



TESIS - TE142599

VIDEO OBJECT EXTRACTION BERBASIS LVQ MENGUNAKAN METRIK JARAK MINKOWSKI DAN EUCLIDEAN

AVIV YUNIAR RAHMAN
2215205012

DOSEN PEMBIMBING
Dr. Surya Sumpeno, ST., M.Sc.
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.

PROGRAM MAGISTER
BIDANG KEAHLIAN JARINGAN CERDAS MULTIMEDIA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2017



TESIS - TE142599

**VIDEO OBJECT EXTRACTION BERBASIS LVQ
MENGUNAKAN METRIK JARAK MINKOWSKI
DAN EUCLIDEAN**

AVIV YUNIAR RAHMAN
2215205012

DOSEN PEMBIMBING
Dr. Surya Sumpeno, ST., M.Sc.
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.

PROGRAM MAGISTER
BIDANG KEAHLIAN JARINGAN CERDAS MULTIMEDIA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2017

LEMBAR PENGESAHAN

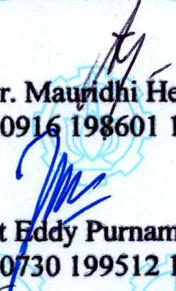
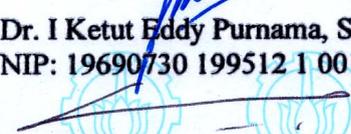
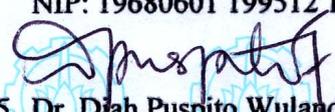
Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Teknik (M.T)
di
Institut Teknologi Sepuluh Nopember

oleh:

Aviv Yuniar Rahman
NRP. 2215205012

Tanggal Ujian : 15 Juni 2017
Periode Wisuda : September 2017

Disetujui oleh:

1.  Dr. Surya Sumpeno, ST., M.Sc. (Pembimbing I)
NIP: 19690613 199702 1 003
2.  Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng. (Pembimbing II)
NIP: 19580916 198601 1 001
3.  Dr. I Ketut Eddy Purnama, ST., MT. (Penguji)
NIP: 19690730 199512 1 001
4.  Dr. Eko Mulyanto Yuniarno, ST., MT. (Penguji)
NIP: 19680601 199512 1 009
5.  Dr. Diah Puspito Wulandari, ST., M.Sc. (Penguji)
NIP: 19801219 200501 2 001

Dekan Fakultas Teknologi Elektro


Dr. Tri Arief Sardjono, S.T., M.T.
NIP. 19700212 199512 1 001

Halaman ini sengaja dikosongkan

PERNYATAAN KEASLIAN TESIS

Dengan ini saya menyatakan bahwa isi keseluruhan Tesis saya dengan judul **“VIDEO OBJECT EXTRACTION BERBASIS LVQ MENGGUNAKAN METRIK JARAK MINKOWSKI DAN EUCLIDEAN”** adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Surabaya, 17 Juli 2017



Aviv Yuniar Rahman

NRP. 2215205012

Halaman ini sengaja dikosongkan

VIDEO OBJECT EXTRACTION BERBASIS LVQ MENGUNAKAN METRIK JARAK MINKOWSKI DAN EUCLIDEAN

Nama mahasiswa : Aviv Yuniar Rahman
NRP : 2215205012
Pembimbing : 1. Dr. Surya Sumpeno, ST., M.Sc.
2. Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.

ABSTRAK

Minor stroke merupakan permasalahan penyakit utama di negara berkembang. Apabila penyakit *minor stroke* tidak segera diatasi akan berakibat lebih parah lagi. Deteksi penyakit *minor stroke* biasanya seperti *Magnetic Resonance Imaging* (MRI), histology, *National Institutes of Health Stroke Scale score* (NIHSS) dan *Paroxysmal Atrial Fibrillation* (PAF). Deteksi penyakit *minor stroke* memerlukan proses waktu dan tenaga. Padahal penyakit *minor stroke* harus segera ditangani. Supaya tidak berakibat pada kerusakan kognitif yang lebih parah, maka memerlukan sistem deteksi dan rehabilitas menggunakan video. Untuk tahap deteksi dan rehabilitas memerlukan proses salah satunya *video object extraction*. Penelitian mengenai *video object extraction* pada kasus *minor stroke* menggunakan LVQ telah dilakukan sebelumnya. Namun hasil akurasi maksimal 68.76% pada $K=4.3$.

Kami mengusulkan perbaikan penelitian sebelumnya dengan mengganti metrik *euclidean* dengan *minkowski distance* pada *vector quantization* (VQ). Serta mengukur kecepatan waktu dalam menyelesaikan ekstraksi pada metrik *minkowski* dan *euclidean distance*. Data yang dipergunakan menggunakan video orang terserang penyakit *minor stroke*. Untuk data pembandingan menggunakan data video *claire*. Karena hanya memiliki satu *video minor stroke* saja. Metode yang dipergunakan dalam ekstraksi *video minor stroke* dan *claire* adalah *learning vector quantization* (LVQ). *Video minor stroke* dan *claire* diuji dengan variasi konstanta $K=0.1$ sampai $K=5$.

Hasil yang diperoleh saat pengujian *minor stroke* dan *claire* dengan perbandingan metrik *minkowski* dan *euclidean distance* adalah akurasi sama sebesar 68.76% pada $K=4.3$. Hal ini dipengaruhi oleh kualitas video *minor stroke* kurang maksimal dan parameter konstanta ekstraksi fitur (K) dan konstanta metrik *minkowski distance* (P). Namun untuk hasil akurasi rata-rata pengujian *claire extraction* dengan *minkowski distance* lebih baik daripada metrik *euclidean distance* sebesar 72.49%. Sedangkan untuk hasil pengujian kecepatan waktu *claire extraction* dengan metrik *minkowski distance* lebih cepat 52 detik pada $K=4.4$ daripada *euclidean distance*.

Kata kunci: *video object extraction*, *minor stroke*, LVQ, *minkowski distance*, *euclidean distance*.

Halaman ini sengaja dikosongkan

VIDEO OBJECT EXTRACTION BASED ON LVQ WITH MINKOWSKI DISTANCE AND EUCLIDEAN MATRIX

By : Aviv Yuniar Rahman
Student Identity Number: 2215205012
Supervisor(s) : 1. Dr. Surya Sumpeno, ST., M.Sc.
2. Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.

ABSTRACT

Minor stroke is the main illness in developed countries and should be prevented to avoid further severe injury. In order to prevent the illness, several detection methods have been developed, such as *Magnetic Resonance Imaging* (MRI), Histology, *National Institutes of Health Stroke Scale score* (NIHSS) and *Paroxysmal Atrial Fibrillation* (PAF). It is commonly known that *minor stroke* detection takes time and energy; thus, efficient video detection and rehabilitation method is required to be able to quickly detect the symptoms with a view to prevent the cognitive impairment. One of the processes in detection and rehabilitation is *video object extraction*. Some researches about *video object extraction* for *minor stroke* using LVQ has been conducted; however, the maximum accuracy achieved was 68.76% with $K=4.3$.

We propose the use of *minkowski distance* instead of *euclidean* in *vector quantization* (VQ). Here, we measure the time to complete an extraction in *minkowski* and *euclidean distance*. Video data from patients with *minor stroke* is used and video data *claire* is used for comparison. With only one *video minor stroke*, a method to extract *video minor stroke and claire* is *Learning Vector Quantization* (LVQ). *Video minor stroke and claire* is tested with constant variant from $K=0.1$ to $K=0.5$.

The same accuracy is derived from *minor stroke and claire* test with *minkowski and euclidean matrix distance*, namely 68.76% with $K=4.3$. This result is affected by a poor quality of *video minor stroke*, constant *parameter extraction* (K) and constant *minkowski distance matrix* (P). However, the mean accuracy for *claire extraction* with *minkowski distance* test is better than *euclidean matrix*, namely 72.49%. In addition the time of *claire extraction* with *minkowski distance matrix* is 52 seconds faster than *euclidean distance* with $K=4.4$.

Key words: *video object extraction, minor stroke, LVQ, minkowski distance, euclidean distance.*

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Penulis bersyukur atas kehadiran Allah SWT atas limpahan ramah dan karuniannya sehingga buku tesis “*Video Object Extraction Berbasis LVQ Menggunakan Metrik Jarak Minkowski dan Euclidean*” telah dapat diselesaikan. Penulis menyusun buku tesis selama kuliah di Magister Teknik Elektro, Fakultas Teknologi Elektro, Bidang Jaringan Cerdas Multimedia ITS. Semoga buku tesis yang disusun oleh penulis dapat bermanfaat dan dapat digunakan oleh mahasiswa Teknik Elektro khususnya. Selain itu, buku dapat bermanfaat untuk bidang kesehatan terutama masalah penyakit *Minor Stroke* yang mengancam masyarakat selama ini.

Terimakasih kepada Dr. Surya Sumpeno, ST., M.Sc dan Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng atas bimbingan selama ini, serta telah mengirim penulis untuk mengikuti International Conference on Information and Communication Technology (ICoICT 2017) di Malacca Malaysia, 17-19 Mei 2017. Terimakasih kepada teman-teman LAB HCCV Teknik Elektro ITS atas bantuan dan dukungan selama penelitian di sini. Terimakasih pula untuk teman-teman seangkatan penulis selama kuliah di Magister Teknik Elektro ITS. Terimakasih sebesar-besarnya untuk keluarga penulis terutama untuk Bapak, Ibu, Kakak dan Mambaus Saadah tercinta. Tidak lupa untuk Lembaga Pengelola Dana Pendidikan Indonesia (LPDP) yang telah memberikan beasiswa kuliah selama di Magister Teknik Elektro ITS, bantuan dana penelitian dan bantuan seminar ke Malaysia, serta semua pihak yang telah membantu dalam penyelesaian buku ini.

Penulis menyadari masih terdapat kekurangan dalam buku ini, untuk kritik dan saran terhadap penyempurnaan buku ini sangat diharapkan. Semoga buku ini dapat memberi manfaat bagi mahasiswa Magister Teknik Elektro ITS khususnya dan bagi semua pihak yang membutuhkan.

Surabaya, 9 Mei 2017

Penulis

Halaman ini sengaja dikosongkan

DAFTAR ISI

LEMBAR PENGESAHAN	iii
PERNYATAAN KEASLIAN TESIS	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xxi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Tujuan	6
1.4 Batasan Masalah	7
1.5 Manfaat	7
1.6 Metodologi Penelitian	8
BAB 2 KAJIAN PUSTAKA	9
2.1 Kajian Penelitian Terkait	9
2.1.1 Video Bidang Kesehatan	9
2.1.2 <i>Object Extraction</i> Menggunakan LVQ	11
2.1.3 Metrik Jarak <i>Minkowski</i> dan <i>Euclidean</i>	16
2.2 Dasar Teori	18
2.2.1 <i>Region of Interest</i>	18
2.2.2 Ekstraksi Fitur	18
2.2.3 Sistem Warna	20
2.2.4 Normalisasi Fitur	20
2.2.5 Metode LVQ	21
2.2.6 Metrik Jarak <i>Minkowski</i>	23
2.2.7 Metrik Jarak <i>Euclidean</i>	23
2.2.8 Evaluasi <i>Video Object Extraction</i>	24
BAB 3 METODOLOGI PENELITIAN	27
3.1 Data <i>Video Object Extraction</i>	28

3.2	<i>Region of Interest (ROI)</i>	28
3.3	Ekstraksi Fitur	28
3.4	Metode LVQ yang Diusulkan	31
3.4.1	<i>Vector Quantization</i> untuk Klustering.....	31
3.4.2	LVQ untuk Klasifikasi	32
3.5	Hasil Ekstraksi Obyek.....	33
3.6	Evaluasi	33
BAB 4 HASIL DAN PEMBAHASAN		37
4.1	Optimasi Parameter P pada Metrik <i>Minkowski Distance</i> dengan <i>Minor Stroke</i>	37
4.2	Optimasi Parameter P pada Metrik <i>Minkowski Distance</i> dengan <i>Claire</i>	42
4.3	Perbandingan Optimasi Parameter P pada <i>Minor Stroke</i> dengan <i>Claire</i>	46
4.4	Kecepatan Waktu pada saat Optimasi Paramater P dengan <i>Minor Stroke</i> dan <i>Claire</i>	47
4.5	Hasil <i>Minor Stroke Extraction</i> dengan <i>Minkowski Distance</i>	48
4.6	Hasil <i>Minor Stroke Extraction</i> dengan <i>Euclidean Distance</i>	50
4.7	Perbandingan <i>Minor Stroke Extraction</i> dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	52
4.8	Hasil <i>Claire Extraction</i> dengan <i>Minkowski Distance</i>	54
4.9	Hasil <i>Claire Extraction</i> dengan <i>Euclidean Distance</i>	56
4.10	Perbandingan <i>Claire Extraction</i> dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	58
4.11	Perbandingan <i>Minor Stroke</i> dengan <i>Claire Extraction</i>	60
4.12	Hasil Akurasi <i>Minor Stroke Extraction</i> dengan <i>Minkowski Distance</i>	64
4.13	Kecepatan Waktu pada saat Pengujian <i>Minor Stroke</i> dengan <i>Minkowski Distance</i>	66
4.14	Hasil Akurasi <i>Minor Stroke Extraction</i> dengan <i>Euclidean Distance</i>	68
4.15	Kecepatan Waktu pada saat Pengujian <i>Minor Stroke</i> dengan <i>Euclidean Distance</i>	70
4.16	Perbandingan Akurasi <i>Minor Stroke Extraction</i> dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	72
4.17	Perbandingan Kecepatan Waktu pada saat Pengujian <i>Minor Stroke</i> dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	73
4.18	Hasil Akurasi <i>Claire Extraction</i> dengan <i>Minkowski Distance</i>	74

4.19	Kecepatan Waktu pada saat Pengujian <i>Claire</i> dengan <i>Minkowski Distance</i>	76
4.20	Hasil Akurasi <i>Claire Extraction</i> dengan <i>Euclidean Distance</i>	78
4.21	Kecepatan Waktu pada saat Pengujian <i>Claire</i> dengan <i>Euclidean Distance</i> 81	
4.22	Perbandingan Akurasi <i>Claire Extraction</i> dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	82
4.23	Perbandingan Kecepatan waktu pada saat Pengujian <i>Claire</i> dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	83
4.24	Perbandingan Kecepatan Waktu pada saat Pengujian <i>Minor Stroke</i> dengan <i>Claire Extraction</i>	85
BAB 5 PENUTUP		91
5.1	Kesimpulan	91
5.2	Penelitian Selanjutnya.....	93
DAFTAR PUSTAKA		95
BIOGRAFI PENULIS		99

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 2. 1 Video untuk <i>Telemedicine</i> [1]	10
Gambar 2. 2 Frame Referensi dengan Obyek Manusia [31].....	11
Gambar 2. 3 Hasil Segmentasi Video pada Obyek Manusia [31].....	11
Gambar 2. 4 Hasil Segmentasi Video pada <i>Mother and Daughter</i> [32].....	12
Gambar 2. 5 Hasil Segmentasi Video pada <i>Table Tennis</i> [33]	13
Gambar 2. 6 <i>Video Sequence Hall Monitor</i> . (a) <i>Original Sequence</i> , (b) Hasil Segmentasi dengan $K=1$, (c) Hasil Segmentasi dengan $K=3.4$ [33]	14
Gambar 2. 7 <i>Image Ground Truth</i> pada <i>Flower Garden</i> [35].....	14
Gambar 2. 8 <i>Video Sequence Horse Riding</i> . (a) <i>Original Sequence</i> , (b) Hasil Segmentasi Algoritma Sebelumnya, (c) Hasil Segmentasi Algoritma yang Diusulkan [35].....	15
Gambar 2. 9 Skalar dalam 3 Kelas (a), Ilustrasi setiap Fungsi $f(x)$ (b) [31].....	21
Gambar 2. 10 Perbandingan <i>Matches</i> , <i>Losses</i> dan <i>Overlap</i> [31]	24
Gambar 2. 11 Contoh Data <i>Ground Truth</i> untuk Evaluasi VOE [35]	25
Gambar 3. 1 Sistem <i>Video Object Extraction</i> Berbasis LVQ Menggunakan Metrik Jarak <i>Minkowski</i> dan <i>Euclidean</i>	27
Gambar 3. 2 Harapan Hasil Ekstraksi <i>Video Object Extraction</i>	33
Gambar 4. 1 Akurasi <i>Mean</i> pada Proses <i>Minor Stroke Unsupervised Learning</i> dengan Nilai P	38
Gambar 4. 2 Akurasi <i>Mean</i> pada Proses <i>Minor Stroke Supervised Learning</i>	39
Gambar 4. 3 Akurasi <i>Median</i> pada Proses <i>Minor Stroke Supervised Learning</i> dengan Nilai P	40
Gambar 4. 4 Kecepatan Waktu saat Optimasi Nilai P pada <i>Minor Stroke</i>	41
Gambar 4. 5 Akurasi <i>Mean</i> pada Proses <i>Claire Unsupervised Learning</i>	43
Gambar 4. 6 Akurasi <i>Mean</i> pada Proses <i>Claire Supervised Learning</i>	44
Gambar 4. 7 Akurasi <i>Median</i> pada Proses <i>Claire Supervised Learning</i>	44
Gambar 4. 8 Kecepatan Waktu saat Optimasi Nilai P pada <i>Claire</i>	45
Gambar 4. 9 Perbandingan Pencarian Optimasi Akurasi <i>Median Minor Stroke</i> dengan <i>Claire</i> Menggunakan Parameter P.....	46
Gambar 4. 10 Kecepatan Waktu saat Mencari Optimasi Parameter P pada <i>Minor Stroke</i> dengan <i>Claire</i>	47
Gambar 4. 11 Hasil <i>Minor Stroke Extraction</i> dengan <i>Minkowski Distance</i> pada $K=0.5$	48
Gambar 4. 12 Hasil <i>Minor Stroke Extraction</i> dengan <i>Minkowski Distance</i> pada $K=4.3$	49
Gambar 4. 13 Hasil <i>Minor Stroke Extraction</i> dengan <i>Euclidean Distance</i> pada $K=0.2$	50
Gambar 4. 14 Hasil <i>Minor Stroke Extraction</i> dengan <i>Euclidean Distance</i> pada $K=4.3$	51
Gambar 4. 15 Hasil Perbandingan <i>Minor Stroke Extraction</i> Terbaik dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	52

Gambar 4. 16 Hasil Perbandingan <i>Minor Stroke Extraction</i> Terendah dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	53
Gambar 4. 17 Hasil <i>Claire Extraction</i> dengan <i>Minkowski Distance</i> pada $K=0.1$.	54
Gambar 4. 18 Hasil <i>Claire Extraction</i> dengan <i>Minkowski Distance</i> pada $K=4.5$.	55
Gambar 4. 19 Hasil <i>Claire Extraction</i> dengan <i>Euclidean Distance</i> pada $K=0.1$.	56
Gambar 4. 20 Hasil <i>Claire Extraction</i> dengan <i>Euclidean Distance</i> pada $K=3.8$.	57
Gambar 4. 21 Hasil Perbandingan <i>Claire Extraction</i> Terbaik dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	58
Gambar 4. 22 Hasil Perbandingan <i>Claire Extraction</i> Terendah dengan <i>Minkowski</i> dan <i>Euclidean Distance</i>	59
Gambar 4. 23 Hasil Perbandingan <i>Minor Stroke</i> dengan <i>Claire</i> Terbaik pada <i>Minkowski Distance</i>	60
Gambar 4. 24 Hasil Perbandingan <i>Minor Stroke</i> dengan <i>Claire</i> Terendah pada <i>Minkowski Distance</i>	61
Gambar 4. 25 Hasil Perbandingan <i>Minor Stroke</i> dengan <i>Claire</i> Terbaik pada <i>Euclidean Distance</i>	62
Gambar 4. 26 Hasil Perbandingan <i>Minor Stroke</i> dengan <i>Claire</i> Terendah pada <i>Euclidean Distance</i>	63
Gambar 4. 27 Akurasi <i>Minor Stroke</i> dengan <i>Minkowski Distance</i> dengan $P=2$...	64
Gambar 4. 28 Akurasi Setiap Frame <i>Minor Stroke</i> dengan <i>Minkowski Distance</i> dengan $P=2$	65
Gambar 4. 29 Kecepatan Waktu saat Pengujian <i>Minor Stroke</i> dengan <i>Minkowski Distance</i> dengan $P=2$	67
Gambar 4. 30 Akurasi <i>Minor Stroke</i> dengan <i>Euclidean Distance</i>	68
Gambar 4. 31 Akurasi <i>Minor Stroke</i> Setiap Frame dengan <i>Euclidean Distance</i>	69
Gambar 4. 32 Kecepatan Waktu saat Pengujian <i>Minor Stroke</i> dengan <i>Euclidean Distance</i> dengan $P=2$	71
Gambar 4. 33 Perbandingan Akurasi Metrik pada <i>Minor Stroke</i>	72
Gambar 4. 34 Perbandingan Kecepatan Waktu saat Pengujian <i>Minor Stroke</i> dengan Metrik Jarak <i>Minkowski</i> dan <i>Euclidean Distance</i>	73
Gambar 4. 35 Akurasi <i>claire</i> pada proses metrik <i>Minkowski Distance</i> dengan $P=1$	74
Gambar 4. 36 Akurasi <i>Claire</i> Setiap Frame dengan <i>Minkowski Distance</i> $P=1$	75
Gambar 4. 37 Kecepatan Waktu pada saat Pengujian <i>Claire</i> dengan <i>Minkowski Distance</i> $P=1$	77
Gambar 4. 38 Akurasi <i>Claire</i> dengan <i>Euclidean Distance</i>	78
Gambar 4. 39 Akurasi <i>Claire</i> Setiap Frame dengan <i>Euclidean Distance</i>	79
Gambar 4. 40 Kecepatan Waktu pada Saat Pengujian <i>Claire</i> dengan <i>Euclidean Distance</i>	80
Gambar 4. 41 Perbandingan Akurasi Metrik <i>Claire</i>	82
Gambar 4. 42 Perbandingan Kecepatan Waktu Metrik pada <i>Claire</i>	83
Gambar 4. 43 Perbandingan Kecepatan Waktu <i>Minor Stroke</i> dengan <i>Claire</i> Menggunakan <i>Minkowski Distance</i>	84

Gambar 4. 44 Perbandingan Kecepatan Waktu <i>Minor Stroke</i> dengan <i>Claire</i> Menggunakan <i>Euclidean Distance</i>	86
Gambar 4. 45 Perbandingan Kecepatan Waktu <i>Minor Stroke</i> dengan <i>Claire</i>	87

Halaman ini sengaja dikosongkan

DAFTAR TABEL

Tabel 2. 1 Keterangan Simbol Persamaan Jarak <i>Minkowski</i>	23
Tabel 4. 1 Perbandingan Optimasi Akurasi pada <i>Minor Stroke</i> dengan Nilai P dan Kecepatan Waktu	37
Tabel 4. 2 Perbandingan Optimasi Akurasi pada <i>claire</i> dengan Nilai P dan Waktu	42

Halaman ini sengaja dikosongkan

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Perkembangan dari video tidak hanya digunakan dalam dunia penyiaran saja. Saat ini, video digunakan dalam bidang kesehatan. Video digunakan dalam aplikasi *e-health* seperti *video conference*. Aplikasi *e-health* dapat menghubungkan pasien dengan tenaga medis atau dokter dengan jarak yang jauh. Sistem software *e-health* di desain untuk meningkatkan fasilitas perawatan pasien yang memiliki rumah yang jauh dengan rumah sakit dan mengurangi biaya [1]. Selain itu, aplikasi *e-health* digunakan dalam keadaan darurat seperti pemeriksaan pasien yang berada di mobil ambulans melalui *video conference*. Pasien yang berada di mobil ambulans memerlukan penanganan segera. Namun pada saat pasien di bawa mobil ambulans, hanya terdapat tenaga medis perawat saja. Oleh karena itu, tenaga medis memerlukan perintah dokter untuk mengambil keputusan dalam penanganan pasien. Supaya nyawa pasien yang berada di mobil ambulans dapat diselamatkan. Walaupun dokter berada jauh dari mobil ambulans yang membawa pasien [2].

Selain telemedicine, video digunakan untuk monitoring kesehatan orang lanjut usia atau disebut lansia. Orang yang berusia di atas enam puluh tahun perlu perawatan karena mengalami penurunan ingatan. Lansia mengalami penurunan ingatan yang dikategorikan sadar, ringan, sedang dan berat. Penyakit penurunan ingatan disebut Alzheimer yang menyerang orang lanjut usia. Monitoring terhadap lansia dengan merekam gerakan mencuci tangan di wastafel dengan video. Gerakan mencuci tangan direkam karena penyakit Alzheimer menyerang motoric dan gerakan tangan [3]. Pemanfaatan monitoring kesehatan melalui video diterapkan di kegiatan sehari-hari seperti makan, minum, menggunakan laptop dan membaca. Hal ini diperlukan karena untuk mengetahui klasifikasi kesehatan dari orang yang dimonitoring. Hasil yang diperoleh dari klasifikasi kesehatan untuk menentukan aplikasi kesehatan yang dibutuhkan [4].

Selain hal tersebut, pasien diabetes milinitus dan obesitas memerlukan monitoring kesehatan. Dari kegiatan dapur dan makanan yang dipantau oleh

perawat. Karena hasil monitoring akan berdampak terhadap gizi dari pasien tersebut. Sehingga sistem monitoring mempermudah dokter untuk memberikan informasi perawatan terhadap pasien [5]. Kegiatan monitoring juga diterapkan terhadap anak yang memiliki penyakit *neonatal* di rumah dengan *video conference*. Perawatan di rumah dengan fasilitas *video conference* biaya lebih murah daripada di rumah sakit. Sehingga dokter lebih mudah untuk mengambil tindakan tanpa pemeriksaan fisik [6].

Penyakit pnuan dan kronis memerlukan perawatan yang serius. Oleh karena itu, Pasien memerlukan video monitoring kesehatan. Supaya terhindari dari kematian dan kecacatan terhadap pasien. Melalui video monitoring fisiologi yang menggunakan cermin, maka pasien dapat dipantau kesehatannya. Sehingga tim medis dapat merawatnya dengan maksimal [7].

Teknologi video dapat diterapkan untuk monitoring kesehatan pasien kardiovaskuler pada saat rehabilitasi. Pasien menaiki sepeda, kemudian mengayuh. Hasil dari pose pasien mengayuh sepeda terlihat warna kulit berubah. Hal ini disebabkan oleh darah mengalir melalui pembuluh darah dan ekstraksi kardiovaskuler. Monitoring terhadap pasien kardiovaskuler sangat penting. Karena penyakit yang menimbulkan kematian nomer satu di dunia. Oleh karena itu, pasien kardiovaskuler memerlukan perawatan maksimal dan murah saat rehabilitasi [8].

Video tidak hanya digunakan untuk monitoring kesehatan, melainkan untuk identifikasi penyakit. Melalui teknologi video, Organ laring dapat dimonitoring terhadap perubahan patologi jaringan pembuluh darah. Penyakit yang menyerang perubahan patologi pada laring disebut tumor. Dengan teknologi video, penyakit tumor dapat diklasifikasi secara otomatis melalui video endoskopi [9].

Program aplikasi *e-Health* memanfaatkan *information communication technologies (ICT) video conferece* untuk usaha kebugaran kesehatan. Cara ini digunakan untuk memberikan fasilitas yang lebih terhadap pelanggan. Untuk menaikkan pendapatan pada usaha kebugaran. Selain itu, ICT *video conference* tidak memerlukan biaya dan tenaga yang banyak. Hanya memanfaatkan layanan *mobile* dan *cloud computing*. Karena persaingan usaha kebugaran kesehatan sangat ketat di Negara Jerman [10].

Perkembangan dari ICT saat ini memberikan informasi kesehatan kepada masyarakat yang mencarinya. Informasi kesehatan dapat ditemukan di social media seperti youtube. Namun jika informasi yang diperoleh tidak benar, maka dapat menyesatkan orang yang mencarinya. Banyak ditemui informasi kesehatan tidak diperbaharui atau produk medis palsu [11]. Sehingga pengguna emosi atau kesal terhadap informasi tersebut. Emosi negatif atau positif dari tayangan yang ditimbulkan akan berdampak bagi kesehatan mereka [12].

Dampak dari emosi negatif berpengaruh terhadap tekanan darah. Setiap individu memiliki tekanan darah yang berbeda. Faktor yang mempengaruhi tekanan darah seperti aktivitas, keadaan emosional, perubahan postur, situasi dan jenis kelamin [13]. Selain hal tersebut, emosi dipengaruhi keadaan cuaca. Dalam penelitiann sebelumnya, cuaca musim dingin mempengaruhi tekanan darah naik [13]. Efek dari tekanan darah naik dapat menyebabkan penyakit hipertensi. Penyebab pasien terkena hipertensi dipengaruhi oleh emosional dan stress [14]. Penyakit hipertensi merupakan penyakit yang umum ditemukan, tidak menular, asimtomatik dan tidak menular. Dampak dari penyakit hipertensi yang berkepanjangan dapat terkena serangan stroke apabila *systolic blood pressure* (SBP) dan *diastolic blood pressure* (DBP) tinggi [15].

Penyakit stroke merupakan permasalahan pada negara berkembang yang penghasilanya masih kurang. Di Negara berkembang mengenai kesadaran perawatan untuk pasien stroke masih kurang [16]. Terutama untuk penanganan penyakit *minor stroke* atau TIA, jika tidak segera diobati akan berdampak serangan berulang dalam seminggu. Oleh karena itu, *minor stroke* memerlukan penanangan yang serius supaya tidak terserang kembali. Dalam penelitian sebelumnya menunjukkan 80-90% tidak berulang lagi. Apabila pasien langsung dirawat di rumah sakit [17].

Sebagian besar pasien *minor stroke* atau TIA terserang gangguan kognitif. Pasien yang memiliki gangguan kognitif seperti *memory* tidak bekerja, abstraksi, penalaran, kefasihan lisan dan fleksibilitas kognitif terganggu. Walaupun pasien sudah pemulihan neurologis [18]. Selain itu, Pasien yang menderita stroke mengalami komplikasi seperti kecacat yang disebut *post-stroke depression* (PSD). Pasien *minor stroke* memiliki PSD yang rendah. Karena hanya difungsi neurologis

yang rusak [19]. Oleh sebab itu, perawatan pasien stroke memerlukan penanganan supaya terhindar dari serangan stroke berulang. Karena 10% dari pasien *minor stroke* di negara china mengalami serangan berulang pada minggu pertama. Oleh karena itu, memerlukan *early neurological deterioration* (END) untuk mengetahui hasil klinis. Karena kerusakan pada *early neurological deterioration* (END) merupakan faktor penting yang dapat memicu *stroke* berulang [20].

Penyakit *transient ischemic attacks* (TIA) atau *Minor Stroke* berhubungan dengan arteri barsilar. Untuk menemukan lesi kecil arteri barsilar memerlukan perangkat pencitraan *magnetic resonance imaging* (MRI) [21]. Namun terdapat beberapa kasus untuk menemukan lesi kecil atau *diffuse ischemic* yang tidak dapat dideteksi menggunakan perangkat MRI. Oleh karena itu, MRI memerlukan perbaikan untuk dapat mendeteksi lesi yang lebih kecil dengan merubah metode *photothrombosis*. Sehingga hasil yang diperoleh pencitraan MRI memiliki intensitas cahaya yang rendah dan pusat lesi yang lebih terang [22].

Orang yang diduga terkena *minor stroke* atau *transient ischemic attack* harus melewati pemeriksaan MRI [23]. Namun terdapat cara lain selain pemeriksaan MRI yaitu *national Institutes of health stroke scale score* (NIHSS) dan *paroxysmal atrial fibrillation* (PAF). Nilai *score* NIHSS dikeluarkan dari trombolis. Dengan cara melakukan lima tes item terhadap pasien. Validasi pasien *minor stroke* yang diusulkan *score* NIHSS = 5 maka terkena, NIHSS ≥ 2 dan NIHSS < 5 maka gejala dan NIHSS = 1 maka tidak terkena. Hasil dari *score* NIHSS untuk menentukan perawatan pasien [24]. Sedangkan deteksi *paroxysmal atrial fibrillation* (PAF) untuk penyakit stroke kriptogenik. Deteksi PAF sangat penting karena tercapai antikoagulan untuk pencegahan sekunder pada pasien stroke. Pemeriksaan pasien *minor stroke* menggunakan PAF yang meliputi MRI, pemeriksaan ultrasonografi arteri serviks, dan elektrokardiografi (EKG) [25].

Sistem untuk deteksi *minor stroke* seperti *magnetic resonance imaging* (MRI), *national Institutes of health stroke scale score* (NIHSS) dan *paroxysmal atrial fibrillation* (PAF) masih mengalami kendala dalam mendeteksi penyakit tersebut. Karena proses deteksi *minor stroke* masih menggunakan tenaga medis yang memakan waktu. Jika menggunakan deteksi PAF akan memerlukan tahap empat. Sedangkan jika menggunakan NIHSS memerlukan lima tahap yang lebih

lama lagi. Padahal penyakit *minor stroke* harus segera ditangani dengan cepat supaya kerusakan fisik tidak semakin parah dan tidak berulang lagi [20]. Mengenai tahap rehabilitasi pasien pasca stroke biasanya pasien dirawat dirumah karena keterbatasan biaya. Padahal perawatan pasien dengan perawat informal kurang optimal dalam merawat orang stroke. Sebab perawat informal mudah stress dan depresi menghadapi pasien. Karena sebelumnya perawat belum mendapatkan pelatihan terlebih dahulu [26].

Proses *detection minor stroke* melalui *pre-processing* dan pengenalan pola. Di dalam tahapan *pre-processing* terdapat video segmentasi atau *video object extraction*. Proses dari *pre-processing* yang paling penting pada klasifikasi video adalah segmentasi atau *object extraction*, ekstraksi fitur dan klasifikasi. Tujuan dari proses *video object extraction* pada kasus *minor stroke* untuk memaksimalkan proses akurasi pada *detection minor stroke* [27].

Video object extraction pada kasus *minor stroke* memerlukan teknik *machine learning* untuk mengambil obyek frame. LVQ merupakan salah jenis metode *machine learning* dalam *video object extraction*. Metode LVQ dalam penelitian sebelumnya bekerja *unsupervised* dan *supervised learning*. Kelebihan dari LVQ yang pertama dapat memisahkan *foreground* dengan *background* yang memiliki warna kompleks dengan baik [28]. Kedua, LVQ bisa memaksimalkan optimasi keputusan kelas untuk membedakan *foreground* dengan *background* [29].

Proses LVQ digunakan untuk memisahkan *foreground* dengan *background* yang diawali dengan frame pertama sebagai referensi. Cara kerja pemisahan *background* dengan *foreground* pada frame video secara otomatis. Namun hasil akurasi *video object extraction* pada kasus *minor stroke* yang terbaik sebesar 68.769 % pada $K=4.3$. Jangkauan variasi konstanta (K) dari $K=0.0$ sampai $K=5.0$ yang berjumlah lima puluh variasi. Dari hasil akurasi *video minor stroke extraction* masih kurang. Hal ini dipengaruhi oleh data *video* yang diproses waktu pengambilan data tidak stabil. Karena yang mengambil data *video* adalah orang yang terkena serangan penyakit *minor stroke* saat mengendarai mobil. Oleh karena itu, untuk meningkatkan akurasi dari *video minor stroke extraction* memerlukan perbaikan pada proses LVQ [28].

