

## **Analisis Metode Kalman Filter, Particle Filter dan Correlation Filter Untuk Pelacakan Objek**

**Ridho Sholehurrohman<sup>1\*</sup>, Mochammad Reza Habibi<sup>2</sup>, Igit Sabda Ilman<sup>3</sup>,  
Rahman Taufiq<sup>4</sup>, Muhaqiqin<sup>5</sup>**

<sup>1,3,4,5</sup>Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung  
Jl. Prof. Dr. Ir. Sumantri Brojonegoro No.1 Bandar Lampung, Lampung

<sup>2</sup>Jurusan Statistika Bisnis, Fakultas Vokasi, Institut Teknologi Sepuluh Nopember  
Kampus ITS Keputih, Sukolilo, Surabaya, 60111, Jawa Timur

\*email: [ridho.sholehurrohman@fmipa.unila.ac.id](mailto:ridho.sholehurrohman@fmipa.unila.ac.id)

(Naskah masuk: 7 April 2023; diterima untuk diterbitkan: 2 Agustus 2023)

**ABSTRAK** – Pelacakan objek merupakan hal yang menantang dalam computer vision. Pelacakan objek dibagi menjadi dua, yaitu bisa berupa satu objek atau beberapa objek, tergantung pada objek yang sedang diamati. Proses dalam pelacakan objek berupa satu objek adalah memperkirakan target pada urutan setelahnya berdasarkan informasi dari frame pertama yang diberikan. Dalam pelacakan objek berupa single object tracking, Ada lima langkah yang sering digunakan dalam metode diskriminatif, diantaranya model gerak, ekstraksi ciri, model observasi, pembaruan model dan metode integrasi. Meskipun berbagai algoritma dari pelacakan objek diusulkan, masih terdapat kegagalan dalam proses pelacakan objek yang disebabkan oleh oklusi, deformasi target yang non-rigid, dan faktor lainnya. Penelitian ini mengusulkan implementasi metode kalman filter, particle filter, dan correlation filter untuk pelacakan objek pada data video. Hasil implementasi ketiga metode tersebut dapat melacak objek pada data video lalu lintas dan video sirkuit naskar. Dalam kalkulasi tracking objek dan analisis metode, Kalman filter mendapatkan 96,89% dimana metode Kalman lebih baik dari segi akurasi dibandingkan dengan metode lainnya. Sedangkan dalam performansi rata-rata waktu komputasi, metode korelasi mendapatkan 26,69 FPS, dimana metode korelasi lebih unggul dibanding metode kompetitor lainnya.

**Kata Kunci** – Kalman Filter; Partikel Filter; Correlation Filter; Pelacakan Objek; Pelacakan Objek Dalam Video.

## **Analysis of Kalman Filter Method, Particle Filter Method and Correlation Filter Method for Object Tracking**

**ABSTRACT** – Object tracking is a challenging in computer vision. Object tracking is divided into two, which can be one object or several objects, depending on the object being observed. The process of tracking an object in the form of one object is to estimate the target in the next sequence based on information from the first frame given. In object tracking in the form of single object tracking, there are five steps that are often used in discriminatory methods, including motion models, feature extraction, observation models, model updates and integration methods. Although various algorithms of object tracking are proposed, there are still failures in the object tracking process caused by occlusion, non-rigid target deformation, and other factors. This study proposes the implementation of the Kalman filter, particle filter, and correlation filter methods for object tracking in video data. The results of the implementation of the three methods can track objects in traffic video data and the script circuit video. In object tracking calculations and method analysis, the Kalman filter gets 96.89% where the Kalman method is better in terms of accuracy compared to other methods. Meanwhile, in the average performance of computation time, the correlation method gets 26.69 FPS, where the correlation method is superior compared to other competitor methods.

**Keywords** – Kalman Filter; Particle Filter; Correlation Filter; Object Tracking; Object Tracking in Video.

## 1. PENDAHULUAN

Pelacakan objek merupakan hal yang menantang dalam *computer vision* [1], [2], [3]. Pelacakan objek dibagi menjadi dua, yaitu bisa berupa satu objek atau beberapa objek, tergantung pada objek yang sedang diamati [4]. Proses dalam pelacakan objek berupa satu objek adalah memperkirakan target pada urutan setelahnya berdasarkan informasi dari frame pertama yang diberikan [1], [5], [6].

