjukkan *corner*. Ilustrasi perhitungan Harris *corner* ditunjukkan pada Gambar 3.11.

1	7	3	4	9
3	2	6	5	7
2	8	8	1	5
9	3	7	4	2
8	7	4	6	3

Gambar 3.11 Contoh matriks penerapan Harris *corner*.

Langkah-langkah perhitungan Harris adalah:

1. Menghitung I_x dan I_y menggunakan operator Sobel (G_x dan G_y), sebagaimana ditunjukkan Gambar 3.12.

G_x	I_x																		
<table border="1"><tr><td>-1</td><td>0</td><td>1</td></tr><tr><td>-2</td><td>0</td><td>2</td></tr><tr><td>-1</td><td>0</td><td>1</td></tr></table>	-1	0	1	-2	0	2	-1	0	1	<table border="1"><tr><td>14</td><td>-4</td><td>5</td></tr><tr><td>13</td><td>-10</td><td>-10</td></tr><tr><td>-2</td><td>-6</td><td>-14</td></tr></table>	14	-4	5	13	-10	-10	-2	-6	-14
-1	0	1																	
-2	0	2																	
-1	0	1																	
14	-4	5																	
13	-10	-10																	
-2	-6	-14																	
G_y	I_y																		
<table border="1"><tr><td>1</td><td>2</td><td>1</td></tr><tr><td>0</td><td>0</td><td>0</td></tr><tr><td>-1</td><td>-2</td><td>-1</td></tr></table>	1	2	1	0	0	0	-1	-2	-1	<table border="1"><tr><td>-8</td><td>-8</td><td>5</td></tr><tr><td>-9</td><td>-2</td><td>6</td></tr><tr><td>0</td><td>4</td><td>-4</td></tr></table>	-8	-8	5	-9	-2	6	0	4	-4
1	2	1																	
0	0	0																	
-1	-2	-1																	
-8	-8	5																	
-9	-2	6																	
0	4	-4																	

Gambar 3.12 Hasil perhitungan I_x dan I_y

2. Menghitung I_x^2, I_y^2 dan $I_x I_y$ dan menentukan ukuran window (missal 3×3), sebagaimana ditunjukkan pada Gambar 3.13.

I_x	I_y	$I_x I_y$																																																																											
<table border="1"><tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>0</td><td>14</td><td>-4</td><td>5</td><td>0</td></tr><tr><td>0</td><td>13</td><td>-10</td><td>-10</td><td>0</td></tr><tr><td>0</td><td>-2</td><td>-6</td><td>-14</td><td>0</td></tr><tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr></table>	0	0	0	0	0	0	14	-4	5	0	0	13	-10	-10	0	0	-2	-6	-14	0	0	0	0	0	0	<table border="1"><tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>0</td><td>-8</td><td>-8</td><td>5</td><td>0</td></tr><tr><td>0</td><td>-9</td><td>-2</td><td>6</td><td>0</td></tr><tr><td>0</td><td>0</td><td>4</td><td>-4</td><td>0</td></tr><tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr></table>	0	0	0	0	0	0	-8	-8	5	0	0	-9	-2	6	0	0	0	4	-4	0	0	0	0	0	0	<table border="1"><tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr><tr><td>0</td><td>-112</td><td>32</td><td>25</td><td>0</td></tr><tr><td>0</td><td>-117</td><td>20</td><td>-60</td><td>0</td></tr><tr><td>0</td><td>0</td><td>-24</td><td>56</td><td>0</td></tr><tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr></table>	0	0	0	0	0	0	-112	32	25	0	0	-117	20	-60	0	0	0	-24	56	0	0	0	0	0	0
0	0	0	0	0																																																																									
0	14	-4	5	0																																																																									
0	13	-10	-10	0																																																																									
0	-2	-6	-14	0																																																																									
0	0	0	0	0																																																																									
0	0	0	0	0																																																																									
0	-8	-8	5	0																																																																									
0	-9	-2	6	0																																																																									
0	0	4	-4	0																																																																									
0	0	0	0	0																																																																									
0	0	0	0	0																																																																									
0	-112	32	25	0																																																																									
0	-117	20	-60	0																																																																									
0	0	-24	56	0																																																																									
0	0	0	0	0																																																																									
I_x^2	I_y^2																																																																												
<table border="1"><tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr></table>	0	0	0	0	0	<table border="1"><tr><td>0</td><td>0</td><td>0</td><td>0</td><td>0</td></tr></table>	0	0	0	0	0																																																																		
0	0	0	0	0																																																																									
0	0	0	0	0																																																																									

0	196	16	25	0	0	64	64	25	0
0	169	100	100	0	0	81	4	36	0
0	4	36	196	0	0	0	16	16	0
0	0	0	0	0	0	0	0	0	0

Gambar 3.13 Hasil perhitungan I_x^2 , I_y^2 dan $I_x I_y$

- Menghitung nilai R Harris *corner* menggunakan persamaan (3.12).

$$M = \begin{bmatrix} 842 & -180 \\ -180 & 306 \end{bmatrix} \quad (3.12)$$

$$R = 225252$$

- Nilai R lebih dari 0 dan besar, menunjukkan titik (3, 3) merupakan *corner*.

Variasi orientasi terhadap *keypoint* menggunakan teknik *intensity centroid*. Orientasi merupakan atribut yang diberikan kepada *keypoint* berdasarkan pixel-pixel disekitarnya. Atribut orientasi menunjukkan sudut yang terbentuk antara garis antara *keypoint* dan *centroid* (pusat) dengan garis horizontal. Pendekatan berdasarkan orientasi *intensity centroid* menggunakan ukuran sederhana namun efektif dari sudut orientasi *keypoint* dari *centroid*. Intensitas *centroid* mengasumsikan bahwa intensitas sudut yang terkoreksi dari pusat, dan *vector* ini dapat digunakan untuk menghubungkan orientasi. Untuk mendapatkan C atau titik tengah (*centroid*) suatu citra dilakukan perhitungan dengan persamaan (3.13). (Rao dan Ikenaga, 2017).

$$C(\bar{x}, \bar{y}) = \left(\frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right) \quad (3.13)$$

$$\bar{x} = \frac{m_{10}}{m_{00}}, \bar{y} = \frac{m_{01}}{m_{00}}$$

Dimana:

$C(\bar{x}, \bar{y})$: pusat koordinat obyek

m_{00} : momen tingkat ke-0

m_{10}, m_{01} : momen tingkat ke-1

Menurut (Rosin, 1999), nilai m atau momen dicari dengan mendefinisikan moment patch sebagaimana persamaan (3.14).

$$m_{pq} = \sum_{x,y} x^p y^q I(x, y) \quad (3.14)$$

dimana:

$I(x, y)$: Nilai intensitas *pixel* pada koordinat x, y

m_{pq} : Momen dengan order $(p + q)$


Dengan menggunakan nilai momen, dapat dibuat sebuah *vector* dari pusat sudut O , ke *centroid*, OC . Secara sederhana orientasi dari *patch* ditunjukkan pada persamaan (3.15).

$$\theta = \text{atan2}(m_{01}, m_{10}) \quad (3.15)$$

dimana:

θ : Sudut dari pusat sudut O ke *centroid*.

Pada Gambar 3.14b menunjukkan arah *keypoint* berpengaruh terhadap variasi rotasi citra. Keypoint mempunyai arah dengan menghitung sudut terhadap titik tengah citra.



Gambar 3.14 Arah keypoint a) Penentuan arah keypoint b) Variasi rotasi citra

3.8.4 BRIEF

Tahap selanjutnya setelah mendapatkan *keypoint-keypoint*, melakukan ekstraksi *binary descriptor* menggunakan algoritma *Binary Robust Independent Elementary Features* (BRIEF). ORB menggunakan *descriptor* BRIEF yang berfungsi untuk melakukan deskripsi terhadap 31×31 *patch* disekitar *keypoint* (setiap *patch* dibuat 5×5 *subpatch*) yang dilakukan *smoothing* pada citra untuk dilakukan *binary test* (Calonder dkk., 2010). Menurut (Rublee dkk., 2011) ORB mengambil 2 *subpatch* untuk dilakukan evaluasi intensitasnya, apakah lebih besar *subpatch* pertama atau kedua sehingga mendapatkan nilai nilai biner 0 atau 1. Ilustrasi *binary descriptor* ditunjukkan pada Gambar 3.15. Untuk melakukan *binary test* τ pada p dengan ukuran 5×5 menggunakan persamaan (3.16).

$$\tau(p; x, y) := f(x) = \begin{cases} 1, & p(x) < p(y) \\ 0, & p(x) \geq p(y) \end{cases} \quad (3.16)$$

Dimana:

p : Potongan gambar yang sudah dilakukan smoothing

$p(x)$: Nilai intensitas dari p saat berada di titik x

$p(y)$: Nilai intensitas dari p saat berada di titik y


Untuk mencari nilai *vector* dan *n binary test* sebagai nilai fiturnya menggunakan persamaan (3.17).

$$f_n(p) := \sum_{1 \leq i \leq n} 2^{i-1} \tau(p; x_i, y_i) \quad (3.17)$$

Dimana:

n : Nilai learning pada ORB yaitu 256.

ORB menggunakan nilai *learning* $n = 256$ untuk *random sampling* menggunakan *Gaussian distribution* yang menunjukkan lokasi di sekitar titik tengah dari *patch* yang dipilih. Penggunaan variasi rotasi pada BRIEF dilakukan dengan *steering* pada BRIEF berdasarkan orientasi *keypoint*.



Gambar 3.15 Ilustrasi binary descriptor citra

Pada Gambar 3.15, dilakukan perbandingan antara pixel pertama dengan pixel kedua yang dipilih. Jika *pixel* pertama lebih terang daripada *pixel* kedua maka bernilai 1, sebaliknya akan bernilai 0. Contoh penerapan algoritma ORB pada citra ditampilkan pada Gambar 3.16.



Gambar 3.16 Contoh hasil penerapan algoritma ORB.

3.9 Algoritma Mean Shift

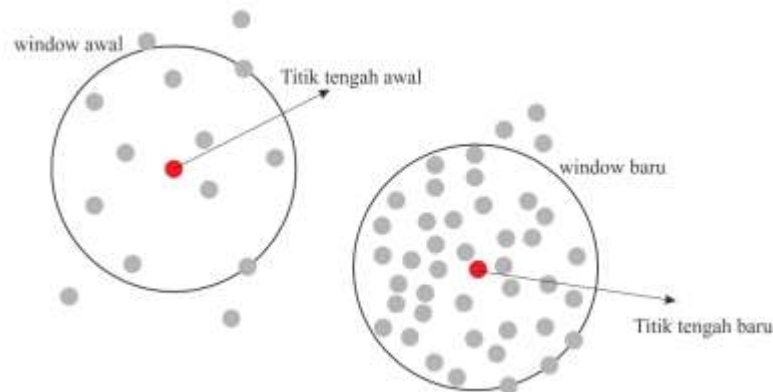
Algoritma klustering bertujuan untuk mengelompokkan *keypoint* kedalam kluster. Kluster-kluster tersebut merupakan kandidat objek. Menurut (Comaniciu dan Meer, 2002), algoritma Mean-Shift berbasis pada titik pusat kluster, yang selalu memperbarui kandidat pusat kluster dengan menghitung *mean* pada semua titik sesuai daerah *window*. *Window* adalah sebuah nilai yang digunakan untuk menentukan seberapa luas area kluster. Titik didalam windows dimasukkan kedalam perhitungan penentuan pusat kluster. Selanjutnya kandidat pusat kluster dilakukan *filtering* untuk menghilangkan duplikasi pusat kluster yang berdekatan. Kandidat pusat kluster x_i pada iterasi t dilakukan update terus menerus dengan persamaan (3.18).

$$x_i^{t+1} = m(x_i^t) \quad (3.18)$$

dimana,

$N(x_i)$: tetangga titik sampel pada jarak yang diberikan disekitar x_i

m : vektor Mean-Shift yang dihitung pada setiap pusat kluster yang menunjuk ke suatu daerah yang terjadi peningkatan titik density.



Gambar 3.17 Ilustrasi algoritma Mean-Shift

Ilustrasi algoritma Mean-Shift ditunjukkan pada Gambar 3.17. Pembaruan pusat kluster $m(x_i^t)$ supaya menjadi mean dari titik sampel yang berada dalam ketetanggaan dilakukan menggunakan persamaan (3.19).

$$m(x_i) = \frac{\sum_{x_j \in N(x_i)} K(x_j - x_i) x_j}{\sum_{x_j \in N(x_i)} K(x_j - x_i)} \quad (3.19)$$

Algoritma Mean-Shift secara otomatis menentukan jumlah kluster, hal ini berdasarkan parameter *bandwidth* yang menentukan ukuran daerah (*window*) pencarian. Parameter ini dapat diinput secara manual atau menggunakan estimasi *bandwidth* menggunakan fungsi `estimate_bandwidth`. Algoritma ini pada waktu dijalankan membutuhkan beberapa pencarian tetangga terdekat sesuai parameter *bandwidth*. Algoritma akan berhenti ketika perubahan posisi titik pusat kluster kecil.

Tahapan Algoritme Mean-Shift adalah sebagai berikut :

1. Anggap semua *keypoint* sebagai pusat kluster.
2. Pada masing-masing pusat kluster, tentukan anggota kluster. Anggota kluster adalah *keypoint-keypoint* yang berjarak kurang dari *window* yang ditentukan (berada didalam lingkaran dengan radius nilai *window*).


3. Lakukan *filtering* terhadap kluster. Apabila ada kluster yang memiliki anggota yang tepat sama, maka kluster tersebut diwakili oleh 1 kluster saja untuk menghilangkan duplikasi.
4. Hitung nilai rata-rata dari setiap *keypoint* didalam kluster yang sama. Hasil nilai rata-rata dianggap sebagai pusat kluster yang baru.
5. Lakukan perulangan poin nomor 2 sampai dengan 4 sampai tidak terjadi perubahan anggota kluster pada setiap kluster (sudah konvergen).

