



TESIS - TE142599

**KLASIFIKASI AKTIVITAS GERAKAN BAYI
SETELAH OPERASI BERBASIS *MOTION VECTOR*
MENGUNAKAN *SUPPORT VECTOR MACHINE***

FAISAL LUTFI AFRIANSYAH
2215205008

DOSEN PEMBIMBING
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
Dr. Eko Mulyanto Yuniarno, ST., MT.

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



TESIS - TE142599

**KLASIFIKASI AKTIVITAS GERAKAN BAYI
SETELAH OPERASI BERBASIS *MOTION VECTOR*
MENGUNAKAN *SUPPORT VECTOR MACHINE***

FAISAL LUTFI AFRIANSYAH
2215205008

DOSEN PEMBIMBING
Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
Dr. Eko Mulyanto Yuniarno, ST., MT.

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:

Faisal Lutfi Afriansyah
NRP. 2215205008

Tanggal Ujian : 15 Juni 2017
Periode Wisuda: September 2017

Disetujui oleh:

1. Prof. Dr. Ir. Mauidhi Hery Purnomo, M.Eng. (Pembimbing I)
NIP: 195809161986011001

2. Dr. Eko Mulyanto Yuniarno, ST., MT. (Pembimbing II)
NIP: 196806011995121009

3. Dr. Supeno Mardi Susiki Nugroho, ST., MT. (Penguji)
NIP: 197003131995121001

4. Dr. Diah Puspito Wulandari, ST., M.Sc. (Penguji)
NIP: 198012192005012001

5. Dr. I Ketut Eddy Purnama, ST., MT. (Penguji)
NIP: 196907301995121001

Dekan Fakultas Teknologi Elektro

Dr. Tri Arief Sardjono, S.T., M.T.
NIP. 197002121995121001

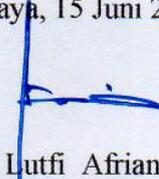
Halaman ini sengaja dikosongkan

PERNYATAAN KEASLIAN TESIS

Dengan ini saya menyatakan bahwa isi keseluruhan Tesis saya dengan judul “**KLASIFIKASI AKTIVITAS GERAKAN BAYI SETELAH OPERASI BERBASIS *MOTION VECTOR* MENGGUNAKAN *SUPPORT VECTOR MACHINE***” 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, 15 Juni 2017



Faisal Lutfi Afriansyah

NRP. 2215205008

Halaman ini sengaja dikosongkan

KLASIFIKASI AKTIVITAS GERAKAN BAYI SETELAH OPERASI BERBASIS MOTION VECTOR MENGGUNAKAN SUPPORT VECTOR MACHINE

Nama mahasiswa : Faisal Lutfi Afriansyah
NRP : 2215205008
Pembimbing : 1. Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng.
2. Dr. Eko Mulyanto Yuniarno, ST., MT.

ABSTRAK

Rasa sakit adalah pengalaman subjektif dan tidak ada tes objektif untuk mengukurnya, IASP (Asosiasi Internasional untuk Studi Rasa Sakit) memutuskan bahwa pasien menyampaikan rasa sakit yang dirasakan sebagai standar penilaian nyeri hingga saat ini. Sedangkan Bayi tidak bisa menyampaikan rasa sakit secara verbal. Dalam tulisan ini, kami mengembangkan sebuah sistem untuk mendeteksi aktivitas gerakan bayi setelah operasi dengan mengamati fitur vektor gerak berdasarkan FLACC. Pada FLACC, aktivitas adalah satu dari lima kategori untuk mengidentifikasi tingkat nyeri pada bayi dimana kategori aktivitas pada FLACC terbagi dalam 3 aktivitas, yaitu aktivitas gerakan tenang dengan skor 0, menggeliat memiliki skor 1 dan menyentak memiliki skor 2. Masukan sistem berupa video berukuran 640 x 480, dengan menggunakan algoritma *block matching* menggunakan *sum of absolute difference* dengan ukuran blok 8 x 8 dengan pendekatan deret Taylor untuk menghasilkan nilai dengan akurasi tinggi dari gerakan *frame* referensi ke *frame* tujuan saat ini dalam bentuk vektor gerak. Gerakan yang terjadi antar frame yang diamati, kemudian dilakukan pengurutan pada skala terbesar untuk mengetahui gerakan terbesar dan sekaligus bertindak sebagai fitur antar frame. Kemudian dilakukan klasifikasi menggunakan SVM (*support vector machine*) untuk mendapatkan kelas aktivitas berdasarkan FLACC yaitu Tenang, Menggeliat dan Menyentak. Hasil akurasi terbaik pada proses klasifikasi mencapai nilai 90,4762%. Metode yang diusulkan dalam penelitian ini adalah penelitian yang pertama pada klasifikasi aktivitas gerakan pada bayi setelah operasi.

Kata kunci: Aktivitas Bayi, Vektor Gerak, Setelah Operasi, Deret Taylor, SVM, *FLACC*.

Halaman ini sengaja dikosongkan

CLASSIFICATION OF INFANT ACTIVITY POST SURGERY BASED ON MOTION VECTOR USING SUPPORT VECTOR MACHINE

By : Faisal Lutfi Afriansyah
Student Identity Number : 2215205008
Supervisors : 1. Prof. Dr. Ir. Mauridhi Hery P, M.Eng.
2. Dr. Eko Mulyanto Yuniarno, ST., MT.

ABSTRACT

Pain is a subjective experience and no objective test exist to measure it, IASP (International Association for the Study of Pain) decided patients self-report as gold standard of pain assessment. Infant cannot provide a self-report of pain verbally. In this reseach, we developed a system to recognize post-surgery infant activity based FLACC (Face, Legs, Activity, Cry, Consolability), score 0 is given if the infant moves easily, score 1 if the infant is squirming, and a score 2 if the baby is jerking by observing the features of motion. In FLACC, activity is one of the five parameters to identify the level of infant pain. Using a block matching algorithm with the addition of the Taylor series to generate a value with high motion accuracy from the reference frame to the current frame in the form of a motion vector. Videos have been verified by doctors and nurses using hormone cortisol with FLACC measurements. The results of the experiment show the classification using SVM could detect the infant activity moves easily, squirming, and jerking at 90.4762%. Nevertheless, this experiment is still novel and needs further study on the infant activity.

Key words: Infant Activity, Motion Vector, Post Surgery, Taylor Series, SVM, FLACC

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Alhamdulillah, segala puja dan puji syukur penulis panjatkan kehadiran Allah SWT yang Maha Pengasih lagi Maha Penyayang yang telah memberikan rahmat, taufik, hidayah dan inayah-Nya kepada penulis serta memberikan nikmat Islam dan Iman serta tidak lupa nikmat kesehatan yang diberikan kepada penulis, sehingga penulis dapat menyelesaikan tesis dengan judul “Klasifikasi Aktivitas Gerakan Bayi Setelah Operasi Berbasis *Motion Vector* Menggunakan *Support Vector Machine*”. Penelitian ini dimaksudkan untuk memenuhi salah satu syarat dalam meraih gelar Magister Teknik (M.T) pada Program Magister Bidang Keahlian Jaringan Cerdas Multimedia, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember (ITS) Surabaya.

Penulis menyadari bahwa banyak pihak yang telah membantu dalam menyelesaikan penulisan tesis. Untuk itu, seiring dengan doa dan ucapan terima kasih yang sebesar-besarnya penulis sampaikan kepada:

1. Direktur beserta jajarannya (Keluarga Besar) Lembaga Pengelola Dana Pendidikan (LPDP) Indonesia yang sudah memberikan beasiswa program magister dan mendorong serta memberikan wadah (naungan), fasilitas, dan layanan yang sangat maksimal demi lancarnya proses perkuliahan dan penyelesaian studi.
2. Bapak Prof. Dr. Ir. Mauridhi Hery Purnomo, M. Eng selaku dosen pembimbing pertama yang senantiasa memberikan motivasi, arahan, didikan, dan masukan-masukan yang dapat membangun karakter penulis agar bisa lebih baik lagi, serta yang sudah banyak memberikan ilmunya.
3. Bapak Dr. Eko Mulyanto Yuniarno, S.T., M.T selaku dosen pembimbing kedua yang sudah banyak memberikan ilmu dan pengalaman baru disetiap proses pembelajaran, memberikan motivasi, dan arahan yang mendidik untuk perbaikan yang lebih baik.
4. Seluruh Dosen Program Magister Bidang Keahlian Jaringan Cerdas Multimedia, Departemen Teknik Elektro Fakultas Teknologi Elektro Institut Teknologi Sepuluh Nopember Surabaya yang telah memberikan

ilmu, pengetahuan, pengalaman, dan wawasan, sebagai pedoman dan bekal bagi penulis kedepannya.

5. Para pegawai atau karyawan Program Magister Bidang Keahlian Jaringan Cerdas Multimedia, Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember Surabaya yang sudah membantu dan memberikan layanan umum dan administrasi yang sangat baik kepada penulis.
6. Orang tua tersayang Drs. Wisono dan Ibu mamik Zubaidah yang selalu memberikan dorongan motivasi, mendoakan, memberikan arahan, didikan, memberikan pertimbangan, menjadi orang tua terbaik dengan segala perjuangannya dan pengorbanan selalu diberikan kepada anaknya.
7. Istri tercinta Niyalatul Muna yang selalu memberikan semangat, dukungan, akhirnya bisa cita-cita untuk bisa bersama-sama mendapatkan kesempatan pendidikan magister bersama dan saling mendukung, semoga nanti bisa lanjut bersama lagi pada jenjang pendidikan doktoral.
8. Ibu Mertua Dr. Hj. Lailial Muhtifah, M.Pd yang selalui memberikan motivasi untuk selalu semangat terus bersekolah hingga jenjang tertinggi dan motivasi dalam menulis tulisan ilmiah baik jurnal mupun conference dan selalu mendoakan kami dan istri Niyalatul Muna untuk selalu sabar.
9. Keluarga tercinta, saudara, adik, dan kakak-kakak tersayang (Mba Ani, Mba ummi, Mba diah, Ifah, Dina, dan Laili) yang senantiasa saling memberikan semangat dan mendorong kearah yang lebih baik, bahagia dan bersyukur memiliki kalian semua.
10. Keluarga Besar Laboratorium Visi Komputer semuanya yang sudah menjadi keluarga, teman berdiskusi dan saling mendorong untuk hal yang lebih baik.
11. Teman-teman Jaringan Cerdas Multimedia, Ibu-Ibu dan Bapak-bapak program doktoral yang senantiasa saling berbagi dan berdiskusi, bertukar pikiran, dan menjalin hubungan yang baik.
12. Teman-teman *Awardee LPDP East Java* dan awardee lainnya yang tersebar diseluruh penjuru dunia, yang saling bersinergi, berbagi, berdiskusi, dan bahu-membahu untuk kemajuan Indonesia yang lebih baik.

Akhirnya atas segala kekurangan dari penyusunan tesis ini, sangat diharapkan kritik dan saran yang bersifat konstruktif dari semua pembaca demi memperbaiki kualitas penulisan selanjutnya. Semoga yang telah tertulis di dalam tesis ini dapat memberikan kontribusi yang bermanfaat dan menambah khasanah ilmu pengetahuan. Amien...

Surabaya, 15 Juni 2017

Penulis

Halaman ini sengaja dikosongkan

DAFTAR ISI

LEMBAR PENGESAHAN	iii
PERNYATAAN KEASLIAN TESIS	iv
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xv
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xix
DAFTAR LAMPIRAN	xxi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan	3
1.4 Batasan Masalah	3
1.5 Kontribusi	3
1.6 Metodologi Penelitian	4
BAB 2 KAJIAN PUSTAKA	7
2.1 Kajian Penelitian Terkait	7
2.2 Penilaian nyeri skala <i>FLACC</i>	8
2.3 Mekanisme dan Persepsi Nyeri (Nociceptive)	9
2.4 Nyeri Pada Bayi	11
2.5 Nyeri akut prosedural	11
2.6 Diagnosis Nyeri Bayi	11
2.7 Penilaian nyeri skala <i>Face, Legs, Activity, Cry and Consolability (FLACC)</i>	12
2.8 Gerakan Aktivitas Bayi	13
2.9 Video	13
2.10 Estimasi Gerak	15
2.11 <i>Block matching</i>	16
2.12 <i>Sum of absolute difference</i>	17
2.13 <i>Motion Vector</i>	18

2.14	Pengurutan	18
2.15	Gerakan Global	19
2.16	Deret Taylor	20
2.17	<i>Support Vector Machine</i>	22
2.17.1	Pengenalan pola menggunakan <i>support vector machine</i>	24
2.17.2	<i>Soft margin</i>	26
2.17.3	Klasifikasi <i>Non Linier</i> pada SVM	27
BAB 3 METODOLOGI PENELITIAN		31
3.1	Video Bayi	32
3.2	Estimasi Gerak	34
3.3	<i>Block matching</i> dengan deret Taylor	36
3.4	<i>Magnitude</i>	37
3.5	Pengurutan	38
3.6	<i>Global motion</i>	39
3.7	<i>Support Vector Machine</i>	40
3.7.1	Pengukuran Kinerja Klasifikasi	43
BAB 4 HASIL DAN PEMBAHASAN		47
4.1	Ekstraksi Fitur <i>Motion Vector</i>	47
4.1.1	Hasil Ekstraksi Fitur <i>Motion Vector</i>	47
4.2	Nilai <i>Magnitude</i> Berdasarkan Data <i>Motion</i>	52
4.2.1	Hasil <i>Magnitude</i>	52
4.3	Hasil Pengurutan Berdasarkan Data <i>Magnitude</i>	53
4.3.1	Hasil Sorting <i>Magnitude</i>	55
4.4	<i>Global Motion</i> Pada Data Video	57
4.5	Hasil Setelah Klasifikasi SVM	59
4.5.1	Hasil Perbandingan Akurasi Kernel	60
BAB 5 KESIMPULAN		63
5.1	Kesimpulan	63
5.2	Saran	64
DAFTAR PUSTAKA		65
LAMPIRAN		69
BIOGRAFI PENULIS		79

DAFTAR GAMBAR

Gambar 2.1. <i>Frame A</i> ke <i>frame B</i> menghasilkan <i>motion vector C</i>	16
Gambar 2.2. <i>Block</i> dengan ukuran macro blok 8x8 dengan search limit 10x10..	17
Gambar 2.3. Tipe vektor gerak untuk bidang (a) Translasi, (b) geometri, (c) affine dan (d) model perspektif (Meier and Giaschi, 2014)	20
Gambar 2.4. SVM berusaha menemukan hyperplane terbaik yang memisahkan antara class -1 dan +1 (C Cortes and Vapnik, 1995).....	23
Gambar 2.5. Fungsi Φ memetakan data ke ruang vektor yang berdimensi lebih tinggi, sehingga kedua class dapat dipisahkan secara linear oleh sebuah hyperplane (C Cortes and Vapnik, 1995).....	28
Gambar 3.1. Bagan penelitian klasifikasi aktivitas gerakan bayi setelah operasi berbasis <i>Motion Vector</i> menggunakan <i>Support Vector Machine</i>	31
Gambar 3.2. Contoh gambar dalam dataset aktivitas gerakan setelah operasi	33
Gambar 3.3. Contoh Pemilihan <i>Frame</i>	34
Gambar 3.4. <i>Motion Vector</i> dari dua <i>frame</i> berurutan.....	35
Gambar 3.5. <i>Block diagram motion estimation</i> menggunakan block matching dengan pendekatan taylor.....	37
Gambar 3.6. Magnitude dari dua <i>frame</i> berurutan.....	38
Gambar 3.7. besaran aktivitas gerakan bayi setelah dilakukan sorting.....	39
Gambar 3.8 contoh global motion.....	40
Gambar 4.1. Inputan dengan <i>frame</i> terpilih dari video pasca operasi.....	48
Gambar 4.2. Hasil ekstraksi <i>Motion Vector</i> pada bayi setelah operasi.....	49
Gambar 4.3. Gabungan <i>Motion Vector</i> dengan <i>frame</i> video setelah operasi (a-c)	50
Gambar 4.4. Magnitude dari beberapa <i>frame</i> yang berurutan (a-c).....	53
Gambar 4.5. Magnitude pada <i>frame</i> berurutan	54
Gambar 4.6. Hasil pengurutan dari beberapa <i>frame</i> berurutan.....	55
Gambar 4.7. Pola pengurutan dari banyak <i>frame</i> berurutan	56
Gambar 4.8. Perbandingan vektor gerak bayi dengan global <i>motion</i> (a-b)	57
Gambar 4.9. Grafik gerakan global terhadap gerakan bayi	58

Halaman ini sengaja dikosongkan

DAFTAR TABEL

Tabel 2.1. Penilaian nyeri dengan sistem skor <i>FLACC</i>	9
Tabel 2.2. Kernel yang umum dipakai pada SVM.....	29
Tabel 3.1. Matrik konfusi dua kelas.....	43
Tabel 4.1. Sampel dari nilai <i>Motion Vector</i> pada bayi setelah operasi	51
Tabel 4.2. Hasil konfusi matrik.....	59
Tabel 4.3. Hasil detail akurasi dari setiap kelas	59
Tabel 4.4. Akurasi perbandingan kernel	60
Tabel 4.5. Perbandingan <i>error</i> MSE dan RMSE pada tiap kernel.....	61

Halaman ini sengaja dikosongkan

DAFTAR LAMPIRAN

Lampiran 1	69
Lampiran 2	70
Lampiran 3	71
Lampiran 4	72
Lampiran 5	73
Lampiran 6	77

Halaman ini sengaja dikosongkan

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Persepsi nyeri telah dikenal sejak kehadiran manusia dimuka bumi ini, namun karena kompleksnya masalah nyeri, definisi nyeri baru dapat disepakati oleh perhimpunan nyeri sedunia *The International Association for the study of pain* (IASP) pada tahun 1997. Definisi tersebut dikemukakan oleh Merkel, nyeri adalah rasa inderawi dan pengalaman emosional yang tidak menyenangkan akibat adanya kerusakan jaringan yang nyata atau yang berpotensi rusak atau sesuatu yang menggambarkan seperti itu (Merkel, 1997). Artinya seseorang yang merasakan nyeri harus ditanya secara langsung pada yang bersangkutan derajat nyeri yang dirasakan dan harus menjelaskan sendiri tentang rasa nyeri yang dialaminya, karena rasa nyeri sangat subjektif. Diagnosis nyeri dengan cara *self report* merupakan standar emas hingga sekarang. Tentu saja definisi ini tidak dapat diterapkan untuk golongan *Non-verbal*, yaitu bayi yang belum mampu berkomunikasi dengan efektif. Seorang bayi tidak dapat mengemukakan apa yang dirasakannya, sehingga penilaian nyeri dilakukan secara tidak langsung dengan mengamati perubahan indikator nyeri yaitu perilaku dan aktivitas.

Konsep nyeri pada bayi yang menyatakan bayi tidak dapat merasakan rangsang nyeri karena belum efektifnya struktur neurologis bayi terbukti kurang tepat, karena bayi sudah dapat merasakan nyeri bahkan sejak fetus (Reynolds, 2005) dan (White and Wolf, 2004). Penilaian nyeri pada bayi merupakan satu aspek dari pengelolaan nyeri secara keseluruhan dan sampai saat ini masih menyisakan permasalahan dalam hal penegakan diagnosis yang dapat dianggap sebagai standar emas. Telah banyak metode dan sistem penilaian nyeri dibuat untuk kelompok usia *non-verbal* (Cong *et al.*, 2017). Tetapi dalam kenyataannya di klinik sangat sedikit yang digunakan secara rutin. Kendala utama dari masalah tersebut disebabkan oleh rumit dan sulitnya pelaksanaan penilaiannya (Dalal *et al.*, 2013). Padahal nyeri harus dinilai secara berkala seperti halnya fungsi vital yang lain karena nyeri bersifat dinamis. Skala pengukuran yang ada memerlukan waktu untuk

menghasilkan diagnosis yang akurat, memerlukan pemahaman skala yang sesuai untuk konteks nyeri yang terjadi, skala yang digunakan juga harus sesuai untuk kelompok usia (Polkki *et al.*, 2014).

Akibat dari kendala-kendala tersebut penilaian nyeri jarang dilakukan pada kelompok bayi, terapi nyeri sering tidak didasarkan pada diagnosis derajat nyeri yang tepat tetapi didasarkan pada perkiraan saja. Dengan demikian terapi yang diberikan juga tidak mempunyai target efektivitas hasil, bahkan potensial dapat mengakibatkan efek samping obat analgetik yang dapat fatal seperti depresi pernafasan (Chen *et al.*, 2016). Studi observasional dikamar bedah pusat terpadu RSUD Dr. Soetomo Surabaya selama 4 bulan pada tahun 2009, terhadap 114 bayi dibawah usia 1 tahun, tidak satupun bayi yang dilakukan tindakan pembedahan tersebut dinilai derajat nyerinya (Hanindito, 2013). Data lain menunjukkan 50% anak mengalami nyeri sedang sampai berat setelah operasi karena tidak mendapatkan terapi nyeri sesuai derajat nyerinya.

