



**DISERTASI - EE186601**

**PENGEMBANGAN METODE HIBRIDA TRANSFORMASI DATA DAN META-  
ALGORITMA: TERAPAN UNTUK IDENTIFIKASI LEVEL KOGNITIF SISWA  
MIPA**

**YUNI YAMASARI  
07111660010011**

**Pembimbing:**

**Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng  
Dr. Supeno Mardi Susiki Nugroho, ST., MT**

**PROGRAM DOKTOR  
DEPARTEMEN TEKNIK ELEKTRO  
FAKULTAS TEKNOLOGI ELEKTRO DAN INFORMATIKA CERDAS  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER SURABAYA  
2020**



**DISERTASI - EE186601**

**PENGEMBANGAN METODE HIBRIDA TRANSFORMASI DATA DAN META-  
ALGORITMA: TERAPAN UNTUK IDENTIFIKASI LEVEL KOGNITIF SISWA  
MIPA**

**YUNI YAMASARI  
07111660010011**

**Pembimbing:**

**Prof. Dr. Ir. Mauridhi Hery Purnomo, M.Eng**

**Dr. Supeno Mardi Susiki Nugroho, ST., MT**

**PROGRAM DOKTOR**

**DEPARTEMEN TEKNIK ELEKTRO**

**FAKULTAS TEKNOLOGI ELEKTRO DAN INFORMATIKA CERDAS**

**INSTITUT TEKNOLOGI SEPULUH NOPEMBER SURABAYA**

**2020**



# LEMBAR PENGESAHAN

## DISERTASI PENGEMBANGAN METODE HIBRIDA TRANSFORMASI DATA DAN META-ALGORITMA: TERAPAN UNTUK IDENTIFIKASI LEVEL KOGNITIF SISWA MIPA

Disertasi disusun untuk memenuhi salah satu syarat memperoleh gelar

**Doktor (Dr)**

di

**Institut Teknologi Sepuluh Nopember**

**Yuni Yamasari**

**NRP. 07111660010011**


Tanggal Ujian: 31 Januari 2020


Periode Wisuda: Maret, 2020

Disetujui oleh:

**Penguji**


**Pembimbing**

1.   
Dr. Drs. I Nyoman Sukajaya,  
M.T.  
NIP. 196711151993031001

1.   
Prof. Dr. Ir. Mauridhi Hery Purnomo,  
M.Eng.  
NIP. 195809161986011001


2.   
Dr. Surya Sumpeno, ST., M.Sc.  
NIP. 196906131997021003

2.   
Dr. Supeno Mardi Susiki Nugroho,  
ST., MT  
NIP. 197003131995121001

3.   
Dr. I Ketut Eddy Purnama, ST.,  
MT.  
NIP. 196907301995121001

Kepala Departemen Teknik Elektro



  
Dedet Candra Riawan, S.T., M.Eng., Ph.D.  
NIP. 197311192000031001



- Halaman ini sengaja dibiarkan kosong -

## PERNYATAAN KEASLIAN DISERTASI

Dengan ini saya menyatakan bahwa isi keseluruhan disertasi saya dengan judul **PENGEMBANGAN METODE HIBRIDA TRANSFORMASI DATA DAN META-ALGORITMA: TERAPAN UNTUK IDENTIFIKASI LEVEL KOGNITIF SISWA MIPA** adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

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



Surabaya, 17 Januari 2020



**Yuni Yamasari**  
Nrp: **07111660010011**



- Halaman ini sengaja dibiarkan kosong -

## KATA PENGANTAR

Semua pujian hanya milik Allah, Tuhan semesta alam, yang telah memberikan rahmat dan karunia-Nya. Sholawat serta salam untuk Rosululloh Muhammad S.A.W atas beliaulah, nikmat iman dan Islam sampai pada kita. Dengan segala doa yang selalu dipanjatkan dan ikhtiyar yang selalu dilakukan, buku disertasi ini dapat diselesaikan. Buku disertasi ini disusun untuk menyebarkan hasil penelitian disertasi yang dilakukan selama studi saya di program doktoral Jurusan Teknik Elektro, ITS.

Disertasi dan penelitian ini dikembangkan dengan melibatkan banyak orang dalam berbagai cara. Pertama-tama, saya ingin mengucapkan terima kasih kepada Promotor saya, Profesor Mauridhi Hery, karena memberikan bimbingan utama selama penelitian, dan co-promotor Dr. Supeno Mardi S. N, ST,MT, yang selalu memantau kemajuan penelitian saya.

Penghargaan dan terima kasih, saya sampaikan juga kepada Dana Abadi Indonesia untuk Pendidikan (BUDI-DN/LPDP), yang memberikan kesempatan melalui beasiswa pendidikan Indonesia untuk program doktor-dalam negeri. Saya juga ingin mengucapkan terima kasih kepada Pejabat Unesa yang memberi saya tugas belajar.

Selanjutnya, saya berterima kasih kepada penguji, Dr. I Ketut Eddy Purnama, Dr. Surya Sumpeno dan Dr. Nyoman Sukajaya, yang telah memberikan koreksi, masukan, dan saran untuk kesempurnaan penulisan penelitian. Kepada manajemen dan staf program pascasarjana di Jurusan Teknik Elektro, Dr. Ardyono, Dr. Wirawan, Dr. Rony Seto, Ronny Mardiyanto, Ph.D, dan Mas Hartono. Terima kasih atas bantuannya dalam administrasi studi saya.

Kepada kolega, mahasiswa program doktor, magister dan sarjana di bawah bimbingan Prof. Hery dan Pak Uki yang mungkin tidak saya sebutkan satu per satu. Terima kasih atas persahabatan, kolaborasi, dan diskusi yang telah dilakukan sejauh ini. Kepada semua anggota WAG 'Ibu2 Cantik S3 Elektro', kalian telah memberikan lingkungan yang menyenangkan dan mendukung selama ini. Terima kasih atas



semua saran, diskusi makan siang yang menarik, dan obrolan santai para ibu. Keluarga dan teman-teman yang terkasih. Terima kasih setinggi-tingginya kepada Ibuku, Bapakku, telah mengajari saya hal-hal penting dalam hidup, dan bantuannya juga dorongannya untuk segera menyelesaikan S3 ini agar bisa fokus membimbing dan mengurus keluarga lagi. Dear Aydin dan Akmal, selama periode ini, kalian berdua tumbuh menjadi anak-anak yang sangat cerdas, manis, dan mandiri. Terima kasih atas kesabarannya, setiap kali saya harus mengerjakan disertasi ini. Dear TA75, rekan hidupku, terima kasih atas dukungannya yang tidak pernah berakhir.

Sebagai penutup, karya ini masih jauh dari sempurna karena kesempurnaan hanya milik Allah. Saya sangat terbuka dengan umpan balik dan saran untuk meningkatkan penelitian ini. Semoga Allah memberi rahmat atas ilmu bagi siapa pun yang membaca buku disertasi ini. Aamiin



Surabaya, 17 Januari 2020

# DEVELOPING THE HYBRID METHOD OF DATA TRANSFORMATIONS AND META-ALGORITHM: AN APPLICATION FOR IDENTIFYING THE COGNITIVE LEVEL OF MIPA STUDENTS

Name : Yuni Yamasari  
NRP : 07111660010011  
Supervisor : Prof. Dr. Ir. Mauridhi Hery Purnomo, M. Eng  
Co-supervisor : Dr. Supeno Mardi Susiki Nugroho, S.T. M.T

## ABSTRACT

The advancement of Information and Communication Technology (ICT) in the education area makes it possible to record a growing number of student characteristics. Actually, this is very beneficial because the more characteristics of students the more accurate the teacher are in the process of determining student achievement, especially the cognitive domain of students. However, on the other hand, this situation causes the teacher to encounter difficulties in this determination process because more and more student characteristics must be considered. This condition stimulates research on modeling student achievement, in particular, in the context of determining the cognitive domain of students. However, the solutions and strategies offered for determining cognitive domains are still very limited. In fact, existing solutions still have low performance so that the identification error is still high.

This is due to the exploration of methods at each stage for developing of the identification system on the cognitive level that has not been done much. For this reason, this dissertation research focuses on the exploitation of methods at each stage so that the system resulted can reduce as many misidentifications as possible. Finally, the efforts worked can present the hybrid of data transformation method and the LogitBoost as meta-algorithm to build a system identifying the cognitive level of MIPA students.

The experimental results show that the system built by the proposed hybrid method has advantages over using only tree methods (Decision Stump, REP Tree, and Random Tree) alone. This is indicated by the highest accuracy increase up to 21,062% from 76,903% to 97,965% and the highest reduction ability from the misidentification of the cognitive level of MIPA students by 24 students from 26 to 2 students.

**Keywords:** LogitBoost, cognitive domain, feature selection, feature extraction, feature discretization



- Halaman ini sengaja dibiarkan kosong -

# PENGEMBANGAN METODE HIBRIDA TRANSFORMASI DATA DAN META-ALGORITMA: TERAPAN UNTUK IDENTIFIKASI LEVEL KOGNITIF SISWA MIPA

Nama : Yuni Yamasari  
NRP : 07111660010011  
Promotor : Prof. Dr. Ir. Mauridhi Hery Purnomo, M. Eng  
Co-promotor : Dr. Supeno Mardi Susiki Nugroho, S.T. M.T

## ABSTRAK

Kemajuan Teknologi Informasi dan Komunikasi (TIK) pada area pendidikan memungkinkan untuk merekam semakin banyak karakteristik siswa. Sebenarnya, hal ini sangat menguntungkan karena semakin banyak karakteristik siswa maka semakin akurat guru dalam melakukan proses penentuan prestasi belajar siswa, khususnya ranah kognitif siswa. Namun, disisi lain, keadaan ini mengakibatkan guru menemui kesulitan dalam proses penentuan ini karena semakin banyak karakteristik siswa yang harus dipertimbangkan. Kondisi ini merangsang penelitian tentang pemodelan prestasi belajar siswa, khususnya, dalam rangka penentuan ranah kognitif siswa. Namun, solusi dan strategi yang ditawarkan untuk penentuan ranah kognitif masih sangat terbatas. Bahkan, solusi yang ada masih mempunyai kinerja yang rendah sehingga kesalahan identifikasi masih tinggi.

Hal ini disebabkan eksplorasi terhadap metode-metode pada tiap tahap pembangunan system identifikasi level kognitif ini belum banyak dilakukan. Untuk itu, penelitian disertasi ini memfokuskan pada eksploitasi metode-metode pada masing-masing tahap agar sistem yang dihasilkan dapat mereduksi kesalahan identifikasi sebanyak mungkin. Upaya-upaya yang dilakukan ini akhirnya dapat menghadirkan metode hibrida transformasi data dan meta-algoritma LogitBoost untuk membangun sistem identifikasi level kognitif siswa MIPA secara lebih optimal.

Hasil eksperimen menunjukkan bahwa sistem yang dibangun oleh metode hibrida yang diusulkan ini mempunyai keunggulan dibandingkan hanya menggunakan metode-metode tree (Decision Stump, REP Tree, Random Tree) saja. Hal ini diindikasikan dengan kenaikan akurasi tertinggi hingga 21,062% dari 76.903% ke 97.965% dan kemampuan reduksi terbanyak dari kesalahan identifikasi level kognitif siswa MIPA sebanyak 24 siswa dari 26 ke 2 siswa.

**Kata kunci:** LogitBoost, ranah kognitif, seleksi fitur, fitur ekstraksi, diskritisasi fitur



- Halaman ini sengaja dibiarkan kosong -

## DAFTAR ISI

LEMBAR PENGESAHAN.....	i
PERNYATAAN KEASLIAN DISERTASI .....	iii
KATA PENGANTAR .....	v
ABSTRACT .....	vii
ABSTRAK .....	ix
DAFTAR ISI .....	xi
DAFTAR GAMBAR .....	xv
DAFTAR TABEL .....	xix
NOMENKLATUR .....	xxi
BAB 1	
PENDAHULUAN .....	1
1.1. Latar belakang .....	1
1.2. Rumusan permasalahan.....	5
1.3. Tujuan dan manfaat penelitian.....	6
1.4. Peta jalan penelitian .....	7
1.5. Kontribusi dan originalitas penelitian.....	9
1.6. Ruang lingkup dan batasan penelitian.....	23
1.7. Struktur penulisan.....	23
BAB 2	
TRANSFORMASI DATA DAN META-ALGORITMA .....	25
2.1. Transformasi data.....	25
2.1.1. Metode normalisasi .....	25
2.1.2. Metode diskritisasi tanpa pengawasan .....	26
2.1.3. Metode ekstraksi fitur.....	27
2.1.4. Metode pemilihan fitur.....	28
2.2. Meta algoritma Logistic Boosting (LogitBoost).....	34
BAB 3	
PENGEMBANGAN PERANGKAT PEMBELAJARAN BERBASIS TIK YANG EFEKTIF .....	39

3.1. Perangkat pembelajaran berbasis TIK .....	39
3.2. Validasi perangkat pembelajaran berbasis TIK.....	41
3.2.1. Validasi fasilitas proses belajar mengajar .....	41
3.2.2. Validasi fasilitas proses evaluasi .....	53
3.3. Intisari pengembangan perangkat pembelajaran berbasis TIK.....	60
BAB 4	
DATA RANAH KOGNITIF SISWA MIPA .....	63
4.1. Proses pengumpulan data ranah kognitif siswa MIPA .....	63
4.2. Deskripsi data ranah kognitif siswa MIPA.....	66
4.2.1. Data siswa yang berkaitan dengan ranah kognitif Matematika.....	66
4.2.2. Data siswa yang berkaitan dengan ranah kognitif IPA .....	67
4.3. Intisari data ranah kognitif siswa MIPA .....	67
BAB 5	
TRANSFORMASI DATA UNTUK MENINGKATKAN KINERJA PADA PEMODELAN RANAH KOGNITIF SISWA MIPA .....	69
5.1. Ekstraksi fitur.....	69
5.1.1. Arsitektur sistem ekstraksi fitur yang diusulkan.....	70
5.1.2. Hasil uji coba dan pembahasan dari metode ekstraksi fitur .....	74
5.1.3. Intisari ekstraksi fitur pada ranah kognitif siswa MIPA .....	79
5.2. Diskritisasi fitur .....	79
5.2.1. Kerangka kerja diskritisasi fitur yang diusulkan .....	79
5.2.2. Hasil uji coba dan pembahasan dari metode diskritisasi fitur .....	81
5.2.3. Intisari diskritisasi fitur pada ranah kognitif siswa .....	88
5.3. Pemilihan fitur .....	89
5.3.1. Kerangka kerja pemilihan fitur yang diusulkan.....	89
5.3.2. Hasil uji coba dan pembahasan dari metode diskritisasi fitur .....	91
5.3.3. Intisari pemilihan fitur pada ranah kognitif siswa MIPA.....	98
BAB 6	
HIBRIDA DARI TRANSFORMASI DATA DAN LOGITBOOST UNTUK IDENTIFIKASI LEVEL KOGNITIF SISWA MIPA .....	99
6.1. Meta-algoritma LogitBoost (Logistic Boosting) .....	100
6.1.1. Meta-algoritma yang diusulkan. ....	102

6.1.2. Tahap pasca pemrosesan. ....	102
6.2. Hasil uji coba dan pembahasan.....	103
6.2.1. Pra-pemrosesan data siswa yang fitur-fiturnya diekstraksi berdasarkan kategori. ....	103
6.2.2. LogitBoost sebagai pendekatan meta-algoritma untuk mengidentifikasi tingkat kognitif siswa.....	106
6.3. Intisari hibrida transformasi data dan meta-algoritma logitboost pada identifikasi prestasi belajar siswa.....	120
<b>BAB 7</b>	
<b>KESIMPULAN DAN PENELITIAN LANJUTAN.....</b>	<b>121</b>
7.1. Kesimpulan.....	121
7.2. Penelitian lanjutan.....	121
<b>DAFTAR PUSTAKA .....</b>	<b>123</b>
<b>APENDIKS 1 RIWAYAT HIDUP</b>	
<b>APENDIKS 2 DAFTAR PUBLIKASI</b>	







- **Halaman ini sengaja dibiarkan kosong** -

## DAFTAR GAMBAR

Gambar 1.1 Peta jalan dari penelitian disertasi .....	21
Gambar 1.2 <i>Fishbone</i> dari Penelitian Disertasi .....	22
Gambar 2.1 <i>Filter-based subset evaluation</i> (FSBE) (Hall, 1999) .....	30
Gambar 2.2 Algoritma pencarian <i>Best first</i> (Hall, 1999) .....	31
Gambar 2.3 Tahapan dari CFS. (Hall, 1999).....	32
Gambar 3.1 Kualitas media pembelajaran e-learning. ....	45
Gambar 3.2 Efektifitas media pembelajaran <i>e-Learning</i> . ....	48
Gambar 3.3 Respon siswa terhadap media pembelajaran <i>e-Learning</i> . ....	53
Gambar 3.4 Hasil validasi RPP .....	56
Gambar 3.5 Hasil validasi kelayakan LKS.....	57
Gambar 3.6 Hasil validasi soal evaluasi.....	59
Gambar 3.7 Hasil validasi respon siswa.....	59
Gambar 4.1. Proses pengumpulan data ranah kognitif siswa MIPA .....	65
Gambar 5.1 Arsitektur sistem ekstraksi fitur yang diusulkan .....	71
Gambar 5.2 Luaran FCM pada pengklasteran ranah kognitif siswa MIPA.....	75
Gambar 5.3 Luaran CBE_FCM pada pengklasteran ranah kognitif siswa MIPA... 75	
Gambar 5.4 Luaran BTBE_FCM pada pengklasteran ranah kognitif siswa MIPA 76	
Gambar 5.5 Level akurasi dari 3 metode .....	77
Gambar 5.6 Waktu Eksekusi dari 3 Metode.....	77
Gambar 5.7 ROC-1- <i>Specificity</i> dan <i>Sensitivity</i> dari 3 Metode .....	78
Gambar 5.8 Kerangka kinerja diskritisasi fitur yang diusulkan .....	80
Gambar 5.9 Garis regresi dengan korelasi tertinggi pada diskritisasi-3 interval-lasso .....	82
Gambar 5.10 Garis regresi dengan korelasi tertinggi pada diskritisasi-3 interval-ridge .....	83
Gambar 5.11 Garis regresi dengan korelasi tertinggi pada diskritisasi-4 interval-lasso .....	83
Gambar 5.12 Garis regresi dengan korelasi tertinggi pada diskritisasi-4 interval-ridge .....	84