3.10 Klasifikasi

Algoritma klasifikasi merupakan algoritma pembelajaran terarah atau *supervised learning* yang digunakan untuk melakukan prediksi terhadap sesuatu yang akan digolongkan kedalam kelas tertentu. Algoritma klasifikasi memerlukan data untuk belajar yaitu data latih. Kemudian setelah pelatihan, akan terbentuk model. Data uji digunakan pada model tersebut untuk mendapatkan hasil klasifikasi. Algoritma klasifikasi yang digunakan pada penelitian kali ini adalah *Support Vector Machine* (SVM). Algoritma SVM digunakan pada data latih untuk membentuk model yang dapat mengklasifikasikan suatu objek sebagai manusia atau bukan manusia.

3.11 Support Vector Machine

Support Vector Machine (SVM) adalah salah satu metode pembelajaran mesin yang termasuk kedalam pembelajaran terarah. SVM dapat digunakan untuk proses klasifikasi maupun regresi. Pada algoritma klasifikasi, SVM digunakan untuk melakukan prediksi suatu data termasuk kedalam kelas tertentu. Tujuan dari SVM adalah untuk menemukan *hyperplane* pemisah yang optimal yang dapat memisahkan kelas satu dengan kelas yang lain. Pemisah yang optimal adalah *hyperplane* yang memiliki jarak yang maksimal dari data-data setiap kelas. *Hyperplane* pada satu dimensi disebut titik. Pada dua dimensi disebut garis, pada tiga dimensi disebut *plane* sedangkan pada lebih dari 3 dimensi disebut *hyperplane*. *Margin* adalah jarak antara *hyperplane* dengan *support vector* atau titik data yang terdekat. *Hyperplane* yang optimal adalah *hyperplane* yang memiliki margin pemisah yang terbesar.



Gambar 3.18 Hyperplane pada SVM membagi menjadi dua kelas (Nugroho dkk., 2003)

Sebuah data set $\{(x_1, y_1), \dots, (x_l, y_l)\}$ dengan $x_i \in R^d$ dan $y_i \in \{-1, 1\}$. Proses pelatihan SVM dilakukan untuk menemukan parameter w dan b dari suatu fungsi linier $f(x) = w \cdot x + b$ untuk menemukan *hyperplane* yang optimal. Diasumsikan bahwa kedua kelas dapat dipisahkan dengan sempurna / *linierly separable data* oleh *hyperplane*. Hyperplane akan didefinisikan dengan persamaan (3.20). (Nugroho dkk., 2003).

$$w \cdot x_i + b = 0 \quad (3.20)$$

Dengan w merupakan normal bidang dan b merupakan posisi relatif bidang terhadap pusat koordinat. Data x_i akan masuk kedalam kelas negatif apabila memenuhi pertidaksamaan (3.21).

$$w \cdot x_i + b \leq -1 \quad (3.21)$$

Sedangkan data x_i akan masuk kedalam kelas positif apabila memenuhi pertidaksamaan (3.22).

$$w \cdot x_i + b \geq 1 \quad (3.22)$$

Margin yang optimal dapat dicari dengan memaksimalkan jarak antara hyperplane dengan titik data yang berada paling dekat dari masing-masing kelas. Jarak ini dirumuskan sebagai $1/\|w\|$. Pada tahap memaksimalkan $1/\|w\|$ sama dengan meminimumkan $\|w\|^2$. Pada pertidaksamaan (3.12) dan (3.13) dapat direpresentasikan dalam pertidaksamaan (3.23). (Sembiring, 2007).

$$y_i(w \cdot x_i + b) - 1 \geq 0 \quad (3.23)$$

Maka untuk mencari bidang pemisah terbaik dengan nilai margin terbesar dapat dirumuskan menjadi masalah optimasi konstrain pada pertidaksamaan (3.24) (Sembiring, 2007).

$$\begin{aligned} \min \frac{1}{2} \|w\|^2 \\ \text{s. t } y_i(w \cdot x_i + b) - 1 \geq 0 \end{aligned} \quad (3.24)$$

Apabila data tidak terpisah secara linier / nonlinierly separable, maka kernel trick dapat dilakukan untuk menyelesaikan masalah tersebut. Terdapat beberapa fungsi kernel yang dapat digunakan diantaranya (Sembiring, 2007):

1. Kernel Linier

$$K(x_i, x) = x_i^T x \quad (3.25)$$

2. Kernel Polynomial

$$K(x_i, x) = (\gamma \cdot x_i^T x + r)^2, \quad \gamma > 0 \quad (3.26)$$

3. Kernel RBF (Radial Basis Function)

$$K(x_i, x) = \exp(-\gamma \cdot |x_i - x|^2), \quad \gamma > 0 \quad (3.27)$$

Fungsi kernel yang direkomendasikan untuk diuji pertama kali yaitu fungsi kernel RBF. Kernel RBF memiliki performansi yang sama dengan kernel linier pada parameter tertentu (Sembiring, 2007).

Pada algoritma SVM terdapat beberapa parameter yang dapat digunakan yaitu nilai C dan nilai gamma. Parameter ini nantinya dapat mempengaruhi hasil dari performa algoritma SVM. Nilai C merupakan nilai toleransi saat kesalahan pada proses klasifikasi. Semakin besar nilai C berarti akan memberikan penalti yang lebih besar pula terhadap error klasifikasi (Nugroho dkk., 2003). Nilai gamma merupakan jarak cakupan data dari hyperplane yang digunakan untuk melakukan proses klasifikasi.

3.12 Evaluasi Sistem Perhitungan Orang

Pengukuran evaluasi pengujian dapat dilakukan dengan menggunakan tabel klasifikasi yang bersifat prediktif. Tabel klasifikasi tersebut bernama *confusion*

matrix sebagaimana ditunjukkan pada Tabel 3.1. *Precision* (ketepatan) adalah rasio jumlah prediksi relevan yang ditemukan dengan jumlah total yang ditemukan oleh sistem. *Precision* berkaitan dengan kualitas himpunan jawaban, tetapi tidak berpengaruh terhadap jumlah total dokumen yang relevan dalam kumpulan dokumen. Persamaan (3.28) menunjukkan rumus perhitungan *precision*. *Recall* dihitung sesuai dengan persamaan (3.29). *F-measure* dihitung sesuai dengan persamaan (3.30).

Tabel 3.1 Indikasi performa hasil klasifikasi dengan confusion matrix

Total Population		Predicted	
		Prediction positive	Prediction negative
True Condition	Condition positive	True Positive (TP)	False Negative (FN)
	Condition negative	False Positive (FP)	True Negative (TN)

$$Precision = \frac{TP}{TP + FP} \quad (3.28)$$

$$Recall = \frac{TP}{TP + FN} \quad (3.29)$$

$$f = 2 * \frac{(Precision * Recall)}{(Precision + Recall)} \quad (3.30)$$

3.13 OpenCV

Open Computer Vision (OpenCV) merupakan library open source untuk computer vision C/C++ dan juga terdapat library di bahasa pemrograman Python. Menurut Pulli dkk. (2012) OpenCV adalah sebuah Application Programming Interface (API) library yang sangat familiar pada pengolahan citra computer vision. Tujuannya adalah agar komputer mempunyai kemampuan yang mirip dengan cara pengolahan visual pada manusia. OpenCV mempunyai API untuk high level maupun low level, terdapat fungsi-fungsi yang siap digunakan, baik untuk loading, saving, akuisisi gambar maupun video. Penggunaan computer vision juga berperan penting dalam mengambil keputusan, melakukan aksi, dan mengenali terhadap suatu objek dengan komputer. Beberapa pengimplementasian dari computer vision



UNIVERSITAS
GADJAH MADA

**PERHITUNGAN ORANG PADA VIDEO SURVEILLANCE MENGGUNAKAN METODE ORIENTED FAST
ROTATED BRIEF DAN SUPPORT
VECTOR MACHINE**

CANGGIH GELAR S A, Dr. Raden Sumiharto, S.Si., M.Kom.; Wahyono, S.Kom., Ph.D
Universitas Gadjah Mada, 2021 | Diunduh dari <http://etd.repository.ugm.ac.id/>

adalah face recognition, face detection, face/object tracking, object detection, feature matching, road tracking, dan lain-lain.

BAB IV

METODOLOGI PENELITIAN

4.1 Studi Literatur

Tahap awal penelitian adalah dengan melakukan studi literatur. Studi literatur dilakukan dengan mempelajari penelitian terkait sebelumnya dari artikel dan publikasi jurnal serta mempelajari teori dari buku dan sumber-sumber lain termasuk informasi yang diperoleh melalui internet. Salah satu bahan referensi adalah Digital Image Processing (3rd ed.). Referensi yang digunakan dalam penelitian ini adalah yang berkaitan dengan pentingnya penerapan perhitungan orang, teknik-teknik deteksi objek dan teknik klasifikasi.

4.2 Prosedur Kerja

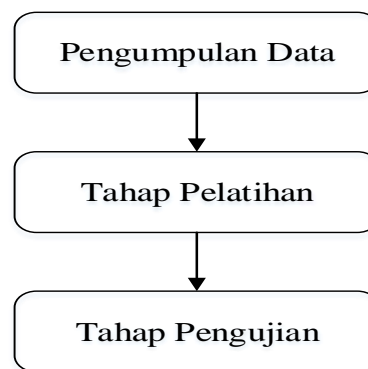
4.2.1 Perancangan Sistem

Penelitian yang dilaksanakan bertujuan untuk perhitungan orang pada video CCTV. Alur penelitian ini dilakukan dengan langkah kerja beserta indicator kesuksesan sebagaimana pada Gambar 4.1. Tahapan penelitian memiliki indicator kesuksesan seperti pada tabel 4.1.

Rancangan sistem ditunjukkan pada Gambar 4.2 yang dimulai dengan Pengambilan data citra latih. Setiap data latih dilakukan *pre-processing* yaitu merubah citra warna menjadi citra *grayscale*. Setelah citra latih diubah menjadi grayscale, dilakukan ekstraksi fitur dengan menggunakan ORB pada semua data latih. Deteksi objek ORB menghasilkan keypoint dan deskriptor. Keypoint yang didapatkan dikelompokkan kedalam klaster dengan menggunakan teknik clustering *Mean-Shift*.

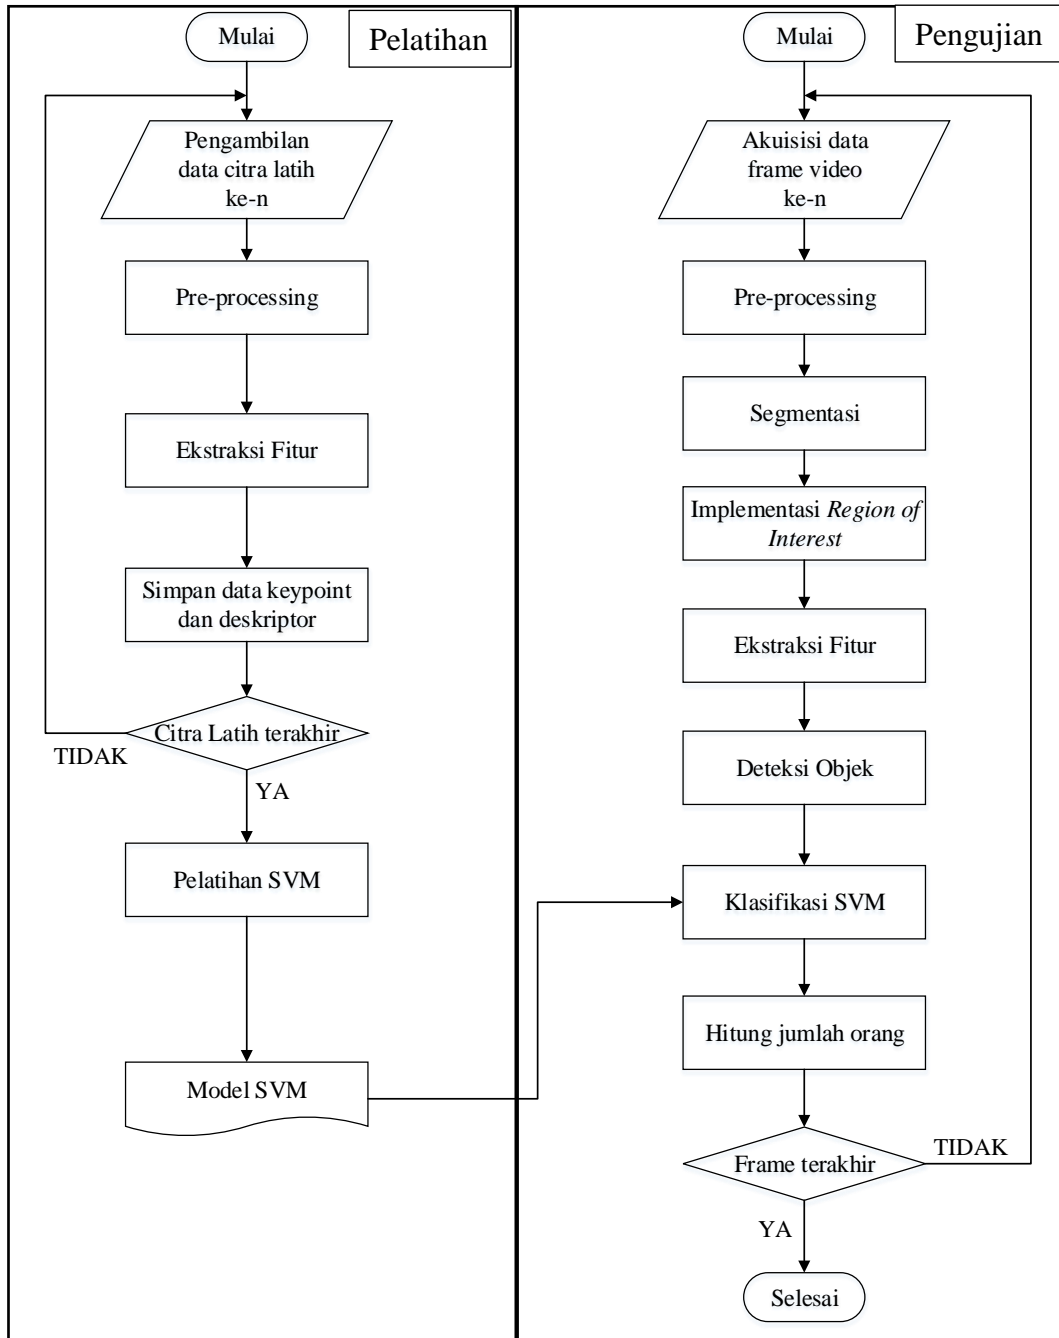
Tabel 4.1 Tabel tahapan penelitian beserta indikator kesuksesan

Tahapan Penelitian	Indikator Kesuksesan
Tahap Pengumpulan Data	Data Rekaman CCTV didapatkan
Tahap Pelatihan	Model SVM dengan akurasi 70%
Tahap Pengujian	Program mampu deteksi objek tertutup sebagian dengan performa diatas nilai f-measure > 0.5



Gambar 4.1 Rencana kegiatan penelitian

Pengelompokkan keypoint menjadi kluster berdasarkan lokasi keypoint. Setelah terbentuk kluster, masing-masing kluster akan dilakukan pelatihan dengan menggunakan SVM untuk mendapatkan *hyperplane* yang memisahkan kelas manusia dengan non manusia. Model Hyperplane ini akan digunakan untuk melakukan proses klasifikasi pada data pengujian. Pada proses pengujian, Video dari CCTV akan dilakukan segmentasi video supaya menjadi data citra yang berurutan atau biasa disebut *frame*. Setiap frame dilakukan pre-processing untuk mengubah menjadi citra *grayscale*. Setelah citra latih diubah menjadi grayscale, dilakukan deteksi objek dengan menggunakan ORB. Hasil deteksi objek ini kemudian diimplementasikan pada model SVM yang telah dibuat dengan menggunakan data latih untuk dapat menentukan objek manusia dan non manusia. Setelah objek manusia terdeteksi, kemudian dilakukan perhitungan jumlah orang.