Pengelolaan nyeri yang efektif merupakan keharusan dalam perawatan bayi setelah operasi karena sangat mempengaruhi hasil terapi secara keseluruhan. Berdasarkan uraian diatas maka menegakkan diagnosis nyeri pada bayi diperlukan cara penilaian nyeri yang sederhana, praktis, mudah digunakan, dengan hasil gradasi yang dapat dipercaya. Untuk mencapai pengukuran yang mempunyai gradasi tersebut, penelitian dapat memanfaatkan teknologi, misalnya mengukur *skin conductance* (Dalal *et al.*, 2013), menganalisis pola akustik tangis sebagai indikator nyeri akut setelah operasi pada bayi (Hanindito, 2013), mengukur secara kuantitatif pola ekspresi wajah serial bayi yang distimulasi nyeri dan dianalisis dinamika perubahan ekspresi wajah secara serial (Schiavenato *et al.*, 2008). Deteksi tangis bayi menggunakan Active Shape Model dan Chaotic NN Classifier (Kristian, Hariadi and Purnomo, 2014). Indikator perilaku yang telah direkomendasi untuk digunakan pada bayi setelah operasi adalah skala *FLACC* (Face Leg Activity Cry Consolability) dan telah diuji validitasnya (APA, 2012), *FLACC* dibuat oleh Merkel pada tahun 1997 dan terdiri dari 5 kategori dengan nilai 0-2, akumulasi dari 5 kategori kemudian dijumlahkan dengan nilai terendah 0 dan tertinggi 10. Salah satunya yaitu *activity* atau perilaku dimana aktivitas bayi adalah gerakan tenang,

bergerak terus dan tegang sehingga dari aktifitas bayi dapat diamati pola gerakan bayi setelah operasi.

1.2 Rumusan Masalah

Berdasarkan Latar belakang yang telah dijelaskan, belum ada penelitian sebelumnya tentang klasifikasi aktivitas gerakan pada bayi setelah operasi berdasarkan standar pengukuran nyeri FLACC.

1.3 Tujuan

Untuk mendapatkan pola aktivitas gerakan pada bayi setelah operasi kemudian dilakukan klasifikasi aktivitas gerakan berdasarkan parameter pengukuran nyeri FLACC.

1.4 Batasan Masalah

Batasan masalah dari penelitian ini adalah video diambil pada bayi setelah tindakan operasi, kondisi bayi lahir cukup bulan dengan usia kehamilan ≥ 37 minggu, usia bayi ≥ 1 bulan hingga ≤ 6 bulan karena pada masa *neonatus* (usia 1 bulan pertama) tangisan dan gerakan aktivitas bayi masih bersifat reflektoris belum mempunyai tujuan atau arti dari pihak bayi (Hanindito, 2013), respon dari individu sekitarnya selama bayi menangis memberikan pengalaman dan pembelajaran untuk selanjutnya bayi akan memanfaatkan kemampuan tangis dan gerakannya sebagai saran komunikasinya. Gerakan aktivitas karena cemas dapat di eliminasi karena pada usia tersebut belum mengenal individu asing dan lingkungan. Pembedahan dilakukan secara terencana dimana tindakan pembedahan yang dilakukan secara terencana, terjadwal dan kondisi penderita harus optimal. Status fisik bayi ASA PS 1 dan atau ASA PS 2 dimana bayi tanpa kelainan sistemik atau kelainan sistemik ringan berdasarkan pedoman ASA (*American Society of Anesthesiologists*).

1.5 Kontribusi

Kontribusi yang diharapkan dari hasil penelitian ini apabila terbukti bahwa ada perbedaan pola aktivitas gerakan bayi setelah operasi, kemudian apabila ada

peningkatan aktivitas gerakan ketika bayi setelah operasi berarti membuktikan bahwa ada korelasi antara nyeri dengan aktivitas gerakan bayi setelah operasi, dengan begitu dalam *FLACC* salah satu kategori untuk penilaian nyeri pada bayi yaitu aktivitas, membuktikan bahwa aktivitas bisa menjadi diagnosis nyeri dengan melihat perubahan pola aktivitas gerakan bayi, bila diagnosis nyeri menjadi mudah dan cepat untuk ditegakkan, maka terapi menjadi lebih optimal, apabila nyeri bisa ditanggulangi lebih dini dan optimal, maka efek nyeri dalam jangka pendek dan jangka panjang bisa di minimalisir.

1.6 Metodologi Penelitian

Pada penelitian ini penulis mengembangkan sebuah sistem pengenalan pola untuk mendeteksi aktivitas gerakan bayi setelah operasi dengan mengamati ciri-ciri aktivitas gerakan, untuk menilai nyeri kelompok *non-verbal* salah satunya menggunakan indikator perilaku, yaitu menggunakan *FLACC* (*Face, Legs, Activity, Cry, Consolability*) merupakan skala penilaian nyeri yang dibuat oleh Merkel (Merkel, 1997). indikator yang diamati adalah ekspresi wajah, gerakan tungkai, aktivitas gerakan, tangisan dan respon terhadap sesuatu yang mengalihkan atau menghibur. Salah satu indikator pada *FLACC* (*Face, Legs, Activity, Cry, Consolability*) adalah aktivitas, aktivitas adalah salah satu dari lima kategori untuk mengetahui tingkatan nyeri pada bayi. Pada penelitian ini inputan awal berupa video ukuran 640 x 480, menggunakan algoritma *block matching* SAD (*Sum of absolute difference*) dengan ukuran blok 8 x 8 dengan penambahan deret Taylor untuk menghasilkan nilai dengan akurasi nilai ketelitian tinggi pergeseran dari *frame* referensi ke *frame* sekarang dalam bentuk *motion vector*. Akan terlihat pergerakan titik-titik yang terjadi antar *frame* yang diamati, selanjutnya besaran dari magnitude dilakukan pengurutan untuk mengetahui gerakan terbesar sekaligus sebagai feature pada tiap-tiap frame, pengurutan ini dilakukan karena kondisi video inputan diambil dalam kondisi tidak dalam posisi diam, namun dalam posisi bergerak, sehingga dengan dilakukan pengurutan tidak perlu mengetahui posisi kepala, tungkai, tangan, tungkai. Namun seberapa besar gerakan vektor gerak nya. Kemudian dilakukan klasifikasi menggunakan klasifikasi SVM (*support vector machine*) untuk di dapatkan kelas gerakan aktivitas berdasarkan kategori aktivitas

pada skala pengukuran nyeri menggunakan FLACC pada bayi setelah operasi, untuk lebih detailnya akan dijelaskan pada BAB 3.

Halaman ini sengaja dikosongkan

BAB 2

KAJIAN PUSTAKA

Bayi hanya dapat berkomunikasi dengan cara menangis dengan bergerak. Pada saat baru lahir sifat tangisan bayi masih reflektoris, tidak mempunyai tujuan atau arti. Respon dari ibu selama bayi menangis memberikan pengalaman dan pembelajaran untuk selanjutnya bayi akan memanfaatkan kemampuan tangisnya sebagai sarana komunikasinya. Salah satu komponennya yaitu aktivitas gerakan dari sarana komunikasi bayi tersebut bisa diobservasi banyaknya gerakan, besarnya gerakan, intensitas gerakan, pola gerakan bayi. Pada Bab ini akan menguraikan teori-teori penunjang baik dari jurnal maupun buku dalam menyelesaikan penelitian ini.

2.1 Kajian Penelitian Terkait

Penelitian tentang nyeri pada bayi sebelumnya pernah diteliti oleh Hanindito menggunakan pola suara akustik tangisan pada bayi kemudian dilakukan validasi menggunakan hormon kortisol sebagai indikator nyeri akut setelah operasi pada bayi untuk mengukur tingkatan nyeri, dalam penelitiannya mengambil data sejumlah 56 video yang diambil dari 23 bayi sebelum dan sesudah prosedur operasi (Hanindito, 2013). Selain itu juga mengkorelasikan skala pengukuran nyeri menggunakan *FLACC* dengan mengukur Hormon kortisol dari air liur setiap bayi sebelum dan sesudah prosedur operasi. Video ini merupakan sumber dataset penelitian ini. Pada tahun 2008, Schiavenato memperkenalkan nyeri primer pada wajah, satu set jarak pasangan titik untuk mengukur nyeri bayi. Mereka melakukan penelitian berdasarkan 57 neonatus yang mewakili kedua jenis kelamin dan 3 latar belakang etnis (*African American, Caucasian and Hispanic / Latino*). Mereka menyimpulkan bahwa tidak ada *cluster* tertentu atau tampilan rasa sakit yang unik berdasarkan jenis kelamin, atau etnisitas (Schiavenato, 2007). Selain itu penelitian yang mengarah tentang tangis pada bayi juga pernah dipublikasi oleh Yosi tentang deteksi tangis bayi pada gambar tunggal menggunakan *Active Shape Model* (Kristian, Hariadi and Purnomo, 2014). Penelitian yang terakhir tentang deteksi

nyeri pada bayi dengan melihat ekspresi tangis bayi diteliti oleh Yosi tentang klasifikasi nyeri wajah bayi. Dataset gambar diklasifikasikan oleh dokter medis dan perawat berdasarkan perbedaan hormon kortisol dan pengukuran *FLACC* (*Face, Legs, Activity, Cry, Consolability*) (Hanindito, 2013). Selain itu mencoba sejumlah fitur berdasarkan AU (*Action Unit*) untuk klasifikasi nyeri wajah bayi, ditemukan bahwa fitur terbaik adalah kombinasi antara fitur geometris dan tekstur. kemudian dilatih menggunakan ASM (*Active Shape Model*) dan mengekstrak fitur geometris berdasarkan poin yang ditemukan oleh ASM. Fitur tekstur diekstraksi menggunakan *Local Binary Pattern* (LBP) dari beberapa *patch* wajah. Setelah itu dilakukan klasifikasi nyeri dua tahap yang didahului oleh sistem deteksi tangis, kemudian dikombinasikan dengan fitur geometris dan tekstur untuk menghasilkan nilai F1 yang sangat tinggi untuk klasifikasi nyeri wajah bayi (Kristian *et al.*, 2017).

2.2 Penilaian nyeri skala *FLACC*

FLACC merupakan skala parameter pengukuran nyeri yang terdiri dari *Face, Legs, Activity, Cry* dan *Consolability*. Untuk menilai nyeri kelompok *non-verbal* selalu digunakan indikator perilaku atau aktivitas (Hanindito, 2013), diperlukan persyaratan dan sifat-sifat skala psikometrik atau alat diagnostik yang akan digunakan. *FLACC* merupakan skala penilaian nyeri yang dibuat oleh Merkel dan dianjurkan untuk bayi setelah operasi dan nyeri prosedural di NICU, PICU atau diruang perawatan (APA, 2012). Indikator yang diamati adalah ekspresi wajah, gerakan tungkai, aktivitas, tangisan dan respon terhadap rangsang distraksi atau tindakan perawatan (diraba, dipeluk, diajak bicara).

Masing-masing indikator mempunyai nilai 0 sampai 2. Jadi nilai terkecil 0, nilai terbesar 10, karena ada 5 kategori sehingga nilai terbesar adalah 10. Dari hasil pengamatan dibuat peringkat derajat nyeri penderita, jika nilai 0 berarti penderita nyaman dan nyeri ringan, nilai 1 sampai 3 berarti penderita merasa kurang nyaman dan nyeri ringan, nilai 4 sampai 6 berarti penderita merasakan nyeri sedang dan nilai 7-10 berarti penderita merasa sangat tidak nyaman dan nyeri hebat. Jika kondisi bayi dalam kondisi sadar, maka pengamatan dilakukan selama 1-5 menit atau lebih lama, jika kondisi bayi dalam keadaan tidur maka pengamatan minimal 5 menit atau lebih lama dari itu. Penderita yang mempunyai nilai akumulasi *FLACC*

lebih besar dari 4 memerlukan terapi analgetika yang lebih efektif. Standar terapi yang disebut *rescue therapy* tersebut adalah obat analgetika golongan opiat, misalnya *morfin* dan *fentanyl*. (Singh *et al.*, 2012)

Tabel 2.1. Penilaian nyeri dengan sistem skor *FLACC*

Kategori	Deskripsi	Skor
Face	Ekspresi Biasa, senyum	0
	Merengut, dahi mengerut, menyeringai	1
	Dagu bergetar, otot rahang kontraksi	2
Legs	Santai, normal	0
	Terus bergerak, tegang	1
	Menyepak, kaki ditekuk	2
Activity	Tenang, santai, normal	0
	Menggeliat, bergerak terus	1
	Posisi kaku, menyentak	2
Cry	Tidak menngis	0
	Merengek, menangis tidak terus menerus	1
	Menangis terus, terus berteriak	2
Consolability	Senang, santai	0
	Tenang dengan pelukan/Sentuhan/suara	1
	Tidak bisa dihibur	2

2.3 Mekanisme dan Persepsi Nyeri (Nociceptive)

Rangsangan kedalaman sistem saraf ditimbulkan oleh stimulus terhadap reseptor sensorik yang akan mengenali berbagai jenis rangsangan, misalnya cahaya, raba, nyeri, dingin, panas. Ada 5 jenis reseptor sensorik terhadap rangsang yaitu :

1. Mekanoreseptor yang akan mengenali rangsangan akibat deformasi mekanis didaerah reseptor.

2. Termoreseptor bertugas menerima rangsang perubahan suhu dingin maupun panas untuk reseptor yang berbeda untuk masing-masing rangsangan.
3. Nosisseptor adalah reseptor untuk rangsangan nyeri akibat kerusakan jaringan akibat fisik maupun kimiawi yang menyebabkan cedera ringan.
4. Reseptor elektromagnetik terdapat di retina mata yang bertugas menerima rangsang cahaya.
5. Kemoreseptor bermanfaat mengenali rasa atau pengecap di dalam mulut, bebauan di dalam hidung, kadar oksigen di darah, osmolaritas plasma dan cairan lain di dalam tubuh, kadar karbon dioksida dan sensori yang lain untuk menjaga kondisi keseimbangan internal yang ideal, di mana semua sistem tubuh bekerja dan berinteraksi dalam cara yang tepat untuk memenuhi semua kebutuhan dari tubuh.

Dasar fisik persepsi nyeri akibat kerusakan jaringan karena trauma adalah mekanisme sistemik, molekuler dari jalur *nociceptive*. Yaitu sistem saraf perifer bagian dari sistem saraf yang terdiri dari sel-sel yang membawa informasi ke (sel saraf sensorik) dan dari (sel saraf motorik) sistem saraf pusat (SSP) yang akan memproses dan memberikan informasi berkaitan dengan rangsang nyeri dan modalitas yang kompleks untuk mempertahankan diri dari akibat stimulus nyeri. Pembedahan merupakan trauma buatan yang akan memicu serangkaian reaksi tubuh yang intinya bertujuan mencegah timbulnya infeksi, membatasi kerusakan lebih lanjut dan melakukan perbaikan dari kerusakan yang terjadi

Persepsi nyeri pada anak dan dewasa bersifat multidimensi dipengaruhi oleh usia, tingkat perkembangan individu, rasa takut, unsur kognitif dan kemampuan berkomunikasi. Respon terhadap rangsang nyeri menggambarkan strategi pembelajaran menyikapi rangsang nyeri yang terjadi sebelumnya dan dipengaruhi oleh berbagai faktor pada tahap integrasi, antara lain sosialisasi dan variasi kultural. Sedangkan respon bayi terhadap nyeri belum dipengaruhi faktor-faktor tersebut (Hanindito, 2013).

2.4 Nyeri Pada Bayi

Penelitian yang menganalisis perubahan oksigenasi cerebral membuktikan sejak usia setelah menstruasi 25 minggu, bayi sudah menunjukkan respon terhadap rangsang nyeri (Slater *et al.*, 2006). Nyeri menyangkut saraf sensori yang dipengaruhi suasana emosi, kecemasan, ketakutan dari penderita yang merasa nyeri, sehingga mempengaruhi persepsi rangsang nyeri. Peran susunan syaraf pusat ditingkat korteks tersebut pada bayi masih belum ada, sehingga pencegahan dan pengurangan rangsang nyeri dengan cara modulasi psikologis tidak dapat dilaksanakan pada kelompok bayi.

2.5 Nyeri akut prosedural

Nyeri akut prosedural adalah nyeri akibat tindakan tenaga medis terhadap penderita dengan tujuan perawatan, diagnosis maupun terapi. Nyeri akut akibat stimulus nyeri tertentu ini bersifat terbatas. Contohnya : suntikan, vaksinasi, pemasangan infus, pengambilan contoh darah, pemasangan pipa endotrakheal, membersihkan sekret dari pipa *endotrakheal*, aspirasi sumsum tulang, pemasangan pipa thoraks, penggantian bebat luka. Nyeri jenis ini pada umumnya terjadi saat bayi dirawat baik diruangan perawatan maupun diunit terapi intensif .

2.6 Diagnosis Nyeri Bayi

Diagnosis nyeri kelompok bayi merupakan masalah yang kompleks dan banyak kendalanya. Banyak teori dan studi empirik yang telah dikembangkan untuk menyempurnakan alat diagnostik nyeri bayi, dengan tujuan agar dapat dikategorikan sebagai baku emas. Hingga saat ini yang dianggap sebagai baku emas untuk diagnosis nyeri pada kelompok anak pada umumnya adalah pendekatan kognitif yaitu *self report*. Anak tersebut harus mengutarakan sendiri apa yang dirasakan sebagai pengungkap intensitas nyeri yang dirasakannya. Tentu saja untuk dapat menggunakan sarana diagnosis ini diperlukan komunikasi verbal dan pemahaman skala perbandingan dari individu yang akan dinilai. (Chen *et al.*, 2016). Pendekatan lain sebagai parameter untuk menegakkan diagnosis nyeri adalah pendekatan perilaku , yang sering diamati adalah perilaku tangis, ekspresi wajah

dan gerak anggota badan, namun parameter fisiologis tersebut sangat dipengaruhi faktor lain sehingga tidak spesifik.

Bayi hanya dapat berkomunikasi dengan cara menangis, pada saat baru dilahirkan sifat tangisan bayi masih *reflektoris*, tidak mempunyai tujuan atau arti dari pihak bayi. Respon dari ibu selama bayi menangis memberikan pengalaman dan pembelajaran untuk selanjutnya bayi akan memanfaatkan kemampuan tangisnya sebagai sarana komunikasi termasuk aktivitas gerakan bayi, karena selain menangis, bayi pasti juga melakukan gerakan.

Penelitian untuk membuktikan kesahihan penilaian nyeri kelompok pediatri telah diteliti, selanjutnya disusun peringkat validitas dan realibilitas pada penilaian nyeri pediatrik, metode penilaian nyeri dianggap baik jika lebih dari dua kali dipublikasikan, informasi penggunaan yang memadai dan pengukuran psikometri yang meyakinkan. Saat ini ada 17 sistem penilaian, pada sistem penilaian tersebut diberikan peringkat *well-established* karena memenuhi semua kriteria, sebanyak 11 sistem penilaian 6 mendapat peringkat *approaching well-established* karena publikasi kurang dan pengukuran psikometritidak meyakinkan. Dari 17 sistem penilaian tersebut, hanya 2 yang dapat digunakan untuk usia dibawah 1 tahun dan salah satunya termasuk *approaching well-established* (Nguyen *et al.*, 2017). *PedIMMPACT (Pediatric Initiative on Methods, Measurement and Pain Assessment in Clinical Trials)* pada kesimpulannya menganjurkan penggunaan skala pengukuran nyeri *FLACC* untuk penelitian yang menilai nyeri setelah operasi pada bayi di rumah sakit.

2.7 Penilaian nyeri skala *Face, Legs, Activity, Cry and Consolability* (*FLACC*)

Untuk menilai nyeri kelompok *non-verbal* selalu digunakan indikator perilaku, diperlukan persyaratan dari sifat-sifat psikometrik skala atau alat diagnostik yang akan digunakan *FLACC* merupakan skala penilain nyeri yang dibuat oleh Merkel (1997) dan dianjurkan untuk bayi setelah operasi dan nyeri prosedural di *NICU, PICU* atau diruang perawatan (APA, 2012). Indikator yang diamati adalah ekspresi wajah, gerakan tungkai, aktivitas gerakan, tangisan dan respon terhadap rangsang distraksi atau tindakan perawatan (diraba, dipeluk, diajak

bicara). Masing-masing indikator mempunyai nilai 0 sampai 2, jadi nilai terkecil 0, nilai terbesar 10. Dari hasil pengamatan dibuat peringkat derajat nyeri penderita, jika nilai 0 berarti penderita nyaman dan tidak ada nyeri ringan, nilai 4-6 berarti penderita merasakan nyeri sedang, sedangkan nilai 7-10 berarti penderita merasa sangat tidak nyaman dan nyeri hebat. Jika penderita dalam keadaan sadar, maka pengamatan dilakukan selama 1-5 menit atau lebih lama. Jika dalam keadaan tidur pengamatan minimal 5 menit. Penderita yang mempunyai nilai ≥ 4 memerlukan terapi analgetik yang lebih efektif, standar terapi yang disebut *rescue therapy* tersebut adalah obat analgetika golongan opiat, misalnya morfin dan fentanyl (Singh *et al.*, 2012)

2.8 Gerakan Aktivitas Bayi

Gerakan aktivitas pada bayi berbeda dengan orang dewasa dimana gerakan aktivitas bayi sangat terbatas karena bayi hanya bisa menangis dan menggerakkan tungkai dan tubuhnya, pada pengukuran nyeri menggunakan skala pengukuran nyeri *FLACC (Face Legs Activity Cry Consolability)*, Activity merupakan satu dari 4 kategori dimana pada *FLACC* gerakan aktivitas pada bayi memiliki beberapa pola gerakan, salah satunya yaitu aktivitas ketika bayi sedang tenang, bayi hanya sedikit menggerakkan anggota tubuhnya baik tungkai maupun tubuhnya, kondisi semacam ini menandakan kondisi bayi sangat nyaman, kemudian gerakan santai, dimana bayi bergerak namun kondisi dia tidak sambil menangis (Merkel, 1997). Kemudian gerakan dimana bayi bergerak terus. Setiap pola gerakan activity pada *FLACC* memiliki skor, dimana skor itu akan dilakukan akumulasi dengan kategori lain yaitu *Face, Legs, Cry dan Consolability* (Shen *et al.*, 2016).