Gambar 5.13 Garis regresi dengan korelasi tertinggi pada diskritisasi-5 interval-lasso .....	84
Gambar 5.14 Garis regresi dengan korelasi tertinggi pada diskritisasi-5 interval-ridge .....	85
Gambar 5.15 Perbandingan dari akurasi level pada semua interval .....	88
Gambar 5.16 Kerangka kerja pemilihan fitur yang diusulkan.....	90
Gambar 5.17 Nilai <i>silhouette</i> yang menunjukkan banyaknya kluster yang paling optimal pada 2 .....	92
Gambar 5.18 Visualisasi hasil pengklasteran dengan set fitur asli & K-mean .....	93
Gambar 5.19 Visualisasi hasil pengklasteran dengan set fitur yang terpilih & K-means .....	93
Gambar 5.20 Gambar kiri (a) visualisasi nilai <i>silhouette</i> dari set fitur asli_K-means dan Gambar kanan (b) visualisasi nilai <i>silhouette</i> dari set fitur terpilih_K-means .....	94
Gambar 5.21 Hasil analisa pengklasteran dari kombinasi K-means dan set fitur asli dengan ANOVA .....	96
Gambar 5.22 Hasil analisa pengklasteran dari kombinasi K-means dan set fitur terpilih dengan ANOVA .....	96
Gambar 5.23 Uji-t dari rerata nilai <i>silhouette</i> dari kedua metode .....	97
Gambar 6.1 (a) Arsitektur dari sistem yang diusulkan untuk mengidentifikasi tingkat kognitif siswa MIPA, (b) Desain metode pemilihan fitur .....	100
Gambar 6.2 <i>Pseudo-code</i> dari LogitBoost .....	103
Gambar 6.3 Uji normalitas multivariat pada data ranah kognitif IPA siswa (SMKUO) .....	104
Gambar 6.4 Perbandingan tingkat akurasi semua interval dari metode diskritisasi pada k-NN .....	105
Gambar 6.5 Perbandingan tingkat akurasi pada semua metode .....	107
Gambar 6.6. Perbandingan rerata tingkat akurasi pada Decision Stump .....	110
Gambar 6.7 Perbandingan rerata tingkat akurasi pada REP Tree.....	111
Gambar 6.8 Perbandingan rerata tingkat akurasi pada Random Tree.....	111
Gambar 6.9 Perbandingan rata-rata tingkat kesalahan dalam metrik MAE.....	113

Gambar 6.10 Visualisasi kinerja terbaik dari sistem identifikasi pada Decision  
Stump menggunakan hibrida transformasi data dan LogitBoost sebagai  
meta-algoritma..... 115






- Halaman ini sengaja dibiarkan kosong -

## DAFTAR TABEL

Tabel 1.1 Penelitian Sebelumnya tentang Identifikasi Prestasi Belajar Siswa .....	10
Tabel 3.1 Hasil Validasi Media Pembelajaran <i>e-Learning</i> terhadap Aspek Kemudahan Pengoperasian Media .....	42
Tabel 3.2 Hasil Validasi Media Pembelajaran <i>e-Learning</i> terhadap Aspek Keterpaduan Media.....	43
Tabel 3.3 Hasil Validasi Media Pembelajaran <i>e-Learning</i> terhadap Aspek Keseimbangan Media.....	43
Tabel 3.4 Hasil Validasi Media Pembelajaran <i>e-Learning</i> terhadap Aspek Bentuk Media .....	44
Tabel 3.5 Hasil Validasi Media Pembelajaran <i>e-Learning</i> terhadap Aspek Format Media .....	46
Tabel 3.6 Hasil Validasi Media Pembelajaran <i>e-Learning</i> terhadap Aspek Isi Media .....	47
Tabel 3.7 Hasil Angket Respon Siswa terhadap Aspek Format Media.....	49
Tabel 3.8 Hasil Angket Respon Siswa terhadap Aspek Isi Media .....	50
Tabel 3.9 Hasil Angket Respon Siswa terhadap Aspek Bahasa Media.....	51
Tabel 3.10 Hasil Angket Respon Siswa terhadap Aspek Kemudahan Pengoperasian Media .....	51
Tabel 3.11 Hasil Angket Respon Siswa terhadap Aspek Sikap Siswa terhadap Penggunaan Media.....	52
Tabel 3.12 Hasil Validasi Rencana Pelaksanaan Pembelajaran.....	54
Tabel 3.13 Penilaian Data Hasil Validasi LKS .....	56
Tabel 3.14 Penilaian Data Hasil Validasi Soal Evaluasi .....	58
Tabel 3.15 Penilaian Data Hasil Validasi Respon Siswa.....	60
Tabel 4.1 Fitur dan Tipe Data dari Ranah Kognitif Siswa Matematika .....	66
Tabel 4.2 Fitur dan Tipe Data dari Ranah Kognitif Siswa IPA .....	67
Tabel 5.1 Fitur dan Tipe Data dari Data Siswa yang Diekstrak Berbasis Kategori.....	72

Tabel 5.2 Fitur dan Tipe Data dari Data Siswa yang Diekstrak Berbasis Taksonomi Bloom.....	72
Tabel 5.3 Matrik <i>Confusion</i> dari 3 Metode.....	74
Tabel 5.4 <i>Area Under Curve (AUC)</i> dari 3 Metode .....	77
Tabel 5.5 Koordinat Kurva dari 3 Metode.....	78
Tabel 5.6 Domain Kognitif Siswa MIPA dengan Fitur yang Terekstraksi Berbasis Kategori.....	81
Tabel 5.7 Akurasi Level dari Kombinasi Regresi Logistik Semua Regulasi dan Diskritisasi 3 Interval.....	86
Tabel 5.8 Akurasi Level dari Kombinasi Regresi Logistik dan Diskritisasi 4 Interval Semua Regulasi .....	86
Tabel 5.9 Akurasi Level dari Kombinasi Regresi Logistik dan Diskritisasi 5 Interval Semua Regulasi .....	87
Tabel 5.10 Analisis Hasil Klaster pada Masing-Masing Kombinasi dengan ANOVA .....	95
Tabel 5.11 Nilai <i>silhouette</i> dari Kombinasi K-means & Set Fitur Asli(OF) dan Kombinasi K-means & Set Fitur Terpilih (FS) .....	97
Tabel 6.1 Korelasi antara Jarak Mahalanobis dan Chi-square.....	105
Tabel 6.2 Hasil Metode Pemilihan Fitur.....	105
Tabel 6.3 Rerata dari Kappa, Precision, Recall, F-Measure and AUC pada Fold 3-12 .....	106
Tabel 6.4 Rerata Level Akurasi, MAE, Banyaknya Siswa yang Salah Identifikasi pada Semua Kombinasi Metode.....	119

## NOMENKLATUR



ANOVA	<i>Analysis of Variance</i>
AUC	<i>Area Under Curve</i>
Alfa	batas toleransi
$a_i$	jarak intra
$b_i$	jarak antar ( <i>between</i> )
$C$	jumlah kelas untuk variabel
CFS	<i>Correlation-based Feature Selection</i>
Done	soal yang dikerjakan
EDM	<i>Educational Data Mining</i>
fj	model regresi ke-j dalam <i>ensemble</i>
fj(a)	prediksinya <i>instance a</i>
FBSE	<i>filter-based subset evaluation (evaluasi subset berbasis filter)</i>
FS	set fitur yang terseleksi (terpilih)
Hint	petunjuk pengerjaan tes
H0	hipotesis nol
H1	hipotesis alternatif
$(J_w(U, V; X))$	fungsi obyektif FCM
$k$ -NN	k-Nearest Neighbor
LogitBoost	Logistic Boosting
OF	fitur original atau asli
$p(1 a)$	estimasi probabilitas untuk kelas pertama
pk	rasio observasi
PercentTrue	prosentasi jawaban benar
ref	korelasi fitur-kelas rata-rata
rff	rata-rata fitur antar-korelasi.
$S_i$	nilai silhoette dari titik ke-i
BTBE	Ekstraksi Fitur Berbasis Taksonomi



$C$	<i>Class/target kelas</i>
$CBE$	Ekstraksi Fitur Berbasis Kategori
$\beta$	parameter yang dicari pada regresi
$D(i, j)$	Jarak data ke $i$ ke pusat cluster $j$
$diff()$	perbedaan dengan hit $x_H$ terdekat dan miss $x_M$ terdekat
$d(k)$	parameter jarak di k-NN
FP	<i>False Positive</i>
FN	<i>False Negative</i>
F	Set fitur
IG	Gini Index
$k$	jumlah interval
$MAE$	<i>Mean Absolute Error</i>
Mean	Mean dari vektor fitur
MIPA	Matematika dan Ilmu Pengetahuan Alam
N	jumlah siswa
$p$	odds ratio
P	kelayakan media
<i>Score</i>	skor siswa
<i>Time</i>	waktu yang dibutuhkan siswa
<i>AccessToHelp</i>	bantuan yang dibutuhkan siswa
TP	<i>True Positive</i>
TN	<i>True Negative</i>
SD	Standar Deviasi
$v=V$	matrik pusat klaster
w	lebar interval
$W(i)$	bobot kualitas
WBSE	<i>wrapper-based subset evaluation (evaluasi subset berbasis wrapper)</i>
x	Vektor fitur original
$X_{ki}$	Data ke $i$ pada atribut data ke $k$

$X_{kj}$	Titik pusat ke j pada atribut ke k
X	data yang akan diklaster
$y_i$	label kelas
$y_m$	kelas target





# BAB 1

## PENDAHULUAN

### 1.1. Latar belakang

Saat ini, hampir semua proses dalam pendidikan bergantung pada Teknologi Informasi dan Komunikasi (TIK) untuk menghasilkan kualitas pendidikan yang lebih baik (Rodrigues, Zárate, & Isotani, 2018). Ketergantungan ini mendorong pengembangan perangkat pembelajaran berbasis TIK (*ICT-based educational tools*), berupa: sistem *e-learning* (Wanarti, Ismayanti, Peni, & Yamasari, 2016), *serious game* (Ibarra, Soto, Ataucusi, & Ataucusi, 2016), (Mangowal, Yuhana, Yuniarno, & Purnomo, 2017), ujian online dan lain sebagainya. Penggunaan perangkat pembelajaran berbasis TIK ini dapat merekam lebih banyak karakteristik dari siswa. Kondisi ini mendorong munculnya analisa terhadap data pendidikan ini. Salah satunya adalah penambangan data pendidikan (*Educational Data Mining=EDM*) (Calvet Liñán & Juan Pérez, 2015).

EDM sendiri didefinisikan sebagai penambangan data berbasis metode, tugas, dan algoritma untuk proses analisa. Analisa ini ditujukan untuk menyelidiki data tersebut sehingga menemukan pola deskriptif dan prediktif yang mengkarakterisasi perilaku, penilaian, fungsi pendidikan, prestasi, konten pengetahuan domain dan aplikasi peserta didik (Peña-Ayala, 2014). Selain itu, EDM dapat dilakukan dengan menggunakan statistik, metode *Data Mining* dan algoritma pembelajaran mesin (Dillenbourg, 2016).

EDM berdasarkan model dikelompokkan menjadi 2, yaitu: model yang bersifat deskriptif dan prediktif. Model deskriptif biasanya dibangun dengan menggunakan *unsupervised learning* (Fan & Sun, 2016), (J. C. De Gagne et al., 2018). Sementara, model prediktif diimplementasikan dengan *supervised learning* (de Morais, Araujo, & Costa, 2014), (Nguyen, Pham, Vo, Vo, & Quan, 2018). Penambangan data berdasarkan tugas (*task*) dapat dibedakan menjadi beberapa model yaitu pengklasteran (Berkhin, 2006), rule asosiasi (*association rules*) (Hong, Lin, & Wang, 2003), analisis korelasi (Hardoon, Szedmak, & Shawe-Taylor, 2003), klasifikasi (Chau, Cheng, Kao, & Ng, 2006), regresi (Wu & Li, 2007) dan

kategorisasi (Genkin, Lewis, & Madi-gan, 2007). Penambangan data pendidikan berdasarkan fungsionalitasnya dibagi menjadi beberapa model (Peña-Ayala, 2014), yaitu: pemodelan perilaku siswa; pemodelan kinerja siswa; pemodelan penilaian; pemodelan siswa; pemodelan dukungan dan umpan balik siswa; pemodelan kurikulum, pengetahuan ranah, urutan dan dukungan guru.

Dalam pemodelan siswa, pembangunan model ditujukan untuk beberapa hal yang berkaitan dengan karakteristik siswa, misalnya: domain pengetahuan, strategi pembelajaran, prestasi belajar, preferensi belajar, keterampilan, evaluasi dan lain sebagainya. Banyaknya karakteristik siswa yang tersimpan ini pada dasarnya diharapkan untuk meningkatkan keakuratan identifikasi emosi, penilaian, kinerja maupun prestasi belajar siswa dan lain sebagainya. Namun, disisi lain, keadaan ini mengakibatkan guru menemui kesulitan, khususnya dalam proses penentuan ini, karena semakin banyak karakteristik siswa yang harus dipertimbangkan. Kondisi ini merangsang penelitian tentang pemodelan prestasi belajar siswa, khususnya, dalam rangka penentuan ranah kognitif siswa. Namun, solusi dan strategi yang ditawarkan untuk penentuan ranah kognitif masih sangat terbatas. Bahkan, solusi yang ada masih mempunyai kinerja yang rendah sehingga kesalahan identifikasi masih tinggi (Yuni Yamasari et al., 2019).

Kinerja yang rendah ini seringkali disebabkan karakteristik pada data siswa berada dalam kondisi yang tidak mendukung target. Sehingga, metode-metode transformasi data perlu diimplementasikan pada tahap pra-pemrosesan data yang mengandung fitur-fitur siswa. Dimana, fitur-fitur ini merupakan karakteristik siswa (Chrysafiadi & Virvou, 2014)(Troussas, Virvou, & Mesaretzidis, 2015). Metode-metode tersebut antara lain: normalisasi fitur, diskritisasi fitur, ekstraksi fitur, pemilihan fitur dan lain-lain (Pang, Steinbach, & Kumar, 2006). Normalisasi fitur ini dilakukan agar fitur dalam keadaan normal dalam hal distribusinya. Sedangkan, ekstraksi fitur dilakukan apabila fitur-fitur tersebut ditemukan ciri atau bagian yang sama atau ingin mengubah fitur, maka diperlukan pembentukan fitur baru dengan formula tertentu. Untuk contoh, penelitian (Yuni Yamasari, Nugroho, Sukajaya, & Purnomo, 2016) melakukan ekstraksi fitur berdasarkan kategorinya agar kinerja pengelompokan prestasi belajar siswa meningkat. Metode yang termasuk dalam transformasi data adalah diskritisasi fitur. Metode ini melakukan transformasi dari

atribut kontinyu ke atribut kategorikal yang melibatkan dua langkah, yaitu: memutuskan berapa banyak kategori dan menetapkan bagaimana memetakan nilai kontinyu ke kategori-kategori tersebut. Diskritisasi ini diimplementasikan agar data berada pada kondisi yang sesuai dengan metode proses penambangan. Hasil yang diharapkan dari penerapan ini adalah kinerja proses lebih optimal seperti ditunjukkan oleh penelitian sebelumnya (Yuni Yamasari et al., 2018). Penelitian ini telah melakukan diskritisasi fitur untuk meningkatkan kinerja model yang berkaitan dengan prestasi belajar siswa.

Berkaitan dengan fitur-fitur baru yang terbentuk, fitur-fitur ini tidak semuanya relevan untuk membangun sebuah model. Metode untuk mengeliminasi fitur yang tidak relevan ini lebih dikenal dengan seleksi fitur. Banyak sekali metode seleksi fitur yang dapat dieksploitasi. Metode-metode tersebut antara lain: relief dan budget tree-random forest (Deepika & Sathyanarayana, 2019); gain informasi, algoritma genetika, dan Redundansi Minimum dan Relevansi Maksimum (MRMR) dan WBSE (SVM) (Punlumjeak & Rachburee, 2015); CfsSubsetEval, ChiSquaredAttributeEval(Zaffar, Hashmani, & Savita, 2017); chi-square(Pong-Inwong & Kaewmak, 2016). Metode-metode di domain transformasi data ini diterapkan agar model dapat dioptimalkan kinerjanya. Namun, dalam domain pemodelan prestasi belajar siswa, penelitian sebelumnya hanya sedikit yang mengeksplorasi transformasi data ini untuk menaikkan kinerja model (diperlihatkan pada Tabel 1.1).

