G-Tech : Jurnal Teknologi Terapan
Vol. 8, No. 1, Januari 2024, hlmn. 330-339
E-ISSN: 2623-064X | P-ISSN: 2580-8737

# Pelacakan Titik Fitur Dengan Kanade-Lucas-Tomasi (KLT) Untuk Pengenalan Ekspresi Mikro Wajah Pada *Dataset* SAMM

**Priska Choirina[1]✉, Ulla Delfana Rosiani[2], Indah Martha Fitriani[3]**

[1] Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Raden Rahmat, Indonesia
[2] Teknik Informatika, Jurusan Teknologi Informasi, Politeknik Negeri Malang, Indonesia
[3] Teknik Elektro, Fakultas Sains dan Teknologi, Universitas Islam Raden Rahmat, Indonesia

**Informasi Artikel**

**Riwayat Artikel**

**Diserahkan** : 20-12-2023
**Direvisi** : 25-12-2023
**Diterima** : 27-12-2023

**ABSTRAK**

Ekspresi Mikro merupakan ekspresi yang terjadi di bawah alam sadar yang muncul ketika seseorang menyembunyikan emosi. Kontribusi utama penelitian ini menerapkan metode KLT yang dapat melacak gerakan serta memberikan akurasi pengenalan pada Dataset SAMM dengan baik. Metode KLT memanfaatkan titik-titik fitur untuk mendeteksi gerakan pada setiap *frame*. Area pengamatan adalah alis, mata dan mulut dengan penanda wajah yang dibentuk oleh *Discriminative Response Map Fitting*(DRMF). Hasil pelacakan seluruh titik-titik fitur berupa *motion features* yang terbentuk dari sebuah vektor hasil perpindahan titik-titik tersebut. Data ekstraksi fitur dibentuk dengan dua jenis yaitu data pemilihan manual (*handcrafted data*) dan *random sampling*. Data ekstraksi dilakukan proses klasifikasi dengan membandingkan dua metode yaitu *Support Vector Machine* (SVM) dan MLP-*Backpropagation*. Hasil penelitian ini menunjukkan hasil yang tergolong signifikan, pada data ekstraksi fitur *random sampling* dengan menggunakan MLP-Backpropagation menghasilkan akurasi tertinggi yaitu 79.8%. Selain itu, waktu pemrosesan pada setiap *frame* dengan menggunakan metode yang diusulkan tergolong sangat cepat.

**Kata Kunci:**

Ekspresi mikro, Pengenalan ekspresi mikro, KLT, SAMM, DRMF

***Keywords*:**

*Micro-expression, Micro-expression recognition, KLT, SAMM, DRMF*

***ABSTRACT***

*Micro Expressions are subconscious expressions that occur when a person hides emotions. The main contribution of this research is the application of the KLT method, which can track motion and provide good recognition accuracy on the SAMM Dataset. KLT method utilizes feature points to detect motion in each frame. The observation areas are eyebrows, eyes, and mouth, with facial markers formed by Discriminative Response Map Fitting (DRMF). The result of tracking all feature points is motion features included from a vector of the displacement of these points. Feature extraction data is formed with two types: handcrafted-data and random sampling. The extraction data is classified by comparing two methods, namely Support Vector Machine (SVM) and MLP-Backpropagation. The results of this study show significant results. Random sampling feature extraction data using MLP-Backpropagation produces the highest accuracy of 79.8%. In addition, the processing time on each frame using the proposed method is fast.*

***Corresponding Author*:**
Priska Choirina
Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Raden Rahmat, Indonesia
Jl. Raya Mojosari No.2, Dawuhan, Jatirejoyoso, Kecamatan. Kepanjen, Kabupaten Malang, Jawa Timur
Email : priska_choirina@uniramalang.ac.id

*This is an open access article under the CC BY license*

## PENDAHULUAN

Ekspresi Mikro merupakan ekspresi yang terjadi di bawah alam sadar yang muncul ketika seseorang mencoba menekan atau menyembunyikan emosi (Adegun & Vadapalli, 2020). Pengenalan ekspresi mikro yang tepat dapat membantu dalam memahami emosi yang sebenarnya, sehingga dapat menjadi dasar yang penting untuk mengidentifikasi perasaan subjektif dari seseorang dalam bidang keamanan publik atau psikoterapi (Ekman & Friesen, 1969). Pada umumnya, ekspresi wajah dikategorikan ke dalam dua jenis, yaitu ekspresi makro dan ekspresi mikro (Xia et al., 2020a). Ekspresi makro biasanya berlangsung antara tiga perempat detik hingga dua detik, dan gerakan otot terjadi secara bersamaan pada beberapa area wajah. Oleh karena itu, ekspresi makro dapat dengan mudah dipahami oleh manusia dalam waktu *real-time* (Xia et al., 2020b).

Karakteristik utama pada ekspresi mikro yaitu memiliki durasi gerakan wajah yang singkat dan gerakan halus pada gerakan otot-otot wajah (Choirina et al., 2023). Berdasarkan karakteristik tersebut, seseorang membutuhkan pelatihan profesional untuk mengenali ekspresi mikro secara manual. Proses pelatihan berbasis pembelajaran manusia membutuhkan waktu yang lama, namun akurasi pengenalan tergolong kurang tepat untuk tujuan analisis secara praktis (Buhari et al., 2020). Beberapa penelitian terdahulu telah mencoba menggunakan dan mengembangkan teknik *computer vision* untuk mengenali ekspresi mikro secara otomatis.