2.9 Video

Kata video berasal dari kata latin, yang berarti 'Saya lihat'. Video adalah teknologi pemrosesan sinyal elektronik yang mewakili gambar bergerak. Aplikasi umum dari teknologi video adalah televisi. Video juga dapat digunakan dalam aplikasi teknik, keilmuan, produksi, dan keamanan. Istilah video juga dapat digunakan sebagai singkatan videotape, perekam video dan pemutar video. Video

adalah teknologi untuk menangkap, merekam, memproses, mentransmisikan dan menata ulang gambar bergerak. Biasanya menggunakan film seluloid, sinyal elektronik, atau media digital. Video digital adalah berkas komputer yang digunakan untuk menyimpan kumpulan berkas digital seperti video, audio, metadata, informasi, pembagian chapter, dan judul sekaligus, yang dapat dimainkan atau digunakan melalui perangkat lunak tertentu pada komputer (Oliveira and Bastos-Filho, 2016).

Video digital pada dasarnya tersusun atas serangkaian *frame* yang ditampilkan pada layar dengan kecepatan tertentu sesuai *frame rate* yang diberikan (dalam *frame/second*). Masing-masing *frame* merupakan citra digital. Karakteristik suatu video digital ditentukan oleh resolusi, kedalaman bit, dan *frame rate*. Karakteristik-karakteristik tersebut akan menentukan kualitas video dan akan dijelaskan sebagai berikut :

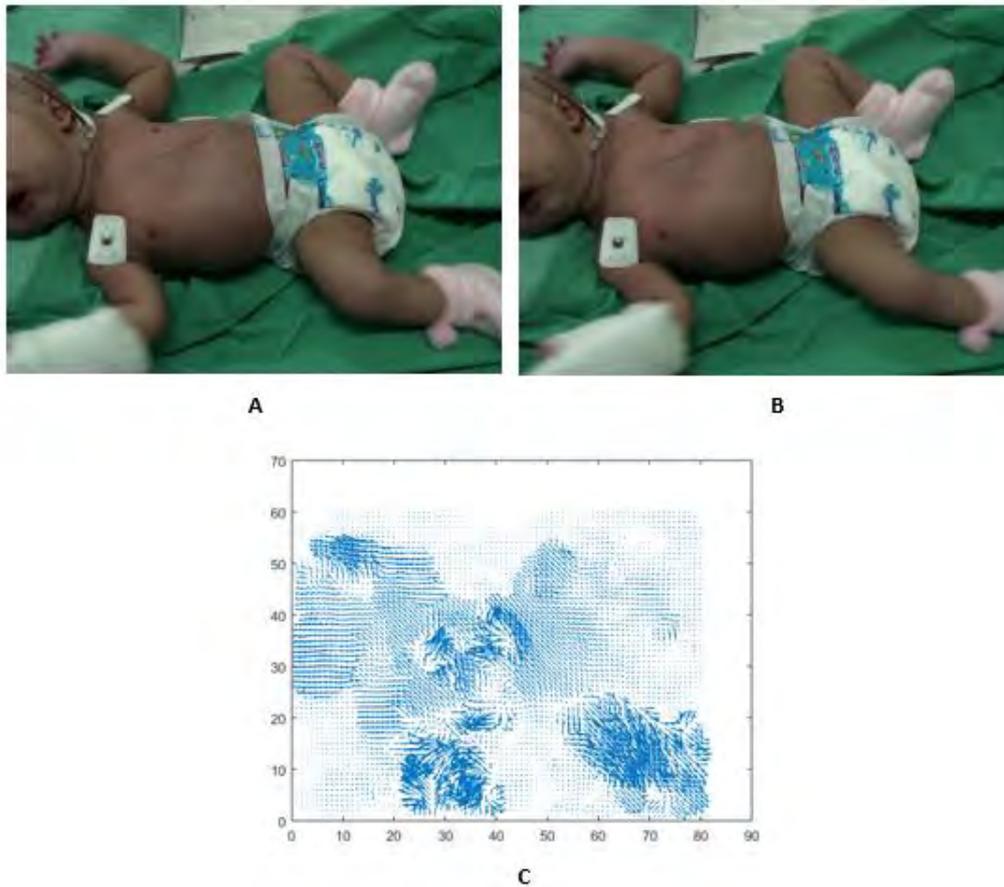
1. Resolusi adalah ukuran sebuah *frame*. Resolusi dinyatakan dalam piksel x piksel. Semakin tinggi resolusi, semakin baik kualitas video yang dihasilkan, dalam artian bahwa ukuran fisiknya sama, video dengan resolusi tinggi akan lebih detail.
2. Kedalaman bit menentukan jumlah bit yang digunakan untuk merepresentasikan tiap piksel pada sebuah *frame*. Kedalaman bit dinyatakan dalam bit/piksel. Semakin banyak bit yang digunakan untuk merepresentasikan sebuah piksel, yang berarti semakin tinggi kedalaman pikselnya, maka semakin baik pula kualitasnya.
3. *Frame rate* menunjukkan jumlah *frame* tiap detik pada suatu video yang dinyatakan dengan *frame/second*. Video yang berkualitas baik akan memiliki *frame rate* yang tinggi, setidaknya harus menampilkan sedikitnya 25 *frame/second*.

Untuk menyampaikan suatu informasi tentu diperlukan suatu media, baik itu melalui media tulisan, media suara atau media citra/gambar. Dengan media tulisan, seseorang harus membaca terlebih dahulu baru dapat menerima informasi yang disampaikan. Dengan media suara, seseorang harus mendengarkan terlebih dahulu baru dapat menerima informasi yang disampaikan, dan tentunya media ini lebih baik dari media tulisan karena dapat menyampaikan informasi lebih banyak.

Dengan media citra, seseorang cukup dengan melihat sebuah citra sebentar saja sudah dapat menerima informasi lebih banyak dari media tulisan dan media suara yang membutuhkan waktu lebih banyak hanya untuk menyampaikan sebuah informasi saja (Mishra *et al.*, 2017). Kini dengan perkembangan teknologi yang semakin pesat, penyampaian informasi pun semakin mengalami perkembangan. Dari media citra berkembang menjadi media video yang merupakan sekumpulan banyak citra. Dan terus berkembang sehingga video juga dapat menampung media suara yang berjalan bersamaan dengan banyak citra, karena itu video termasuk multimedia. Sehingga dapat dikatakan video adalah suatu multimedia yang merupakan gabungan banyak citra dan media suara dapat diikutsertakan didalamnya, yang berjalan secara bersamaan sehingga menjadi sebuah video (Wang, Lo and Huang, 2016).

2.10 Estimasi Gerak

Estimasi gerak mempunyai peranan penting pada pengolahan video. Salah satu pemanfaatan estimasi gerakan adalah untuk, misalkan *video coding*, super resolusi, restorasi video dan lain lain. Sehingga sampai saat ini estimasi gerakan masih merupakan topik yang menarik untuk diteliti, Estimasi gerakan merupakan proses untuk menentukan pergerakan obyek-obyek pada video sekuensial. Pergerakan obyek tersebut dikenal dengan istilah *Motion Vector*. Metode yang sangat populer dan banyak digunakan adalah pendekatan berbasis area yang dikenal dengan *Block matching*. Mekanisme *Block matching* dilakukan dengan skema pencarian gerak dalam ukuran window tertentu. Estimasi Gerak membuat basis model *frame* baru pada data yang tersedia dalam satu atau lebih *frame encoded* sebelumnya yaitu *frame referensi*. Sebuah *Motion Vector* menunjukkan perpindahan sebuah titik diantara *frame* sekarang dengan *frame referensi*. Dari *Motion Vector* yang didapat, akan terlihat pergerakan titik-titik yang terjadi antar *frame* yang diamati. Dari situlah akan terlihat korelasi elemen temporal yang terjadi, apakah itu berupa pergerakan obyek ataukah perubahan sudut pandang atau pergerakan kamera (Poularakis *et al.*, 2017). Contoh hasil estimasi *Motion Vector* tampak pada Gambar 2.1.



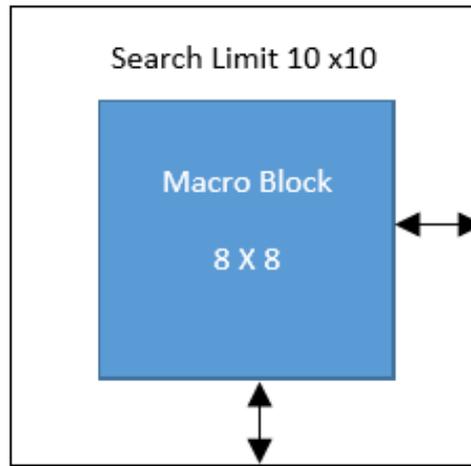
Gambar 2.1. *Frame A ke frame B menghasilkan motion vector C*

Pada umumnya metode estimasi gerakan dapat diklasifikasikan menjadi tiga kategori: metode berbasis feature, metode berbasis gradient dan metode berbasis area. Diantara ketiga metode tersebut yang sangat populer dan banyak digunakan adalah pendekatan berbasis area yang dikenal dengan *block matching* (Meuel *et al.*, 2016). Algoritma *block matching* terkenal akan kesederhanaannya dan kemudahan dalam implementasinya.

2.11 *Block matching*

Block matching adalah metode estimasi gerakan yang paling populer. *Block matching* dilakukan dengan membagi *frame* saat ini (*current frame*) ke dalam bentuk blok-blok piksel kemudian dibandingkan dengan blok yang posisinya sama

dan berdekatan dalam *search range* pada *frame* sebelumnya (*reference frame*). Hal ini bertujuan untuk menentukan perpindahan piksel dan direpresentasikan dengan *Motion Vector*. Berikut contoh pencarian *block matching* pada gambar 2.2.



Gambar 2.2. *Block* dengan ukuran macro blok 8x8 dengan search limit 10x10

Pada gambar 2.2. menampilkan ukuran *macro block* 8x8 dengan batas pencarian 10x10, maksud batas disini untuk membatasi *macro block* dalam mencari nilai kecocokan dari *frame* referensi ke *frame* tujuan.

2.12 *Sum of absolute difference*

Salah satu teknik Algoritma *Block matching* yang umum digunakan pada pengolahan video adalah *Sum of absolute differences* (SAD). Error matching antara blok pada posisi (n_1, n_2) pada *frame* sekarang F , dan kandidat blok pada posisi $((n_1 + d_1, n_2 + d_2))$ pada *frame* referensi F_2 , dapat didefinisikan oleh *Sum of absolute differences* (SAD) sebagai Persamaan 2.1.

$$SAD(d_1, d_2) = \sum_{(n_1, n_2) \in B} |I(n_1, n_2) - J(n_1 + d_1, n_2 + d_2)| \quad (2.1)$$

B pada Persamaan 2.1 adalah ukuran blok. Estimasi terbaik untuk blok *Motion Vector* (v_1, v_2) berada pada blok yang memiliki error matching terkecil dengan posisi $(n_1 + d_1, n_2 + d_2)$. Vektor (v_1, v_2) dapat dicari dengan menggunakan

Algoritma Full Search (FS) untuk menghitung dan membandingkan error matching untuk setiap posisi yang dicari pada *frame* referensi.

2.13 *Motion Vector*

Motion Vector adalah besaran dan arah pergerakan sebuah objek atau piksel dari satu koordinat pada *frame* sekarang ke koordinat berikutnya pada *frame* selanjutnya. Dengan *Motion Vector* tersebut akan terlihat besar dan arah pergerakan yang dilakukan sebuah objek atau piksel dari satu *frame* ke *frame* berikutnya. Sedangkan untuk mendapatkan *Motion Vector* digunakan algoritma *block matching*. Dimana titik-titik yang diamati pada gambar referensi diambil *macroblock*-nya untuk kemudian dicari letak titik yang bersesuaian pada gambar sekarang .

2.14 Pengurutan

Pengurutan data didefinisikan sebagai suatu proses untuk menyusun kembali humpunan obyek menggunakan aturan tertentu. Menurut Microsoft Bookshelf, definisi algoritma pengurutan adalah algoritma untuk meletakkan kumpulan elemen data ke dalam urutan tertentu berdasarkan satu atau beberapa kunci dalam tiap-tiap elemen.

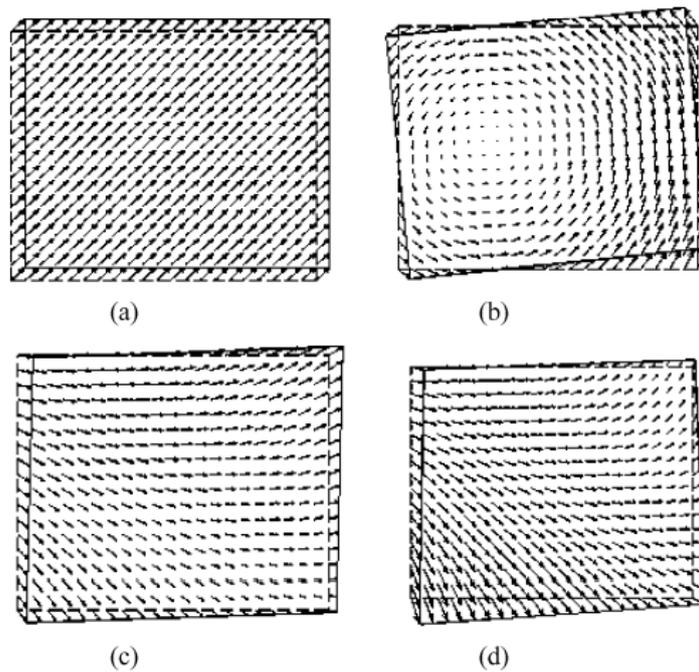
Ada dua macam urutan yang biasa digunakan dalam proses pengurutan yaitu :

1. Urut naik (*ascending*) yaitu dari data yang mempunyai nilai paling kecil sampai paling besar.
2. Urut turun (*descending*) yaitu data yang mempunyai nilai paling besar sampai paling kecil.

Keuntungan dari data yang sudah dalam keadaan terurutkan adalah data menjadi mudah dicari (misalnya dalam buku telepon atau kamus bahasa), mudah untuk dibetulkan, dihapus, disisipi atau digabungkan. Dalam keadaan terurutkan, kita mudah melakukan pengecekan apakah ada data yang hilang, mempercepat proses pencarian data yang harus dilakukan berulang kali.

2.15 Gerakan Global

Gerakan global dalam rangkaian video yang disebabkan oleh gerakan kamera, sering dimodelkan oleh transformasi parametrik gambar dua dimensi (Stiller and Konrad, 1999). Proses estimasi parameter transformasi disebut GME (*general motion estimation*). GME merupakan *tool* penting yang banyak digunakan dalam komputer visi, pengolahan video, dan bidang lainnya. Pertimbangkan sebuah titik pada objek yang bergerak di ruang tiga dimensi (3-D). Posisinya dapat dinyatakan dalam koordinat 3-D, dan mendefinisikan lintasannya yang bergerak di ruang 3-D dari waktu ke waktu. Sistem akuisisi gambar memproyeksikan dunia 3-D ke dalam bidang gambar 2-D dan sampel pada grid yang biasanya seragam. Proyeksi ini menghasilkan lintasan gerak 2-D. Secara umum, medan gerak adalah fungsi vektor gerak dari lintasan gerak pada koordinat ruang spasial. Dalam aplikasi praktis, fungsi ini biasanya dijelaskan dalam bentuk parametrik sebagai transformasi dengan set parameter atau lintasan gerak dari beberapa titik referensi. Representasi yang pertama lebih mudah untuk melakukan transformasi, dan yang terakhir lebih berguna untuk mengkodekan transformasi. Ini karena parameter model yang berbeda memerlukan tingkat presisi yang berbeda untuk mewakili, sementara menggambarkan pergerakan titik referensi dengan akurasi bilangan bulat atau setengah pixel biasanya cukup. Berbagai model gerak global parametrik praktis 2-D dan bidang Motion Vektor sesuai ditunjukkan pada Gambar 2.3. Model yang berbeda dilambangkan dengan jumlah parameter sebagai subskrip. Sebagai aturan umum, model orde yang lebih tinggi memiliki lebih banyak parameter dan dapat mewakili gerakan yang lebih kompleks. Model orde yang lebih rendah adalah kasus khusus model yang lebih umum. Model geometrik empat parameter dapat mewakili perbesaran isotropik, rotasi, dan gerakan terjemahan. Model affine memiliki enam parameter, dimana garis sejajar tetap sejajar dalam transformasinya (Meier and Giaschi, 2014).



Gambar 2.3. Tipe vektor gerak untuk bidang (a) Translasi, (b) geometri, (c) affine dan (d) model perspektif (Meier and Giaschi, 2014)

2.16 Deret Taylor

Deret Taylor merupakan dasar untuk menyelesaikan masalah dalam metode numerik, terutama penyelesaian persamaan diferensial (Wang and Yuan, 2017).

Berikut bentuk umum deret Taylor :

$$f(x_{i+1}) = f(x_i) + f'(x_i) \frac{\Delta x}{1!} + f''(x_i) \frac{\Delta x^2}{2!} + \dots + f^n(x_i) \frac{\Delta x^n}{n!} + R_n \quad (2.2)$$

Jika suatu $f(x)$ diketahui di titik x_i dan semua turunan f terhadap x diketahui pada titik tersebut, maka dengan deret Taylor dapat dinyatakan nilai f pada titik x_{i+1} yang terletak pada jarak Δx dari titik x_i .

Dimana $f(x_i)$ adalah fungsi di titik x_i , sedangkan $f(x_{i+1})$ adalah fungsi di titik x_{i+1} , $f', f'' \dots f^n$ adalah turunan pertama, kedua, Ke n dari fungsi, untuk

Δx adalah jarak antara x_i dan $x_{(i+1)}$, sedangkan R_n adalah kesalahan pemotongan, untuk ! adalah operator faktorial.

Dalam prakteknya sulit untuk memperhitungkan semua suku pada deret taylor tersebut dan biasanya hanya diperhitungkan beberapa suku pertama saja.

- Memperhitungkan satu suku pertama (order nol)

$$f(x_{i+1}) \approx f(x_i) \quad (2.3)$$

Artinya nilai f pada titik x_{i+1} sama dengan nilai pada x_i . perkiraan tersebut benar jika fungsi yang diperkirakan konstan. Jika fungsi tidak konstan, maka harus diperhitungkan suku-suku berikutnya dari deret taylor.

- Memperhitungkan dua suku pertama (order satu)

$$f(x_{(i+1)}) \approx f(x_i) + f'(x_i) \frac{\Delta x}{1!} \quad (2.4)$$

- Memperhitungkan tiga suku pertama (order dua)

$$f(x_{i+1}) = f(x_i) + f'(x_i) \frac{\Delta x}{1!} + f''(x_i) \frac{\Delta x^2}{2!} \quad (2.5)$$

Deret taylor akan memberikan perkiraan suatu fungsi yang benar jika semua suku dari deret tersebut diperhitungkan (Chung, 2016). Dalam prakteknya hanya beberapa suku pertama saja yang diperhitungkan sehingga hasilnya tidak tepat seperti pada penyelesaian analitik. Sehingga terdapat kesalahan (*error*) yang disebutkan dengan kesalahan pemotongan (truncation error, R_n), yang ditulis :

$$R_n = O(\Delta x^{n+1}) = f^{n+1}(x_i) \frac{\Delta x^{n+1}}{n+1} + f^{n+2}(x_i) \frac{\Delta x^{n+2}}{(n+2)!} + \dots \quad (2.6)$$

$O(\Delta x^{n+1})$ berarti kesalahan pemotongan mempunyai order Δx^{n+1} atau kesalahan adalah sebanding dengan langkah ruang pangkat $n + 1$.