Dalam pelacakan objek berupa satu objek (*single object tracking*), terdapat dua metode yaitu metode diskriminatif dan metode generative [1], [5], [6] [7]. Ada lima langkah yang sering digunakan dalam metode diskriminatif, diantaranya model gerak, ekstraksi ciri, model observasi, pembaruan model dan metode integrasi [7], [8]. Meskipun berbagai algoritma dari pelacakan objek diusulkan, masih terdapat permasalahan atau kegagalan dalam proses pelacakan objek yang disebabkan oleh oklusi, deformasi target yang non-rigid, dan banyak faktor lainnya [9].

Dalam Penelitian [3], metode kalman filter merupakan metode yang bagus dan diusulkan dalam pelacakan objek secara *real-time*. Selanjutnya dalam penelitian [10] telah dibahas bahwa implementasi metode kalman filter dan metode partikel filter pada bidang *Wireless Sensor Networks* (WSN), metode kalman filter lebih baik dalam mendeteksi lokasi objek terutama dalam kasus robot lokalisasi. Namun, dalam penelitian [5] metode korelasi filter dalam pelacakan objek merupakan algoritma yang komprehensif yang dapat melakukan pelacakan objek dengan baik.

Selain itu, Terdapat banyak sekali referensi terkait penanganan permasalahan atau kegagalan dalam pelacakan objek, diantaranya Kalman Filter, Particle Filter, dan *Correlation Filter* [1]-[18]. Pada paper ini akan diimplementasikan pelacakan objek pada video dengan metode tersebut. Selanjutnya hasil pelacakan tersebut akan dianalisis pemantauan gerak objek.

## 2. METODE DAN BAHAN

### Metode Kalman Filter

Kalman diambil dari nama author yaitu Rudolf Kalman. Kalman filter merupakan suatu filter sama dengan filter pada umumnya. Sebagai contoh, low-pass filter menerima sejumlah frekuensi dan menyaring low-frekuensi dengan meminimalisir high-frekuensi [3], [9], [10], [11].

Kalman filter sendiri menerima sejumlah informasi (dengan noise) dan menyaring informasi tersebut dengan meminimalisir noise [3], [10], [12]. Kalman filter didesain pada ruang linear sehingga Kalman filter juga dinamakan linear quadratic

estimation. Kalman filter didefinisikan oleh [3], [9], [10]:

$$\begin{aligned} \mathbf{x}_k &= \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{G}_{k-1} \mathbf{u}_{k-1} + \mathbf{w}_{k-1} \\ \mathbf{y}_k &= \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k \end{aligned} \quad (1)$$

dimana

- $x$  : vector state ( $n_x \times 1$ )
- $u$  : vector input ( $n_u \times 1$ )
- $y$  : vector output ( $n_y \times 1$ )
- $w$  : vector noise/proses ( $n_x \times 1$ )
- $v$  : vector noise/measure ( $n_y \times 1$ )
- $F$  : koefisien matriks state ( $n_x \times n_x$ )
- $G$  : koefisien matriks input ( $n_x \times n_u$ )
- $H$  : observasi matriks ( $n_y \times n_x$ )

Selain itu, juga terdapat  $P$ ,  $Q$ , dan  $R$  yang berturut-turut merupakan *error* kovarian matriks dari *state*, *proses*, dan *measure* [3], [10].

Kalman filter terdiri dari proses prediksi dan koreksi. Proses tersebut biasa dinamakan prediksi-koreksi. Kalman filter menggunakan informasi (*state*) yang diketahui untuk memprediksi satu langkah ke depan [3], [5], [10]. Sebagai contoh, jika diketahui posisi dan kecepatan suatu mobil sebelumnya, maka dapat diprediksi posisi mobil selanjutnya. Kemudian proses koreksi membandingkan pengukuran dari prediksi dengan nilai sebenarnya [3], [5], [10], [11].

Kalman filter merupakan algoritma rekursif. Kalman filter dimulai dengan mengasumsikan inisial *state*  $\hat{\mathbf{x}}_0$  dan inisial *state error* kovarian matriks  $P_0$  [3], [10], [11].

Proses Kalman filter dapat dibagi menjadi beberapa bagian sebagai berikut [3], [10], [11]:

- a. Mengasumsikan initial *state*  $\hat{\mathbf{x}}_0$  dan initial *state error* kovarian matriks  $P_0$ .
- b. Memprediksi vector *state* melalui:

$$\hat{\mathbf{x}}_{k|k-1} = \mathbf{F}_{k-1} \hat{\mathbf{x}}_{k-1} + \mathbf{G}_{k-1} \mathbf{u}_{k-1} \quad (2)$$

- c. Memprediksi *error* kovarian matriks melalui

$$\mathbf{P}_{k|k-1} = \mathbf{F}_{k-1} \mathbf{P}_{k-1} \mathbf{F}_{k-1}^T + \mathbf{Q}_{k-1} \quad (3)$$