Pengenalan ekspresi mikro saat ini telah menarik banyak perhatian dalam beberapa tahun terakhir. *Dataset* SAMM (Yap et al., 2019) berbasis video, yang terdiri dari urutan gambar yang berurutan (*image sequences*), oleh karena itu tekstur dinamis lebih disukai untuk menggambarkan informasi *spatio-temporal* yang ada dalam video. Resolusi gambar dalam SAMM berukuran 2048x1088 dengan resolusi wajah yang dipotong dengan ukuran 400x400 sebagai bahan eksperimen. *Dataset* SAMM (Yap et al., 2019) berisi gerakan mikro yang direkam dengan kamera 200fps. Gerakan makro ekspresi termasuk dalam data tersebut bertujuan untuk agar tidak mengabaikan potensi gerak yang berguna untuk menganalisa ekspresi.

Fitur konvensional dari gambar wajah dapat dibagi menjadi fitur berbasis geometris (*geometric based*) dan fitur berbasis penampilan (*appearance-based*) (Fan & Tjahjadi, 2019). Fitur *geometric based* bertujuan untuk mendeteksi dan menemukan landmark wajah atau bentuk tertentu untuk mendapatkan fitur yang merepresentasikan geometri wajah. Fitur *appearance-based* merupakan fitur tingkat rendah, yang menangkap informasi tekstur dan penampilan wajah. Metode *Gabor Wavelets* dan *Local Binary Patterns* (LBP) merupakan metode *appearance-based* yang paling banyak digunakan untuk mendeskripsikan ekspresi wajah dengan menggunakan informasi penampilan lokal (*local appearance information*).

Namun, fitur berbasis tekstur menyulitkan untuk menangkap perubahan tampilan yang cepat dan berintensitas rendah yang terjadi pada ekspresi mikro. Sementara itu, fitur gerakan yang berasal dari *optical flow* dianggap sebagai pendekatan yang kuat dan akurat untuk pengenalan ekspresi mikro (Yuhong, 2021). Metode ini mencoba untuk mengenali aktivitas wajah dengan menganalisis gerakan itu sendiri. Karena ekspresi mikro dapat dicirikan dengan baik oleh fitur gerakan, kinerja pendekatan gerakan lebih baik daripada pendekatan *appearance-based* (Fan & Tjahjadi, 2019).

Dalam penelitian ini metode deteksi gerakan untuk pengenalan ekspresi mikro yaitu salah satu metode *optical flow*. Metode *optical flow* merupakan bagian dari metode gerak berbasis piksel (*pixel-based motion*) yang bertujuan untuk mengamati dan mendeteksi gerakan *non-rigid* dari komponen wajah. Salah satu metode *optical flow* adalah Kanade Lucas Tomasi (KLT) yang mampu mendeteksi gerakan halus berdasarkan pelacakan fitur titik (Rosiani et al., 2021). Metode KLT menghitung jumlah perbedaan kuadrat intensitas antara fitur-fitur dari dua gambar.

Penelitian terdahulu oleh Choirina, dkk (Choirina et al., 2023) menerapkan metode KLT untuk pengenalan ekspresi mikro pada C*hinese Academy of Sciences Micro-expression* (CASME II) berdasarkan pelacakan titik-titik yang dibentuk oleh *Discriminative Response Map Fitting* (DRMF),

selanjutnya titik fitur tersebut dilakukan pelacakan menggunakan KLT. Pelacakan fitur menghasilkan data fitur gerakan sebagai data ekstraksi fitur. Penelitian tersebut menggunakan metode klasifikasi *Support Vector Machine* (SVM) dan MLP-Backpropagatioan yang menghasilkan akurasi terbaik pada *Backpropagation* sebesar 81.3%.

Kontribusi utama penelitian ini adalah menerapkan salah satu metode *optical flow* yang dapat melacak gerakan dengan baik yaitu Kanade Lucas Tomasi (KLT). Metode KLT memanfaatkan titik-titik fitur untuk mendeteksi gerakan pada setiap *frame* , sehingga tidak membutuhkan area pengamatan yang luas. Area pengamatan pada penelitian ini adalah alis, mata dan sudut mulut dengan penanda wajah yang dibentuk oleh *Discriminative Response Map Fitting* (DRMF). Hasil pelacakan seluruh titik-titik fitur berupa *motion features* yang terbentuk dari sebuah vektor hasil perpindahan titik-titik tersebut. Data ekstraksi fitur dibentuk dengan dua jenis yaitu data pemilihan manual (*handcrafted data*) dan *random sampling* dengan menggunakan *dataset*. Penelitian ini bertujuan mendapatkan akurasi untuk memberikan hasil pengenalan ekspresi mikro yang baik pada *Dataset* ekspresi mikro SAMM.

## METODE PENELITIAN

Dalam penelitian ini terdapat tiga tahapan utama yaitu: 1) pra-pemrosesan, 2) ekstraksi fitur dan 3) klasifikasi. Pada bagian ini menjelaskan lebih rinci kerangka kerja untuk pengenalan ekspresi mikro menggunakan pelacakan titik fitur. Penelitian ini mengenali ekspresi mikro menggunakan *Dataset* SAMM dengan melacak titik-titik komponen wajah yaitu alis, mata, dan sudut mulut. Pada **Error! Reference source not found.** menunjukkan diagram blok pengenalan ekspresi mikro berdasarkan pelacakan titik fitur. Pada **Error! Reference source not found.**, menggunakan komponen wajah pada area alis kiri untuk menunjukkan pergerakan otot pada ekspresi mikro.