Selain transformasi data, penelitian sebelumnya berusaha meningkatkan kinerja model dengan penerapan meta-algoritma. *Boosting* merupakan salah satu meta-algoritma *ensemble* yang membangun beberapa model dan juga menggabungkan prediksi dari berbagai model ke dalam prediksi tunggal (Rokach, 2010). Tentu saja, prediksi yang diharapkan mencapai kinerja terbaik (Polikar, 2006). Metode *ensemble* yang paling populer adalah *Adaptive Boosting* (AdaBoost)(Opitz & Maclin, 1999). Metode ini dapat digunakan bersama dengan algoritma pembelajaran yang lainnya untuk meningkatkan kinerja. *Output* dari algoritma pembelajaran yang lemah (*weak learner*) digabungkan menjadi jumlah terbobot yang mewakili hasil akhir dari *classifier* yang ditingkatkan akurasi. (Law, 2012) (Freund & Schapire, 1997). Metode *ensemble* yang lain adalah

*Logistic Boosting* (LogitBoost) yang sering juga dieksploitasi oleh banyak penelitian. Metode ini hampir sama dengan AdaBoost, perbedaannya terletak pada *base learner*-nya berupa skema regresi (Friedman, Hastie, Tibshirani, & Stanford, 1998). Namun, metode-metode *ensemble* ini belum dieksplorasi lebih mendalam di domain pemodelan prestasi belajar siswa, khususnya pada identifikasi level kognitif siswa (diperlihatkan pada Tabel 1.1).

Ranah kognitif yang paling banyak dieksplorasi oleh peneliti sebelumnya adalah mata pelajaran Matematika (diperlihatkan pada Tabel 1.1). Hal ini disebabkan karena Matematika mempunyai hubungan yang erat dengan perilaku-perilaku sehari-hari. Matematika merupakan ilmu pengetahuan tentang penalaran yang *logic* dan masalah yang berhubungan dengan bilangan. Jadi, penguasaan pada Matematika sangat diperlukan. Seiring dengan perkembangannya, matematika selalu mendampingi ilmu-ilmu lain, tidak terkecuali Ilmu Pengetahuan Alam. Matematika adalah ilmu pendukung IPA sebagai dasar perhitungan dan logika. Dalam perkembangannya, IPA tidak pernah lepas dari matematika, bahkan IPA tidak akan bisa berkembang tanpa adanya Matematika. Matematika dalam Ilmu Pengetahuan Alam (IPA) memiliki peran dan hubungan erat baik dalam hal bahasa maupun hitungan dan sebagainya.

Oleh karena itu, penelitian disertasi ini mengusulkan metode hibrida transformasi data dan meta-algoritma untuk meningkatkan kinerja dalam identifikasi level kognitif siswa MIPA. Untuk itu, penelitian disertasi ini diawali dengan membentuk fitur baru dari beberapa fitur asli agar banyaknya fitur lebih sedikit sehingga pemetaan data ranah kognitif siswa MIPA hanya mengkonsumsi waktu eksekusi lebih sedikit dan kinerja meningkat, dalam istilah level akurasi. Proses ini dilakukan dengan mengeksplorasi metode ekstraksi fitur. Selanjutnya, penelitian difokuskan pada penentuan banyaknya level kognitif siswa MIPA dengan menggunakan metode diskritisasi fitur. Untuk langkah berikutnya, penelitian ini menganalisa fitur yang ada untuk menemukan fitur yang paling berpengaruh pada proses identifikasi dengan metode seleksi fitur. Terakhir, penelitian berupaya untuk meningkatkan proses identifikasi dengan menerapkan meta-algoritma *boosting*.

## 1.2. Rumusan permasalahan

Penelitian yang telah dilakukan pada pemodelan prestasi belajar siswa mengalami peningkatan pada beberapa dekade terakhir. Berkaitan dengan identifikasi level kognitif siswa MIPA, meskipun terdapat banyak strategi peningkatan kinerja dari pemodelan prestasi belajar siswa ini. Namun, solusi yang ditawarkan masih terbatas. Beberapa tantangan dalam meningkatkan kinerja identifikasi ini dapat dirumuskan sebagai berikut:

1. Bagaimana membentuk fitur baru dari fitur yang ada pada ranah kognitif siswa MIPA, agar siswa berada pada kelompok yang sesuai dengan prestasi belajar yang dicapainya? Fitur pada data siswa berkaitan dengan karakteristik siswa. Semakin banyak karakteristik siswa yang tersimpan seringkali membuat guru mengalami kesulitan dalam penentuan prestasi belajar siswa, khususnya ranah kognitif. Hal ini dikarenakan semakin banyak yang harus dipertimbangkan. Untuk itu, pembentukan fitur baru dari beberapa fitur yang ada tanpa menghilangkan informasi yang tersimpan merupakan upaya yang perlu diimplementasikan. Lebih dari itu, dengan pembentukan fitur baru ini, proses penentuan diharapkan mengkonsumsi waktu yang lebih sedikit dan kinerja yang lebih tinggi.
2. Bagaimana cara menentukan berapa banyaknya level kognitif dari siswa MIPA?  
Penentuan banyaknya level kognitif dari siswa MIPA pada data yang berkaitan dengan ranah kognitif siswa pada fitur yang telah terekstraksi bukanlah hal yang mudah dilakukan. Ketepatan proses ini memberikan pemahaman yang benar pada kondisi ranah kognitif siswa dan tentu saja juga berdampak pada kinerja dari sistem yang akan dibangun.
3. Bagaimana mengidentifikasi karakteristik siswa yang paling berpengaruh dalam penentuan level kognitif siswa MIPA? Fitur yang terbentuk dari fitur ekstraksi tidak semuanya relevan untuk dipergunakan membangun sebuah model. Ketidakrelevanan fitur ini dapat menyebabkan turunnya kinerja. Oleh karena itu, penelitian yang berkaitan dengan identifikasi karakteristik



siswa yang paling berperan dalam penentuan level kognitif siswa MIPA sangat diperlukan.

4. Identifikasi prestasi belajar siswa pada dasarnya terdiri dari 3 ranah, yaitu ranah kognitif, psikomotor dan afektif. Penelitian yang paling banyak dilakukan adalah pada ranah kognitif siswa. Namun, penelitian yang ada belum membangun sistem yang optimal sehingga hasil identifikasi yang salah pada level kognitif siswa masih cukup tinggi. Bagaimana meningkatkan kinerja sistem identifikasi level kognitif siswa MIPA agar banyaknya siswa yang salah identifikasi dapat dikurangi sebanyak mungkin?

### **1.3. Tujuan dan manfaat penelitian**

Penelitian ini bertujuan untuk mengembangkan sistem yang efektif dalam identifikasi level kognitif siswa MIPA agar guru dapat memotivasi dan mengoptimalkan potensi siswa pada ranah ini. Sehingga, siswa dapat mencapai prestasi belajar yang terbaik, khususnya level kognitifnya. Sistem yang efektif ini dapat diwujudkan melalui pengembangan metode hibrida transformasi data dan meta-algoritma.

Proses pengembangan terdiri dari beberapa langkah yang masing-masing langkahnya mencari strategi terbaik, yaitu: eksplorasi metode ekstraksi fitur untuk pembentukan fitur baru dari beberapa fitur asli. Hal ini ditujukan agar proses pemetaan hanya mengkonsumsi waktu eksekusi lebih sedikit dan kinerja lebih meningkat. Langkah selanjutnya, metode diskritisasi fitur diterapkan untuk penentuan banyaknya level kognitif siswa MIPA yang optimal. Kemudian, metode seleksi fitur diimplementasikan untuk menemukan fitur yang paling berpengaruh pada proses identifikasi. Langkah terakhir adalah penerapan meta-algoritma LogitBoost untuk meningkatkan proses identifikasi.

Sistem identifikasi yang efektif ini nantinya bermanfaat bagi guru untuk mengevaluasi dan memperbaiki rencana pelaksanaan pembelajaran, proses belajar mengajar, proses evaluasi dan sebagainya.

#### 1.4. Peta jalan penelitian

Pendekatan EDM yang dikategorikan berdasarkan fungsionalitas terdiri dari 6 pemodelan yaitu: 1. Pemodelan siswa; 2. Pemodelan perilaku siswa; 3. Pemodelan kinerja siswa; 4. Pemodelan penilaian; 5. Pemodelan dukungan dan umpan balik siswa; 6. Pemodelan kurikulum, ranah pengetahuan, urutan dan dukungan guru (Peña-Ayala, 2014). Pemodelan siswa sendiri diorientasikan untuk membentuk berbagai domain dari karakteristik pelajar, yaitu: prestasi belajar, emosi, kognisi, domain pengetahuan, strategi pembelajaran, fitur, preferensi belajar, keterampilan, dan evaluasi.

Berkaitan dengan proses identifikasi level kognitif siswa, pembahasan ini tidak bisa dipisahkan dengan pemodelan prestasi belajar siswa. Untuk memahaminya, definisi dari prestasi dan belajar terlebih dahulu sangat diperlukan. Prestasi merupakan hasil yang telah dicapai seseorang dalam mengerjakan suatu kegiatan. Prestasi belajar dibedakan menjadi lima aspek menurut (R. M. Gagne, 1985), yaitu: kemampuan intelektual, strategi kognitif, informasi verbal, sikap dan keterampilan.

(Sardiman, 2005) menjelaskan beberapa definisi menurut beberapa ahli, antara lain: 1. Cronbach mendefinisikan pembelajaran yang diperlihatkan dengan sebuah perubahan dalam perilaku sebagai hasil dari pengalaman, 2. Harold Spears mendefinisikan pembelajaran adalah mengamati, membaca, memprakarsai, mencoba sesuatu sendiri, mendengarkan, mengikuti arahan. 3. Geoch mendefinisikan pembelajaran adalah sebuah perubahan dalam kinerja sebagai hasil dari latihan. Berdasarkan ketiga definisi ini, kita bisa menyimpulkan bahwa belajar itu senantiasa merupakan perubahan tingkah laku atau kinerja dari beberapa kegiatan misalnya: membaca, mengamati, mendengarkan, meniru dan sebagainya. Berkaitan dengan proses belajar, apabila seseorang tidak mendapatkan suatu peningkatan kualitas dan kuantitas kemampuan, maka orang tersebut sebenarnya belum mengalami proses belajar atau dengan kata lain mengalami kegagalan di dalam proses belajar.

(Winkel, 2007) mengatakan bahwa “prestasi belajar adalah suatu bukti keberhasilan belajar atau kemampuan seseorang siswa dalam melakukan kegiatan belajarnya sesuai dengan bobot yang dicapainya”. Sedangkan, menurut Kamus

Besar Bahasa Indonesia yang dikeluarkan oleh Departemen Pendidikan dan Kebudayaan (1988), prestasi belajar adalah “penguasaan pengetahuan atau keterampilan yang dikembangkan oleh mata pelajaran. Penguasaan ini lazimnya ditunjukkan dengan nilai tes atau nilai angka yang diberikan oleh guru”. Jadi, dengan adanya nilai dari guru dapat diketahui apakah prestasi belajar siswa itu baik atau tidak.

Prestasi belajar merupakan hasil dari pengukuran terhadap peserta didik yang meliputi faktor kognitif, afektif dan psikomotor. Proses pembelajaran diukur dengan menggunakan instrumen yang relevan. Hal ini sesuai dengan Taksonomi Bloom yang diperkenalkan oleh Benjamin S. Bloom pada tahun 1956. Taksonomi ini terdiri dari tiga domain, yaitu:

1. *Cognitive domain* (ranah kognitif) mencakup perilaku-perilaku yang menekankan aspek intelektual, seperti pengetahuan, pengertian, dan keterampilan berpikir.

2. *Affective domain* (ranah afektif) meliputi perilaku-perilaku yang menekankan aspek perasaan dan emosi, seperti minat, sikap, apresiasi, dan cara penyesuaian diri.

3. *Psychomotor domain* (ranah psikomotor) mencakup perilaku-perilaku yang menekankan aspek keterampilan motorik seperti tulisan tangan, mengetik, berenang, dan mengoperasikan mesin.

Setiap ranah terdiri dari beberapa kategori dan sub-kategori yang berurutan secara hierarkis yang di mulai dari tingkah laku yang sederhana sampai tingkah laku yang paling kompleks. Berdasarkan studi literatur yang disajikan pada Tabel 1.1 ini, identifikasi prestasi belajar siswa, khususnya ranah kognitif, pada umumnya belum membahas peningkatan kinerja dari model atau sistem yang dibuat.

Oleh karena itu, penelitian disertasi ini memfokuskan ke arah tersebut. Hal ini ditunjukkan pada Gambar 1.1 yang menggambarkan pemetaan umum studi dalam identifikasi prestasi belajar siswa, yang meliputi tiga bidang yaitu, ranah kognitif, afektif dan psikomotor. Gambar 1.1 juga mendeskripsikan studi yang masih berlangsung dan akan dilakukan dalam disertasi ini.

### 1.5. Kontribusi dan originalitas penelitian

Kontribusi utama penelitian ini adalah strategi terbaik untuk melakukan identifikasi ranah kognitif siswa MIPA. Strategi-strategi ini mencakup empat bidang dalam studi identifikasi level kognitif siswa MIPA, sebagai berikut:

1. Metode pembentukan fitur baru dari beberapa fitur asli menggunakan metode ekstraksi fitur. Fitur baru yang terbentuk dimaksudkan untuk meningkatkan kinerja proses pemetaan pada ranah kognitif siswa MIPA.
2. Metode penentuan banyaknya level kognitif siswa MIPA menggunakan metode diskritisasi fitur.
3. Metode penentuan fitur yang paling berpengaruh dalam proses identifikasi level kognitif siswa MIPA berdasarkan eksplorasi metode seleksi fitur.
4. Metode peningkatan kinerja dari sistem identifikasi level kognitif siswa MIPA menggunakan penerapan meta-algoritma.

Gambar 1.2 menunjukkan diagram tulang ikan yang mengategorikan beberapa topik penelitian untuk menghasilkan kinerja yang tinggi pada identifikasi level kognitif siswa MIPA. Hal ini merupakan tujuan utama penelitian ini dengan strategi terbaik pada ekstraksi fitur, diskritisasi fitur, seleksi fitur dan meta-algoritma. Kontribusi terutama berfokus pada topik ranah kognitif yang berasal dari peta jalan penelitian yang ditunjukkan pada Gambar 1.1.

Tabel 1.1 Penelitian Sebelumnya tentang Identifikasi Prestasi Belajar Siswa

Topik	No.	Judul	Hasil	Deskripsi
Ranah kognitif	1.	Stella, Luz <i>et.al.</i> , “ <i>A cluster-based analysis to diagnose students’ learning achievements</i> ”, 2013.(Stella, Pedrozo, Rodriguez-artacho, & Member, 2013)	Makalah ini memaparkan penelitian yang bertujuan untuk mengidentifikasi permasalahan kognitif siswa dan menyediakan personalisasi serta saran-saran pembelajaran yang cerdas. Penilaian siswa di domain kognitif ini dilakukan melalui media berupa permainan dengan konten matematika. Hasil ujicoba menunjukkan bahwa penelitian ini telah menghasilkan informasi yang sangat penting berupa estimasi yang bagus dari parameter-parameter yang mengukur level kemampuan dari masing-masing siswa. Pengukuran ini berpengaruh terhadap pembuatan soal dari seluruh topik dan level kesulitannya.	<ul style="list-style-type: none"> <li>- Identifikasi dilakukan pada ranah kognitif</li> <li>- Tidak melakukan transformasi data</li> <li>- Tidak menerapkan meta-algoritma</li> </ul>
	2.	Cerezo, Rebeca <i>et.al.</i> , “ <i>Students’ LMS interaction patterns and their relationship with</i>	Penelitian memfokuskan pada penambangan data tentang perilaku siswa ketika melakukan pembelajaran dengan LMS. Penambangan data ini ditujukan untuk mengetahui perilaku apa saja yang berpengaruh	<ul style="list-style-type: none"> <li>- Identifikasi dilakukan pada ranah kognitif</li> <li>- Tidak melakukan transformasi data</li> </ul>

		<p><i>achievement: A case study in higher education</i>”, 2016. (Cerezo, Sánchez-Santillán, Paule-Ruiz, &amp; Núñez, 2016)</p>	<p>terhadap prestasi belajar siswa. Penambahan data yang digunakan adalah pengklasteran (<i>clustering</i>). Sedangkan perilaku yang digunakan dalam penelitian ini berkaitan dengan usaha, waktu dan sikap menunda yang sering dilakukan siswa. Hasil eksperimen menunjukkan bahwa usaha (secara individu dan grup) dan sikap menunda (menunda atau tidak). Kedua perilaku itu yang paling berpengaruh terhadap prestasi belajar siswa dan juga paling cocok digunakan untuk pengelompokan siswa.</p>	<ul style="list-style-type: none"> <li>- Tidak menerapkan meta-algoritma</li> </ul>
Ranah kognitif	3.	<p>Imtiyaz, Mansha, “<i>Evaluating the Quality of Teaching in Higher Education Institutes using Clustering Approach and Set Pair Analysis</i>”, 2015 (Imtiyaz, 2015)</p>	<p>Makalah ini melakukan penelitian tentang evaluasi kualitas pengajaran dengan mengkombinasikan pendekatan pengelompokan (<i>clustering</i>) dan teori matematika fuzzy. Penerapan kombinasi ditujukan untuk menghapus ketidakpastian dalam hasil dan menjamin hanya respon yang asli yang dipertimbangkan dalam perhitungan. Hasil eksperimen menunjukkan akurat dan dapat diandalkan kombinasi ini untuk mengevaluasi kualitas pengajaran.</p>	<ul style="list-style-type: none"> <li>- Identifikasi dilakukan pada ranah kognitif saja</li> <li>- Tidak melakukan transformasi data</li> <li>- Tidak menerapkan meta-algoritma</li> </ul>