Metode LVQ pada penelitian *video minor stroke extraction* sebelumnya terdiri dari *vector quantization* (VQ) dan LVQ [28]. VQ bekerja *unsupervised learning* untuk mengenali *foreground* dengan *background*. Sedangkan LVQ bekerja *supervised learning*. Hasil dari VQ untuk data pelatihan pada proses LVQ. Untuk meningkatkan proses LVQ dapat memperbaiki VQ dengan mengganti metrik jarak *euclidean* dengan *minkowski* [30]. Hasil dari penelitian tersebut menunjukkan bahwa metrik *minkowski* lebih baik dari *euclidean distance* dan *quadratic*. Karena metrik *minkowski* mempunyai keunggulan komputasi pada VQ lebih cepat daripada metrik *euclidean distance* dan *quadratic* [30].

1.2 Rumusan Masalah

Video object extraction sangat penting dalam dunia kesehatan. Karena hasil ekstraksi dari *object minor stroke* dapat digunakan untuk proses deteksi *minor stroke* pada penelitian selanjutnya. Penelitian mengenai *video minor stroke extraction* menggunakan LVQ telah dikerjakan sebelumnya. Data video yang dipergunakan adalah orang yang tiba-tiba terkena serangan *minor stroke* di mobile. Data video tersebut kemudian diolah menggunakan LVQ. Tujuannya untuk menghasilkan *object minor stroke* yang dipisahkan dengan *background* pada video. Sistem yang diusulkan penelitian sebelumnya berhasil memisahkan *object minor stroke* dengan *background* pada frame video. Namun, hasil akurasi yang diperoleh dari *video object extraction* pada kasus *minor stroke* masih 68.76 % pada $K=4.3$. Nilai K merupakan konstanta dari $K=0.1$ sampai $K=5$.

1.3 Tujuan

Video object extraction menggunakan LVQ sudah dikerjakan sebelumnya. Namun, hasil akurasi dari *video object extraction* pada kasus *minor stroke* masih kurang dari 70%. Oleh karena itu, penelitian ini mengusulkan *video object extraction* berbasis *minkowski distance* pada kasus *minor stroke* dan *claire* sebagai data pembanding. Karena hanya memiliki satu data video *minor stroke*. Tujuan penelitian ini menggunakan metrik *minkowski distance* adalah untuk meningkatkan kinerja dan mempercepat waktu dari *video object extraction*. Karena dalam

penelitian sebelumnya, metode LVQ menggunakan proses *vector quantization* (VQ) dan *learning vector quantization* (LVQ). VQ bekerja *unsupervised learning* dengan metrik *euclidean distance*. Sedangkan LVQ bekerja *supervised learning* dengan metrik *euclidean distance*. Untuk meningkatkan akurasi *video object extraction*, maka sistem memerlukan pembenahan metrik pada VQ dengan *minkowski distance*. Karena akurasi penelitian sebelumnya menggunakan metrik *minkowski distance* lebih baik daripada *euclidean distance* dan *quadratic* pada proses *vector quantization*. Sehingga hasil akurasi *video object extraction* yang diharapkan dengan metrik jarak *minkowski* lebih baik daripada *euclidean*.

1.4 Batasan Masalah

Video object extraction menggunakan dua data yang terdiri dari *video minor stroke* dan *claire*. Tipe Data *video minor stroke* dan *claire* adalah MPEG-4. *Video object extraction* menggunakan teknik semi otomatis dalam memisahkan *foreground* dengan *background*. Metode semi otomatis merupakan teknik yang menggunakan bantuan manusia untuk mengidentifikasi *object* yang bermakna. Frame pertama pada video dipisahkan *foreground* dengan *background* oleh manusia. Untuk frame kedua sampai terakhir dipisahkan secara otomatis oleh LVQ. Evaluasi hasil dari kinerja LVQ dengan data *ground truth* yang dibandingkan dengan hasil ekstraksi sistem. Formula yang dipergunakan dalam evaluasi terdiri dari akurasi *mean* dan *median*.

1.5 Manfaat

Hasil peningkatan performa akurasi dari *video object extraction* pada bidang kesehatan dapat digunakan untuk deteksi *minor stroke* dan rehabilitasi pasien. Proses deteksi *minor stroke* memerlukan tahapan *pre-processing* dan pengenalan pola. Untuk meningkatkan performa deteksi *minor stroke*, maka tahap *pre-processing* harus maksimal. Proses untuk meningkatkan performa deteksi *minor stroke* dengan cara memperbaiki metrik pada *vector quantization* (VQ) pada *video object extraction*. Jadi hasil akurasi dari deteksi *minor stroke* akan meningkat.

1.6 Metodologi Penelitian

Penelitian *video object stroke extraction* menggunakan LVQ berbasis *minkowski* dan *eculidean distance*, terdapat tahapan untuk mencapainya. Metodologi penelitian yang dipergunakan dimulai dari studi literatur, pengumpulan data desain sistem, pengujian sistem dan penelitian, penyusunan laporan tesis. Penjelasan dari bagian metodologi penelitian adalah sebagai berikut:

a. Studi Literatur

Tahapan pertama dalam penelitian adalah studi literatur. Proses ini digunakan untuk menentukan topik penelitian dan judul. Setelah mendapat judul, kemudian mencari literatur di jurnal. Hasil review beberapa jurnal digunakan untuk merumuskan latar belakang, permasalahan dan tujuan penelitian.

b. Pengumpulan Data

Tahapan setelah studi literatur adalah pengumpulan data. Tahap ini digunakan untuk mencari data sebagai obyek topik. Data yang dipergunakan bertipe MPEG-4 untuk *minor stroke* dan *claire*. Data *video minor stroke* diambil dari youtube yang diunggah oleh rumah sakit singapura. Untuk *video claire* diambil dari penelitian *video object extraction* sebelumnya.

c. Desain Sistem

Video object extraction memiliki usulan sistem yang terdiri dari data video, *region of interest*, ekstraksi fitur, normalisasi, evaluasi, hasil ekstraksi dan metode LVQ yang terdiri dari VQ untuk klastering dan LVQ untuk klasifikasi.

d. Pengujian Sistem dan Penelitian

Tahap ke empat ini menguji dan meneliti tentang hasil dari sistem yang diusulkan beserta kelemahannya. Pengujian sistem untuk mencari akurasi tertinggi dengan mencari metrik terbaik. Pembahasan dalam penelitian terdiri dari hasil *video object extraction* pada kasus *minor stroke* dan *claire*, akurasi terbaik, terendah, hasil perbandingan metrik dan kecepatan proses *video object extraction* sebelum dan sesudah penelitian.

e. Penyusunan Buku Tesis

Penyusunan buku tesis merupakan tahap terakhir dalam metodologi penelitian. Penyusunan buku terdiri dari latar belakang, kajian pustaka, metodologi penelitian, hasil dan pembahasan berserta kesimpulan dan saran.

BAB 2

KAJIAN PUSTAKA

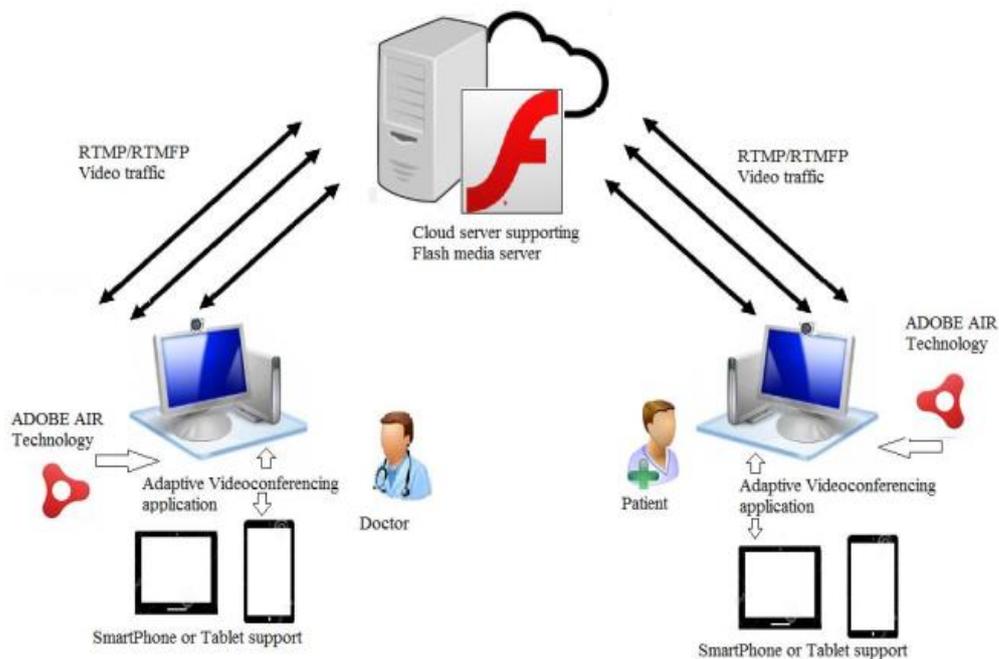
Bab ini berisi ulasan mengenai kajian penelitian terkait mengenai *video object extraction* yang telah dikerjakan sebelumnya seperti data, *pre-processing*, metode, hasil ekstraksi obyek dan evaluasinya. Penelitian terkait ini digunakan untuk membandingkan hasil penelitian sebelumnya dengan penelitian yang sedang dilakukan sekarang. Hasil penelitian terkait untuk mengusulkan metodologi penelitian yang digunakan dalam menyelesaikan permasalahan yang telah dibahas pada bab 1. Kedua, mengenai kajian pustaka dalam bab ini dibahas mengenai dasar teori yang digunakan dalam metode penelitian. Dasar teori yang digunakan dalam penelitian ini terdiri dari *region of interest (ROI)*, ekstraksi fitur, sistem warna, normalisasi fitur, metode *learning vector quantization (LVQ)*, metrik jarak *minkowski*, metrik jarak *euclidean* dan evaluasi *video object extraction*.

2.1 Kajian Penelitian Terkait

2.1.1 Video Bidang Kesehatan

Video dibidang kesehatan digunakan untuk *telemedicine*, monitoring, diagnosa dan marketing usaha kesehatan. Gambar 2.1 adalah *video* bidang *telemedicine* yang diterapkan untuk konsultasi pasien yang berada jauh dari fasilitas kesehatan seperti rumah sakit [1]. Konsultasi jarak jauh juga digunakan saat menolong pasien gawat darurat yang berada di mobil ambulans [2]. Ketiga, perawatan perilaku anak *neonatal* di rumah dengan fasilitas *video-conferencing tool (MVCT)* [6]. Dengan fasilitas *video conference*, pasien lebih mudah berkonsultasi mengenai kesehatannya dengan tenaga medis tanpa perlu datang dan tenaga medis lebih cepat mengambil keputusan [1][6].

Video dibidang monitoring dimanfaatkan untuk mengklasifikasi kesehatan orang dan merekomendasikan pemakaian aplikasi kesehatan. Layanan yang direkomendasikan *e-health* untuk rehabilitasi, perawatan lansia, rumah pintar dan rumah sakit, monitoring kebugaran dan kesehatan mental [3].

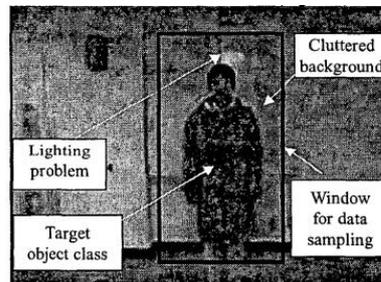


Gambar 2. 1 Video untuk *Telemedicine* [1]

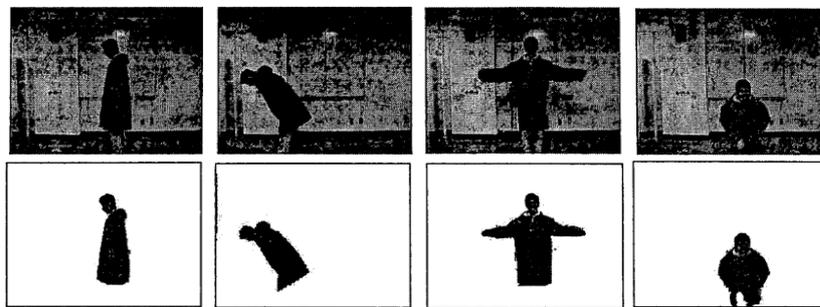
Monitoring video juga diterapkan untuk kegiatan dapur dan perilaku makan pada pasien yang menderita penyakit diabetes dan obesitas [4]. Selain itu, video untuk monitoring kesehatan pasien yang memiliki penyakit penuaan dan kronis. Informasi yang diambil dari pasien adalah aktivitas dan psikologis [7].

Perkirakan pose pengendalian sepeda untuk monitoring penyakit kardiovaskuler melalui teknologi video ketika rehabilitasi. Pasien kardiovaskuler yang menaiki sepeda akan berakibat warna kulit berubah. Hal ini disebabkan oleh darah yang mengalir melalui pembuluh dan ekstraksi darah kardiovaskular [8]. Video juga digunakan untuk mendeteksi dan klasifikasi lesi laring secara otomatis melalui video endoskopi. Teknik yang dipergunakan dalam deteksi dan klasifikasi adalah segmentasi dan analisis jaringan pembuluh darah [9]. Selain itu, Video digunakan untuk marketing dalam usaha kebugaran melalui informasi dan komunikasi teknologi (ICT). Karena persaingan usaha yang semakin sulit. Oleh karena itu, usaha kebugaran memerlukan metode supaya memberikan fasilitas yang lebih baik [10].

2.1.2 Object Extraction Menggunakan LVQ



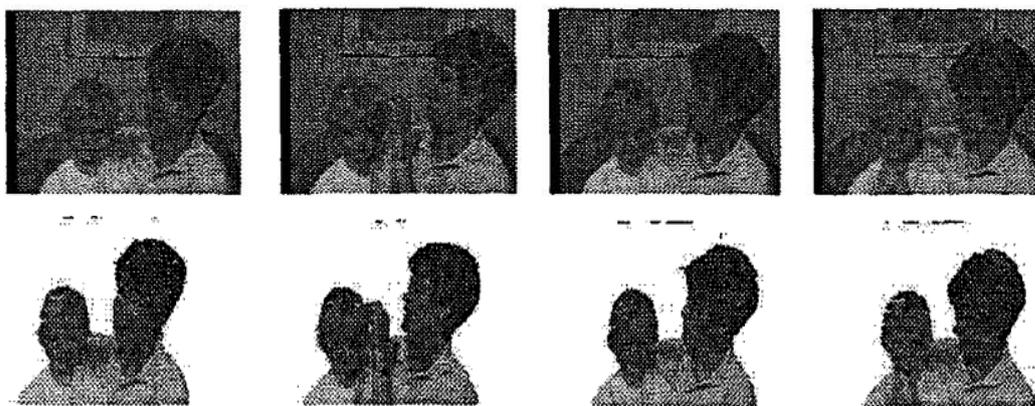
Gambar 2. 2 Frame Referensi dengan Obyek Manusia [31]



Gambar 2. 3 Hasil Segmentasi Video pada Obyek Manusia [31]

Segmentasi obyek manusia menggunakan LVQ diterapkan pada gerakan manusia dari urutan video warna digital. Masalahnya adalah memisahkan gerakan manusia sebagai target obyek dari gambar latar belakang dalam urutan video warna. Dalam pendekatan ini, setiap *pixel* bingkai video dianggap sebagai vektor 5 dimensi yang terdiri dari x-y sebagai koordinat *pixel* dan HSV pada ruang warna. Ide dasarnya adalah menggunakan *learning vector quantization* (LVQ) yang didefinisikan dalam vektor 5 dimensi [31].

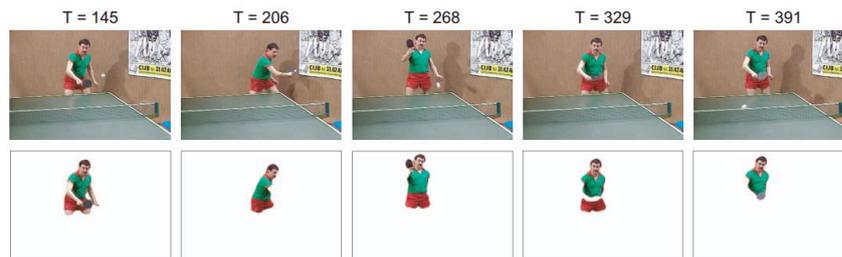
Ruang untuk membedakan objek sasaran manusia dari gambar latar belakang. Proses pemisah obyek dan latar belakang dengan frame pertama sebagai kunci seperti pada Gambar 2.2. Data klasifikasi awal digunakan untuk melatih sistem untuk menghasilkan *codebook vektor* awal. *Codebook vector* untuk menentukan daerah kelas dalam 5-Dimensi ruang vektor. Untuk pelacakan target frame pada kelas obyek manusia seperti pada Gambar 2.3. Kemudian *codebook vector* LVQ diperbarui secara berkala dengan memberi hasil klasifikasi ke dalam tahap pelatihan. Penelitian obyek manusia juga menyajikan evaluasi kinerja algoritma segmentasi berbasis LVQ [31].



Gambar 2. 4 Hasil Segmentasi Video pada *Mother and Daughter* [32]

Penelitian mengenai segmentasi video menggunakan *learning vector quantization* (LVQ) diperbaharui dengan akurasi *pixel-wise*. Tujuannya penelitian segmentasi video adalah untuk memecahkan masalah pemisahan citra manusia sebagai objek yang menarik dari gambar latar belakang. Penelitian ini menggunakan pendekatan setiap *pixel* dari rangkaian video. Fitur yang diusulkan dalam penelitian ini vektor 5 dimensi, yang terdiri dari komponen koordinat posisi *pixel* (koordinat x , y). Ditambah informasi warna *pixel* di HSV (*hue*, *saturation*, dan *value*). Pertama, membuat frame referensi dari objek manusia yang dikehendaki. Langkah ini dilakukan hanya pada frame pertama dari video [32].

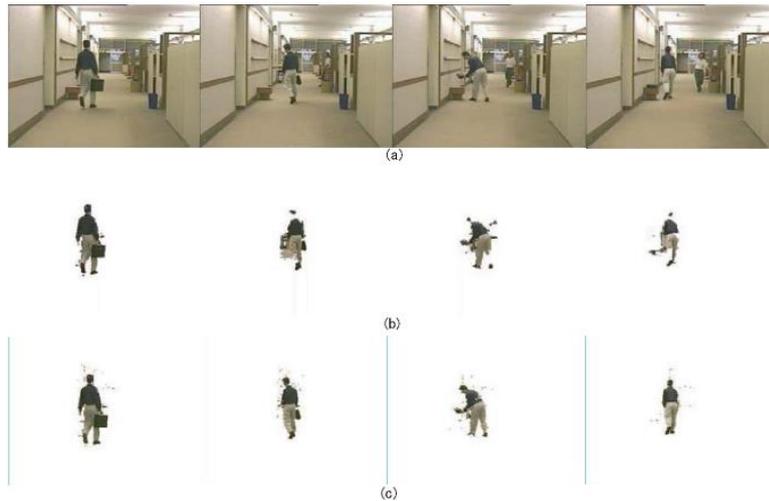
Learning vector quantization (LVQ) kemudian digunakan untuk memberi wilayah kelas yang optimal. Keputusan antara kelas objek manusia dan kelas latar belakang dengan melatih vektor *codebook*-nya, yang diawasi oleh kerangka referensi. Hasil segmentasi video yang dihasilkan dengan melakukan kuantisasi vektor LVQ. Proses segmentasi dengan menabur *codebook vektor* ke semua *pixel* bingkai frame. Akhirnya, untuk memperoleh gerakan *object* kelas orang di frame berhasil. Selanjutnya, *codebook vektor* LVQ diperbarui dengan memperbaharui *codebook vector* segmentasi ke dalam langkah latihan. Hasil segmentasi video terlihat dapat memisahkan obyek dengan background pada Gambar 2.4. Sistem segmentasi video juga menguji kinerja algoritma yang diusulkan untuk beberapa tes video MPEG-4 [32].



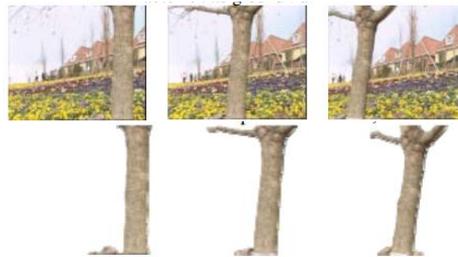
Gambar 2. 5 Hasil Segmentasi Video pada *Table Tennis* [33]

Segmentasi *video object* semi otomatis dengan menggunakan kuantisasi vektor pembelajaran (LVQ). Untuk setiap frame video, penelitian ini menggunakan fitur vektor 5-D yang komponennya adalah informasi spasial dalam koordinat pixel dan informasi warna pada ruang warna YUV. Pertama, objek yang diminati dan latar belakangnya didefinisikan dengan bantuan manusia. Kedua, *object* yang diminati dan latar belakangnya adalah yang digunakan untuk melatih *codebook vector* LVQ untuk mendekati bentuk *object*. Berikutnya, *codebook vector* LVQ digunakan untuk segmentasi *object* yang dituju secara otomatis untuk frame berikutnya. Penelitian segmentasi *video object* semi otomatis menggunakan variabel konstanta (K) skala vector 5-D untuk menyesuaikan keseimbangan antara informasi spasial dan warna untuk segmentasi yang akurat [34].

Hasil percobaan menunjukkan bahwa algoritma yang diusulkan berguna untuk melacak *object* yang bergerak dengan kecepatan sedang. Penelitian ini membahas tentang metode *temporal tracking* berbasis *learning vector quantization* untuk segmentasi video object secara semi-*automatic*. Suatu *semantic video object* diinisialisasi menggunakan bantuan pengguna pada sebuah referensi frame, untuk memberi klasifikasi patokan dari object yang diinginkan serta background-nya. LVQ training menggunakan video *object* dan *background*-nya untuk segmentasi *video object* pada frame-frame berikutnya, hal ini dikenal dengan istilah *temporal tracking*. Untuk melatih LVQ, dimasukan secara *sampling* setiap *pixel* dari sebuah video frame dalam bentuk vektor 5-dimensi, yang mengkombinasikan 2-dimensi posisi *pixel* pada koordinat (x, y) dan 3-dimensi *color space* HSV. Penelitian ini juga menampilkan hasil percobaan pada Gambar 2.6, menggunakan standar video tes MPEG-4 untuk mengevaluasi keakuratan dari metode yang diusulkan [34].



Gambar 2. 6 *Video Sequence Hall Monitor*. (a) *Original Sequence*, (b) Hasil Segmentasi dengan $K=1$, (c) Hasil Segmentasi dengan $K=3.4$ [33]



Gambar 2. 7 *Image Ground Truth* pada *Flower Garden* [35]

Algoritma semi otomatis untuk ekstraksi *object video*. Algoritma yang diusulkan mengasumsikan frame video utama objek semantik didefinisikan terlebih dahulu dengan bantuan manusia. Frame *object video* yang telah didefinisikan, selanjutnya untuk proses melacak dan segmentasi secara otomatis menggunakan *learning vector quantization* (LVQ). Setiap *pixel* bingkai video diwakili oleh sebuah vektor fitur 5 dimensi yang mengintegrasikan informasi spasial dan warna. Penelitian segmentasi *video object* semi otomatis menyajikan teknik untuk meningkatkan kinerja ekstraksi dari algoritma yang diusulkan. Evaluasi eksperimental menggunakan uji standar MPEG. Urutan video menunjukkan bahwa algoritma yang diusulkan dapat mengekstrak *object video* dengan kesalahan rata-rata 1% [29][33]. Hasil algoritma semi otomatis dengan *video sequence table tennis* terlihat pada Gambar 2.5.



Gambar 2. 8 *Video Sequence Horse Riding*. (a) *Original Sequence*, (b) Hasil Segmentasi Algoritma Sebelumnya, (c) Hasil Segmentasi Algoritma yang Diusulkan [35]

Teknik *video object extraction* telah dikembangkan. Namun, tidak ada evaluasi kinerja standar *video object extraction* tersedia. Oleh karena itu, teknik untuk mengevaluasi dan membandingkan hasil eksperimen ini dengan penelitian orang lain menjadi tugas yang sulit. Penelitian ini mengusulkan alat evaluasi kinerja standar untuk *video object extraction*. Alat evaluasi terdiri dari jumlah frame *ground-truth* dengan berbagai jenis urutan video dan metrik kesalahan sederhana [33]. Gambar 2.7 merupakan contoh *image sequence original* dan *image ground truth* pada *flower garden*.

Metode pelacakan *temporal* berbasis *learning vector quantization* (LVQ) untuk segmentasi objek video semi-otomatis. *Video object semantic* diinisialisasi menggunakan bantuan pengguna dalam bingkai referensi untuk memberi klasifikasi awal objek video dan wilayah latar belakangnya. Pelatihan LVQ untuk mendekati *object video* dan klasifikasi latar belakang. Hasil pelatihan LVQ digunakan untuk segmentasi otomatis *objek video* pada frame berikut sehingga pelatihan LVQ melakukan pelacakan *temporal*. Untuk input pelatihan LVQ, penelitian segmentasi video mengambil sampel setiap *pixel* bingkai video sebagai vektor 5 dimensi untuk menggabungkan posisi *pixel* 2 dimensi (x, y) dan ruang warna HSV 3 dimensi. Penelitian ini juga menunjukkan percobaan menggunakan beberapa rangkaian video uji MPEG-4 untuk mengevaluasi keakuratannya dari metode yang diusulkan [35]. Hasil pelacakan *temporal* berbasis *learning vector quantization* seperti pada Gambar 2.8.

2.1.3 Metrik Jarak *Minkowski* dan *Euclidean*

Metode pengembangan jaringan baru untuk mempercepat pembelajaran dan mengekstrak fitur eksplisit dalam pola masukan yang kompleks. Penelitian ini telah mengusulkan jenis algoritma baru dari pertumbuhan jaringan yang disebut algoritma jaringan penggabungan. Dengan algoritma ini, jaringan dapat tumbuh secara bertahap dengan memaksimalkan informasi pada pola masukan. Dalam algoritma, kebalikan dari kuadrat jarak *euclidean* biasanya antara pola input dan bobot koneksi digunakan untuk menghasilkan output unit yang kompetitif. Bila diterapkan pada beberapa masalah, metode sebelumnya telah menunjukkan pembelajaran yang lamban, dan terkadang metode tersebut tidak dapat menghasilkan keadaan dimana informasi cukup besar. Metode sebelumnya menghasilkan representasi internal eksplisit. Untuk memperbaiki kekurangan ini, penelitian jaringan baru mengusulkan jarak *minkowski* antara pola input dan bobot koneksi yang digunakan untuk menghasilkan parameter unit yang kompetitif untuk jarak *minkowski* lebih besar. Metode yang diusulkan mempunyai komponen terperinci dalam pola masukan yang dapat dihilangkan. Sehingga memungkinkan jaringan berkumpul lebih cepat dan untuk mengekstrak bagian utama pola masukan. Penelitian jaringan baru menerapkan metode baru untuk analisis beberapa data ekonomi. Dalam percobaan tersebut, hasilnya mengkonfirmasi bahwa metode baru dengan jarak *minkowski* dapat mempercepat pembelajaran secara signifikan, dan fitur yang lebih jelas dapat diekstraksi [36].

Perhitungan yang efisien terhadap tindakan mengukur jarak *Minkowski* mendesak. Secara umum, usaha komputasi yang dibutuhkan oleh momen-independen. Langkah penting terdiri dari dua aspek: menjalankan model untuk mendapatkan sampel untuk memperkirakan fungsi distribusi dan menghitung jarak *minkowski* antara fungsi distribusi asli dan fungsi distribusi bersyarat. Langkah yang terakhir yang sering melibatkan teknik integrasi numerik dan intensitas komputasi. Langkah ini bisa diabaikan dengan membandingkan proses pertama, terutama bila modelnya terkait dengan kode komputer yang sudah berjalan lama. Studi untuk memperkirakan secara efisien langkah-langkah penting independen telah dilakukan, dan teknik di dalamnya juga dapat digunakan untuk memperkirakan ukuran jarak *minkowski* [37].

Setiap *skizofrenia* kasus baru akan dihitung dengan menggunakan metode kesamaan *minkowski weighted*. Penelitian ini berfokus pada penentuan Lambda (r) yang paling efisien antara nilai 1, 2 dan 3 pada model jarak *Minkowski*. Data yang diperoleh dari rekam medis sebanyak 95 kasus dimana 80 kasus digunakan sebagai data pelatihan dan 15 kasus digunakan sebagai data uji. Berdasarkan hasil pengujian yang dilakukan, nilai lambda yang memiliki tingkat akurasi terbaik adalah 3. Untuk mendiagnosis jenis *skizofrenia*, Model Jarak *minkowski* dengan nilai lambda 3 dapat digunakan [38].

Penelitian *minkowski distance* selanjutnya, menyajikan rumusan umum tentang tindakan penting momen-independen dan beberapa tindakan penting yang dibahas secara umum dan disatukan berdasarkan jarak *minkowski*. Langkah-langkah penting sesaat dapat dikategorikan menjadi tiga kelas ukuran jarak jauh *minkowski* terdiri dari fungsi kepadatan probabilitas, fungsi distribusi kumulatif dan berbasis kuantitatif [37].

Beberapa sifat dari tindakan ukuran jarak *minkowski* yang diusulkan untuk diselidiki. Beberapa tindakan penting juga diturunkan sebagai kasus khusus dari langkah-langkah jarak jauh *minkowski* yang umum dan diilustrasikan dengan beberapa studi kasus [39].

Jarak *minkowski* yang dinormalkan dalam metrik *hausdorff*, penelitian Jarak *minkowski* memberikan beberapa hasil sensitivitas. Sehubungan dengan tiga konjungsi *fuzzy interval-value* yang khas, yang bernilai interval *Gödel t-norm* dan implikasi yang sesuai. Nilai interval *Lukasiewicz t-norm* dan implikasi yang sesuai, nilai interval *Goguen t-norm* dan implikasi yang sesuai. Kemudian penelitian ini membahas tentang ketangguhan algoritma inferensi *triple I, interval-valued fuzzy* 48.

Algoritma inferensi *triple I, interval-valued fuzzy* terkait dengan hubungan perturbasi *interval-valued fuzzy*. Penelitian ini membuktikan bahwa metode *triple I* berdasarkan *t-norm lukasiewicz* bernilai interval dan implikasi yang sesuai adalah algoritma terbaik untuk perkiraan penalaran. Sedangkan metode *triple I* berdasarkan *t-norma Gödel* bernilai interval dan implikasi yang sesuai. *Norma Goguen* dan implikasi yang sesuai tidak memiliki perilaku ketahanan yang baik [40].

2.2 Dasar Teori

2.2.1 *Region of Interest*

Sistem pengambilan citra berbasis wilayah selalu mempertimbangkan area utama, bukan keseluruhan gambar. *Region of interest* adalah konsep yang digunakan untuk pengambilan dari database. *Region of interest* berdasarkan minat gambar yang melibatkan dua teknik penting. Salah satunya adalah dimana pengguna memilih wilayah yang diminati. Selain itu, *region of interest* sebagai tempat mesin untuk melakukan semacam minat pengguna dan bergantung pada citra *query*. *Region of interest* berdasarkan gambar minat yang melibatkan teknik berbasis wilayah yang memungkinkan pengguna untuk menentukan wilayah sebenarnya ke *query*. Daerah yang dipilih oleh pengguna akan digunakan lebih jauh untuk ekstraksi fitur dan daerah lainnya akan terpotong [41].

2.2.2 Ekstraksi Fitur

Bagian ini menjelaskan konsep dasar sistem segmentasi gerakan manusia yaitu masalah, konfigurasi vektor untuk input data dan lain-lain. Beberapa masalah segmentasi gerak manusia datang ke latar belakang yang kompleks, pencahayaan perspektif, deformasi objek manusia, warna kesamaan antara objek dan latar belakang yang berantakan, urutan gambar video. Untuk mengatasi masalah di atas, penelitian sebelumnya merancang sistem segmentasi yang memiliki akurasi *pixel-wise*. Tujuannya untuk akurasi segmentasi berbasis *pixel* dan tipe data vektor khusus harus dibuat untuk memberikan informasi *pixel* yang akurat ke sistem segmentasi. Oleh karena itu, penelitian VOE sebelumnya mengusulkan konfigurasi vektor data 5 dimensi, menggabungkan sistem koordinat (x, y) dan model warna HSV [32].

Deskripsi model warna HSV adalah H, karena *hue* mewakili nilai warna yang berbeda (yaitu merah, hijau, biru) dan semua dari berbagai warna di antaranya. S sebagai *saturation*, karena jumlah warna yang digunakan. S membawa nilai ke atas untuk meningkatkan warna dan menurunkan nilai yang pada akhirnya akan memberi warna abu-abu. V sebagai nilai *brightness* yang bisa memberi warna pencahayaan lebih banyak. Beberapa penelitian menggunakan model warna RGB sebagai komponen warna dari vektor data. Masalah model warna RGB adalah nilai RGB cenderung berubah secara signifikan saat kondisi cahaya sedang berubah.

Alasan penggunaan model HSV sebagai salah satu komponen vektor adalah karena toleransi terhadap perubahan cahaya. Pada model HSV, hanya komponen V yang berubah dalam kondisi cahaya yang berbeda. Komponen H dan S tidak berubah secara signifikan. Ide dasar penggunaan kombinasi posisi *pixel* koordinat dan informasi adalah sebagai berikut [32]:

- Pendekatan menggunakan informasi warna *pixel* saja, kompleksitas latar belakang, noise gambar dan kesamaan warna antar kelas objek dan kelas latar akan menjadi kesulitan yang parah. Masalahnya bagaimana menentukan *pixel* kelas objek sekalipun. Ketika mereka memiliki warna yang sama seperti *pixel* kelas *background*.
- Pendekatan menggunakan koordinat posisi *pixel*. Deformasi kelas *object* manusia akan menjadi masalah pendekatan dengan hanya menggunakan informasi posisi. Jika gerakan manusia memiliki bentuk yang stabil dan hanya mengubah posisinya, sebuah teknik *block matching* bisa melacaknya. Tapi, jika *object video* diganti, masalahnya akan lebih parah.

Integrasi *pixel* posisi koordinat dan informasi warna dalam model HSV bisa memberi informasi *pixel* yang akurat. Kombinasi fitur akan bertindak sebagai satu vektor tunggal [32]. Berikut adalah desain dari vektor 5 dimensi pada persamaan (2.1).

$$(x, y, S \cos H, S \sin H, V)^T \quad (2.1)$$

Setiap komponen vektor memiliki perilaku yang berbeda. Koordinat posisi bersifat kontinyu, dan *band* lainnya. Model warna HSV bersifat diskrit atau berserakan. Untuk mencegah satu fitur mendominasi pada perhitungan jarak *euclidean*, maka komponen vektor 5 dimensi harus dinormalisasi [32].

2.2.3 Sistem Warna

Ide dasar menggunakan model warna *hue*, *saturation* dan *value* (HSV) adalah toleransi terhadap perubahan cahaya. *Hue* mewakili nilai warna yang berbeda (yaitu merah, hijau, dan Biru dan warnanya bermacam-macam di antaranya). HSV membawa nilai ini ke atas, sehingga akan meningkatkan warna dan menurunkan nilai *value*. Model HSV akhirnya memberi warna abu-abu. *Value* adalah kecerahan yang bisa memberi pencahayaan lebih pada warnanya [31].