- d. Setelah proses prediksi selesai, dihitung matriks Kalman gain melalui

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{H}^T (\mathbf{H}_k \mathbf{P}_{k|k-1} \mathbf{H}_k^T + \mathbf{R}_k)^{-1} \quad (4)$$

- e. *Update vector state* menggunakan Kalman gain melalui

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_{k|k-1} + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}_k \hat{\mathbf{x}}_{k|k-1}) \quad (5)$$

- f. *Update error* kovarian matriks menggunakan Kalman gain melalui

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_{k|k-1} \quad (6)$$

### Metode Particle Filter

Particle Filter merupakan metode *state space* untuk menerapkan filter Bayesian [10], [12], [13], [14], [15]. Gagasan utamanya adalah mendekati perkiraan distribusi probabilitas posterior oleh partikel. Setiap partikel mewakili satu keadaan hipotetis objek, dengan *sampling* diskrit yang sesuai dengan probabilitas (berat) [10], [12], [14]. Partikelnya biasanya dilakukan *resampling* untuk meringankan degenerasi partikel [10], [12], [13]. Efisiensi dan keakuratan filter partikel untuk pelacakan bergantung pada distribusi dan model observasi yang efektif untuk pembobotan partikel [10], [12], [13], [14], [15]. Berawal dari model Bayesian, distribusi posterior dari *state* dapat ditulis [10], [12], [13], [14]:

$$p\left(\frac{x_t}{y_t}\right) = \beta p\left(\frac{y_t}{x_t}\right) p\left(\frac{x_t}{\bar{y}_{t-1}}\right) \quad (7)$$

Dimana:

$\beta$  : faktor normalisasi

$x_t$  : sistem *state* pada waktu ke- $t$

$\bar{y}_t$  : informasi yang terkumpul hingga waktu ke- $t$

Terlihat Persamaan (6) sistem  $x_t$  bergantung pada kondisi  $\bar{y}_t$ . Particle Filter memberikan estimasi dari peluang posterior dari Persamaan (2) dalam 3 langkah, yaitu proses *sampling*, pembobotan dan *resampling*. Proses *sampling* terdiri dari mengambil sample (partikel) dari  $p(x_t/\bar{y}_{t-1})$  yang disebut sebagai distribusi prior. Setelah itu dilakukan proses pembobotan, dimana hasil dari partikel tersebut diberi bobot dengan *likelihood*  $p(y_t/x_t)$ . Setelah dilakukan pembobotan maka dilakukan *resampling* untuk menghindari degenerasi partikel yang tidak terpakai [10], [12], [13], [14].

Dari Bayesian tersebut didapatkan pengembangannya yang salah satunya disebut *Particle Filter*. Algoritma *Particle Filter* yang digunakan dalam makalah ini adalah *Adaptive Particle Filter*. *Adaptive Particle Filter* merupakan metode *Particle Filter* dengan menerapkan *adaptive motion model* untuk mendapatkan pendekatan distribusi yang lebih baik. Untuk lebih menyaring gangguan-gangguan yang ada, *motion continuity* dan kehalusan lintasan dikombinasikan dengan template korelasi dalam observasi *likelihood* [12], [13], [14].

Didefinisikan vektor keadaan objek sebagai  $X=(x,y)$  dengan  $(x,y)$  adalah pusat objek. Model ruang keadaan dari objek yang dilacak adalah [10], [13], [14]:

$$\begin{aligned} X_{t+1} &= f(X_t, \mu_t) \\ Z_t &= g(X_t, \xi_t) \end{aligned} \quad (8)$$

Dimana:

$X_t$  : representasi vektor keadaan objek

$X_t : \begin{bmatrix} x \\ y \end{bmatrix}$  dimana  $x, y$  adalah pusat objek

$Z_t$  : vektor observasi, juga terbentuk  $\begin{bmatrix} x \\ y \end{bmatrix}$

$t$  : waktu

$f$  : model dinamik

$g$  : model observasi

$\mu_t$  : proses noise (digunakan jika ada noise)

$\xi_t$  : observasi noise (digunakan jika ada noise)

Dalam metode *Adaptive Particle Filter* ini dibedakan menjadi 2 yaitu model dinamik serta model observasi, yang masing-masing memiliki fungsi yang berbeda-beda. Model dinamik untuk menentukan perubahan keadaan objek pada frame sedangkan model observasi digunakan untuk melakukan pembobotan partikel berdasarkan fungsi *likelihood*nya [10], [12], [13], [14].