Gambar 4.2 Rancangan sistem

4.3 Pengumpulan Data

Data yang digunakan sebagai input dari penelitian ini adalah rekaman yang diambil menggunakan kamera CCTV didalam ruang kelas 420 di gedung S2/S3 Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Gadjah Mada.

4.4 Tahap Pelatihan

4.4.1 Pengambilan Data Citra

Tahap akuisisi data dilakukan dengan melakukan cropping pada objek-objek yang terekam pada frame rekaman video CCTV lantai 4 gedung S2/S3 Fakultas FMIPA UGM. Citra hasil *cropping* pada frame video dipisahkan antara citra yang mengandung objek yang merupakan manusia dan citra yang mengandung objek-objek selain objek human. Citra yang mengandung objek manusia disimpan pada folder manusia. Citra yang tidak mengandung objek manusia disimpan pada folder non human.

4.4.2 Tahap Pre-processing

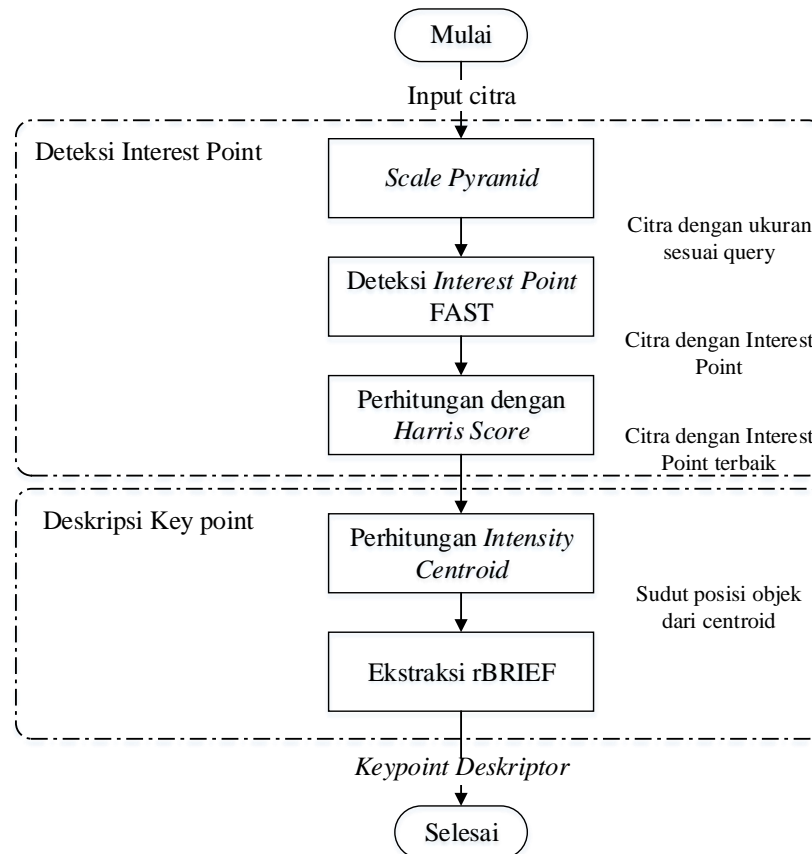
Tahapan *preprocessing* yang diperlukan adalah konversi citra ke citra *grayscale* karena pemrosesan algoritme ORB menggunakan citra *grayscale*. Formula yang digunakan untuk operasi *grayscale* sebagaimana persamaan (3.1). Pada penelitian kali ini, skala keabuan didapatkan dengan menggunakan metode Luminosity dengan tipe BT.601. BT601 merupakan standar format untuk standar-definition television (SDTV) dengan nilai skala keabuan didapatkan dengan persamaan (4.1). Input dari tahapan preprocessing pada tahap pelatihan adalah citra hasil cropping pada frame video.

$$I = 0,2989R + 0,587G + 0,1141B \quad (4.1)$$

4.4.3 Ekstraksi Fitur

Ekstraksi Fitur merupakan proses mengekstrak fitur citra seperti warna dan tekstur dari *frame*. Ekstraksi Fitur pada penelitian ini menggunakan algoritma *Oriented FAST and Rotated BRIEF* (ORB). Algoritma ORB digunakan untuk menghasilkan *keypoint* dari citra melalui fitur-fitur yang menonjol pada citra. Tahapan untuk memperoleh *keypoint* dimulai dengan transformasi *scale pyramid* pada citra. Kemudian mendeteksi suatu titik menggunakan *FAST detector* untuk

mendeteksi titik sudut dari citra. FAST mendeteksi suatu keypoint misalnya pixel p dibandingkan dengan 16 pixel disekelilingnya yang membentuk lingkaran. Pixel lingkaran diurutkan kedalam 3 kelas, yaitu lebih terang dari p , lebih gelap dari p , dan sama dengan p . Jika terdapat lebih dari 8 pixel yang lebih gelap atau lebih terang dari p , maka p menjadi keypoint. Hasil deteksi FAST kemudian dihitung menggunakan Harris *Corner* untuk mencari *keypoint* terbaik.



Gambar 4.3 Tahapan Ekstraksi Fitur


Setelah didapat *keypoint* dilakukan pencarian orientasi menggunakan intensitas *centroid*. Hasil dari tahap ini kemudian diekstraksi menggunakan algoritma BRIEF. Karena BRIEF tidak memiliki variasi rotasi, maka digunakan rBRIEF dimana BRIEF akan diarahkan sesuai *keypoint*nya. Tahap selanjutnya adalah dilakukan perbandingan nilai seluruh *sampling pairs* (*pixel* pertama dengan *pixel* kedua), jika *pixel* pertama lebih terang daripada *pixel* kedua maka bernilai 1, sebaliknya akan

bernilai 0. Proses seperti ini akan diulang sampai terpenuhi 256 pasangan. Tahapan penerapan algoritma ORB pada *frame* video ditunjukkan pada Gambar 4.3.

1. *Scale Pyramid*

Scale pyramid diawali dari citra asli. Tahapan *Scale pyramid* adalah sebagai berikut :

- a. Gunakan citra asli dari *frame* video yang akan diolah.
- b. Olah menggunakan FAST hingga didapatkan kandidat *keypoint*.
- c. Lakukan pengecilan ukuran citra dengan mengalikan lebar dengan skala dan mengalikan tinggi citra dengan skala.
- d. Ulangi langkah (b) hingga ukuran iterasi dipenuhi.



Gambar 4.4 Ilustrasi tahap *Pyramid Scale*

2. FAST

FAST digunakan untuk mendeteksi titik sudut dari citra. FAST adalah tidak menghasilkan fitur *multiscale* sehingga perlu dikombinasikan dengan *scale pyramid* terhadap citra untuk menghasilkan fitur FAST (berdasar Harris

filter) disetiap tingkat piramida. Tahapan dari FAST adalah sebagai berikut:


- a. Pilih titik p dengan koordinat (x, y) secara random.
- b. Tentukan 16 titik di sekitar titik $p(x, y)$ dengan ketentuan :
- c. Jika titik p berada di koordinat $p(x,y)$, maka 16 titik pembanding berada di koordinat :

$t1(x, y+3)$, $t2(x+1, y+3)$, $t3(x+2, y+2)$, $t4(x+3, y+1)$, $t5(x+3, y)$,
 $t6(x+3, y-1)$, $t7(x+2, y-2)$, $t8(x+1, y-3)$, $t9(x, y-3)$, $t10(x-1, y-3)$, $t11(x,$
 $y-2)$, $t12(x-3, y-1)$, $t13(x-3, y)$, $t14(x-3, y+1)$, $t15(x-2, y+2)$, $t16(x-1,$
 $y+3)$. Ilustrasi titik pembanding seperti pada gambar 4.5

		P16 (x-1,y+3)	P1 (x,y+3)	P2 (x+1,y+3)		
	P15 (x-2,y+2)				P3 (x+2,y+2)	
P14 (x-3,y+1)						P4 (x+3,y+1)
P13 (x-3,y)			P(x,y)			P5 (x+3,y)
P12 (x-3,y-1)						P6 (x+3,y-1)
	P11 (x-2,y-2)				P7 (x+2,y-2)	
		P10 (x,y-3)	P9 (x,y-3)	P8 (x,y-3)		

Gambar 4.5 Ilustrasi titik kandidat keypoint dan titik pembanding.

- d. Bandingkan titik p dengan 16 titik disekitar titik p .
- e. Hitung jumlah titik yang :
 - a. Lebih cerah dari titik p
 - b. Lebih gelap dari titik p
- f. Jika jumlah titik yang lebih cerah dari titik p lebih dari 8 titik, atau jika jumlah titik yang lebih gelap dari titik p lebih dari 8 titik, maka titik p adalah keypoint.



Gambar 4.6 Ilustrasi tahap FAST (Rosten dan Drummond, 2006)

Sebagai contoh, pada Gambar 4.6, titik yang dipilih memiliki warna hitam. Titik terpilih p dibandingkan dengan 16 titik di sekitarnya. Dari hasil perbandingan intensitas, dihasilkan titik $t_1, t_2, t_3, t_4, t_5, t_6, t_{12}, t_{13}, t_{14}, t_{15}$ dan t_{16} memiliki warna lebih cerah dibandingkan titik p . Titik p termasuk kedalam *keypoint* karena terdapat 12 titik disekitar titik p yang lebih cerah dari titik p .

3. *Harris Corner*

Harris corner digunakan untuk memilih *keypoint* yang berada disudut. *Harris corner* dilakukan dengan menggunakan operator *Sobel*. Operator *sobel* digunakan untuk melakukan deteksi tepi. Sudut dapat dipahami sebagai pertemuan dua tepi sehingga dengan mendeteksi dua tepi yang bersinggungan, maka titik singgung adalah sudut. Tahapan dari penerapan *Harris Corner* adalah sebagai berikut:

- a. Tentukan Operator *Sobel* horizontal dan operator *Sobel* vertical.
- b. Lakukan *sliding windows* dengan menggunakan operator *Sobel* tersebut untuk mendapatkan
- c. Sudut dapat dipahami sebagai pertemuan dua sisi, maka titik pertemuan tersebut memiliki nilai R yang besar sesuai dengan persamaan (3.11).

4. *Intensity Centroid*

Deteksi *interest point* FAST tidak dapat mendeteksi orientasi dari objek sehingga jika pada saat *matching* objek berada pada posisi miring, maka FAST tidak dapat melakukan deteksi dengan baik. Penerapan *Intensity centroid* dapat mengatasi masalah tersebut. Kombinasi FAST dengan *intensity centroid* menghasilkan detector FAST yang dapat mengenai

orientasi atau biasa disebut oFAST. Tahapan pada penerapan *intensity centroid* adalah sebagai berikut :

- a. Tentukan objek yang akan ditinjau.
- b. Hitung koordinat centroid dari objek tersebut.
- c. Bandingkan posisi setiap keypoint dari objek dengan centroid dari objek. Hasilnya adalah orientasi dari masing-masing keypoint.

5. BRIEF

BRIEF memberikan deskriptor pada keypoint yang sudah didapatkan dengan metode oFAST. Deskriptor tersebut didapatkan dengan membandingkan intensitas pada keypoint dengan titik disekitar keypoint. Jumlah titik pembanding dapat dipilih antara 128, 256 ataupun 512 titik. ORB menggunakan BRIEF256 yang artinya jumlah titik pembanding ada 256 titik. Pemilihan titik pembanding dilakukan dengan random sampling menggunakan Gaussian distribution yang menunjukkan lokasi di sekitar titik tengah dari patch yang dipilih. Hasil perbandingan hanya bernilai 0 dan 1. Hasil bernilai 0 jika titik keypoint lebih gelap daripada titik pembanding dan bernilai 1 jika keypoint lebih terang. Urutan 256 bit hasil perbandingan tersebut diubah menjadi 32 bit desimal dengan masing-masing bit desimal dengan rentang antara 0 sampai dengan 255 yang mewakili 8bit hasil perbandingan. Hasil akhir dari BRIEF adalah 32 fitur yang mewakili 256 bit hasil perbandingan. Tahapan dari BRIEF adalah sebagai berikut :

- a. Pilih keypoint yang akan diuji.
- b. Pilih 256 titik disekitar keypoint dengan menggunakan *Gaussian distribution*.
- c. Bandingkan masing-masing titik dengan keypoint. Beri nilai 0 jika keypoint lebih gelap dan beri nilai 1 jika keypoint lebih cerah.
- d. Urutkan hasil pembanding menjadi 256 hasil perbandingan.
- e. Bagi masing-masing kedalam 8bit.
- f. Ubah setiap 8 bit kedalam desimal antara 0 sampai dengan 255.
- g. Urutkan 32 bit desimal sebagai fitur / deskriptor hasil dari BRIEF.