2.2.4 Normalisasi Fitur

Vektor hasil ekstraksi fitur harus dinormalisasi untuk mencegah satu fitur mendominasi dalam perhitungan metrik jarak *euclidean*. Sebagai contoh, $j = 5$ adalah nilai dimensi dari vektor x_i di mana $x_i = (x_1, x_2, \dots, x_n)$. Sehingga untuk setiap nilai dimensi j^{th} dari x_i , maka menjadi $x_{ij} = (x_{1j}, x_{2j}, \dots, x_{nj})$, oleh karena itu, j^{th} disebut dimensi dari *mean vector* x . Setelah input data vektor 5 dimensi, kemudian proses normalisasi berlangsung. Komponen input data vektor siap dipekerjakan pada proses segmentasi. Persamaan (2.2), (2.3) dan (2.4) adalah persamaan untuk mencari normalisasi vector [31].

$$\mu_j = \frac{1}{N} \sum_{i=1}^N x_{ij} \quad (2.2)$$

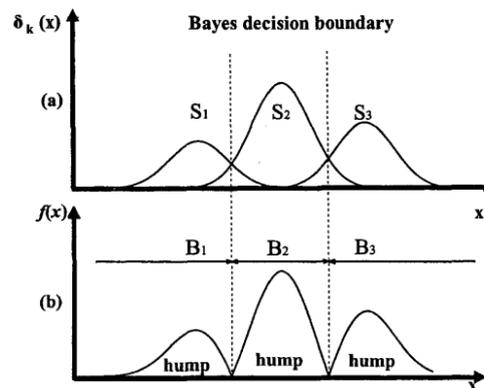
Standar deviasi

$$\sigma_j = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_{ij} - \mu_j)^2} \quad (2.3)$$

Normalisasi

$$Norm_{x_{ij}} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (2.4)$$

2.2.5 Metode LVQ



Gambar 2. 9 Skalar dalam 3 Kelas (a), Ilustrasi setiap Fungsi $f(x)$ (b) [31]

LVQ berhubungan erat dengan *vector quantization* (VQ) dan SOM. Sementara dasar VQ dan SOM adalah metode pengelompokan dan pembelajaran tanpa diawasi atau *unsupervised learning*. Sedangkan LVQ merupakan metode yang diawasi atau *supervised learning*, tidak seperti SOM, LVQ adalah tanpa struktur topologi. LVQ hanya menyediakannya informasi masing-masing neuron, bukan melestarikan struktur topologi [31].

Tujuan LVQ adalah mengoptimalkan daerah kelas optimal atau pola statistik di ruang data masukan. Dengan demikian, biasanya dibahas dalam kerangka kerja teori bayes tentang probabilitas [31].

VQ klasik cenderung mendekati $p(x)$ sebagai fungsi kerapatan probabilitas x dengan membentuk sebuah kuantisasi aproksimasi. X adalah input data vektor $x \in \mathcal{R}^n$ digunakan sebagai *codebook vector* dengan jumlah terbatas $m_i \in \mathcal{R}^n, i = 1, 2, \dots, N$ untuk menemukan *codebook vector* dari m_c, x adalah input ruang data ketika menggunakan metrik *euclidean distance* [31].

Dalam algoritma LVQ, bukan $p(x)$ sebuah aproksimasi untuk fungsi kepadatan lain $f(x)$ oleh VQ dapat dipertimbangkan. Gambar 2.9 mengilustrasikan bentuk $f(x)$ dengan skalar x yang terdiri dari 3 kelas S_1, S_2 dan S_3 pada sumbu x dan masing-masing distribusi $p(x|x \in S_k) P(S_k)$ sebagai sumbu y . Pada Gambar 2.9 (a), batas bayesian yang optimal dimana $f(x) > 0$. Ditandai dengan garis putus-putus, dan $f(x) > 0$ ada pada Gambar 2.9 (b) di tiga "gundukan". VQ akan mendefinisikan perbatasan bayesian dengan bebas. VQ keakuratannya bagus, tergantung dari jumlah *codebook vektor* yang digunakan. Oleh karena itu, jika

$P(S_k)$ menjadi probabilitas *learning* kelas S_k dengan perbatasan bayesian B_k dan pertimbangkan probabilitas sebagai $P(S_r)$ lainnya, berikut adalah algoritma LVQ 1 [31]:

Jika $x(t) \in B_k$ dan $x(t) \in S_r$, (x dan m_c , di kelas yang sama), selanjutnya

$$m_c(t+1) = m_c(t) + \alpha(t)[x(t) - m_c(t)] \quad (2.5)$$

Jika $x(t) \in B_k$ dan $x(t) \in S_r$, (x dan m_c , di kelas yang berbeda), selanjutnya

$$m_c(t+1) = m_c(t) - \alpha(t)[x(t) - m_c(t)] \quad (2.6)$$

Sebaliknya

$$m_i(t+1) = m_i(t) \text{ untuk } i \neq c \quad (2.7)$$

Jika label kelas dari *codebook vector* m_c , (*codebook vector winner*) sesuai dengan label kelas. Contoh pelatihan x , maka *codebook vector* dipindahkan menuju x . Jika tidak, m_c terhindar dari input sampel, dimana $0 < \alpha(t) < 1$, sesuai hasil pembelajarannya [31].

Algoritma LVQ 1 dapat diperluas sedemikian dengan menilai tingkat penghasilan yang berbeda $\alpha(t)$ ditugaskan untuk masing-masing m_c . Dengan demikian, proses pembelajaran dari persamaan (2.7) dapat dinyatakan sebagai [31]:

$$m_c(t+1) = [1 - s(t)\alpha_c(t)] m_c(t) + s(t)\alpha(t)x(t) \quad (2.8)$$

Dimana $s(t) = +1$ jika klasifikasi benar, dan $s(t) = -1$ jika klasifikasi salah. Nilai "optimal" dari konvergensi persamaan cepat (2.8) ditentukan oleh rekursi sebagai berikut [31]:

$$\alpha(t) = \frac{\alpha(t-1)}{1+s(t)\alpha(t-1)} \quad (2.9)$$

2.2.6 Metrik Jarak *Minkowski*

$$d(C_i, C_j) = \left(\frac{\sum_{k=1}^n W_r^K |d(C_i, C_j)|}{\sum_{k=1}^n W_r^K} \right) \quad (2.10)$$

Tabel 2. 1 Keterangan Simbol Persamaan Jarak *Minkowski* [39]

Parameter	Keterangan
$d(C_i, C_j)$	Nilai kesamaan antara kasus C_j dan kasus C_i
C_i	Kasus baru
C_j	Kasus lama
N	Jumlah atribut dalam setiap kasus
K	Atribut individu, antara 1 s / d n
W	Bobot yang diberikan untuk atribut ke k
R	Faktor <i>minkowski</i> (bilangan bulat positif)

Persamaan (2.10) adalah rumus *weighted minkowski*. Nilai parameter r adalah angka positif $r \geq 1$, (antara 1 hingga tak terhingga). Jika $r = 1$ dikenal sebagai metrik jarak *manhattan/city block*, jika $r = 2$ dikenal sebagai jarak *euclidean* dan jika $r =$ tak terhingga (*infinity*) dikenal sebagai metrik jarak *chebyshev* [39].

2.2.7 Metrik Jarak *Euclidean*

Hal ini juga disebut jarak L_2 . Jika $u = (x_1, y_1)$ dan $v = (x_2, y_2)$ adalah dua titik, maka jarak *euclidean* antara u dan v [42].

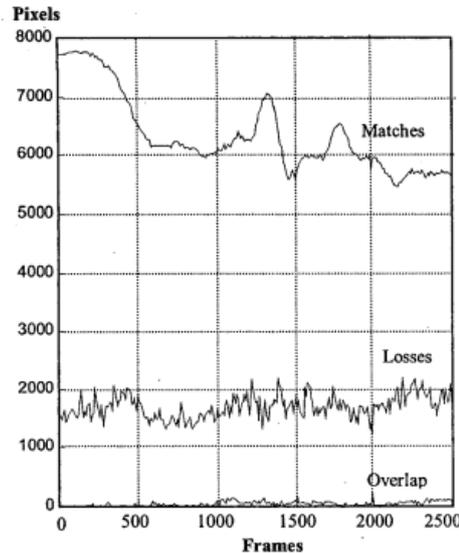
$$EU(u, v) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (2.11)$$

Alih-alih dua dimensi, jika poin memiliki ukuran n dimensi, seperti $a = (x_1, x_2, \dots, x_n)$ dan $b = (y_1, y_2, \dots, y_n)$ maka, persamaan (2.11) dapat digeneralisasikan oleh jarak *euclidean* untuk menentukan antara a dan b seperti persamaan (2.12) dan (2.13) [42].

$$EU(u, v) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (2.12)$$

$$EU(u, v) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.13)$$

2.2.8 Evaluasi Video Object Extraction

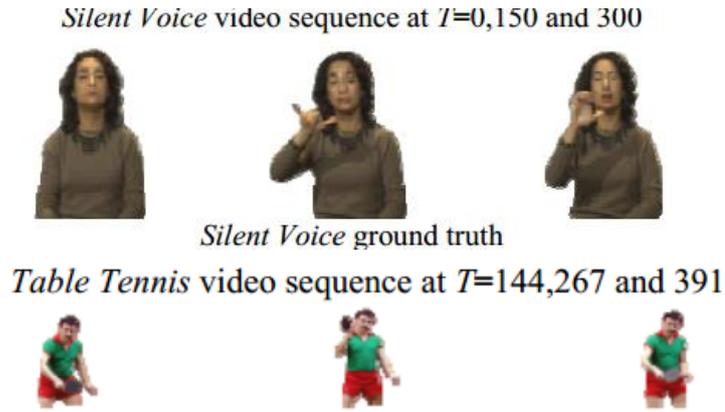


Gambar 2. 10 Perbandingan *Matches*, *Losses* dan *Overlap* [31]

Sampai saat ini, sangat sulit untuk mengevaluasi kualitas segmentasi gerakan oleh VQ dan LVQ. Biasanya hanya mata manusia yang bisa mengevaluasi kualitas segmentasi gerakan. Dalam percobaan segmentasi gerakan manusia ini, kinerja sistem telah diuji untuk mendeteksi video. Evaluasi kinerja dilakukan dengan membandingkan proses segmentasi gerakan manual ke hasil segmentasi sistem. Segmentasi manual dilakukan pada setiap frame urutan video. Kemudian dibandingkan dengan frame yang nomor sama dari hasil segmentasi gerakan. Evaluasi kinerja untuk menghitung 3 kriteria: *matches*, *losses* and *overlap pixel areas* antara hasil segmentasi otomatis dengan segmentasi manual seperti hasil pada Gambar 2.10. Persamaan untuk evaluasi *matches* pada persamaan (2.14), *losses* pada persamaan (2.15), *overlap pixel areas* pada persamaan (2.16) dan *error* pada persamaan (2.17). Keterangan untuk parameter R_s hasil segmentasi otomatis dengan LVQ. Sedangkan parameter R_m hasil segmentasi manual oleh manusia [31].

$$Matches = R_s \cap R_m \quad (2.14)$$

$$Losses = R_m - (R_s \cap R_m) \quad (2.15)$$



Gambar 2. 11 Contoh Data *Ground Truth* untuk Evaluasi VOE [35]

$$Overlap = R_s - (R_s \cap R_m) \quad (2.16)$$

$$Error \% = \frac{losses + losses}{R_m} \times 100 \quad (2.17)$$

Penelitian evaluasi *video object extraction* selanjutnya, membandingkan hasil ekstraksi algoritma yang diusulkan dengan ekstraksi manual oleh manusia (data *ground truth*) pada Gambar 2.11. Definisi metrik kesalahan ini seharusnya kompatibel dengan evaluasi penglihatan manusia. Kesalahan rendah harus menghasilkan hasil yang baik untuk dilihat oleh mata manusia. Kesalahan ekstraksi untuk setiap frame ditentukan oleh rumus *Error* dan *Mean_Error*. Rumus *Mean_Error* untuk mencari rata-rata kesalahan dalam temporal segmen saat ini [35].

Persamaan *Error* pada persamaan (2.18) untuk *Error* dan persamaan (2.19) untuk *Mean_Error*. Keterangan untuk *sum of misclassified pixels* adalah jumlah *pixel* segmentasi yang salah. Sedangkan *sum of total pixels in a frame* adalah jumlah seluruh *pixel* pada frame [35].

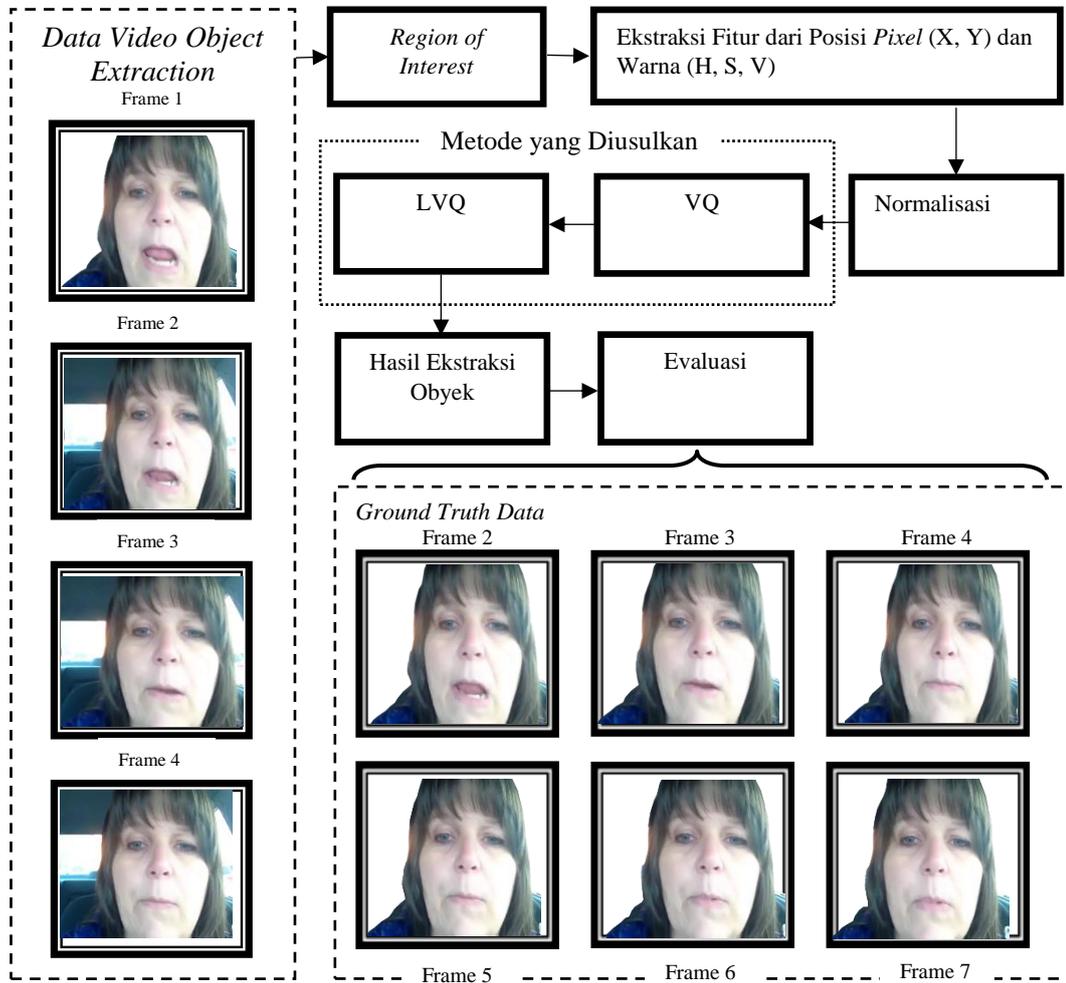
$$Error = \frac{sum\ of\ misclassified\ pixels}{sum\ of\ total\ pixels\ in\ a\ frame} \times 100 \quad (2.18)$$

$$Mean_error = \frac{sum\ of\ error}{number\ of\ frame} \times 100 \quad (2.19)$$

Halaman ini sengaja dikosongkan

BAB 3

METODOLOGI PENELITIAN



Gambar 3. 1 Sistem *Video Object Extraction* Berbasis LVQ Menggunakan Metrik Jarak *Minkowski* dan *Euclidean*

Gambar 3.1 adalah sistem *video object extraction* yang diusulkan. Sistem terbagi menjadi tujuh bagian proses yang terdiri dari *data video object extraction*, *region of interest*, ekstraksi fitur terdiri dari posisi *pixel* dan warna, normalisasi, metode LVQ yang diusulkan, hasil ekstraksi obyek dan evaluasi. Metode LVQ berisi mengenai LVQ untuk klasifikasi dan *vector quantization* (VQ) untuk klustering. Sistem VQ berisi usulan metrik jarak *minkowski* dan *euclidean*. Metrik jarak VQ dengan *minkowski* adalah pembaharuan dari penelitian sebelumnya yang menggunakan *euclidean*.

3.1 Data Video Object Extraction

Data penelitian terdiri dari *video minor stroke* dan *claire*. Sumber *video minor stroke* berasal dari youtube, sedangkan *claire* dari penelitian *video object extraction* sebelumnya. Jenis video yang digunakan dalam penelitian adalah MPEG-4. Video diekstrak menjadi lima puluh frame pada penelitian ini. Frame pertama sebagai acuan untuk *video object extraction* semi otomatis. Ekstraksi frame pertama dengan bantuan manusia untuk mengidentifikasi *object* yang bermakna *minor stroke* dan *claire*. Ekstraksi frame kedua sampai frame terakhir secara otomatis dengan metode LVQ yang diusulkan pada penelitian ini.

3.2 Region of Interest (ROI)

Region of Interest (ROI) bagian proses dalam *pre-processing* sistem *video object extraction* (VOE). Proses ini digunakan untuk menabur *codebook vector* pada wilayah tepi obyek saja. Tujuannya ialah untuk mempercepat waktu komputasi. Bila proses ROI dihilangkan akan memperlambat sistem. Karena proses penaburan *codebook vector* akan ditabur disemua wilayah, baik di *background* maupun *foreground*. ROI bekerja pada semua frame dari awal sampai akhir frame.

3.3 Ekstraksi Fitur

Ekstraksi fitur bagian dari proses pengambilan parameter yang unik dari hasil *region of interest*. Tujuan untuk ekstraksi fitur untuk meningkatkan performa akurasi dalam *video object extraction* dan menghemat waktu komputasi. Ekstraksi fitur yang diusulkan dalam sistem ini terdiri dari posisi koordinat *pixel* dan informasi warna pada frame video. Fitur posisi koordinat terdiri dari x dan y. Sedangkan fitur informasi warna terdiri *red*, *green* dan *blue* (RGB).

Hasil ekstraksi fitur informasi warna masih perlu proses konversi RGB ke HSV. Karena fitur informasi warna *red*, *green* dan *blue* (RGB) bila ada perubahan intensitas cahaya, maka nilainya akan cepat berubah. Sedangkan hasil konversi warna dari RGB ke *hue*, *saturation* dan *value* (HSV) akan lebih stabil bila terdapat perubahan intensitas cahaya.

Persamaan (3.1), (3.2) dan (3.3) adalah untuk mencari konversi dari RGB ke HSV. Parameter yang dipergunakan dalam persamaan adalah $R=red$, $G=green$, $B=blue$, $H=hue$, $S=saturation$ dan $V=value$. Persamaan (3.1) merupakan formula untuk mencari nilai $V=value$. Nilai keluaran dari $value$ berkisar dari 0 sampai 255. Nilai V akan berubah bila terdapat perubahan intensitas cahaya. Persamaan (3.2) digunakan untuk mencari nilai $S=saturation$. Bila nilai saturasi sedang, maka warna meningkat. Sebaliknya jika nilai $saturation$ menurun, maka warna turun berubah menjadi abu-abu. Nilai S tidak akan berubah jika terjadi perubahan intensitas cahaya. Hasil keluaran nilai S berkisar 0 sampai 1. Persamaan (3.3) adalah untuk mencari nilai $H=hue$. Konversi nilai RGB ke hue terdapat empat kondisi. Pertama bila kondisi nilai $value$ sama dengan $reed$ dan $green$ lebih dari $value$. Kondisi ke dua bila nilai $green$ sama dengan nilai $value$. Ketiga bila kondisi $blue$ sama dengan $value$. Kondisi keempat bila nilai $value$ sama dengan nilai $reed$ dan nilai $green$ lebih kecil dari $blue$. Hasil keluaran nilai H adalah 0^0 sampai 360^0 . Nilai H merupakan representasi dari warna $reed$, $green$ dan $blue$ (RGB).

$$V = \max \{R, G, B\} \quad V \in [0, 255] \quad (3.1)$$

$$S = \frac{V - \min\{R, G, B\}}{V} \quad S \in [0, 1] \quad (3.2)$$

$$H = \left\{ \begin{array}{l} \frac{G-B}{V - \min\{R, G, B\}} \cdot 60^0, \text{ if } V = R \text{ and } G \geq B \\ \left(\frac{B-R}{V - \min\{R, G, B\}} + 2 \right) \cdot 60^0, \text{ if } G = V \\ \left(\frac{R-G}{V - \min\{R, G, B\}} + 4 \right) \cdot 60^0, \text{ if } B = V \\ \left(\frac{R-B}{V - \min\{R, G, B\}} + 4 \right) \cdot 60^0, \text{ if } V = R \text{ and } G < B \end{array} \right\} \quad H \in [0^0, 360^0] \quad (3.3)$$

$$K * (x, y, S \cos H, S \sin H, V)^T \quad (3.4)$$

Persamaan (3.4) merupakan fitur lima dimensi terdiri dari posisi koordinat $pixel$ dan informasi warna yang telah melewati konversi RGB ke HSV. Nilai S

dikalikan dengan $S \cos H$ dan $S \cos H$ untuk model warna HSV geometri. Jenis HSV menggunakan tipe koordinat polar. Hasil dari ekstraksi fitur kemudian dikalikan konstanta (K) dengan variasi 0.1 sampai 5. Nilai K berfungsi untuk mengejar perpindahan warna pada frame.

3.1. Normalisasi

Hasil ekstraksi fitur yang terdiri dari fitur posisi koordinat *pixel* dan informasi warna HSV masih belum standar ukurannya. Karena fitur posisi koordinat *pixel* dengan informasi warna berbeda satuannya. Oleh karena itu, fitur lima dimensi memerlukan proses normalisasi. Tujuan dari *pre-processing* normalisasi adalah untuk menstandarkan beberapa fitur kedalam satuan yang sama. Normalisasi adalah proses untuk menstandarkan ukuran pada bagian fitur.

$$\mu_j = \frac{1}{N} \sum_{i=1}^N x_{ij} \quad (3.5)$$

$$\sigma_j = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_{ij} - \mu_j)^2} \quad (3.6)$$

$$Norm_x_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (3.7)$$

Proses normalisasi melewati persamaan (3.5), (3.6) dan (3.7). Adapun parameter yang dipergunakan dalam persamaan tersebut adalah j yang bernilai 1 sampai 5. Sedangkan nilai parameter i berjumlah total dari pixel pada frame tersebut. Persamaan (3.5) digunakan untuk mencari rata-rata setiap fitur dan *pixel*. Parameter N adalah nilai tertinggi pada fitur yang dituju. Sedangkan x_{ij} merupakan fitur yang terdapat di tiap *pixel*. Persamaan (3.6) digunakan untuk mencari sudut deviasi dari rata-rata. Untuk persamaan (3.7) adalah proses terakhir untuk normalisasi. Cara kerja proses normalisasi ialah tiap nilai fitur dikurangi dengan nilai rata-rata, kemudian dibagi dengan sudut deviasi. Hasil dari normalisasi akan diulang pada fitur berikutnya dan berhenti pada *pixel* terakhir. Selain itu, tujuan dari proses *pre-processing* normalisasi untuk mencegah satu fitur untuk mendominasi perhitungan pada pengukuran metrik.

3.4 Metode LVQ yang Diusulkan

LVQ yang diusulkan dalam penelitian ini terdiri dari proses *vector quantization* (VQ) dan *learning vector quantization* (LVQ). *Vector quantization* (VQ) bekerja secara *unsupervised learning*. Sedangkan LVQ bekerja *supervised learning*. Sistem ini diusulkan karena proses *unsupervised* pada VQ dapat melacak obyek yang bergerak pada video. Proses LVQ dapat maksimal setelah data video melewati normalisasi. Untuk dapat memisahkan proses *foreground* dengan *background* secara otomatis, maka memerlukan frame pertama sebagai referensi. Dengan bantuan identifikasi obyek *minor stroke* pada frame pertama oleh batuan manusia, maka pada frame berikutnya dapat diekstrak obyek secara otomatis. Berikutnya merupakan sistem LVQ yang diusulkan terdiri dari VQ dan LVQ.

Cara kerja sistem LVQ ketika frame pertama ditabur *codebook* secara acak. Kemudian proses VQ berjalan untuk memisahkan *foreground* dengan *background* tanpa dilatih. VQ memisahkan obyek dengan cara mengukur *codebook vector* yang terdekat dengan persamaan metrik yang diusulkan. Hasil dari VQ digunakan sebagai data training untuk memprediksi obyek yang diekstrak pada frame berikutnya. Proses prediksi pada frame berikutnya menggunakan LVQ. Proses VQ dan LVQ berjalan bergantian sampai frame terakhir selesai diekstrak obyeknya.

3.4.1 *Vector Quantization* untuk Klustering

Vector quantization (VQ) merupakan bagian dari *self organizing maps* (SOM) yang bekerja secara *unsupervised learning*. VQ digunakan dalam sistem ekstraksi obyek *minor stroke* yang diusulkan pada penelitian ini. Karena hasil VQ digunakan untuk data training pada proses LVQ. VQ dapat memisahkan *object* ekstraksi secara otomatis dengan cara mengukur kedekatan *codebook vector* pada dua kelas tersebut. Persamaan 3.8 dan 3.9 adalah metrik untuk mengukur kedekatan fitur dengan kelas *codebook vector* pada *object* atau non *object*.

$$m_c = \min\{\|x - m_i\|\} \quad (3.8)$$

$$m_c = \sqrt[p]{\sum_{j=1}^N |x - m_i|^p} \quad (3.9)$$

Persamaan (3.8) merupakan metrik *euclidean distance* yang digunakan dalam sistem *video object extraction* sebelumnya. Parameter yang dipergunakan dalam persamaan (3.8) seperti m_i adalah *codebook vector*. Sedangkan x adalah nilai fitur dari *video object extraction*. Namun, hasil akurasi yang diperoleh di bawah tujuh puluh persen. Oleh karena itu, VOE memerlukan proses perbaikan metrik pada VQ. Metrik yang diusulkan pada penelitian *video object extraction* menggunakan *minkowski distance* seperti pada persamaan 3.9. Parameter N adalah jumlah total fitur yang diproses, m_i adalah *codebook vector*, x adalah fitur tiap *pixel* dan parameter p adalah konstanta pangkat pada *minkowski* untuk mencari jarak terdekat yang optimal. Fitur x , x_{tj} , m_i dan x_{tj} berisi fitur posisi koordinat *pixel* dan informasi warna HSV pada persamaan (3.4). M_c pada persamaan (3.8) dan (3.9) adalah *codebook winner* untuk mengukur jarak terdekat.

3.4.2 LVQ untuk Klasifikasi

$$m_c(t + 1) = m_c(t) + \alpha(t)[x(t) - m_c(t)] \quad (3.10)$$

$$m_c(t + 1) = m_c(t) - \alpha(t)[x(t) - m_c(t)] \quad (3.11)$$

$$\alpha(t) = \frac{\alpha(t-1)}{1+s(t)\alpha(t-1)} \quad (3.12)$$

Persamaan (3.10), (3.11) dan (3.12) digunakan untuk persamaan *learning vector quantization* (LVQ). Persamaan tersebut digunakan untuk memprediksi *object minor stroke* secara *supervised learning* pada frame kedua sampai terakhir. Dengan cara hasil keluaran *codebook winner* m_c untuk data training LVQ. Hasil keluaran dari persamaan LVQ adalah sama kelas (*foreground*) dan tidak sama (*background*). Jika nilai keluaran m_c sama x maka α positif pada persamaan (3.10). Sebaliknya jika keluaran m_c tidak sama x maka α negatif pada persamaan (3.11).



Gambar 3. 2 Harapan Hasil Ekstraksi *Video Object Extraction*

Persamaan (3.12) digunakan untuk mengoptimalkan *learning rate*. Nilai α berkisar 0 sampai 1. Variabel s bernilai +1 jika klasifikasi benar dan sebaliknya klasifikasi salah bernilai -1. Paramater t merupakan *step index* untuk *learning codebook vector*.

3.5 Hasil Ekstraksi Obyek

Sistem yang diusulkan ini menghasilkan *foreground* dengan *background* yang terpisah secara otomatis. *Foreground* yang dihasilkan adalah *object* orang yang terkena *minor stroke*. Sedangkan *background* adalah warna putih pada frame video *minor stroke*. Hasil ekstraksi object yang dihasilkan merupakan proses dari *video object extraction*. Hasil ekstraksi obyek yang diharapkan seperti pada Gambar 3.2.

3.6 Evaluasi

Evaluasi pada metodologi penelitian digunakan untuk mengukur kinerja hasil sistem yang diusulkan. Karena hasil *video object extraction* yang dihasilkan oleh sistem masih terdapat kesalahan. Sehingga untuk penelitian mendatang diharapkan lebih baik lagi dari penelitian sebelumnya.

Evaluasi pada proses *minor stroke* untuk membandingkan hasil sistem *video object extraction* dengan *data ground truth*. Data pembanding dipisahkan secara *manual* antara *foreground* dan *background* dengan bantuan manusia yang disebut *data ground truth*.

Persamaan (3.14) dan (3.16) digunakan untuk mengukur evaluasi pada sistem *video object extraction* yang diusulkan. Persamaan (3.14) digunakan untuk mengukur akurasi *mean* pada proses *unsupervised* dan *supervised learning* dari *video object extraction*. Proses perhitungan akurasi setiap frame dimulai dari persamaan (3.13) dengan cara menjumlah *pixel* dari hasil segmentasi pada parameter $I_{sg_{ij}}$ dibandingkan dengan *pixel* pada *data ground truth* dengan parameter $I_{gd_{ij}}$. Jumlah hasil *pixel* yang benar pada perbandingan kedua data tersebut, kemudian dibagi dengan jumlah total *pixel* yang berada dalam frame ($h.w$). Hasil pembagian jumlah kebenaran *pixel* dan total *pixel* pada frame kemudian dikalikan dengan seratus persen. Untuk menghitung akurasi *mean* dengan menjumlah akurasi setiap frame $Akurasi_f$ pada persamaan 3.14 dibagi dengan jumlah total frame fn .

$$Akurasi_f = \frac{\sum_{i=1}^h \sum_{j=1}^w (I_{gd_{ij}} \cdot I_{sg_{ij}})}{(h.w)} \times 100 \quad (3.13)$$

$$Akurasi\ Mean = \frac{\sum_{f=1}^{fn} Akurasi_f}{fn} \quad (3.14)$$

$$I_{sg_m_{ij}} = med \left(\begin{array}{c} I_{sg_{ij}}[m, n-1], I_{sg_{ij}}[m, n], I_{sg_{ij}}[m, n+1], \\ I_{sg_{ij}}[m-1, n], I_{sg_{ij}}[m+1, n] \end{array} \right) \quad (3.15)$$

$$Akurasi\ Median\ Filter = \frac{\sum_{i=1}^h \sum_{j=1}^w (I_{gd_{ij}} \cdot I_{sg_m_{ij}})}{(h.w)} \times 100 \quad (3.16)$$

Persamaan (3.16) digunakan untuk mengukur performa dari hasil *supervised learning* untuk akurasi *median filter*. Proses pengukuran akurasi *median filter* melalui persamaan 3.15 dengan cara operasi *cross median filter 3x3 window*. Parameter m dan n digunakan untuk mengeliling nilai median. Nilai m dan n pada evaluasi ini telah diset sebesar sembilan. Parameter $I_{sg_m_{ij}}$ untuk menampung operasi *cross median filter* dari hasil segmentasi. Persamaan 3.16 digunakan untuk

mencari akurasi *median filter* dengan cara membandingkan *pixel* pada data *ground truth* $I_{gd_{ij}}$ dengan *pixel* pada operasi *cross median filter* $I_{sg_{m_{ij}}}$. Hasil kebenaran *pixel median filter* dibagi dengan jumlah *pixel* yang berada dalam frame dan dikalikan seratus persen. Persamaan akurasi *median filter* digunakan dalam proses *supervised learning* pada sistem *video object extraction* yang diusulkan. Karena pengukuran akurasi menggunakan persamaan *median filter* tidak terpengaruh oleh data yang banyak pada *pixel* frame.

Halaman ini sengaja dikosongkan

BAB 4

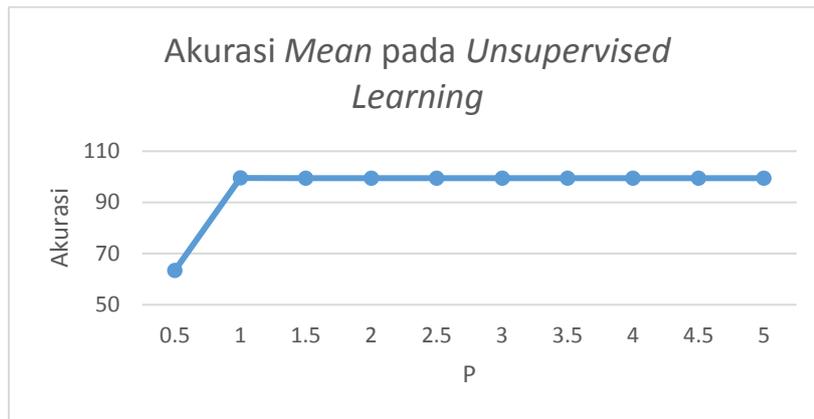
HASIL DAN PEMBAHASAN

Pada bagian ini, penulis melakukan pengujian sistem yang diusulkan pada *video object extraction* berbasis LVQ menggunakan metrik jarak *minkowski* dan *euclidean*. Tujuan dari pengujian ini untuk menyelesaikan permasalahan dan tujuan yang telah diuraikan pada BAB I. Permasalahan *video object extraction* pada kasus *minor stroke* adalah hasil akurasi yang telah dikerjakan masih kurang dari 70%. Untuk memperbaiki akurasi dari *video object extraction*, maka memerlukan tahapan perbaikan sistem dan pengujian. Tahapan yang diusulkan oleh penulis meliputi optimasi parameter P pada metrik *minkowski distance*, hasil *minor stroke extraction* dengan *minkowski distance*, hasil akurasi *minor stroke extraction* dengan *minkowski distance*, hasil *minor stroke extraction* dengan *euclidean distance*, hasil akurasi *minor stroke extraction* dengan *euclidean distance* dan perbandingan akurasi *minor stroke extraction* dengan *minkowski* dan *euclidean distance*. Penjelasan mengenai tahapan pengujian akan dijelaskan lebih detail pada sub paragraf.