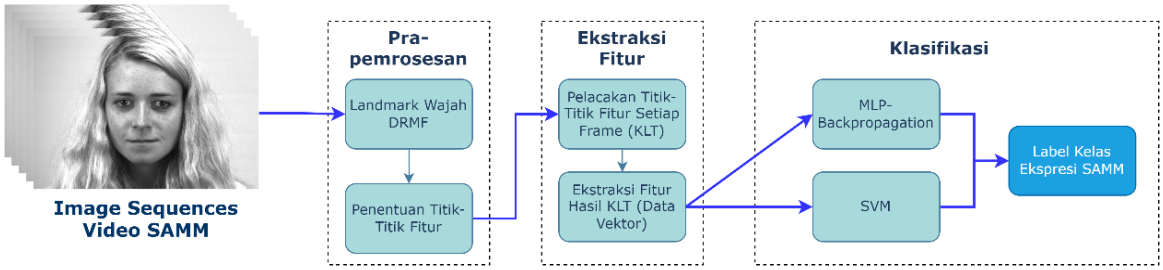


**Gambar 1. Kerangka Kerja Sistem**

### Pra-pemrosesan

Pada bagian pra-pemrosesan ini membahas terkait proses pendeteksian lokasi komponen pada wajah yaitu alis kanan, alis kiri, mata kanan, mata kiri, dan mulut. Pada tahapan pra-pemrosesan menggunakan *frame* pertama pada video sebagai acuan untuk *reference frame* . Hal ini terjadi karena perubahan yang terjadi pada ekspresi mikro sangat kecil dan dapat meminimalkan waktu dalam pemrosesan di seluruh *image sequences*. Pada penelitian ini menggunakan DRMF untuk menemukan komponen wajah secara akurat dalam waktu yang cepat. Metode DRMF dapat menyesuaikan bentuk wajah dengan kinerja yang mengesankan dan cocok untuk menangani kondisi oklusi dan iluminasi cahaya. Pendeteksian komponen wajah dengan DRMF memiliki tiga tahapan.

Metode DRMF (Ben et al., 2021) merupakan salah satu metode berbasis tekstur holistic yang mengandalkan inisialisasi bentuk. Selain itu, sebagai pendekatan berbasis regresi diskriminatif, DRMF berkinerja sangat baik dalam *face fitting scenario* (Bodini, 2019). Metode DRMF merupakan pendekatan berbasis regresi diskriminatif baru dalam kerangka kerja *Constrained Local Model* (CLM). Metode ini bekerja dengan baik pada kondisi landmark wajah secara umum dan sangat cocok untuk menangani objek latar belakang yang dinamis, oklusi dalam

jumlah besar, dan kondisi pencahayaan. Deteksi *landmark* wajah menggunakan metode DRMF menerapkan 66 titik yang tersebar di seluruh komponen wajah, diilustraksikan pada Gambar 1.

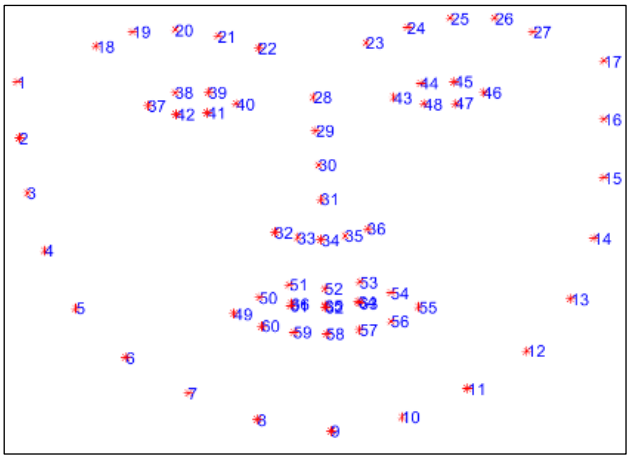

**Gambar 1. Distribusi titik-titik fitur pada wajah menggunakan DRMF**

Tahapan awal melakukan deteksi lokasi wajah menggunakan metode Viola Jones, kedua menghitung set fitur awal dari template DRMF dengan mengekstraksi respon patch untuk proyeksi dimensi rendah (*low dimensional projection*) (Salem et al., 2021). Selanjutnya metode ini melakukan perulangan titik fitur awal menghubungkan dengan *target frame* . *Output* dari metode DRMF merupakan sekumpulan titik yang berjumlah 66 yang tersebar pada area komponen wajah. Selanjutnya, pemilihan titik fitur dilakukan pada bagian alis, mata dan sudut mulut, pemilihan titik fitur mengadopsi penelitian terdahulu (Choirina et al., 2023) dapat dilihat pada Tabel 1.