Gambar 4.7 adalah contoh hasil penerapan ORB terhadap citra. Dari contoh tersebut dapat dilihat bahwa titik keypoint yang dihasilkan algoritma ORB selalu berada di sudut dari objek.



a)

b)

Gambar 4.7 Hasil Deteksi Fitur menggunakan algoritma ORB a) Citra asli

b) Citra setelah diolah dengan ORB

Tabel keypoint dan deskriptor adalah sebagai berikut :

Tabel 4.2 Tabel Deteksi Fitur ORB

Koordinat keypoint	Deskriptor
(309 , 142)	[63 79 98 78 87 149 250 112 73 76 125 207 104 200 183 164 126 169 151 239 196 51 44 255 54 76 128 169 127 191 122 213]
(205 , 158)	[64 176 185 248 109 237 241 95 171 93 52 24 156 159 112 58 173 27 127 17 19 111 178 209 223 221 26 110 208 0 167 250]
(232 , 127)	[7 91 155 219 164 134 175 208 214 216 209 102 148 214 241 104 220 121 31 223 195 197 59 240 129 24 175 204 152 59 49 177]
(192 , 132)	[216 220 151 254 155 196 23 166 190 26 136 0 190 247 33 114 225 115 108 82 106 15 154 127 249 230 6 90 48 17 37 43]

4.4.4 Penyimpanan Data keypoint dan Descriptor

Hasil dari deteksi objek berupa nilai lokasi *keypoint* (x, y) dan deskriptor seperti ditunjukkan pada tabel 4.1. Data disimpan sampai semua citra didalam data latih telah dilakukan ekstraksi fitur. Data yang telah disimpan ini kemudian dilakukan pelatihan dengan menggunakan metode SVM Hasil deteksi objek dari data latih

akan dilakukan pelatihan dengan menggunakan SVM untuk mendapatkan model SVM yang telah di latih. Hasil deteksi objek dari frame video CCTV akan diimplementasikan pada model SVM yang telah dilatih untuk dapat membedakan objek manusia dan non manusia.

4.4.5 Pelatihan SVM

Tahap training adalah tahap pelatihan mesin agar dapat mengenali manusia dan bukan manusia. Data set diberikan perlakuan sampai dengan deteksi objek. Data training diolah menggunakan algoritma ORB sehingga menghasilkan keypoint dan deskriptor. Hasil ini kemudian diolah dengan metode SVM untuk menghasilkan model klasifikasi. Training menggunakan nilai $c = 1$ menggunakan sample data kepala dan pundak. Sample data berisi sampel data positif yang berupa gambar kepala dan pundak dan juga sampel negatif yang berisi gambar lain. Contoh data training positif seperti pada gambar 4.8. Contoh data training negatif seperti pada gambar 4.9.



Gambar 4.8 Contoh sampel citra training positif




Gambar 4.9 Contoh sampel citra training negatif

Citra training diproses (deteksi objek) untuk mendapatkan keypoint dan deskriptor menggunakan algoritme ORB. Data keypoint dan deskriptor kemudian dilatih dengan menggunakan SVM untuk mendapatkan bobot dan *support vector* terbaik yang dapat melakukan klasifikasi antara manusia dan non manusia.

4.4.6 Pembentukan Model SVM

Validasi dilakukan dengan metode *K-Fold Cross Validation*. Pada metode ini, data latih akan dibagi menjadi beberapa bagian sebanyak nilai K. Misalkan nilai K adalah 5, maka data latih akan dibagi menjadi 5 bagian. Kemudian pilih blok pertama sebagai data uji dan 4 bagian data yang lain sebagai data training sampai didapatkan nilai akurasi. Iterasi kedua dilakukan dengan blok kedua sebagai data testing dan 4 blok selain blok kedua sebagai data training. Lakukan iterasi sampai setiap blok pada data latih pernah menjadi data testing. Jika nilai K 5, maka iterasi akan dilakukan sebanyak 5 kali. Kemudian nilai akurasi yang didapat dari setiap iterasi dijumlahkan dan dibagi dengan jumlah iterasi yang dilakukan untuk mendapatkan nilai rata-rata. Ilustrasi K-Fold Cross Validation seperti ditunjukkan pada Gambar 4.10.




Gambar 4.10 Ilustrasi K-Fold Cross Validation.

4.5 Tahap Pengujian

4.5.1 Akuisisi Data

Tahap pra pemrosesan dilakukan dengan segmentasi video menjadi frame. Video dengan ukuran gerakan 30 fps memiliki 30 frame setiap detik. Dengan benchmark kecepatan pengolahan cascade SURF yaitu 20ms, maka ukuran gerakan 30 fps akan dapat diolah dengan baik oleh sistem sehingga tidak diperlukan pemilihan frame atau sistem bisa berjalan secara realtime.



Gambar 4.11 Tidak diperlukan pemilihan frame.

4.5.2 Pre-processing

Setelah tahap segmentasi video menjadi frame video, tahapan preprocessing dilanjutkan dengan konversi citra ke citra *grayscale*. Metode konversi citra *grayscale* sama seperti pada tahap pelatihan. Input dari tahapan preprocessing pada tahap pengujian adalah citra hasil segmentasi video.

4.5.3 Segmentasi

Tahap segmentasi bertujuan untuk memisahkan antara *foreground* dengan *background*. *Background* pada video CCTV berupa lorong, bangku, kusen dan

objek lain selain objek manusia. Penerapan tahap segmentasi dengan menggunakan metode *Mixture of Gaussian* (MOG). Masukan dari tahap segmentasi adalah citra *grayscale* hasil dari tahap preprocessing. Hasil dari tahap segmentasi adalah citra dengan warna hitam untuk *background* dan warna putih untuk *foreground*.

4.5.4 Implementasi *Region of Interest*

Region of interest adalah area pada citra yang dipilih untuk diproses pada tahap selanjutnya. Area diluar *region of interest* diberi masking kemudian ditutup dengan warna putih. Area pada *region of interest* dibiarkan tetap seperti citra aslinya. Hal ini dilakukan agar area pencarian terfokus pada area yang dilalui oleh manusia. Masukan dari *region of interest* adalah citra yang telah terpisahkan antara *background* dan *foreground*. Hasil dari *Region of interest* adalah citra dengan warna asli pada area *region of interest* dan berwarna putih untuk pixel diluar area *region of interest*.

4.5.5 Ekstraksi Fitur

Tahapan ekstraksi fitur pada pengujian sama dengan tahapan ekstraksi fitur pada pelatihan. Masukan dari tahap ekstraksi fitur adalah citra yang telah dilakukan *masking* dengan *region of interest*. Hasil dari tahap ekstraksi fitur adalah pasangan antara koordinat *keypoint* dengan *descriptor*.

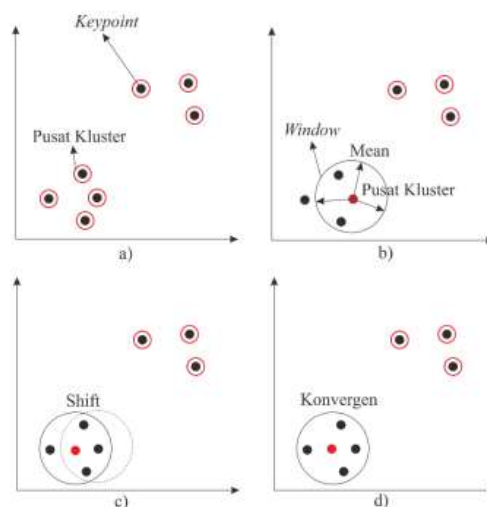
4.5.6 Deteksi Objek

Deteksi Objek adalah merupakan proses yang digunakan untuk menentukan keberadaan objek tertentu didalam citra digital. Proses deteksi objek dilakukan dengan mengelompokkan fitur citra seperti warna dan tekstur dari *keyframe* untuk proses temu kembali *frame* video. Deteksi Objek pada penelitian ini menggunakan algoritma *Mean-Shift*. *Mean-shift* digunakan karena klaster *keypoint* yang dihasilkan oleh masing-masing frame dari video berubah-ubah. Penentuan pusat klaster pada frame berdasarkan ukuran *bandwidth* yang dihitung otomatis dengan fungsi *estimate_bandwidth*.

Koordinat dari *keypoint* yang telah terdeteksi pada tahap deteksi fitur dilakukan pengelompokan dengan *Mean-Shift Clustering*. Klaster yang terbentuk dari

kumpulan *keypoint* menjadi sebuah objek. Objek ini akan diklasifikasikan kedalam kelas manusia atau non manusia pada tahap berikutnya yaitu tahap klasifikasi objek.

Tahapan klustering algoritma Mean-Shift dimulai dengan menyimpan titik koordinat *keypoint* hasil ekstraksi fitur algoritma SIFT, SURF, atau ORB. Semua *keypoint* menjadi pusat kluster, sebagaimana ditunjukkan pada Gambar 4.12a. Selanjutnya ukuran *window* (*kernel bandwidth*) ditentukan otomatis dengan *estimate_bandwidth*. Kemudian penentuan lokasi awal *window* hasil estimasi *bandwidth*. Sesuai nama algoritmanya, algoritma ini melakukan perhitungan *mean* pusat kluster terhadap semua titik pada *window*. Pada awalnya pusat kluster pada semua *keypoint*, sebagaimana ditunjukkan Gambar 4.12b. Kemudian melakukan pergeseran (*Shift*) pada daerah yang lebih padat dengan mengupdate nilai *mean* pusat kluster dengan titik ketetanggaannya menggunakan persamaan (3.19), sebagaimana ditunjukkan pada Gambar 4.12c. Algoritma berhenti ketika posisi pusat kluster sudah tidak berubah, sebagaimana ditunjukkan pada Gambar 4.12d.



Gambar 4.12 Ilustrasi algoritma *Mean-Shift*

Masukan dari tahap deteksi objek adalah kumpulan pasangan *keypoint* dan deskriptor. *Keypoint-keypoint* tersebut dikelompokkan kedalam kluster berdasarkan koordinatnya. Setiap kluster yang terbentuk merupakan kandidat objek. Hasil dari

tahap deteksi objek adalah kumpulan kluster yang didalam kluster terdiri dari sekumpulan *keypoint*.

Gambar 4.13 menunjukkan ilustrasi pengelompokan *keypoint* ke dalam kluster. *Keypoint-keypoint* dikelompokkan kedalam kluster berdasarkan lokasinya. Gambar 4.13 menunjukkan terdapat 2 kluster sehingga terdapat 2 kandidat objek yang selanjutnya diklasifikasi dengan menggunakan model SVM yang telah dilatih.



4.13 Ilustrasi pengelompokan *keypoint* kedalam kluster

4.5.7 Klasifikasi SVM

Kandidat objek yang terbentuk pada tahap deteksi objek dilakukan klasifikasi dengan model SVM yang telah dilatih pada tahap pelatihan. Kumpulan *deskriptor* dari kandidat objek dimasukkan ke dalam model SVM. Kandidat objek yang diklasifikasikan sebagai manusia oleh model SVM dihitung sebagai 1 orang. Kandidat yang diklasifikasikan sebagai *non-human* tidak dihitung.

4.5.8 Hitung Jumlah Orang

Tahapan penghitungan orang dilakukan dengan menambahkan *variable* dengan nilai 1 untuk setiap kandidat objek yang diklasifikasikan sebagai manusia oleh model SVM. Nilai akhir *variable* merupakan banyaknya orang yang berhasil dihitung oleh sistem pada suatu *frame* video. *Variable* diatur kembali menjadi 0 untuk setiap *frame* video.

4.6 Deteksi objek tertutup sebagian

Deteksi objek dapat dilakukan dengan menggunakan metode *local descriptor* karena fitur yang diekstrak bersifat lokal. Apabila sebagian fitur hilang karena tertutup oleh objek lain, maka fitur-fitur yang masih terlihat dapat digunakan untuk tahap klasifikasi.

Objek tertutup sebagian adalah sebuah objek yang sebagian areanya tertutup oleh objek lain. Objek dikatakan tertutup sebagian apabila ada sedikit saja bagian yang tertutup oleh objek lain dan masih terdapat bagian lain dari objek tersebut yang masih terlihat (tidak tertutup 100%). Gambar 4.14 menunjukkan contoh deteksi objek tertutup sebagian. Gambar 4.14 bagian (a) adalah gambar objek yang tidak tertutup objek lain. Pada gambar tersebut terdapat 10 titik keypoint dengan descriptor ditunjukkan pada tabel 4.3. Gambar 4.14 bagian (b) merupakan gambar objek yang sebagian tertutup oleh objek lain. Gambar 4.14 bagian (b) memperlihatkan area muka, leher dan badan tertutup sebagian oleh objek lain. Gambar tersebut terdapat 7 keypoint dengan descriptor ditunjukkan pada tabel 4.4. Pada gambar 4.13, terlihat 3 keypoint pada gambar 4.14 bagian (a) yang pada bagian (b) tertutup oleh objek lain. Keypoint gambar 4.14 bagian (a) yang tidak tertutup oleh objek lain cocok dengan keypoint pada gambar bagian (b). Dengan keypoint yang masih terlihat tersebut diharapkan objek dapat diklasifikasikan dengan benar sebagai objek manusia atau objek bukan manusia.