Model dinamik mencirikan perubahan keadaan objek pada frame. Estimasi gerak onjek dinotasikan  $V_t$  dan  $\mu_t$  adalah *error* prediksi keadaan dan dapat diperoleh dari  $|uI_x + vI_y + I_t|$ ,  $u$  adalah besar gerakan pada sumbu  $x, v$  merupakan besaran gerak pada sumbu  $y$ , sedangkan  $I_x, I_y$  dan  $I_t$  adalah perubahan turunan parsial dari fungsi terhadap  $x, y, t$ . Maka model dinamik (1) dapat dibentuk kembali menjadi [13], [14]

$$X_{t+1} = X_t + V_t + \mu_t \quad (9)$$

Model Observasi merupakan model yang digunakan untuk melakukan pembobotan partikel berdasarkan fungsi *likelihood*. Fungsi *likelihood* didefinisikan [13], [14]:

$$P(Z_t|X_t) = P(Z_t^{int}|X_t)P(Z_t^{mot}|X_t)^{0_{t-1}} P(Z_t^{trj}|X_t)^{1-0_{t-1}} \quad (10)$$

$$\text{dengan } Z_t = \{Z_t^{int}, Z_t^{mot}, Z_t^{trj}\}$$

Dimana:

$Z_t^{int}$  : pengukuran intensitas yang independen terhadap  $Z_t^{mot}$  dan  $Z_t^{trj}$

$Z_t^{mot}$  : Pengukuran gerakan

$Z_t^{trj}$  : Pengukuran lintasan

0 : 0 jika objek mengalami oklusi dan n1 untuk yang lain.

Sebuah pengukuran intensitas dihitung berdasarkan kemiripan objek yang dilacak dengan partikel menggunakan *Sum of Squeece Differeces* (SSD) yang didefinisikan [13], [14]:

$$r(X_t) = \sum_{\chi \in W} [T(\chi) - I(\chi + X_t)]^2 \quad (11)$$

Dimana:

$U$  : sebuah kekacauan background yang diasumsikan berdistribusi uniform

$C_N$  : faktor normalisasi

$q_j$  :  $\frac{1-q_0}{j}$  adalah peluang prior dengan  $q_0 = 0,5$

*Likelihood* gerakan objek dihitung berdasarkan selisih antara perubahan posisi partikel dengan kecepatan rata-rata objek pada waktu sebelumnya yaitu [13], [14]:

$$d_{mot}^2 = (\Delta x_t \overline{\Delta y})^2 + (\Delta y_t \overline{\Delta x})^2, t > 1 \quad (13)$$

Dimana:

$\Delta x, \Delta y$  : perubahan posisi partikel

$\overline{\Delta x}, \overline{\Delta y}$  : kecepatan rata-rata objek pada waktu sebelumnya

Jika diketahui persamaan sebagai berikut [12], [13], [14]:

$$\overline{\Delta x} = \sum_{s=t-k}^{t-1} \frac{|x_s - x_{s-1}|}{k}, \quad (14)$$

$$\overline{\Delta y} = \sum_{s=t-k}^{t-1} \frac{|y_s - y_{s-1}|}{k}$$

Maka diperoleh perhitungan *likelihood* gerakan:

$$P(Z_t^{mot} | X_t) = \frac{1}{\sqrt{2\pi}\sigma_{mot}} \exp\left(-\frac{d_{mot}^2}{2\sigma_{mot}^2}\right) \quad (15)$$

Dimana  $\sigma_{mot}^2$  adalah varians untuk *likelihood* gerakan. Sedangkan untuk *likelihood* lintasan dari kedekatan partikel terhadap lintasan yang diperoleh dari posisi objek pada waktu sebelumnya. Didefinisikan fungsi lintasan dalam bentuk polynomial [12], [13], [14]:

$$y = \sum_{i=0}^m a_i x^i \quad (16)$$

Dimana:

$y$  : fungsi lintasan dalam bentuk polinomial

$a_i$  : koefisien polinomial

$m$  : order dari polinomial

*Likelihood* lintasan ini berdistribusi normal sehingga dapat ditulis [13], [14]

$$P(Z_t^{trj} | X_t) = \frac{1}{\sqrt{2\pi}\sigma_{trj}} \exp\left(-\frac{d_{trj}^2/F^2}{2\sigma_{trj}^2}\right) \quad (17)$$

Dimana  $\sigma_{trj}^2$  adalah varians untuk *likelihood*

lintasan,  $d_{trj} = |y - \sum_{i=0}^m a_i x^i|$  adalah *close metric* (nilai kedetana dari lintasan),  $F = \lambda_f^{t_0}$  adalah lintasan forgotten factor ( $\lambda_f = \text{rasio forgotten}$  ( $0 < \lambda_f < 1$ )) dan  $t_0 =$  banyak-nya frame pada saat objek mengalami oklusi [12], [13], [14].