**Tabel 1. Titik-titik fitur komponen area wajah**

| Fitur Wajah | Titik Ke | Jumlah Titik |
|---|---|---|
| Alis Kiri | 23-24 | 4 |
| Alis Kanan | 18-22 | 4 |
| Mata Kiri | 43-46 | 4 |
| Mata Kanan | 37-40 | 4 |
| Sudut Mulut | 49, 52, 55 dan 58 | 4 |

## Ekstraksi Fitur

Pada penelitian ini, tahapan ekstraksi fitur menggunakan salah satu metode *optical flow* yaitu KLT. Metode KLT mampu melacak titik-titik fitur dengan menggunakan *good features*. Pada penelitian ini menggunakan titik-titik fitur hasil pemilihan pada tahapan sebelumnya yaitu pada area alis, mata dan sudut mulut. Pelacakan titik-titik fitur tersebut yang dilacak menggunakan KLT pada *current frame* dan *reference frame* . Metode KLT pada penelitian ini memiliki dua tahapan utama yaitu menyelaraskan titik-titik fitur yang telah pada *current frame* $(f_n(x,y))$ yaitu *frame* pertama seperti pada Gambar 2. Selanjutnya, titik-titik fitur tersebut dilacak dan diselaraskan sesuai dengan perpindahannya pada *reference image* $f_{n+1}(x,y)$).

Metode KLT merupakan suatu algoritma yang digunakan untuk melacak dan mendeteksi fitur dalam gambar ataupun video. Metode KLT ini berguna dalam berbagai aplikasi termasuk dalam pelacakan objek dan estimasi pergerakan. Teknik ini digunakan secara luas pada bidang visi komputer dan robotika (He, 2023) untuk melacak titik-titik fitur termasuk dalam pengenalan ekspresi mikro. Salah satu kelebihan KLT adalah dapat mendeteksi titik-titik fitur yang memiliki ciri yang baik (*good features*) untuk melacak titik tersebut(Sinha et al., 2011).

Tujuan dari metode KLT adalah untuk menyelaraskan template $T(x)$ ke gambar input. KLT dapat menemukan keselarasan terbaik antara template dengan dengan *warped image* dengan meminimalkan jumlah kesalahan kuadrat di antara keduanya (Yongyong et al., 2020). Keseluruhan sistem KLT secara keseluruhan ditunjukkan pada **Gambar 3**. Titik awal diberikan sebagai acuan awal untuk proses pelacakan. Pelacakan mencoba menyelarasakan titik acuan awal dengan posisi dalam template pada gambar. Jika template dan gambar tidak konvergen, pelacak aan mencari titik lain untuk menemukan kecocokan dengan titik awal. Proses berulang-ulang ini berlanjut hingga penyelarasan terbaik dapat ditemukan dan kondisi baru dapat diekstraksi. Selanjutnya, kondisi baru akan digunakan sebagai titik awal untuk *frame* berikutnya.

$$W(x,p) = \begin{pmatrix}(1+p_1).x + p_3.y + p_5\\ p_2.x + (1+p_4).y + p_6\end{pmatrix} = \begin{pmatrix}1+p_1+p_3+p_5\\ p_2+1+p_4+p_6\end{pmatrix}\begin{pmatrix}x\\ y\\ 1\end{pmatrix} \quad (1)$$

Template sebagai model target digunakan untuk mengestimasi kondisi pada pelacak KLT yang menyelaraskan gambar template $T(x)$ yang merupakan sun-area (misalnya menggunakan window = $9 \times 9$) pada $t = 1$ ke gambar $I(x)$ pada $t = 2$, di mana koordinat oikselnya adalah $(x, y)$. Penyelarasan memetakan piksel $x$ pada template ke titik yang sesuai pada gambar input dengan *warp* $W(x,p)$, di mana $p = (p_1, p_2, \dots, p_n)$, $T$ adalah sekumpulan parameter. Sebagai contoh, kondisi objek bergerak, berikut formula *warp affine* pada Persamaan 1.

$$\sum_x \left[I\big(w(x,p)\big) - T(x)\right]^2 \quad (2)$$

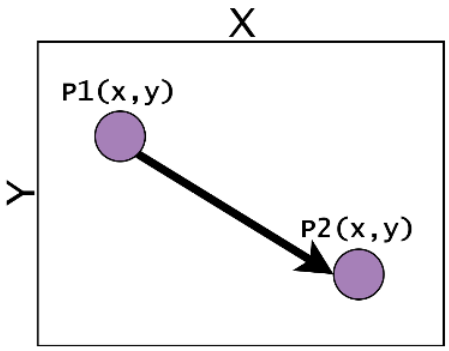


**Gambar 2. Ilustrasi pergerakan titik P1 (*current frame* ) P2 (*reference frame* )**

Pada Persamaan 2 dilakukan pada semua piksel $x$ dalam template $T(x)$ dan minimalisasi diperoleh dari hubungan dengan $p$. Bahkan jika *warp* $W(x,p)$ linier dalam $p$, namun Persamaan 2 tidak linier karena nilai piksel $I$ tidak linier. Untuk mengatasi masalah ini, KLT mengasumsikan bahwa $p$ untuk estimasi saat ini ada dan secara iteratif mencari $p$ yang baru dengan Persamaan 3. Di mana $\delta p$ merupakan sebuah *increment* dari p dan dapat memperbaharui $p$ dengan Persamaan 4. Iterasi pada Persamaan 2 dan Persamaan 3 berlanjut hingga parameter $p$ konvergen. Uji konvergensi biasanya dilakukan dengan membandingkan norma $p$ dengan *threshold* pada Persamaan 5. Algoritma ini dapat menemukan penyelarasan terbaik untuk setiap lokasi yang mungkin dalam ruang pencarian yang berisi beberapa wilayah di sekitar *previous states* (Yongyong et al., 2020).