4.1 Optimasi Parameter P pada Metrik *Minkowski Distance* dengan *Minor Stroke*

Tabel 4. 1 Perbandingan Optimasi Akurasi pada *Minor Stroke* dengan Nilai P dan Kecepatan Waktu

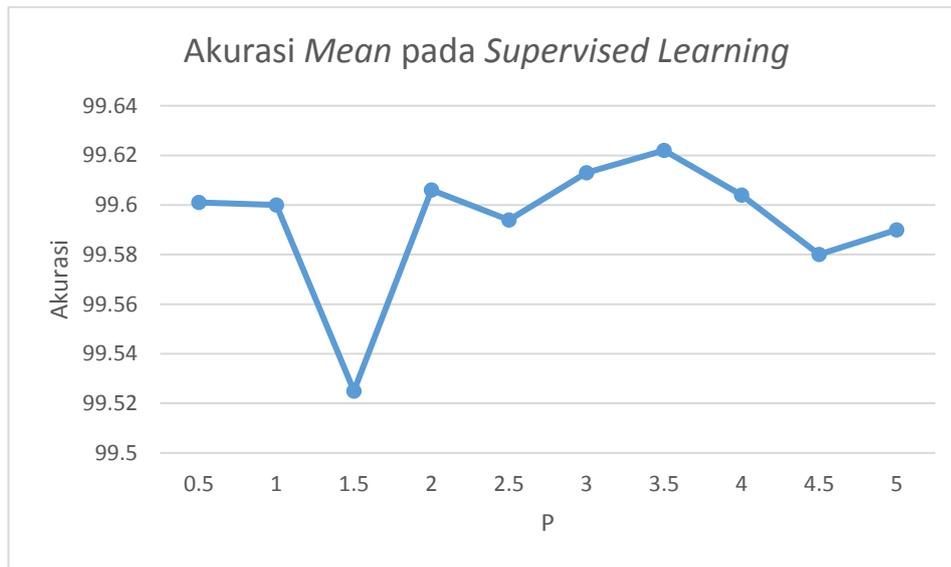
No	Nilai P	Akurasi Mean pada Unsupervised Learning	Akurasi Mean pada Supervised Learning	Akurasi Median pada Supervised Learning	Waktu (detik)
1	0.5	63.40	99.60	99.70	21
2	1.0	99.54	99.60	99.67	11
3	1.5	99.52	99.52	99.68	19
4	2.0	99.50	99.60	99.70	10
5	2.5	99.49	99.59	99.68	19
6	3.0	99.49	99.61	99.70	19
7	3.5	99.49	99.62	99.69	23
8	4.0	99.49	99.60	99.68	21
9	4.5	99.47	99.58	99.67	21
10	5.0	99.47	99.59	99.68	21



Gambar 4. 1 Akurasi Mean pada Proses *Minor Stroke Unsupervised Learning* dengan Nilai P

Metrik *minkowski distance* terdiri dari beberapa parameter yang perlu diatur supaya hasil akurasi maksimal. Nilai P adalah konstanta pangkat pada *minkowski* untuk mencari jarak terdekat yang optimal. Tujuan dari pengujian dengan memberikan variasi nilai dengan kelipatan 0.5 untuk mencari nilai akurasi maksimal. Pengujian nilai P dengan membandingkan hasil akurasi yang terdiri dari *mean* pada proses *unsupervised learning*, *mean* pada proses *supervised learning* dan *median* pada proses *supervised learning*. Akurasi *mean* diambil dari jumlah total kebenaran *pixel* setiap frame dibagi dengan jumlah total *pixel* pada frame. Sedangkan akurasi *median* diambil dari jumlah hasil *cross median filter* pada setiap frame dibagi jumlah total *pixel* setiap frame. Selain itu, pengujian kecepatan waktu setiap nilai P juga dibandingkan. Hasil perbandingan akurasi dengan nilai P dan waktu pada Tabel 4.1.

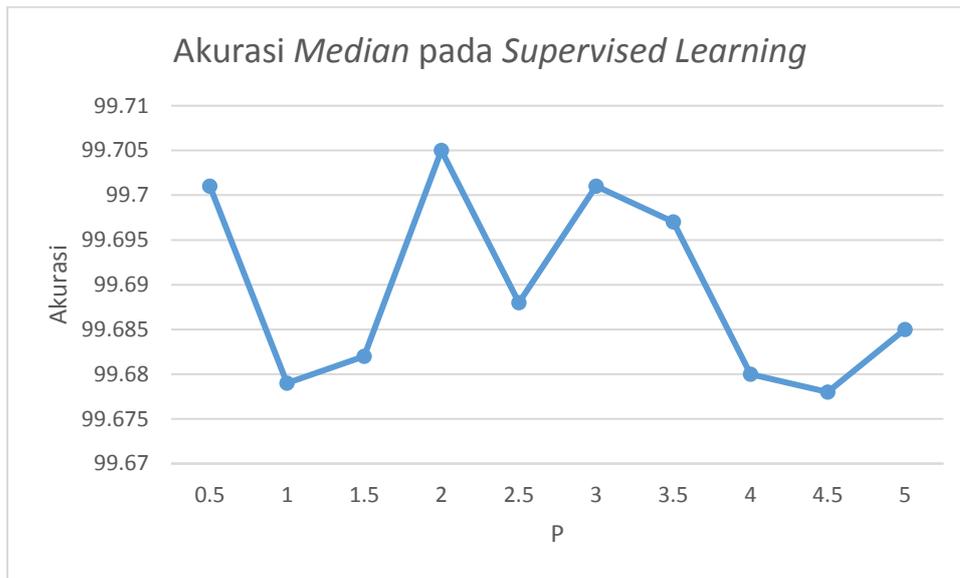
Gambar 4.1 merupakan hasil pengujian akurasi *mean* pada proses *unsupervised learning* dengan variasi nilai P. Untuk standarisasi pengujian nilai P dengan kelipatan 0.5 belum ada. Oleh karena itu, kami mengusulkan pengujian dengan kelipatan nilai P=0.5. Pengujian nilai P pertama menunjukkan bahwa akurasi masih 60 %. Setelah nilai P dinaikan ke angka satu, terlihat bahwa akurasi naik sekitar 90%. Nilai akurasi P=1 sampai P=5 terlihat stabil 90%, hampir mendekati 100%. Akurasi maksimal sebesar 99.49% pada P=2.5. Sedangkan akurasi terendah sebesar 63.40% pada P=0.5. Hasil perbandingan akurasi pada Gambar 4.1 memperlihatkan bahwa variasi nilai P mempengaruhi hasil akurasi *mean* pada proses *unsupervised learning*.



Gambar 4. 2 Akurasi *Mean* pada Proses *Minor Stroke Supervised Learning*

Gambar 4.2 adalah hasil akurasi *mean* pada proses *supervised learning* dengan nilai P. Variasi pengujian dengan nilai P=0.5 sampai P=5. Kelipatan nilai P pada pengujian ini sebesar 0.5. Perbandingan akurasi yang diujikan adalah akurasi *mean* pada proses *supervised learning* dengan variasi nilai P. Hasil memperlihatkan bahwa akurasi yang dihasilkan nilai P pada saat nilai P=0.5 sampai P=5 di atas 99.52%. Rata-rata akurasi *mean* sebesar 99.6%. Pada saat nilai P=1.5, hasil akurasi yang diperoleh sangat rendah sebesar 99.52%. Sedangkan pada saat nilai P=3.5 sebesar 99.62% adalah nilai akurasi tertinggi. Hal ini menunjukkan bahwa variasi nilai P antara 0.5 sampai 5, mempengaruhi hasil akurasi pada proses *supervised learning*.

Gambar 4.3 merupakan akurasi *median* pada proses *supervised learning* dengan Nilai P. Perbandingan antara akurasi *median* pada *supervised learning* dengan variasi nilai P. Kelipatan yang dipergunakan dalam penelitian ini adalah P=0.5. Pengujian untuk mencari nilai maksimal dengan nilai P=0.5 sampai P=5. Hasil yang diperoleh pada saat nilai awal P=0.5 sebesar 99.6%, kemudian mengalami penurunan sebesar 99.52% pada saat nilai P=1.5. Selanjutnya akurasi proses *median* pada *supervised learning* mengalami kenaikan saat nilai P=2 sampai P=4. Kemudian mengalami penurunan pada saat nilai P=4.5 sebesar 99.58% dan naik kembali pada saat P=5. Akurasi maksimal pada proses *supervised learning*

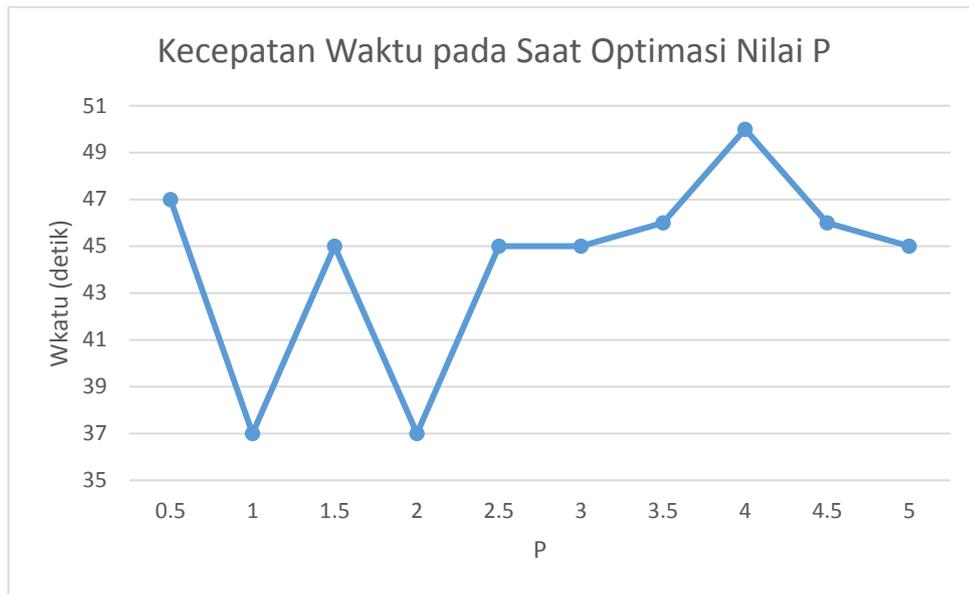


Gambar 4. 3 Akurasi *Median* pada Proses *Minor Stroke Supervised Learning* dengan Nilai P

yang dihasilkan sebesar 99.70% saat nilai P=2. Sedangkan akurasi minimal yang dihasilkan sebesar 99.67% saat nilai P=4.5. Hasil akurasi *median* pada *supervised learning* dapat dipengaruhi oleh variasi nilai P dari 0.5 sampai 5.

Mencari nilai optimal pada Nilai P memerlukan proses pengukuran. Setiap P dari P=0.5 sampai P=5 memerlukan proses waktu yang berbeda untuk menyelesaikannya. Gambar 4.4 adalah hasil pengujian kecepatan waktu saat mencari nilai optimal P. Parameter P mempengaruhi dari cepat atau lamanya proses pengerjaan. Nilai P=0.5 memerlukan proses 47 detik. Kemudian saat nilai P=1 hanya memerlukan waktu 37 detik. Saat nilai P=1.5 mengalami kenaikan waktu sebesar 45 detik. Selanjutnya saat nilai P=2 mengalami penurunan waktu sebesar 37 detik. Nilai P=2 dan P=2.5 mengalami kenaikan yang sama sebesar 45 detik. Kemudian naik 46 detik saat nilai P=3.5. Pengujian nilai P=4 memerlukan waktu 50 detik. Kemudian mengalami penurunan saat nilai P=4.5 sebesar 46 detik. Saat pengujian terakhir P=5 memakan waktu sebesar 45 detik. Waktu terendah pada saat nilai P=1 dan P=2. Sedangkan waktu terlama untuk memproses sistem saat P=4. Jadi untuk perubahan nilai P mempengaruhi waktu penyelesaian.

Gambar 4.1 mempunyai akurasi *mean* terbaik saat nilai P=1 sebesar 99.54%. Sedangkan akurasi *mean* terendah sebesar 99.47% pada saat nilai P=5. Hasil akurasi *mean* terbaik saat nilai P=1. Karena pangkat satu dari nilai P yang



Gambar 4. 4 Kecepatan Waktu saat Optimasi Nilai P pada *Minor Stroke*

tidak mempengaruhi dari selisi nilai pada saat pengukuran jarak *codebook vector* dengan fitur. Nilai akurasi terendah saat $P=5$, hal ini membuktikan bahwa semakin tinggi nilai pangkat dari P tidak akan mempengaruhi kenaikan akurasi.

Gambar 4.2 saat nilai $P=3.5$ adalah maksimal karena saat pengukuran jarak pada proses *supervised learning* terpengaruh oleh kelipatan nilai P . Sedangkan saat nilai $P=1.5$ adalah minimum disebabkan oleh saat pengukuran metrik *euclidean distance* untuk nilai P bukan kelipatan dari jarak yang diukur.

Gambar 4.3 memiliki akurasi maksimal sebesar 99.70% pada saat nilai $P=2$. Sedangkan akurasi minimal sebesar 99.67% pada saat nilai $P=4.5$. Akurasi maksimal dipengaruhi nilai $P=2$, jika dipangkatkan dan diakarkan pada nilai jarak genap akan maksimal. Sebaliknya jika nilai jarak ganjil akan menurun.

Kecepatan waktu saat mencari nilai akurasi optimal P pada metrik *minkowski distance* mempengaruhi proses *unsupervised* dan *supervised* pada Gambar 4.4. Akurasi maksimal pada proses *mean unsupervised* maksimal dan minimum. Selanjutnya untuk akurasi pada proses *mean supervised learning* maksimal dan minimum. Sedangkan akurasi pada proses *supervised learning* maksimal dan minimum. Jadi semakin tinggi nilai P akan meningkatkan waktu pada saat proses tersebut.

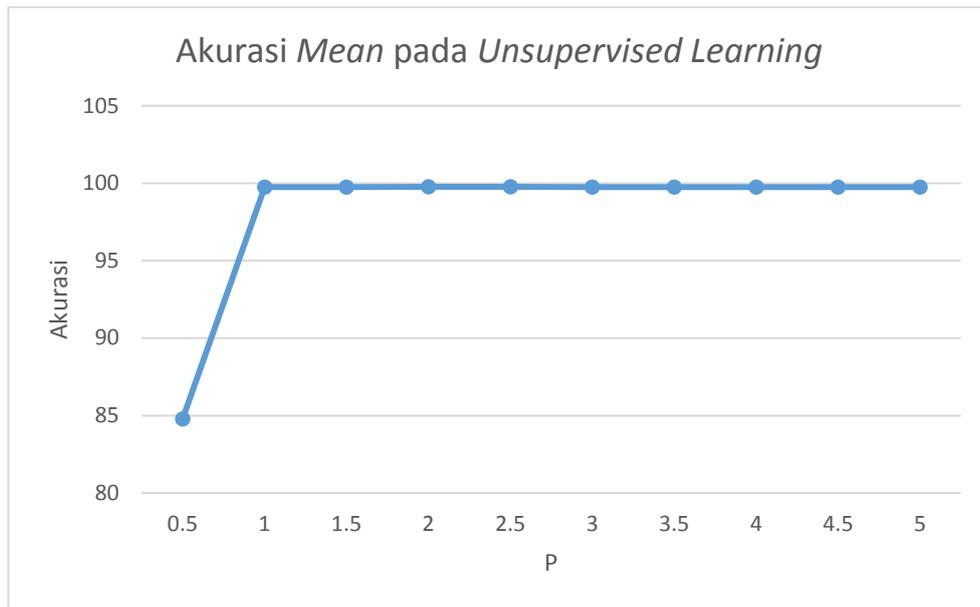
4.2 Optimasi Parameter P pada Metrik *Minkowski Distance* dengan *Claire*

Tabel 4. 2 Perbandingan Optimasi Akurasi pada *claire* dengan Nilai P dan Waktu

No	Nilai P	Akurasi Mean pada Unsupervised Learning	Akurasi Mean pada Supervised Learning	Akurasi Median pada Supervised Learning	Waktu (detik)
1	0.5	84.79	99.76	99.74	10
2	1.0	99.74	99.77	99.75	6
3	1.5	99.75	99.77	99.74	10
4	2.0	99.76	99.78	99.74	6
5	2.5	99.76	99.77	99.74	10
6	3.0	99.75	99.75	99.73	9
7	3.5	99.74	99.77	99.74	10
8	4.0	99.74	99.77	99.74	10
9	4.5	99.74	99.78	99.74	10
10	5.0	99.75	99.77	99.74	9

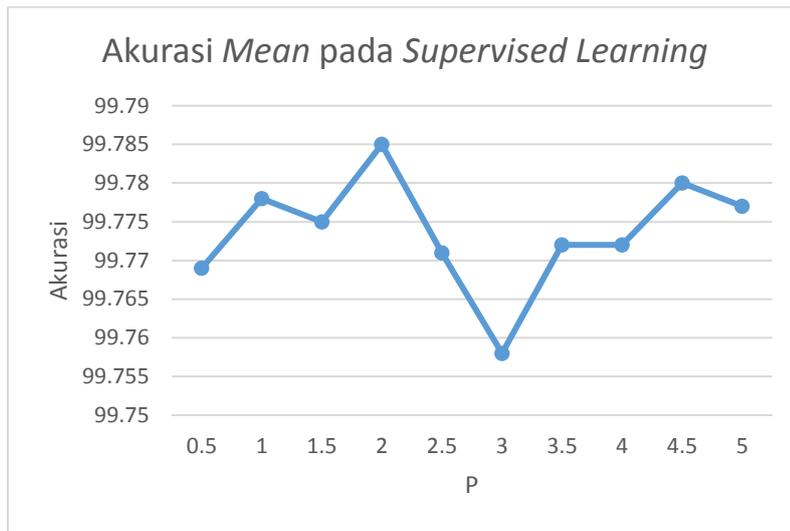
Sebelum pengujian data *claire* dengan metrik *minkowski distance*, maka memerlukan optimasi nilai parameter P. Agar akurasi yang terbaik diperoleh dari pengujian parameter P. Cara percobaan dengan memasukan nilai P=0.5 sampa P=5.0. Setiap perpindahan percobaan dengan kelipatan 0.5. Jumlah percobaan sebanyak 10 kali. Hasil yang diperoleh dari optimasi parameter P adalah akurasi *mean* pada *unsupervised learning*, akurasi *mean* pada *supervised learning*, akurasi *median* pada *supervised learning* dan pengujian kecepatan waktu pada Tabel 4.2.

Gambar 4.5 merupakan hasil akurasi *mean* pada proses *claire unsupervised learning*. Pengujian dengan memasukan parameter P sebanyak sepuluh kali. Dimulai dari P=0.5 sampai P=5 dengan kelipatan 0.5 pada P. Akurasi yang diperoleh saat pengujian P berada di atas 85%. Pada saat P=0.5 hasil yang diperoleh 85% dan saat P=1 sampai P=5 sebesar 100%. Hal ini menunjukkan bahwa nilai P mempengaruhi nilai akurasi pada proses *claire unsupervised learning*. Nilai P yang tepat untuk proses *claire unsupervised learning* dari P=1 sampai P=5. Karena untuk nilai P kurang dari satu akan menghasilkan akurasi kurang maksimal.



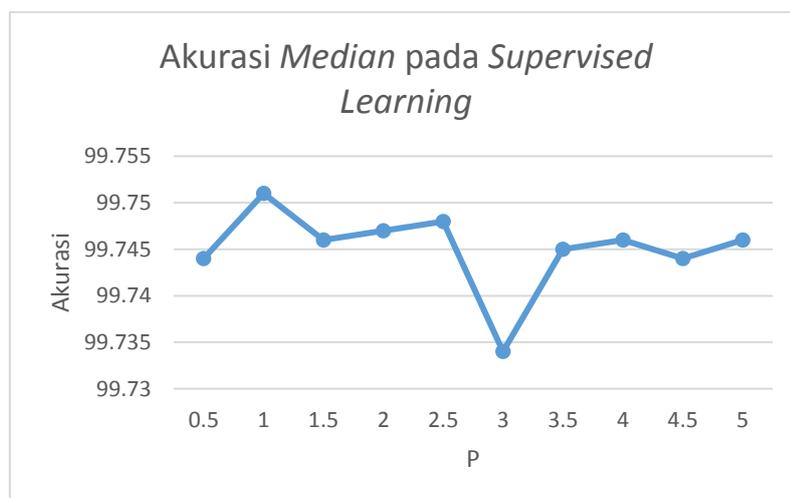
Gambar 4. 5 Akurasi Mean pada Proses *Claire Unsupervised Learning*

Gambar 4.6 adalah akurasi mean pada proses *claire supervised learning*. Perbandingan akurasi mean pada proses *claire supervised learning* dengan parameter P. Pengujian dilakukan dengan merubah nilai parameter dari 0.5 sampai lima. Kelipatan yang dipergunakan adalah 0.5 pada nilai P. Saat pengujian awal nilai P=0.5 diperoleh akurasi sebesar 99.76%. Selanjutnya pada saat nilai P=1 sebesar 99.77%. Akurasi yang diperoleh sama ketika P=1.5 sebesar 99.77%. Nilai akurasi kemudian naik sebesar 99.78% pada P=2. Akurasi saat parameter P=2 merupakan akurasi tertinggi. Pengujian selanjutnya pada saat P=2.5 mengalami penurunan sebesar 99.77%. Dilanjutkan saat P=3 mengalami penurunan yang sangat tinggi sebesar 99.75%. Hal ini dipengaruhi dari nilai parameter P yang kurang tepat pada metrik *vector quantization*. Percobaan selanjutnya saat P=3.5 dan P=4 yang menghasilkan akurasi sama sebesar 99.77%. Kemudian mengalami kenaikan akurasi sebesar 99.78% saat P=4.5. Nilai parameter P terbaik saat P=2 dan P=4.5 sebesar 99.78%. Sedangkan saat P=3 adalah nilai parameter terendah sebesar 99.75%. Hal ini dipengaruhi dari parameter P=2 adalah bilangan genap, jika dipangkatkan dan diakarkan akan menghasilkan bilangan genap.

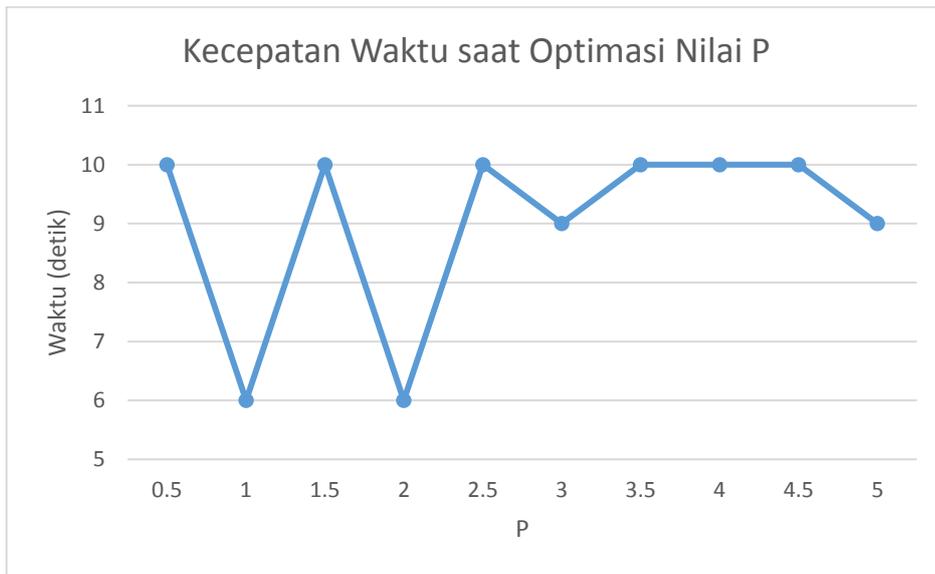


Gambar 4. 6 Akurasi Mean pada Proses Claire Supervised Learning

Hasil akurasi pada proses *claire supervised learning* masih kurang tepat. Oleh karena itu, *claire supervised learning* memerlukan evaluasi untuk data yang banyak seperti *median*. Gambar 4.7 adalah hasil akurasi *median* pada proses *claire supervised learning*. Perbandingan pengujian akurasi dengan nilai parameter P. Setiap nilai P berisi kelipatan 0.5. Nilai parameter P dimulai P=0.5 sampai P=5. Hasil akurasi pada saat awal P=0.5 sebesar 99.74%. Kemudian mengalami kenaikan sebesar 99.75% pada P=1. Percobaan diteruskan dengan parameter P=1.5 sebesar 99.75%.



Gambar 4. 7 Akurasi Median pada Proses Claire Supervised Learning

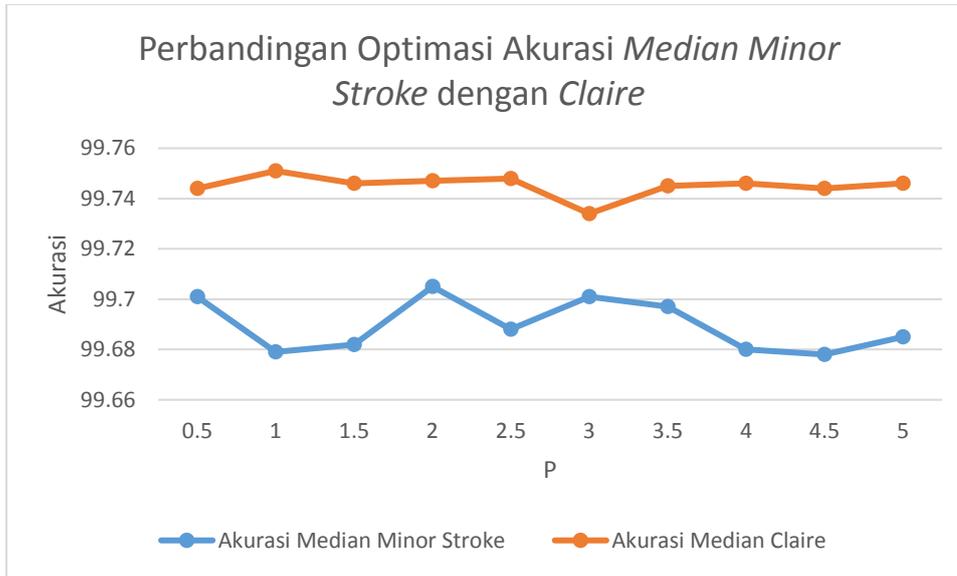


Gambar 4. 8 Kecepatan Waktu saat Optimasi Nilai P pada *Claire*

Kemudian mengalami penurunan sebesar 99.74% saat $P=1.5$. Selanjutnya akurasi sama sebesar 99.74% saat $P=2$. Kembali sama lagi sebesar 99.74% saat $P=2.5$. Pengujian diulang kembali saat $P=3$ mengalami akurasi sama sebesar 99.74%. Kemudian mengalami akurasi sama saat $P=3.5$ sebesar 99.74%. Percobaan selanjutnya saat $P=4.5$ mengalami penurunan sedikit sebesar 99.74% dan kembali sama sebesar 99.74% saat $P=5$. Nilai akurasi tertinggi saat $P=1$ sebesar 99.75% dan terendah sebesar 99.74%. Hal ini dipengaruhi oleh nilai parameter P yang bernilai satu, jika dipangkatkan dan diakar tetap positif.

Pengujian untuk mencari optimasi parameter P memerlukan waktu. Pada Gambar 4.8 adalah hasil pengujian kecepatan waktu data *claire* saat mencari akurasi *mean unsupervised learning*, *mean supervised learning* dan *median supervised learning*. Pengujian kecepatan waktu digunakan untuk mencari waktu yang tercepat atau terlama saat mencari nilai optimasi P . Pengujian kecepatan waktu pada proses *claire* optimasi dimulai dari $P=0.5$ sampai $P=5$. Kelipatan nilai P yang dipergunakan saat perpindahan percobaan sebesar 0.5. Jumlah pengujian sebanyak sepuluh kali.

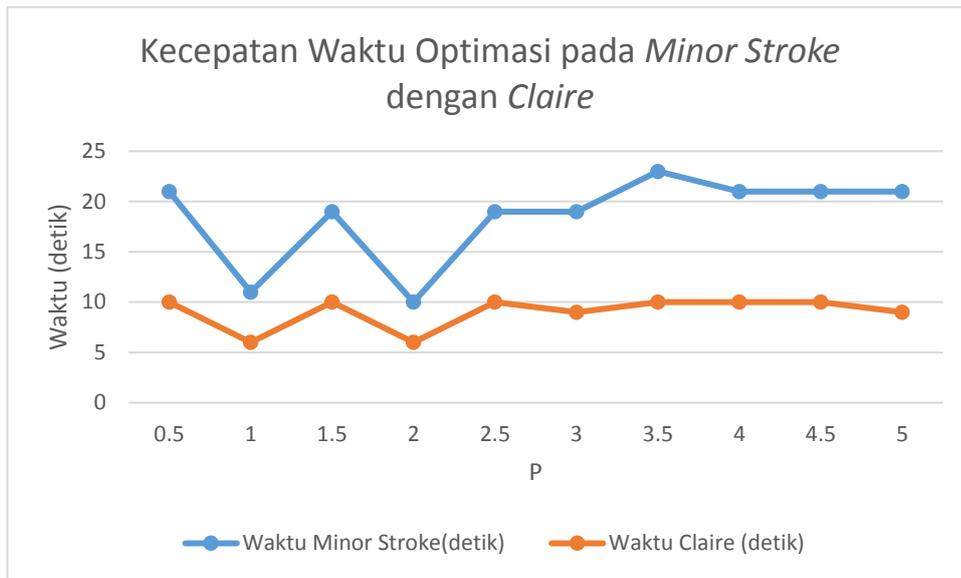
4.3 Perbandingan Optimasi Parameter P pada *Minor Stroke* dengan *Claire*



Gambar 4. 9 Perbandingan Pencarian Optimasi Akurasi *Median Minor Stroke* dengan *Claire* Menggunakan Parameter P

Pengujian saat parameter P=1 dan P=2 memerlukan waktu sebesar 6 detik. Sedangkan saat nilai P=3 dan P=5 memerlukan waktu 9 detik. Selain P yang telah disebutkan sebesar 10 detik. Waktu yang tersepat saat nilai P=1 dan P=2. Sedangkan waktu lama saat P=0.5, P=1.5, P=2.5, P=3.5, P=4, dan P=4.5. Hal ini dipengaruhi oleh nilai 1 dan 2 yang hasilnya positif.

Gambar 4.9 merupakan hasil perbandingan optimasi akurasi untuk mencari P pada Data *minor stroke* dan *claire*. Grafik warna orange adalah hasil akurasi *median* dari data *claire*. Sedangkan warna biru merupakan hasil akurasi *median* dari data *minor stroke*. Perbandingan Optimasi parameter P diambil dari percobaan parameter P dibanding dengan Akurasi. Nilai P dimulai dari P=0.5 samapai P=5. Kelipatan yang dipakai untuk percobaan sebesar 0.5. Jumlah pengujian perbandingan optimasi parameter P sebanyak sepuluh kali. Dari Grafik warna orange menunjukkan akurasi lebih stabil pada semua parameter P daripada warna biru.



Gambar 4. 10 Kecepatan Waktu saat Mencari Optimasi Parameter P pada *Minor Stroke* dengan *Claire*

Hasil akurasi memperlihatkan bahwa akurasi terbaik sebesar 99.70% saat $P=2$ pada *minor stroke*. Sedangkan terendah saat $P=4.5$ sebesar 9.67% pada *minor stroke*. Untuk akurasi terbaik *claire* sebesar 99.75%. Sedangkan akurasi terendah saat $P=3$ sebesar 99.73%. Akurasi data *claire* terbaik dibandingkan dengan *minor stroke*. Hal ini dipengaruhi oleh cara pengambilan data *video minor stroke*. Karena orang yang mengambil terjadi serangan *minor stroke*. Sedangkan data *video claire* diambil oleh pengambil video yang profesional.

4.4 Kecepatan Waktu pada saat Optimasi Paramater P dengan *Minor Stroke* dan *Claire*

Gambar 4.10 merupakan hasil perbandingan pengujian kecepatan waktu saat mencari optimasi akurasi pada *minor stroke* dengan *claire*. Pengujian *minor stroke* dan *claire* dilakukan dengan membandingkan parameter P dan waktu. Percobaan P dimulai dari $P=0.5$ dan berakhir saat $P=5$. Jumlah pengujian P sebanyak sepuluh kali dengan kelipatan $P=0.5$. Warna biru pada grafik adalah hasil pengujian kecepatan waktu pada *minor stroke*. Sedangkan warna orange pada grafik adalah hasil pengujian *claire*. Hasil memperlihatkan bahwa waktu pengujian *claire* lebih cepat daripada *minor stroke* sebesar 6 detik. Hal ini dipengaruhi dari ukuran data dan kerumitan ekstraksi *object* tersebut.

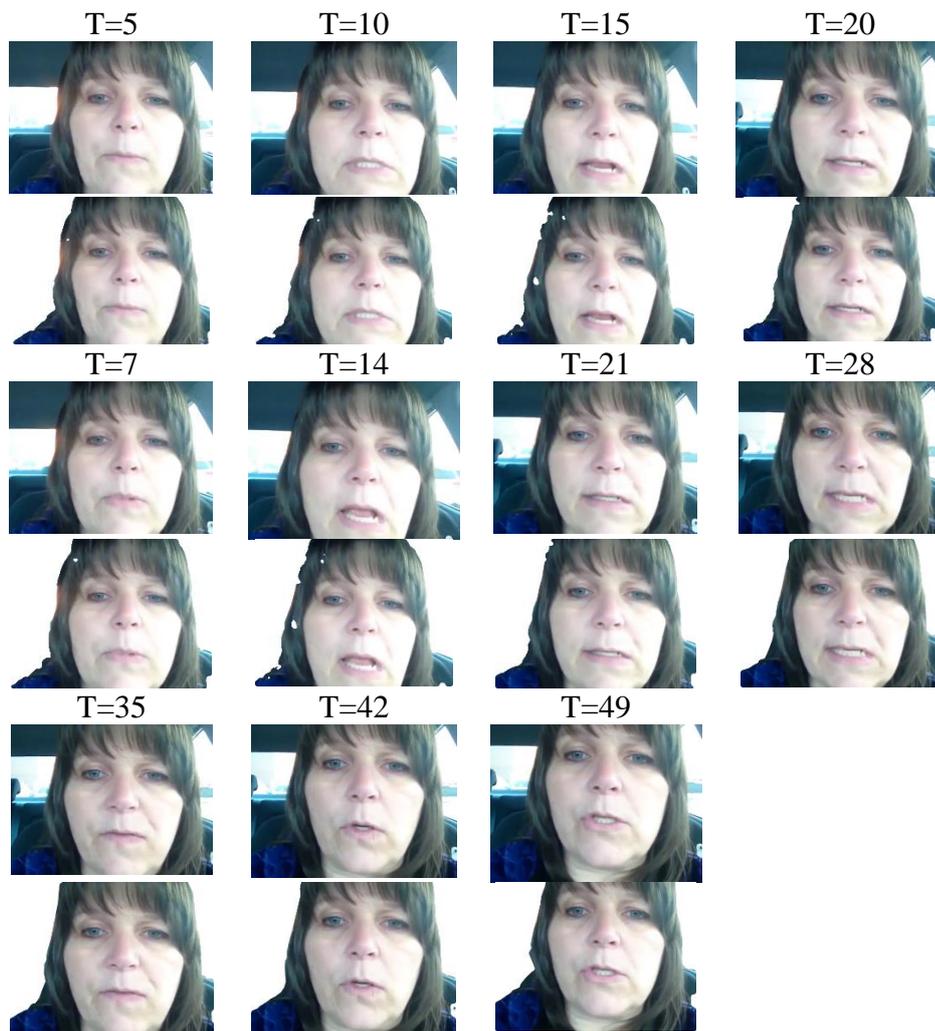
4.5 Hasil *Minor Stroke Extraction* dengan *Minkowski Distance*



Gambar 4. 11 Hasil *Minor Stroke Extraction* dengan *Minkowski Distance* pada $K=0.5$

Gambar 4.11 merupakan hasil *minor stroke extraction* dengan menggunakan metrik *minkowski distance* pada $K=0.5$. Pengujian dimulai dari frame 1 sampai frame 50. Frame pertama sebagai referensi yang dipisahkan secara manual dengan bantuan manusia. Variasi ekstraksi *object* dengan konstanta (K) dari $K=0.1$ sampai $K=5$. Jumlah variasi sebanyak lima puluhan. Fungsi K digunakan untuk mengejar perpindah warna jika terlalu cepat atau terlalu lambat.

Hasil *minor stroke extraction* terbaik ketika menggunakan metrik *minkowski distance* pada Gambar 4.11 saat $K=4.3$. Sedangkan hasil terendah saat ekstraksi *object* pada Gambar 4.12. Hal ini dipengaruhi oleh hasil rekaman *video* saat direkam. Karena yang mereka pada saat itu adalah wanita yang berumur kurang lebih 40 tahun. Saat mengendarai mobil tiba-tiba terserang *minor stroke*. Wanita tersebut kemudian merekam dengan ponsel.