Kesalahan pemotongan tersebut adalah kecil apabila :

1. Interval Δx adalah kecil.
2. Memperhitungkan lebih banyak suku dari deret Taylor.

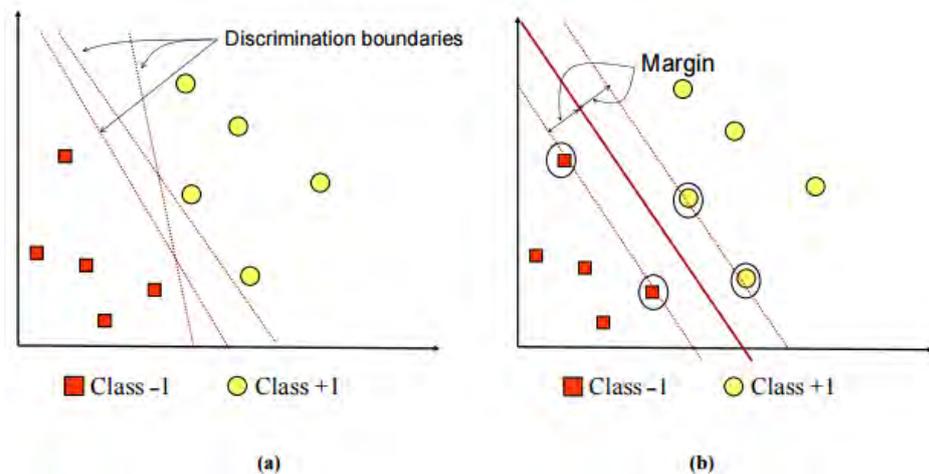
2.17 *Support Vector Machine*

Support Vector machine (SVM) pertama kali diperkenalkan oleh Vapnik pada tahun 1995 sebagai rangkaian konsep-konsep dalam bidang pattern recognition. Sebagai salah satu metode pattern recognition, evaluasi kemampuan dalam berbagai aplikasinya menempatkannya sebagai state of the art dalam pattern recognition, dan dewasa ini merupakan salah satu tema yang berkembang dengan pesat. SVM adalah metode learning machine yang bekerja atas prinsip Structural Risk Minimization dengan tujuan menemukan hyperplane terbaik yang memisahkan dua buah class pada input space.

Pattern Recognition merupakan salah satu bidang dalam komputer sains, yang memetakan suatu data ke dalam konsep tertentu yang telah didefinisikan sebelumnya. Konsep tertentu ini disebut class atau category. Aplikasi pattern recognition sangat luas, di antaranya mengenali suara dalam sistem sekuriti, mengklasifikasikan penyakit secara otomatis berdasarkan hasil diagnosa kondisi medis pasien dan sebagainya. Berbagai metode dikenal dalam pattern recognition, seperti linear discrimination analysis, hidden markov model hingga metode kecerdasan buatan seperti artificial neural network. Salah satu metode yang akhir-akhir ini banyak mendapat perhatian sebagai *state of the art* dalam pattern recognition adalah *support vector machine* (Pradhan, 2012).

Support vector machine (SVM) dikembangkan oleh Boser, Guyon, Vapnik, dan pertama kali dipresentasikan pada tahun 1992 di Annual Workshop on Computational Learning Theory. Konsep dasar SVM sebenarnya merupakan kombinasi harmonis dari teori-teori komputasi yang telah ada puluhan tahun sebelumnya, seperti margin hyperplane (Duda & Hart, 1973) (Cover, 1965)

(Vapnik, 1964), kernel diperkenalkan oleh Aronszajn tahun 1950, dan demikian juga dengan konsep-konsep pendukung yang lain. Akan tetapi hingga tahun 1992, belum pernah ada upaya merangkaikan komponen-komponen tersebut (Cholette *et al.*, 2017).



Gambar 2.4. SVM berusaha menemukan hyperplane terbaik yang memisahkan antara class -1 dan +1 (C Cortes and Vapnik, 1995)

Berbeda dengan strategi neural network yang berusaha mencari hyperplane pemisah antar class seperti tampak pada gambar 2.4, SVM berusaha menemukan hyperplane yang terbaik pada input space. Prinsip dasar SVM adalah linear classifier, dan selanjutnya dikembangkan agar dapat bekerja pada problem non-linear. dengan memasukkan konsep kernel trick pada ruang kerja berdimensi tinggi. Perkembangan ini memberikan rangsangan minat penelitian di bidang pattern recognition untuk investigasi potensi kemampuan SVM secara teoritis maupun dari segi aplikasi. Dewasa ini SVM telah berhasil diaplikasikan dalam problema dunia nyata (real-world problems), dan secara umum memberikan solusi yang lebih baik dibandingkan metode konvensional seperti misalnya artificial neural network. Tulisan ini memperkenalkan konsep dasar SVM, dan membahas aplikasinya di *biomedical engineering*, yang akhir-akhir ini merupakan salah satu bidang yang berkembang cukup pesat.

2.17.1 Pengenalan pola menggunakan *support vector machine*

Konsep SVM dapat dijelaskan secara sederhana sebagai usaha mencari hyperplane terbaik yang berfungsi sebagai pemisah dua buah class pada input space. Gambar 1a memperlihatkan beberapa pattern yang merupakan anggota dari dua buah class : +1 dan -1. Pattern yang tergabung pada class -1 disimbolkan dengan warna merah (kotak), sedangkan pattern pada class +1, disimbolkan dengan warna kuning(lingkaran). Problem klasifikasi dapat diterjemahkan dengan usaha menemukan garis (hyperplane) yang memisahkan antara kedua kelompok tersebut. Berbagai alternatif garis pemisah (discrimination boundaries). Ditunjukkan pada gambar 2.4-a.

Hyperplane pemisah terbaik antara kedua class dapat ditemukan dengan mengukur margin hyperplane tersebut. dan mencari titik maksimalnya. Margin adalah jarak antara hyperplane tersebut dengan pattern terdekat dari masing-masing class. Pattern yang paling dekat ini disebut sebagai support vector. Garis solid pada gambar 2.4-b menunjukkan hyperplane yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua class, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah support vector. Usaha untuk mencari lokasi hyperplane ini merupakan inti dari proses pembelajaran pada SVM.

Data yang tersedia dinotasikan sebagai $\vec{x}_i \in \mathcal{R}^d$ sedangkan label masing-masing dinotasikan $y_i \in \{-1, +1\}$ untuk $i = 1, 2, \dots, l$, yang mana l adalah banyaknya data. Diasumsikan kedua *class* -1 dan +1 dapat terpisah secara sempurna oleh hyperplane berdimensi d , yang di definisikan

$$\vec{w} \cdot \vec{x} + b = 0 \quad (2.7)$$

Pattern \vec{x}_i yang termasuk class -1 (sampel negatif) dapat dirumuskan sebagai pattern yang memenuhi pertidaksamaan

$$\vec{w} \cdot \vec{x} + b \leq -1 \quad (2.8)$$

Sedangkan pattern \vec{x}_i yang termasuk class +1 (sampel positif)

$$\vec{w} \cdot \vec{x} + b \geq +1 \quad (2.9)$$

Margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak antara hyperplane dan titik terdekatnya, yaitu $1/\|\vec{w}\|$. Hal ini dapat dirumuskan sebagai *Quadratic Programming (QP) problem*, yaitu mencari titik minimal persamaan 2.10, dengan memperhatikan *constraint* persamaan 2.11

$$\min \tau(w) = \frac{1}{2} \|\vec{w}\|^2 \quad (2.10)$$

$$y_i(\vec{x}_i \cdot \vec{w} + b) - 1 \geq 0, \quad \forall i \quad (2.11)$$

Problem ini dapat dipecahkan dengan berbagai teknik komputasi, diantaranya Lagrange Multiplier.

$$L(\vec{w}, b, a) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^l a_i (y_i((\vec{x}_i \cdot \vec{w} + b) - 1)) \quad (i = 1, 2, \dots, l) \quad (2.12)$$

a_i adalah Lagrange multipliers, yang bernilai nol atau positif ($a_i \geq 0$). Nilai optimal dari persamaan 2.11 dapat dihitung dengan meminimalkan L terhadap \vec{w} dan b , dan memaksimalkan L terhadap a_i . Dengan memperhatikan sifat bahwa pada titik optimal gradient $L = 0$. Persamaan 2.12 dapat dimodifikasi sebagai maksimalisasi problem yang hanya mengandung a_i . Sebagaimana persamaan 2.13.

Maximize :

$$\sum_{i=1}^l a_i - \frac{1}{2} \sum_{i,j=1}^l a_i a_j y_i y_j \vec{x}_i \cdot \vec{x}_j \quad (2.13)$$

Subject to :

$$a_i \geq 0 (i = 1, 2, \dots, l) \quad \sum_{i=1}^l a_i y_i = 0 \quad (2.14)$$

Dari hasil perhitungan diperoleh a_i yang kebanyakan bernilai positif. Data yang berkorelasi dengan a_i yang positif inilah yang disebut sebagai *support vector*.

2.17.2 Soft margin

Dalam beberapa kasus belum tentu kedua belah class dapat terpisah secara sempurna oleh hyperplane. Akan tetapi, umumnya dua belah class pada input space tidak dapat terpisah sempurna. Hal ini menyebabkan constraint pada persamaan 2.11 tidak dapat terpenuhi, sehingga optimasi tidak dapat dilakukan. Untuk mengatasi masalah ini, SVM dirumuskan ulang dengan memperkenalkan teknik *softmargin*. Dalam *softmargin*, persamaan 2.15 dimodifikasi dengan memasukkan *slack variable* ξ_i ($\xi_i > 0$).

$$y_i(\vec{x}_i \cdot \vec{w} + b) \geq 1 - \xi_i, \quad \forall_i \quad (2.15)$$

Dengan demikian persamaan 2.10 diubah menjadi :

$$\min_{\vec{w}} \tau(\vec{w}, \xi) = \frac{1}{2} \|\vec{w}\|^2 + c \sum_{i=1}^l \xi_i \quad (2.16)$$

Parameter C dipilih untuk mengontrol tradeoff antara margin dan error klasifikasi ξ . Nilai C yang besar berarti akan memberikan penalti yang lebih besar terhadap error klasifikasi.

2.17.3 Klasifikasi *Non Linier* pada SVM

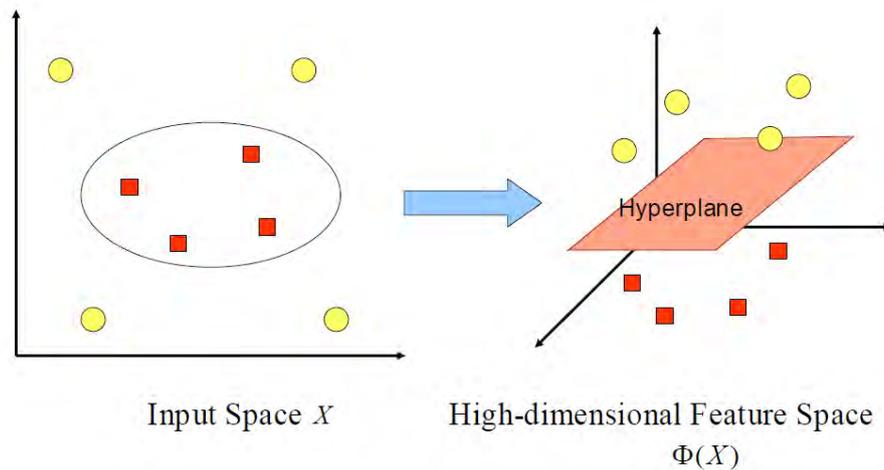
Pada umumnya masalah dalam domain dunia nyata (real world problem) jarang yang bersifat *linear separable*. Kebanyakan bersifat *non linear*. Untuk menyelesaikan problem *non linear*, SVM dimodifikasi dengan memasukkan fungsi Kernel. Dalam non linier SVM, pertama-pertama data \vec{x} dipetakan oleh fungsi $\Phi(\vec{x})$ ke ruang vektor yang berdimensi lebih tinggi. Pada ruang vektor yang baru ini, hyperplane yang memisahkan kedua class tersebut dapat dikonstruksikan. Hal ini sejalan dengan teori Cover yang menyatakan “Jika suatu transformasi bersifat non linear dan dimensi dari feature space cukup tinggi, maka data pada input space dapat dipetakan ke feature space yang baru, dimana *pattern-pattern* tersebut pada probabilitas tinggi dapat dipisahkan secara linear” (C Cortes and Vapnik, 1995).

$$\Phi: \mathbb{R}^d \rightarrow \mathbb{R}^q \quad d < q \quad (2.17)$$

Pada gambar 2.5-a, diperlihatkan data pada class kuning dan data pada class merah yang berada pada input space berdimensi dua tidak dapat dipisahkan secara linear. Selanjutnya gambar 2.5-b, menunjukkan bahwa fungsi Φ memetakan tiap data pada input *space* tersebut ke ruang vektor baru yang berdimensi lebih tinggi (3D), dimana kedua class dapat dipisahkan secara linear oleh sebuah hyperplane, persamaan 2.17 adalah Notasi matematikanya.

Pemetaan ini dilakukan dengan menjaga topologi data, dalam artian dua data yang berjarak dekat pada input space akan berjarak dekat juga pada feature space, sebaliknya dua data yang berjarak jauh pada input space akan juga berjarak jauh pada *feature space*. Selanjutnya proses pembelajaran pada SVM dalam menemukan titik-titik support vector, hanya bergantung pada dot product dari data yang sudah ditransformasikan pada ruang baru yang berdimensi lebih tinggi.

$$\Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) \quad (2.18)$$



Gambar 2.5. Fungsi Φ memetakan data ke ruang vektor yang berdimensi lebih tinggi, sehingga kedua class dapat dipisahkan secara linear oleh sebuah hyperplane (C Cortes and Vapnik, 1995)

Karena umumnya transformasi Φ ini tidak diketahui, dan sangat sulit untuk difahami secara mudah, maka perhitungan dot product tersebut sesuai teori Mercer dapat digantikan dengan fungsi kernel $K(\vec{x}_i, \vec{x}_j)$ yang mendefinisikan secara implisit transformasi Φ . Hal ini disebut sebagai *Kernel Trick*, seperti persamaan 2.19 .

$$K(\vec{x}_i, \vec{x}_j) = \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) \quad (2.19)$$

Kernel trick memberikan berbagai kemudahan, karena dalam proses pembelajaran SVM, untuk menentukan support vector, kita hanya cukup mengetahui fungsi kernel yang dipakai, dan tidak perlu mengetahui wujud dari fungsi non linear Φ . Berbagai jenis fungsi kernel, sebagaimana dirangkumkan pada Tabel 2.2.

Selanjutnya hasil klasifikasi dari data \vec{x} diperoleh dari persamaan berikut :

$$f(\Phi(\vec{x})) = \vec{w} \cdot \Phi(\vec{x}) + b \quad (2.20)$$

Tabel 2.2. Kernel yang umum dipakai pada SVM

No.	Nama Kernel	Definisi Fungsi
1	Linier	$K(x, y) = x \cdot y$
2	<i>Polinomial of degree d</i>	$K(x, y) = (x \cdot y)^d$
3	<i>Polinomial of degree up to d</i>	$K(x, y) = (x \cdot y + c)^d$
4	Gaussian RBF	$K(x, y) = \exp\left(\frac{-\ x - y\ ^2}{2\sigma^2}\right)$
5	Signoid (Tangen Hiperbolik)	$K(x, y) = \tanh(\sigma(x \cdot y) + c)$
6	<i>Invers Multi Kuadratik</i>	$K(x, y) = \frac{1}{\sqrt{\ x - y\ ^2 + c^2}}$
7	<i>Additive</i>	$K(x, y) = \sum_{i=1}^n K_i(x_i, y_i)$

Tabel 2.2 digunakan sesuai jenis dan model persebaran nilai fitur-fitur yang dimiliki untuk dilakukan proses klasifikasi. Dari persamaan (2.20) lanjutan rumus dari data \vec{x} dijelaskan pada rumus berikut ini:

$$f(\Phi(\vec{x})) = \sum_{i=1, \vec{x}_i \in SV}^n a_i y_i \Phi(\vec{x}) \cdot \Phi(\vec{x}_i) + b \quad (2.21)$$

$$f(\Phi(\vec{x})) = \sum_{i=1, \vec{x}_i \in SV}^n a_i y_i K(\vec{x}, \vec{x}_i) + b \quad (2.22)$$

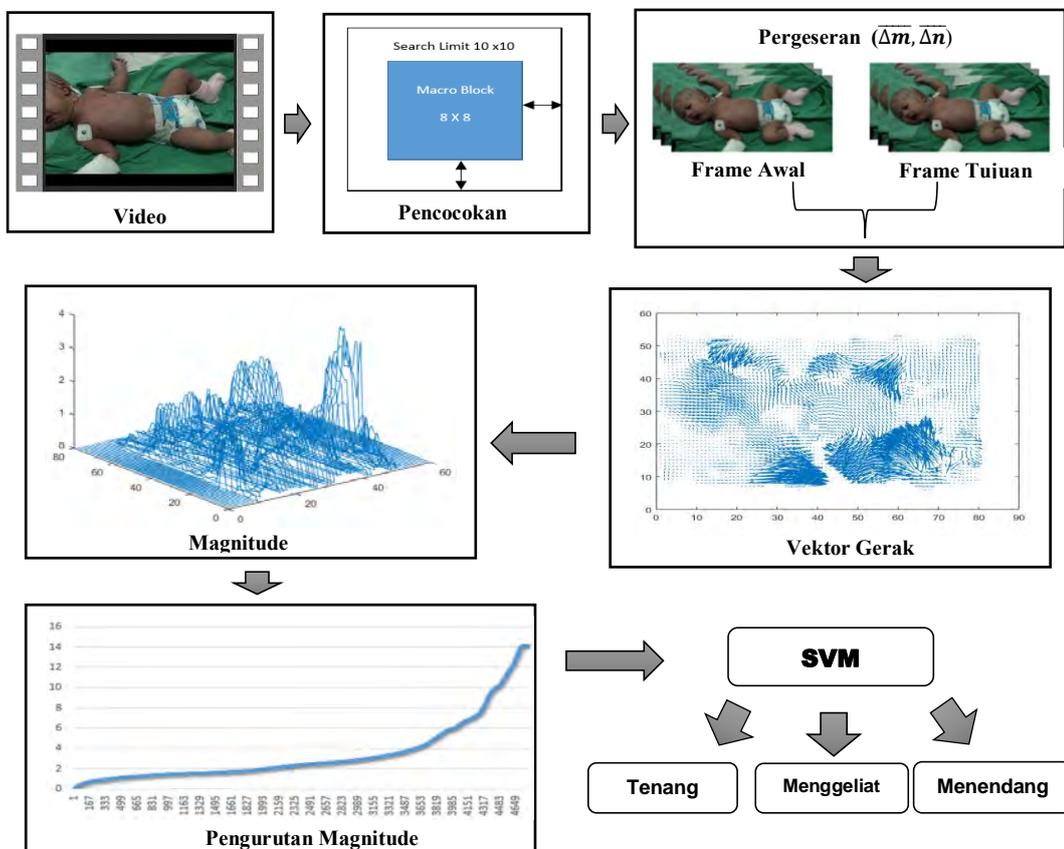
Pada persamaan 2.21 dan 2.22 dimaksudkan dengan *subset* dari *training set* yang terpilih sebagai *support vector*, dengan kata lain data \vec{x}_i yang berkorespondensi pada $a_i \geq 0$.

Halaman ini sengaja dikosongkan

BAB 3

METODOLOGI PENELITIAN

Pada bab ini dijelaskan garis besar langkah-langkah penelitian. Metodologi penelitian ini disusun agar penelitian fokus pada rencana awal, penelitian ini menggunakan indikator perilaku yang telah direkomendasikan (APA, 2012) yaitu menggunakan skala pengukuran nyeri menggunakan *FLACC* (*Face Leg Activity Cry Consolability*), penelitian ini khusus meneliti kategori *activity* pada *FLACC* dimana dalam kategori *activity* terbagi dalam tiga kelas *activity* yaitu kelas tenang, menggeliat dan menyentak, dimana masing-masing kelas memiliki skor berbeda-beda untuk mengukur tingkatan aktivitas pada bayi setelah operasi.



Gambar 3.1. Bagan penelitian klasifikasi aktivitas gerakan bayi setelah operasi berbasis *Motion Vector* menggunakan *Support Vector Machine*

3.1 Video Bayi

Video pada dasarnya tersusun atas serangkaian *frame* yang ditampilkan pada layar dengan kecepatan tertentu sesuai *frame rate* yang diberikan (dalam *frame/second*). Masing-masing *frame* merupakan citra digital. Karakteristik suatu video digital ditentukan oleh resolusi, kedalaman bit, dan *frame rate*. Pada penelitian ini pengambilan gambar video diambil dari bayi rawat inap yang akan menjalani pembedahan terencana di instalasi bedah pusat terpadu RSUD Dr. Soetomo oleh Hanindito, populasi penelitian dilakukan pada kasus pembedahan rawat inap pediatri (Hanindito, 2013).