$$\sum_x \left[I\big(w(x,p+\delta p)\big) - T(x)\right]^2 \quad (3)$$

$$p \leftarrow p + \delta p \quad (4)$$

$$\|\delta p\| \leq \epsilon \quad (5)$$

Dalam penelitian ini metode KLT bekerja dengan beberapa tahapan sebagai berikut (Choirina et al., 2023; Rosiani et al., 2021):

1) Inisiasi titik-titik fitur untuk pelacakan
2) *Reference frame* pada perpindahan titik-titik fitur dihitung minimal *error* dengan nilai perpindahannya
3) titik-titik fitur tersebut digolongkan menjadi dua bagian *foreground features* dan *background features.*
4) Jumlah perpindahan pada target dihitung dengan nilai perpindahan yang bergeser dari setiap titik-titik fitur *foreground point features*, nilai bobot tergantung pada nilai jarak disetiap titik terhadap koordinat pusat.

Setiap koordinat titik-titik fitur yang bergeser pada setiap *frame* disimpan untuk proses ekstraksi fitur.

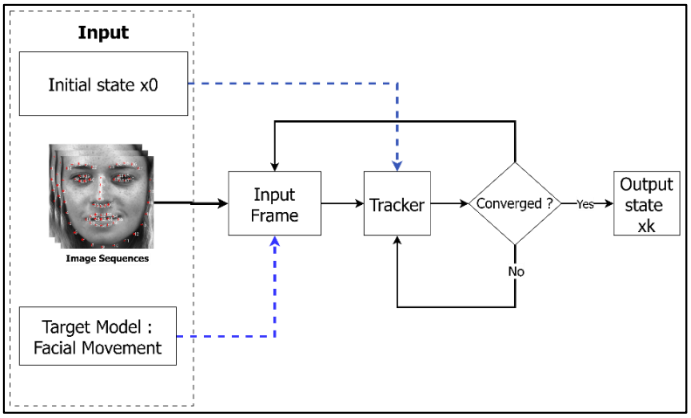


**Gambar 3. Sistem pelacakan KLT**

Setelah pelacakan pada setiap titik-titik fitur pada Tabel 1 di setiap *frame* dilakukan, *output* data merupakan vektor gerak dari setiap titik. Pergerakan setiap titik yang dilakukan pada proses pelacakan adalah ekstraksi dari karekteristik dari *motion features* (Lu et al., 2018). Karakterisitik dari motion features memiliki empat komponen yaitu koordinat $X$ dan $Y$, magnitude ($|\overrightarrow{PQ}|$) dan *orientation* ($O_{x,y}$). Komponen dari motion featues dirumuskan pada Persamaan 6 dan Persamaan 7.

$$RX = \left(x_{p,f} - x_{p,f-1}\right) \quad (6)$$

$$RY = \left(y_{p,f} - y_{p,f-1}\right) \quad (7)$$

Notasi $x_{p,f}$ dan $y_{p.f}$ merupakan variabel untuk titik dari $RX$ dan $RY$ pada *reference frame* . Sedangkan $x_{p,f-1}$ dan $y_{p,f-1}$ untuk menandakan pada *current frame*. Pada Persamaan 6 dan Persamaan 7 untuk menghasilkan nilai pada selisih fitur (perpindahan) untuk setiap fitur titik yang dilakukan pelacakan. Dua puluh titik fitur disetiap *frame* yang dilacak menghasilkan dimensi vektor berjumlah dua puluh data. Dimensi vektor memiliki komponen seperti *magnitude* (besaran) dan *tetha* (orientasi), dijelaskan pada Persamaan 8 dan Persamaan 9. Pada Persamaan 8 merupakan formula untuk *magnitude* yang didefinisikan dengan $|\overrightarrow{PQ}|$. Nilai dari *magnitude* didapatkan dari koordinat titik awal dan akhir dari vektor. Persamaan 9, merupakan rumus dari *orientation* (arah) dari vektor yaitu besar sudut yang dibentuk dari garis *horizontal*.

$$|\overrightarrow{PQ}| = \sqrt{((x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (8)$$

$$O(x,y) = \tan^{-1} \frac{i_{(x,y)}}{j_{(x,y)}} \quad (9)$$

Pada Gambar 4 merupakan informasi terkait koordinat titik ke 28 pada area mata kiri di *reference frame* dan *current frame* . Pada *current frame* , titik ke 28 dengan koordinat $(x, y) = [536, 303]$, sedangkan pada *reference frame* berpindah pada koordinat $(x, y) = [537, 304]$, dapat

disimpulkan terdapat perpindahan titik pada kedua *frame* tersebut. Selanjutnya hasil koordinat tersebut dihitung sesuai dengan komponen vektor pada Persamaan 6-9.