(a)

(b)

Gambar 4.14 Contoh Deteksi objek tertutup sebagian (a) Objek tidak tertutup

(b) objek tertutup sebagian

Tabel 4.3 Tabel Fitur objek tidak tertutup objek lain

Keypoint	Desc
46 125	122 235 35 147 135 174 231 44 112 145 171 250 14 5 176 243 91 214 47 223 51 13 102 202 38 169 182 147 76 115 131 231
49 134	122 171 242 185 149 174 37 51 84 17 38 94 14 5 182 65 67 146 31 26 2 9 231 234 102 163 184 83 46 115 33 227
50 131	122 171 172 31 179 143 39 55 84 1 39 124 14 129 178 227 79 198 171 218 98 137 230 226 230 167 184 19 44 115 33 226
56 174	243 43 225 172 9 44 226 54 71 110 180 188 98 23 144 165 134 124 43 119 240 11 37 73 100 209 242 175 139 26 79 91
71 118	92 155 23 189 36 42 1 0 48 178 138 200 10 12 79 110 169 219 27 70 18 107 202 166 98 169 156 253 42 248 191 225
86 120	198 121 50 254 223 6 92 229 61 56 218 141 18 99 246 178 4 208 83 238 160 33 127 28 57 65 208 126 58 5 188 9
89 54	114 104 183 25 214 135 101 187 93 65 46 218 64 183 176 209 119 130 223 24 52 142 103 200 6 39 82 147 60 119 2 239
95 170	218 244 142 125 240 227 46 73 220 145 41 91 212 180 34 74 115 194 194 208 125 158 78 137 145 12 20 81 116 163 34 229
97 175	120 244 135 29 224 226 126 137 184 177 15 123 204 60 38 216 123 67 250 89 29 188 6 131 151 46 23 32 100 240 130 224

Tabel 4.4 Tabel Fitur objek tertutup sebagian

Keypoint	Desc
45 133	122 43 96 27 211 166 167 55 112 17 43 90 26 1 180 193 75 150 63 152 33 11 230 194 38 229 176 147 76 115 163 226
47 136	250 107 240 91 215 166 167 47 125 129 51 94 18 161 180 65 11 18 63 153 41 136 231 192 36 97 184 83 92 55 32 162
55 60	114 232 185 147 246 198 227 171 93 161 46 219 64 54 176 193 103 2 223 218 114 140 103 192 86 111 86 211 84 119 18 234
60 56	114 105 189 21 231 198 229 171 93 161 46 251 0 183 176 225 103 6 223 217 112 140 231 192 70 111 210 211 84 119 2 234
65 121	28 171 47 181 39 15 84 241 178 24 76 200 14 133 88 247 91 208 162 126 183 1 66 252 98 143 243 66 42 98 14 111
84 122	118 249 181 12 164 66 101 8 57 129 191 252 8 38 147 44 134 77 187 255 243 165 101 212 94 227 190 217 16 118 24 66
97 57	114 104 189 27 228 198 103 187 93 1 46 222 64 182 176 209 103 2 223 216 114 140 229 192 6 103 18 211 28 119 16 234

4.7 Rancangan Implementasi

Tahap implementasi dilaksanakan dengan tahapan seperti pada gambar 4.1. Implementasi setiap tahap dilakukan dengan Bahasa pemrograman python versi 3.7.

4.7.1 Pengumpulan Data

Tahap pengumpulan data dilakukan dengan menggunakan kamera CCTV di lantai 4 gedung S2/S3 FMIPA UGM.

4.7.2 Preprocessing

Tahap *preprocessing* terdiri dari segmentasi video dan *grayscale* frame. Tahap segmentasi video adalah membagi video menjadi *frame*. Proses segmentasi video menggunakan pustaka python yaitu. *Grayscale* menggunakan metode *luminance* dengan tipe BT.601. Implementasi program dengan menggunakan pustaka python yaitu OpenCV.

4.7.3 Ekstraksi Fitur

Proses ekstraksi fitur menggunakan metode ORB. Implementasi metode ORB dengan menggunakan pustaka python yaitu OpenCV.

4.7.4 Deteksi Objek

Tahap deteksi objek adalah dengan menerapkan metode *clustering* K-Mean. Implementasi metode K-Mean dengan menggunakan pustaka python yaitu SKLearn.

4.7.5 Klasifikasi Objek

Tahap klasifikasi objek adalah dengan menerapkan metode klasifikasi *Support Vector Machine (SVM)*. Implementasi metode SVM dengan menggunakan pustaka python yaitu SKLearn.

4.7.6 Perhitungan orang

Tahap perhitungan orang dan tahap penggabungan program dilakukan oleh penulis.

4.8 Rancangan Pengujian Sistem

Pengujian sistem merupakan tahap lanjutan setelah implementasi algoritma ORB ke dalam sistem. Pengujian sistem dilakukan untuk membuktikan apakah sistem yang dibuat menggunakan ORB mampu menangani data oklusi. Proses perhitungan orang menggunakan 2 skenario video sebagai berikut:

1. Video kegiatan harian di lorong FMIPA UGM
2. Video dengan objek manusia tertutup sebagian / oklusi

4.8.1 Evaluasi Deteksi

Evaluasi deteksi dilakukan dengan membandingkan hasil yang dikeluarkan oleh sistem dengan perhitungan manual. Evaluasi deteksi memeriksa apakah seluruh orang yang ada pada citra telah terdeteksi. Hasil berupa perbandingan jumlah orang yang terhitung dengan jumlah orang sebenarnya.

4.8.2 Evaluasi Klasifikasi

Evaluasi klasifikasi dilakukan dengan membandingkan hasil yang dikeluarkan oleh sistem dengan perhitungan manual. Evaluasi klasifikasi memeriksa apakah seluruh objek orang diklasifikasikan dengan benar. Pengukuran evaluasi pengujian dapat dilakukan dengan menggunakan nilai f-measure yang didapatkan dari persamaan 3.30.

BAB V

IMPLEMENTASI

Implementasi penelitian mengenai perhitungan orang pada video surveillance menggunakan bahasa pemrograman Python 3.7.4. Tahapan implementasi perhitungan orang dibagi kedalam dua tahapan besar yaitu tahap pelatihan dan tahap pengujian. Tahap pelatihan diawali dengan tahap akuisisi data, preprocessing, ekstraksi fitur dan pembentukan model. Tahap pengujian dimulai dengan tahap akuisisi data, preprocessing, segmentasi, ekstraksi fitur, clustering hingga tahap matching.

5.1 Spesifikasi Hardware dan Software

Penelitian ini dilakukan dengan menggunakan hardware dan software dengan spesifikasi sebagai berikut:

Processor	: Processor Intel(R) Core(TM) i3-6006U CPU @ 2.00GHz, 1992 Mhz, 2 Core(s), 4 Logical Processor(s)
RAM	: 4,00 GB
VGA	: Name NVIDIA GeForce 920MX
Sistem Operasi	: OS Name Microsoft Windows 10 Home Single Language
Software	: JetBrains Pycharm Community Edition 2019.1.3
Library	: cv2, numpy, pickle, os, io, re dan sklearn

```
1. import cv2
2. import numpy as np
3. from sklearn.cluster import MeanShift, estimate_bandwidth
4. import pickle
5. import os
6. import io
7. import re
8. from sklearn.metrics import classification_report, confusion_matrix, accuracy_score
9. from sklearn.svm import LinearSVC
10. from sklearn.model_selection import cross_val_score
```

Gambar 5.1 *Library* digunakan pada pengembangan sistem perhitungan orang

Gambar 5.1 menunjukkan *source code library* yang digunakan untuk membangun sistem perhitungan orang pada video CCTV. *Library* pandas

digunakan untuk . *Library cv2* digunakan untuk pemrosesan citra. Pada sistem ini, *library cv2* digunakan untuk melakukan *background subtraction*, deteksi dan ekstraksi fitur menggunakan ORB dan menampilkan hasil pengolahan dari frame video. *Library numpy* digunakan untuk melakukan operasi vector dan matriks dengan mengolah array atau array multidimensi. Citra merupakan array dari intensitas sehingga pengolahan citra membutuhkan pengolahan array atau array multidimensi. Hal ini dapat dilakukan dengan menggunakan *library numpy*.

Library pickle digunakan untuk menyimpan features, model dan label kedalam bentuk file dan untuk membuka file model untuk digunakan pada tahap pengujian. *Library os* digunakan untuk mengakses file pada sebuah direktori. *Library re* digunakan untuk operasi pencocokan regular expression. Pada penelitian ini, *library re* digunakan untuk mencari file dengan ekstensi jpg. *Library sklearn* digunakan untuk pembelajaran mesin. *Library sklearn* menyediakan berbagai jenis algoritma klasifikasi, klustering maupun regresi. Pada penelitian ini, *library sklearn* digunakan untuk pembentukan model SVM, klasifikasi objek yang ditemukan, validasi model dengan menggunakan *K-Fold Cross Validation* dan untuk mengelompokkan keypoint kedalam kluster sesuai dengan posisi koordinat keypoint.

5.2 Tahap Pelatihan

5.2.1 Akuisisi Data

Tahap akuisisi data dilakukan dengan melakukan *cropping* pada objek-objek yang terekam pada frame rekaman video CCTV *channel 4* lantai 4 gedung S2/S3 Fakultas FMIPA UGM. Video yang digunakan sebagai data latih adalah video tanggal 20 November 2019 sampai dengan 28 November 2019 di jam 09:00 sampai dengan 13:30 sedangkan untuk data uji, video diambil pada tanggal yang sama di jam 13:30 sampai dengan jam 15:00. Tabel 5.1 menunjukkan pembagian data pelatihan dan data pengujian.

Setelah dilakukan *cropping* pada frame video, objek-objek dipisahkan antara objek yang merupakan manusia dan objek-objek selain objek manusia. Gambar 5.2 merupakan contoh hasil *cropping* frame video yang merupakan objek manusia

sedangkan gambar 5.3 adalah contoh hasil *cropping* video yang bukan merupakan objek manusia. Citra hasil *cropping* yang berisi objek manusia dikumpulkan didalam folder p sedangkan citra hasil *cropping* yang tidak mengandung objek manusia dikumpulkan didalam folder n. Hasil pemisahan dataset kedalam folder seperti pada gambar 5.4.

Tabel 5.1 Pembagian data latih dan data uji

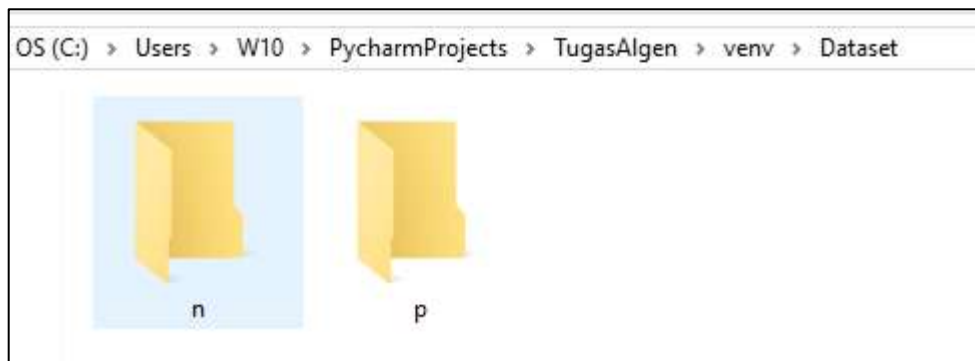
Tanggal	Jam	Banyak File	Total Durasi	Data Split
20-Nov	09:00 - 12:00	20	00:33:03	Latih
	12:00 - 15:00	11	00:02:50	Uji
21-Nov	09:00 - 12:00	6	00:31:18	Latih
	12:00 - 15:00	11	00:03:43	Uji
22-Nov	09:00 - 12:00	14	00:28:12	Latih
	12:00 - 15:00	8	00:03:48	Uji
25-Nov	09:00 - 12:00	5	00:19:18	Latih
	12:00 - 15:00	6	00:03:33	Uji
26-Nov	09:00 - 12:00	9	00:29:33	Latih
	12:00 - 15:00	11	-	Uji
27-Nov	09:00 - 12:00	10	00:23:27	Latih
	12:00 - 15:00	8	00:05:15	Uji
28-Nov	09:00 - 12:00	3	00:08:16	Latih
	12:00 - 15:00	8	-	Uji
Total Data Train			02:53:07	Latih
Total Data Tes			00:19:09	Uji



Gambar 5.2 Contoh citra dengan objek manusia



Gambar 5.3 Contoh citra dengan objek bukan manusia



Gambar 5.4 Contoh pemisahan dataset kedalam folder n dan p

5.2.2 Preprocessing

Tahap preprocessing yang dilakukan adalah dengan mengubah citra pada dataset dari citra berwarna menjadi citra grayscale. Proses grayscaling dilakukan dengan menggunakan nilai Luminance dengan standar BT.601 seperti pada persamaan (3.1). Tahap preprocessing dilakukan dengan menjalankan potongan kode berikut :

```
gray = cv2.cvtColor(img, cv2.COLOR_BGR2GRAY)
```

Gambar 5.5 Potongan kode penerapan grayscaling.

5.2.3 Ekstraksi Fitur

Tahap ekstraksi fitur menggunakan algoritma ORB. Algoritma ekstraksi fitur ORB melakukan deteksi keypoint pada citra kemudian melakukan perhitungan descriptor pada masing-masing keypoint. Lokasi keypoint dan descriptor dari masing-masing keypoint adalah fitur dari objek pada citra.

Penerapan ekstraksi fitur dengan algoritma ORB menggunakan library ORB yang merupakan bagian dari library cv2. Input dari algoritma ORB adalah citra grayscale. Hasil dari ORB adalah koordinat dari keypoint dan descriptor dari

masing-masing keypoint tersebut. Potongan kode untuk penerapan ORB ditunjukkan pada gambar 5.6.

```
1. if os.path.exists('features'):
2.     features = pickle.load(open('features', 'rb'))
3.     labels = pickle.load(open('labels', 'rb'))
4. else:
5.     dir_list = [x[0] for x in os.walk(images_dir)]
6.     dir_list = dir_list[1:]
7.     list_images = []
8.     for image_sub_dir in dir_list:
9.         sub_dir_images = [image_sub_dir + '/' + f for f in os.listdir(image_sub_dir) if re.search('jpg|JPG', f)]
10.        list_images.extend(sub_dir_images)
11.
12.        method = cv2.ORB_create()
13.        kps = method.detect(pre_img)
14.        kps, dsc = method.compute(pre_img, kps)
15.        dsc = dsc.flatten()
16.        needed_size = (vector_size * jmlfeatures)
17.        if dsc.size < needed_size:
18.            dsc = np.concatenate([dsc, np.zeros(needed_size - dsc.size)])
19.        features[ind, :] = dsc
20.        labels.append(imlabel)
21.        pickle.dump(features, open('features', 'wb'))
22.        pickle.dump(labels, open('labels', 'wb'))
23.        print('Features obtained and saved.')
```

Gambar 5.6 Potongan kode penerapan tahapan ekstraksi fitur

Tahap ekstraksi fitur diawali dengan memanggil library ORB dengan menggunakan perintah pada baris 12. Proses dilanjutkan dengan mencari titik-titik yang merupakan keypoint pada citra. Citra yang digunakan untuk mencari keypoint adalah “pre_img”. Pre_img adalah citra dari frame video yang telah diubah menjadi citra grayscale pada tahap preprocessing. Proses dilanjutkan dengan menghitung nilai descriptor dari masing-masing keypoint seperti ditunjukkan pada perintah baris 14. Baris 16 sampai dengan baris 18 bertujuan untuk menyeragamkan ukuran dari descriptor. Proses dilanjutkan dengan menyimpan descriptor kedalam array features dan menyimpan label dari descriptor kedalam array imlabel. Tahapan diakhiri dengan menyimpan variabel features kedalam file features dan variabel labels kedalam file labels.