			<p>Pengelompokkan pada pengguna siswa dilakukan dengan menggunakan prestasi belajarnya,</p>	
<p>Ranah kognitif</p>	<p>4.</p>	<p>Buniamin, N. et.al, <i>“Educational data mining for prediction and classification of engineering students’ achievement”</i>, 2015. (Buniamin, Mat, &amp; Arshad, 2015)</p>	<p>Penelitian ini memfokuskan pada pentingnya penambangan data siswa untuk perencanaan pendidikan. Pada makalah ini, penambangan data ditujukan untuk prediksi dan klasifikasi kinerja akademik yaitu: mengetahui lebih awal siswa yang mempunyai capaian kinerja (<i>didasarkan pada cumulative grade point average</i>) yang rendah sehingga universitas dapat menyediakan asistensi yang diperlukan. Klasifikasi dilakukan pada data kognitif siswa. Hasil eksperimen menunjukkan pemilihan sistem yang tepat dapat memaksimalkan hasil penelitian ini, misalnya mentor, saran, nasehat dan pemilihan kursus dan sebagainya. Selain itu, sistem ini mampu memberikan nilai yang memperlihatkan probabilitas dari siswa untuk mencapai level yang paling bagus apabila siswa mengalami lemah di pelajaran tertentu.</p>	<ul style="list-style-type: none"> <li>- Identifikasi dilakukan pada ranah kognitif</li> <li>- Tidak melakukan transformasi data</li> <li>- Tidak menerapkan meta-algoritma</li> </ul>

Ranah kognitif	5.	I Nyoman S <i>et.al.</i> , “ <i>Intelligent Classification of Learner’s Cognitive Domain using Bayes Net, Naïve Bayes, and J48 Utilizing Bloom’s Taxonomy-based Serious Game</i> ”, 2015. (Nyoman Sukajaya, Ketut Eddy Purnama, & Purnomo, 2015)	Pada makalah ini, pemodelan siswa di domain kognitif dilakukan melalui media berupa permainan dengan konten matematika. Tantangan dalam permainan ini berupa soal matematika yang terdiri dari 9 soal. Soal disusun berdasarkan taksonomi bloom sehingga soal dibagi menjadi 3 level C1, C2 dan C3 (dari mudah menuju ke sulit). Klasifikasi dilakukan dengan menggunakan beberapa metode klasifikasi yaitu Bayes Net, Naïve Bayes dan J48 dengan akurasi sekitar 85%.	<ul style="list-style-type: none"> <li>- Identifikasi dilakukan pada ranah kognitif</li> <li>- Tidak melakukan transformasi data</li> <li>- Tidak menerapkan meta-algoritma</li> </ul>
	6.	“ <i>Application of Hierarchical Clustering Algorithm to Evaluate Students Performance of an Institute</i> ”. (Rana & Garg, 2016)	Makalah ini melakukan penerapan algoritma pengelompokan ( <i>clustering</i> ) untuk mengevaluasi kinerja siswa. Penerapan dilakukan pada data kognitif dari siswa. Kompleksnya data siswa menjadi dasar untuk menggali data dengan menggunakan metode atau algoritma pengelompokan ( <i>clustering</i> ).	<ul style="list-style-type: none"> <li>- Identifikasi dilakukan pada ranah kognitif</li> <li>- Tidak melakukan transformasi data</li> <li>- Tidak menerapkan meta-algoritma</li> </ul>



Ranah afektif	1.	Ibrahim, Yildirim, <i>“The Effects of Gamification-Based Teaching Practices on Student Achievement and Students’ Attitudes toward Lessons.” The Internet and Higher Education.</i> (Yildirim, 2017)	Makalah ini memfokuskan pada penelitian praktik pengajaran berbasis pada <i>gamification</i> untuk meningkatkan motivasi, prestasi belajar akademik, dan sikap terhadap matematika pada siswa. Pada saat eksperimen, siswa dibagi menjadi 2 grup: grup eksperimen dan grup kontrol. Untuk prestasi belajar akademik siswa, pengukurannya dilakukan dengan instrumen pra-tes dan pasca-tes. Sedangkan untuk sikap dan motivasi, pengukurannya dilakukan dengan menggunakan metode survey berupa angket. Hasil eksperimen menunjukkan siswa yang diajar dengan menggunakan pengajaran berbasis <i>gamification</i> memiliki prestasi belajar akademik yang lebih tinggi dibanding dengan yang tidak.	Identifikasi pada ranah afektif menggunakan metode survey-angket.
Ranah afektif	2.	Kebritchi, M. et.al, <i>“The effects of modern mathematics computer games on mathematics achievement and class motivation”</i> ,2010.	Penelitian ini memfokuskan pengaruh dari game komputer pada prestasi belajar siswa untuk pelajaran matematika dan juga pengaruh terhadap motivasi siswa. Partisipan, dalam hal ini siswa, dibagi dalam 2 grup yaitu: eksperimen dan kontrol. Berkaitan dengan pengaruh game komputer pada prestasi belajar siswa	Identifikasi pada ranah afektif menggunakan metode survey-angket.

		(Kebritchi, Hirumi, & Bai, 2010)	untuk ranah kognitif, analisa data dilakukan pada pra-tes dan pasca-tes. Sedangkan untuk ranah afektif, dalam hal ini motivasi, dilakukan dengan menggunakan teknik wawancara. Hasil eksperimen memperlihatkan bahwa prestasi belajar siswa yang menggunakan game computer lebih tinggi dibanding siswa yang tidak mempergunakan. Hal ini disebabkan siswa lebih termotivasi untuk belajar matematika ketika mereka belajar dengan menggunakan game.	
Ranah afektif	3.	Lucas M.Jeno <i>et.al.</i> , “ <i>The effect of a mobile-application tool on biology students’ motivation and achievement in species identification: A Self Determition Theory perspective</i> ”, 2017.(Jeno, Grytnes, & Vandvik, 2017)	Makalah ini mengusulkan media baru <i>berupa mobile-application tool</i> untuk mengidentifikasi species yang sebelumnya menggunakan <i>textbook</i> . Penggunaan tool ini ditujukan agar siswa mempunyai motivasi intrinsik, kompetensi yang dirasakan dan prestasi belajar yang lebih baik. Untuk motivasi intrinsik dan kompetensi yang dirasakan, instrumen yang digunakan berasal dari IMI ( <i>Intrinsic Motivation Inventory</i> ). Sedangkan prestasi belajar diukur dengan menggunakan tes yang terdiri dari 9 soal.	<ul style="list-style-type: none"> <li>- Identifikasi pada ranah kognitif dan afektif yang menggunakan metode survey-angket.</li> <li>- Ranah kognitif belum melakukan transformasi data dan menerapkan meta-algoritma.</li> </ul>

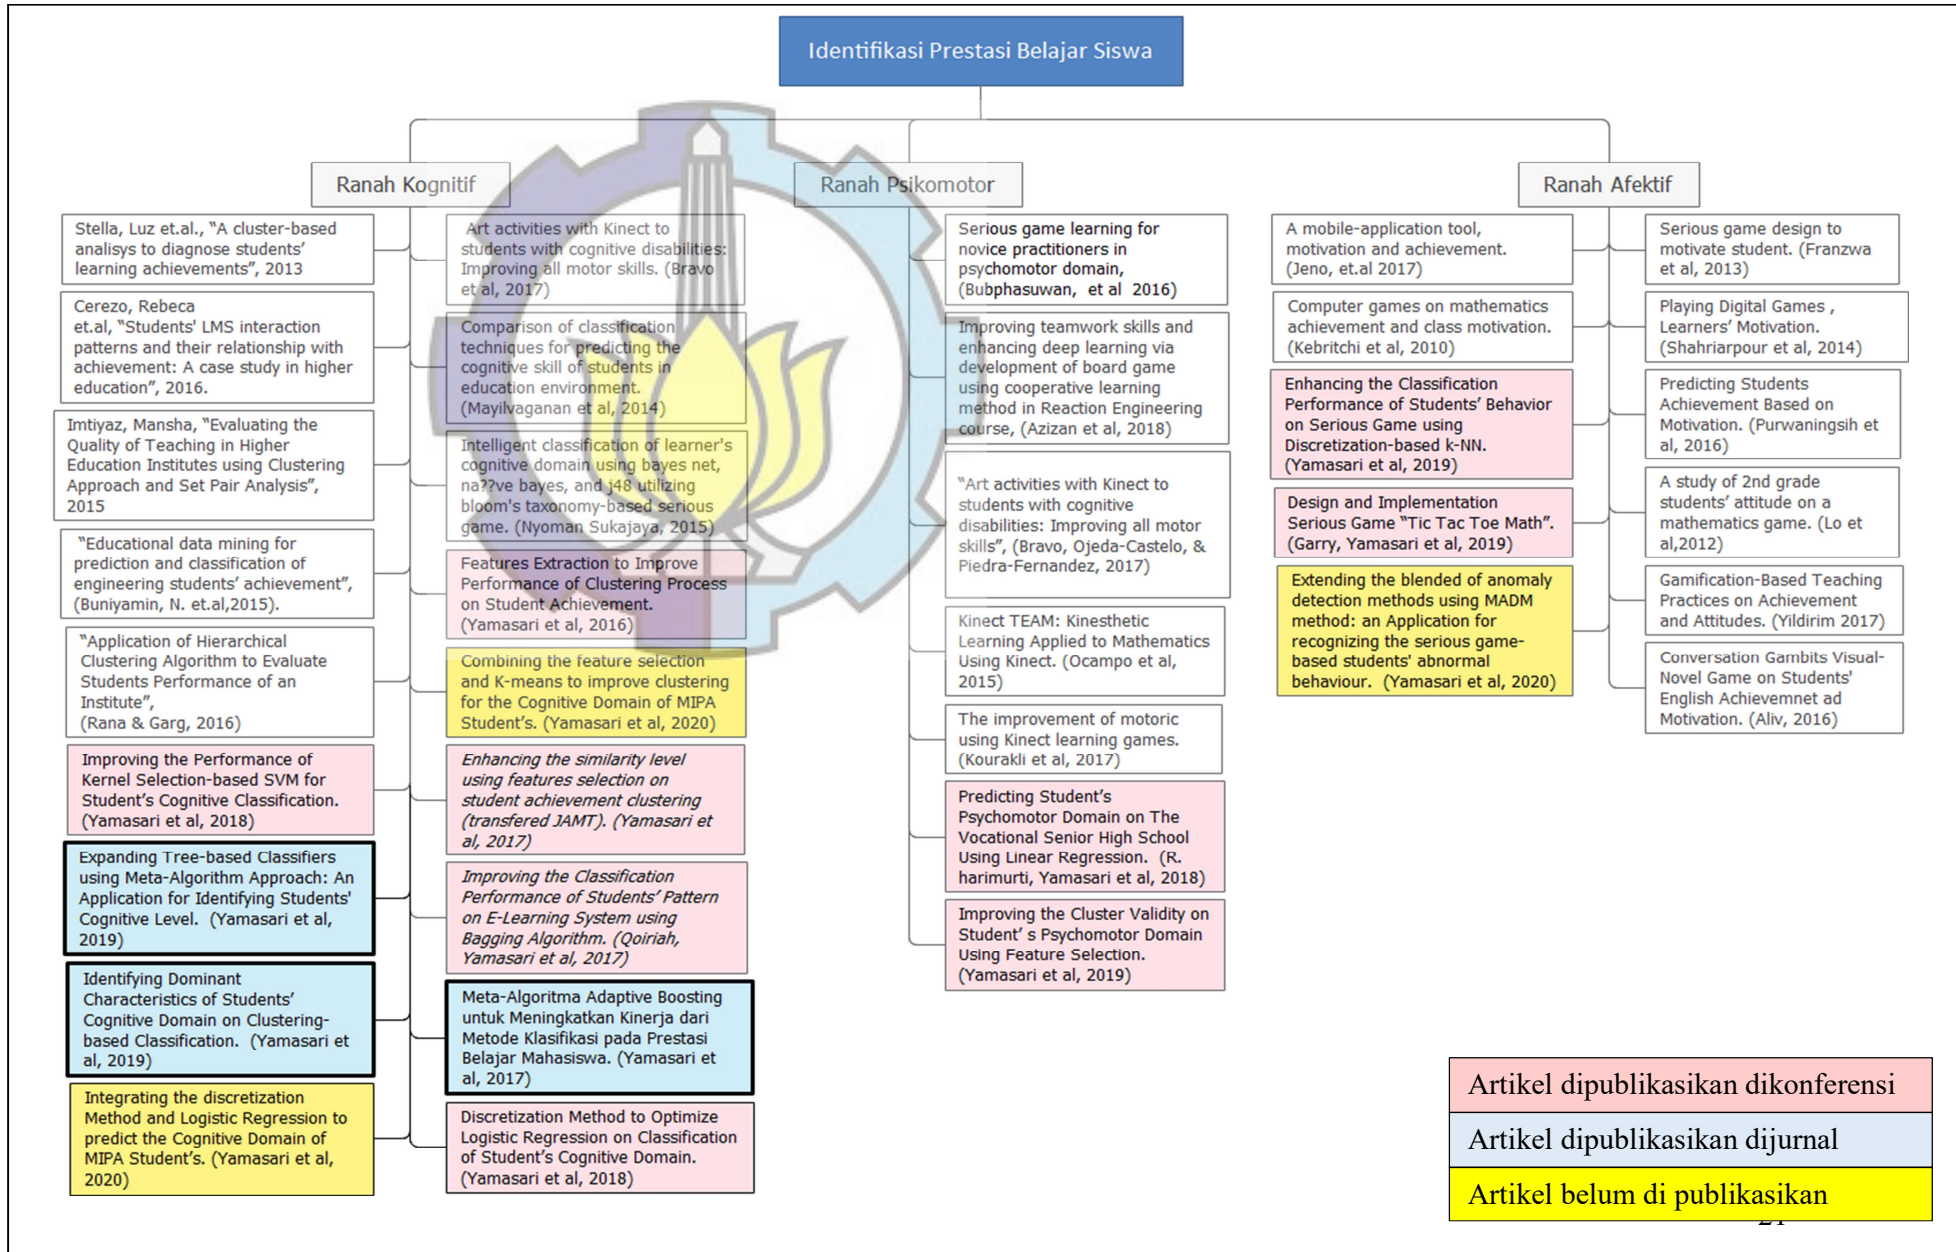
			Hasil penelitian merekomendasikan penggunaan tool aplikasi mobile untuk belajar tentang identifikasi spesies.	
Ranah afektif	4.	Shahriarpour, Nahid <i>et.al.</i> , “ <i>On the Effect of Playing Digital Games on Iranian Intermediate EFL Learners’ Motivation toward Learning English Vocabularies</i> ”, 2014.(Shahriarpour & kafi, 2014)	Penelitian ini memfokuskan pada peningkatan motivasi siswa ketika mereka belajar tentang kosakata-kosakata dalam Bahasa Inggris dengan menggunakan game digital. Peningkatan motivasi ini ditujukan untuk meningkatkan pembelajaran kosakata Inggris. Pengumpulan data dilakukan dengan wawancara dan teknik pengamatan. Dengan prosedur ini, motivasi dan ketertarikan siswa terhadap game digital untuk belajar kosakata Inggris ini dapat diketahui. Hasil penelitian menunjukkan siswa lebih termotivasi dalam belajar kosakata Inggris ini karena siswa merasa senang dan menikmati proses pembelajaran tersebut.	<ul style="list-style-type: none"> <li>- Identifikasi siswa pada aspek kognitif dan afektif.</li> <li>- Ranah kognitif belum melakukan transformasi data dan menerapkan meta-algoritma.</li> </ul>
Ranah afektif	5.	Aliv F.M, “ <i>The effects of Conversation Gambits Visual-Novel Game on Students’ English</i> ”	Makalah ini melakukan penelitian tentang penggunaan game <i>Conversation-Gambits Visual</i> dengan tujuan meningkatkan motivasi siswa dalam belajar Bahasa Inggris. Data hasil ujicoba diolah dengan menggunakan MANCOVA dan hasilnya menunjukkan	Identifikasi afeksi diperoleh dengan menggunakan angket.