### Metode Correlation Filter

Metode *Correlation Filter* pertama kali diperkenalkan untuk pelacakan objek oleh Bolme, dkk pada tahun 2010 yang biasa dikenal dengan MOSSE [1], [2], [4], [5], [6], [7], [8], [9], [16], [17]. Seiring berjalannya waktu, algoritma *Correlation Filter* semakin berkembang. Namun pada paper ini akan dibahas tentang dasar dari *Correlation Filter* itu sendiri [1], [2], [4], [5], [6], [7], [8].

*Correlation Filter* menggunakan pembelajaran yang membedakan antara target dengan sekitarnya, dengan tujuan diterapkan ke wilayah yang diinginkan pada frame tertentu untuk menentukan target [5], [6], [7]. Tujuan dari pelacakan objek menggunakan *Correlation Filter* adalah untuk menemukan fungsi yang meminimalkan *error* kuadrat dari matriks  $x_i$  dan target regresi  $y_i$  [5], [6]

$$\min_w \sum_i (f(x_i) - y_i)^2 + \lambda \|w\|^2 \quad (18)$$

Proses meminimalkan memiliki bentuk [1], [5], [6]:

$$w = (X^T X + \lambda I)^{-1} X^T y \quad (19)$$

Dimana  $w$  adalah vektor *Correlation Filter*,  $X$  adalah matriks circulant yang terdiri dari semua pergeseran circulant berdasarkan sampel  $x_i, y$  merupakan vektor dari Gaussian 2D dan setiap elemen dari  $y$  merupakan target regresi dari  $y_i, \lambda$  adalah parameter regular untuk mengontrol overfitting dan  $I$  adalah matriks identitas. Jumlahannya merupakan kompleks di domain Fourier, sehingga persamaan (2) dapat dituliskan [1], [5], [6]:

$$w = (X^H X + \lambda I)^{-1} X^H y \quad (20)$$

$X^H$  merupakan transpose Hermitian atau transpose konjugat. Matriks circulant dapat didiagonalisasi dengan menggunakan Transformasi Fourier Diskrit (TFD) sebagai berikut [1], [5], [6]:

$$X = F \text{diag}(\hat{x}) F^H \quad (21)$$

Dimana  $F$  merupakan matriks Transformasi Fourier Diskrit (TFD),  $F^H$  merupakan transpose Hermitian atau gtranspose konjugat,  $\hat{x}$  merupakan

notasi Transformasi Fourier Diskrit (TFD) dari vektor  $x$  dan  $\hat{x} = F(x) = \sqrt{n}Fx$ . Berikut adalah bentuk dari matriks circulant [2], [5], [6], [9]:

$$X = C(X) = \begin{bmatrix} x_1 & x_2 & x_3 & \dots & x_n \\ x_n & x_1 & x_2 & \dots & x_{n-1} \\ x_{n-2} & x_n & x_1 & \dots & x_{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_2 & x_3 & x_4 & \dots & x_1 \end{bmatrix} \quad (22)$$

Dengan menerapkan persamaan (4) ke persamaan (3), dihasilkan model pembaruan yaitu [2], [5], [6], [9]:

$$\hat{w} = \frac{\hat{x}^* \odot \hat{y}^*}{\hat{x}^* \odot \hat{x}^* + \lambda} \quad (23)$$

Dimana  $\hat{x}^*$  adalah konjugat kompleks dari  $\hat{x}$ . Untuk mendeteksi lokasi dari target baru di frame selanjutnya, kita dapat menghitung respon  $f(z)$ . Untuk semua calon patches  $z$ , diagonalisasikan  $f(z)$  untuk memperoleh lokasi target [2], [5], [6], [9]:

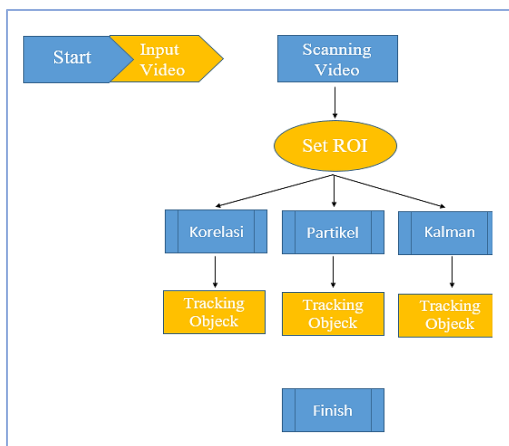
$$\hat{f}(z) = \hat{r}_p = \hat{w} \odot \hat{z} \quad (24)$$

Persamaan (6) dan (7) merupakan solusi dari domain primal, dimana solusi pada domain dual adalah untuk memperoleh model pembaruan yaitu [2], [5], [6], [9]:

$$\hat{\alpha} = \frac{\hat{y}^*}{\hat{x}^* \odot \hat{y}^* + \lambda} \quad (25)$$

### Tahapan Penelitian

Adapun tahapan penelitian pelacakan objek yang dilakukan menggunakan metode kalman filter, partikel filter dan korelasi filter ditunjukkan pada gambar 1.