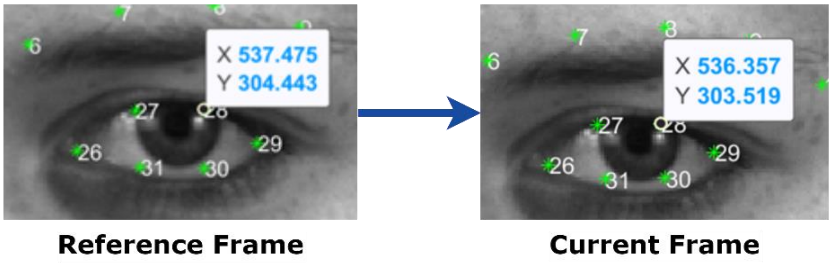


**Gambar 4. Koordinat dari hasil perpindahan mata kiri pada *reference frame* dan *current frame***

## HASIL DAN PEMBAHASAN

Pada penelitian ini evaluasi kinerja dengan percobaan pada *Dataset* ekspresi mikro yaitu SAMM. Penelitian ini menggunakan empat kelas ekspresi yaitu *sadness, disgust, happiness* dan *surprise* dari *Dataset* SAMM. Pembagian data training dan testing dijelaskan pada Tabel 2. *Dataset* SAMM terdiri dari 147 video dengan 343 ekspresi makro dan 159 ekspresi mikro (Yap et al., 2019). *Dataset* ini dikodekan dengan FACS-coded dengan AUs yang dijelaskan secara rinci. Fungsi FACS dan AUs dapat menjadi referensi mengambilan area sesuai dengan informasi kedua kode tersebut. Pada Tabel 2 terdapat 56 video pada keempat kelas ekspresi yaitu *sadness, disgust, happiness* dan *surprise.* Dalam penelitian ini menggunakan pembagian data 60% untuk data training dan 40% untuk data testing pada kelas ekspresi mikro.

**Tabel 2. Sampel Video Data Analisa SAMM**

| No | Kelas Ekspresi | Jumlah Data | | |
|---|---|---|---|---|
| | | *Training* (60%) | *Testing* (40%) | Total |
| 1 | *Disgust* | 5 | 4 | 9 |
| 2 | *Happiness* | 15 | 11 | 26 |
| 3 | *Sadness* | 4 | 2 | 6 |
| 4 | *Surprise* | 9 | 6 | 15 |
| | | | **Total** | **56** |

### Waktu Komputasi

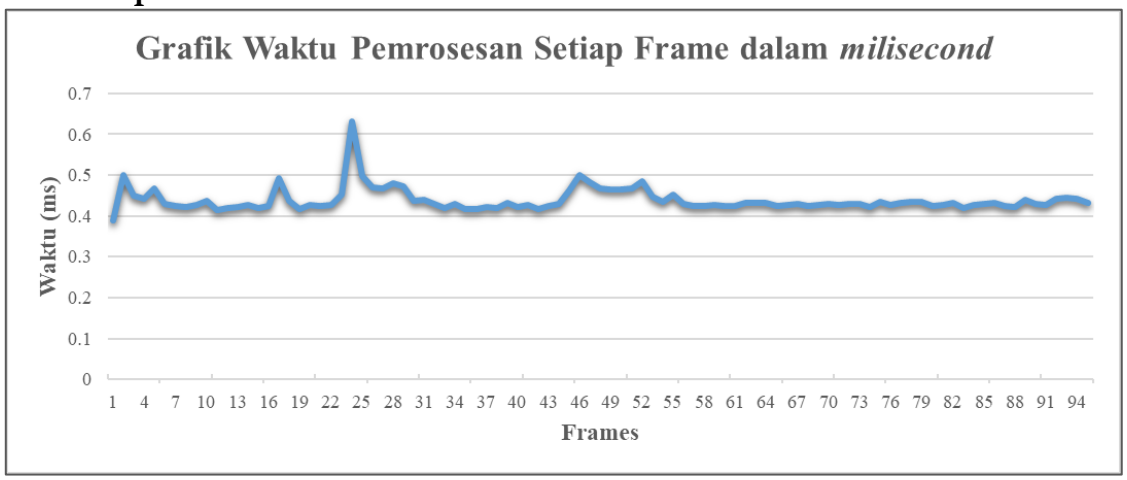


**Gambar 5. Grafik waktu pemrosesan setiap *frame* pada *video* 026_7_3-*Disgust***

Karakteristik dari ekspresi mikro memiliki gerakan yang halus dengan durasi yang sangat cepat. Dalam analisa pengenalan ekspresi mikro membutuhkan analisa pengukuran waktu dalam pemrosesan setiap *frame* . Penelitian ini dilakukan eksperimen pada *software* MATLAB yang berjalan pada CPU Intel(R) Core(TM) i3 dengan RAM 8 GB menggunakan sistem operasi windows. Pada Gambar 5 menunjukkan waktu pemrosesan pada salah satu sampel video dengan label ekspresi *disgust* pada file "026_7_3" yang memiliki 95 *frame* dalam satu video. Pada setiap *frame* memberikan estimasi waktu antara 0,38 ms hingga 0,63 ms dengan rata-rata waktu yang dibutuhkan dalam satu video adalah 0,43ms. Dengan waktu pemrosesan tersebut, sistem yang diusulkan dapat memberikan proses yang tergolong cepat dalam pengenalan ekspresi mikro.