5.2.4 Pembentukan Model

Tahap pembentukan model menggunakan algoritme SVM. Input dari pembentukan model adalah label dari citra dan nilai descriptor dari masing-masing

keypoint yang terdapat didalam citra tersebut. Nilai descriptor digunakan untuk menghitung nilai bobot dari masing-masing dimensi dalam SVM hingga didapatkan hyperplane yang dapat memisahkan antara kelas 1 dengan kelas yang lain. Model yang terbentuk disimpan agar model tersebut dapat dipanggil pada tahap pengujian.

Penerapan pembentukan model menggunakan algoritma SVM dilakukan dengan menggunakan library sklearn. Library sklearn memiliki banyak metode. Pada penerapan kali ini digunakan metode LinearSVC yang merupakan bagian dari method SVM didalam library sklearn. Potongan kode untuk tahap pembentukan model adalah sebagai berikut:

```
1. from sklearn.svm import LinearSVC
2. from sklearn.model_selection import cross_val_score
3.
4. X_train, X_test, y_train, y_test = model_selection.train_test_split(fe
   atures, labels, test_size=0.2, random_state=21)
5.
6. if os.path.exists('finalized_model.sav'):
7.     filename = 'finalized_model.sav'
8.     clf = pickle.load(open(filename, 'rb'))
9.
10. else:
11.     print('Support Vector Machine starting ...')
12.     clf = LinearSVC()
13.
14.     start_time = time.time()
15.     clf.fit(X_train, y_train)
16.     scores = cross_val_score(clf, features, labels, cv=5)
17.     print(scores)
18.     y_pred = clf.predict(X_test)
19.
20.     filename = 'finalized_model.sav'
21.     pickle.dump(clf, open(filename, 'wb'))
22.     print('Finalized model obtained and saved.')
```

Gambar 5.7 Potongan kode 5-Fold Validation pembentukan model

Tahap pembentukan model diawali dengan memanggil library LinearSVC dengan menggunakan perintah pada baris 1. Library cross_val_score dipanggil pada perintah baris 2 untuk membantu penerapan K-Fold validation. Tahapan dilanjutkan dengan membagi dataset menjadi data train dan data test seperti pada perintah baris 4. Baris ke 6 melakukan check model kedalam folder. Apabila sudah terdapat file “finalized_model.sav”, maka dilanjutkan dengan menyimpan model tersebut kedalam variabel clf. File “finalized_model.sav” adalah model yang sudah terbentuk sehingga apabila didalam folder sudah terdapat file tersebut, maka

training pembentukan model sudah pernah dilakukan. Apabila didalam folder tidak ditemukan file “finalized_model.sav”, maka tahapan akan dilanjutkan dengan melakukan training model. Tahapan training model diawali dengan membuat variabel clf yang merupakan model awal SVM seperti pada perintah baris ke 12. Pelatihan dilakukan dengan melakukan eksekusi perintah clf.fit pada baris ke 15. Tahapan dilanjutkan dengan melakukan validasi sebanyak 5 kali dengan menggunakan cross validation dengan perintah pada baris ke 16. Proses diakhiri dengan menyimpan model seperti dilakukan dengan perintah baris ke 20 dan 21.

5.3 Tahap Pengujian

5.3.1 Akuisisi Data

Data untuk tahap pengujian diambil dari rekaman video CCTV channel 4 di lantai 4 gedung S2/S3 FMIPA UGM. Video yang digunakan sebagai data pengujian adalah data video dari tanggal 26 November 2019 sampai dengan tanggal 3 Desember 2019.

Proses akuisisi data dilakukan dengan pengambilan video dari folder dataset. Implementasi akuisisi data dilakukan dengan menjalankan potongan kode berikut :

```
1. cap = cv2.VideoCapture('CCTV1.avi')
2. while(True):
3.     a = 0
4.     ret, frame = cap.read()
```

Gambar 5.8 Potongan kode akuisisi data video

5.3.2 Preprocessing

Tahap preprocessing dilakukan dengan mengubah frame video dari yang semula berupa citra berwarna menjadi citra grayscale. Proses grayscale dengan menggunakan library opencv. Grayscale pada library opencv menggunakan standard BT601 metode luminance. Eksekusi tahap preprocessing dilakukan dengan menjalankan potongan kode seperti pada gambar 5.5.

5.3.3 Segmentasi

Tahap segmentasi bertujuan untuk memisahkan antara foreground dengan background. Background pada video CCTV berupa lorong, bangku, kusen dan

objek lain selain objek manusia. Penerapan tahap segmentasi dengan menggunakan metode Mixture of Gaussian (MOG). Penerapan segmentasi dengan metode MOG menggunakan kelas MOG yang merupakan bagian dari library cv2. Hasil dari penerapan MOG adalah citra dengan background berwarna gelap dan foreground berwarna terang. Potongan kode untuk menerapkan tahap segmentasi dengan metode MOG seperti pada gambar 5.9.

```
1. fgbg = cv2.bgsegm.createBackgroundSubtractorMOG()  
2. fgmask = fgbg.apply(imag)
```

Gambar 5.9 Potongan kode tahap segmentasi


Gambar 5.9 baris pertama adalah perintah untuk memanggil kelas MOG yang merupakan bagian dari library cv2. Perintah baris ke-2 adalah perintah untuk menjalankan metode MOG pada frame video. Hasil fgmask adalah citra dengan warna gelap untuk background dan warna terang untuk foreground.



Gambar 5.10 Citra frame video dan hasil segmentasi menggunakan metode MOG

5.3.4 Region of Interest (ROI)

Region of interest adalah area pada citra yang dipilih untuk diproses pada tahap selanjutnya. Pada penelitian ini, area yang dipilih adalah area sepanjang 8 meter dari depan pintu kelas 421 sampai dengan area didepan pintu 420. Area yang menjadi region of interest digambarkan seperti pada gambar 5.11.



Gambar 5.11 Area didalam trapesium dipilih sebagai ROI

Gambar 5.12 merupakan potongan kode untuk implementasi ROI. Perintah pada baris pertama dan baris kedua adalah perintah untuk membaca setiap frame pada video. Perintah baris ketiga dan keempat adalah perintah untuk melakukan *masking frame* video dengan warna putih. Baris kelima adalah penentuan titik-titik yang menjadi sudut dari area yang dipilih sebagai ROI. Pada penelitian ini, area yang dipilih berbentuk trapesium dengan titik-titik sudut trapesium yaitu titik 1 pada koordinat (850, 250), titik kedua pada koordinat (1050, 250), titik ketiga pada koordinat (1200, 1000) dan titik keempat pada koordinat (650, 1000). Baris keenam dan ketujuh adalah perintah untuk menutup area diluar trapesium yang dipilih dengan warna putih. Area diluar trapesium tertutup dengan *masking* warna putih karena menggunakan perintah `bitwise_or`. Apabila ROI yang diinginkan adalah area diluar trapesium dengan area didalam trapesium ditutup dengan warna hitam, maka perintah yang digunakan adalah `bitwise_and`. Hasil dari implementasi tahap ROI ditunjukkan pada gambar 5.13. Gambar 5.13 sebelah kiri adalah frame asli dari video sebelum diolah. Gambar 5.13 sebelah kanan adalah frame dari video setelah penerapan metode ROI.

```

1. while(True):
2.     ret, frame = cap.read()
3.     mask = np.zeros(shape=frame.shape, dtype="uint8")
4.     mask.fill(255)

```

```

5. ROIpoint = np.array([[850, 250), (1050, 250), (1200, 1000), (650,
1000)]], dtype=np.int32)
6. cv2.fillPoly(mask, ROIpoint, 0)
7. imag = cv2.bitwise_or(frame, mask)

```

Gambar 5.12 Potongan kode tahap ROI



Gambar 5.13 Hasil implementasi metode ROI

5.3.5 Ekstraksi Fitur

Tahap ekstraksi fitur adalah tahapan untuk menemukan koordinat keypoint dan menghitung descriptor dari masing-masing keypoint tersebut. Koordinat keypoint dicari dari citra hasil segmentasi. Hasil koordinat keypoint digunakan untuk menghitung descriptor dari masing-masing keypoint. Perhitungan descriptor dengan menggunakan citra grayscale sebelum dilakukan segmentasi. Koordinat keypoint dan descriptor dari masing-masing keypoint merupakan fitur dari frame video yang berhasil diekstrak.

```

1. orb = cv2.ORB_create(nfeatures=7000, nlevels=10, patchSize=20, edgeThreshold=5)
2. while(True):
3.     ret, frame = cap.read()
4.     mask = np.zeros(shape=frame.shape, dtype="uint8")
5.     mask.fill(255)
6.     ROIpoint = np.array([[850, 250), (1050, 250), (1200, 1000), (650,
1000)]], dtype=np.int32)
7.     cv2.fillPoly(mask, ROIpoint, 0)
8.     imag = cv2.bitwise_or(frame, mask)
9.     fgmask = fgbg.apply(imag)
10.    kps = orb.detect(fgmask, None)
11.    kps, descs = orb.compute(frame, kps)
12.    img7 = cv2.drawKeypoints(frame, kps, None)

```

Gambar 5.14 Potongan kode implementasi ekstraksi fitur

Proses ekstraksi fitur diawali dengan memanggil kelas orb dengan perintah pada baris pertama. Baris kedua dan baris ketiga adalah perintah untuk membaca frame

dari video. Baris keempat sampai dengan baris kedelapan adalah implementasi ROI. Baris kesembilan adalah implementasi dari *background subtraction*. Baris kesepuluh adalah perintah untuk melakukan deteksi *keypoint* dari citra hasil *background subtraction*. Hasil *keypoint* tersebut digunakan untuk menghitung nilai deskriptor dari masing-masing *keypoint* seperti pada perintah baris kesebelas. Perhitungan deskriptor menggunakan *frame* dari video. Perintah baris kesebelas adalah perintah untuk menampilkan posisi *keypoint* kedalam *img7*.

5.3.6 Clustering

Tahap clustering digunakan untuk mengelompokkan *keypoint* ke dalam klaster. Pengelompokan *keypoint* dilakukan berdasarkan lokasi *keypoint* tersebut. Setiap klaster yang terbentuk merupakan kandidat objek. Deskriptor dari setiap *keypoint* dalam klaster diklasifikasikan dengan model SVM yang telah dilatih sebelumnya untuk mengetahui klaster tersebut merupakan objek manusia atau objek bukan manusia. Berikut adalah potongan kode implementasi tahap clustering.

```
1. x = np.array([kps[0].pt])
2. y = np.array([descs[0]])
3.
4. for i in range(len(kps)):
5.     x = np.append(x, [kps[i].pt], axis=0)
6.     y = np.append(y, [descs[i]], axis=0)
7. x = x[1:len(x)]
8. bandwidth = estimate_bandwidth(x, quantile=0.2)
9.
10. ms = MeanShift(bandwidth=bandwidth, bin_seeding=True, cluster_all=True
    )
11. ms.fit(x)
12. labels = ms.labels_
13. cluster_centers = ms.cluster_centers_
14.
15. labels_unique = np.unique(labels)
16. n_clusters_ = len(labels_unique)
```

Gambar 5.15 Potongan kode tahap clustering

Implementasi tahap clustering ditunjukkan gambar 5.15. Tahap clustering diawali dengan menyimpan nilai *keypoint* kedalam variabel *x* dan nilai deskriptor kedalam variabel *y* seperti pada perintah baris pertama sampai dengan perintah baris keenam. Perintah baris kedelapan adalah perintah untuk memberikan estimasi *bandwidth* untuk clustering menggunakan *Meanshift*. *Bandwidth* berpengaruh pada

ukuran dari kluster yang terbentuk. Semakin besar nilai quantile, maka nilai bandwidth semakin besar sehingga ukuran kluster semakin besar. Pada penelitian ini, klustering digunakan untuk pengelompokan keypoint berdasarkan koordinat keypoint. Implementasi klustering keypoint berdasarkan lokasi keypoint dijalankan dengan perintah baris kesebelas. Perintah baris kedobelabel digunakan untuk menyimpan label dari kluster kedalam variabel labels. Perintah baris ketigabelabel digunakan untuk menyimpan posisi pusat kluster kedalam variabel cluster_centers.

5.3.7 Klasifikasi

Tahap klasifikasi menggunakan metode SVM. Input dari tahap klasifikasi adalah model yang sudah dibentuk dan descriptor dari setiap keypoint dari semua cluster pada frame pada video. Output dari tahap klasifikasi adalah kelas dari masing-masing kluster. Apabila kluster diklasifikasikan sebagai manusia, maka tambahkan 1 pada variabel a. Penambahan nilai a dengan menjalankan perintah baris ke-5. Nilai akhir a pada setiap looping menunjukkan jumlah manusia yang terdeteksi pada masing-masing frame dari video. Nilai a ditampilkan pada layar dan dikembalikan ke nilai 0 setiap berganti frame berikutnya. Perintah pada baris ke-7 digunakan untuk menampilkan nilai a pada setiap frame video. Perintah baris-1 digunakan untuk inisiasi awal nilai a dan untuk mereset nilai a kembali ke 0 pada saat berganti frame berikutnya. Berikut adalah potongan kode tahap klasifikasi.

```
1. a = 0
2. y_pred = clf.predict(t)
3. for k in range(n_clusters_):
4.     if y_pred[k] == 'p' :
5.         a += 1
6.         img5 = cv2.rectangle(img5, (jmin, miny), (jmax, imax), (0, 0,
7. 255), 2)
7. cv2.putText(img5, str(a), (10, 50), font, 1, (255, 0, 0), 3)
```


Gambar 5.16 Potongan kode tahap klasifikasi

BAB VI

HASIL DAN PEMBAHASAN

6.1 Hasil Pra-pemrosesan Data

Video hasil rekaman CCTV channel 4 gedung S2/S3 yang telah didapatkan diekstrak menjadi frame-frame video. Salah satu contoh hasil ekstraksi frame video ditunjukkan pada gambar 6.1



Gambar 6.1 Contoh hasil ekstraksi frame video

Hasil ekstraksi video adalah berupa frame dari video. Frame dari video tersebut kemudian diubah menjadi citra grayscale. Hasil dari citra grayscale seperti ditampilkan pada gambar 6.2



Gambar 6.2 Hasil konversi citra berwarna menjadi citra grayscale

6.2 Hasil Pelatihan Video Latih

Tahap pelatihan dilakukan untuk membentuk model SVM yang dapat membedakan objek manusia dengan objek non manusia. Data citra yang digunakan sebagai data latih adalah data citra hasil cropping dari frame video latih. Hasil dari proses cropping adalah 1869 citra. Citra hasil cropping tersebut kemudian dipisahkan antara citra yang terdapat objek manusia dan citra tanpa objek manusia. Hasil pemisahan adalah 842 citra tanpa objek manusia dan 1027 citra dengan objek manusia. Kemudian dilakukan pelatihan dengan metode SVM untuk mendapatkan model pengklasifikasi citra objek manusia dan citra tanpa objek manusia. Hasil Validasi dari model yang terbentuk dengan menggunakan 5 fold Cross Validation mendapatkan nilai rata-rata 0.74.