Gambar 1. Diagram Blok Tahapan Penelitian

Dalam Gambar 1 tahapan penelitian, data video yang digunakan adalah video berupa kendaraan yang berada diruas jalan umum dan kendaraan disirkuit. Selanjutnya dalam pelacakan objek ini menggunakan ROI (*region of interest*), dimana objek yang berada didalam wilayah ROI saja yang akan diinvestigasi atau diobservasi [19], [20], [21], [22]. Dengan cara menentukan batas *endocardial* pemrosesan pelacakan objek yang akan diteliti akan lebih optimal [19], [20], [21]. ROI dapat ditentukan dengan beberapa cara seperti menggambar kotak pembatas yang diinginkan atau dengan menentukan koordinat fokus wilayah yang akan diteliti [19], [20]. Metode-metode yang diusulkan akan melacak (*tracking*) objek untuk dianalisis performansi metode tersebut. Analisis performa metode dilakukan dengan melihat akurasi pelacakan objek dan waktu komputasinya.

### 3. HASIL DAN PEMBAHASAN

Pada penelitian ini diimplementasikan metode kalman filter, particle filter dan metode correlation filter untuk tracking objek mobil pada data video lalu lintas dan video sirkuit nascar dengan menggunakan Python OpenCV. Video input yang digunakan memiliki format .mp4 dan sudah tersimpan pada komputer yang representasikan pada tabel 1.

Tabel 1. Jumlah Frame Pada Data Video

No	Nama	Jumlah Frame
1	Nascar	165
2	Dashcam	157
3	Drone	228

Selanjutnya dilakukan uji coba tracking objek menggunakan ketiga metode tersebut pada data pertama yaitu video lalu lintas dalam keadaan cuaca bersalju dan data kedua yaitu video nascar pada sebuah sirkuit. Hal ini dilakukan untuk menguji ketiga metode tersebut dan dapat mengetahui tingkat performansi metode. Untuk dapat melihat hasil tracking objek yang lebih jelas, diberikan visualiasi hasil dari implementasi tracking objek terhadap data tersebut sebagai berikut:

1. Implementasi Data Video Lalu Lintas




Gambar 2. Hasil dari Metode Partikel Filter



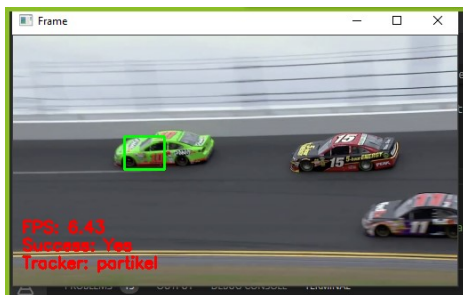


Gambar 3. Hasil dari Metode Korelasi Filter



Gambar 4. Hasil dari Metode Kalman Filter


## 2. Implementasi Data Video Sirkuit Nascar



Gambar 5. Hasil dari Metode Partikel Filter



Gambar 6. Hasil dari Metode Korelasi Filter



Gambar 7. Hasil dari Metode Kalman Filter

Dalam Gambar 2, 3 dan 4 hasil data video lalu lintas tersebut diambil pada frame ke 50 dari total frame seluruh video. Analisis visualisasi pada gambar diatas terlihat bahwa ketiga metode tersebut sukses dalam tracking objek mobil. Selanjutnya hasil performansi dari metode partikel filter adalah 5,59 FPS, untuk metode kalman filter diperoleh 9,54 FPS sedangkan dari metode korelasi filter diperoleh hasil 23,71 FPS.

Dalam analisis visualisasi waktu komputasi pada Gambar 2, 3, dan 4 terlihat bahwa metode korelasi lebih unggul dibandingkan dengan metode Partikel filter dan Kalman filter yaitu sebesar 23,71 FPS. Sedangkan metode Partikel filter merupakan metode paling kecil dalam hal komputasi. Dalam Gambar 5, 6 dan 7 hasil data sirkuit nascar tersebut diambil pada frame ke 50 dari total frame video keseluruhan. Analisis visualisasi pada gambar diatas terlihat bahwa ketiga metode tersebut sukses dalam tracking objek mobil. Selanjutnya hasil performansi waktu dari metode partikel filter adalah 6,42 FPS, untuk metode kalman filter diperoleh 9,23 FPS sedangkan dari metode korelasi filter diperoleh hasil 23,53 FPS.