		<i>Achievemnet and Motivation.</i> ”(M, 2016)	bahwa prestasi belajar siswa yang menggunakan game lebih tinggi dari siswa yang menggunakan buku. Hal ini disimpulkan bahwa siswa yang mempergunakan game lebih termotivasi. Untuk motivasi, data diperoleh dari siswa dengan pengisian angket.	
Ranah afektif	6.	<i>“Predicting Students Achievement Based on Motivation in Vocational School Using Data Mining Approach.”</i> .(Purwaningsih & Suwarno, 2016)	Makalah ini memfokuskan pada prediksi prestasi belajar siswa yang didasarkan pada motivasi mereka. Prediksi diperoleh dengan penerapan data mining khususnya klasifikasi terhadap data siswa dengan metode naïve bayes. Data siswa yang berkaitan aspek kognitif dikumpulkan dengan program tertentu sedangkan data siswa yang berkaitan dengan motivasi diperoleh dengan kuisisioner. Untuk klasifikasi, penelitian ini menggunakan 4 variabel yang terdiri dari 3 variabel yang menggambarkan kebutuhan siswa dan 1 variabel GPA sebagai indikator prestasi belajar akademik. Hasil uji coba menunjukkan bahwa variabel motivasi lebih akurat dalam memprediksi prestasi belajar siswa.	<ul style="list-style-type: none"> <li>- Pemodelan siswa pada aspek kognitif dan afektif.</li> <li>- Ranah kognitif belum melakukan transformasi data dan menerapkan meta-algoritma.</li> </ul>

Ranah afektif	7.	<p>J. J. Lo and F. M. Lin, “A study of 2nd grade students’ attitude on a mathematics game,” (Lo &amp; Lin, 2012)</p>	<p>Makalah ini membahas tentang penelitian sikap (<i>attitude</i>) pada game “Arithmetic Climbing”. Dalam game ini, pemain diminta untuk menghitung bilangan dalam sebuah mode yang strategi untuk memindahkan token-token mereka ketujuan secara lebih cepat dari lawannya. Sikap yang diteliti dibagi menjadi 2: sikap ke matematika dan sikap ke game. Untuk sikap ke matematika, sikap ini terdiri dari 3 variabel, yaitu: kognisi, afeksi dan perilaku. Sikap yang dilakukan dengan perancangan pra-tes dan pasca-tes. Untuk sikap ke game, sikap ini terdiri dari 4 variabel: pedagogi, game, himpunan dan sistem. Hasil uji coba memperlihatkan bahwa siswa mempunyai kognisi dan perilaku tinggi tetapi afeksi yang rendah pada matematika. Selanjutnya, ada perbedaan yang signifikan antara pra tes dan pasca tes untuk kognisi, afeksi dan perilaku. Untuk sikap yang berkaitan dengan game, hasil uji coba menunjukkan siswa mempunyai sikap yang positif terhadap game <i>Arithmetic Climbing</i>.</p>	<p>Pemodelan sikap dilakukan dengan kuisioner.</p>
---------------	----	--	---	--

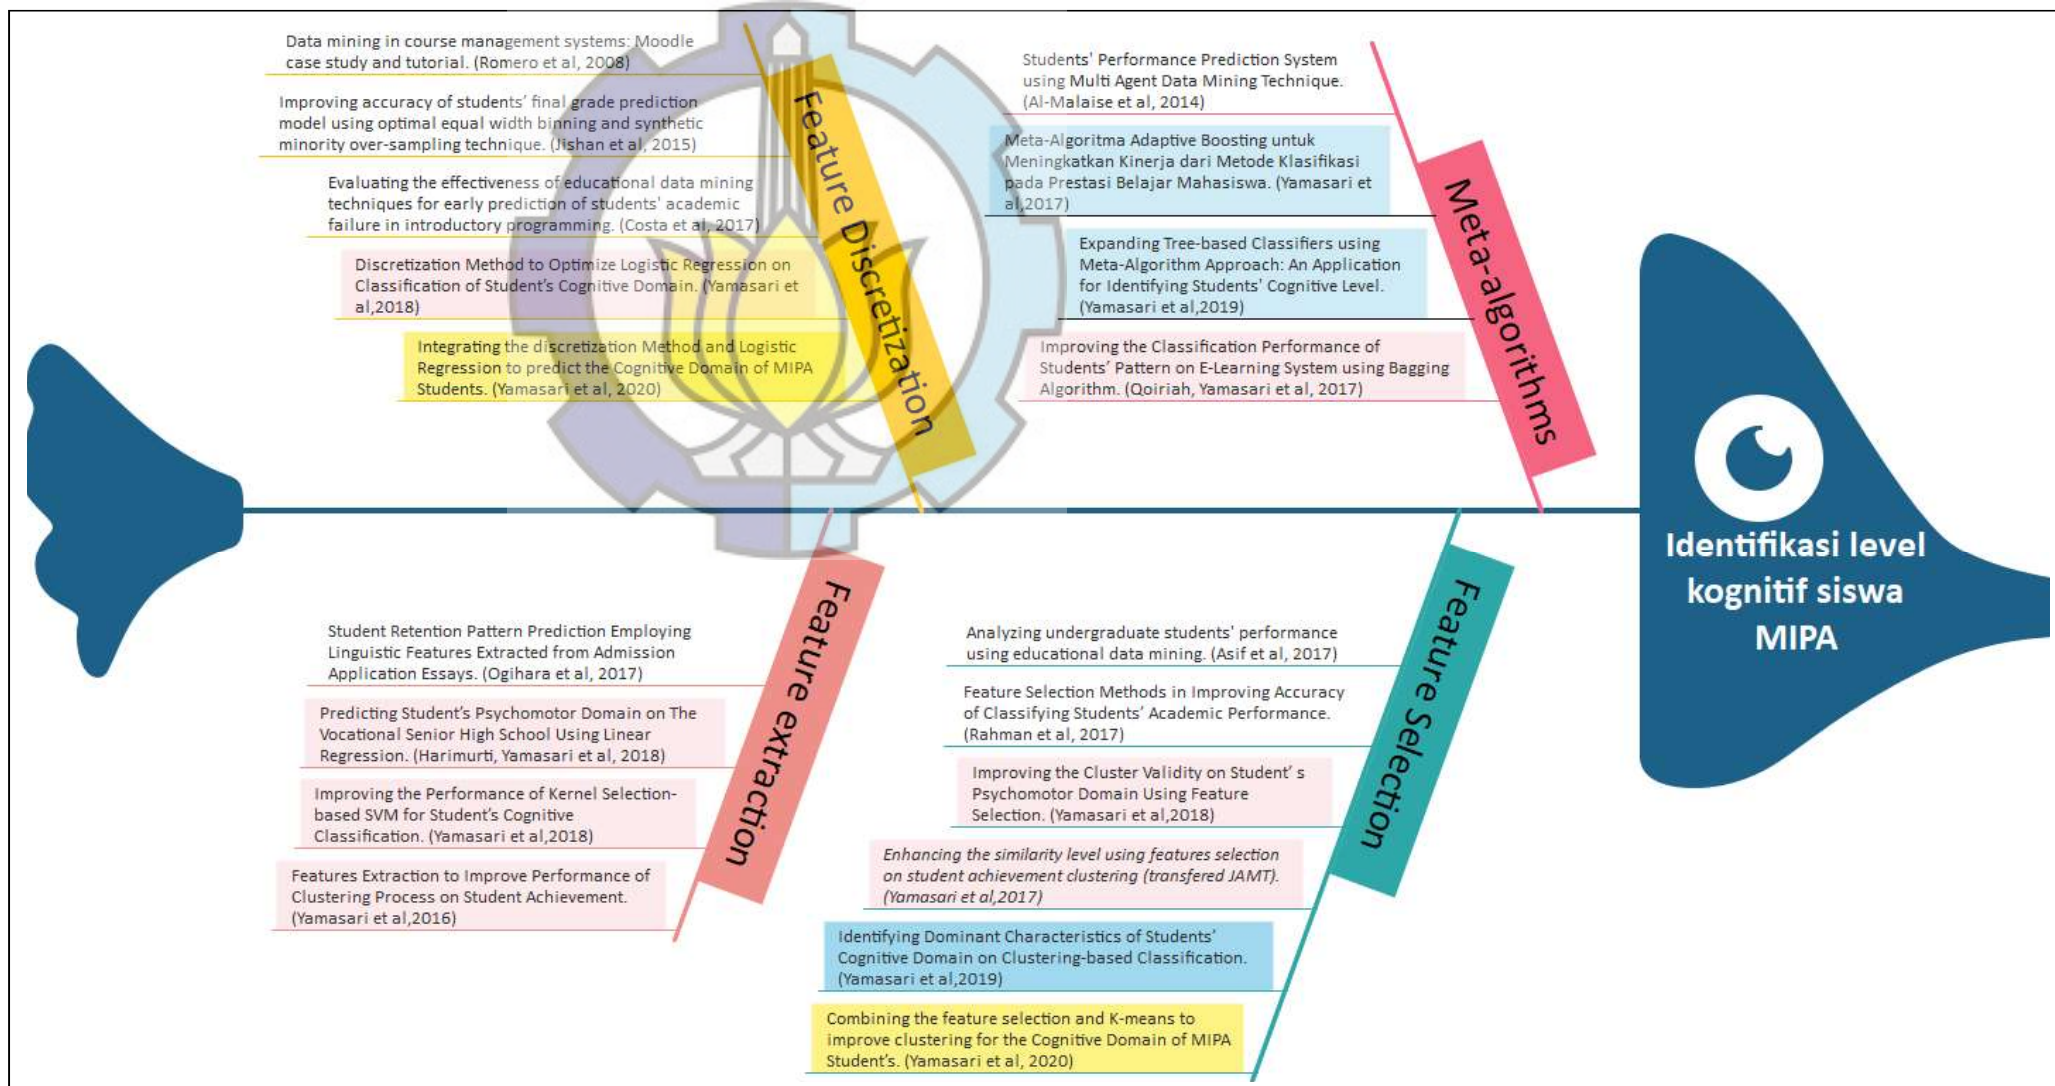
Ranah psikomotor	1.	<p><i>“Towards the improvement of the cognitive, motoric and academic skills of students with special educational needs using Kinect learning games,”</i>.(Kourakli et al., 2017)</p>	<p>Penelitian ini bertujuan untuk meningkatkan kognitif, motorik dan ketrampilan akademik untuk siswa berkebutuhan khusus menggunakan <i>Kinect learning games</i>. Untuk ranah motorik, aspek ini dinilai dari 2 sisi, yaitu: ketrampilan kinestetik dan kecepatan psikomotor. Ketrampilan kinestetik didefinisikan sebagai keterampilan yang bergantung pada indera untuk mendeteksi posisi, berat badan, gerakan otot dll, dan itu terlibat dalam proses pengendalian dan koordinasi gerakan tubuh, seperti berjalan, berbicara dan gerak tubuh. Sedangkan, kecepatan psikomotor didefinisikan sebagai kecepatan dan fleksibilitas gerakan tubuh yang dilakukan.</p>	<p>Penelitian ini membahas ranah psikomotor dari siswa.</p>
Ranah psikomotor	2.	<p><i>“Kinect TEAM: Kinesthetic Learning Applied to Mathematics Using Kinect”</i> (Ocampo Orona, Maldonado, Salinas</p>	<p>Penelitian ini mengembangkan perangkat pembelajaran yang melibatkan <i>augmented reality</i> dan <i>virtual reality</i> agar siswa lebih memahami dan mempelajari mata pelajaran kalkulus. Siswa bermain dengan karakter. Siswa berinteraksi secara visual dan menggunakan <i>gesture</i> dengan <i>graph</i> dari fungsi-fungsi variabel yang nyata. <i>Gesture</i> yang terjadi</p>	<p>Penelitian ini membahas ranah psikomotor dari siswa.</p>

		Martínez, & Ocampo, 2015)	menghasilkan representasi grafik dari gerakan dalam bentuk garis.	
Ranah psikomotor	3.	<i>“Art activities with Kinect to students with cognitive disabilities: Improving all motor skills”</i> , (Bravo, Ojeda-Castelo, & Piedra-Fernandez, 2017)	Penelitian ini menghadirkan sekumpulan aktivitas yang interaktif dengan berbasis pada <i>dance</i> dan musik dalam bentuk game. Aktivitas-aktivitas ini ditujukan untuk siswa yang mengalami disabilitas kognitif yang mempunyai kecenderungan menolak terapi-terapi rehabilitasi yang bersifat fisik. Hasil penelitian menunjukkan bahwa siswa lebih termotivasi untuk melakukan terapis dengan adanya game ini.	Penelitian ini membahas ranah psikomotor dari siswa.



Gambar 1.1 Peta jalan dari penelitian disertasi





Gambar 1.2 Fishbone dari Penelitian Disertasi

## 1.6. Ruang lingkup dan batasan penelitian

Penelitian ini menggunakan data primer siswa yang diambil dengan 2 perangkat pembelajaran berbasis TIK yang telah terbangun, yaitu serious game BoTySeGa yang dikembangkan oleh Nyoman Sukajaya dkk dan sistem e-Learning SMKN Surabaya.

Penelitian ini menggunakan istilah level kognitif pada data siswa primernya dengan istilah *good*, *fair* dan *poor*.

Penelitian ini hanya menghadirkan model dari identifikasi level kognitif siswa MIPA.

## 1.7. Struktur penulisan

Disertasi ini terdiri dari 7 Bab. Bab pertama mendeskripsikan latar belakang mengapa penelitian ini penting dilakukan, perumusan masalah penelitian, tujuan yang hendak dicapai dan manfaat yang diharapkan dari pelaksanaan penelitian, kontribusi dan orisinalitas penelitian, peta alur penelitian, dan sistematika penulisan buku disertasi. Bab kedua membahas tentang dasar teori, yaitu: transformasi data dan meta-algoritma. Bab ketiga membahas tentang pengembangan perangkat pembelajaran berbasis TIK yang efektif. Bab keempat menjelaskan tentang proses pengumpulan data siswa dan deskripsi data ranah kognitif siswa MIPA. Bab kelima menguraikan tentang peningkatan kinerja pemodelan ranah kognitif siswa MIPA menggunakan transformasi data. Bab keenam membahas tentang metoda hibrida dari transformasi data dan LogitBoost untuk identifikasi level kognitif siswa MIPA. Terakhir, Bab ketujuh menguraikan tentang kesimpulan dan penelitian lanjutan.

- Halaman ini sengaja dibiarkan kosong -



## **BAB 2**

### **TRANSFORMASI DATA DAN META-ALGORITMA**

Bab ini menjelaskan tentang metode-metode yang berkaitan dengan transformasi data dan meta-algoritma. Metode-metode ini diterapkan dengan tujuan untuk meningkatkan kinerja suatu model atau sistem baik itu yang berkaitan dengan waktu, biaya maupun kualitas.

#### **2.1. Transformasi data**

##### **2.1.1. Metode normalisasi**

Satuan ukuran yang digunakan dapat berpengaruh terhadap analisis data. Perubahan satuan ukuran menyebabkan hasil yang sangat berbeda, contoh: perubahan ukuran dari meter ke inci untuk ukuran tinggi atau dari kilogram ke pound untuk ukuran berat. Secara umum, ekspresi sebuah atribut dalam satuan yang lebih kecil akan menyebabkan range yang lebih besar untuk atribut tersebut dan hal ini cenderung memberikan efek yang lebih besar. Ketergantungan pada satuan ukuran yang dipilih dapat dihindari dengan melakukan normalisasi atau standarisasi. Hal ini melibatkan transformasi dari data dalam range yang lebih kecil yaitu  $[-1,1]$  atau  $[0.0, 1.0]$ . Normalisasi data ini mencoba untuk memberikan semua atribut dengan bobot yang sama.

Normalisasi juga dapat didefinisikan sebagai transformasi variabel yang diterapkan pada semua nilai variabel. Dengan kata lain, untuk masing-masing obyek, transformasi diterapkan pada nilai dari variabel pada obyek tersebut. Dalam komunitas data mining, istilah normalisasi sering digunakan bergantian dengan istilah standarisasi. Normalisasi merupakan transformasi yang digunakan untuk membuat kenormalan dari variabel, misalnya: Gaussian. Transformasi ini membentuk variabel baru yang mempunyai mean 0 dan standar deviasi 1. Salah satu formula yang dipergunakan untuk normalisasi adalah Z-Score dengan rumus seperti dalam persamaan (2.1):

$$x' = \frac{x - Mean}{SD} \quad (2.1)$$

Dimana:  $x$ , Mean dan SD adalah nilai fitur original, rata-rata dari nilai fitur dan standar deviasi. Normalisasi secara khusus bermanfaat untuk algoritma klasifikasi yang melibatkan pengukuran jarak seperti klasifikasi atau kluster yang berbasis pada *nearest-neighbor*. Normalisasi memberikan manfaat dalam mempercepat *learning phase* ketika tiap atribut diukur dalam *tuple training*. Untuk metode-metode berbasis jarak, normalisasi membantu mencegah atribut dengan range inisial yang besar.

### 2.1.2. Metode diskritisasi tanpa pengawasan

Dougherty, Kohavi, dan Sahami (Dougherty, Kohavi, & Sahami, 1995) mendefinisikan 3 kategori tentang metode diskritisasi yaitu: diawasi versus tidak diawasi, global versus lokal, statis versus dinamis. Sementara, penggolongan lain mendefinisikan ada dua pendekatan dasar untuk masalah diskritisasi yaitu: diskritisasi tanpa pengawasan dan dengan pengawasan (Witten, Frank, & Hall, 2011).

Secara umum, diskritisasi terbaik bergantung pada algoritma yang digunakan dan fitur yang didiskritisasi. Diskritisasi merupakan transformasi dari fitur kontinu ke fitur kategorikal yang melibatkan dua langkah, yaitu: memutuskan berapa banyak kategori dan menetapkan bagaimana memetakan nilai kontinu ke kategori-kategori tersebut. Pada **langkah pertama**, setelah nilai fitur kontinu diurutkan, nilai tersebut dibagi kedalam  $n$  interval dengan menetapkan  $n-1$  *split point*. **Langkah kedua** adalah semua nilai satu interval dipetakan ke nilai kategori yang sama. Oleh karena itu, permasalahan diskritisasi adalah memutuskan berapa banyak *split point* dan dimana saja tempat *split point* tersebut. Perbedaan mendasar dari metode-metode diskritisasi adalah dipergunakan atau tidaknya informasi kelas. Apabila informasi kelas dipergunakan dalam proses diskritisasi maka disebut sebagai diskritisasi yang diawasi (*supervised discretization*). Sedangkan, apabila informasi kelas tidak dipergunakan maka diskritisasi disebut sebagai diskritisasi tanpa pengawasan (*unsupervised discretization*). Pada metode diskritisasi tanpa pengawasan, ada 2 pendekatan sederhana yang umum diterapkan yaitu:

1. Pendekatan *equal-width*

Algoritma ini membagi data ke dalam k-interval dengan ukuran yang sama. Pembagian rentang antara nilai terkecil dan terbesar diamati secara merata. Dimana,  $w$  = lebar interval (*width*),  $k$  = jumlah interval yang dapat diatur secara manual. Rumus pendekatan ini dinyatakan dalam persamaan (2.2):

$$w = \frac{(value_{max} - value_{min})}{k} \quad (2.2)$$

Untuk batasan rentang atau *threshold* pada  $value_{min} + iw$ , dimana,  $i = 1, \dots, k-1$ , masing-masing rentang dapat didefinisikan sebagai berikut:

$$value_{min} + w, value_{min} + 2w, \dots, value_{min} + (k-1)w \quad (2.3)$$

## 2. Pendekatan *equal-frequency*

Algoritma membagi data menjadi k-interval yang masing-masing interval berisi perkiraan jumlah nilai yang sama.