Pada Tabel 3 menunjukkan perbandingan waktu pemrosesan pengenalan ekspresi mikro di setiap *frame* pada penelitian Liong, dkk (Liong et al., 2018) dan penelitian ini. Penelitian Liong, dkk menggunakan ekstraksi fitur *Bi-Weighted Oriented Optical Flow* (Bi-WOOF) yang menggunakan area blok besar pada wajah. Hasil penelitian tersebut membutuhkan waktu 3.940ms, sedangkan pada penelitian ini menghasilkan waktu komputasi yang lebih cepat yaitu 0,43ms. Waktu komputasi pada penelitian ini lebih cepat karena menggunakan blok-blok kecil pada titik-titik fitur yang dilacak, sehingga membutuhkan waktu yang singkat dalam pemrosesan.

**Tabel 3. Perbandingan Waktu Pemrosesan**

| Penulis | Ekstraksi Fitur | Rata-rata Waktu (ms) |
|---|---|---|
| Liong, dkk (Liong et al., 2018) | Bi-WOOF | 3,94 |
| **Penelitian ini** | **KLT** | **0,43** |

## Klasifikasi Pengenalan Ekspresi Mikro

Hasil ekstraksi fitur pada data *motion features* dari vektor perpindahan antara current *frame* dan reference *frame* menggunakan perbandingan dari metode klasifikasi Multi-*Layer Perceptron* (MLP) dan *Support Vector Machine* (SVM). Kedua metode tersebut berperan sebagai mengukur akurasi dengan melakukan klasifikasi emosi dalam ekspresi mikro. Pada metode SVM yang digunakan bersifat non-linier dengan menerapkan kernel *Radian Basis Function* (RBF). Pada RBF mampu memetakan sampel dalam ruang dimensi yang lebih tinggi. Dalam metode MLP mengimplementasikan salah satu algoritma *training data* yang sering digunakan yaitu *backpropagation*. Algoritma backpropagation menggunakan fungsi aktivasi logistic sigmoid, sedangkan untuk learning rate menggunakan nilai 0,001 (antara 0 sampai 1) dengan nilai epoch bernilai 200.

Tahapan klasifikasi pada penelitian ini dibagi dalam dua kondisi yaitu dengan membagi jumlah data pada setiap label ekspresi yaitu data training dan testing. Pengaturan data *training* dan data *testing* diproses secara manual sesuai dengan Tabel 2. Kedua, menggunakan pembagian data secara acak menggunakan salah satu metode sampling yaitu *Random Sampling*. Pengaturan persentase Random Sampling pada data *training* sebesar 60% dan data *testing* 40% yang dilakukan secara acak oleh sistem. Proses dalam *random sampling* dilakukan sebanyak sepuluh kali pengulangan terhadap masing-masing data *training* dan data *testing*.

Pada Tabel 4, merupakan hasil persentase akurasi dari dua jenis pengolahan data secara manual (*handcrafted data*) dan *random sampling*. Pada *handcrafted data* dengan metode SVM menghasilkan akurasi sebesar 56.3%, namun pada metode *backpropagation* akurasi sedikit meningkat sebesar 2.3% yaitu dengan akurasi 58.6%. Pada *random sampling* menghasilkan peningkatan akurasi sekitar 20% dari *handcrafted data* pada klasifikasi SVM dan Backpropagation. Hasil akurasi pada SVM sebesar 73.6% dan pada backpropagation sebesar 79.8%. Hasil akurasi dari kedua jenis data dapat dianalisa bahwa dengan metode *random sampling* menghasilkan persentase akurasi terbaik dari metode yang diusulkan dalam penelitian ini. *Random sampling* cenderung menghasilkan sampel data yang lebih representatif dari populasi data secara keseluruhan. Karena setiap elemen pada data memiliki peluang yang sama untuk dipilih, setiap

jenis elemen dalam data juga memiliki peluang yang sama untuk muncul dalam sebuah sampel. Dalam hal ini dapat membantu mengindari bias dalam metode pengambilan secara acak.

**Tabel 4. Klasifikasi Pengaturan *Handcrafted Data* dan *Random Sampling***

| Klasifikasi | *Handcrafted Data* (%) | *Random Sampling* (%) |
|---|---|---|
| SVM | 56.3 | 73.6 |
| MLP-Backpropagation | 58.6 | 79.8 |

## KESIMPULAN

Berdasarkan analisa yang telah dilakukan, dapat disimpulkan bahwa pengenalan ekspresi mikro dengan menerapkan metode KLT tergolong berhasil. Penelitian ini memanfaatkan titik-titik fitur yang tersebar pada area pengamatan seperti area mata, alis dan sudut mulut pada deretan *frame* dari *Dataset* SAMM. Data hasil ekstraksi fitur berupa *motion features* yang berasal dari gerakan perpindahan titik di setiap *frame* . Data *motion features* terdiri dari karakteristik vektor yaitu koordinat x, koordinat y, magnitude, dan *orientation*. Data ekstraksi fitur diproses dengan menerapkan perbandingan metode klasifikasi SVM dan MLP-Backpropagation. Pada penelitian ini data ekstraksi fitur dibagi menjadi dua tipe yaitu *handcrafted* dan *random sampling*. Hasil terbaik dari pembagian dua jenis data tersebut pada jenis *Random Sampling* yang menghasilkan akurasi tertinggi pada metode Backpropagation. Selain itu, waktu pemrosesan pada setiap *frame* dengan menggunakan metode yang diusulkan di penelitian ini tergolong sangat cepat. Sehingga dapat memberikan hasil pengenalan yang lebih cepat. Hasil penelitian ini menunjukkan hasil yang tergolong signifikan, pada data ekstraksi fitur *Random Sampling* dengan menggunakan MLP-Backpropagation menghasilkan akurasi tertinggi yaitu 79.8%. Selain itu, waktu pemrosesan pada setiap *frame* dengan menggunakan metode yang diusulkan tergolong sangat cepat.