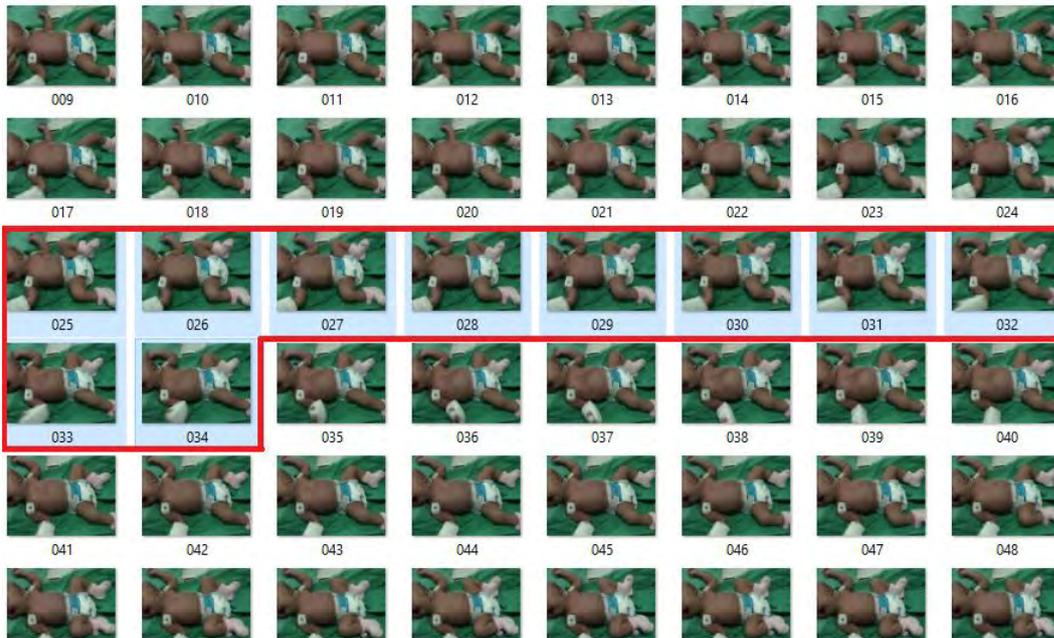
Hanindito membuat dataset yang terdiri dari 51 video dari 28 bayi. Yang terdiri dari 23 video sebelum operasi dan 28 video setelah operasi. Video diambil sebelum dan sesudah prosedur operasi. Selain itu juga mengukur hormon kortisol air liur pada bayi dan mencetak instrumen *FLACC* setiap bayi sebelum dan sesudah prosedur operasi. Kemudian Hanindito menyimpulkan apakah bayi sedang dalam keadaan nyeri parah, nyeri ringan, nyeri sedang, atau tidak sakit. Berdasarkan rekaman video dan pengukuran hormon kortisol pada air liur bayi, termasuk penilaian menggunakan *FLACC* dilakukan secara klinis di rumah sakit oleh dokter dan perawat, dengan izin dari orang tua bayi. Untuk penelitian ini menggunakan 46 video sebelum dan sesudah prosedur operasi. yang terdiri dari 23 video bayi sebelum operasi dan 23 video bayi setelah operasi. 46 video ini merupakan sumber kumpulan data video. Namun 5 video tidak dapat dilakukan pemrosesan karena kondisi data video tidak memenuhi syarat untuk dilakukan pemrosesan data, karena tidak secara frontal terlihat seluruh badan.

Dari 23 video setelah operasi, kami mengekstrak 10 *frame* dari setiap video dan memilih *frame* berurutan sebanyak 10 *frame* pada tiap-tiap video untuk gerakan aktivitas bayi. Contoh proses pemilihan *frame* dalam penelitian ini dapat dilihat pada Gambar 3.3. dalam penelitian ini terbagi dalam tiga kelas: kelas tenang, kelas menggeliat dan kelas menendang. Tujuan utamanya adalah untuk melakukan klasifikasi aktivitas gerakan setelah operasi dengan ketepatan tertinggi. Beberapa contoh dataset kita dapat dilihat pada Gambar 3.2.



Gambar 3.2. Contoh gambar dalam dataset aktivitas gerakan setelah operasi

Data yang kami proses berupa data bayi dengan usia lebih dari 1 bulan hingga kurang dari 6 bulan, karena pada masa *neonatus* (usia 1 bulan pertama) tangisan dan gerakan aktivitas bayi masih bersifat reflektoris belum mempunyai tujuan atau arti dari pihak bayi (Hanindito, 2013), respon dari individu sekitarnya selama bayi menangis memberikan pengalaman dan pembelajaran, untuk selanjutnya bayi akan memanfaatkan kemampuan tangis dan gerakannya sebagai saran komunikasi yang akan dilakukan untuk komunikasi dengan individu disekitarnya. Kondisi bayi saat dilakukan pengambilan video dalam kondisi bayi puasa selama 6 jam tidak minum susu dan 2 jam tidak minum air bening atau teh manis. Selanjutnya bayi direkam perilakunya dari jarak 1 meter setelah pembedahan menggunakan alat perekam gambar video Sony HDR-XR520, Kemudian dilakukan analisis untuk dilakukan klasifikasi berdasarkan aktivitas gerakan pada skala pengukuran nyeri FLACC.



Gambar 3.3. Contoh Pemilihan *Frame*

Pada gambar 3.3 adalah tahapan dalam memilih *frame* untuk nantinya dilakukan ekstraksi *Motion Vector*, dalam hal ini ada 23 video setelah operasi, setiap video diambil 10 *frame* secara berurutan. Hal ini dilakukan pemilihan dikarenakan tidak semua dalam video bisa digunakan untuk ekstraksi gerak, oleh karena itu dilakukan pemilihan *frame* tertentu secara berurutan, sedangkan alasan mengambil 10 *frame* dari setiap data video dikarenakan dengan mengambil 10 *frame* pada tiap-tiap video sudah cukup untuk pemrosesan data *image sequence*, kemudian kenapa tidak mengambil lebih dari 10 *frame* berurutan, dikarenakan ada data video dimana tidak bisa diambil lebih dari 10 *frame* dikarenakan kondisi kamera bergerak, sehingga untuk memudahkan dalam pengambilan data agar bisa dalam kondisi sama dengan mengambil 10 *frame* adalah pilihan terbaik, selain itu kenapa tidak mengambil kurang dari 10 *frame* dikarenakan jika terlalu sedikit maka akan terjadi kesulitan dalam hal penentuan pola dari tiap-tiap *frame* dan gerakan dalam *image sequence*.

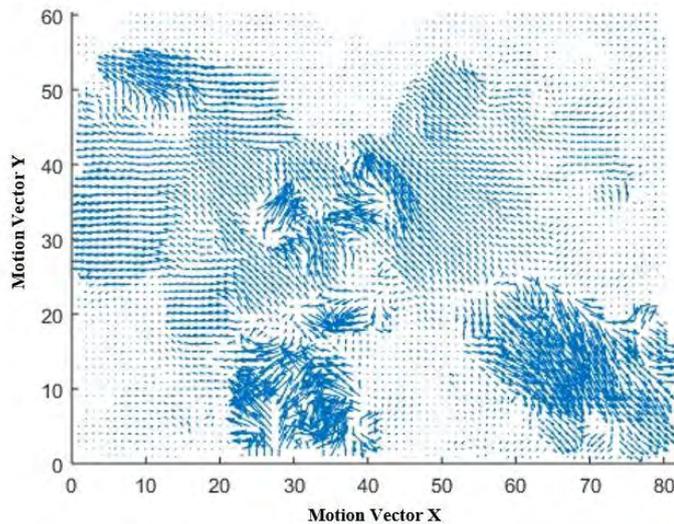
3.2 Estimasi Gerak

Estimasi gerakan merupakan proses untuk menentukan pergerakan piksel-piksel pada video, pergerakan piksel tersebut dikenal dengan istilah *Motion Vector*.

Sebuah *Motion Vector* menunjukkan perpindahan sebuah piksel diantara *frame* tujuan dengan *frame* referensi. Berdasarkan *Motion Vector* tersebut akan terlihat pergerakan piksel-piksel antar *frame* yang terbentuk dari arah motion sumbu *x* dan arah motion sumbu *y*, pada gambar 3.4 ukuran *Motion Vector* dalam penelitian ini yaitu 60 x 80 dengan jumlah data ada 4800 fitur *Motion Vector* per *frame*. sehingga rumus perhitungan dalam penelitian ini seperti pada persamaan 3.1.

$$JTF = FDSF \times JF \times JD \quad (3.1)$$

FDSF (Fitur dalam satu *frame*) yaitu 4800 dikalikan dengan JF (Jumlah *frame*) kemudian dikalikan JD (Jumlah data) maka menghasilkan JTF (jumlah total fitur). Sehingga dengan menggunakan persamaan 3.1, apabila penulis memiliki 23 video setelah operasi dan setiap data diambil 10 *frame* dan setiap *frame* memiliki 4800 fitur, maka penulis memiliki 1.104.000 fitur.



Gambar 3.4. *Motion Vector* dari dua *frame* berurutan.

Estimasi gerak merupakan proses untuk menentukan pergerakan piksel-piksel pada video, ukuran video pada penelitian kami yaitu 640 x 480, pergerakan piksel tersebut dikenal dengan istilah *Motion Vector*. Sebuah *Motion Vector* menunjukkan perpindahan sebuah piksel antar *frame* tujuan dengan *frame* referensi.

Berdasarkan *Motion Vector* tersebut akan terlihat pergerakan piksel-piksel antar *frame* yang terbentuk dari arah motion sumbu x dan arah motion sumbu y , pada gambar 3.4 ukuran *Motion Vector* dalam penelitian kami yaitu 60×80 dengan jumlah data ada 4800 fitur *Motion Vector*.

3.3 *Block matching* dengan deret Taylor

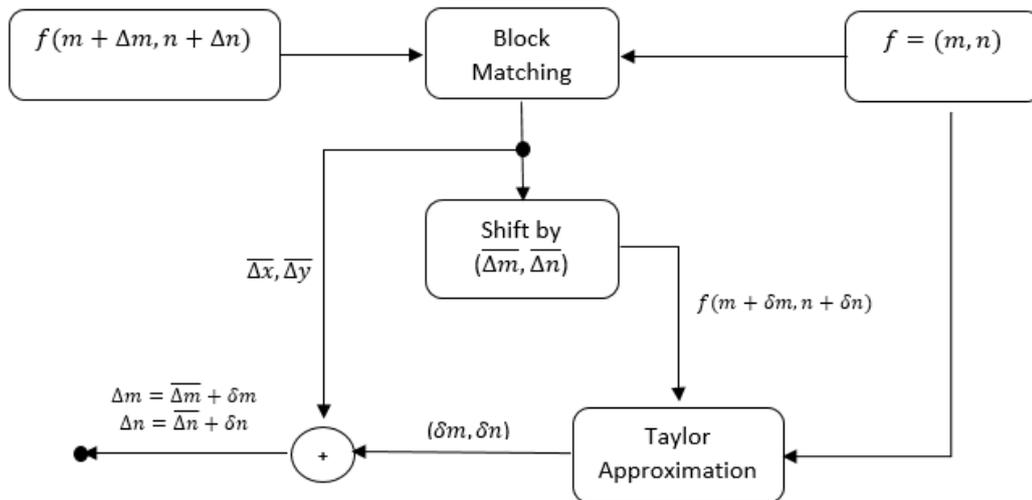
Block matching algorithm bertujuan menentukan perpindahan piksel antar *frame* dengan cara membagi *current frame* dan *reference frame* ke dalam bentuk blok-blok piksel. Dalam penelitian ini ukuran *macro block* berukuran 8×8 . Kemudian blok-blok pada *frame* saat ini dibandingkan dengan blok-blok dalam *search range* pada *frame* referensi untuk dihitung nilai dan arah perpindahannya yang di representasikan oleh sebuah *Motion Vector*. Daerah pencarian *macro block* dibatasi sampai dengan 10×10 piksel yang disebut dengan *search limit*, yang berfungsi membatasi daerah pencarian oleh *macro block*.

Pada penelitian ini kami menggunakan algoritma *block matching SAD* (*Sum of Absolute Differences*) untuk mendapatkan percobaan blok yang terbaik dalam daerah pencarian, blok dengan hasil perhitungan nilai terkecil adalah hasil yang paling sesuai dengan *frame* saat ini dan akan menentukan *Motion Vector*. Yang di deskripsikan pada persamaan berikut :

$$SAD(d_1, d_2) = \sum_{(n_1, n_2) \in B} |I(n_1, n_2) - J(n_1 + d_1, n_2 + d_2)| \quad (3.2)$$

Error matching antara blok pada posisi (n_1, n_2) pada *frame* sekarang I_1 dan kandidat blok pada posisi $(n_1 + d_1, n_2 + d_2)$ pada *frame* referensi J_2 . B adalah ukuran *macro blok*, estimasi terbaik untuk blok matching berada pada blok yang memiliki error matching terkecil dengan posisi $(n_1 + d_1, n_2 + d_2)$, dalam penelitian ini menggunakan algoritma *full search*.

Ketika sudah menemukan besaran nilai *Motion Vector* hasil dari *block matching* kemudian dilakukan pendekatan Taylor untuk meningkatkan nilai ketelitian, adapun *block diagram* seperti gambar 3.5.



Gambar 3.5. Block diagram *motion estimation* menggunakan block matching dengan pendekatan Taylor.

Dilakukan pencocokan *frame* menggunakan algoritma *Block matching* pada *Frame* awal $f(m, n)$ dengan *frame* tujuan $f(m + \Delta m, n + \Delta n)$ kemudian setelah mendapatkan hasil nilai besaran perpindahan $\overline{\Delta m}, \overline{\Delta n}$ digunakan sebagai inputan untuk pemrosesan deret Taylor dengan *frame* awal, hasil dari deret Taylor akan dijumlahkan dengan hasil besaran dari *block matching*, sehingga menghasilkan nilai perubahan *Motion Vector* dengan ketelitian tinggi. Berikut rumus deret Taylor :

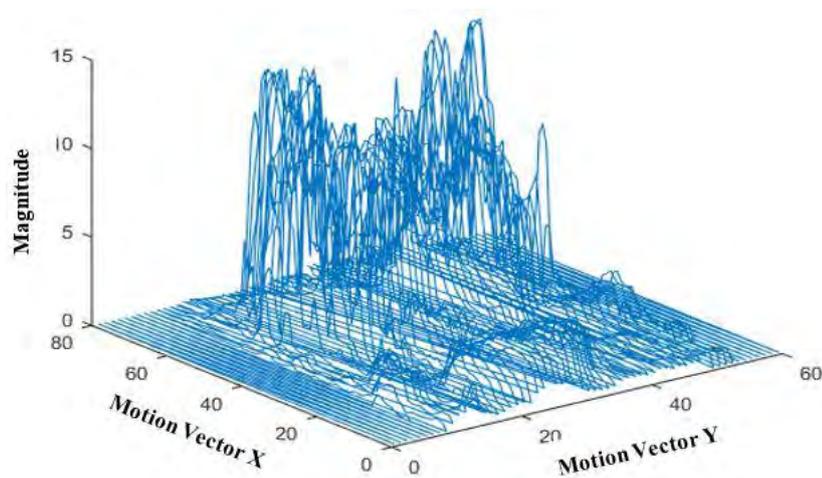
$$\begin{aligned}
 l(m, n) &= f(m + \Delta m, n + \Delta n) \\
 &\approx f(m, n) + \Delta m \frac{\partial}{\partial m} f(m, n) + \Delta n \frac{\partial}{\partial n} f(m, n)
 \end{aligned}
 \tag{3.3}$$

Dimana *frame* awal $f(m, n)$ dijumlahkan dengan selisih besaran hasil dari perhitungan *block matching* yaitu Δm adalah selisih *Motion Vector* m dan Δn adalah selisih *Motion Vector* n .

3.4 Magnitude

Magnitude digunakan untuk mengetahui besaran dari nilai hasil *Motion Vector*, namun pada magnitude tidak diketahui letak posisi terbesar dari besaran terbesar dari magnitude, sehingga untuk memudahkan dalam analisis besaran

magnitude di ambil yang terbesar dengan cara dilakukan pengurutan atau sorting dengan tujuan agar bisa dilihat berapa besaran terbesar dari tiap-tiap *frame* tersebut, yang nantinya besaran terbesar tersebut digunakan sebagai fitur untuk penentuan besarnya motion pada dua *frame* tersebut.



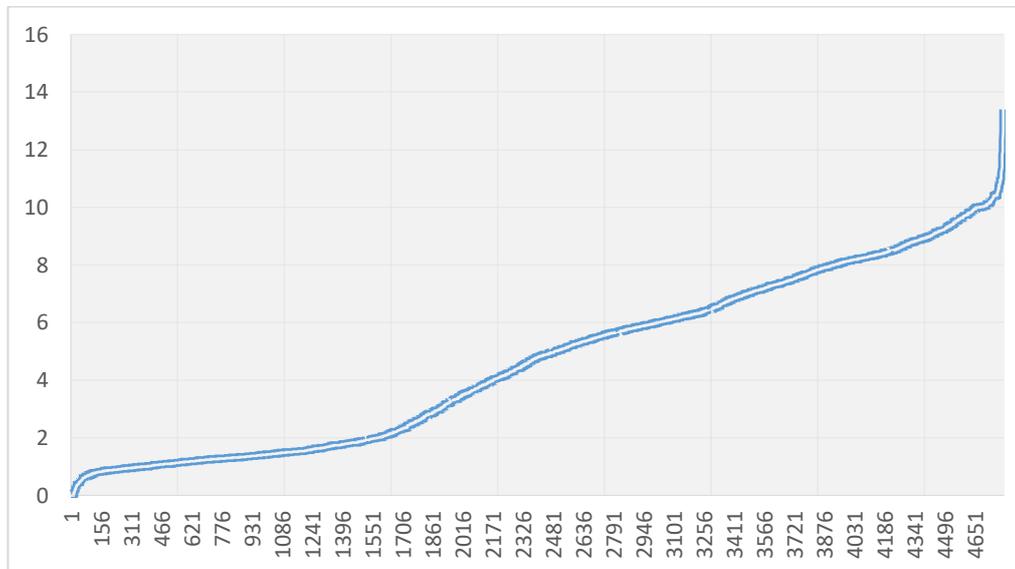
Gambar 3.6. Magnitude dari dua *frame* berurutan

Pada gambar 3.6 tidak diketahui letak posisi terbesar dari besaran terbesar dari magnitude yang saya maksud adalah tidak mengetahui dimana letak gerakan terbesar dan berapa besaran terbesar, karena kondisi data pada magnitude adalah secara tersebar, hal ini bermanfaat untuk mengetahui fitur gerakan dalam sebuah *frame* terhadap besaran magnitude, seperti pada gambar 3.6 hal ini dapat dilakukan dengan melakukan *sorting* data *Motion Vector*, sehingga dari hal itu kita dapat dilihat seberapa besar besaran gerakan pada masing-masing *frame* dan hal ini bisa dijadikan sebagai fitur,.

3.5 Pengurutan

Pengurutan dilakukan dengan menjadikan matrik menjadi satu dimensi kemudian dilakukan pengurutan dari nilai terkecil ke nilai terbesar untuk mengetahui besaran terbesar dari hasil ekstraksi vektor gerak dari dua *frame*. Dengan dilakukan pengurutan dapat diketahui besaran terbesar dari dua *frame* tersebut dan menjadi fitur dari , besaran terbesar tersebut dijadikan sebagai *feature* dari gerakan antar *frame*. Sehingga nantinya besaran magnitude bisa di bandingkan

dengan *frame* selanjutnya, sekaligus sebagai *feature* dari gerakan pada *frame* tersebut untuk nantinya dilakukan klasifikasi.



Gambar 3.7. besaran aktivitas gerakan bayi setelah dilakukan sorting

Pada gambar 3.6 adalah magnitude dimana bisa dilihat besarannya namun tidak diketahui letaknya dimana dikarenakan tersebar, selain itu kesulitan lain yaitu sulit untuk menemukan pola dari gerakan aktivitas berdasarkan data magnitude, oleh karena itu untuk memudahkan dalam melakukan analisa dan pola terhadap data motion dilakukan pengurutan data dengan hasil seperti pada gambar 3.7, dimana dengan pengurutan data bisa dilihat pola grafik dan juga besar nya gerakan aktivitas pada data motion, untuk nantinya bisa dijadikan data untuk pengenalan pola oleh SVM (*support vector machine*).

3.6 Global motion

Dalam penelitian ini penulis menemukan ada global motion dalam data video, dimana dalam global motion ini digunakan oleh penulis untuk membedakan objek yang bergerak atau kamera yang bergerak. Sehingga dalam melakukan penelitian ini bisa dibedakan ketika oboek bayi yang bergerak atau kamera yang bergerak, hal ini sangat penting untuk meningkatkan validasi dari data yang diproses. Pola global motion adalah besaran magnitude yang cenderung datar,

dikarenakan besarannya cenderung sama dan searah dalam satu *frame*. Sedangkan untuk gerakan bayi yang sesungguhnya polanya adalah lonjakan secara ekstrim. Pada gambar 3.8 adalah contoh global motion dimana dalam satu frame penuh terjadi pergerakan namun pergerakan tidak sebesar jika ada gerakan pada bayi.



Gambar 3.8 contoh global motion

Dalam penelitian ini penulis menemukan data dimana data ini sangat kecil dan cenderung konstan atau tidak ada lonjakan data seperti data yang lain, awalnya penulis mengira hal ini adalah bagian pola dari gerakan aktivitas bayi setelah operasi, dikarenakan ada juga dimana ukuran pola dan besarannya seperti itu, namun ada hal yang sangat membedakan dengan pola yang lain, yaitu bentuknya yang cenderung besarannya tetap, setelah ditelusuri ternyata ditemukan data seperti pada gambar 3.8 dimana *Motion Vector* seluruh *frame* bergerak ke arah tertentu dengan besaran relatif sama, hal ini terjadi dikarenakan ada pergerakan kamera pada saat pengambilan data, sehingga hal semacam ini oleh penulis digunakan sebagai pembeda data antar data objek gerak bayi dan data global motion dilihat dari polanya.