### 2.1.3. Metode ekstraksi fitur

Saat ini, fitur dari data set seringkali berjumlah ratusan hingga ribuan. Ekstraksi fitur bertujuan untuk mengurangi jumlah fitur dalam dataset dengan membuat fitur baru dari yang sudah ada. Set fitur yang diperkecil ini seharusnya dapat merangkum sebagian besar informasi yang terkandung dalam set fitur asli. Dengan cara ini, versi ringkasan dari fitur asli dapat dibuat dari kombinasi set aslinya. Ekstraksi fitur ini merupakan salah satu dari metode yang berkaitan dengan pembentukan fitur. Ekstraksi fitur merupakan pembentukan sekumpulan fitur baru dari data mentah asli. Sekumpulan fitur ini mengambil informasi penting dari data set agar lebih efektif. Jumlah fitur baru ini bisa lebih sedikit dari fitur aslinya.

Ekstraksi fitur adalah proses pengurangan dimensionalitas dimana set awal data mentah direduksi menjadi kelompok yang lebih mudah dikelola untuk diproses. Karakteristik dari kumpulan data besar ini adalah sejumlah besar variabel yang membutuhkan banyak sumber daya komputasi untuk diproses. Ekstraksi fitur adalah nama untuk metode yang menggabungkan fitur, secara efektif mengurangi jumlah data yang harus diproses, sementara masih secara akurat dan lengkap menggambarkan kumpulan data asli.

Ekstraksi fitur juga dapat mengurangi jumlah data yang berlebihan untuk analisis yang diberikan. Juga, pengurangan data dan upaya mesin dalam membangun kombinasi fitur memfasilitasi kecepatan pembelajaran dan langkah-langkah generalisasi dalam proses pembelajaran mesin. Dalam EDM, penelitian yang memfokuskan pada ekstraksi ini hanya sedikit, yaitu: (Zhou, Chen, Chen, Zhang, & Li, 2016) mengekstrak fitur-fitur penting untuk meningkatkan kinerja pengklasteran. Kemudian, (Bharti & Singh, 2015) mengurangi dimensi dengan mengintegrasikan pemilihan fitur dan ekstraksi fitur.

#### 2.1.4. Metode pemilihan fitur


Pada dasarnya ada dua kategori metode pemilihan fitur, yaitu: pendekatan berbasis *wrapper* dan berbasis *filter* yang diperlihatkan pada Gambar 2.1 (Punlumjeak & Rachburee, 2015). Pemilihan *subset* berbasis wrapper (WBSE=*wrapper-based subset evaluation*) dibangun oleh *classifier* untuk memperkirakan nilai setiap *subset* fitur. Berikutnya, evaluasi *subset* berbasis *Filter* (FBSE=*filter-based subset evaluation*) ditujukan untuk menyelesaikan masalah fitur redundansi (Solorio-Fernández, Carrasco-Ochoa, & Martínez-Trinidad, 2016). Pembahasan sub bab ini memfokuskan pada FSBE karena pemilihan fitur pada disertasi ini menerapkan metode-metode kategori ini. FBSE mengevaluasi seluruh *subset* dengan cara multivariat, menghilangkan fitur yang tidak relevan dan mengeksplorasi derajat hubungan di antara fitur-fitur tersebut. FBSE adalah metode yang didasarkan pada heuristik yang mengeksploitasi langkah-langkah statistik dan probabilitas untuk mencari dan mengevaluasi utilitas semua fitur yang telah diketahui. FBSE mengeksplorasi langkah-langkah jarak dan fungsi korelasi untuk memilih kriteria filter (Pang et al., 2006).

Berkaitan dengan pemilihan fitur di bidang pendidikan, banyak peneliti mengeksplorasi metode ini untuk kinerja yang lebih baik dalam data mining. Deepika dkk. (Deepika & Sathyanarayana, 2019) mengusulkan metode pemilihan fitur yang memadukan Relief-F dan Budget Tree-Random Forest untuk meningkatkan kinerja prediksi dari akademik siswa. Penelitian lain mengeksplorasi metode pemilihan fitur yang terdiri dari FBSE (gain informasi, algoritma genetika,

dan redundansi minimum dan relevansi maksimum-MRMR) dan WBSE (SVM)(Rachburee & Punlumjeak, 2015). Untuk mengevaluasi metode ini, mereka menerapkan empat pengklasifikasi: Naïve bayes, Decision tree, k-Nearest Neighbour (k-NN) dan jaringan saraf. Kinerja tertinggi dicapai oleh kombinasi MRMR dan k-NN. Kemudian, penelitian (Zaffar et al., 2017) mengusulkan metode FBSE yang terdiri dari CfsSubsetEval, ChiSquaredAttributeEval dan dievaluasi oleh 14 pengklasifikasi dan kemudian hasilnya saling dibandingkan. Hasil terbaik dicapai oleh kombinasi random forest dan komponen utama. Penelitian lainnya dilakukan oleh (Pong-Inwong & Kaewmak, 2016). Mereka menggunakan metode FBSE untuk memilih fitur, yaitu: Chi-Square, untuk meningkatkan sentimen analisis pada evaluasi pengajaran. Hasil percobaan menunjukkan bahwa kombinasi metode Chi-Square dan metode *ensemble* sangat efisien. Penelitian yang dilakukan oleh (Y. Yamasari, Nugroho, Harimurti, & Purnomo, 2018) memfokuskan peningkatan kinerja pada pemetaan domain psikomotorik siswa dengan seleksi fitur ini sehingga siswa yang memiliki karakteristik serupa dari domain psikomotorik berada dalam kelompok yang sama. Kemudian, (Rahman, Setiawan, & Permasari, 2017) menerapkan metode ini untuk meningkatkan kinerja klasifikasi, dalam hal akurasi. (Sasi Regha, Uma, & Associate, 2016) mengoptimalkan proses klasifikasi pada kinerja siswa menggunakan metode yang sama.

Pemilihan fitur yang diterapkan dalam EDM diusulkan untuk mengembangkan sistem yang lebih efektif dan efisien. Metode pemilihan fitur yang diusulkan oleh Liang et al (Liang, Liu, Li, He, & Xu, 2016) diimplementasikan untuk meningkatkan efisiensi dan mengurangi biaya proses Klaster. Dengan berfokus pada peningkatan akurasi, (Anusha & Sathiaselan, 2015) juga melakukan proses pemilihan fitur. Apabila dikaji lebih mendalam pada penelitian sebelumnya, metode yang paling banyak dieksplorasi didasarkan pada filter. Hal ini akibat metode lain berdasarkan *wrapper* mengkonsumsi waktu yang lebih banyak walaupun menghasilkan sistem yang lebih akurat.





Gambar 2.1 *Filter-based subset evaluation* (FSBE) (Hall, 1999)

### Gini Index

Gini Index merupakan salah satu kriteria pemilihan fitur selain Gain Informasi dan Rasio Gain. Jika kelas *instance* dinyatakan dengan  $k$ ,  $k=1,2,\dots,C$ , dimana  $C$  adalah jumlah kelas untuk variabel atau *output dependent*  $y$ . Gini Index untuk suatu cabang dihitung dengan persamaan (2.4):

$$IG(B) = 1 - \sum_{k=1}^c p_k^2 \quad (2.4)$$

Dimana,  $p_k$  = rasio observasi dalam cabang  $B$  yang masuk dalam kelas  $k$ . Jika  $IG(B) = 0$  berarti semua data pada cabang  $B$  berasal dari kelas yang sama. Nilai  $IG(B)$  mencapai maksimum jika dalam kelas  $k$  proporsi data dari masing-masing kelas yang ada mencapai nilai yang sama.

### CFS

*Correlation-based Feature Selection* (CFS) merupakan algoritma *filter* sederhana yang meranking *subset* fitur menurut fungsi evaluasi heuristik berbasis korelasi. Bias dari fungsi evaluasi adalah ke arah himpunan bagian yang berisi fitur yang sangat berkorelasi dengan kelas dan tidak berkorelasi satu sama lain. Fitur-fitur yang tidak relevan diabaikan karena fitur-fitur ini mempunyai korelasi yang rendah dengan kelas. Fitur-fitur yang mubazir harus disaring karena fitur-fitur ini

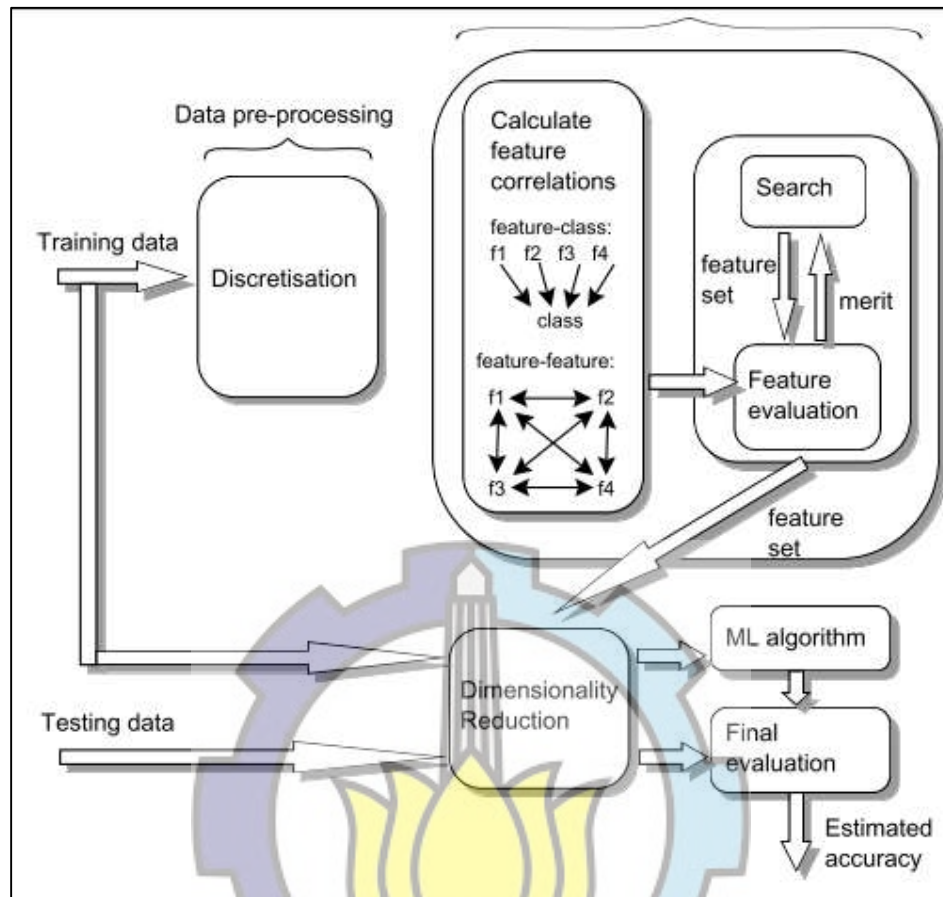
akan sangat berkorelasi dengan satu atau lebih dari fitur yang tersisa. Penerimaan fitur akan tergantung pada sejauh mana ia memprediksi kelas-kelas di area ruang *instance* yang belum diprediksi oleh fitur lain. Fungsi evaluasi subset fitur CFS disajikan pada persamaan 2.5 dengan rumus sebagai berikut:

$$MS = k\bar{r}_{cf} / \sqrt{k + k(k-1)\bar{r}_{ff}} \quad (2.5)$$

di mana MS adalah "merit" heuristik dari subset fitur S yang berisi fitur k,  $r_{cf}$  adalah korelasi fitur-kelas rata-rata ( $f \in S$ ), dan  $r_{ff}$  adalah rata-rata fitur antar-korelasi. Pembilang Persamaan (2.5) dapat dianggap memberikan indikasi tentang bagaimana prediksi kelas sekumpulan fitur; penyebut berapa banyak redundansi yang ada di antara fitur-fiturnya. Persamaan (2.5) membentuk inti dari CFS dan memaksakan peringkat pada subset fitur di ruang pencarian semua subset fitur yang mungkin. Berkaitan dengan strategi evaluasi, menurut (Langley & Langley, 1994), algoritma pemilihan fitur ini berbasis pada pencarian. Dimana, salah satu implementasi CFS yang digunakan yaitu strategi pencarian heuristik *best first*.

1. Begin with the OPEN list containing the start state, the CLOSED list empty, and BEST ← start state.
2. Let  $s = \arg \max e(x)$  (get the state from OPEN with the highest evaluation).
3. Remove  $s$  from OPEN and add to CLOSED.
4. If  $e(s) \geq e(\text{BEST})$ , then  $\text{BEST} \leftarrow s$ .
5. For each child  $t$  of  $s$  that is not in the OPEN or CLOSED list, evaluate and add to OPEN.
6. If BEST changed in the last set of expansions, goto 2.
7. Return BEST.

Gambar 2.2 Algoritma pencarian *Best first* (Hall, 1999)



Gambar 2.3 Tahapan dari CFS. (Hall, 1999)

*Best first* dapat dimulai dengan tanpa fitur atau semua fitur. Jika dimulai dengan tanpa fitur, pencarian berlangsung maju melalui ruang pencarian yang menambahkan fitur tunggal. Sedangkan, jika diawali semua fitur, pencarian bergerak mundur melalui ruang pencarian dengan menghapus fitur tunggal. Untuk mencegah pencarian pertama yang terbaik dari menjelajahi seluruh ruang pencarian *subset* fitur, kriteria penghentian diberlakukan. Pencarian akan berakhir jika lima himpunan bagian berturut-turut yang diperluas tidak menunjukkan peningkatan atas *subset* terbaik saat ini. *Pseudo code* dari algoritma *Best first* disajikan pada Gambar 2.2.

Sementara itu, Gambar 2.3 menunjukkan tahapan dari algoritma CFS dan bagaimana itu digunakan bersama dengan skema pembelajaran mesin. Salinan data pelatihan pertama kali didiskritisasi menggunakan metode (Fayyad & Irani, 1993),

kemudian diteruskan ke CFS. CFS menghitung korelasi fitur-kelas dan kemudian mencari ruang subset fitur. *Subset* dengan nilai tertinggi (yang diukur dengan Persamaan (2.5) yang ditemukan selama pencarian digunakan untuk mengurangi dimensi dari kedua data pelatihan asli dan data pengujian. Kedua kumpulan data yang berkurang kemudian dapat diteruskan ke skema pembelajaran mesin untuk pelatihan dan pengujian.

### Relief

(Kira & Rendell, 1992) menjelaskan suatu algoritma yang disebut RELIEF yang menggunakan pembelajaran berbasis instance untuk menetapkan bobot relevansi untuk setiap fitur. Setiap bobot fitur mencerminkan kemampuannya untuk membedakan antara nilai-nilai kelas. Fitur diberi peringkat berdasarkan berat dan yang melebihi ambang yang ditentukan pengguna dipilih untuk membentuk subset terakhir. Algoritma ini bekerja dengan mengambil contoh secara acak dari data pelatihan. Untuk setiap *instance* sampel, *instance* terdekat dari kelas yang sama (hit terdekat) dan kelas berlawanan (miss terdekat) ditemukan. Bobot fitur diperbarui menurut seberapa baik nilainya membedakan contoh yang diambil dari hit terdekat dan miss terdekat. Fitur akan menerima bobot tinggi jika ia membedakan antara instance dari kelas yang berbeda dan memiliki nilai yang sama untuk instance dari kelas yang sama. Persamaan (2.6) menunjukkan rumus pembaruan bobot yang digunakan:

$$W_x = W_x - \frac{\text{diff}(X, R, H)^2}{m} + \frac{\text{diff}(X, R, M)^2}{m} \quad (2.6)$$

Dimana,  $W_x$  adalah bobot fitur X, R adalah *instance* yang di sampling secara random, H adalah *hit* terdekat, M adalah *miss* yang terdekat dan m adalah banyaknya *instance* yang di sampling secara random. Fungsi *diff* mengkalkulasi perbedaan diantara 2 *instance* untuk fitur yang diberikan.

## 2.2. Meta algoritma Logistic Boosting (LogitBoost)

Algoritma yang mengeksploitasi algoritma lain sebagai perwakilan, dan yang memiliki sub-algoritma, dimana parameternya dapat diganti, didefinisikan sebagai meta-algoritma. *Boosting*, *simulated annealing*, *bootstrap aggregating*, *AdaBoost*, dan *random-restart hill climbing* merupakan contoh dari meta-algoritma ini.

*Boosting* sendiri merupakan salah satu dari meta-algoritma *ensemble* yang berguna dalam mereduksi bias dan juga variance (Breiman, 2001). Dalam *machine learning*, *boosting* ini melakukan *supervised learning*. Teori *boosting* dikenalkan berdasarkan pertanyaan yang diajukan oleh Kearns (1988): Dapatkah sekumpulan *weak learner* menciptakan satu kesatuan *strong learner*? *Weak learner* adalah *classifier* yang hanya memiliki sedikit korelasi dengan klasifikasi yang sebenarnya. Sementara, *strong learner* adalah *classifier* yang memiliki korelasi kuat dengan klasifikasi yang sebenarnya. Secara umum, *boosting* terjadi dalam iterasi, secara *incremental* menambahkan *weak learner* ke dalam satu *strong learner*. Pada setiap iterasi, satu *weak learner* belajar dari suatu data latihan. Kemudian, *weak learner* itu ditambahkan ke dalam *strong learner*. Setelah *weak learner* ditambahkan, data-data kemudian diubah masing-masing bobotnya. Data-data yang mengalami kesalahan klasifikasi akan mengalami penambahan bobot, dan data-data yang terklasifikasi dengan benar akan mengalami pengurangan bobot. Oleh karena itu, *weak learner* pada iterasi selanjutnya akan lebih terfokus pada data-data yang mengalami kesalahan klasifikasi oleh *weak learner* yang sebelumnya.