Gambar 4. 12 Hasil *Minor Stroke Extraction* dengan *Minkowski Distance* pada $K=4.3$

Hasil Pengujian *minor stroke* selanjutnya adalah setiap frame video pada Gambar 12. T merupakan parameter urutan frame *video object extraction*. Hasil ekstraksi *object* saat frame T=5 sampai T=15 memperlihatkan kurang maksimal. Setelah T=20 sampai T=49 terlihat lebih maksimal hasil ekstraksi *minor stroke*. Hasil terbaik saat $K=4.3$ berada pada frame. Sedangkan hasil terendah pada frame 5 pada Gambar 4.12.

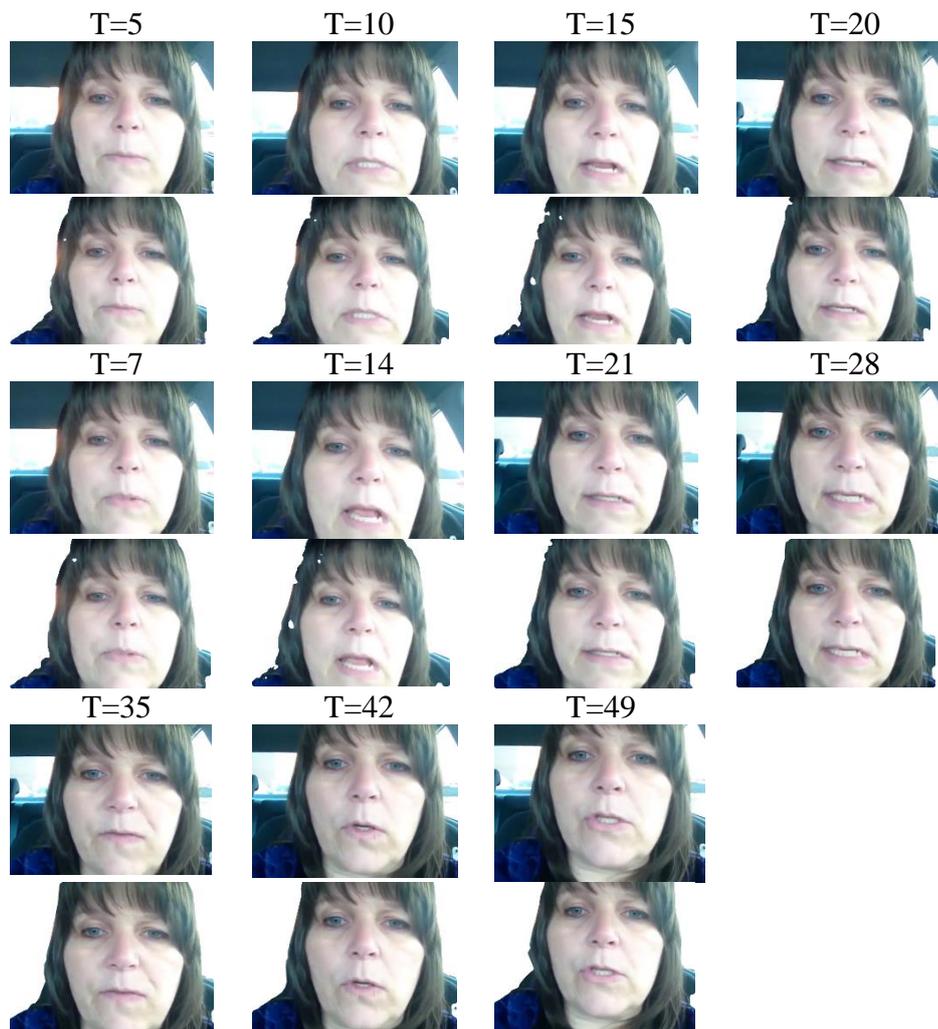
4.6 Hasil *Minor Stroke Extraction* dengan *Euclidean Distance*



Gambar 4. 13 Hasil *Minor Stroke Extraction* dengan *Euclidean Distance* pada $K=0.2$

Gambar 4.13 adalah hasil *minor stroke extraction* dengan menggunakan *minkowski distance* pada $K=0.2$ Pengujian ekstraksi *object* dengan frame *video minor stroke* sebanyak lima puluh frame. Terdiri dari frame pertama sebagai referensi dan frame berikutnya untuk diekstrak secara otomatis oleh *machine learning* menggunakan *pixel wise classification*. Frame referensi dipisahkan secara *manual* oleh bantuan manusia untuk dapat memaknai obyek dan *non-object*. Hasil pengujian menunjukkan bahwa T=7 sampai T=28 kurang maksimal. Sedangkan frame 35 sampai T=49 adalah maksimal. T adalah urutan frame yang diekstraksi *object*-nya. Hal ini dipengaruhi oleh pada saat pengambil rekaman video masih kurang stabil. Karena yang mengambil video adalah orang yang terserang *minor stroke*.

Hasil pengujian *minor stroke extraction* yang terbaik adalah Gambar 4.14 pada saat $K=4.3$. Sedangkan terendah pada Gambar 4.13 saat $K=0.2$. Hal ini terlihat hasil dari T=7 sampai T=49 pada Gambar 4.13.

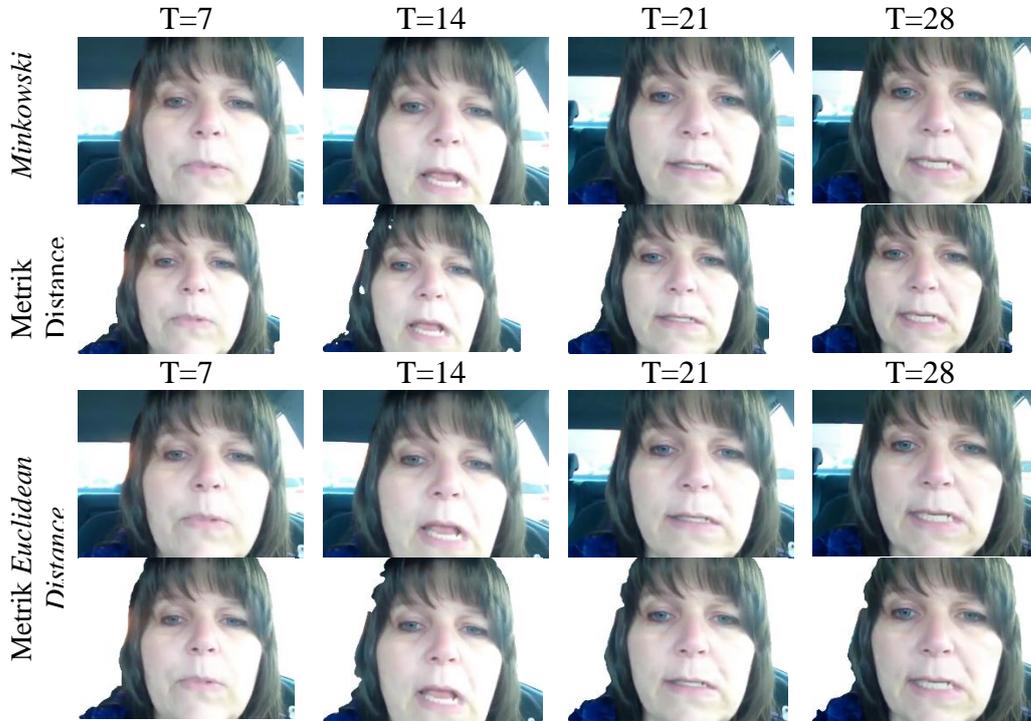


Gambar 4. 14 Hasil *Minor Stroke Extraction* dengan *Euclidean Distance* pada $K=4.3$

Gambar yang dihasilkan pada saat $T=14$ dan $T=21$ banyak hasil *object minor stroke* terpotong. Oleh karena itu, VOE memerlukan penyesuaian perpindahan warna frame dengan K .

Gambar 4.14 adalah hasil *minor stroke extraction* terbaik dari hasil variasi pengujian konstanta (K) dari $K=0.1$ sampai $K=5$. Jumlah variasi sebanyak lima puluh kali. Hasil pengujian *minor stroke extraction* dengan metrik *euclidean* terlihat sangat baik. Dari $T=20$ sampai $T=49$ lebih maksimal dari mengektrak *object minor stroke*. Namun pada saat $T=5$ sampai $T=15$ terlihat hasil ekstraksi *object* oleh mesin banyak lubang bulat putih. Hal ini dipengaruhi dari gerakan *object*, rekaman video dan perubahan warna saat pindah frame. Sehingga akan terlihat maksimal jika nilai K pas.

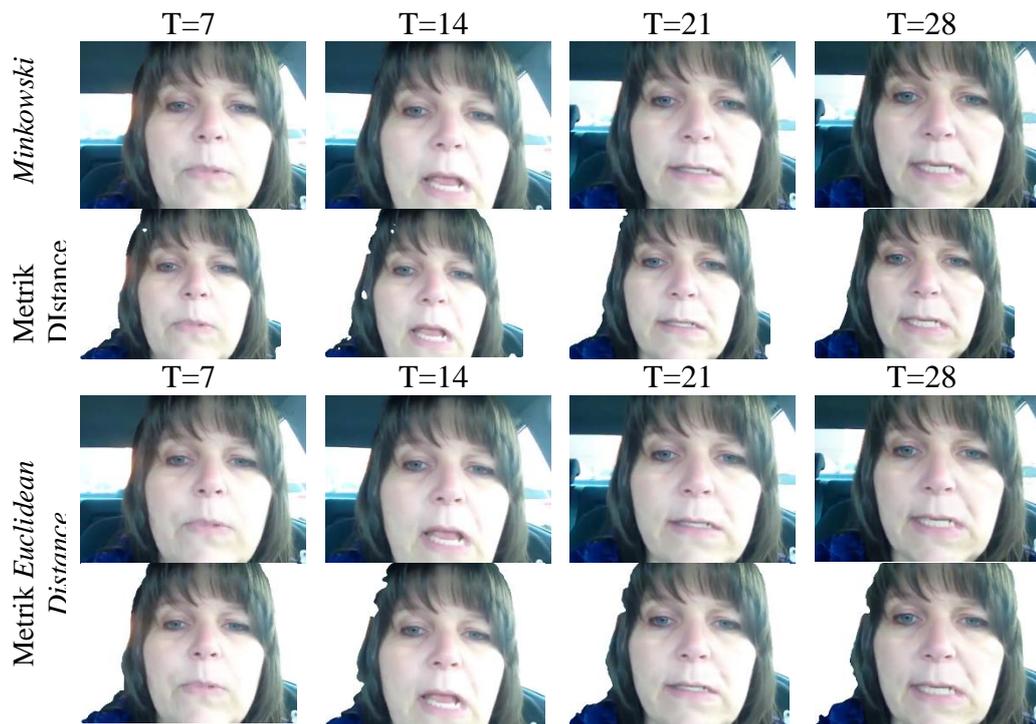
4.7 Perbandingan *Minor Stroke Extraction* dengan *Minkowski* dan *Euclidean Distance*



Gambar 4. 15 Hasil Perbandingan *Minor Stroke Extraction* Terbaik dengan *Minkowski* dan *Euclidean Distance*

Gambar 4.15 adalah hasil perbandingan *minor stroke extraction* terbaik antara metrik *minkowski* dengan *euclidean distance*. Hasil pengujian dari frame pertama sampai frame lima puluh. Frame pertama sebagai referensi yang hasil ekstraksi dibantu oleh manusia untuk memaknai. T sebagai parameter urutan frame yang diekstrak. T pertama sebagai referensi, sedangkan T=2 sampai T=50 sebagai target *minor stroke extraction*. Gambar 4.15 terbagi dalam dua hasil yang pertama adalah metrik *minkowski distance* dan kedua adalah metrik *euclidean distance*.

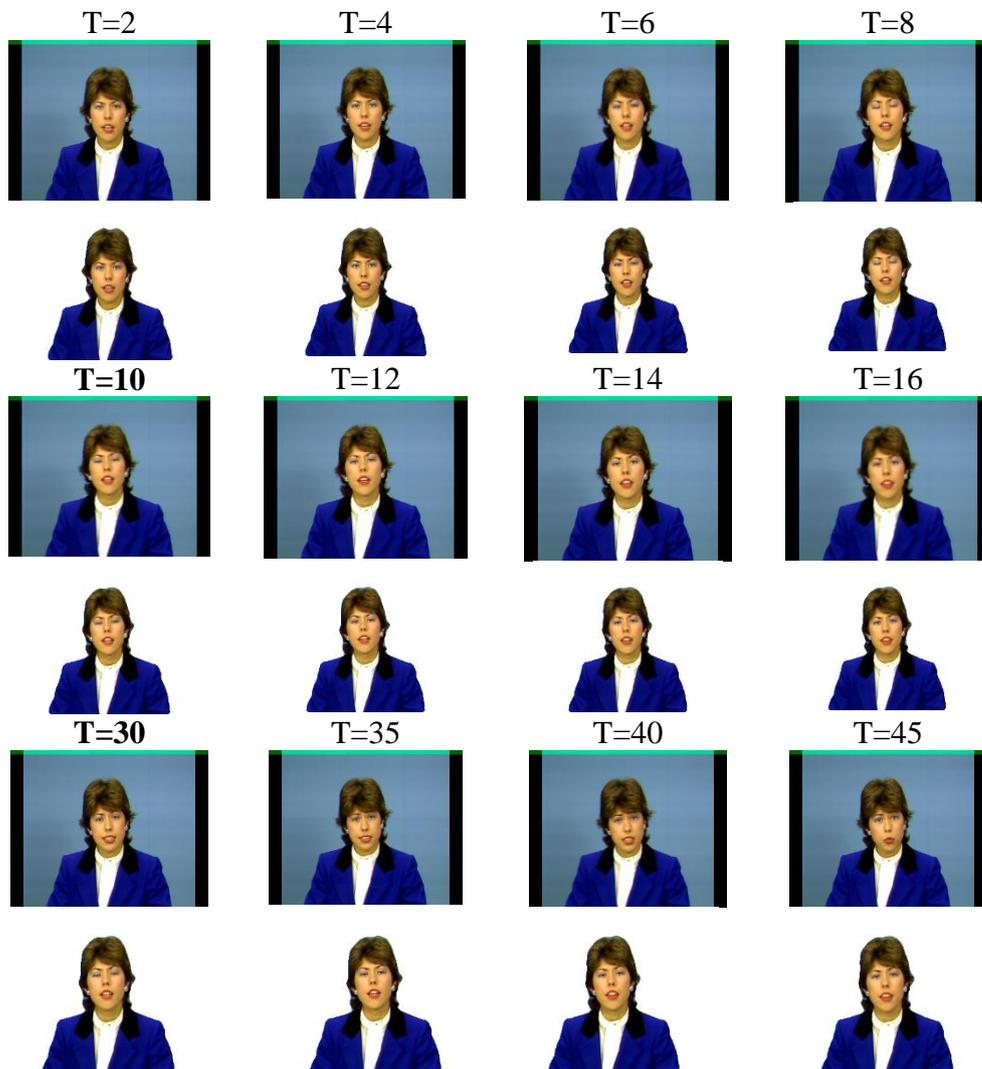
Hasil T=7 sampai T=28 dapat kita lihat hasil ekstraksi T=21 sampai T=28 lebih baik daripada T sebelumnya pada metrik *minkowski distance*. Hasil yang diperoleh T=7 dan T=14 terlihat berlubang pada *object* rambut orang yang terkena *minor stroke*. Hal ini dipengaruhi dari nilai konstanta (K) yang berfungsi untuk menyesuaikan kecepatan warna saat pindah frame. Selain hal tersebut pengaruh dari gerakan *object* dan latar belakang serta dari hasil rekaman *video minor stroke*. Karena saat pengambilan *video* bergoyang-goyang akan mempengaruhi dari hasil ekstraksi obyek *minor stroke*.



Gambar 4. 16 Hasil Perbandingan *Minor Stroke Extraction* Terendah dengan *Minkowski* dan *Euclidean Distance*

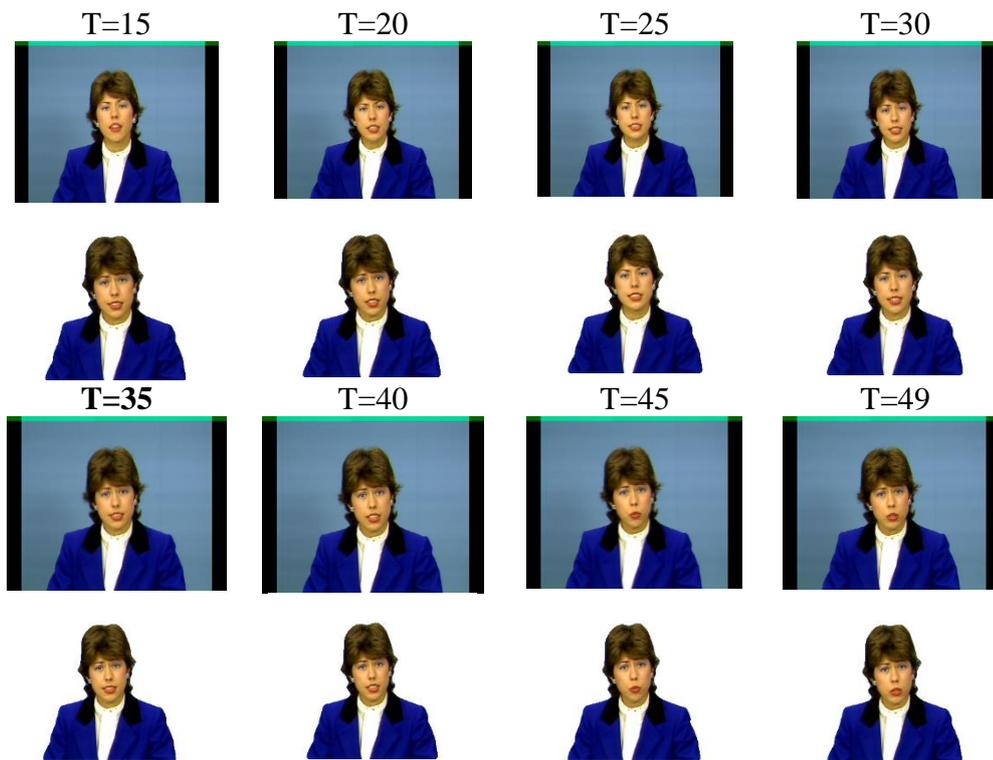
Gambar 4.16 merupakan proses perbandingan *minor stroke extraction* dengan metrik *minkowski* dan *euclidean distance*. Proses pengujian melewati variasi parameter konstanta (K) dari K=0.1 sampai K=5. Kelipatan yang dipergunakan dalam pengujian adalah 0.5. Jumlah pengujian sebanyak lima puluh. Gambar 4.16 terbagi menjadi dua bagian yang terdiri dari metrik *minkowski* dan *euclidean distance*. Hasil yang diperoleh ketika menggunakan metrik *minkowski distance* terlihat hasil ekstraksi *object* baik. Namun terdapat sedikit ekstraksi *object* yang masih kurang sempurna. Saat T=7 terlihat hanya ada satu lubang warna putih pada rambut orang yang terkena *minor stroke*. Gambar *minor stroke extraction* baik. Saat T=14 terlihat banyak sekali lubang putih dirambut orang yang terkena *minor stroke*, hasil gambar kurang bagus. Selanjutnya saat T=21, hasil yang diperoleh sangat maksimal. Tidak terdapat lubang warna putih pada *object*. Saat T=28 terlihat sempurna seperti gambar T=21 yang tidak ada lubang warna putih. Sedangkan hasil metrik *euclidean distance* terlihat kurang sempurna terutama saat T=14. Gambar yang lain terlihat lebih baik saat T=7, T=21 dan T=28. Gambar 4.16 adalah gambar yang hasilnya paling rendah. Gambar 4.16 dibanding dengan Gambar 4.15 yang terlihat lebih baik.

4.8 Hasil *Claire Extraction* dengan *Minkowski Distance*



Gambar 4. 17 Hasil *Claire Extraction* dengan *Minkowski Distance* pada $K=0.1$

Gambar 4.17 adalah hasil *claire extraction* ketika menggunakan metrik *minkowski distance*. Pengujian *claire extraction* dilakukan dengan variasi konstanta (K) sebanyak lima puluh kali. Variasi nilai parameter K dimulasi dari $K=0.1$ sampai $K=5$. Gambar 4.17 merupakan hasil ekstraksi terbaik dari data *claire* ketika menggunakan metrik *minkowski distance* pada $K=0.1$. Hasil ekstraksi *claire* dengan *minkowski distance* bisa dilihat pada Gambar 4.17 yang terdiri dari $T=2$ sampai $T=45$. Terlihat hasil ekstraksi keliapatan dua pada T sangat sempurna. Antara obyek dan non-obyek tidak terlihat ada lubang putih di *object* atau *foreground*.

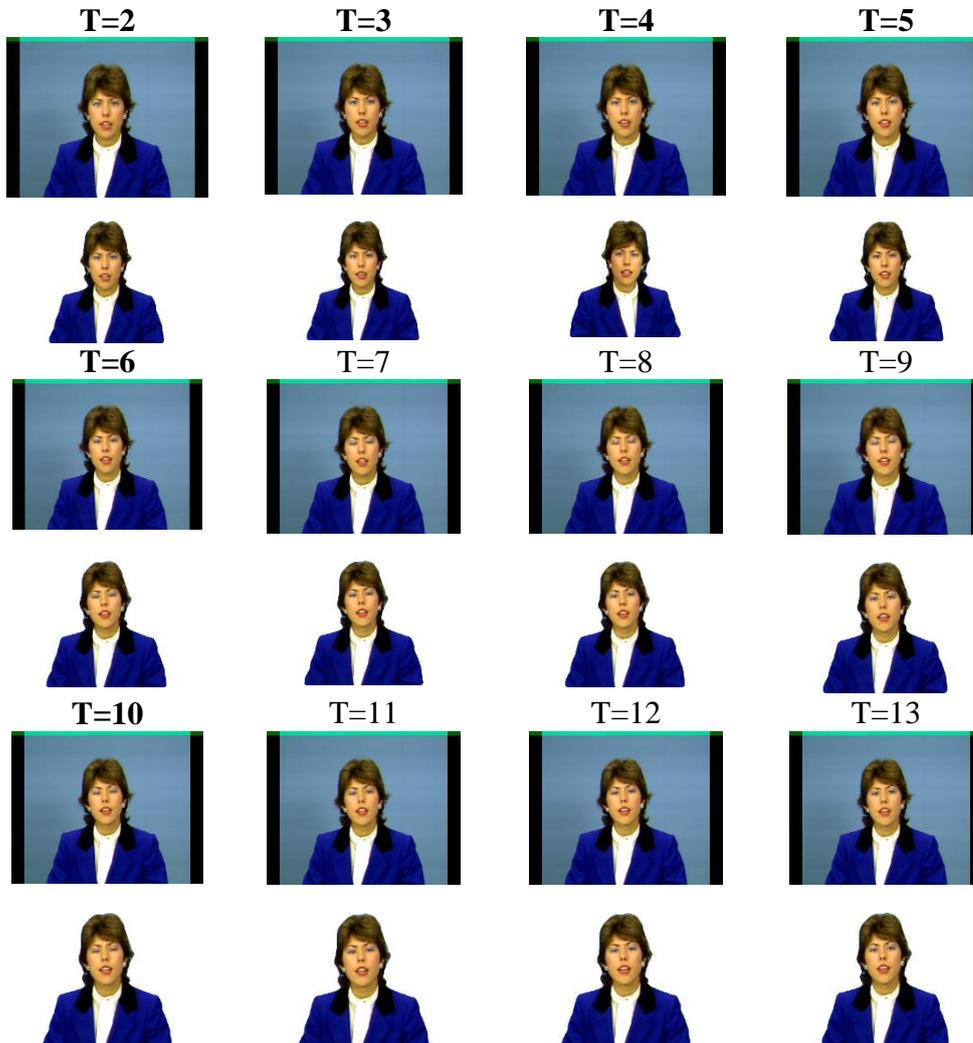


Gambar 4. 18 Hasil *Claire Extraction* dengan *Minkowski Distance* pada $K=4.5$. Sedangkan kelipatan lima pada T yang dimulai dari $T=30$ sampai $T=45$ terlihat sangat jelas. Antara *foreground* dengan *background* terlihat tanpa ada lubang putih atau goresan dari *object* tersebut.

Data *video claire* direkam oleh perekam video yang profesional. Sehingga hasil olahan *video* setiap frame terlihat stabil. Biasanya video rekaman oleh seorang amatir akan bergoyang-goyang. Sehingga hasil yang diperoleh ketika mengekstrak *object* secara otomatis tidak bisa maksimal. Karena perpindahan dari frame-frame tidak teratur.

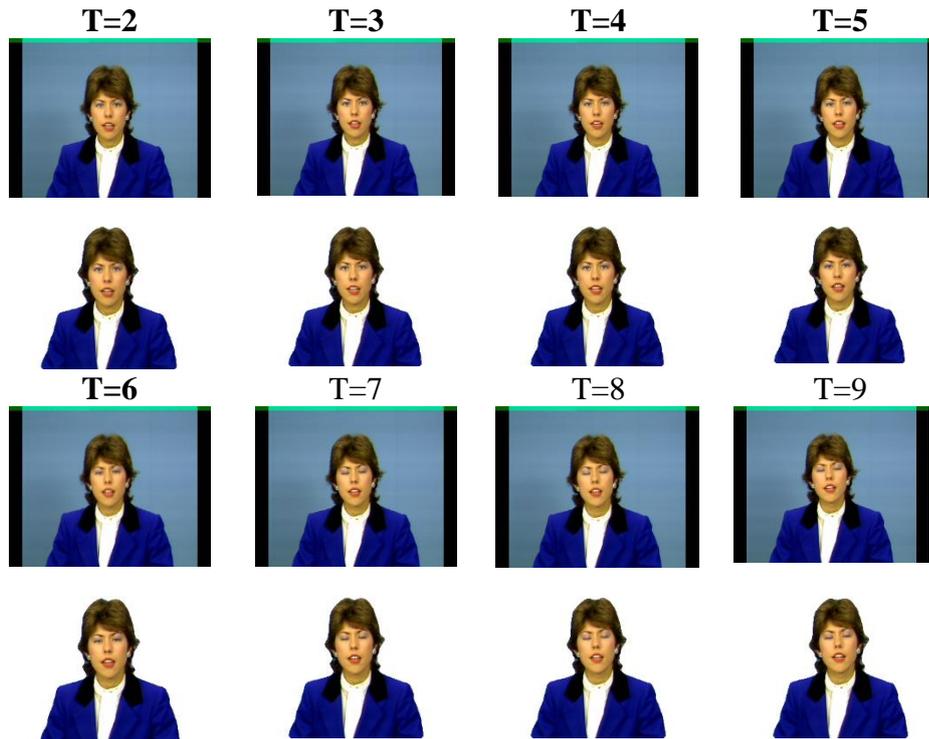
Gambar 4.18 adalah hasil *claire* yang menggunakan metrik *euclidean distance* pada nilai $K=4.5$. Pengujian *claire* dilakukan dengan menggunakan frame pertama sebagai referensi. Sedangkan frame kedua sampai terakhir sebagai target *claire extraction* oleh *machine learning*. Percobaan dilakukan dengan nilai konstanta (K) yang divariasikan sebanyak 50 kali. Nilai K dimulai dari K awal $K=0.1$ sampai $K=5$. Hasil yang diperoleh adalah *claire extraction* yang dapat memisahkan *foreground* dengan *background* secara otomatis. Gambar 4.18 adalah hasil terendah dari *claire extraction* dengan metrik *minkowski distance* pada $K=4.5$.

4.9 Hasil *Claire Extraction* dengan *Euclidean Distance*



Gambar 4. 19 Hasil *Claire Extraction* dengan *Euclidean Distance* pada $K=0.1$

Gambar 4.19 adalah hasil dari *claire extraction* menggunakan *euclidean distance* pada $K=0.1$. Pengujian *claire extraction* dilakukan dengan $K=0.1$ sampai $K=5$. Jumlah *claire extraction* yang diuji sebanyak lima puluh kali. Data yang dipergunakan adalah *claire*. Seorang presenter wanita yang sedang menyiarkan berita. Data yang dipergunakan sebanyak lima puluh. Frame pertama sebagai referensi *object* ekstraksi oleh bantuan manusia. Sedangkan frame kedua sampai terakhir sebagai target untuk *claire extraction*.



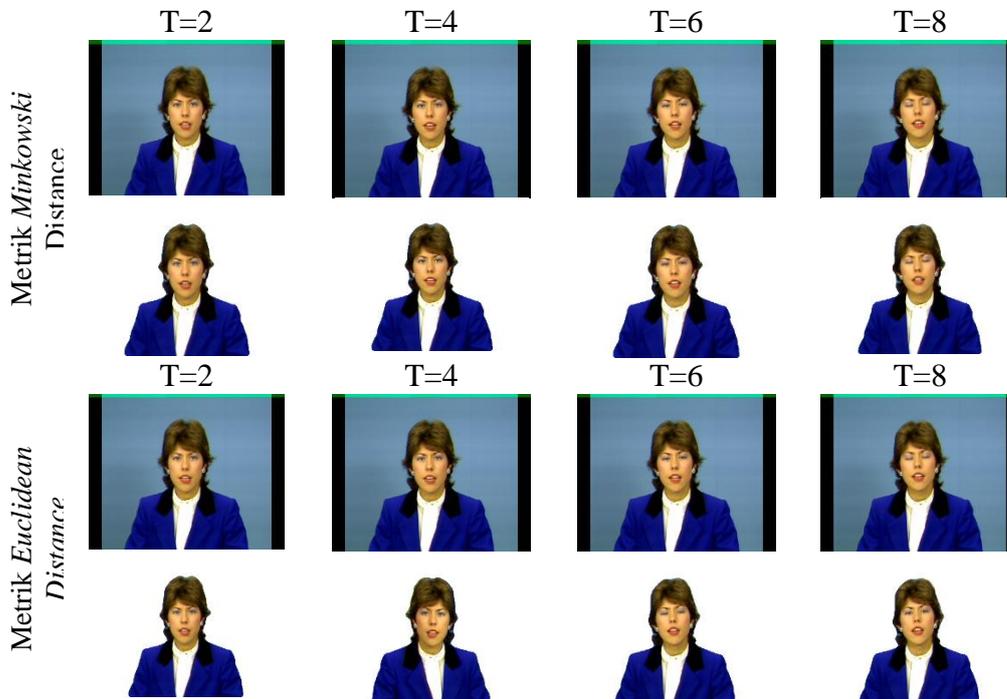
Gambar 4. 20 Hasil *Claire Extraction* dengan *Euclidean Distance* pada $K=3.8$

Gambar 4.19 terdiri dari frame yang belum diekstrak dan yang sudah diekstrak. Frame yang diekstrak atau yang sudah diberi nomer urut yang dinamakan parameter T . Hasil pengujian terlihat bahwa antara *foreground* dengan *background* dapat dipisahkan secara otomatis pada $T=2$ sampai $T=13$. Tidak terlihat bercak putih di *foreground* atau bercak warna pada *background*. Hal ini dipengaruhi oleh hasil rekaman *video claire* oleh seorang perekaman video profesional. Sehingga hasil yang diperoleh terlihat saat perpindahan frame yang stabil. Hasil frame ekstraksi obyek pada *video claire* yang terbaik adalah $T=2$ pada $K=0.1$. Sedangkan frame yang kurang maksimal terdapat pada $T=7$ pada $K=0.1$.

Gambar 4.20 merupakan hasil *claire extraction* dengan metrik *euclidean distance*. Jumlah frame yang diujikan dalam *claire extraction* sebanyak lima puluh frame. Pengujian dalam *claire extraction* sebanyak lima puluh dengan memasukan nilai $K=0.1$ sampai $K=5$. Hasil dalam *claire extraction* yang diperoleh dari $T=2$ sampai $T=9$ terlihat bagus. Gambar 4.20 adalah hasil ekstraksi antara *foreground* dengan *background* dapat dipisahkan secara otomatis. Namun hasil *claire extraction* pada $K=3.8$ adalah paling terendah. Hal ini dipengaruhi oleh parameter konstanta yang tidak sesuai dengan kecepatan perpindahan warna frame *claire*.

4.10 Perbandingan *Claire Extraction* dengan *Minkowski* dan *Euclidean*

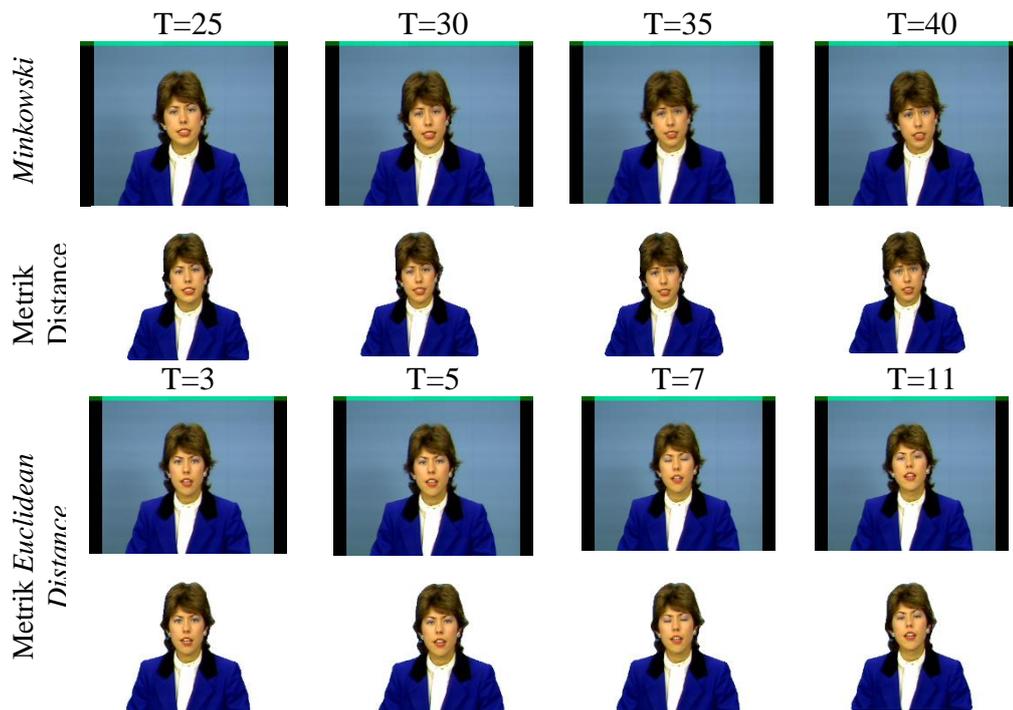
Distance



Gambar 4. 21 Hasil Perbandingan *Claire Extraction* Terbaik dengan *Minkowski* dan *Euclidean Distance*

Gambar 4.21 adalah hasil perbandingan antara *claire extraction* terbaik. Gambar terdiri dari metrik *minkowski* dan *euclidean distance*. Nilai T pada frame menandakan urutan dari frame yang diekstrak. Pengujian frame *claire* sebanyak lima puluh frame yang terdiri dari frame pertama sebagai referensi. Sedangkan frame kedua dan terakhir sebagai target. Hasil terlihat baik pada metrik *minkowski distance* dari T=2 sampai T=8. Terlihat frame kedua lebih sempurna dan tidak terdapat goresan di *foreground*. Biasanya hasil ekstraksi *object* terdapat bercak putih di *foreground* atau *object*. Namun hasil ekstraksi terlihat tidak ada satu goresanpun sampai frame terakhir.