3.7 *Support Vector Machine*

Pada tahapan klasifikasi untuk membedakan kelas tenang, menggeliat dan menyentak pada bayi setelah operasi menggunakan *support vector machine*, pada tahapan ini digunakan data yang terdiri dari 23 video setelah operasi, dimana setiap video diambil 10 *frame*, dimana setiap data memiliki 4800 atribut fitur motion. 90 data digunakan sebagai data training dan 21 digunakan sebagai data testing.

Dalam proses pengujian sistem dilakukan dua tahap, tahap yang pertama adalah pelatihan sedangkan tahap yang kedua adalah tahap pengujian. Tahap pelatihan digunakan untuk mendapatkan koordinat dari support vector, weight, bias dan jarak support vector, koordinat-koordinat kemudian digunakan pada proses pengujian menggunakan data-data selain data pelatihan yaitu 21 data gerakan aktivitas bayi, aktivitas gerakan bayi setelah operasi untuk mendapatkan hasil klasifikasi, sehingga dapat diketahui tingkat akurasi. Nilai akurasi didapatkan dengan perbandingan antara hasil klasifikasi dengan hasil target.

Pada proses klasifikasi akan menggunakan *function* LibSVM yang dapat digunakan untuk klasifikasi SVM. Pada *function* LibSVM formula yang akan digunakan *C-support vector classification* (C-SVC) dengan kernel RBF (*Radial Basic Function*) Pada penelitian ini data yang digunakan berbentuk numerik dan proses klasifikasi tidak dapat di asumsikan secara linear, oleh karena itu akan digunakan kernel sebagai parameter yang dapat melakukan klasifikasi terhadap data yang bersifat tidak linear. Melakukan klasifikasi data yang tidak dapat diklasifikasikan secara linier dengan cara mentransformasikan data kedalam ruang fitur (*feature space*) berdimensi tinggi sehingga dapat dipisah secara linier pada *feature space*.

Feature space dalam prosesnya biasanya memiliki dimensi yang lebih tinggi dari vektor input (*input space*). Hal ini akan mengakibatkan komputasi pada *feature space* akan menjadi sangat besar, karena ada kemungkinan *feature space* akan memiliki jumlah feature yang tidak terhingga. Selain itu, untuk mengetahui fungsi transformasi yang tepat juga sangat sulit. Untuk itu pada SVM menggunakan “*kernel trick*”. Syarat sebuah fungsi untuk menjadi fungsi kernel adalah memenuhi Teorema Mercer yang menyatakan bahwa matriks kernel yang dihasilkan harus bersifat positif *semidefinite*.

Pada formula *C-Support Vector Classification* diberikan pelatihan vektor $x_i \in R^n, i = 1, \dots, l$, pada dua kelas dan vektor indikator $y \in R^l$ seperti pada $y_i \in \{1, -1\}$ (Corinna Cortes and Vapnik, 1995) memecahkan masalah optimasi sebagai berikut:

$$\min_{w, b, \xi} \frac{1}{2} w^T w + C \sum_{i=1}^l \xi_i \quad (3.4)$$

$$\begin{aligned} \text{Subject to } & y_i (w^T \phi(x_i) + b) \geq 1 - \xi_i, \\ & \xi_i \geq 0, i = 1, \dots, l, \end{aligned} \quad (3.5)$$

Dimana $\phi(x_i)$ Memetakan x_i ke ruang dimensi yang lebih tinggi dan $C > 0$ adalah parameter reguler, karena kemungkinan dimensi tinggi vektor pada variabel w ,

$$\min_a \frac{1}{2} a^T Q a - e^T a \quad (3.6)$$

$$\begin{aligned} \text{Subject to } & y^T a = 0, \\ & 0 \leq a_i \leq C, i = 1, \dots, l, \end{aligned} \quad (3.7)$$

Dimana $e = [1, \dots, 1]^T$ adalah vektor dari semua 1, Q adalah l dari l positive semidefinite matrix, $Q_{ij} \equiv y_i y_j K(x_i, x_j)$ dan $K(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j)$ adalah fungsi kernel. Setelah masalah vektor dari semua sudah terselesaikan, menggunakan primal-dual relationship, optimalisasi w :

$$w = \sum_{i=1}^l y_i a_i \phi(x_i) \quad (3.8)$$

Dan fungsi keputusannya adalah

$$\text{sgn}(w^T \phi(x) + b) = \text{sgn} \left(\sum_{i=1}^l y_i a_i K(x_i, x) + b \right) \quad (3.9)$$

Kemudian menyimpan $y_i a_i \forall_i, b$, nama label, support vector, dan informasi lainnya seperti Parameter kernel pada model untuk prediksi.

3.7.1 Pengukuran Kinerja Klasifikasi

Pengukuran kinerja klasifikasi pada data asli dan data hasil dari model klasifikasi dilakukan dengan menggunakan tabulasi silang (matriks konfusi) yang berisi informasi tentang kelas data asli yang direpresentasikan pada baris matriks dan kelas data hasil prediksi suatu algoritma direpresentasikan pada kolom klasifikasi.

Tabel 3.1. Matrik konfusi dua kelas

		Kelas Prediksi	
		Kelas 1	Kelas 2
Kelas Aktual	Kelas 1	A	B
	Kelas 2	C	D

Ketepatan klasifikasi dapat dilihat dari akurasi klasifikasi. Akurasi klasifikasi menunjukkan performansi model klasifikasi secara keseluruhan, dimana semakin tinggi akurasi klasifikasi hal ini berarti semakin baik performansi model klasifikasi.

$$Akurasi\ Klasifikasi = \frac{A + D}{B + D} \quad (3.10)$$

$$Error\ Klasifikasi = \frac{B + C}{A + B + C + D} \quad (3.11)$$

Semua klasifikasi berusaha untuk membentuk model dengan nilai akurasi tinggi dan error rendah. Untuk mengetahui validasi dari sebuah metode diperlukan pendekatan yang mengevaluasi hasil perhitungan. Pada umumnya validasi yang dihitung juga berkaitan dengan perhitungan ROC area yang menghitung akurasi, sensitifitas dan spesifisitas berdasarkan TP, FP, TN, dan FN. Dimana TP adalah *true positif* (nilai kebenaran antara hasil uji coba dengan kelas sebenarnya), TN adalah *true negatif* (nilai kebenaran antara hasil ujicoba dengan kelas lainnya), FP adalah *false positif* (nilai ketidaktepatan antara hasil ujicoba dengan kelasnya), dan

FN adalah *false negatif* merupakan nilai ketidaktepatan antara hasil ujicoba dengan kelas lainnya.

Detail Akurasi	Keterangan
<i>TP Rate (True Positive)</i>	Tingkat positif yang benar (uji coba diklasifikasikan dengan benar sebagai kelas yang diberikan)
<i>FP Rate (False Positive)</i>	Tingkat positif yang tidak benar (contoh yang salah dikategorikan sebagai kelas tertentu)
<i>Precision</i>	Proporsi sampel dataset yang benar-benar kelasnya dibagi dengan dataset total yang diklasifikasikan sebagai kelas itu
<i>Recall</i>	Proporsi sampel dataset yang diklasifikasikan sebagai kelas yang diberikan dibagi dengan jumlah aktual di kelas tersebut (setara dengan TP)
<i>F-Measure</i>	Ukuran gabungan untuk presisi dan <i>recall</i> dihitung sebagai $2 * Precision * Recall / (Precision + Recall)$
<i>ROC Area</i>	Kurva karakteristik operasi relatif, merupakan perbandingan dua karakteristik operasi (TP dan FP)
<i>PRC Area</i>	Kurva karakteristik dari proposi sampel uji coba, perbandingan <i>precision</i> dan <i>recall</i>

Berikut adalah rumus akurasi dalam pengukuran kinerja klasifikasi pada SVM (*support vector machine*):

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.12)$$

Selanjutnya adalah rumus spesifitas dalam pengukuran kinerja klasifikasi pada SVM (*support vector machine*):

$$\text{Spesifisitas} = \frac{TN}{TN + FP} \quad (3.13)$$

Untuk mengevaluasi hasil prediksi juga digunakan pengukuran hasil akurasi perkiraan suatu model. Dengan pendekatan *Root Mean Square Error* (RMSE) dan *Mean Absolute Error* (MAE) dengan rumus berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (a_{obs,i} - a_{model,i})^2}{n}} \quad (3.14)$$

RMSE adalah aturan penilaian kuadrat yang juga mengukur besarnya rata-rata kesalahan. Metode akar kuadrat dari rata-rata perbedaan kuadrat antara prediksi dan pengamatan sebenarnya. RMSE telah digunakan sebagai metrik statistik standar untuk mengukur kinerja model dalam sebuah penelitian (Chai and Draxler, 2014).

$$MAE = \frac{1}{n} \sum_{i=1}^n |a_i - a| \quad (3.15)$$

MAE juga merupakan ukuran lain yang berguna yang banyak digunakan dalam evaluasi model. MAE mengukur besarnya rata-rata kesalahan dalam serangkaian prediksi, tanpa mempertimbangkan arahnya. Ini merupakan rata-rata diatas sampel uji perbedaan *absolut* antara prediksi dan pengamatan aktual, dimana semua perbedaan memiliki bobot yang serupa.

Halaman ini sengaja dikosongkan

BAB 4

HASIL DAN PEMBAHASAN

Bab ini membahas tentang implementasi dari tahapan-tahapan proses yang ada pada bab 3 untuk mendapatkan hasil klasifikasi aktivitas gerakan bayi setelah operasi menggunakan *support vector machine*. Gerakan aktivitas bayi setelah operasi berasal dari fitur *Motion Vector* yang akan dianalisa berdasarkan besaran gerakan pada tiap-tiap *frame* berurutan berdasarkan selisih pergerakan antar *frame* referensi dengan *frame* tujuan. Data input pada penelitian ini menggunakan video yang diambil pada bayi rawat inap yang telah menjalani pembedahan terencana di instalasi bedah pusat terpadu RSUD Dr. Soetomo oleh Hanindito, Video diambil oleh Hanindito setelah prosedur operasi, populasi penelitian dilakukan pada kasus pembedahan rawat inap pediatri.

4.1 Ekstraksi Fitur *Motion Vector*

Berdasarkan inputan berupa video pada penelitian ini dengan ukuran resolusi 480 x 640, kemudian dilakukan pencocokan *block* dari *frame* referensi dengan *frame* tujuan menggunakan algoritma *block matching Sum of absolute difference* dengan ukuran *block matching* 8 x 8 dengan batas pencarian berukuran 10 x 10, dengan penambahan pendekatan taylor menghasilkan *Motion Vector* dengan ukuran 60 x 80, sehingga pada setiap melakukan pencocokan dari *frame* referensi dengan *frame* tujuan menghasilkan 4800 fitur *Motion Vector* hasil dari ekstraksi video ukuran 480 x 640. Dari total 23 video setelah operasi kami mengekstrak 10 *frame* dari setiap video dan memilih gerakan aktivitas bayi yang sesuai dengan gerakan aktivitas pada bayi.

4.1.1 Hasil Ekstraksi Fitur *Motion Vector*

Video yang digunakan dengan resolusi 480 x 640 Inputan dari video diambil beberapa *frame* yang saling berurutan untuk nantinya dilakukan ekstraksi *Motion Vector*, gambar 4.1 menunjukkan *frame* yang dipilih pada video setelah operasi untuk nantinya dilakukan ekstraksi *Motion Vector*.



Frame 25



Frame 26



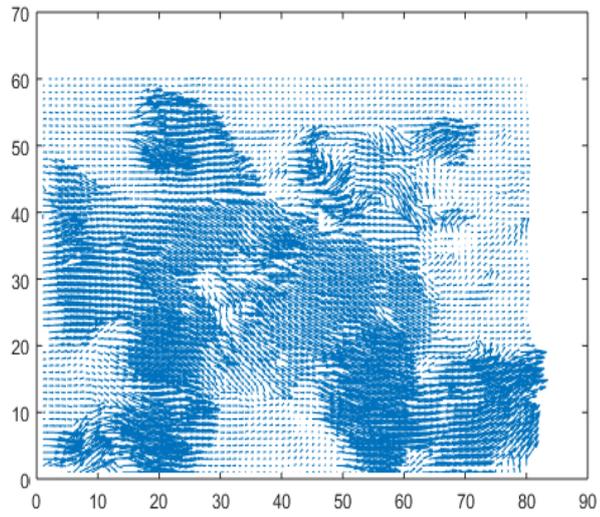
Frame 27



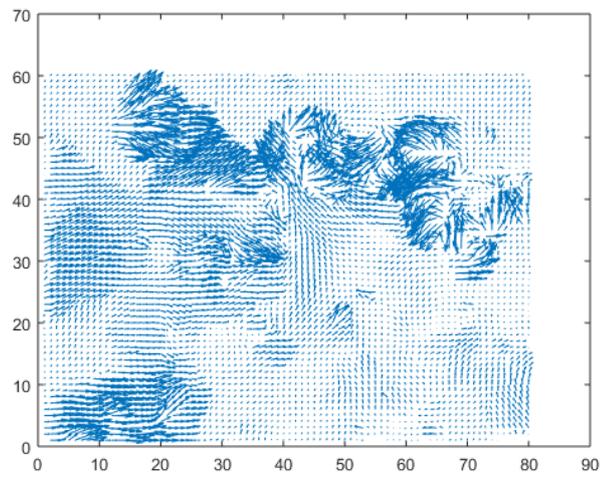
Frame 28

Gambar 4.1. Inputan dengan *frame* terpilih dari video pasca operasi

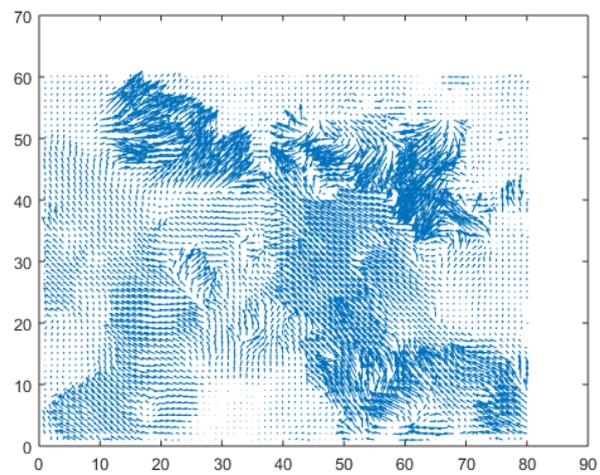
Setelah melakukan pemilihan *frame* tertentu pada video untuk selanjutnya dilakukan pemrosesan untuk ekstraksi *Motion Vector* dari *frame* referensi dengan *frame* tujuan untuk mengetahui seberapa besar pergerakan objek bayi dalam *frame* tersebut. Ekstraksi *Motion Vector* ini menggunakan *block matching* ukuran 8 x 8 menggunakan *Sum of absolute difference* dengan tambahan deret Taylor. Pada gambar 4.2 menunjukkan hasil ekstraksi *Motion Vector* dari *frame* yang ada pada gambar 4.1 untuk kasus bayi pasca operasi.



Frame 25-26

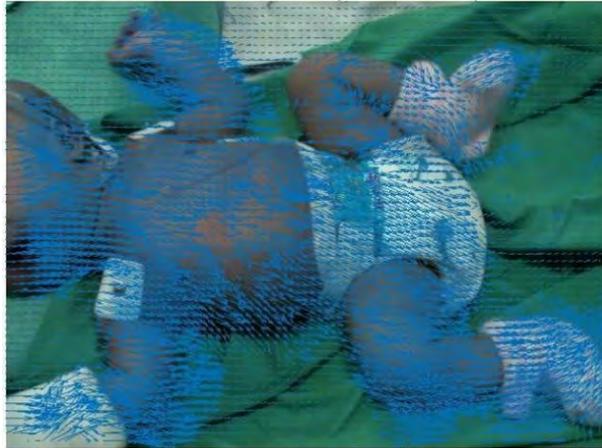


Frame 26-27



Frame 27-28

Gambar 4.2. Hasil ekstraksi *Motion Vector* pada bayi setelah operasi



Motion Vector Frame 25-26 (a)



Motion Vector Frame 26-27 (b)



Motion Vector Frame 27-28 (c)

Gambar 4.3. Gabungan *Motion Vector* dengan *frame* video setelah operasi (a-c)

Dari gambar 4.1 diketahui inputan video dalam *frame* yang berurutan, selanjutnya dilakukan ekstraksi *Motion Vector* dengan hasil seperti yang ditunjukkan pada gambar 4.2, selanjutnya dilakukan validasi terhadap hasil ekstraksi tadi dalam bentuk *Motion Vector* sesuai dengan gerakan dari data inputan, sehingga dilakukan penggabungan antar *Motion Vector* hasil ekstraksi dengan *frame* inputan, hasilnya bisa dilihat pada pada gambar 4.3.

Gabungan *Motion Vector* dengan *frame* tujuan ini adalah untuk mengetahui apakah arah motion sudah sesuai dengan arah objek yang sesungguhnya pada gerakan aktivitas bayi setelah operasi, hal ini diperlukan untuk validasi terhadap hasil ekstraksi *Motion Vector*.

Tabel 4.1 menunjukkan sampel hasil ekstraksi nilai *Motion Vector* dari gambar 4.3, dengan data terakhir dan tertinggi dari beberapa *frame* yang berurutan setelah dilakukan sorting atau pengurutan.

Tabel 4.1. Sampel dari nilai *Motion Vector* pada bayi setelah operasi

Frame	Fitur ke								
	1	2	3	4	...	4797	4798	4799	4800
25-26	0	0	0	0	...	12.29697086	12.64552	12.78385	13.38612
26-27	0	0	0	0	...	13.67910654	13.67911	13.69959	14.09399
27-28	0	0	0	0	...	14.14213562	14.14214	14.14214	14.14214

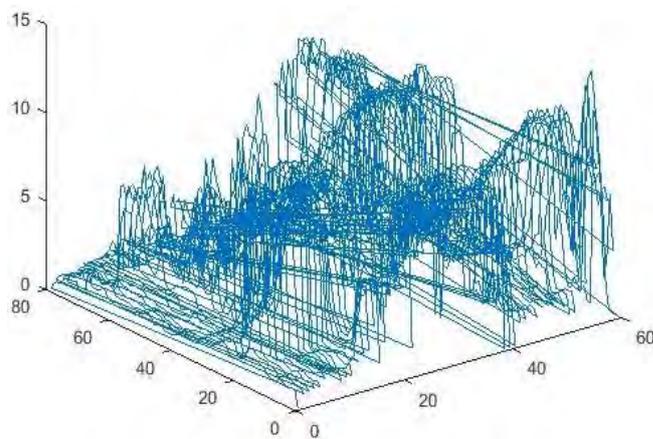
Hasil pada Tabel 4.1 adalah sampel dari nilai hasil ekstrak *Motion Vector*, ada 4800 fitur motion dalam setiap hasil ekstraksi *Motion Vector*, didapat dari membandingkan dua *frame* yang berurutan secara kontinyu. Pada Tabel 4.1 menampilkan hasil dengan adanya penambahan deret taylor, dengan hasil acak kesulitan dalam penentuan pola, sehingga untuk memudahkan dalam melakukan analisa, dilakukan dengan cara pengurutan untuk mempermudah menemukan pola dari tiap-tiap *frame* secara kontinyu. Pendekatan Taylor digunakan dalam penelitian untuk tingkat ketelitian tinggi terhadap objek yang di ekstrak.

4.2 Nilai Magnitude Berdasarkan Data *Motion*

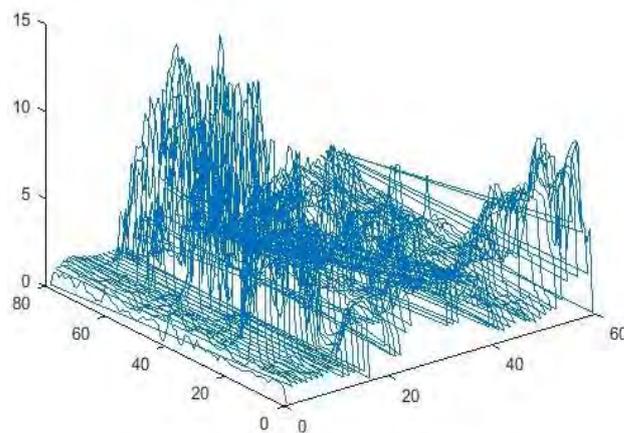
Magnitude dalam penelitian ini adalah untuk mengetahui seberapa besar gerakan aktivitas gerakan bayi, sehingga dari magnitude bisa mengetahui seberapa besar aktivitas gerakan bayi, yang menjadi masalah adalah berapa besaran terbesar dari sebuah hasil dari ekstraksi motion pada setiap perbandingan dari dua *frame* yang berurutan. Hal ini diperlukan untuk kemudahan dalam analisa hasil dari data motion.