Ketika *boosting* pertama kali muncul, hal itu memicu para peneliti untuk meningkatkan kinerja algoritma yang *weak learner*. Ahli statistik menemukan bahwa algoritma itu bisa disusun kembali sebagai algoritma *greedy* untuk dipasangkan dengan model aditif. Model aditif memiliki sejarah panjang dalam statistik. Secara umum, istilah ini merujuk pada cara apa pun untuk menghasilkan prediksi dengan merangkum kontribusi yang diperoleh dari model lain. Sebagian besar algoritma pembelajaran untuk model aditif tidak membangun model dasar secara independen tetapi memastikan bahwa mereka saling melengkapi satu sama lain dan mencoba untuk membentuk *ensemble* dari model dasar yang

mengoptimalkan kinerja prediksi sesuai dengan kriteria tertentu. *Boosting* menerapkan pemodelan aditif *stagewise* maju. Kelas algoritma ini dimulai dengan *ensemble* kosong dan menggabungkan anggota baru secara berurutan. Pada setiap tahap, model yang memaksimalkan kinerja prediktif dari *ensemble* secara keseluruhan ditambahkan, tanpa mengubah yang sudah ada dalam *ensemble*. Mengoptimalkan kinerja *ensemble* menyiratkan bahwa model berikutnya harus fokus pada *instance* latih yang kinerjanya rendah. Inilah yang *boosting* kerjakan untuk memberikan *instance-instance* bobot yang lebih besar.

Metode pemodelan aditif *stagewise* maju yang terkenal untuk prediksi numeric adalah regresi. Pertama, buat model regresi standar, misalnya, pohon regresi. Kesalahan yang ditunjukkan pada data pelatihan, perbedaan antara nilai yang diprediksi dan yang diamati disebut residual. Kemudian perbaiki kesalahan ini dengan mempelajari model kedua, mungkin pohon regresi lain yang mencoba memprediksi residu yang diamati. Untuk melakukan ini, cukup ganti nilai-nilai kelas asli dengan residu mereka sebelum mempelajari model kedua. Menambahkan prediksi yang dibuat oleh model kedua ke yang pertama secara otomatis menghasilkan kesalahan yang lebih rendah pada data pelatihan. Biasanya, beberapa residu masih tersisa karena model kedua bukan yang sempurna, jadi melanjutkan dengan model ketiga yang belajar untuk memprediksi residu residu, dan seterusnya. Jika masing-masing model meminimalkan kesalahan kuadrat prediksi, seperti yang dilakukan model regresi linier, algoritma ini meminimalkan kesalahan kuadrat dari *ensemble* secara keseluruhan. Dalam praktiknya, ini juga bekerja dengan baik ketika *base learner* menggunakan pendekatan heuristik sebagai gantinya, seperti regresi dan model tree.

Salah satu metode *boosting* yang menerapkan regresi logistik aditif adalah LogitBoost. Dimisalkan bahwa setiap iterasi algoritma *boosting* cocok dengan fungsi regresi sederhana dengan melalui semua atribut, kemudian menemukan fungsi regresi sederhana dengan kesalahan terkecil, dan menambahkannya ke dalam model aditif. Jika algoritma LogitBoost dijalankan hingga konvergensi, hasilnya adalah maksimum-kemungkinan, model regresi multi-logistik. Namun, untuk kinerja optimal pada data selanjutnya, biasanya tidak perlu menunggu konvergensi. Jumlah iterasi *boosting* yang tepat dapat ditentukan dengan

memperkirakan kinerja yang diharapkan untuk sejumlah iterasi menggunakan *cross-validation* dan menghentikan proses ketika kinerja berhenti meningkat. Pengembangan sederhana dari algoritma ini mengarah ke pohon model logistik. Proses peningkatan berakhir ketika tidak ada struktur lebih lanjut dalam data yang dapat dimodelkan menggunakan fungsi regresi linier-logistik. Namun, mungkin masih ada struktur yang model linier dapat ditampung jika perhatian terbatas pada himpunan bagian data, diperoleh, misalnya, dengan memisahkan data menggunakan kriteria standar Decision Tree seperti gain informasi. Kemudian, setelah tidak ada perbaikan lebih lanjut dapat diperoleh dengan menambahkan model linier yang lebih sederhana, data dibagi dan dilanjutkan secara terpisah di setiap *subset*. Proses ini mengambil model logistik yang dihasilkan sejauh ini dan memurnikannya secara terpisah untuk data di setiap subset. Sekali lagi, validasi silang dijalankan di setiap *subset* untuk menentukan jumlah iterasi yang tepat untuk dilakukan dalam *subset* itu.

Regresi aditif juga dapat diterapkan pada klasifikasi seperti halnya regresi linier. Tetapi, regresi logistik lebih cocok daripada regresi linier untuk klasifikasi. Ternyata adaptasi serupa dapat dibuat untuk model aditif dengan memodifikasi metode pemodelan *stagewise* maju untuk melakukan regresi logistik aditif. Gunakan transformasi logit untuk menerjemahkan masalah estimasi probabilitas menjadi masalah regresi dan selesaikan tugas regresi menggunakan *ensemble* model, misalnya, pohon regresi, seperti halnya regresi aditif. Pada setiap tahap, tambahkan model yang memaksimalkan probabilitas data yang diberikan penggolong *ensemble*.

*Simple Logistic* membuat model regresi logistik menggunakan LogitBoost dengan fungsi regresi sederhana sebagai *base learner* dan menentukan berapa banyak iterasi yang harus dilakukan dengan menggunakan validasi silang, yang mendukung pemilihan atribut otomatis (Landwehr, Hall, & Frank, 2005). Logistik adalah implementasi alternatif untuk membangun dan menggunakan model regresi logistik multinomial. Untuk  $m$  input fitur dan  $k$  kelas, probabilitas prediksi untuk kelas  $j$  didefinisikan dalam persamaan (3.1):

$$p[j | a_1, a_2, \dots, a_m] = \frac{\exp(w_0^j + w_1^j a_1 + w_2^j a_2 + \dots + w_m^j a_m)}{1 + \sum_{j=1}^{k-1} \exp(w_0^j + w_1^j a_1 + w_2^j a_2 + \dots + w_m^j a_m)} \quad (3.1)$$

Dimana,  $w_0^j$  adalah istilah intercept untuk kelas j. Probabilitas dari kelas terakhir k diberikan dengan persamaan (3.2),

$$1 - \sum_{j=1}^{k-1} P[j | a_1, a_2, \dots, a_m] \quad (3.2)$$

LogitBoost terlihat sangat berbeda dari AdaBoost, tetapi prediktor yang mereka hasilkan berbeda terutama karena yang pertama mengoptimalkan kemungkinan secara langsung. Sedangkan yang kedua mengoptimalkan fungsi kerugian eksponensial yang dapat dianggap sebagai perkiraan untuk itu. Dari perspektif praktis, perbedaannya adalah bahwa LogitBoost menggunakan skema regresi sebagai *base learner* sedangkan AdaBoost bekerja dengan algoritma klasifikasi. Versi ini hanya menunjukkan dua kelas dari LogitBoost, tetapi algoritma dapat digeneralisasi untuk masalah *multiclass*. Seperti halnya regresi aditif, bahaya *overfitting* dapat dikurangi dengan mengecilkan prediksi individu  $f_j$  dengan pengganda yang telah ditentukan dan menggunakan validasi silang untuk menentukan jumlah iterasi yang sesuai.





- **Halaman ini sengaja dibiarkan kosong** -

## **BAB 3**

### **PENGEMBANGAN PERANGKAT PEMBELAJARAN BERBASIS TIK YANG EFEKTIF**

Bab ini menjelaskan tentang pengembangan perangkat pembelajaran berbasis TIK yang dipergunakan untuk pengambilan data siswa dari penelitian disertasi ini. Pembahasan diawali dengan perangkat pembelajaran berbasis TIK yang dikembangkan kemudian validasi dilakukan untuk mengukur efektivitas dan validitas dari perangkat pembelajaran berbasis TIK tersebut.

#### **3.1. Perangkat pembelajaran berbasis TIK**

Perangkat pembelajaran berbasis TIK yang dipergunakan pada penelitian ini pada dasarnya meliputi 2 perangkat, yaitu: *serious game* dan sistem *e-Learning*. Namun, pembahasan lebih memfokuskan pada proses pengembangan perangkat sistem *e-Learning*. Hal ini dikarenakan sebagian besar penelitian disertasi ini mempergunakan data siswa pada saat siswa berinteraksi dengan *e-Learning*. Sementara itu, pembahasan dari *serious game* telah dibahas secara detail pada publikasi “*A New Approach of Learners’ Assessment using Bloom’s Taxonomy-Based Serious Game*” di jurnal *Kursor* (Sukajaya, Nugroho, Ketut Eddy Purnama, & Purnomo, 2015).

Perangkat pembelajaran berbasis TIK sistem *e-Learning* terdiri dari 2 fasilitas utama, yaitu: fasilitas proses belajar mengajar dan fasilitas proses evaluasi. Sistem yang dikembangkan ini bersifat *mobile learning* dan menerapkan teknik *responsive web design*. Fasilitas proses belajar ini terdiri dari beberapa sub menu, yaitu: 1). Halaman *log in*: halaman ini dapat diakses oleh semua pengunjung alamat web media. Pada halaman *log in* juga terdapat tombol untuk mengunduh buku panduan penggunaan website media pembelajaran *e-learning*. 2). *Home*: hanya dapat diakses oleh siswa dan guru. 3). Tujuan Instruksional: halaman ini tentang penjabaran tujuan pembelajaran pada setiap pokok bahasan. Pokok bahasan tersebut diantaranya adalah medan magnet, hukum ampere, hukum induksi faraday, dan sifat-sifat bahan magnet. 4). Materi: Bagian materi berisi link atau tombol akses sub

materi. Sub materi tersebut merupakan pokok bahasan yang yang dibahas pada materi fisika I. Dalam hal ini terdapat 4 link sub materi, yaitu link medan magnet, link hukum ampere, link hukum induksi faraday, dan link sifat-sifat bahan magnet. 5) Latihan soal: Bagian latihan soal terdapat link berupa latihan soal 1 yang berisikan soal-soal pilihan ganda yang berjumlah 20. Latihan soal ini merupakan soal-soal untuk pokok bahasan medan magnet, hukum ampere, hukum induksi faraday, dan sifat-sifat bahan magnet. 6). Profil: Bagian profil merupakan identitas dari pembuat media pembelajaran *e-Learning* fisika 1. 7). *Log Out*: Link menu *log out* merupakan link yang digunakan pengguna media untuk keluar dari halaman utama media *e-Learning* menuju ke halaman utama *log in* pengguna media pembelajaran.

Fasilitas proses evaluasi dari sistem *e-Learning* ini terdiri dari beberapa sub menu, yaitu: 1). Ujian yang tersedia: sub menu ini biasanya dipilih siswa setelah sudah cukup dalam membaca maupun download materi. Sub menu ujian ini akan tampil sesuai dengan tanggal berlangsungnya ujian. 2). Deskripsi ujian: sub menu ini berisi tentang deskripsi, maupun peraturan mengenai ujian sebelum ujian dimulai. 3). Mulai ujian: pada sub menu ini, siswa sudah bisa mengerjakan soal-soal yang ada dengan cara membaca soal, kemudian memilih jawaban yang menurut siswa itu tepat pada dropdown. Jika jawaban sudah yakin maka siswa dapat menekan tombol “Jawab”, namun apabila siswa masih ragu terhadap jawaban maka siswa dapat menekan tombol “Lewati” untuk menuju soal selanjutnya, dan apabila siswa memerlukan informasi singkat mengenai soal maka siswa dapat menekan tombol “Petunjuk”. Siswa harus mempertimbangkan jawaban yang dipilih, karena soal yang sudah di jawab tidak akan bisa di ganti dengan jawaban lain. Dan perhatikan waktu yang terus berjalan, karena jika waktu habis maka soal tidak akan keluar dengan sendirinya, namun apabila siswa sudah selesai mengerjakan soal sebelum waktunya habis, siswa dapat menekan tombol “Selesai”. 4). Ujian selesai: sub menu ini muncul setelah siswa selesai mengerjakan soal. 5). Sudah melakukan ujian: siswa sudah melakukan ujian, kemudian siswa menekan tombol “Ikuti Ujian” pada halaman pilihan ujian tersedia maka akan tampil halaman sudah melakukan ujian. Hal tersebut menandakan bahwa siswa telah melakukan ujian, dan tidak bisa

melakukan ujian ulang. 6). Hasil ujian pada panel siswa: Ketika siswa telah selesai mengerjakan ujian, maka siswa dapat melihat hasil dari ujiannya.

### **3.2. Validasi perangkat pembelajaran berbasis TIK**

Perangkat pembelajaran berbasis TIK yang telah terbangun harus melalui validasi sebelum diujicobakan secara massal. Sub bab ini membahas validasi kedua fasilitas tersebut.

#### **3.2.1. Validasi fasilitas proses belajar mengajar**

Fasilitas proses belajar mengajar ini mengandung konten berupa media pembelajaran untuk pelajaran MIPA. Media pembelajaran ini telah melalui beberapa proses validasi sebelum diujicobakan secara masal oleh siswa. Beberapa validasi tersebut antara lain:

##### **Validasi perangkat pembelajaran oleh ahli media**

Validasi ini ditujukan untuk mengukur kualitas dari media. Validasi dilakukan oleh ahli media. Dalam penelitian ini, ahli media terdiri dari 3 ahli media dari Universitas Negeri Surabaya dan validasi yang dilakukan meliputi 5 aspek, antara lain:

##### **1). Validasi terhadap aspek kemudahan pengoperasian media pembelajaran**

Berdasarkan pada lembar validasi media pembelajaran *e-learning* yang diberikan kepada 3 dosen sebagai validator ahli media, diperoleh hasil kualitas media pada aspek kemudahan pengoperasian seperti yang tersaji dalam Tabel 3.1. Berdasarkan pada Tabel 3.1 tersebut, terlihat bahwa media pembelajaran *e-learning* mendapatkan persentase hasil validasi ahli media sebesar 95%. Persentase tersebut menunjukkan bahwa validasi media pada aspek kemudahan pengoperasian, mendapatkan kriteria media yang sangat layak. Kategori tersebut diperoleh berdasarkan lima butir pernyataan yang berkaitan tentang kemudahan pengoperasian media. Oleh karena itu, kualitas media yang dikembangkan termasuk dalam kualitas.

Tabel 3.1 Hasil Validasi Media Pembelajaran *e-Learning* terhadap Aspek Kemudahan Pengoperasian Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Kemudahan Pengoperasian					
Ketersediaan penggunaan akses poin internet untuk mengakses media pembelajaran <i>e-learning</i> pada lingkungan kampus.			1	2	11
Kemudahan akses login pada website media pembelajaran <i>e-learning</i> .			1	2	11
Kemudahan akses tombol menu media pembelajaran <i>e-learning</i> mudah digunakan.				3	12
Kemudahan akses login halaman latihan soal pada website media pembelajaran <i>e-learning</i> .				3	12
Kemudahan akses logout pada website media pembelajaran <i>e-learning</i> .			1	2	11
Jumlah skor	57				
Presentase	95%				

2). Validasi media pembelajaran terhadap aspek keterpaduan media

Berdasarkan pada lembar validasi media pembelajaran *e-Learning* yang diberikan kepada 3 dosen sebagai validator ahli media, diperoleh hasil berdasarkan kualitas media pada aspek keterpaduan seperti yang tersaji dalam Tabel 3.2. Berdasarkan pada Tabel 3.2 tersebut, terlihat bahwa media pembelajaran *e-Learning* mendapatkan persentase hasil validasi ahli media sebesar 85%. Persentase tersebut menunjukkan bahwa validasi media pada aspek keterpaduan media mendapatkan persentase kriteria media yang sangat layak. Kategori tersebut diperoleh berdasarkan tiga butir pernyataan yang berkaitan tentang keterpaduan media. Oleh karena itu, kualitas media yang dikembangkan termasuk dalam kualitas media yang sangat layak digunakan sebagai media pembelajaran.

3). Validasi media pembelajaran terhadap aspek keseimbangan media

Berdasarkan pada lembar validasi media pembelajaran *e-Learning* yang diberikan kepada 3 dosen sebagai validator ahli media, diperoleh hasil berdasarkan kualitas media pada aspek keseimbangan seperti yang tersaji dalam Tabel 3.3. Berdasarkan pada Tabel 3.3 tersebut, terlihat bahwa media pembelajaran *e-Learning* mendapatkan persentase hasil validasi ahli media sebesar 83.3%.

Tabel 3.2 Hasil Validasi Media Pembelajaran *e-Learning* terhadap Aspek Keterpaduan Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Keterpaduan					
Urutan antar materi dan link menu pada media pembelajaran <i>e-Learning</i> sesuai.				3	12
Petunjuk yang digunakan dalam media pembelajaran berbantuan komputer sesuai.			2	1	10
Pemilihan warna desain media pembelajaran <i>e-learning</i> sesuai.		1	1	1	9
Jumlah skor	31				
Presentase	85%				

Persentase tersebut menunjukkan bahwa validasi media pada aspek keseimbangan media mendapatkan persentase kriteria media yang sangat layak. Kategori tersebut diperoleh berdasarkan empat butir pernyataan yang berkaitan tentang keseimbangan media. Oleh karena itu, kualitas media yang dikembangkan termasuk dalam kualitas media yang sangat layak digunakan sebagai media pembelajaran.