Dalam analisis visualisasi waktu komputasi pada Gambar 5, 6 dan 7 terlihat bahwa metode korelasi lebih unggul dibandingkan dengan metode partikel filter dan Kalman filter yaitu sebesar 23,53 FPS. Sedangkan metode Partikel filter merupakan metode paling kecil dalam hal komputasi.

### Analisis Metode

Dalam hasil tracking objek terhadap keseluruhan data, terdapat beberapa objek pada frame yang tidak terdeteksi. Hasil kalkulasi tracking objek dari ketiga metode tersebut terhadap kedua video adalah sebagai berikut:

#### 1. Kalkulasi tracking objek pada video lalu lintas

Tabel 2. Jumlah Tracking 1

No	Metode	Jumlah Frame Terdeteksi	Jumlah Frame Tidak Terdeteksi
1	Kalman	152	5
2	Partikel	150	7
3	Korelasi	141	16

#### 2. Kalkulasi tracking objek pada video sirkuit nascar

Tabel 3. Jumlah Tracking 2

No	Metode	Jumlah Frame Terdeteksi	Jumlah Frame Tidak Terdeteksi
1	Kalman	160	5
2	Partikel	153	12
3	Korelasi	122	43


Dalam kalkulasi tracking objek video 1 dan video 2 diatas terlihat kalman filter lebih unggul dibandingkan dengan metode kompetitor yang lain dalam jumlah frame yang berhasil terlacak. Selanjutnya untuk memudahkan mengetahui performansi ketiga tracking objek mobil tersebut akan dihitung dengan persamaan berikut.

$$PK = \frac{JT}{JS} \times 100\% \quad (26)$$

Dimana:

- PK = persentase performa
- JT = jumlah frame terdeteksi
- JS = jumlah frame keseluruhan

Selanjutnya, didapatkan kalkulasi keseluruhan persentase performansi akurasi tracking objek oleh ketiga metode dapat dilihat pada grafik sebagai berikut.



Gambar 8. Persentase performansi akurasi tracking objek

Dalam Gambar 8 performansi akurasi tracking objek ketiga metode terlihat bahwa, kalman filter lebih akurat dibandingkan metode partikel filter dan korelasi. *Error target* ketiga metode berturut-turut didapatkan persentase *error* metode kalman yaitu 3,11%, persentase *error* metode partikel 5,91% sedangkan untuk metode korelasi memiliki persentase *error* 18,33%, dimana metode korelasi merupakan metode dengan *error* terbesar.


Selanjutnya dalam hasil tracking objek oleh ketiga metode tersebut terhadap keseluruhan data, telah didapatkan kalkulasi performansi waktu komputasi sebagai berikut:

Tabel 4. Performa waktu komputasi tracking objek

No	Metode	Jumlah Frame Terdeteksi	Jumlah Frame Tidak Terdeteksi
1	Kalman	8,52	10,98
2	Partikel	5,26	6,04
3	Korelasi	23,05	30,32

Dalam Tabel 4, terlihat bahwa performansi waktu komputasi metode korelasi mengungguli metode

partikel filter dan kalman filter. Jika dilihat dalam Gambar 8 dan Tabel 4 tersebut, dapat disimpulkan bahwa waktu komputasi berbanding terbalik dengan performa akurasi. Sebagaimana perbandingan antara rata-rata waktu komputasi dan persentase akurasi dapat dilihat dalam Gambar 9 berikut.



Gambar 9. Perbandingan persentase waktu komputasi dan performansi akurasi tracking objek

#### 4. KESIMPULAN

Dalam penelitian ini, implementasi metode kalman filter, partikel filter dan korelasi filter dapat melacak objek pada data video lalu lintas dan sirkuit naskar. Persentase akurasi dari hasil kalkulasi tracking objek dan analisis metode menunjukkan metode kalman filter mendapatkan 96,89%, dimana metode tersebut lebih baik dalam segi akurasi dibanding kedua kompetitornya yaitu partikel filter dan korelasi filter. Sedangkan dalam performansi rata-rata waktu komputasi menunjukkan metode korelasi mendapatkan 26,69 FPS, dimana metode korelasi mengungguli metode lainnya. Hal ini dapat disimpulkan bahwa performansi waktu komputasi berbanding terbalik dengan performansi akurasi.