4.2.1 Hasil *Magnitude*

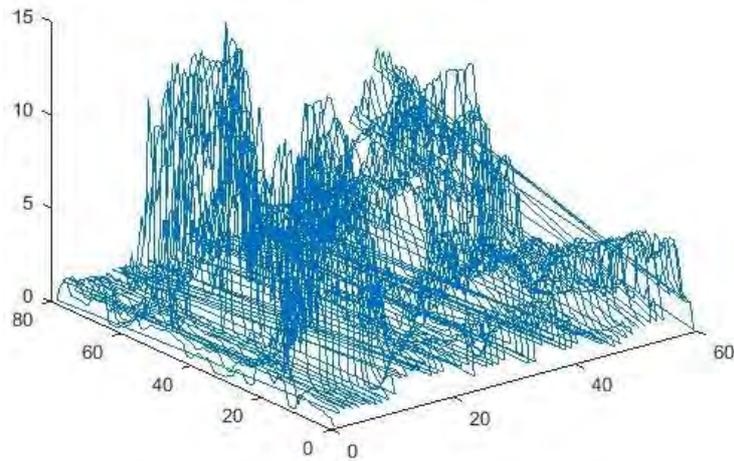
Gambar 4.4 adalah contoh sampel hasil dari magnitude aktivitas gerakan bayi setelah operasi pada *image sequence*.



Frame 25-26 video setelah operasi (a)



Frame 26-27 video setelah operasi (b)



Frame 27-28 video setelah operasi (c)

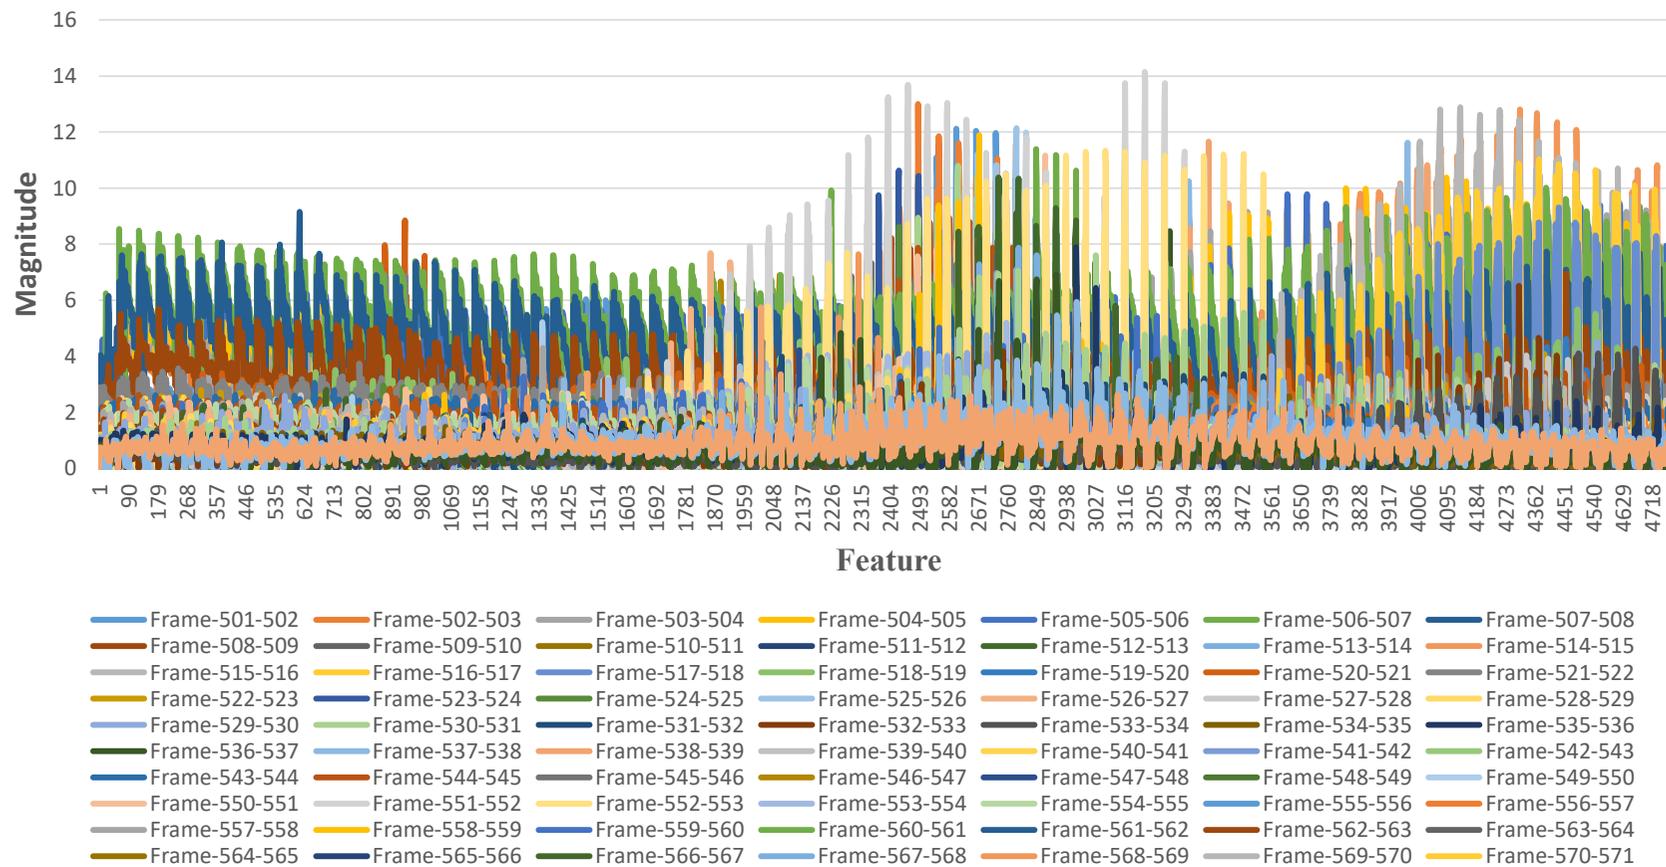
Gambar 4.4. Magnitude dari beberapa *frame* yang berurutan (a-c)

Pada gambar 4.4 dapat dilihat magnitude pada *image sequence* pada bayi setelah operasi, dengan kondisi seperti pada gambar 4.4 (a) adalah image akan kesulitan dalam hal menemukan fitur pada tiap-tiap *frame*, sampel pada gambar 4.4 hanya menampilkan tiga *frame* berurutan, pada gambar 4.5 adalah magnitude pada 90 *frame* yang saling berurutan.

Gambar 4.5 adalah besaran gerak dari beberapa *frame* yang saling berurutan, hal ini akan mempersulit dalam hal penentuan pola dari tiap-tiap *frame*, oleh karena ini dilakukan pengurutan magnitude dari nilai terkecil ke nilai besaran vektor terbesar pada tiap-tiap *frame* sehingga membentuk pola pada tiap *frame*nya.

4.3 Hasil Pengurutan Berdasarkan Data *Magnitude*

Setelah melihat hasil besaran dari data *Motion Vector*, namun tidak mengetahui letak besaran terbesar, sehingga melakukan sorting untuk nantinya bisa mengetahui berapa besaran terbesar dari setiap *frame* yang nantinya dari hasil pengurutan ini sebagai fitur untuk tiap-tiap hasil *Motion Vector* perbandingan dari dua *frame* untuk dibandingkan dengan *frame* berikutnya.

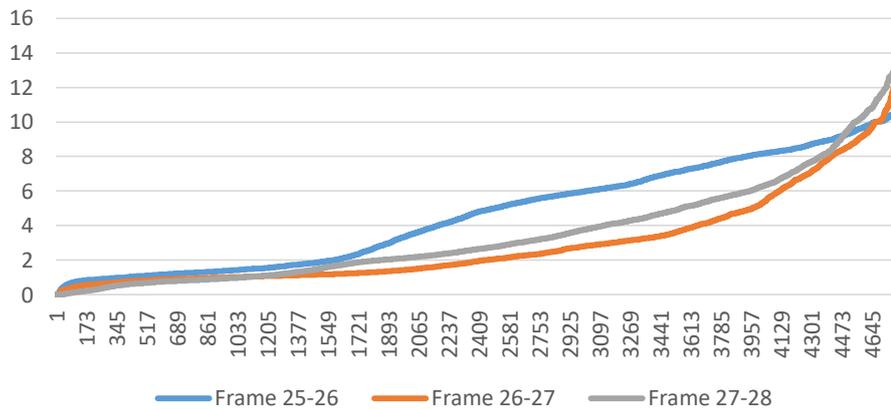


Gambar 4.5. Magnitude pada frame berurutan

4.3.1 Hasil Sorting Magnitude

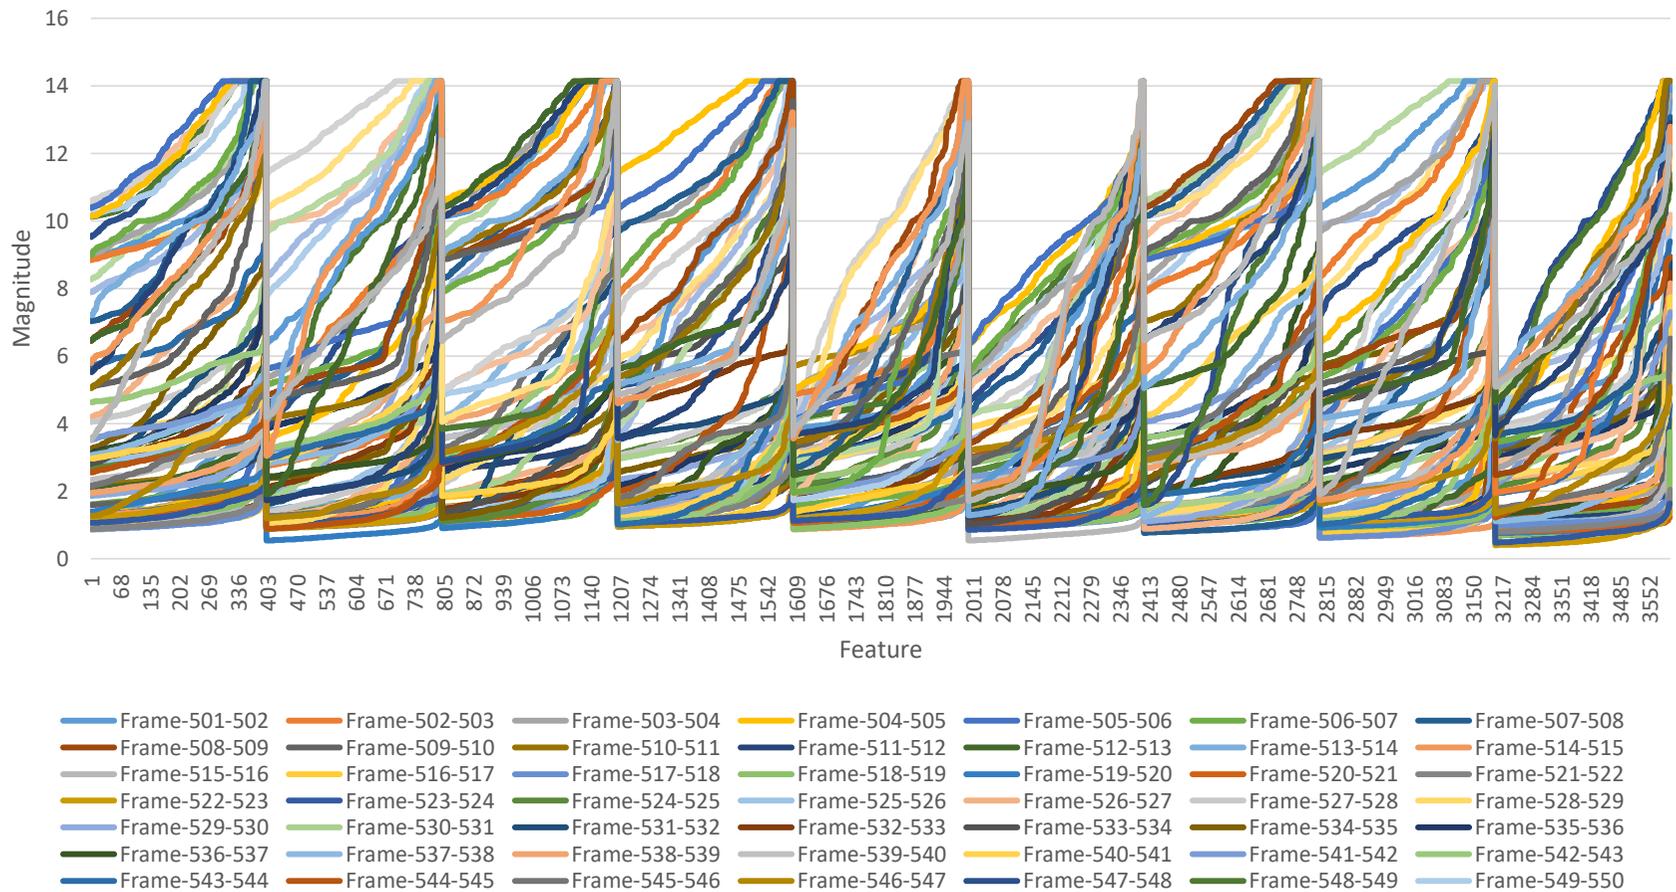
Pada gambar 4.6 dengan sampel tiga frame berurutan menunjukkan beda-beda pola aktivitas gerakan bayi pasca operasi yang nantinya akan dilakukan klasifikasi menggunakan SVM. Hasil pengurutan dilakukan untuk mencari fitur aktivitas bayi setelah operasi untuk melihat seberapa besar perubahan yang terjadi disetiap gerakan tanpa melihat posisinya.

Pada gambar 4.7 adalah hasil pengurutan dari banyak frame yang saling berurutan, dimana pada gambar 4.7 diambil pada besaran terbesar untuk menghindari kemungkinan adanya *global motion* yang ikut masuk pada data yang akan dilakukan klasifikasi.



Gambar 4.6. Hasil pengurutan dari beberapa *frame* berurutan

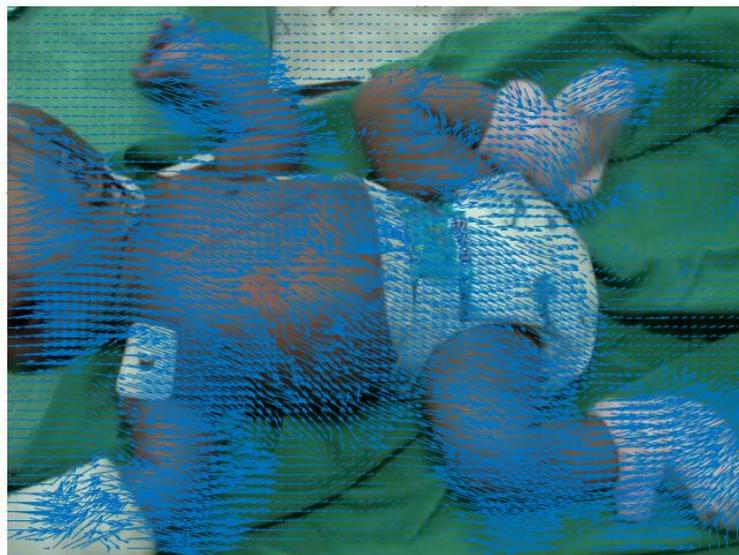
Gerakan yang terjadi memiliki besaran yang tidak jauh berbeda disetiap framenya, akan tetapi perubahan nilai yang terjadi terukur dengan jelas dan terlihat perbedaannya sesuai klasifikasinya. Nilai magnitude tertinggi dari setiap perubahan mencapai nilai 14 lebih disetiap urutan frame yang bergerak. Dengan teknik dan metode yang dilakukan dapat terlihat bahwa gerakan aktivitas bayi setelah operasi yang terlihat pada sebuah video, dapat diamati dan diklasifikasi, tanpa harus mengetahui posisi masing-masing bagian tubuh yang bergerak dari seorang bayi.



Gambar 4.7. Pola pengurutan dari banyak *frame* berurutan

4.4 *Global Motion* Pada Data Video

Dalam penelitian ini menemukan adanya *global motion*, pada awalnya asumsinya adalah aktivitas gerakan bayi setelah operasi, namun nilainya sangat kecil dan cenderung datar dari awal data hingga akhir data, sangat berbeda dengan pola gerakan aktivitas pasca operasi dimana ada lonjakan meskipun kecil, berbeda dengan *global motion* dimana lonjakannya sangat kecil dan cenderung mendatar dalam satu *frame*, sehingga setelah penulis telusuri ternyata data tersebut adalah *global motion*.



Setelah Operasi (a)



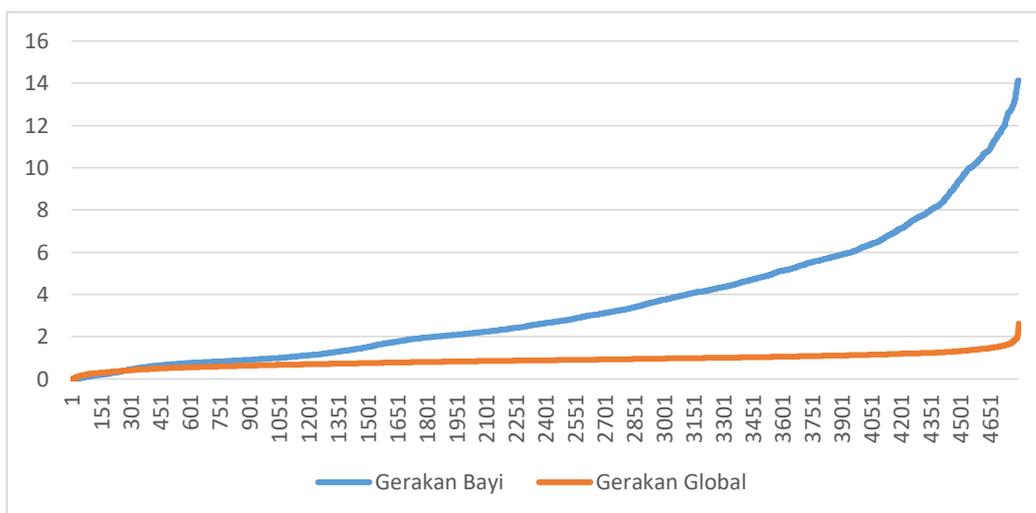
Global motion (b)

Gambar 4.8. Perbandingan vektor gerak bayi dengan *global motion* (a-b)

Pada gambar 4.8 adalah perbandingan global motion dan aktivitas gerakan setelah operasi, dapat dilihat dimana motion vector pada bayi setelah operasi hanya bergerak pada gerakan bayinya saja, sedangkan pada global motion satu frame penuh terjadi gerakan dengan besaran hampir sama dan arah yang sama, hal ini terjadi ketika kondisi kamera bergerak.

Pada gambar 4.9 adalah perbandingan vektor gerak antara aktivitas gerakan bayi dengan gerak global, dimana pada gerak global bisa terlihat dalam satu frame vektor gerak nya bergerak semua tidak mengikuti objek yang bergerak, namun seluruh frame nya bergerak, hal ini terjadi karena kondisi kamera yang bergerak.

Pada gambar 4.9 dapat dilihat perbedaan pola antara pola aktivitas gerakan setelah operasi dan pola gerakan global. Gerakan global cenderung datar dikarena dalam satu *frame* seluruhnya bergerak dengan besaran yang hampir sama, dalam grafik ditunjukkan dalam bentuk datar dan cenderung lonjakannya kecil atau tidak ada lonjakan besaran, dimana hal tersebut menunjukkan tidak ada besaran besar dalam nya.



Gambar 4.9. Grafik gerakan global terhadap gerakan bayi

4.5 Hasil Setelah Klasifikasi SVM

Dari hasil klasifikasi menggunakan SVM (*support vector machine*) dengan kernel RBF (*radial basic function*), dengan data training sebanyak 69 data dan untuk testing 21 data. Menghasilkan konfusi matrik seperti pada Tabel 4.2.

Tabel 4.2. Hasil konfusi matrik

		Prediksi		
		Tenang	Menggeliat	Menyentak
Aktual	Tenang	7	0	0
	Menggeliat	2	5	0
	Menyentak	0	0	7

Pada Tabel 4.2 dengan menggunakan kernel RBF didapatkan konfusi matrik dengan jumlah total 90 data dengan data *testing* sebanyak 21 data. Dimana dari total 21 data yang digunakan sebagai data testing ada 2 data yang dinyatakan kurang tepat dalam klasifikasi. Berdasarkan data konfusi matrik didapatkan hasil dengan akurasi 90.4762 %. Untuk nilai *error* nilai *MAE* sebesar 0.2434 dan nilai *RMSE* sebesar 0.3086. Adapun untuk hasil akurasi secara detail dari uji coba pertama dapat dilihat pada Tabel 4.3 dimana setiap kelasnya dihitung dan dievaluasi masing-masing.