6.3 Hasil Pengujian Klustering

Keypoint yang dihasilkan pada tahap ekstraksi fitur, dikelompokkan berdasarkan koordinatnya dengan menggunakan metode klustering MeanShift. Klustering dilakukan untuk mengelompokkan keypoint ke dalam kluster. Masing-masing kluster diuji dengan menggunakan model SVM yang telah dibentuk pada tahap pelatihan untuk menentukan kluster sebagai objek manusia atau sebagai objek

non manusia. Parameter yang berpengaruh pada tahap klustering adalah bandwidth. Bandwidth ditentukan dengan melakukan estimasi bandwidth. Estimasi bandwidth dilakukan dengan menentukan nilai dari parameter quantile. Penentuan parameter quantile menggunakan metode *background subtraction* MOG, dengan banyak fitur ORB sebanyak 7000. Berikut adalah pengaruh dari penerapan metode *background subtraction* terhadap performa sistem perhitungan orang:

Tabel 6.1 Pengaruh parameter quantile terhadap nilai f-measure.

Metode	Quantile	Presisi	Recall	F measure
MOG	q = 0,18	0,506	0,521	0,514
	q = 0,22	0,541	0,520	0,530
	q = 0,26	0, 616	0, 511	0, 559

Tabel menunjukkan bahwa menggunakan nilai parameter quantile 0,26 menghasilkan nilai f yang tertinggi yaitu 0,536. Nilai quantile mempengaruhi nilai estimate bandwidth yang merupakan ukuran area atau daerah (window) pencarian. Penambahan nilai quantile mempengaruhi ukuran bonding box yang terbentuk. Semakin besar nilai quantile, semakin besar bonding box yang terbentuk. Pada percobaan, nilai f measure semakin membaik dengan penambahan nilai quantile. Hal ini disebabkan karena dengan bonding box yang semakin besar, maka kemungkinan objek manusia terdeteksi sebagai lebih dari 1 objek manusia semakin kecil sehingga mengurangi nilai false positif. Penurunan nilai false positif terlihat dari nilai Presisi yang semakin meningkat seiring bertambahnya nilai quantile.

6.4 Hasil Segmentasi

Tahap berikutnya adalah *background subtraction*. Tahap preprocessing menghasilkan citra grayscale sebagai outputnya. Citra grayscale tersebut diolah dengan metode segmentasi untuk memisahkan antara obyek/*foreground* dengan *background*. Beberapa metode dapat digunakan untuk implementasi *background subtraction*. Pada penelitian ini, percobaan dilakukan dengan membandingkan metode MOG dan KNN untuk melakukan *background subtraction* terhadap citra

grayscale hasil *preprocessing*. Hasil dari implementasi kedua metode tersebut ditampilkan pada gambar



Gambar 6.3 Hasil *background subtraction* metode MOG dan KNN

Dari gambar hasil implementasi, metode KNN menghasilkan banyak *noise* tetapi bentuk dari objek lebih utuh. Metode MOG menghasilkan *noise* lebih sedikit tetapi bentuk dari objek tidak utuh. Berikut adalah pengaruh dari penerapan metode background subtraction terhadap performa sistem perhitungan orang.

Tabel 6.2 Perbandingan performa metode background subtraction

Metode	Quantile	Presisi	Recall	F measure
MOG	q = 0,26	0,616	0,511	0,559
KNN	q = 0,26	0,422	0,412	0,417

Tabel 6.2 menunjukkan bahwa nilai f tertinggi didapatkan pada saat menggunakan metode MOG. Hal ini disebabkan karena noise yang banyak terdapat pada metode KNN. *Noise* menyebabkan proses klastering menjadi semakin sulit mendapatkan objek yang tepat. Pada metode MOG, noise yang terjadi tidak banyak sehingga *keypoint* terkumpul pada objek. *Keypoint* terkumpul pada objek memudahkan proses klastering. Klastering yang baik menghasilkan deteksi manusia yang lebih baik.

6.5 Hasil Region of Interest

Tahapan berikutnya yaitu *Region of Interest* (ROI). *Region of Interest* diterapkan agar titik-titik *keypoint* terpusat pada area yang diamati. Pada penelitian ini, area yang diamati adalah area lorong didepan pintu kelas 421, sampai dengan area didepan pintu kelas 420. Area yang dipilih berbentuk trapesium dengan titik-titik sudut trapesium yaitu titik 1 pada koordinat (850, 250), titik kedua pada koordinat (1050, 250), titik ketiga pada koordinat (1200, 1000) dan titik keempat pada koordinat (650, 1000). Area tersebut dipilih karena Obejk yang diamati adalah manusia yang berjalan di sepanjang lorong tersebut. Hasil implementasi ROI ditunjukkan pada gambar 6.4



Gambar 6.4 Hasil implementasi *Region of Interest*

6.6 Pengujian Jumlah fitur ORB


Hasil dari ekstraksi fitur adalah *keypoint* dan *descriptor*. *Keypoint* dikelompokkan kedalam klaster sebagai kandidat objek. *Deskriptor* dari *keypoint-keypoint* tersebut digunakan untuk menentukan sebuah objek sebagai objek manusia atau objek bukan manusia. Banyaknya *keypoint* yang dideteksi berpengaruh terhadap komposisi klaster yang terbentuk. Komposisi *keypoint* dalam klaster mempengaruhi hasil deteksi orang. Pengujian ini dilakukan dengan

memasukkan banyak fitur pada algoritma ORB dengan variasi 3000, 5000 dan 7000. *Background subtraction* yang digunakan adalah metode MOG. Nilai *quantile* untuk klastering Mean-Shift adalah 0,26 dengan menggunakan ROI sebagai area deteksi *keypoint*.

Tabel 6.3 Perbandingan performa ekstraksi fitur ORB dengan variasi banyak fitur.

Banyak Fitur	Presisi	Recall	F measure
3000	0,544	0,527	0,535
5000	0,544	0,527	0,535
7000	0,616	0,511	0,559

Tabel 6.3 menunjukkan bahwa nilai f-measure terbaik adalah 0,559 dengan banyak fitur 7000 sedangkan banyak fitur 3000 dan 5000 memiliki performa yang sama. Banyak fitur 7000 memiliki performa terbaik karena nilai presisinya lebih baik dari banyak fitur 3000 maupun 5000. Gambar 6.5 menunjukkan bahwa pada banyak fitur 3000, klaster yang memuat pintu dan tempat sampah terdeteksi sebagai objek manusia. Pada banyak fitur 5000 memasukkan klaster yang memuat pintu, kaki dan bayangan sebagai objek manusia. Hasil yang baik didapatkan pada banyak fitur 7000. Terdapat lebih banyak fitur pada area pintu dan area tempat sampah sehingga klaster tersebut tidak dideteksi sebagai objek manusia.



Gambar 6.5 Perbandingan banyak fitur 3000, 5000 dan 7000 pada frame ke-879

6.7 Pengujian Ketertutupan Objek / Oklusi

Pengujian ini dilakukan dengan mengambil frame dari video pada saat objek manusia tertutup sebagian oleh objek lainnya. Pengujian dilakukan dengan menggunakan metode *background subtraction Mixture of Gaussian*, banyak fitur 7000 fitur dengan variasi nilai *quantile*. Pengujian objek tertutup sebagian untuk nilai *quantile* 0.18 menghasilkan nilai *f-measure* 0.582. Nilai *quantile* 0.22 mendapatkan nilai *f-measure* 0.483 dan Nilai *quantile* 0.26 menghasilkan nilai *f-measure* 0.444. Nilai *f-measure* menurun dengan bertambahnya nilai *quantile*. Hal ini disebabkan karena pada gambar yang bermuatan objek manusia yang tertutup sebagian, posisi *keypoint* objek manusia berdekatan dengan posisi *keypoint* objek yang menutupinya. Nilai *quantile* yang lebih besar menyebabkan *bonding box* lebih besar sehingga *keypoint-keypoint* yang berdekatan dikelompokkan kedalam 1 kluster yang sama. Nilai *quantile* yang lebih kecil menyebabkan *bonding box* lebih kecil sehingga *keypoint-keypoint* yang berdekatan dikelompokkan kedalam kluster yang berbeda. Untuk posisi objek yang tertutup sebagian diperlukan *bonding box* yang lebih kecil agar dapat memisahkan *keypoint-keypoint* dari objek yang berdekatan kedalam kluster yang berbeda sehingga dapat diidentifikasi sebagai 2 objek yang berbeda. *Bonding box* yang lebih besar menyebabkan 2 objek yang memiliki *keypoint* yang berdekatan dikelompokkan kedalam kluster yang sama sehingga dideteksi sebagai 1 objek. Beberapa objek yang berdekatan yang di deteksi sebagai 1 objek meningkatkan nilai *false negative* sehingga menurunkan nilai *recall* sehingga nilai *f-measure* juga menurun. Hal ini menjelaskan mengapa nilai *quantile* yang 0.18 memiliki performa yang lebih baik daripada nilai *quantile* 0.26. Nilai *quantile* yang lebih kecil dapat memisahkan objek yang berhimpit dengan lebih baik daripada nilai *quantile* yang besar tetapi jika objek aktual tidak tertutup sebagian, objek tersebut dapat dideteksi sebagai lebih dari 1 objek. Dari pengamatan objek manusia tertutup sebagian, Sistem dapat melakukan deteksi manusia. Deteksi manusia dapat dilakukan tetapi hasil deteksi masih belum konsisten. Penggunaan metode tracking dapat memperbaiki kelemahan sistem perhitungan orang. Gambar 6.6 menunjukkan bahwa sistem berhasil mendeteksi orang yang tertutup sebagian tetapi tidak konsisten. Terlihat bahwa pada gambar

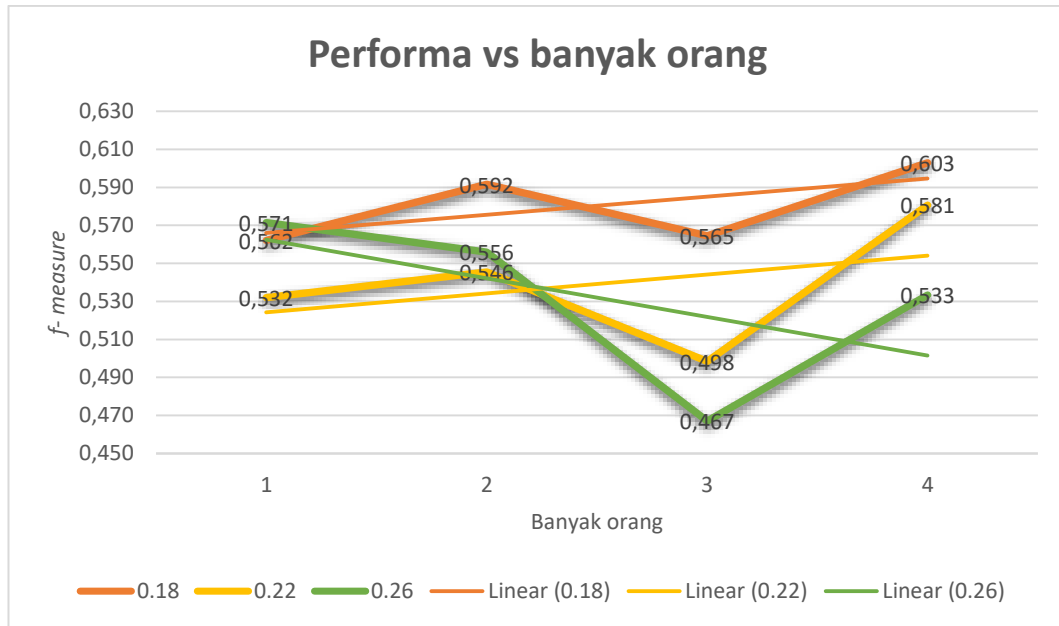
6.6a, sistem berhasil mendeteksi dengan baik, tetapi pada frame berikutnya terdapat kesalahan deteksi seperti ditunjukkan gambar 6.6b. Hasil deteksi lebih baik apabila hasil pada gambar 6.6a kemudian dilakukan tracking terhadap objek yang telah terdeteksi.