Gambar 4.21 adalah hasil *claire extraction* metrik *Euclidean distance* yang maksimal. Dari frame pertama sampai frame ke empat. Hasil ekstraksi *claire* terlihat lebih rapi dan tidak terlihat goresan atau lubang di *foreground*. Gambar *claire* pada T=2 terlihat lebih baik daripada T yang lain. Hasil *claire extraction* dari metrik *minkowski* dan *euclidean* terlihat paling baik pada T=2. Hal ini dipengaruhi oleh gerakan dari *object* yang pas dengan nilai parameter K.



Gambar 4. 22 Hasil Perbandingan *Claire Extraction* Terendah dengan *Minkowski* dan *Euclidean Distance*

Gambar 4.22 terlihat parameter T yang digunakan untuk penomoran frame di metrik *minkowski* dan *euclidean distance*. Hasil ekstraksi *claire* pada metrik *minkowski distance* terlihat secara visual baik dari T=25 sampai T=40. Hasil ekstraksi *foreground* dengan *background* pada obyek *claire* terlihat baik. Tidak terlihat goresan di *foreground* maupun *background*. Sedangkan di metrik *euclidean distance* terlihat bahwa hasil ekstraksi *video claire* baik dari T=25 sampai T=40. Hasil ekstraksi *foreground* dengan *background* oleh LVQ terlihat tidak terdapat bercak pada *foreground* maupun *background*.

Hasil ekstraksi *video claire* terendah pada Gambar 4.22 adalah frame 30 atau T=30 pada metrik *minkowski distance*. Sedangkan ekstraksi *video claire* terendah pada metrik *euclidean distance* adalah frame ke 7. Hasil ekstraksi metrik *minkowski distance* yang paling rendah berada pada urutan ganjil. Sedangkan hasil ekstraksi metrik *euclidean distance* yang paling rendah pada urutan genap. Karena pengaruh dari karakteristik pengukuran saat proses *unsupervised learning*.

4.11 Perbandingan *Minor Stroke* dengan *Claire Extraction*



Gambar 4. 23 Hasil Perbandingan *Minor Stroke* dengan *Claire* Terbaik pada *Minkowski Distance*

Gambar 4.23 adalah hasil dari perbandingan data *video minor stroke* dengan *claire*. *Video* diuji dengan metrik *minkowski distance*. Pengujian *video minor stroke* dan *claire* menggunakan variasi konstanta (K). Nilai parameter dalam pengujian dari $K=0.1$ sampai $K=5$. Total percobaan yang dilakukan sebanyak lima puluh kali. Terlihat bahwa hasil percobaan ekstraksi T=7 masih ada bercak putih di rambut orang yang terkena *minor stroke*. Saat T=14 terlihat hasil ekstraksi terdapat bercak putih di rambut wanita tersebut. Selanjutnya saat T=21 terlihat hasil ekstraksi tanpa ada bercak di *foreground* maupun *background*. Sedangkan frame T=28 terlihat sama dengan T=21 yang tidak ada bercaknya dan lebih stabil. Frame terbaik pada *minor stroke* pada T=21.

Selain hasil ekstraksi *minor stroke* pada metrik *minkowski*, Gambar 4.23 juga terdapat hasil *claire* dengan metrik *minkowski distance*. Hasil dari ekstraksi ditampilkan pada T=2 sampai T=8. Hasil ekstraksi *claire* lebih halus daripada *minor* pada semua frame atau T. Hasil ekstraksi *claire* terbaik pada T=2. Karena pengaruh dari saat rekaman *video claire* yang stabil.



Gambar 4. 24 Hasil Perbandingan *Minor Stroke* dengan *Claire* Terendah pada *Minkowski Distance*

Gambar 4.24 adalah hasil terendah ekstraksi dari *video minor stroke* dan *claire*. Pengujian video menggunakan metrik *minkowski distance*. Variasi dari pengujian dengan konstanta (K). Jumlah variasi K yang digunakan sebanyak lima puluh yang terdiri dari K=0.1 sampai K=5. Jumlah frame yang diujikan sebanyak lima puluh dari *video minor stroke* dan *claire*.

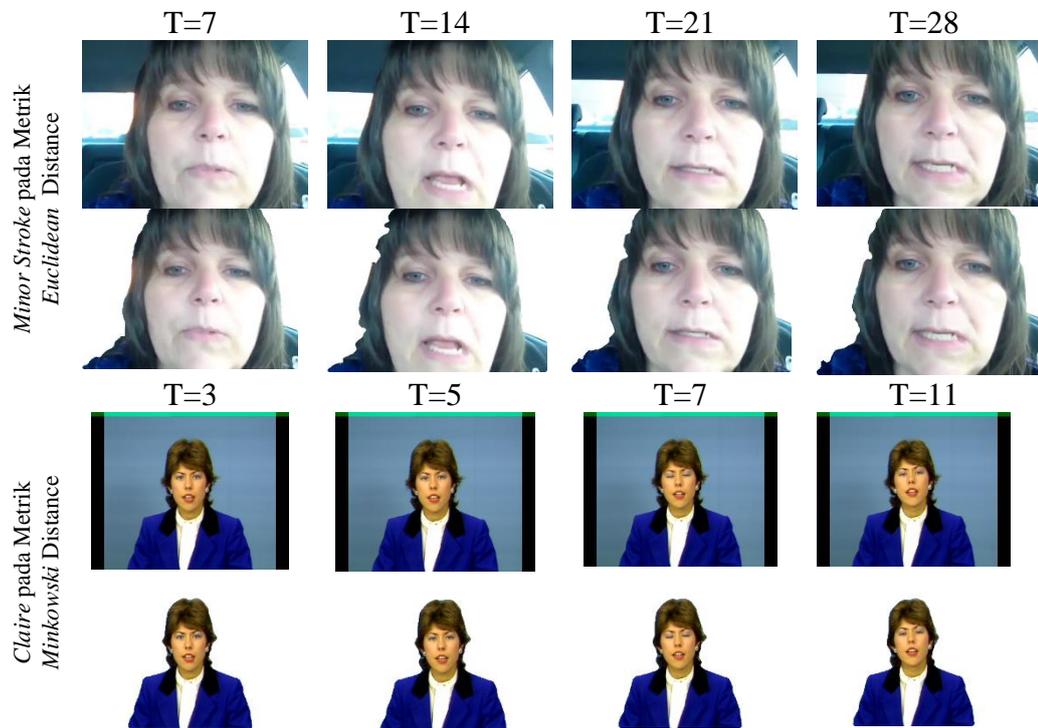
Gambar 4.24 memuat hasil ekstraksi *minor stroke* dari *foreground* dan *background* dengan metrik *minkowski distance*. Hasil *minor stroke* ditampilkan pada T=7 sampai T=28. Parameter T merupakan urutan dari frame *video minor stroke*. T awal terlihat ada bercak putih berjumlah satu pada rambut pasien *minor stroke*. Saat T=5 terlihat banyak lubang putih pada *foreground*. Selanjutnya saat T=7 dan T=28 terlihat hasil ekstraksi *minor stroke* yang lebih baik daripada T=7 dan T=14. Untuk hasil frame yang terendah berada pada T=5. Hal ini dipengaruhi oleh kualitas *video* saat pengambilan data awal. Gambar 4.24 terdapat juga hasil ekstraksi *claire* dengan metrik *minkowski distance*. Jumlah frame yang diujikan sebanyak lima puluh. Namun hasil ekstraksi *claire* yang ditampilkan disini sebagai contoh sebanyak empat. Terdiri dari frame T=3, T=5, T=7 dan T=11. Dari hasil ekstraksi *claire* terlihat lebih bagus walaupun kategori terendah.



Gambar 4. 25 Hasil Perbandingan *Minor Stroke* dengan *Claire* Terbaik pada *Euclidean Distance*

Gambar 4.25 adalah hasil perbandingan dari video *minor stroke* dengan *claire* terbaik. Percobaan video *minor stroke* dan *claire* menggunakan metrik *euclidean distance*. Variasi percobaan menggunakan konstanta (K) yang digunakan untuk menahan laju perubahan warna jika terlalu cepat atau lambat. Jumlah variasi K sebanyak lima puluh kali yang dimulai dari K=0.1 sampai K=5.

Terlihat hasil *video object extraction* yang ditampilkan pada T=7, T=14, T=21 dan T=28. Parameter T merupakan urutan dari frame yang diekstraksi. Hasil ekstrasi *minor stroke* pada frame ke 2 lebih baik. Tidak terdapat bercak baik pada *foreground* maupun *background* pada frame. Namun hasil VOE pada T=7 terlihat banyak potongan di rambut yang orang terkena *Minor Stroke*. Hasil T=6 dan T=8 hampir sama kepotong pada rambut. Karena pengaruh pengambilan video waktu rekaman dan karakteristik dari metrik *euclidean distance*. Sedangkan untuk hasil *claire extraction* terlihat dari T=2, T=4, T=6 dan T=8 bersih. Tidak terdapat bercak di *foreground* maupun *background*. T terbaik pada *claire extraction* dengan *euclidean distance* adalah frame ke 2 atau T=2. Sedangkan hasil *minor stroke extraction* terbaik pada T=21.

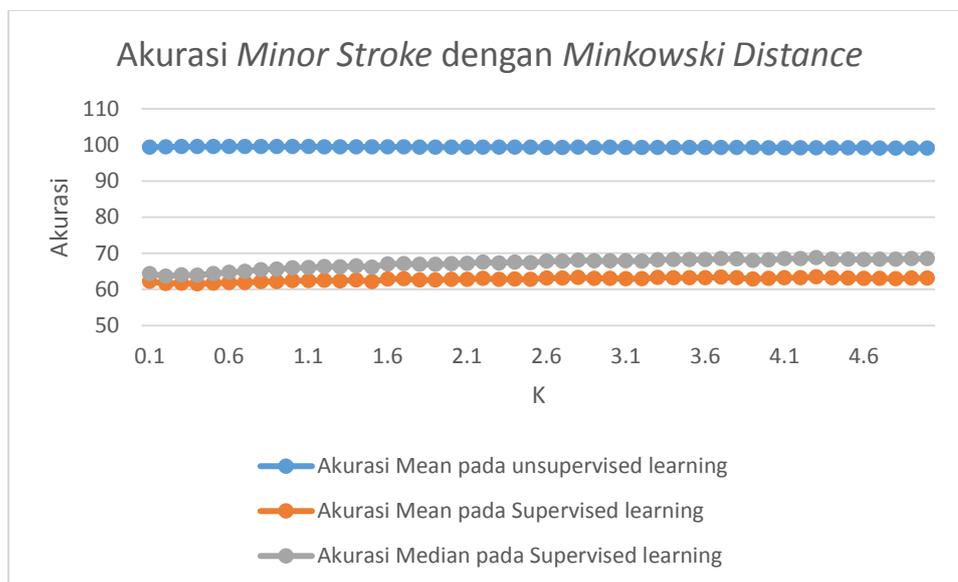


Gambar 4. 26 Hasil Perbandingan *Minor Stroke* dengan *Claire* Terendah pada *Euclidean Distance*

Gambar 4.26 adalah hasil perbandingan *video minor stroke* dengan *claire* terendah. Pengujian *claire extraction* yang digunakan menggunakan metrik euclidean distance. Jumlah variasi konstant (T) yang dipergunakan sebanyak lima puluh. Variasi konstanta dimulai dari $K=0.1$ sampai $K=5$. Variasi K digunakan untuk mengejar perubahan warna saat perpindahan frame, bila terlalu cepat maupun terlalu lambat.

Gambar 4.26 adalah hasil ekstraksi *minor stroke* dengan metrik *euclidean distance* terendah. Hasil terlihat pada Gambar $T=7$, $T=14$, $T=21$ dan $T=28$. Hasil ekstraksi terlihat pada $T=3$ tanpa ada potongan di *foreground*. Saat $T=5$ terlihat rambutnya terpotong tidak sempurna. Hasil ekstraksi *object minor stroke* saat $T=7$ tidak terlalu jelek. Sedangkan saat $T=11$ hampir mirip hasilnya dengan $T=7$. Hal ini dipengaruhi oleh karakteristik dari kualitas video saat pengambilnya. Selain hasil ekstraksi pada Gambar 4.26 terdapat hasil *video claire* menggunakan *euclidean distance*. Hasil *claire extraction* terlihat lebih rapi saat ekstraksi *object* dan *non-object* pada $T=3$, $T=5$, $T=7$ dan $T=11$. Hal ini dipengaruhi kualitas pengambilan *video claire* yang lebih baik daripada *minor stroke*.

4.12 Hasil Akurasi *Minor Stroke Extraction* dengan *Minkowski Distance*

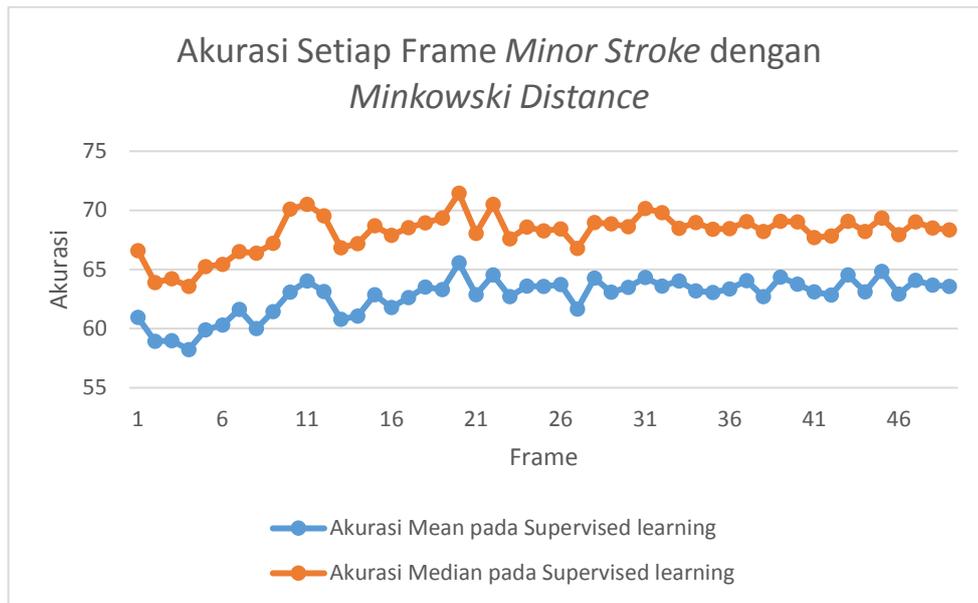


Gambar 4. 27 Akurasi *Minor Stroke* dengan *Minkowski Distance* dengan $P=2$

Gambar 4.27 merupakan grafik hasil *minor stroke* dengan metrik *minkowski distance*. Pengujian *video minor stroke* dengan variasi konstanta (K) yang berjumlah lima puluh. Nilai K berfungsi untuk mengejar perpindahan warna pada frame. Nilai K dimulai dari $K=0.1$ sampai $K=5$. Parameter K yang diujikan pada proses untuk mencari akurasi *unsupervised learning*, *mean supervised* dan *median supervised learning*.

Warna biru pada Gambar 4.27 menggambarkan hasil akurasi proses *unsupervised learning*. Pengujian proses *unsupervised* dimulai dari $K=0.1$ sampai $K=5$. Hasil *unsupervised learning* digunakan sebagai data *training* pada proses *supervised learning*. Data yang dihasilkan pada proses *unsupervised learning* terdiri dari *object* dan *non-object*. Hasil proses *unsupervised learning* terlihat stabil dengan akurasi 99% pada $K=0.1$ sampai $K=5$.

Selain proses *unsupervised learning* pada Gambar 4.27, terdapat pula hasil akurasi *mean supervised learning*. Warna orange menggambarkan hasil akurasi *mean supervised learning*. Hasil dari pengujian *minor stroke* dapat dilihat dari nilai $K=0.1$ sampai $K=0.5$.



Gambar 4. 28 Akurasi Setiap Frame *Minor Stroke* dengan *Minkowski Distance* dengan $P=2$

Grafik akurasi semakin naik dari $K=0.1$ sampai $K=4.3$, kemudian turun lagi. Hal ini dipengaruhi oleh perubahan warna pada perpindahan frame yang terlalu lambat pada $K=0.1$ sampai $K=4.2$. Akurasi terbaik sebesar 63.49% pada $K=4.3$. Sedangkan akurasi terendah sebesar 61.61% pada $K=0.2$.

Sebagai hasil pembandingan akurasi *mean supervised learning*, maka pada Gambar 4.27 menyajikan hasil *median supervised learning*. Karena hasil dari *mean* kurang peka terhadap data yang jumlahnya besar. Dari grafik terlihat bahwa akurasi terbaik pada $K=4.3$ sebesar 68.76%. Sedangkan akurasi terendah sebesar 63.68% pada $K=0.2$. Hasil akurasi *median* tidak bisa mencapai maksimal karena hasil rekaman video *minor stroke* pada saat pengambilan tidak stabil.

Gambar 4.28 merupakan hasil akurasi dari setiap frame *minor stroke* pada $K=4.3$. *Video minor stroke* diuji dengan metrik *minkowski distance*. Jumlah frame *minor stroke* yang diujikan berjumlah lima puluh. Frame pertama sebagai referensi untuk ekstraksi. Frame pertama diolah secara manual oleh bantuan manusia untuk mengidentifikasi *object* dan *non-object*.

Warna biru pada Gambar 4.28 merupakan hasil akurasi *mean* setiap frame *minor stroke* pada *supervised learning*. Metrik yang dipergunakan dalam penelitian adalah *minkowski distance*. Pengujian frame dilakukan pada frame pertama sampai frame lima puluh. Frame pertama diolah dengan bantuan manusia. Hasil akurasi terlihat pada frame 2 sampai frame 50. Akurasi *mean* pada *supervised learning* saat frame 2 sebesar 60.96%, frame 6 sebesar 59.91%, frame 11 sebesar 63.09%, frame 16 sebesar 62.86%, frame 21 sebesar 65.56%, frame 26 sebesar 63.58%, frame 31 sebesar 63.48%, frame 36 sebesar 63.05%, frame 41 sebesar 63.75%, frame 46 sebesar 64.85%. Akurasi *mean* terbaik setiap frame *minor stroke* sebesar 65.56% pada frame 21. Sedangkan terendah sebesar 58.24% pada frame 5.

Akurasi *median minor stroke* pada *supervised learning* digambarkan warna orange pada Gambar 4.28. Akurasi *median* digunakan untuk mencari akurasi yang lebih tepat. Sebab hasil akurasi *median* tidak terpengaruhi oleh data besar. Hasil akurasi *median supervised learning* saat frame 2 sebesar 66.585%, frame 6 sebesar 65.25%, frame 11 sebesar 70.09%, frame 16 sebesar 68.70%, frame 21 sebesar 71.45%, frame 26 sebesar 68.27%, frame 31 sebesar 68.60%, frame 36 sebesar 68.39%, frame 41 sebesar 69.01%, frame 46 sebesar 69.34%. Akurasi *median* terbaik setiap frame *minor stroke* sebesar 71.45% pada frame 21. Sedangkan terendah sebesar 63.56% pada frame 5. Akurasi tidak maksimal karena pengaruhi kualitas *video minor stroke* saat pengambilan datanya. Sehingga mempengaruhi hasil ekstraksi *minor stroke extraction*.

4.13 Kecepatan Waktu pada saat Pengujian *Minor Stroke* dengan *Minkowski Distance*

Gambar 4.29 adalah hasil pengukuran waktu saat pengujian *minor stroke* dengan metrik *minkowski*. *Video minor stroke* diuji menggunakan variasi $K=0.1$ sampai $K=5$ pada proses *mean unsupervised learning*, *mean supervised learning* dan *median supervised learning*. Saat pengujian *minor stroke* dengan variasi konstanta (K) memerlukan waktu penyelesaian.

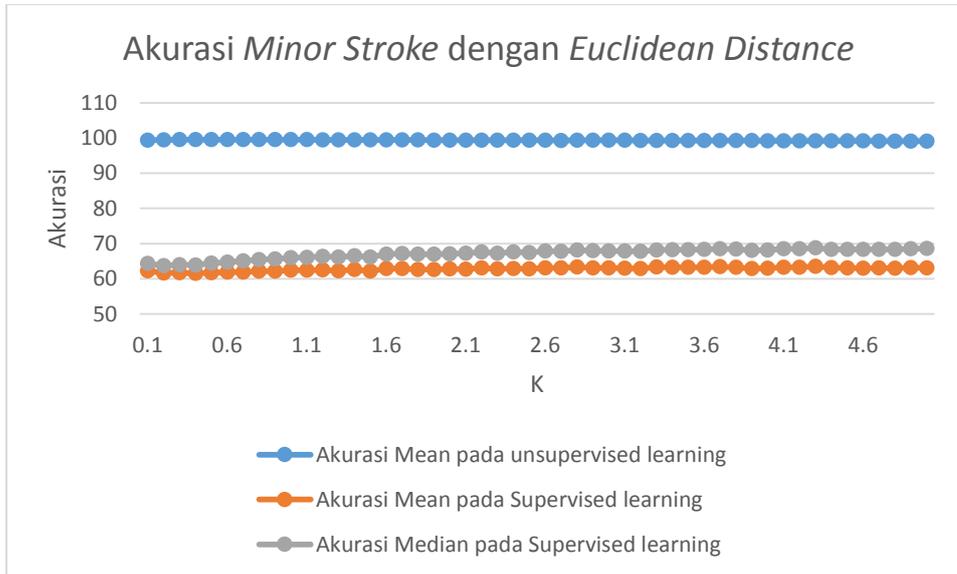


Gambar 4. 29 Kecepatan Waktu saat Pengujian *Minor Stroke* dengan *Minkowski Distance* dengan $P=2$

Pengujian kecepatan waktu *video minor stroke extraction* (VME) dimulai saat $K=0.1$ memerlukan waktu 254 detik. Saat pengujian VME pada $K=0.6$ memerlukan waktu 217 detik. Kemudian saat pengujian VME pada $K=1.1$ memerlukan waktu 206 detik. Selanjutnya saat pengujian VME pada $K=1.6$ memerlukan waktu 219 detik. Saat pengujian VME pada $K=2.1$ memerlukan waktu 224 detik. Pengujian VME dilakukan pada $K=2.6$ dengan waktu tempuh 219 detik. Saat pengujian VME pada $K=3.1$ memerlukan waktu 223 detik. Kemudian saat pengujian VME pada $K=3.6$ memerlukan 228 detik. Selanjutnya pengujian VME pada saat $K=4.1$ membutuhkan waktu 209 detik. Saat pengujian VME pada $K=4.6$ memerlukan waktu 215 detik.

Hasil pengujian *video minor stroke extraction* dengan metrik *minkowski distance* tercepat memerlukan 205 waktu detik pada $K=1.6$ Sedangkan waktu terlama 257 detik untuk menyelesaikan pengujian VME dengan metrik *minkowski* pada $K=3.9$. Parameter K mempengaruhi hasil penyelesaian pengujian pada VME. Semakin tinggi nilai parameter K akan semakin lama dalam penyelesaiannya. Selain itu parameter P mempengaruhi dari waktu pengujian.

4.14 Hasil Akurasi *Minor Stroke Extraction* dengan *Euclidean Distance*

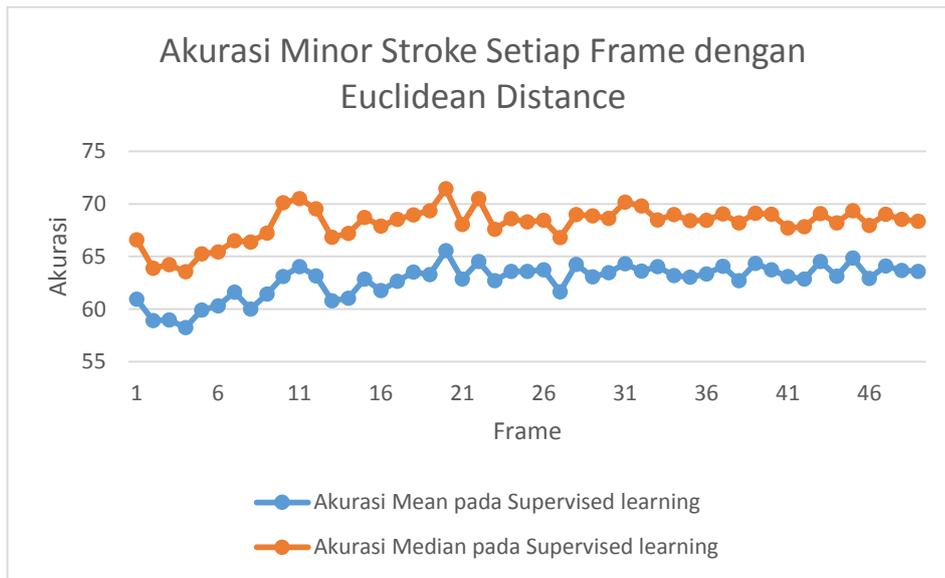


Gambar 4. 30 Akurasi *Minor Stroke* dengan *Euclidean Distance*

Gambar 4.30 adalah hasil akurasi *minor stroke* dengan metrik *euclidean distance*. Pengujian *video minor stroke* dilakukan dengan variasi nilai konstanta (K) dari K=0.1 sampai K=5. Jumlah pengujian *video minor stroke* sebanyak lima puluh kali. Gambar 4.30 berisi hasil pengujian akurasi *mean* pada *supervised learning* dan *unsupervised learning* dan *median supervised learning*.

Grafik warna biru pada Gambar 4.30 menggambarkan hasil akurasi *mean* pada proses *unsupervised learning*. Hasil akurasi *mean* pada proses *unsupervised learning* stabil. Proses ini berjalan pada frame pertama untuk menentukan data *training* yang terdiri obyek dan non obyek. Hasil akurasi terlihat rata 99%. Akurasi *mean* terbaik pada *unsupervised learning* sebesar 63.49% pada K=4.3. Sedangkan terendah pada K=0.2 sebesar 61.61%.

Selain grafik warna biru pada Gambar 4.30, terdapat pula akurasi *mean* pada *supervised learning* yang digambarkan warna orange. Pengujian *minor stroke* yang dilakukan sama dengan grafik warna biru dengan konstanta K. Hasil akurasi *minor stroke* terlihat ketika nilai K juga naik. Hasil akurasi terbaik *mean* pada *supervised learning* sebesar 68.76% pada K=4.3. Sedangkan akurasi *mean* terendah sebesar 61.61% pada K=0.2.



Gambar 4. 31 Akurasi *Minor Stroke* Setiap Frame dengan *Euclidean Distance*

Akurasi *median* pada *supervised learning* digambarkan grafik warna abu-abu pada Gambar 4.30. Pengujian *minor stroke* yang dilakukan sama dengan grafik warna biru dan orange. Hasil akurasi *median* terbaik sebesar 68.76%. pada $K=4.3$. Sedangkan akurasi *median* terendah 63.68% pada $K=0.2$. Hasil akurasi *minor stroke* tidak maksimal ketika menggunakan metrik *euclidean distance* karena pengaruh kualitas *video minor stroke* saat rekaman.

Gambar 4.31 adalah hasil akurasi *minor stroke* setiap frame. Pengujian *video minor stroke* setiap frame dengan menggunakan metrik *euclidean distance* pada $K=4.3$. Pengujian frame *video minor stroke* berjumlah lima puluh video. Frame pertama sebagai referensi untuk ekstraksi. Sedangkan frame kedua sampai terakhir sebagai target ekstraksi otomatis LVQ.

Hasil akurasi *mean* pada proses *supervised learning* pada Gambar 4.31. Akurasi *mean* pada proses *minor stroke* dengan *euclidean distance* digambarkan warna biru. Pengujian akurasi *minor stroke* dimulai pada frame kedua sampai lima puluh. Hasil akurasi *mean* pada frame 2 sebesar 60.96%, saat frame 6 sebesar 59.91%, kemudian saat frame 11 sebesar 63.09%, kemudian saat frame 16 sebesar 62.86%, dilanjutkan pengujian frame 21 sebesar 65.56%, saat frame 26 sebesar 63.58%,

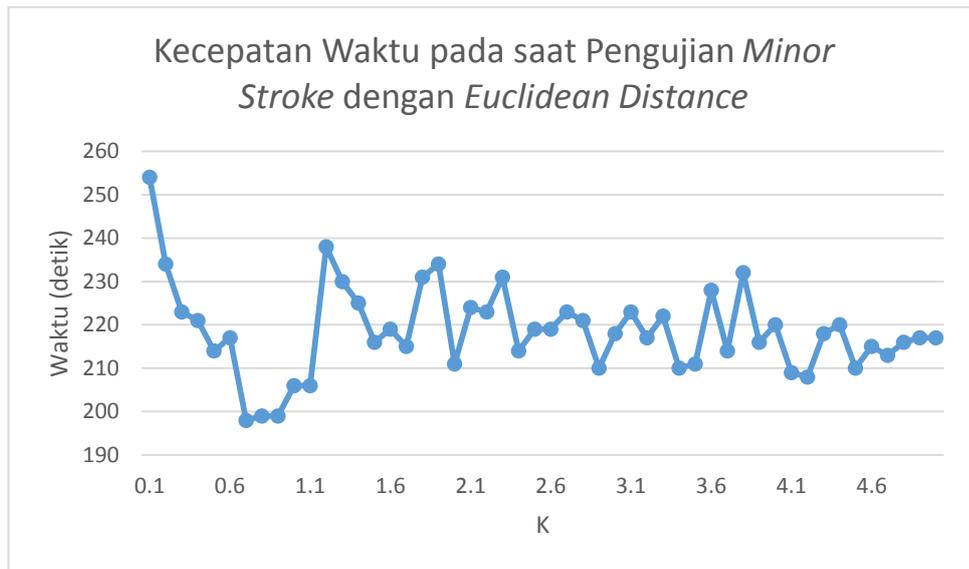
selanjutnya saat frame 31 sebesar 63.48%, kemudian frame 36 sebesar 63.05%, dilanjutkan frame 41 sebesar 63.75% dan frame 46 sebesar 64.85%. Hasil akurasi terbaik *minor stroke* saat frame 21 sebesar 65.56%. Sedangkan akurasi *minor stroke* terendah pada saat frame 5 sebesar 58.24%. Faktor yang mempengaruhi ekstraksi *object* saat frame 21 adalah proses rekaman video yang sudah stabil. Sedangkan frame 5 masih belum stabil.

Evaluasi kinerja *video minor stroke* dengan metrik *euclidean distance* menggunakan *median*. Karena hasil evaluasi *video minor stroke* tidak terpengaruh oleh data besar. Akurasi *median* pada proses pengujian setiap frame digambarkan warna orange. Hasil akurasi *median* terbaik saat frame 21 sebesar 71.45%. Sedangkan akurasi *median* terendah pada saat frame 5 sebesar 63.56%. Hasil grafik *mean* dan *median* pada proses pengujian *minor stroke* setiap frame terlihat polanya sama. Namun akurasinya lebih baik *daripada median*. Hasil akurasi dari pengujian *mean* atau *median* tidak maksimal karena pengaruh dari kualitas *video minor stroke* yang diambil oleh orang yang terkena stroke. Sehingga kualitas *video minor stroke* saat diekstraksi tidak maksimal.

Gambar 4.32 merupakan hasil pengujian kecepatan waktu pada saat pengujian *video minor stroke* dengan metrik *euclidean distance*. Pengujian *video minor stroke* dilakukan pada proses akurasi *mean unsupervised learning*, *mean supervised learning* dan *median supervised learning*. Pengujian *video minor stroke* dilakukan dengan variasi $K=0.1$ sampai $K=5$. Jumlah variasi K yang diujikan sebanyak lima puluh.

4.15 Kecepatan Waktu pada saat Pengujian *Minor Stroke* dengan *Euclidean Distance*

Hasil pengujian kecepatan waktu pada Gambar 4.32 digambarkan grafik warna biru. Pengujian video *Minor Stroke* dengan *euclidean distance* saat $K=0.1$ dibutuhkan waktu 254 detik, saat pengujian $K=0.6$ memerlukan waktu 217 detik,

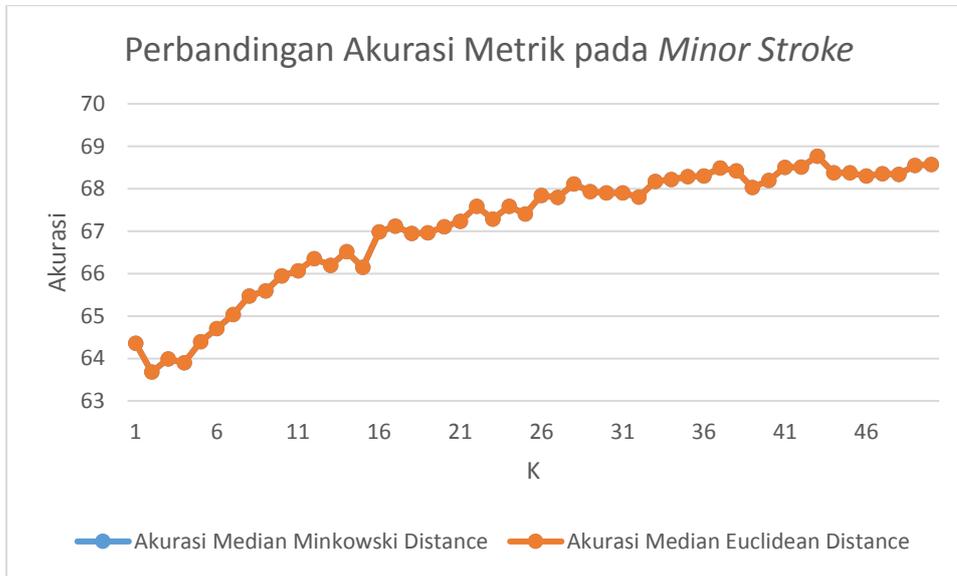


Gambar 4. 32 Kecepatan Waktu saat Pengujian *Minor Stroke* dengan *Euclidean Distance* dengan $P=2$.

kemudian saat pengujian $K=2.1$ memerlukan waktu 224 detik, selanjutnya saat $K=2.6$ membutuhkan waktu 219 detik, selanjutnya saat $K=3.1$ memerlukan waktu 223 detik, saat pengujian $K=3.6$ membutuhkan waktu 228 detik, kemudian saat $K=4.1$ memerlukan waktu 209 detik dan ketika $K=4.6$ membutuhkan waktu 215 detik. Terlihat pada Gambar 4.36, grafik yang pertama naik kemudian turun dan saat $k=1.1$ sampai $K=4.6$ stabil. Hasil pengujian *video minor stroke* dengan *euclidean distance* tercepat memerlukan waktu detik. Sedangkan waktu terlama pengujian *video minor stroke* dengan *euclidean*.

Hasil grafik pada Gambar 4.32 dipengaruhi oleh nilai konstanta (K) dan nilai parameter P pada metrik *minkowski distance*. Hasil akurasi *minor stroke* terlihat pada saat $K=0.1$ malah waktu terlama dibandingkan dengan $K=0.6$ sampai $K=4.3$. Karena pengaruh dari nilai yang tidak bulat dan parameter $P=2$ jika diproses dengan bilangan tidak bulat pada K akan menghasilkan waktu yang lama. Akurasi terbaik pada proses *video minor stroke* dengan metrik *euclidean* memerlukan waktu 218 detik pada $K=4.3$. Sedangkan akurasi *minor stroke* terendah membutuhkan waktu 234 detik pada $K=0.2$.