## UCAPAN TERIMA KASIH

Tim peneliti mengucapkan terima kasih kepada Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi yang telah memberikan pendanaan penelitian melalui skema Penelitian Dosen Pemula (PDP) tahun anggaran 2023

## REFERENSI

Adegun, I. P., & Vadapalli, H. B. (2020). Facial micro-expression recognition: A machine learning approach. *Scientific African*, *8*, e00465–e00465. https://doi.org/10.1016/j.sciaf.2020.e00465

Ben, X., Ren, Y., Zhang, J., Wang, S.-J., Kpalma, K., Meng, W., & Liu, Y.-J. (2021). Video-based Facial Micro-Expression Analysis: A Survey of Datasets, Features and Algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1–1. https://doi.org/10.1109/TPAMI.2021.3067464

Bodini, M. (2019). A Review of Facial Landmark Extraction in 2D Images and Videos Using Deep Learning. *Big Data and Cognitive Computing*, *3*(1). https://doi.org/10.3390/bdcc3010014

Buhari, A. M., Ooi, C.-P., Baskaran, V. M., Phan, R. C. W., Wong, K., & Tan, W.-H. (2020). FACS-Based Graph Features for Real-Time Micro-Expression Recognition. *Journal of Imaging*, *6*(12), Article 12. https://doi.org/10.3390/jimaging6120130

Choirina, P., Rosiani, U. D., Fitriani, I. M., & Baqi, R. (2023). Facial Micro Expression Recognition for Feature Point Tracking using Apex Frames on CASME II Database. *Sinkron : Jurnal Dan Penelitian Teknik Informatika*, *8*(1), Article 1. https://doi.org/10.33395/sinkron.v8i1.11946

Ekman, P., & Friesen, W. V. (1969). Nonverbal Leakage and Clues to Deception†. *Psychiatry*, *32*(1), Article 1. https://doi.org/10.1080/00332747.1969.11023575

Fan, X., & Tjahjadi, T. (2019). Fusing dynamic deep learned features and handcrafted features for facial expression recognition. *Journal of Visual Communication and Image Representation*, *65*, 102659. https://doi.org/10.1016/j.jvcir.2019.102659

He, C. (2023). Face tracking using Kanade-Lucas-Tomasi algorithm. *Fifth International Conference on Computer Information Science and Artificial Intelligence (CISAI 2022)*, *12566*, 948–958. https://doi.org/10.1117/12.2667789

Liong, S.-T., See, J., Wong, K., & Phan, R. C.-W. (2018). Less is more: Micro-expression recognition from video using apex frame. *Signal Processing: Image Communication*, *62*, 82–92. https://doi.org/10.1016/j.image.2017.11.006

Lu, H., Kpalma, K., & Ronsin, J. (2018). Motion descriptors for micro-expression recognition. *Signal Processing: Image Communication*, *67*, 108–117.

Rosiani, U. D., Choirina, P., & Shoumi, M. N. (2021). Micro-expression recognition based on motion detection method. *IOP Conference Series: Materials Science and Engineering*, *1073*(1), 012069. https://doi.org/10.1088/1757-899X/1073/1/012069

Salem, E., Hassaballah, M., Mahmoud, M. M., & Ali, A.-M. M. (2021). Facial Features Detection: A Comparative Study. In A. E. Hassanien, A. Haqiq, P. J. Tonellato, L. Bellatreche, S. Goundar, A. T. Azar, E. Sabir, & D. Bouzidi (Eds.), *Proceedings of the International Conference on Artificial Intelligence and Computer Vision (AICV2021)* (pp. 402–412). Springer International Publishing. https://doi.org/10.1007/978-3-030-76346-6_37

Sinha, S. N., Frahm, J.-M., Pollefeys, M., & Genc, Y. (2011). Feature tracking and matching in video using programmable graphics hardware. *Machine Vision and Applications*, *22*(1), 207–217. https://doi.org/10.1007/s00138-007-0105-z

Xia, B., Wang, W., Wang, S., & Chen, E. (2020a). Learning from macro-expression: A micro-expression recognition framework. *Proceedings of the 28th ACM International Conference on Multimedia*, 2936–2944.

Xia, B., Wang, W., Wang, S., & Chen, E. (2020b). Learning from Macro-expression: A Micro-expression Recognition Framework. *Proceedings of the 28th ACM International Conference on Multimedia*, 2936–2944. https://doi.org/10.1145/3394171.3413774

Yap, C. H., Kendrick, C., & Yap, M. H. (2019). SAMM Long Videos: A Spontaneous Facial Micro- and Macro-Expressions Dataset. *arXiv Preprint arXiv:1911.01519*.

Yongyong, D., Xinhua, H., Zongling, W., & others. (2020). Image stabilization algorithm based on KLT motion tracking. *2020 International Conference on Computer Vision, Image and Deep Learning (CVIDL)*, 44–47.

Yuhong, H. (2021). Research on Micro-Expression Spotting Method Based on Optical Flow Features. In *Proceedings of the 29th ACM International Conference on Multimedia* (pp. 4803–4807). Association for Computing Machinery. https://doi.org/10.1145/3474085.3479225