Gambar 6.6 Hasil pengujian frame oklusi

6.8 Pengujian Banyak Orang

Pengujian banyak orang dilakukan dengan memilah *frame-frame* video berdasarkan aktual banyak orang. Pengujian menggunakan metode *background subtraction Mixture of Gaussian*, banyak fitur ORB 7000 fitur dan nilai *quantile* dilakukan variasi. Hasil dari pengujian banyak orang ditunjukkan pada gambar 6.7



Gambar 6.7 Grafik performa terhadap banyaknya orang dalam *frame* video

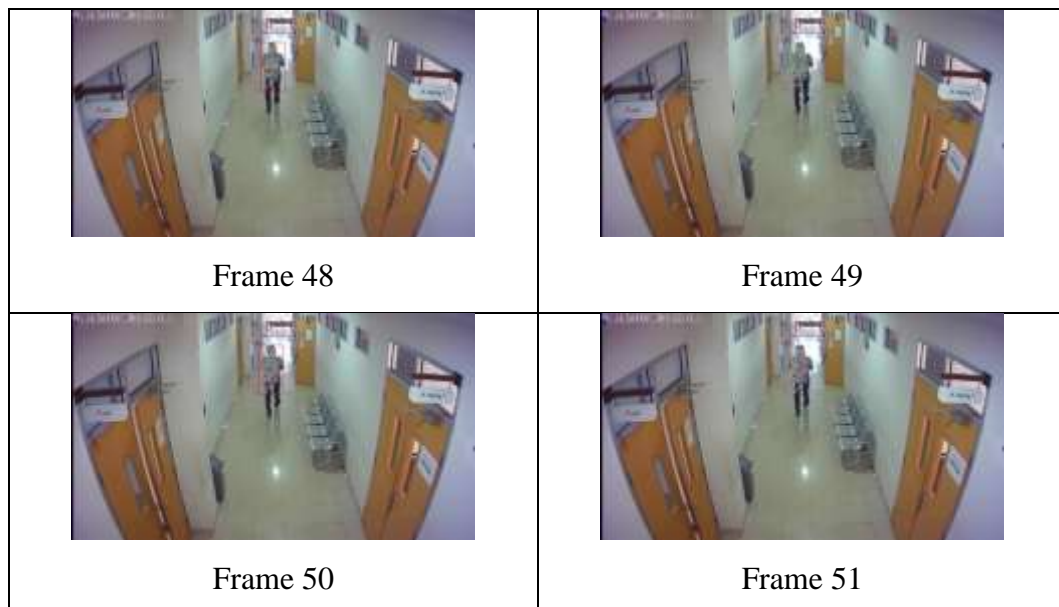
Pada gambar 6.7, untuk banyak orang dalam *frame* video sebanyak 1 orang, nilai f terbaik adalah untuk nilai *quantile* 0,26 dengan nilai f sebesar 0,571. Penambahan nilai *quantile* mempengaruhi ukuran *bonding box* yang terbentuk. Semakin besar nilai *quantile*, semakin besar *bonding box* yang terbentuk. Untuk banyak orang 1, *bonding box* yang besar mengurangi kemungkinan kesalahan 1 orang terdeteksi beberapa kali. Hal ini mengurangi nilai *false positive* sehingga meningkatkan nilai presisi dan nilai f . *Trend* performa untuk nilai *quantile* 0,26 menurun dengan bertambahnya banyak orang dalam *frame*. Hal ini disebabkan karena *bonding box* yang besar menyebabkan beberapa orang dideteksi sebagai 1 orang. Hal ini meningkatkan nilai *false negative* sehingga mengurangi nilai *recall* dan nilai f . Untuk nilai *quantile* 0,22 dan 0,26 menghasilkan *trend* performa yang membaik seiring bertambahnya banyak orang pada *frame*. Hal ini dikarenakan nilai *quantile* yang lebih kecil menghasilkan area pencarian yang lebih kecil. Untuk 1 orang dalam *frame*, hal ini menyebabkan kemungkinan 1 orang terdeteksi beberapa kali. Tetapi untuk banyak orang yang lebih banyak, area pencarian yang kecil mengurangi kesalahan beberapa orang terdeteksi sebagai 1 orang.

6.9 Analisa dan Pembahasan

Pada pengujian yang telah dilakukan, metode ORB telah digunakan untuk mengembangkan sistem perhitungan orang. Sistem mampu mendeteksi orang yang berjalan mendekati kamera atau wajah menghadap kamera maupun orang yang berjalan menjauhi kamera atau wajah membelakangi kamera. Deteksi mampu dilakukan pada area ROI yaitu berjarak 1 meter sampai dengan 11 meter dari kamera. Sistem mampu mendeteksi beberapa orang yang berjalan bersamaan. Hasil terbaik yang dicapai oleh sistem adalah nilai f sebesar 0,559 dengan menggunakan metode background subtraction MOG, nilai quantile 0,26 dan banyak fitur ORB 7000. Hasil ini diperoleh dengan berberapa kendala sebagai berikut :

1. Deteksi tidak konsisten

Gambar 6.8 menunjukkan bahwa pada *frame* yang berurutan, objek manusia tidak selalu terdeteksi. Hal ini disebabkan karena komposisi *keypoint* yang terdeteksi pada *frame* satu dengan *frame* yang lain tidak selalu sama sehingga hasil klustering mungkin mengalami perbedaan antar *frame*. Hasil kluster yang berbeda memungkinkan objek manusia dideteksi sebagai objek non manusia. Salah satu cara mengatasi permasalahan kestabilan deteksi adalah dengan menerapkan metode tracking.



Gambar 6.8 Deteksi orang tidak stabil

2. Bayangan terdeteksi sebagai objek manusia

Gambar 6.8 menunjukkan salah satu kelemahan dari sistem perhitungan orang yaitu bayangan terdeteksi sebagai objek manusia. Bayangan yang terdeteksi sebagai objek manusia menyebabkan bertambahnya nilai *false positive* sehingga menurunkan nilai presisi. Penerapan algoritme *shadow removal* dapat mengatasi kesalahan ini.



Gambar 6.9 Bayangan terdeteksi sebagai orang.

3. Klustering keypoint

Permasalahan pengelompokan keypoint kedalam kluster menjadi trade-off pada penelitian. Pengaturan luas area *bonding box* dapat diatur dengan melakukan pengaturan nilai quantile pada tahap klustering. Quantile yang kecil menyebabkan area bonding box yang kecil. Hal ini dapat menyebabkan kesalahan deteksi seperti ditunjukkan gambar 6.9. Tetapi apabila quantile diperbesar, maka bonding box juga menjadi lebih besar. Hal ini rentan dengan kesalahan deteksi 2 objek manusia dideteksi sebagai 1 objek manusia.



Gambar 6.10 Satu orang dihitung sebagai 4 orang.

BAB VII

KESIMPULAN DAN SARAN

7.1 KESIMPULAN

Dari Penelitian yang telah dilakukan diperoleh kesimpulan sebagai berikut:

1. Algoritma ORB menghasilkan nilai f -measure sebesar 0,559 dengan metode MOG sebagai metode background subtraction, metode mean-shift dengan nilai $quantile$ 0,26 sebagai metode klustering dan banyaknya fitur ORB 7000.
2. Metode yang diusulkan dapat mendeteksi objek tertutup dan menghasilkan nilai f -measure terbaik sebesar 0,582 dengan metode MOG sebagai metode background subtraction, metode Mean-Shift dengan nilai $quantile$ 0,18 sebagai metode klustering dan banyaknya fitur ORB 7000.
3. Nilai $quantile$ yang lebih kecil dapat memisahkan objek yang berhimpit dengan lebih baik daripada nilai $quantile$ yang besar tetapi Nilai $quantile$ yang kecil menyebabkan 1 objek yang tidak berhimpit, dideteksi sebagai lebih dari 1 objek.

7.2 SARAN

Penelitian ini masih ada beberapa kekurangan yang masih dapat diperbaiki oleh peneliti selanjutnya. Beberapa saran untuk penelitian selanjutnya adalah :

1. Penambahan metode tracking agar deteksi objek lebih konsisten.
2. Bayangan yang terdeteksi sebagai objek manusia dapat menurunkan performa dari sistem, untuk itu diperlukan penerapan metode *shadow removal*.
3. Penggunaan metode klustering Mean Shift menyebabkan trade-off pada saat penentuan nilai $quantile$ yang juga menyebabkan permasalahan deteksi orang sebagai lebih dari 1 orang. Penggunaan metode klustering yang lain untuk mengatasi permasalahan 1 objek manusia terdeteksi sebagai beberapa objek manusia.

DAFTAR PUSTAKA

- Azad, P., Asfour, T. dan Dillmann, R., 2009, Combining Harris interest points and the SIFT descriptor for fast scale-invariant object recognition, *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, [Online], Oktober 2009 IEEE, St. Louis, MO., hlm. 4275–4280, tersedia di DOI:10.1109/IROS.2009.5354611, diakses 30 Juli 2019.
- Calonder, M., Lepetit, V., Strecha, C. dan Fua, P., 2010, *BRIEF Binary Robust Independent Elementary Featur*, 1–14,
- Comaniciu, D. dan Meer, P., 2002, Mean shift: a robust approach toward feature space analysis, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, [Online] 24 (5), 603–619, tersedia di DOI:10.1109/34.1000236.
- Dal Pozzolo, A., Boracchi, G., Caelen, O., Alippi, C. dan Bontempi, G., 2018, Credit card fraud detection: a realistic modeling and a novel learning strategy, *IEEE transactions on neural networks and learning systems*, 29 (8), 3784–3797,
- Deisman, W., 2003, *CCTV: Literature Review and Bibliography*, 38, tersedia di <http://dsp-psd.pwgsc.gc.ca/Collection/JS62-108-2003E.pdf>
- Filonenko, A., Hernandez, D.C., Shahbaz, A., dan Kang-Hyun Jo, 2016, Unified smoke and flame detection for intelligent surveillance system, *2016 IEEE 25th International Symposium on Industrial Electronics (ISIE)*, [Online], Juni 2016 IEEE, Santa Clara, CA, USA., hlm. 953–957, tersedia di DOI:10.1109/ISIE.2016.7745019, diakses 30 Juli 2019.
- Gonzalez, R.C., Eddins, S.L. dan Woods, R.E., 2004, *Digital image publishing using MATLAB*, Prentice Hall.
- Hanzi Wang dan Suter, D., 2005, A Re-evaluation of Mixture-of-Gaussian Background Modeling, *Proceedings. (ICASSP '05). IEEE International Conference on Acoustics, Speech, and Signal Processing, 2005.*, [Online], 2005 IEEE, Philadelphia, Pennsylvania, USA., hlm. 1017–1020, tersedia di DOI:10.1109/ICASSP.2005.1415580, diakses 20 Juli 2021.
- Karami, E., Prasad, S. dan Shehata, M., t.t., *Image Matching Using SIFT, SURF, BRIEF and ORB: Performance Comparison for Distorted Images*, 5,
- Li, J. dan Zhang, Y., 2013, Learning SURF Cascade for Fast and Accurate Object Detection, *2013 IEEE Conference on Computer Vision and Pattern Recognition*, [Online], Juni 2013 IEEE, Portland, OR, USA., hlm. 3468–3475, tersedia di DOI:10.1109/CVPR.2013.445, diakses 30 Juli 2019.
- Nugroho, A.S., Witarto, A.B. dan Handoko, D., 2003, Support vector machine, *Proceeding Indones. Sci. Meeting Cent. Japan*,
- Rao, T. dan Ikenaga, T., 2017, Quadrant segmentation and ring-like searching based FPGA implementation of ORB matching system for Full-HD video, *2017 Fifteenth IAPR International Conference on Machine Vision Applications (MVA)*, [Online], Mei 2017 hlm. 89–92, tersedia di DOI:10.23919/MVA.2017.7986797.

- Rosin, P.L., 1999, Measuring Corner Properties, *Computer Vision and Image Understanding*, [Online] 73 (2), 291–307, tersedia di DOI:10.1006/cviu.1998.0719.
- Rosten, E. dan Drummond, T., 2006, Machine learning for high-speed corner detection, *In European Conference on Computer Vision*, 2006 hlm. 430–443,
- Rublee, E., Rabaud, V., Konolige, K. dan Bradski, G., 2011, ORB: An efficient alternative to SIFT or SURF, *2011 International Conference on Computer Vision*, [Online], November 2011 IEEE, Barcelona, Spain., hlm. 2564–2571, tersedia di DOI:10.1109/ICCV.2011.6126544, diakses 30 Juli 2019.
- Sembiring, K., 2007, Support Vector Machine, *Training*, 1–28,
- Stauffer, C. dan Grimson, W.E.L., 1999, Adaptive background mixture models for real-time tracking, *cvpr*, 1999 IEEE., hlm. 2246,
- Sudha, D. dan Priyadarshini, J., 2015, Reducing Semantic Gap in Video Retrieval with Fusion: A Survey, *Procedia Computer Science*, [Online] 50496–502, tersedia di DOI:10.1016/j.procs.2015.04.020.
- Tekalp, A.M., 1995, *Digital Video Processing*, 2 edisi, Prentice Hall PTR, New Jersey.
- Wahyono, Filonenko, A. dan Jo, K.-H., 2016, Unattended Object Identification for Intelligent Surveillance Systems Using Sequence of Dual Background Difference, *IEEE Transactions on Industrial Informatics*, [Online] 12 (6), 2247–2255, tersedia di DOI:10.1109/TII.2016.2605582.
- Wahyuni, E.S., Alinra, R.R. dan Setiawan, H., 2017, People counting for indoor monitoring, *2017 International Conference on Computing, Engineering, and Design (ICCED)*, [Online], November 2017 IEEE, Kuala Lumpur., hlm. 1–5, tersedia di DOI:10.1109/CED.2017.8308112, diakses 30 Juli 2019.
- Xie, S., Zhang, W., Ying, W. dan Zakim, K., 2013, Fast detecting moving objects in moving background using ORB feature matching, *2013 Fourth International Conference on Intelligent Control and Information Processing (ICICIP)*, [Online], Juni 2013 IEEE, Beijing, China., hlm. 304–309, tersedia di DOI:10.1109/ICICIP.2013.6568087, diakses 30 Juli 2019.
- Zeng, C. dan Ma, H., 2010, Robust Head-Shoulder Detection by PCA-Based Multilevel HOG-LBP Detector for People Counting, *2010 20th International Conference on Pattern Recognition*, [Online], Agustus 2010 IEEE, Istanbul, Turkey., hlm. 2069–2072, tersedia di DOI:10.1109/ICPR.2010.509, diakses 30 Juli 2019.
- Zhang, F., Yang, L. dan Zhang, G., 2012, Adaptive fast Gaussian background subtraction algorithm, *Proceedings of 2012 2nd International Conference on Computer Science and Network Technology*, [Online], Desember 2012 IEEE, Changchun, China., hlm. 766–771, tersedia di DOI:10.1109/ICCSNT.2012.6526045, diakses 20 Juli 2021.