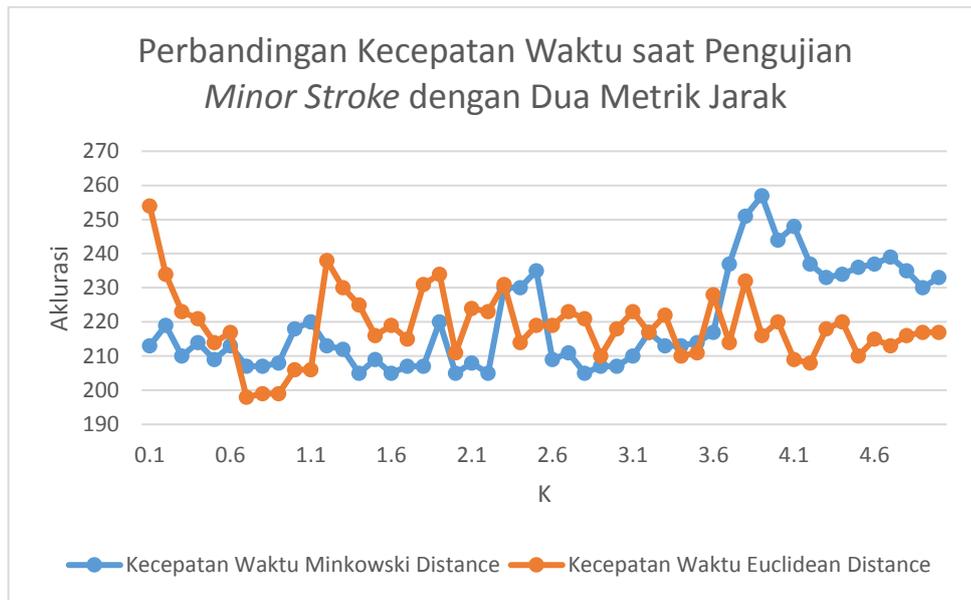
4.16 Perbandingan Akurasi *Minor Stroke Extraction* dengan *Minkowski* dan *Euclidean Distance*



Gambar 4. 33 Perbandingan Akurasi Metrik pada *Minor Stroke*

Gambar 4.33 merupakan hasil perbandingan dari akurasi metrik pada *video minor stroke extraction*. Pengujian *minor stroke* dilakukan dengan metrik *minkowski* dan *euclidean distance*. Cara pengujian *video minor stroke extraction* dengan variasi nilai konstanta (K). Jumlah parameter K yang diujikan sebanyak lima puluh. Nilai K dimulai dari K=0.1 sampai K=5.

Grafik warna biru menggambarkan akurasi *minor stroke* pada proses *minkowski distance*. Hasil akurasi terlihat semakin besar nilai K, maka akurasi semakin naik. Sebaliknya jika nilai K kurang, maka akurasi rendah. Hal ini menandakan bahwa perubahan warna pada frame *video minor stroke* adalah lebih cepat. Akurasi terbaik *minor stroke* pada proses *median minkowski distance* sebesar 68.76% pada K=4.3. Sedangkan akurasi *video minor stroke extraction* terendah pada proses *median minkowski distance* sebesar 63.68%. Akurasi *video minor stroke extraction* pada proses *median euclidean distance* digambarkan warna orange. Akurasi *median* yang dihasilkan saat K=0.1 sampai K=10 adalah rendah. Sedangkan saat akurasi *median* saat K>10 adalah tinggi. Semakin tinggi nilai K, maka akurasi *minor stroke* yang dihasilkan semakin tinggi. Sedangkan apabila nilai K rendah, maka akurasi *minor stroke* juga rendah pada kasus *minor stroke*.



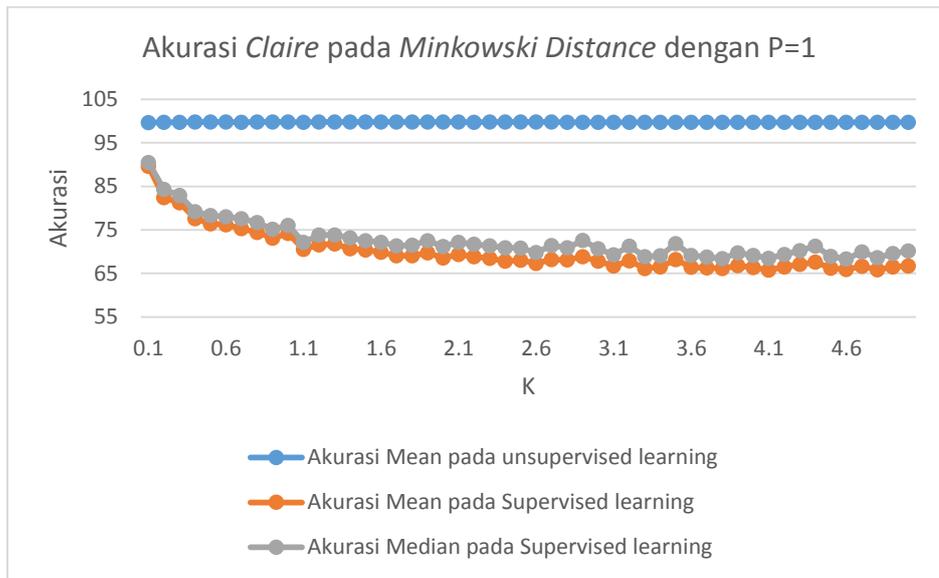
Gambar 4. 34 Perbandingan Kecepatan Waktu saat Pengujian *Minor Stroke* dengan Metrik Jarak *Minkowski* dan *Euclidean Distance*

Padahal metrik yang digunakan pada proses *vector quantization* berbeda. Hal ini disebabkan oleh parameter K dan P yang berada pada titik optimal yang sama. Sedangkan akurasi yang diperoleh tidak maksimal karena pengaruh dari hasil rekaman video yang tidak stabil.

4.17 Perbandingan Kecepatan Waktu pada saat Pengujian *Minor Stroke* dengan *Minkowski* dan *Euclidean Distance*

Gambar 4.34 adalah hasil perbandingan kecepatan waktu pada metrik *minor stroke*. *Video minor stroke* diuji dengan metrik *minkowski* dan *euclidean distance*. Variasi pengujian *video minor stroke* dengan nilai konstanta (K). Jumlah variasi K yang diujikan sebanyak lima puluh. Parameter K yang diujikan dari K=0.1 sampai K=5.

Grafik warna biru menggambarkan waktu yang diperlukan untuk *minkowski distance* pada Gambar 4.34. Pengujian *minor stroke* pada proses metrik *minkowski distance* yang paling cepat memerlukan waktu 205 detik pada K=(1.4, 1.6, 2, 2.2 dan 2.8). Sedangkan waktu terlama membutuhkan 257 detik pada K=3.9. Karena metrik *minkowski distance* terdapat parameter P. Nilai pangkat semakin tinggi pada P, maka proses perpangkatan dan akar semakin lama.

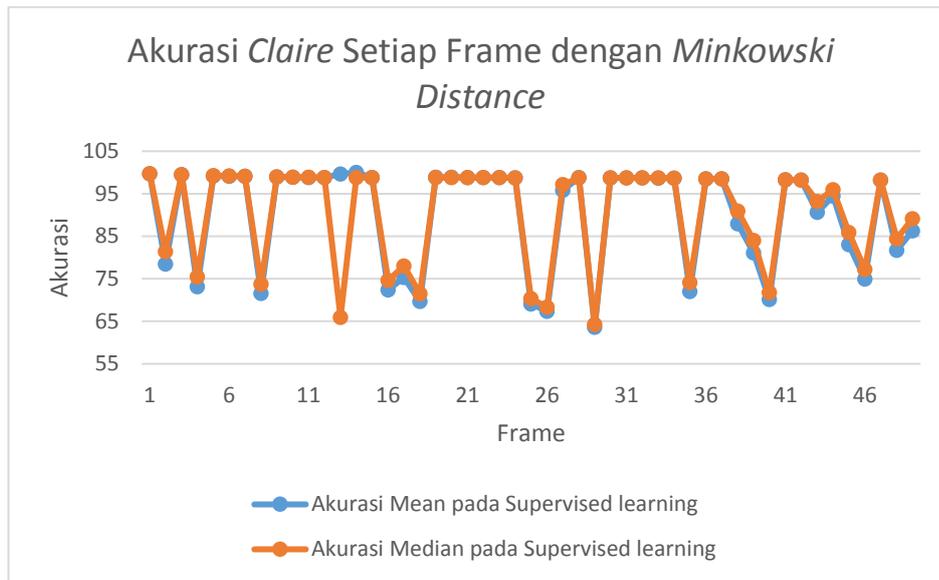


Gambar 4. 35 Akurasi *claire* pada proses metrik *Minkowski Distance* dengan $P=1$ Sebaliknya jika nilai parameter kecil, maka lebih cepat. Selain itu, metrik *minkowski distance* diuji dengan parameter $K=0.1$ sampai $K=5$ yang memerlukan waktu yang lama, bila nilai K tinggi.

Kecepatan waktu pada *video minor stroke* pada proses metrik *euclidean distance* digambarkan grafik orange. Hasil yang diperoleh saat pengujian kecepatan waktu saat $K=0.1$ memerlukan waktu yang lama. Sebaliknya saat nilai $K>0.1$ sampai $K=1.1$ lebih cepat. Ketika nilai $K>1.1$ maka memerlukan waktu penyelesaian yang lama. Waktu yang tercepat *video minor stroke* pada proses *euclidean distance* adalah 198 detik pada $K=0.7$. Sedangkan waktu yang lama memerlukan 254 detik pada $K=0.1$. Hasil pengujian kecepatan waktu metrik *euclidean* lebih cepat daripada *minkowski distance*. Karena metrik *euclidean distance* tidak terdapat parameter P .

4.18 Hasil Akurasi *Claire Extraction* dengan *Minkowski Distance*

Gambar 4.35 adalah hasil akurasi *video claire* pada proses metrik *minkowski distance* dengan parameter $P=1$. *Video claire* diuji dengan variasi nilai $K=0.1$ sampai $K=5$. Jumlah variasi pengujian sebanyak lima puluh. Evaluasi pengujian *video claire* terbagi menjadi tiga bagian. Pertama evaluasi kinerja akurasi



Gambar 4. 36 Akurasi *Claire* Setiap Frame dengan *Minkowski Distance* $P=1$ *mean* pada proses *unsupervised learning*. Kedua evaluasi kinerja akurasi *mean* pada proses *supervised learning*. Ketiga evaluasi kinerja akurasi *median* pada proses *supervised learning*. Evaluasi kinerja akurasi *mean* saat proses *unsupervised learning* digambarkan warna biru. Grafik warna biru menunjukkan bahwa saat $K=0.1$ sampai $K=5$ cenderung akurasi stabil berkisar 99%. Kinerja *vector quantization* dengan metrik *minkowski distance* berjalan maksimal.

Akurasi *mean* pada proses *supervised learning* digunakan dalam proses *pixel wise classification*. Hasil akurasi ini digambarkan warna orange pada Gambar 4.35. Dari grafik warna orange terlihat akurasi tinggi saat $K=0.1$. Sedangkan saat kondisi $K>0.1$ terlihat akurasi semakin menurun. Karena *video claire* saat perpindahan warna pada frame cenderung lambat. Sehingga akurasi terbaik sebesar 85.59% pada $K=0.1$. Sedangkan akurasi terendah sebesar 66.22% pada $K=4.5$.

Hasil evaluasi *median* digunakan dalam pengukuran kinerja *claire*. Karena evaluasi *median* tidak terpengaruh oleh data yang besar. Hasil evaluasi kinerja *claire* pada proses akurasi *median supervised learning* digambarkan warna abu-abu. Hasil akurasi terlihat ketika maksimal pada $K=0.1$ sebesar 90.49%. Sedangkan akurasi minimum sebesar 68.93% pada $K=4.5$. Hasil kinerja *claire* menggunakan metrik *minkowski* dapat maksimal 90% karena faktor parameter optimasi P dan K . Selain itu, karena kualitas rekaman *video claire* baik.

Gambar 4.36 merupakan hasil akurasi *claire* setiap frame dengan metrik *minkowski distance* pada $K=0.1$. Pengujian *claire* dengan jumlah frame sebanyak lima puluh. Frame pertama sebagai referensi ekstraksi oleh bantuan manusia. Hasil ekstraksi frame pertama digunakan untuk proses *supervised learning*. Frame kedua sampai frame lima puluh sebagai target ekstraksi oleh LVQ.

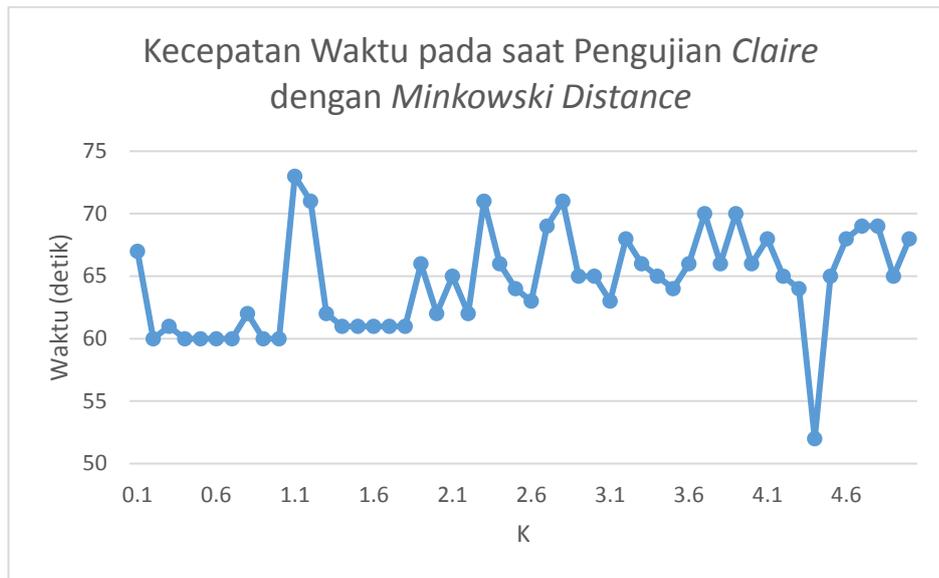
Evaluasi kinerja *claire* setiap frame pada proses *mean supervised learning* digambarkan warna biru. Grafik tersebut terlihat akurasi optimal di atas 90%. Namun ada pula yang turun sampai di bawah 70%. Saat frame ke 2 sebesar 99.74%, frame ke 6 sebesar 99.22%, frame ke 11 sebesar 98.89%, frame ke 16 sebesar 98.82%, frame ke 21 sebesar 98.86%, frame ke 26 sebesar 69.05%, frame ke 31 sebesar 98.74%, frame 36 sebesar 72%, frame 41 sebesar 70.13% dan frame 46 sebesar 83.03%. Akurasi *mean* terbaik sebesar 99.74% pada frame ke 2. Sedangkan akurasi *mean* terendah sebesar 63.63% pada frame 30. Akurasi *video claire* dapat maksimal, sebab dipengaruhi oleh kualitas pengambilan video setiap framenya.

Akurasi *median* pada *supervised learning* digambarkan grafik warna orange. Evaluasi *median* digunakan untuk mengantisipasi evaluasi data yang besar. Hasil akurasi *median supervised learning* terlihat optimal 90% pada beberapa frame. Namun ada pula frame yang akurasi median-nya turun sampai 65%. Saat frame ke 2 sebesar 81.39%, frame ke 6 sebesar 99.24%, frame ke 11 sebesar 98.90%, frame ke 16 sebesar 98.83%, frame ke 21 sebesar 98.84%, frame ke 26 sebesar 70.36%, frame ke 31 sebesar 98.74%, frame 36 sebesar 74.14%, frame 41 sebesar 71.80% dan frame 46 sebesar 83.03%. Akurasi terbaik proses *median* sebesar 99.72% pada frame ke 2. Sedangkan akurasi *median* terendah sebesar 85.92% pada frame 30. Akurasi *video claire* maksimal karena pengaruh dari nilai parameter P pada metrik *minkowski distance*. Selain itu, karena nilai K yang kecil mempengaruhi dalam ekstraksi otomatis oleh LVQ.

4.19 Kecepatan Waktu pada saat Pengujian Claire dengan Minkowski

Distance

Gambar 4.37 adalah hasil pengujian kecepatan waktu pada saat *video claire extraction* (VCE) dengan *minkowski*. Nilai parameter yang dipergunakan dalam metrik *minkowski distance* adalah $P=1$.

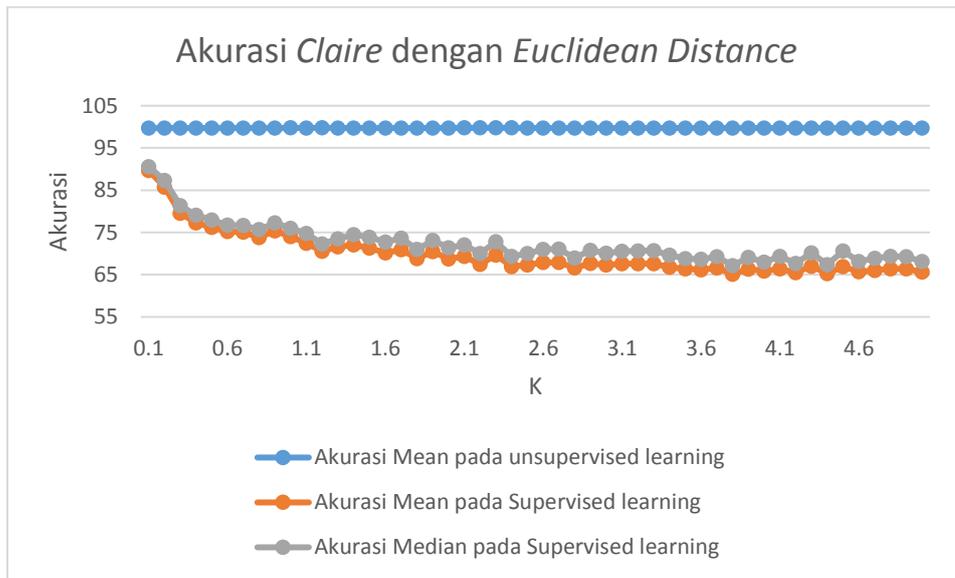


Gambar 4. 37 Kecepatan Waktu pada saat Pengujian *Claire* dengan *Minkowski Distance* P=1

Pengujian *claire* dengan metrik *minkowski distance* meliputi proses *mean unsupervised learning*, *mean supervised learning* dan *median supervised learning*. Variasi pengujian *claire* menggunakan konstanta $K=0.1$ sampai $K=5$. Jumlah variasi yang diujikan sebanyak lima puluh.

Gambar grafik warna biru pada Gambar 4.37 merupakan hasil pengujian kecepatan waktu pada *video claire extraction* (VCE). Saat nilai konstanta $K=0.1$ memerlukan waktu 67 detik. Selanjutnya saat $K=0.6$ memerlukan waktu 60 detik. Kemudian percobaan saat $K=1.1$ membutuhkan waktu 73 detik. Saat konstanta $K=1.6$ memerlukan waktu 61 detik. Pengujian VCE dilanjutkan saat $K=2.1$ membutuhkan waktu 63 detik. Selanjutnya untuk pengujian VCE pada $K=2.6$ memerlukan waktu 63 detik. Percobaan VCE selanjutnya saat $K=3.1$ membutuhkan 63 detik. Kemudian VCE saat konstanta $K=3.6$ membutuhkan waktu 66 detik. Saat VCE berada pada konstanta $K=4.1$ memerlukan waktu 68%. Saat pengujian VCE pada $K=4.6$ membutuhkan waktu 68 detik. Nilai K semakin tinggi akan mempengaruhi waktu penyelesaian VCE. Namun ada kondisi K semakin tinggi waktu penyelesaian lebih cepat.

Hasil pengujian kecepatan waktu VCE tercepat 52 detik pada $K=4.4$. Sedangkan waktu pengujian paling lama 73 detik pada $K=1.1$.



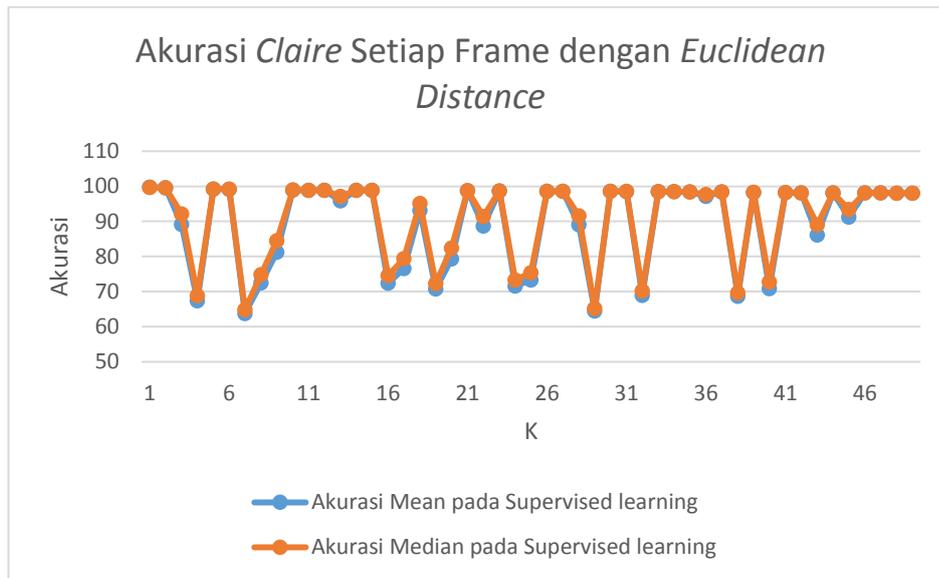
Gambar 4. 38 Akurasi *Claire* dengan *Euclidean Distance*

Faktor yang mempengaruhi dari waktu pengujian VCE adalah ukuran *video claire*, kerumitan dalam memisahkan *foreground* dengan *background* secara otomatis, gerakan dari *object claire* yang terlalu cepat dan akan meleset saat pemisahaan dari *background*, nilai parameter K dan P pada metrik *minkowski distance*.

4.20 Hasil Akurasi *Claire Extraction* dengan *Euclidean Distance*

Gambar 4.38 adalah hasil akurasi *video claire extraction* (VCE) dengan metrik *euclidean distance*. Evaluasi pengujian *video claire extraction* terbagi menjadi tiga bagian. Evaluasi pertama untuk akurasi *mean* pada *unsupervised learning*. Evaluasi kedua untuk akurasi *mean* pada *supervised learning*. Evaluasi ketiga untuk akurasi *median* pada *supervised learning*.

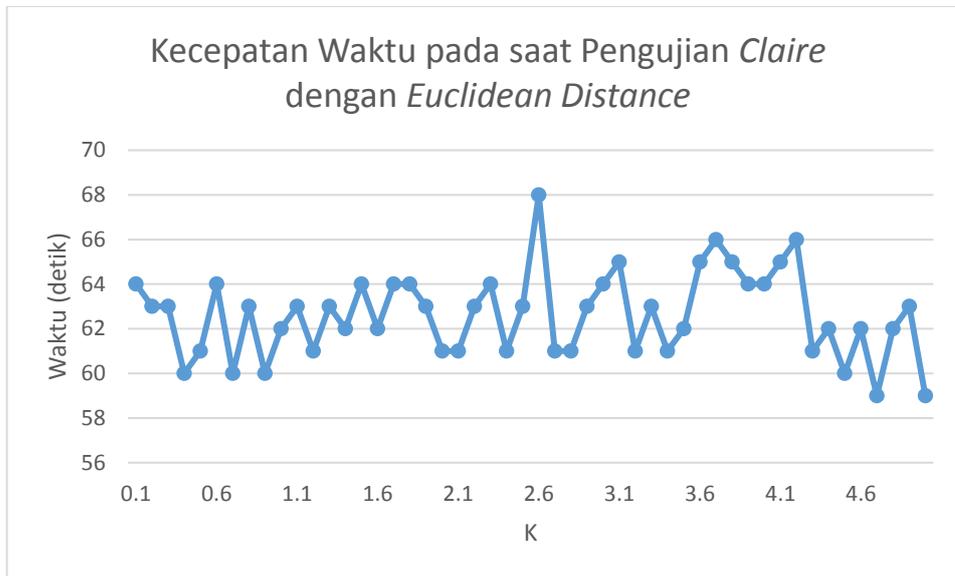
Hasil akurasi *vector quantization* (VQ) atau proses *unsupervised learning* yang digambarkan warna biru. Hasil VQ terlihat stabil sebesar 99% dari K=0.1 sampai K=5. Hal ini dipengaruhi oleh frame pertama yang sudah diekstraksi manual dengan bantuan manusia. Sehingga saat proses VQ tinggal mengelompokan *object* dan *non-object* untuk proses *supervised learning*. Berbeda jika VQ tidak dibantu oleh manusia pada frame pertama terlebih dahulu. Hasil ekstraksi berikutnya kurang maksimal.



Gambar 4. 39 Akurasi *Claire* Setiap Frame dengan *Euclidean Distance*

Grafik warna orange merupakan hasil akurasi *mean* pada proses *supervised learning* pada Gambar 4.38. Proses akurasi ini bekerja setelah *pixel wise classification*. Hasil akurasi *claire extraction* terlihat saat $K=0.1$ maksimal. Sedangkan saat $K>0.1$ maka hasil akurasi *claire extraction* menurun. Hal ini dipengaruhi parameter konstanta dan proses perpindahan warna pada frame. Dari hasil akurasi pada $K=0.1$ terlihat bahwa saat pergeseran warna sangat pelan. Sehingga memerlukan nilai parameter K yang rendah. Akurasi *median* pada *supervised learning* digunakan untuk perbandingan evaluasi akurasi *mean*. Karena hasil akurasi *mean* terpengaruhi oleh data *pixel* yang besar. Akurasi *median* pada proses *supervised learning* digambarkan grafik warna abu-abu. Hasil akurasi *claire* maksimal sebesar 90.59% pada $K=0.1$. Sedangkan akurasi *claire* terendah sebesar 67.17% pada $K=3.8$.

Gambar 4.39 adalah hasil akurasi *video claire extraction* (VCE) setiap frame dengan metrik *euclidean distance*. Pengujian VCE digunakan untuk mengetahui akurasi maksimal pada frame video. *Video claire extraction* diuji setiap frame dengan *euclidean distance* pada nilai konstanta $K=0.1$. Nilai parameter K yang dipilih berdasarkan akurasi yang optimal. Pengujian VCE frame dimulai dari frame pertama sampai frame lima puluh. Frame pertama digunakan untuk frame referensi. Sedangkan frame kedua sampai ke frame lima puluh untuk target ekstraksi oleh LVQ.



Gambar 4. 40 Kecepatan Waktu pada Saat Pengujian *Claire* dengan *Euclidean Distance*

Grafik warna biru pada Gambar 4.39 menggambarkan akurasi *mean* pada proses *supervised learning*. Hasil pengujian akurasi *mean* terhadap frame terlihat naik turun. Ada akurasi *claire* tinggi pada proses *mean supervised learning*. Namun adapula yang berada pada akurasi rendah. Akurasi *mean supervised learning* terbaik sebesar 99.75% pada frame ke 2. Sedangkan akurasi *claire extraction* terendah sebesar 99.18% pada frame ke 7. Frame ke 2 maksimal terpengaruh oleh kondisi ekstraksi awal yang *error*-nya masih rendah. Sehingga saat frame ke 7 mulai *error*-nya paling tinggi. Dengan adanya hasil akurasi tiap frame ini, maka *video claire extraction* kualitas setiap framenya dapat terlihat.

Akurasi *median* pada proses *supervised learning* digunakan untuk mengevaluasi kinerja *claire* dengan metrik *euclidean distance*. Karena hasil akurasi *mean* kurang maksimal. Hasil akurasi *median* pada proses *supervised learning* digambarkan grafik warna orange. Hasil akurasi *claire extraction* setiap frame terlihat turun dan naik. Akurasi *claire extraction* diatas 90 % terlihat lebih banyak daripada di bawahnya. Akurasi *median* terbaik sebesar 99.72% pada frame 2. Sedangkan akurasi *claire extraction* terendah sebesar 99.21%. Hasil akurasi *median* dapat maksimal dibebberapa frame. Karena pengaruh dari hasil rekaman video *claire*. Terlihat dibebberapa frame, akurasi *claire* dapat maksimal 90%.

4.21 Kecepatan Waktu pada saat Pengujian *Claire* dengan *Euclidean*

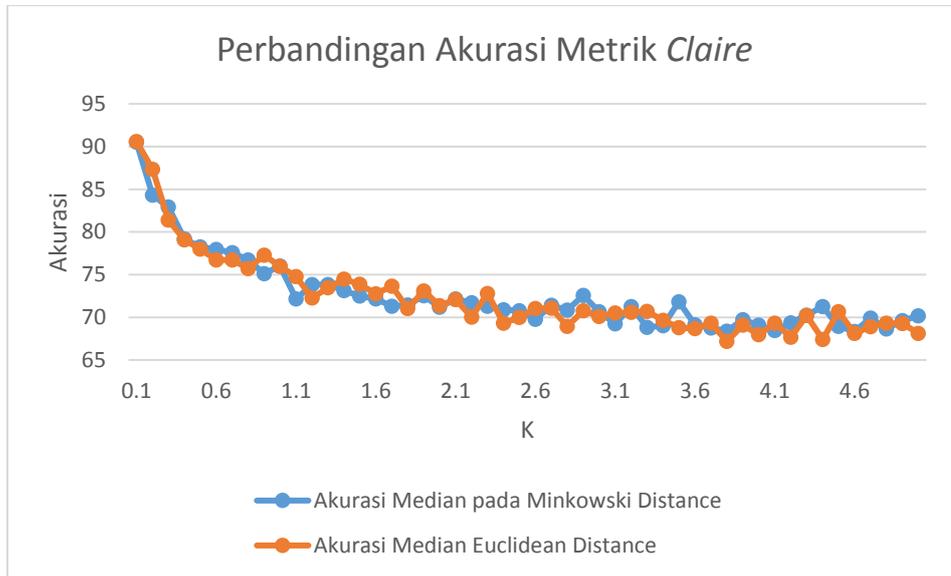
Distance

Gambar 4.40 adalah hasil pengujian kecepatan waktu pada *video claire extraction* (VCE) dengan metrik *euclidean distance*. Pengujian kecepatan waktu pada VCE dengan variasi konstanta (K) sebanyak lima puluh. Parameter K terdiri dari K=0.1 sampai K=5. Evaluasi pengujian VCE berisi *mean unsupervised learning*, *mean supervised learning* dan *median supervised learning*.

Grafik warna biru menggambarkan hasil pengujian kecepatan waktu pada *video claire extraction* dengan metrik *euclidean distance* pada Gambar 4.40. Waktu yang diperlukan VCE untuk menyelesaikan 64 detik pada K=0.1. Kemudian, VCE saat pengujian K=0.6 memerlukan waktu 64 detik. Saat percobaan VCE pada K=1.1 membutuhkan waktu 63 detik. Kemudian dilanjutkan percobaan VCE saat K=1.6 membutuhkan waktu 62 detik. Saat VCE pada K=2.1 diperlukan waktu 61 detik. Selanjutnya saat VCE pada K=2.6 membutuhkan waktu 68 detik. Saat VCE pada K=3.1 membutuhkan waktu 65 detik. Selanjutnya saat VCE pada K=3.1 memerlukan waktu 65 detik. Selanjutnya saat VCE pada K=3.6 membutuhkan 65 detik. Sedangkan saat VCE pada K=4.1 memerlukan waktu 65 detik. Saat kondisi pengujian VCE pada K=4.6 memerlukan 62 detik. Waktu yang dibutuhkan VCE paling cepat 59 detik pada K=4.7 dan K=5. Sedangkan waktu VCE yang terlama 68 detik pada K=2.6.

Kondisi pengujian *video claire extraction* saat K tertinggi malah semakin cepat. Sedangkan saat K berada kondisi tengah malah lebih lama. Hal ini dipengaruhi oleh pengukuran jarak antar *codebook vector* yang berada pada kelipatan K tertinggi. Selain itu, pengaruh dari ukuran video yang dipergunakan dalam pengukuran akurasi akan mempengaruhi waktu tempuhnya. *Object video claire* yang tidak terlalu rumit mempengaruhi kinerja sistem untuk menyelesaikan lebih cepat. Apabila *object video* rumit untuk diekstrak, maka memerlukan waktu yang lama.

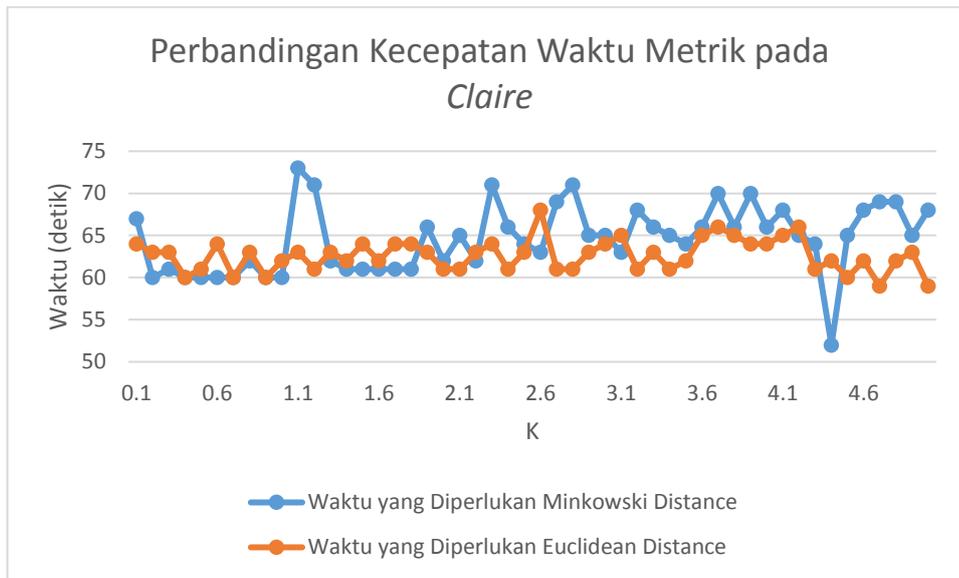
4.22 Perbandingan Akurasi *Claire Extraction* dengan *Minkowski* dan *Euclidean Distance*



Gambar 4. 41 Perbandingan Akurasi Metrik *Claire*

Gambar 4.41 adalah hasil perbandingan akurasi VCE dengan metrik *minkowski* dan *euclidean distance*. Perbandingan akurasi metrik pada VCE bertujuan untuk menguji kinerja metrik *minkowski distance*. *Video claire extraction* diuji dengan variasi K sebanyak lima puluh. Parameter K dimulai dari K=0.1 sampai K=5. Akurasi *median* pada *minkowski distance* digambarkan grafik warna biru pada Gambar 4.41. Hasil akurasi terlihat maksimal pada saat K=0.1 sebesar 90.49%. Sedangkan saat akurasi minum pada K=3.8 sebesar 68.37%. Hasil akurasi rata-rata dari K=0.1 sampai K=5 sebesar 72.49%. Hasil akurasi *median* dengan metrik *minkowski distance* dipengaruhi oleh parameter P. Semakin rendah nilai Parameter P pada metrik *minkowski distance*, maka akurasi naik pada kasus *claire*. Sebaliknya jika nilai parameter P turun, maka akurasi rendah pada kasus VCE. Selain hal tersebut, terdapat parameter K sebagai parameter optimasi. Fungsi K digunakan untuk mempercepat atau memperlambat perubahan warna saat perpindahan frame. Sehingga hasil ekstraksi otomatis oleh LVQ dapat maksimal.

Warna orange pada Gambar 4.41 menggambarkan hasil akurasi *median* pada metrik *euclidean distance*. Hasil akurasi VCE maksimal saat nilai K=0.1 sebesar 90.59%. Sedangkan akurasi VCE minimal saat nilai K=3.8 sebesar 67.17%.