Tabel 4.3. Hasil detail akurasi dari setiap kelas

Kelas	<i>Recall</i>	<i>Precision</i>	<i>F-Measure</i>	<i>ROC</i>
Tenang	1,000	0,778	0,875	0,929
Menggeliat	0,714	1,000	0,833	0,898
Menyentak	1,000	1,000	1,000	1,000

Berikut adalah rumus Recall, Precision dan F-Measure dalam perhitungan hasil akurasi dari tiap-tiap kelas. Recall adalah proporsi sampel dataset yang diklasifikasikan sebagai kelas yang diberikan dibagi dengan jumlah aktual di kelas tersebut (setara dengan TP)

$$Recall = \frac{TP}{TP + FN} \quad 4.1$$

Precision adalah proporsi sampel dataset yang benar-benar kelasnya dibagi dengan dataset total yang diklasifikasikan sebagai kelas itu

$$Precision = \frac{TP}{TP + FP} \quad 4.2$$

F-Measure adalah ukuran gabungan untuk presisi dan *recall* dihitung sebagai $2 * Precision * Recall$ dibagi $Precision + Recall$

$$F - Measure = 2 \frac{Precision . Recall}{Precision + Recall} \quad 4.3$$

4.5.1 Hasil Perbandingan Akurasi Kernel

Bagian ini membahas mengenai perbandingan kinerja kernel yang diterapkan pada 23 data video setelah operasi. dengan jumlah data training sebanyak 69 data dan data testing sebanyak 21 data, dimana setiap video diambil 10 *frame*. Sehingga total 230 data, Adapun hasil akurasi disetiap percobaan yang sudah dicoba dapat dilihat pada Tabel 4.4.

Tabel 4.4. Akurasi perbandingan kernel

Kelas	Kernel			
	RBF	Linier	Polinomial	Sigmoid
Tenang	7	7	7	7
Menggeliat	5	5	2	0
Menyentak	7	3	1	7
Tidak Sesuai	2	6	11	7
Akurasi	90.4762 %	71.4286 %	47.619 %	66.6667 %

Akurasi terbaik adalah menggunakan Kernel RBF (*radial basic function*) dengan hasil kelas tenang sebanyak 7 data, kelas menggeliat sebanyak 5 data, kelas

menyentak sebanyak 7 data dan tidak sesuai sebanyak 2 data dengan akurasi sebesar 90.4762 %.

Tabel 4.5. Perbandingan *error* MSE dan RMSE pada tiap kernel

Error	RBF	Linier	Polinomial	Sigmoid
MAE	0.2434	0.1905	0.3492	0.2222
RMSE	0.3086	0.4364	0.5909	0.4714

Selanjutnya adalah perbandingan nilai MAE (*mean absolute error*) dan nilai *error* menggunakan pendekatan RMSE (*root mean squared error*) dapat dilihat pada Tabel 4.5. Dimana pada pengujian beberapa kernel, *error* MAE pada kernel linier memiliki *error* terkecil daripada kernel yang lain yaitu 0.1905, sedangkan *error* MAE terbesar adalah pada kernel polinomial sebesar 0.3492. Sedangkan pada RMSE *error* terkecil adalah pada kernel RBF dengan nilai *error* sebesar 0.3086, sedangkan pada *error* terbesar adalah pada kernel polinomial sebesar 0.5909. Akan tetapi nilai *error* kecil tidak menjamin bahwa kernel tersebut adalah kernel dengan nilai klasifikasi terbaik, sebaliknya nilai *error* terbesar juga tidak menjamin bahwa kernel tersebut adalah kernel dengan nilai akurasi klasifikasi terburuk. Pada penelitian ini nilai *error* MAE terkecil adalah kernel linier, dan nilai *error* RMSE terkecil adalah RBF, namun hasil akurasi klasifikasi terbaik adalah pada kernel RBF.

Halaman ini sengaja dikosongkan

BAB 5

KESIMPULAN

5.1 Kesimpulan

Klasifikasi aktivitas gerakan setelah operasi berdasarkan standar pengukuran nyeri menggunakan FLACC (*Face, Legs, Activity, Cry, Consolability*) pada bayi setelah operasi merupakan penelitian baru yang belum pernah dilakukan penelitian sebelumnya. Penelitian ini dilakukan untuk melihat pola aktivitas gerakan bayi berdasarkan kategori aktivitas pada FLACC dan untuk membuktikan bahwa ada perbedaan pola aktivitas gerakan bayi setelah operasi berdasarkan FLACC yaitu aktivitas gerakan tenang, menggeliat dan menyentak. Hal ini dilakukan sebagai dasar bahwa untuk mengukur aktivitas bayi dimana bayi umur dibawah enam bulan belum bisa menyampaikan rasa nyeri secara lisan seperti pada orang dewasa, salah satunya menggunakan skala pengukuran nyeri yaitu FLACC. Pada FLACC terdiri dari lima kategori dimana salah satunya adalah kategori aktivitas, penelitian ini khusus membahas pada kategori aktivitas, dalam kategori aktivitas terdapat tiga kelas yaitu kelas tenang, menggeliat dan menyentak dimana pada tiap-tiap kelas memiliki nilai skor untuk nantinya dilakukan akumulasi dengan kategori lain pada FLACC sebagai penentuan tingkat nyeri oleh dokter terhadap bayi untuk perlu tidaknya diberikan anti nyeri golongan opiad.

Penelitian ini dikerjakan sesuai langkah-langkah metodologi penelitian dan diuji coba dengan menggunakan data testing yang berbeda dengan data training pada kondisi bayi setelah operasi. Pemilihan fitur melalui ekstraksi *Motion Vector* dengan pendekatan *Taylor* mampu memberikan hasil ketelitian yang sangat baik dengan tujuan gerakan halus pada aktivitas gerakan bayi pun tetap dapat di deteksi. Selain itu fungsi pengurutan *magnitude* berdasarkan *motion vector* adalah terobosan baru dalam menemukan pola gerakan pada kasus video dengan kondisi pengambilan gambar tidak dalam posisi diam, dikarenakan dengan kondisi pengambilan gambar bergerak maka akan kesulitan dalam hal penentuan bagian tubuh yang akan dideteksi dan adanya global motion dikarenakan adanya gerakan pada kamera, sedangkan menggunakan pengurutan *magnitude* pada *motion vector*

tidak memerlukan informasi untuk mengetahui posisi bagian tubuh bayi, melainkan seluruh gerakan pada bayi di lakukan pengenalan dan perhitungan untuk nantinya dilakukan klasifikasi berdasarkan besaran *motion vector* dengan kategori aktivitas pada FLACC yaitu gerakan tenang, menggeliat dan menyentak. Pada tahap klasifikasi menggunakan SVM proses klasifikasi diuji cobakan dengan berbagai kernel yaitu kernel RBF (*radial basic function*), kernel linier, kernel polinomial dan kernel sigmoid.

Hasil akurasi terbaik pada proses klasifikasi aktivitas gerakan bayi setelah operasi yaitu gerakan tenang, menggeliat dan menyentak menggunakan kernel RBF dengan data training sebanyak 69 data dan data testing sebanyak 21 data mencapai nilai akurasi 90,4762 %.

5.2 Saran

Penelitian mengenai aktivitas gerakan pada bayi setelah operasi masih perlu untuk dikembangkan dan ditingkatkan kinerja metodenya baik untuk proses ekstraksi fitur maupun proses deteksi maupun klasifikasi berdasarkan gerakan aktivitasnya mengingat ini adalah penelitian yang pertama. Penelitian ini sangat bermanfaat dalam bidang medis untuk nantinya membantu dokter spesialis anestesi pediatri dalam melakukan penilaian berdasarkan aktivitas gerakan pada kelompok *non-verbal* khususnya pada bayi. Untuk penelitian selanjutnya berdasarkan penelitian ini bahwa aktivitas gerakan bayi setelah operasi dapat dilakukan klasifikasi yaitu gerakan tenang, menggeliat dan menyentak, maka harapannya akan bisa digabung dengan kategori lainnya pada FLACC, mengingat setiap kategori pada FLACC memiliki skor nilai yang nantinya dilakukan akumulasi untuk digunakan oleh dokter mengukur tingkat nyeri pada bayi setelah operasi.

DAFTAR PUSTAKA

- APA (2012) *Good Practice in Postoperative and Procedural Pain 2nd Edition, A guideline from the Association of Paediatric Anaesthetists of Great Britain and Ireland*. Pediatric Anesthesia.
- Chai, T. and Draxler, R. R. (2014) ‘Root mean square error (RMSE) or mean absolute error (MAE)? -Arguments against avoiding RMSE in the literature’, *Geoscientific Model Development*, 7(3), pp. 1247–1250. doi: 10.5194/gmd-7-1247-2014.
- Chen, S., Zhang, Q., Xie, R.-H., Wen, S. W. and Harrison, D. (2016) ‘What is the Best Pain Management During Gastric Tube Insertion for Infants Aged 0–12months: A Systematic Review’, *Journal of Pediatric Nursing*. Elsevier Inc. doi: 10.1016/j.pedn.2016.12.015.
- Cholette, M. E., Borghesani, P., Gialleonardo, E. Di and Braghin, F. (2017) ‘Using Support Vector Machines for the Computationally Efficient Identification of Acceptable Design Parameters in Computer-Aided Engineering Applications’, *Expert Systems with Applications*. Elsevier Ltd, 81, pp. 39–52. doi: 10.1016/j.eswa.2017.03.050.
- Chung, Y. (2016) ‘Vector Taylor series based model adaptation using noisy speech trained hidden Markov models’, *Pattern Recognition Letters*. Elsevier B.V., 75, pp. 36–40. doi: 10.1016/j.patrec.2016.02.013.
- Cong, X., Wu, J., Vittner, D., Xu, W., Hussain, N., Galvin, S., Fitzsimons, M., McGrath, J. M. and Henderson, W. A. (2017) ‘The impact of cumulative pain/stress on neurobehavioral development of preterm infants in the NICU’, *Early Human Development*. Elsevier B.V., 108, pp. 9–16. doi: 10.1016/j.earlhumdev.2017.03.003.
- Cortes, C. and Vapnik, V. (1995) ‘Support-Vector Networks’, *Machine Learning*, 20(3), pp. 273–297. doi: 10.1023/A:1022627411411.
- Cortes, C. and Vapnik, V. (1995) ‘Support vector machine’, *Machine learning*, pp. 1303–1308. doi: 10.1007/978-0-387-73003-5_299.

- Dalal, P. G., Doheny, K. K., Klick, L., Britcher, S., Rebstock, S., Bezinover, D., Palmer, C., Berlin, C., Postula, M., Kong, L. and Janicki, P. K. (2013) 'Analysis of acute pain scores and skin conductance measurements in infants', *Early Human Development*. Elsevier Ltd, 89(3), pp. 153–158. doi: 10.1016/j.earlhumdev.2012.09.008.
- Hanindito, E. (2013) *Dynamic Acoustic Pattern as Pain Indicator on Baby Cries Post Surgery Procedure*. PhD Thesis, Universitas Airlangga.
- Kristian, Y., Hariadi, M. and Purnomo, M. H. (2014) 'Ideal Modified Adachi Chaotic Neural Networks and active shape model for infant facial cry detection on still image', *Proceedings of the International Joint Conference on Neural Networks*, pp. 2783–2787. doi: 10.1109/IJCNN.2014.6889520.
- Kristian, Y., Takahashi, H., Purnama, I. K. E., Yoshimoto, K., Setiawan, E. I., Hanindito, E. and Purnomo, M. H. (2017) 'A Novel Approach on Infant Facial Pain Classification using Multi Stage Classifier and Geometrical-Textural Features Combination', *IAENG International Journal of Computer Science*, 44:1, *IJCS_44_1_13*.
- Meier, K. and Giaschi, D. (2014) 'The maturation of global motion perception depends on the spatial and temporal offsets of the stimulus', *Vision Research*. Elsevier Ltd, 95, pp. 61–67. doi: 10.1016/j.visres.2013.12.007.
- Merkel (1997) 'The FLACC: A Behavioral Scale for Scoring Postoperative Pain in Young Children', 23(3).
- Meuel, H., Angerstein, L., Henschel, R., Rosenhahn, B. and Ostermann, J. (2016) 'Moving Object Tracking for Aerial Video Coding using Linear Motion Prediction and Block Matching', pp. 0–4.
- Mishra, K., Mathai, M., Della Rocca, R. C. and Reddy, H. S. (2017) 'Improving Resident Performance in Oculoplastic Surgery: A New Curriculum Using Surgical Wet Laboratory Videos', *Journal of Surgical Education*. Elsevier, pp. 1–6. doi: 10.1016/j.jsurg.2017.02.009.
- Nguyen, T., Fundora, M. P., Welch, E., Douglas, P. S., Eidem, B. W., Campbell, R. M.,

- Weiner, R. B., Stern, K. W. D., Benavidez, O. J., Lai, W. W., Sachdeva, R. and Lopez, L. (2017) ‘Application of the Pediatric Appropriate Use Criteria for Chest Pain’, *The Journal of Pediatrics*. Elsevier Inc. doi: 10.1016/j.jpeds.2017.02.073.
- Oliveira, R. F. S. C. and Bastos-Filho, C. J. A. (2016) ‘Human detection in digital videos using motion features extractors’, *2016 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, pp. 1–2. doi: 10.1109/LA-CCI.2016.7885745.
- Polkki, T., Korhonen, A., Axelin, A., Saarela, T. and Laukkala, H. (2014) ‘Development and preliminary validation of the Neonatal Infant Acute Pain Assessment Scale (NIAPAS)’, *International Journal of Nursing Studies*, 51(12), pp. 1585–1594. doi: 10.1016/j.ijnurstu.2014.04.001.
- Poularakis, S., Avgerinakis, K., Briassouli, A. and Kompatsiaris, I. (2017) ‘Efficient motion estimation methods for fast recognition of activities of daily living’, *Signal Processing : Image Communication*. Elsevier B.V., 53(November 2016), pp. 1–12. doi: 10.1016/j.image.2017.01.005.
- Pradhan, A. (2012) ‘SUPPORT VECTOR MACHINE-A Survey’, *International Journal of Emerging Technology and Advanced Engineering*, 2(8), pp. 82–85. Available at: http://www.ijetae.com/files/Volume2Issue8/IJETAE_0812_11.pdf.
- Reynolds, F. (2005) ‘Effects of pain relief on the fetus and newborn’, *Women’s Health Medicine*, 2(4), pp. 31–34. doi: 10.1383/wohm.2005.2.4.31.
- Schiavenato, M. (2007) ‘Evaluating Neonatal Facial Pain Expression: Is There a Primal Face of Pain?’ doi: 10.1017/CBO9781107415324.004.
- Schiavenato, M., Byers, J. F., Scovanner, P., McMahon, J. M., Xia, Y., Lu, N. and He, H. (2008) ‘Neonatal pain facial expression: Evaluating the primal face of pain’, *PAIN*, 138(2), pp. 460–471. doi: 10.1016/j.pain.2008.07.009.
- Shen, J., Giles, S. A., Kurtovic, K., Fabia, R., Besner, G. E., Wheeler, K. K., Xiang, H. and Groner, J. I. (2016) ‘Evaluation of nurse accuracy in rating procedural pain among pediatric burn patients using the Face, Legs, Activity, Cry, Consolability (FLACC) Scale’, *Burns*. Elsevier Ltd and International Society of Burns Injuries,

43(1), pp. 114–120. doi: 10.1016/j.burns.2016.07.009.

Singh, J., Shah, R. S., Vaidya, N., Mahato, P. K., Shrestha, S. and Shrestha, B. L. (2012) ‘Comparison of ketamine, fentanyl and clonidine as an adjuvant during bupivacaine caudal anaesthesia in paediatric patients’, *Kathmandu University Medical Journal*, 10(39), pp. 25–29.

Slater, R., Cantarella, A., Gallella, S., Worley, A., Boyd, S., Meek, J. and Fitzgerald, M. (2006) ‘Cortical Pain Responses in Human Infants’, *Journal of Neuroscience*, 26(14), pp. 3662–3666. doi: 10.1523/JNEUROSCI.0348-06.2006.

Stiller, C. and Konrad, J. (1999) ‘Estimating motion in image sequences’, *IEEE Signal Processing Magazine*, 16(4), pp. 70–91. doi: 10.1109/79.774934.

Wang, C., Lo, Y. and Huang, C. (2016) ‘Exploration of Video Art and Color Vision : The Application of Image Change in Digital Interaction’, pp. 512–515.

Wang, X. and Yuan, Z. (2017) ‘Discrete singular convolution and Taylor series expansion method for free vibration analysis of beams and rectangular plates with free boundaries’, *International Journal of Mechanical Sciences*. Elsevier Ltd, 122(December 2016), pp. 184–191. doi: 10.1016/j.ijmecsci.2017.01.023.

White, M. C. and Wolf, A. R. (2004) ‘Pain and stress in the human fetus’, *Best Practice & Research Clinical Anaesthesiology*, 18(2), pp. 205–220. doi: 10.1016/j.bpa.2003.12.011.

LAMPIRAN

Lampiran 1

1. Prosedur pengambilan sampel penelitian :
 - A. Tangis & FLACC setelah operasi:
 - 10-15 menit pertama sebelum analgetik diberikan
 - 30 menit setelah analgetik diberikan
2. Pengambilan video (FLACC) menggunakan : Sony HDR-XR520
3. Pengambilan data setelah operasi dengan durasi 3-2 menit (1-2 menit seluruh tubuh, 1-2 menit wajah).

Lampiran 2

Tabel diagnosa pembedahan

DIAGNOSA	JUMLAH KASUS	%
Malformasi anorectal	8	35
Hernia inguinalis	3	13
Phymosis	3	13
Megacolon congenital	2	8,7
Hypertrophic pyloric stenosis	2	8,7
CTEV	2	8,7
Constriction band curis	1	4,3
Lymphangioma	1	4,3
Biopsi rectum	1	4,3
JUMLAH	23	100

Lampiran 3

Tabel jenis pembedahan

JENIS PEMBEDAHAN	JUMLAH KASUS	%
Anopasty	8	35
Hermiotomy	3	13
Circumcisi	3	13
Colostomy	2	8,7
Release CTEV	2	8,7
Pyloromyotomy	2	8,7
Lymphangioma excision	1	4,3
Release constriction band	1	4,3
Biopsi rectum	1	4,3
JUMLAH	23	100

Lampiran 4

Tabel hasil nilai FLACC sebelum operasi & setelah operasi

Kasus	Sex	ASA PS	BB (Kg)	Usia (Hari)	FLACC	
					Sebelum operasi	Setelah operasi
1	L	1	4,1	55	0	9
2	W	1	4,2	41	0	2
3	W	2	3,7	77	3	0
4	L	1	5,7	68	0	4
5	W	1	7,7	172	0	2
6	L	2	4,6	70	0	3
7	W	2	5,0	176	3	5
8	L	1	3,4	55	0	9
9	L	1	8,5	171	2	5
10	L	1	6,5	88	0	9
11	W	1	7,0	174	0	6
12	L	2	3,5	80	0	4
13	L	1	8,2	155	0	9
14	L	1	7,7	172	0	9
15	W	1	4,6	114	0	7
16	W	1	6,0	106	0	9
17	L	1	6,3	176	0	9
18	L	1	4,5	98	4	2
19	L	1	3,8	63	0	0
20	L	1	6,0	159	0	9
21	L	1	5,5	102	0	9
22	W	1	7,0	224	0	8
23	W	1	5,4	81	0	2

ASA PS 1-2 : Status fisik bayi tanpa kelainan sistemik atau kelainan sistemik ringan berdasarkan pedoman *American Society of Anesthesiologist*.

Lampiran 5

Dataset Video

DATA	SEBELUM OPERASI	SETELAH OPERASI
1		
2		
3		
4		
5		
6		

7		
8		
9		
10		
11		
12		
13		

14		
15		
16		
17		
18		
19		
20		

21		
22		
23		

Lampiran 6

Tabel survei pengelolaan nyeri setelah operasi bayi usia < 1 tahun di Gedung bedah pusat terpadu RSUD Dr. Soetomo, Februari – Mei 2009, n = 114

USIA	PEMBEDAHAN					ANALGETIKA			SKALA NYERI
	CNS	ABDOMEN	ORTHOPEDI	PLASTIK	LL	NSAID	MORPHIN	-	
≤ 1 bulan									Tidak dilakukan
	6 (37%)	10 (62%)				14 (88%)		2 (12%)	
1 bln-6 bln (86%)	16 (16%)	34 (34%)	2 (2%)	11 (11%)	35 (36%)	83 (85%)	2(2%)	13(13%)	Tidak dilakukan

Halaman ini sengaja dikosongkan

BIOGRAFI PENULIS



Faisal Lutfi Afriansyah lahir di Blitar pada 29 April 1991. Blitar dikenal sebagai kota Proklamator karena dikota ini tempat dimakamkannya presiden pertama Republik Indonesia Soekarno. Ayahnya bernama Drs. Wisono dan ibunya bernama Mamik Zubaidah. Pada masa kecilnya bersekolah di MI Mamba'ul Ulum di kampungnya di Desa Tawangrejo Blitar lulus pada tahun 2003, kemudian melanjutkan di SMPN 1 Kesamben Blitar lulus pada tahun 2006, selanjutnya Sekolah Menengah Atas di SMAN 1 Talun Blitar lulus pada tahun 2009. Setelah lulus Sekolah Menengah Atas, melanjutkan kuliah di Universitas Islam Negeri Maulana Malik Ibrahim di Malang, selama kuliah sarjana mulai semester empat mendapatkan beasiswa pendidikan dari Kementerian Agama hingga menyelesaikan pendidikan sarjananya pada tahun 2013. Pada tahun 2015 mendapat beasiswa dari LPDP (Lembaga Pengelola Dana Pendidikan) untuk melanjutkan pendidikan Magister di ITS (Institut Teknologi Sepuluh Nopember) Surabaya.

Penulis bisa dihubungi melalui faisal.lutfi.afriansyah@gmail.com atau faisal.lutfi.afriansyah@ieee.org