#### DAFTAR PUSTAKA

- [1] Ma Chao, dkk. "Adaptive Correlation Filters with Long-Term and Short-Term Memory for Object Tracking", International Journal of Computer Vision 126:771-796, 2018.
- [2] Zuo Wangmeng, dkk. "Learning Support Correlation Filters for Visual Tracking", IEEE Transactions on Pattern Analysis and Machine Intelligence - 0162-8828, 2018.
- [3] Jeong Jong-Min, dkk. "Kalman Filter Based Multiple Objects Detection-Tracking Algorithm Robust to Occlusion". SICE Annual Conference, Sapporo, Japan. 2014.
- [4] Peng, Zheng dan Lu, XinJiang. "Learning region sparse constraint correlation filter for tracking". Elsevier, 2020.
- [5] Liu, Shuai, Liu, Dongye, dkk. "Overview of Correlation Filter Based Algorithms in Object Tracking". Springer, 2020.

- [6] Henriques F J, Caseiro R, Martins P, Batista J, "High-speed tracking with kernelized correlation filter", IEEE Transaction On Pattern Analysis and Machine Intelligence pp 3-6, 2015.
- [7] Lukezić A, dkk, "Discriminative Correlation Filter with Channel and Spatial Reliability". The Computer Vision Doundation -IEEE Xplore (6309-6318). 2022.
- [8] Sarifah L, Sulistyaningrum D R, Yunus M. "The correlation filter method for moving vehicle on transportation video". *Traitement du Signal Journal*, 2020.
- [9] Xuan Shiyu, dkk. "Object Tracking in Satellite Videos by Improved Correlation Filters With Motion Estimations", IEEE Transactions On Geoscience And Remote Sensing, Vol. 58, No. 2, page:1074-1086, 2022.
- [10] Ullah Inam, dkk."A Localization Based on Unscented Kalman Filter and Particle Filter Localization Algorithms", Special Section On Green Communications On Wireless Networks, Vol. 8, page: 2233-2246, 2020.
- [11] Xu Yabo, dkk. "Research on Particle Filter Tracking Method Based on Kalman Filter", IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference, 978-1-5386-1803-5/18, 2018.
- [12] Yang Changjiang, Duraiswami R, dan Davis L. "Fast Multiple Object Tracking via a Hierarchical Particle Filter", Proceedings of the Tenth IEEE International Conference on Computer Vision (ICCV'05). 2005.
- [13] Moghaddasi Somayyeh Sadegh, Faraji Neda. "A hybrid algorithm based on particle filter and genetic algorithm for target tracking", Expert Systems With Applications, 2020.
- [14] Jia-Qiang Li, dkk. "Target Tracking Algorithm Based On Adaptive Strong Tracking Particle Filter". IET Science, Measurement & Technology. Vol. 10, Iss 7, pp. 704-710. 2016.
- [15] Wang Yu, "Moving Vehicle Detection and Tracking Based on Video Sequences", *Traitement du Signal Journal*, page:325-331, 2020.
- [16] Liu qianbo, Hu Guoqing, dan Islam Mojahidul MD. "Robust Visual Tracking With Spatial Regularization Kernelized Correlation Filter Constrained by a Learning Spatial Reliability Map", IEEE. Translations and content mining, Vol 7. page: 27339-27351, 2019.
- [17] Wang Junan, dkk. "Object Tracking Based on a Time-Varying Spatio-Temporal Regularized Correlation Filter With Aberrance Repression". IEEE Photonics Journal, VOL. 14, NO. 6, 2022.
- [18] Jawas N, Sumiari N K. "Pelacakan Gerak Tangan dengan Metode Metode Pelacakan Objek Berbasis Korelasi". SMARTICS Journal Vol. 4, No. 2. 2018.
- [19] Jung Kyunghwa, dkk. "A hands-free region-of-interest selection interface for solo surgery with a wide-angle endoscope: preclinical proof of concept", Springer, 2016.
- [20] Gentili Claudio, dkk. "The case for preregistering all region of interest (ROI) analyses in neuroimaging research". *European Journal of Neuroscience*, 2020.
- [21] Hofbauer Markus, dkk. "Measuring Driver Situation Awareness Using Region-of-Interest Prediction and Eye Tracking", 2020 IEEE International Symposium on Multimedia (ISM), 978-1-7281-8697-9. 2020.
- [22] Pandey D, dkk. "Automatic and fast segmentation of breast region-of-interest (ROI) and density in MRIs", *Heliyon-ELSEVIER*, pp. 2405-8440. 2018.