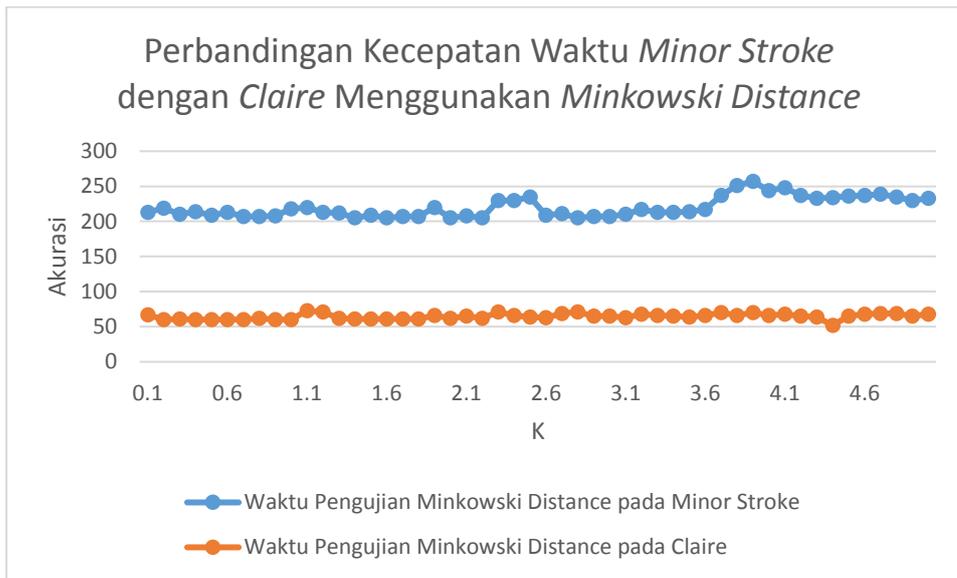
Gambar 4. 42 Perbandingan Kecepatan Waktu Metrik pada Claire

Hasil akurasi VCE maksimal lebih besar pada metrik *euclidean distance* sebesar 90.59% daripada metrik *minkowski distance*. Sedangkan parameter K yang optimal pada kedua metrik yang diujikan sama K=0.1. Untuk akurasi *claire extraction* terendah lebih besar metrik *minkowski* dibanding metrik *euclidean distance*. Hasil akurasi *claire extraction* terendah pada kedua metrik berada pada K=3.8.

4.23 Perbandingan Kecepatan waktu pada saat Pengujian Claire dengan Minkowski dan Euclidean Distance

Gambar 4.42 adalah hasil perbandingan pengujian kecepatan waktu metrik pada VCE. Hasil pengujian kecepatan waktu metrik *claire* meliputi *mean unsupervised learning*, *mean supervised learning* dan *median supervised learning*. VCE diuji dengan variasi K sebanyak lima puluh kali. Parameter K dimulai dari K=0.1 sampai K=5. Tujuan perbandingan pengujian kecepatan waktu metrik saat pengujian VCE. Untuk mengetahui kecepatan waktu penyelesaian dari kedua metrik tersebut.

Grafik warna biru merupakan hasil kecepatan waktu mengekstrak VCE dengan metrik *minkowski distance*. Hasil waktu tercepat 52 detik saat K=4.4 pada kecepatan waktu metrik *minkowski distance*. Sedangkan waktu terlama 73 detik saat K=1.1 pada saat pengujian kecepatan waktu *minkowski distance*.



Gambar 4. 43 Perbandingan Kecepatan Waktu *Minor Stroke* dengan *Claire* Menggunakan *Minkowski Distance*

Nilai rata-rata waktu untuk metrik *minkowski distance* 64.54 detik. Faktor yang mempengaruhi kecepatan waktu penyelesaian ekstraksi adalah parameter P dan K. Saat parameter P di metrik *minkowski* rendah, maka akan lebih cepat. Sedangkan jika nilai parameter P tinggi maka akan lebih lama. Selain hal tersebut, parameter konstanta (K) mempengaruhi dalam penyelesaiannya ekstraksi *claire* dengan metrik *minkowski*. Hasil pengujian kecepatan waktu *euclidean distance* pada Gambar 4.42 digambarkan wana orange.

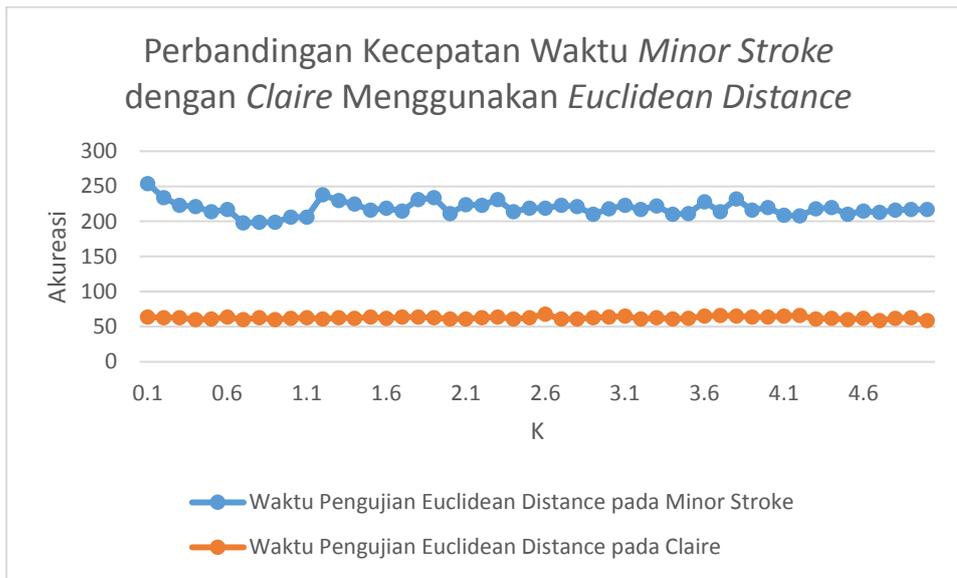
Hasil pengujian kecepatan waktu *euclidean distance* terlihat lebih stabil di atas 55 detik. Waktu tercepat untuk menyelesaikan ekstraksi *claire* dengan metrik *euclidean distance* 59 detik pada K=4.7 dan K=5. Sedangkan waktu terlama menyelesaikan ekstraksi *claire* 68 detik pada K=2.6. Rata-rata waktu untuk metrik *euclidean distance* 62.62 detik. Rata-rata waktu metrik *euclidean distance* lebih cepat 62.62 detik daripada *minkowski distance*. Namun untuk waktu tercepat 52 detik pada saat K=4.4, metrik *minkowski distance* lebih unggul. Faktor yang mempengaruhi kecepatan waktu adalah parameter P metrik *minkowski* dan K.

4.24 Perbandingan Kecepatan Waktu pada saat Pengujian *Minor Stroke* dengan *Claire Extraction*

Gambar 4.43 hasil perbandingan kecepatan waktu minor stroke dengan *video claire extraction* (VCE) saat menggunakan metrik *minkowski distance*. Pengujian video minor stroke (VME) dan *claire* menggunakan variasi konstanta K sebanyak lima puluh. Parameter K dimulai dari K=0.1 sampai K=5. Gambar 4.47 berisi informasi waktu pengujian VME dan VCE. Tujuan dari perbandingan ini untuk mengetahui waktu pengujian tercepat atau terlama saat menggunakan kedua metrik.

Grafik warna biru pada Gambar 4.43 adalah hasil pengujian kecepatan waktu metrik *minkowski distance* dengan *video minor stroke extraction*. Hasil pengujian waktu tercepat memerlukan 205 detik pada K=1.4, K=1.6, K=2, K=2.2 dan K=2.8. Sedangkan pengujian waktu terlama memerlukan waktu 219 detik pada K=0.2. Semakin tinggi nilai K tidak mempengaruhi lama penyelesaian. Sedangkan nilai K menengah akan mempengaruhi waktu penyelesaian cepat. Hal ini dipengaruhi oleh parameter P genap, jika dikalikan bilangan genap menghasilkan hasil yang genap. Sehingga proses komputasi perkalian lebih cepat. Hasil rata-rata waktu pengujian K=0.1 sampai K=5 memerlukan waktu 220.06 detik.

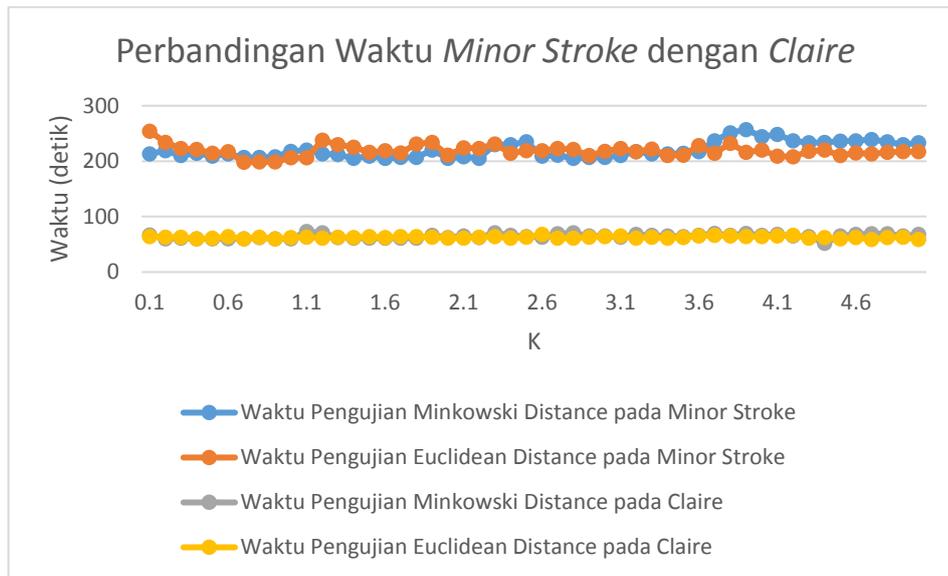
Waktu pengujian kecepatan metrik *minkowski distance* pada *video claire extraction* digambarkan warna orange pada Gambar 4.43. Hasil waktu tercepat saat pengujian memerlukan waktu 52 detik. Sedangkan waktu terlama saat penyelesaian 73 detik. Hasil waktu rata-rata pengujian VCE dari K=0.1 sampai K=5 memerlukan waktu 64.54 detik. Pengujian VCE lebih cepat daripada video VME. Karena hasil rekaman *video minor stroke* kurang stabil. Sehingga mempengaruhi saat ekstraksi *object*. *Video claire* lebih unggul dalam penyelesaian rata-rata daripada *video minor stroke*. Karena pengaruh kualitas dari *video* tersebut.



Gambar 4. 44 Perbandingan Kecepatan Waktu *Minor Stroke* dengan *Claire* Menggunakan *Euclidean Distance*

Gambar 4.44 adalah hasil perbandingan waktu pengujian *video minor stroke extraction* (VME) dengan *video claire extraction* (VCE). Kedua video yang diujikan menggunakan metrik *euclidean distance*. Tujuan dari pengujian kecepatan waktu *video minor stroke extraction* maupun *video claire extraction* untuk mengetahui kecepatan penyelesaian dari ekstraksi. Gambar 4.44 berisi informasi pengujian *video minor stroke extraction* dan *video claire extraction* dengan metrik *minkowski distance*.

Hasil pengukuran kinerja *video minor stroke extraction* dengan metrik *euclidean distance* yang digambarkan warna biru pada Gambar 4.44. Hasil kecepatan waktu terlihat lama saat $K=0.1$. Ketika pengujian *video minor stroke extraction* berada $K>0.1$ beransur-ansur lebih cepat. Hasil pengujian *video minor stroke extraction* tercepat membutuhkan waktu 198 detik pada $K=0.7$. Sedangkan waktu penyelesaian VME terlama membutuhkan waktu 254 detik pada $K=0.1$. Hasil pengujian waktu *video minor stroke extraction* rata-rata memerlukan waktu 218.56 detik. *Video minor stroke extraction* dengan *euclidean distance* memerlukan waktu lama. Karena pengaruh dari kualitas pengambilan *video minor stroke extraction* yang tidak stabil. Sehingga saat ekstraksi *foreground* dengan *background* pada frame memerlukan waktu lama.



Gambar 4. 45 Perbandingan Kecepatan Waktu *Minor Stroke* dengan *Claire*

Grafik warna orange menggambarkan hasil pengujian kecepatan waktu *video claire extraction* dengan metrik *euclidean distance*. Hasil pengujian *video claire extraction* terlihat memerlukan waktu yang stabil 50 detik. Hasil pengujian *video claire extraction* dengan metrik *euclidean distance* memerlukan waktu tercepat 59 detik pada $K=4.7$ dan $K=5$. Sedangkan waktu pengujian *video claire extraction* pada metrik *euclidean distance* terlama memerlukan waktu 68 detik pada $K=2.6$. Hasil waktu rata-rata *video claire extraction* dari $K=0.1$ sampai $K=5$, memerlukan waktu 62.62 detik. Hasil pengujian VCE dengan metrik *euclidean distance* lebih cepat daripada *video minor stroke extraction* dengan metrik *euclidean distance*. Hal ini dipengaruhi oleh parameter P pada metrik *minkowski distance*. Sehingga proses *video claire extraction* memakan waktu lama.

Gambar 4.45 adalah hasil perbandingan waktu *video minor stroke extraction* dengan *video claire extraction*. Tujuan dari perbandingan kecepatan waktu untuk mengetahui waktu tercepat dalam menyelesaikan ekstraksi. Pengujian *video minor stroke extraction* menggunakan variasi K sebanyak lima puluh. Parameter K dimulai dari $K=0.1$ sampai $K=5$.

Hasil pengujian kecepatan waktu *video minor stroke extraction* dengan metrik *minkowski distance* yang digambarkan warna biru pada Gambar 4.45. Hasil pengujian kecepatan waktu *video minor stroke extraction*, terlihat pada grafik

memerlukan waktu sekitar 200 detik. Hasil pengujian metrik *minkowski distance* tercepat pada *video minor stroke extraction*, memerlukan waktu 205 detik pada $K=1.4$, $K=1.6$, $K=2$, $K=2.2$ dan $K=2.8$. Sedangkan waktu terlama dalam penyelesaian *video minor stroke extraction* dengan *minkowski distance*, memerlukan waktu 257 detik pada $K=3.9$. Hasil rata-rata waktu pengujian *video minor stroke extraction* dari $K=0.1$ sampai $K=5$ dengan *minkowski distance* memerlukan waktu 220.06 detik.

Gambar grafik warna merah pada Gambar 4.45 menggambarkan hasil pengujian kecepatan waktu metrik *euclidean distance* pada *video minor stroke extraction*. Hasil pengujian *video minor stroke extraction* terlihat memerlukan waktu di atas 200 detik. Hasil pengujian *video minor stroke extraction* memerlukan waktu tercepat 198 detik pada $K=0.7$. Sedangkan waktu pengujian *video minor stroke extraction* terlama 254 detik pada $K=0.1$. Hasil rata-rata waktu pengujian *video minor stroke extraction* dari $K=0.1$ sampai $K=5$ dengan *minkowski distance* memerlukan waktu 218.56 detik.

Hasil pengujian waktu *video claire extraction* dengan *euclidean distance* yang digambarkan warna abu-abu pada Gambar 4.44. Hasil pengujian *video claire extraction* dengan *euclidean distance* terlihat memerlukan waktu kurang 100 detik. Hasil pengujian *video claire extraction* tercepat memerlukan waktu 52 detik pada $K=4.4$. Sedangkan waktu *video claire extraction* terlama memerlukan waktu 73 detik pada $K=11$. Hasil rata-rata pengujian waktu *video claire extraction* memerlukan waktu 64.54 detik.

Hasil pengujian *video claire extraction* dengan metrik *euclidean distance* yang digambarkan grafik warna kuning pada Gambar 4.45. Hasil pengujian waktu *video claire extraction* dengan metrik *euclidean distance* terlihat memerlukan waktu kurang 100 detik. Hasil pengujian waktu *video claire extraction* dengan metrik *euclidean distance* tercepat memerlukan 59 detik pada $K=4.7$ dan $K=5$. Sedangkan waktu terlama *video claire extraction* memerlukan 68 detik pada $K=2.6$. Hasil pengujian waktu rata-rata *video claire extraction* dengan metrik *euclidean distance* memerlukan 62.62 detik.

Hasil pengujian kecepatan waktu *video claire extraction* dengan metrik *minkowski distance* lebih cepat daripada *video minor stroke extraction* dengan

metrik *minkowski distance*. Hal ini dipengaruhi oleh kerumitan saat *object* yang diekstrak. Semakin mudah gerakan *object* diekstrak, maka proses pemisahan *object* dengan *non-object* lebih cepat. Sebaliknya jika ekstraksi *object* sulit, maka proses pemisahan *foreground* dengan *background* memerlukan waktu yang lebih lama.

Untuk hasil pengujian kecepatan waktu *video claire extraction* dengan metrik *euclidean distance* lebih cepat daripada *video minor stroke extraction* dengan metrik *euclidean distance*. Hal ini dipengaruhi oleh karakteristik dari pengambilan *video minor stroke extraction* yang kurang stabil. Karena saat pengambilan video diambil oleh orang yang terserang *minor stroke*. Orang yang terserang *minor stroke* mempunyai kerusakan kognitif. Sehingga gerakan tanganya saat pengambilan *video* kurang stabil.

Kecepatan waktu tercepat memerlukan 52 detik dalam pengujian *video claire extraction* dengan metrik *minkowski distance*. Hal ini sesuai dengan penelitian sebelumnya bahwa metrik *minkowski* lebih cepat daripada *euclidean distance*. Sedangkan waktu terlama memerlukan 257 detik saat pengujian pada proses *video minor stroke extraction* dengan *minkowski distance*. Untuk waktu rata-rata tercepat 62.62 detik pada proses *video claire extraction* dengan *euclidean distance*. Sedangkan kecepatan waktu rata-rata terlama 220.06 detik pada proses *video minor stroke extraction* dengan *minkowski distance*.

Halaman ini sengaja dikosongkan

BAB 5

PENUTUP

5.1 Kesimpulan

Video object extraction pada kasus *minor stroke* berbasis LVQ menggunakan metrik *minkowski distance* telah diuji. Hasil dari percobaan *video minor stroke extraction* meliputi optimasi parameter P pada metrik *minkowski* dan *euclidean distance*, pengujian kecepatan waktu optimasi, hasil *minor stroke* dan *claire extraction* pada metrik *minkowski* dan *euclidean distance*, perbandingan kecepatan saat pengujian *video minor stroke extraction* dengan *claire extraction*, hasil akurasi *video minor stroke extraction* dan *claire extraction*.

Hasil Optimasi maksimal P=2 pada *video minor stroke extraction* dengan metrik *minkowski distance*. Selain akurasi, pengujian kecepatan pada proses *video minor stroke extraction* dengan *minkowski distance* juga diperhitungkan. Waktu pengujian optimasi yang paling cepat 10 detik pada P=2. Sedangkan waktu pengujian optimasi paling lama 23 detik pada P=3.5. Hasil Optimasi maksimal P=1 pada *video claire extraction* dengan metrik *euclidean distance*. Waktu tercepat 6 detik pada pengujian optimasi *claire* dengan metrik *euclidean distance* P=1 dan P=2. Hasil akurasi *median claire* lebih unggul saat pencarian optimasi parameter P. Pengujian kecepatan *video claire extraction* lebih unggul daripada *video minor stroke extraction* saat proses pencarian optimasi *video claire*.

Hasil pengujian *minor stroke* dengan metrik *minkowski distance* terbaik pada K=4.3. Hasil *video minor stroke extraction* terbaik dengan metrik *euclidean distance* pada frame 21 pada K=4.3. Sedangkan hasil frame 5 pada K=4.3 merupakan terendah. Karena saat frame 21 masih belum stabil. Hasil pengujian *minor stroke* dengan metrik *euclidean distance* terbaik pada K=4.3. Hasil *video minor stroke extraction* terbaik dengan metrik *euclidean* pada frame ke 21 pada K=4.3. Sedangkan hasil frame kurang dari 21 adalah terendah. Karena saat frame lebih dari 21 sudah stabil. Hasil pengujian akurasi *video minor stroke* dengan metrik *minkowski distance* dan metrik *euclidean distance* adalah sama. Karena pengaruh parameter P dan K yang ketemu titik optimal.

Hasil pengujian *claire* dengan metrik *minkowski distance* terbaik pada $K=0.1$. Hasil *claire* terbaik dengan metrik *euclidean* pada frame 2 pada $K=0.1$. Sedangkan hasil frame 30 pada $K=0.1$ merupakan terendah. Karena saat frame 30, antara parameter P dan K tidak sinkron. Hasil pengujian *claire* dengan metrik *euclidean distance* terbaik pada $K=0.1$. Hasil *claire* terbaik dengan metrik *euclidean* pada frame 2 pada $K=0.1$. Sedangkan hasil frame 7 pada $K=0.1$ adalah terendah. Karena saat frame 7, antara perubahan warna perpindah frame tidak sinkron dengan parameter K.

Hasil pengujian *claire* dengan metrik *minkowski distance* lebih baik daripada metrik *euclidean distance*. Karena hasil ekstraksi obyek lebih rapi daripada *euclidean distance*. Hasil akurasi terbaik saat pengujian *minor stroke* dengan metrik *minkowski distance* sebesar 68.76% pada $K=4.3$. Hasil pengukuran waktu *minor stroke* terbaik memerlukan 205 detik pada ($K=1.4$, $K=1.6$, $K=2$, $K=2.2$, $K=2.8$) saat pengujian *minor stroke* dengan *minkowski distance*. Hasil akurasi terbaik saat pengujian *minor stroke* dengan *euclidean distance* sebesar 68.76% pada $K=4.3$. Hasil pengujian kecepatan waktu *minor stroke* terbaik memerlukan 198 detik pada $K=0.7$ saat pengujian *minor stroke* dengan *euclidean distance*.

Hasil akurasi *minor stroke* dengan metrik *minkowski distance* yang diperoleh 68.76% pada $K=4.3$ dan *euclidean distance* yang diperoleh 68.76% pada $K=4.3$ adalah sama. Karena berada titik optimal parameter K dan P. Hasil akurasi terbaik saat pengujian *claire* dengan metrik *minkowski distance* sebesar 90.49% pada $K=0.1$. Hasil pengujian kecepatan waktu *claire* terbaik dengan *minkowski distance* memerlukan 52 detik pada $K=4.4$. Hasil akurasi terbaik saat pengujian *claire* dengan *euclidean distance* sebesar 90.59% pada $K=0.1$. Hasil pengujian kecepatan waktu *claire* terbaik memerlukan 59 detik pada $K=4.7$ dan $K=5$ saat pengujian *claire* dengan *euclidean distance*.

Hasil akurasi *claire* dengan metrik *euclidean distance* yang diperoleh 90.59% pada $K=0.1$. Hasil perbandingan akurasi metrik *euclidean distance* dengan *minkowski* lebih baik sebesar 90.49% pada $K=0.1$. Namun untuk evaluasi akurasi rata-rata dari $K=0.1$ sampai $K=0.2$ sebesar 72.49%, metrik *minkowski distance* lebih baik daripada *euclidean distance*.

Hasil perbandingan kecepatan waktu dari semua pengujian yaitu *claire* tercepat daripada *minkowski distance*. Untuk waktu rata-rata terbaik adalah *claire* dengan *euclidean distance*. Sedangkan waktu terlama adalah *minor stroke* dengan *minkowski distance*. Dari hasil pengujian akurasi *minor stroke* terlihat bahwa belum bisa memperbaiki hasil akurasi sebelumnya. Namun untuk kasus *claire extraction* dengan evaluasi rata-rata lebih baik daripada metrik *euclidean distance*. Hal ini dipengaruhi oleh pengambilan *video minor stroke* kurang maksimal. Karena yang mengambil *video* adalah orang yang sedang terserang penyakit *minor stroke*. Orang yang mengalami penyakit *minor stroke* tertanggung koqnitifnya seperti saat memegang handpone dan merekam. Jadi hasil rekaman *video minor stroke* tidak stabil.

Dari uraian paragraf sebelumnya mengenai pengujian kecepatan waktu, dapat diambil dua ringkasan. Pertama, hasil pengujian kecepatan waktu yang terbaik adalah *claire* dengan metrik *minkowski distance*. Hal ini terbukti pada penelitian sebelumnya bahwa metrik *minkowski* lebih cepat daripada *euclidean distance*. Karena proses komputasi lebih sederhana daripada *euclidean distance*. Kedua, hasil pengujian *minor stroke* dengan *euclidean distance* tidak terbukti. Karena pengujian *minor stroke* mempunyai kendala kerumitan dan kualitas video.

5.2 Penelitian Selanjutnya

Hasil perbaikan *video object extraction* pada kasus *minor stroke* belum terbukti untuk menaikkan akurasi yang lebih dari 70%. Oleh karena itu, *video object extraction* pada kasus *minor stroke* memerlukan perbaikan, pertama dari fitur yang diambil terdiri dari lima yaitu posisi koordinat *pixel* x dan y, serta warna HSV. Diharapkan dengan perbaikan fitur akan menghasilkan akurasi yang meningkat. Kedua, untuk proses perhitungan jarak pada *video minor stroke extraction* masih membandingkan dengan metrik jarak *minkowski*. VOE perlu membandingkan metrik *mahalanobis* dan metrik yang lain. Diharapkan dengan perbaikan metrik bisa menaikkan akurasi menjadi 70% lebih. Kemudian untuk data yang diujikan di *video object extraction* perlu diuji dengan data yang lain. Sehingga akan menghasilkan penelitian baru lagi.

Halaman ini sengaja dikosongkan

DAFTAR PUSTAKA

- [1] A. Khalifeh, M. A. Al-tae, S. Ieee, F. Alabsi, S. Alrawi, and A. Murshed, "A Videoconferencing Platform for eHealth Services in Jordan," pp. 3–6, 2016.
- [2] S. Cical, M. Mazzotti, S. Moretti, V. Tralli, S. Member, and M. Chiani, "Multiple Video Delivery in m-Health Emergency Applications," vol. 18, no. 10, pp. 1988–2001, 2016.
- [3] A. Ashraf and B. Taati, "Automated Video Analysis of Handwashing Behavior as a Potential Marker of Cognitive Health in Older Adults," vol. 20, no. 2, pp. 682–690, 2016.
- [4] I. Y. Gu, "Exploiting Riemannian Manifolds for Daily Activity Classification in Video Towards Health Care," pp. 0–5, 2016.
- [5] S. Whitehouse, K. Yordanova, A. Paiement, and M. Mirmehdi, "Recognition of unscripted kitchen activities and eating behaviour for health monitoring."
- [6] J. Fredriksson, K. Groth, M. Räsänen, H. Bergius, and E. Rylander, "Effects of mobile video-mediated communication for health care professionals in advanced home care of children," 2014.
- [7] A. Fern and J. L. Car, "Unobtrusive Health Monitoring System Using Video-Based Physiological Information and Activity Measurements," 2012.
- [8] M. J. H. Van Gastel, H. M. C. Kemps, and P. H. N. De With, "e-Health Video System for Performance Analysis In Heart Revalidation Cycling," pp. 31–35.
- [9] C. Barbalata and L. S. Mattos, "Laryngeal Tumor Detection and Classification in Endoscopic Video," vol. 2194, no. c, pp. 1–13, 2014.
- [10] R. Ruseva and P. Ruskov, "An application of a customer-centric innovation approach in the health industry."
- [11] R. Karlsen, J. Enrique, B. Morell, L. Fernández, L.-I. Member, and T. S.-E. Member, "Retrieval of Trustworthy Health Videos from YouTube," pp. 25–28, 2014.
- [12] L. D. Rumpa, A. D. Wibawa, M. H. Purnomo, and H. Tulak, "Validating video stimulus for eliciting human emotion : A Preliminary study for e-Health monitoring system," pp. 208–213, 2015.
- [13] D. James, L. S. Yee, and T. G. Pickering, "WINTER-SUMMER DIFFERENCES IN THE EFFECTS OF EMOTION , POSTURE AND PLACE OF MEASUREMENT ON BLOOD PRESSURE," vol. 31, no. li, pp. 1213–1217, 1990.

- [14] E. Pervichko, Y. Zinchenko, and O. Ostroumova, "Emotion regulation in patients with essential hypertension : subjective-evaluative , physiological , and behavioral aspects," *Procedia - Soc. Behav. Sci.*, vol. 127, pp. 686–690, 2014.
- [15] A. Biderafsh and M. Karami, "Estimating the potential impact fraction of hypertension as the main risk factor of stroke : Application of the distribution shift method," *J. Epidemiol. Glob. Health*, pp. 1–7, 2015.
- [16] R. F. Macko, T. Forrester, P. Francis, G. Nelson, C. Hafer-macko, and S. Member, "Interactive Video Exercise Tele-Rehabilitation (IVET) for Stroke Care in Jamaica," pp. 150–153, 2016.
- [17] P. M. Rothwell *et al.*, "Eff ect of urgent treatment of transient ischaemic attack and minor stroke on early recurrent stroke (EXPRESS study): a prospective population-based sequential comparison," vol. 370, 2007.
- [18] S. Peter, M. Harnadek, T. Blake, and V. Hachinski, "NU SC," *J. Neurol. Sci.*, 2015.
- [19] D. Liu *et al.*, "Early Magnetic Resonance Imaging Predicts Early Neurological Deterioration in Acute Middle Cerebral Artery Minor Stroke," vol. 25, no. 2, pp. 469–474, 2016.
- [20] Y. Shi *et al.*, "Depression after minor stroke : Prevalence and predictors," *J. Psychosom. Res.*, vol. 79, no. 2, pp. 143–147, 2015.
- [21] A. B. Conforto and G. R. De Freitas, "Prodromal Transient Ischemic Attack or Minor Stroke and Outcome in Basilar Artery Occlusion," vol. 24, no. 9, pp. 2117–2121, 2015.
- [22] U. I. Tuor, Q. Deng, D. Rushforth, T. Foniok, and M. Qiao, "Model of minor stroke with mild peri-infarct ischemic injury," *J. Neurosci. Methods*, vol. 268, pp. 56–65, 2016.
- [23] H. Taguchi, Y. Hasegawa, K. Bandoh, K. Shimazaki, H. Shima, and M. Miyakawa, "Implementation of a Community-Based Triage for Patients with Suspected Transient Ischemic Attack or Minor Stroke Study : A Prospective Multicenter Observational Study," pp. 1–7, 2015.
- [24] T. H. Park *et al.*, "Validation of Minor Stroke Definitions for Thrombolysis Decision Making," *J. Stroke Cerebrovasc. Dis.*, vol. 22, no. 4, pp. 482–490, 2013.
- [25] V. Sudacevschi, C. Bertrand, M. L. Chadenat, C. Tarnaud, and F. Pico, "Predictors of Occult Atrial Fibrillation in One Hundred Seventy-One Patients with Cryptogenic Transient Ischemic Attack and Minor Stroke," *J. Stroke Cerebrovasc. Dis.*, pp. 1–5, 2016.
- [26] M. A. Pesantes, L. R. Brandt, A. Ipince, J. J. Miranda, and F. Diez-canseco, "An exploration into caring for a stroke-survivor in Lima , Peru : Emotional impact , stress factors , coping mechanisms and unmet needs of informal

- caregivers,” *ENSCI*, vol. 6, pp. 33–50, 2017.
- [27] A. F. C. S, M. H. L, and G. A. H. L, “Video analysis for segmentation and classification of players at soccer games Análisis de video para la segmentación y clasificación de jugadores en juegos de fútbol,” pp. 331–338, 2015.
- [28] A. Y. Rahman, S. Sumpeno, and M. H. Purnomo, “Video Minor Stroke Extraction Using Learning Vector Quantization,” vol. 0, no. c, pp. 270–276, 2017.
- [29] “29. An Improved Technique for LVQ-Based Video Object Extraction - 2006.pdf.” .
- [30] F. R. McInnes, “Bound for Minkowski metric or quadratic metric applied to VQ codeword search,” no. 4.
- [31] M. Hariadi, A. Harada, T. Aoki, and T. Higuchi, “For human,” pp. 171–176.
- [32] M. Hariadi, A. Harada, T. Aoki, and T. Higuchi, “Pixel-Wise Human Motion Segmentation Using Learning Vector Quantization,” 2002.
- [33] S. Sumpeno, H. Mochamad, K. Ito, and T. Aoki, “LVQ-Based Video Object Extraction and Its Performance Improvement,” pp. 1–6.
- [34] T. A. Hariadi Mochamed, Hui Chien Loy, “Lqv-Based Video Object Segmentation Through Combination of Spatial and Color,” vol. 1.
- [35] S. Sumpeno, H. Mochamad, and T. Aoki, “A Standard Performance Evaluation Tool for Video Object Extraction,” pp. 5–8, 2006.
- [36] M. Hariadi and M. H. Purnomo, “a Lvq-Based Temporal Tracking for Semi-Automatic,” vol. 18, no. 2, pp. 49–57, 2007.
- [37] R. Kamimura and O. Uchida, “Greedy network-growing by Minkowski distance functions,” *IEEE Int. Conf. Neural Networks - Conf. Proc.*, vol. 4, pp. 2837–2842, 2004.
- [38] Q. Zhai, J. Yang, M. Xie, and Y. Zhao, “Generalized moment-independent importance measures based on Minkowski distance,” *Eur. J. Oper. Res.*, vol. 239, no. 2, pp. 449–455, 2014.
- [39] A. Labellapansa, A. Efendi, A. Yulianti, and A. K. Evizal, “Lambda value analysis on Weighted Minkowski distance model in CBR of Schizophrenia type diagnosis,” *2016 4th Int. Conf. Inf. Commun. Technol. ICoICT 2016*, vol. 4, no. c, pp. 1–4, 2016.
- [40] M. Luo and X. Zhou, “Robustness of reverse triple i algorithms based on interval-valued fuzzy inference,” *Int. J. Approx. Reason.*, vol. 66, no. 61273018, pp. 16–26, 2015.
- [41] L. B. Damahe, “A Review : Region of Interest based Image Retrieval,”

2016.

- [42] M. D. Malkauthekar, “Analysis of euclidean distance and manhattan distance measure in face recognition,” *Third Int. Conf. Comput. Intell. Inf. Technol.*, vol. 1, no. 4, pp. 3–7, 2013.
- [43] A. Y. Rahman and S. Sumpeno, “Segmentasi Arca pada Museum Mpu Tantular Sidoarjo Menggunakan Learning Vector Quantization,” pp. 16–21, 2016.

BIOGRAFI PENULIS

Nama : Aviv Yuniar Rahman

Tempat/Tanggal Lahir : Suruh Semarang, 10 Juni 1988

Agama : Islam

Pekerjaan : Dosen Teknik Elektro dan Informatika,
Universitas Widyagama Malang

ALamat Kantor : Jl. Taman Borobudur Indah No.35, Malang 65142

Nomor Telepon Kantor : (0341) 41129

Alamat Rumah : Jl. Kedawung 25 G, Gang V, RT/RW 05/05, Malang
64141

Nomor HP : 085641667373

E-mail : aviv.yuniar@gmail.com



Riwayat Pendidikan

- TK Pertiwi Suruh, Kab.Semarang 1993 - 1995
- SD Negeri 1 Kec.Suruh, Kab.Semarang 1995 - 2001
- SMP Negeri 6 Salatiga 2001 - 2004
- SMA Negeri 2 Salatiga 2004 - 2007
- DIII Instrumentasi dan Elektronika, Fisika UNDIP 2007 - 2010
- S1 Teknik Elektro ITS 2010 - 2013
- S2 Teknik Elektro ITS 2015 – 2017
- Penerima Beasiswa Magister LPDP Kementerian Keuangan,
PK 40

Daftar Publikasi Selama Studi Magister

Seminar Nasional

- Y. Rahman and S. Sumpeno, "Segmentasi Arca pada Museum Mpu Tantular Sidoarjo Menggunakan Learning Vector Quantization," pp. 16–21, 2016.

Seminar Internasional

- Y. Rahman, S. Sumpeno, and M. H. Purnomo, "Video Minor Stroke Extraction Using Learning Vector Quantization," vol. 0, no. c, pp. 270–276, 2017.