Tabel 3.3 Hasil Validasi Media Pembelajaran *e-Learning* terhadap Aspek Keseimbangan Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Keseimbangan					
Ukuran animasi dan tulisan tiap halaman website sesuai.			2	1	10
Ukuran gambar pada tiap halaman sesuai.			1	2	11
Tata letak tulisan tiap halaman seimbang.			2	1	10
Keteraturan desain halaman media <i>e-Learning</i> .			3		9
Jumlah skor	40				
Presentase	83.3%				

#### 4). Validasi media pembelajaran terhadap aspek bentuk media

Berdasarkan pada lembar validasi media pembelajaran *e-Learning* yang diberikan kepada 3 dosen sebagai validator ahli media, diperoleh hasil berdasarkan kualitas

media pada aspek bentuk media seperti yang tersaji dalam Tabel 3.4. Berdasarkan pada Tabel 3.4 tersebut, terlihat bahwa media pembelajaran *e-learning* mendapatkan persentase hasil validasi ahli media sebesar 95%. Persentase tersebut menunjukkan bahwa validasi media pada aspek bentuk media mendapatkan persentase kriteria media yang sangat layak. Kategori tersebut diperoleh berdasarkan lima butir pernyataan yang berkaitan tentang bentuk media. Oleh karena itu, kualitas media yang dikembangkan termasuk dalam kualitas media yang sangat layak digunakan sebagai media pembelajaran.

Tabel 3.4 Hasil Validasi Media Pembelajaran *e-Learning* terhadap Aspek Bentuk Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Bentuk					
Animasi flash yang digunakan menarik.				3	12
Bentuk huruf yang mudah dibaca.				3	12
Bentuk tombol link website mudah digunakan dan menarik.			1	2	11
Bentuk halaman login menarik.				3	12
Bentuk halaman utama website menarik.		1		2	10
Jumlah skor	57				
Presentase	95%				

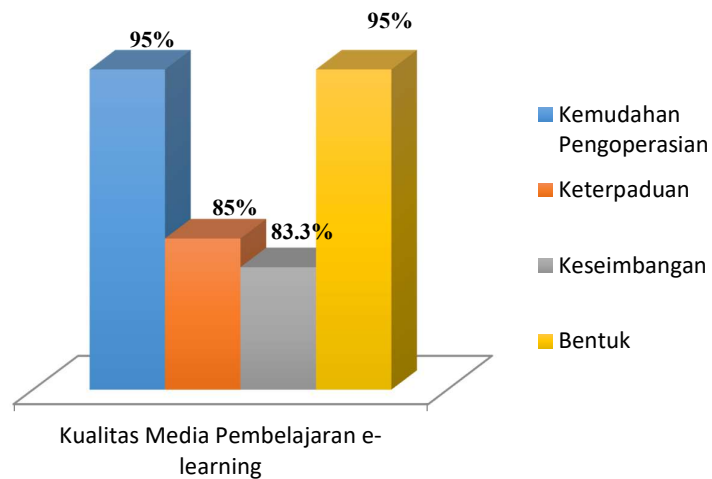
5). Validasi media pembelajaran berdasarkan aspek kualitas media pembelajaran secara keseluruhan

Validasi kualitas media pembelajaran *e-learning* ini dideskripsikan pada Gambar 3.1.

Lebih lanjut, berdasarkan persentase validasi kelayakan (P) dari masing-masing aspek kualitas media pembelajaran, secara keseluruhan diperoleh rata-rata ( $\bar{X}$ ) persentase kualitas media pembelajaran dengan perhitungan sebagai berikut.

$$\bar{X}P = \frac{P_1 + P_2 + P_3 + P_4}{n} \quad (3.1)$$

$$= (95\% + 85\% + 83.3\% + 95\%) / 4 = 89.5\%$$



Gambar 3.1 Kualitas media pembelajaran e-learning.

Dari hasil penilaian validasi secara umum pada variabel kualitas media pembelajaran e-learning, dapat diketahui rata-rata presentase kualitas media adalah 89.5%. Hal ini berarti bahwa media pembelajaran e-learning berada pada kategori interpretasi skala penilaian kualitas sangat layak menurut penilaian pakar media.

#### **Validasi media pembelajaran oleh ahli materi**

Validasi ini ditujukan untuk mengukur efektifitas media. Dalam penelitian ini, ahli materi terdiri dari 3 ahli materi, 2 dari Universitas Negeri Surabaya dan 1 dari SMKN 3 Surabaya dan validasi yang dilakukan meliputi 3 aspek, yaitu:

##### 1). Validasi media pembelajaran terhadap aspek format materi media

Berdasarkan pada lembar validasi media pembelajaran *e-Learning* yang diberikan kepada 3 validator ahli materi, diperoleh hasil tentang efektifitas media pada aspek format media seperti yang tersaji dalam Tabel 3.5. Berdasarkan pada Tabel 3.5 tersebut, terlihat bahwa media pembelajaran *e-Learning* mendapatkan persentase hasil validasi ahli materi sebesar 85%. Persentase tersebut menunjukkan bahwa validasi media pada aspek format materi media mendapatkan persentase kriteria media yang sangat efektif. Kategori tersebut diperoleh berdasarkan lima butir pernyataan yang berkaitan tentang kesesuaian format materi media. Oleh karena itu, media yang dikembangkan termasuk dalam media yang sangat efektif digunakan sebagai media pembelajaran.



Tabel 3.5 Hasil Validasi Media Pembelajaran *e-Learning* terhadap Aspek Format Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Format					
Keruntutan materi sesuai tujuan instruksional pembelajaran.			1	2	11
Kesesuaian penggunaan contoh animasi pada materi medan magnet.			2	1	10
Kesesuaian penggunaan contoh animasi pada materi hukum ampere.			2	1	10
Kesesuaian penggunaan contoh animasi pada materi hukum induksi faraday.			2	1	10
Kesesuaian penggunaan contoh animasi pada materi sifat-sifat magnet bahan.			2	1	10
Rata-rata skor	51				
Presentase	85%				

2). Validasi media pembelajaran terhadap aspek isi materi media

Berdasarkan pada lembar validasi media pembelajaran *e-Learning* yang diberikan kepada 3 dosen sebagai validator ahli materi, diperoleh hasil tentang efektifitas media pada aspek isi media seperti yang tersaji dalam Tabel 3.6.


Berdasarkan pada Tabel 3.6 tersebut, terlihat bahwa media pembelajaran *e-learning* mendapatkan persentase hasil validasi ahli materi sebesar 87%. Persentase tersebut menunjukkan bahwa validasi media pada aspek isi materi media mendapatkan persentase kriteria media yang sangat efektif. Kategori tersebut diperoleh berdasarkan tiga belas butir pernyataan yang berkaitan tentang isi materi media. Oleh karena itu, media yang dikembangkan termasuk dalam media yang sangat efektif digunakan sebagai media pembelajaran.

3). Validasi media pembelajaran berdasarkan aspek efektifitas media pembelajaran secara keseluruhan

Validasi efektifitas media pembelajaran divisualisasikan pada Gambar 3.2.

Tabel 3.6 Hasil Validasi Media Pembelajaran *e-Learning* terhadap Aspek Isi Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Isi					
Kesesuaian judul dengan isi materi.				3	12
Kejelasan pengertian medan magnet yang disampaikan pada media pembelajaran e-learning.			2	1	10
Kejelasan pengertian hukum ampere yang disampaikan pada media pembelajaran e-learning.			3		9
Kejelasan pengertian hukum induksi faraday yang disampaikan pada media pembelajaran e-learning.			3		9
Kejelasan pengertian sifat-sifat magnetik bahan yang disampaikan pada media pembelajaran e-learning.			2	1	10
Kejelasan penggunaan contoh animasi pada medan magnet yang disampaikan pada media pembelajaran e-learning.			2	1	10
Kejelasan penggunaan contoh animasi pada hukum ampere yang disampaikan pada media pembelajaran e-Learning.			1	2	11
Kejelasan penggunaan contoh animasi pada hukum induksi faraday yang disampaikan pada media pembelajaran e-Learning.			3		9
Kejelasan penggunaan contoh animasi pada sifat-sifat magnetik bahan yang disampaikan pada media pembelajaran <i>e-Learning</i> .			2	1	10
Ketepatan penggunaan contoh soal animasi pada medan magnet yang disampaikan pada media pembelajaran <i>e-Learning</i> .				3	12
Ketepatan penggunaan contoh soal pada hukum ampere yang disampaikan pada media pembelajaran <i>e-Learning</i> .			1	2	11
Ketepatan penggunaan contoh soal pada hukum induksi faraday yang disampaikan pada media pembelajaran <i>e-Learning</i> .			1	2	11
Ketepatan penggunaan contoh soal pada sifat-sifat magnetik bahan yang disampaikan pada media pembelajaran <i>e-Learning</i> .				3	12
Jumlah skor	136				
Presentase	87%				



Gambar 3.2 Efektifitas media pembelajaran *e-Learning*.

Lebih jauh, berdasarkan persentase validasi media ( $P$ ) secara keseluruhan tentang variabel efektifitas media pembelajaran, diperoleh rata-rata ( $\bar{X}$ ) persentase efektifitas media pembelajaran sebagai berikut.

$$\begin{aligned} \bar{X}P &= \frac{P_1 + P_2}{n} & (3.2) \\ &= \frac{85\% + 87\%}{2} = 86\% \end{aligned}$$

Dari hasil penilaian validasi secara umum pada variabel efektifitas media pembelajaran *e-Learning*, dapat diketahui rata-rata presentase efektifitas media adalah 86%. Hal ini menunjukkan bahwa media pembelajaran *e-Learning* berada pada kategori interpretasi skala penilaian sangat efektif menurut penilaian ahli materi.

### Validasi angket respon siswa

Angket siswa merupakan angket yang digunakan oleh peneliti untuk mengetahui bagaimana tanggapan siswa terhadap media pembelajaran *e-Learning* yang dikembangkan oleh peneliti.

Berikut merupakan penjelasan hasil respon siswa dengan penilaian terhadap setiap aspek yang termasuk dalam kategori penggunaan media pembelajaran

berbasis *e-Learning* pada mata kuliah Fisika I. Beberapa aspek tersebut diantaranya adalah format media, isi media, bahasa yang digunakan media, kemudahan pengoperasian media, dan sikap siswa terhadap penggunaan media pembelajaran *e-Learning*.

1). Hasil respon siswa terhadap aspek format media pembelajaran *e-Learning* Berdasarkan data angket respon siswa terhadap media pembelajaran *e-Learning*, diperoleh hasil respon siswa berdasarkan aspek format media yang tersaji pada Tabel 3.7.

Tabel 3.7 Hasil Angket Respon Siswa terhadap Aspek Format Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Format					
Tampilan (gambar, warna, animasi, dll) pada penyajian materi media pembelajaran <i>e-Learning</i> membuat saya tertarik untuk membacanya.			3	17	77
Penyajian materi pada media pembelajaran <i>e-Learning</i> jelas dan runtut sehingga saya mudah memahami isi materi.	1		7	12	71
Tampilan penggunaan huruf pada penyajian materi media pembelajaran <i>e-Learning</i> memudahkan saya dalam membaca tulisan dalam media pembelajaran <i>e-Learning</i> .		1	8	11	70
Jumlah skor	218				
Presentase	90.8%				

Berdasarkan pada Tabel 3.7. tersebut, dapat diketahui bahwa respon siswa terhadap penggunaan media pembelajaran *e-Learning* pada mata kuliah Fisika I mendapatkan persentase respon sebesar 90.8%. Dari hasil persentase tersebut, dapat diketahui bahwa respon siswa sangat baik terhadap aspek format media pembelajaran *e-Learning* yang dikembangkan.

2). Hasil respon siswa terhadap aspek isi media pembelajaran *e-Learning*

Berdasarkan data angket respon siswa terhadap media pembelajaran *e-Learning*, diperoleh hasil respon siswa berdasarkan aspek isi media yang tersaji pada Tabel 3.8.

Tabel 3.8 Hasil Angket Respon Siswa terhadap Aspek Isi Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Isi					
Judul materi yang digunakan dalam pada media pembelajaran <i>e-Learning</i> memudahkan saya untuk memahami materi fisika I tentang medan magnet, hukum ampere, hukum induksi faraday, dan sifat-sifat bahan magnet.			4	16	76
Media pembelajaran <i>e-Learning</i> dapat membantu saya memahami isi materi fisika I tentang medan magnet, hukum ampere, hukum induksi faraday, dan sifat-sifat bahan magnet.		1	6	13	72
Jumlah skor	148				
Persentase	92.5%				

Berdasarkan pada Tabel 3.8. tersebut, dapat diketahui bahwa respon siswa terhadap penggunaan media pembelajaran *e-Learning* pada mata kuliah Fisika I mendapatkan persentase respon sebesar 92,5%. Dari hasil persentase tersebut, dapat diketahui bahwa respon siswa sangat baik terhadap aspek isi media pembelajaran *e-Learning*.

### 3). Hasil respon siswa terhadap aspek bahasa media pembelajaran *e-Learning*

Berdasarkan data angket respon siswa terhadap media pembelajaran *e-Learning*, diperoleh hasil respon siswa berdasarkan aspek bahasa media yang tersaji pada Tabel 3.9 berikut ini.

Berdasarkan pada Tabel 3.9. tersebut, dapat diketahui bahwa respon siswa terhadap penggunaan media pembelajaran *e-Learning* pada mata kuliah Fisika I mendapatkan persentase respon sebesar 90%. Dari hasil persentase tersebut, dapat diketahui respon siswa sangat baik terhadap aspek bahasa media pembelajaran *e-Learning*.

Tabel 3.9 Hasil Angket Respon Siswa terhadap Aspek Bahasa Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Bahasa					
Penggunaan bahasa pada media pembelajaran <i>e-Learning</i> komunikatif dan mudah saya pahami.		2	6	12	70
Makna kalimat dalam media pembelajaran memudahkan saya dalam memahami konsep materi fisika I tentang medan magnet, hukum ampere, hukum induksi faraday, dan sifat-sifat bahan magnet.		2	2	16	74
Rata-rata skor	144				
Presentase	90%				

4). Hasil respon siswa terhadap aspek kemudahan pengoperasian media pembelajaran *e-Learning*

Berdasarkan data angket respon siswa terhadap media pembelajaran *e-Learning*, diperoleh hasil respon siswa berdasarkan aspek kemudahan pengoperasian media yang tersaji pada Tabel 3.10 berikut ini.

Tabel 3.10 Hasil Angket Respon Siswa terhadap Aspek Kemudahan Pengoperasian Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Kemudahan Pengoperasian					
Penggunaan gambar flash pada media pembelajaran <i>e-Learning</i> membuat saya lebih mudah memahami materi pelajaran.			5	15	75
Akses login pada media pembelajaran <i>e-Learning</i> mudah dan cepat.		1	6	13	72
Akses menu pada media pembelajaran <i>e-Learning</i> sesuai dengan isi dan cepat.		1	6	13	72
Tata cara pengoperasian media pembelajaran berbasis <i>e-Learning</i> memudahkan saya dalam mengoperasikan media.		1	2	17	76
Rata-rata skor	295				
Presentase	92%				

Berdasarkan pada Tabel 3.10. tersebut, dapat diketahui bahwa respon siswa terhadap penggunaan media pembelajaran *e-Learning* pada mata kuliah Fisika I mendapatkan persentase respon sebesar 92%. Dari hasil persentase tersebut, dapat diketahui bahwa respon siswa sangat baik terhadap aspek kemudahan pengoperasian media pembelajaran *e-Learning*.

4). Hasil respon siswa terhadap aspek sikap siswa terhadap penggunaan media pembelajaran *e-Learning*

Berdasarkan data angket respon siswa terhadap media pembelajaran *e-Learning*, diperoleh hasil respon siswa berdasarkan aspek sikap siswa terhadap penggunaan media yang tersaji pada Tabel 3.11 berikut ini.

Tabel 3.11 Hasil Angket Respon Siswa terhadap Aspek Sikap Siswa Terhadap Penggunaan Media

Aspek Penilaian	Skor				Jumlah Skor
	1	2	3	4	
Sikap Siswa Terhadap Penggunaan Media Pembelajaran <i>E-Learning</i>					
Saya berminat untuk mengikuti kegiatan pembelajaran dengan menggunakan media pembelajaran <i>e-Learning</i> .	1	2	5	12	68
Kegiatan pembelajaran dengan menggunakan media pembelajaran <i>e-Learning</i> bermanfaat bagi saya.		1	5	14	73
Jumlah skor	141				
Presentase	88%				


Berdasarkan pada Tabel 3.11. tersebut, dapat diketahui bahwa respon siswa terhadap penggunaan media pembelajaran *e-Learning* pada mata kuliah Fisika I mendapatkan persentase respon sebesar 88%. Dari hasil persentase tersebut, dapat diketahui bahwa respon siswa sangat baik terhadap aspek sikap siswa terhadap penggunaan media pembelajaran *e-Learning*.

5). Hasil perhitungan angket respon siswa secara keseluruhan

Berdasarkan persentase respon ( $P$ ) secara keseluruhan tentang respon siswa terhadap media pembelajaran, diperoleh rata-rata ( $\bar{X}$ ) persentase respon siswa terhadap media pembelajaran sebagai berikut.

$$\begin{aligned}\bar{X}P &= \frac{P_1 + P_2 + P_3 + P_4 + P_5}{n} \\ &= \frac{90.8\% + 92.5\% + 90\% + 92\% + 88\%}{5} = 90.6\%\end{aligned}\tag{3.3}$$

Dari hasil penilaian validasi secara umum pada variabel respon siswa terhadap media pembelajaran *e-Learning*, dapat diketahui rata-rata presentase respon media adalah 90.6%. Hal ini berarti bahwa media pembelajaran *e-Learning* berada pada kriteria sangat baik pada tanggapan atau respon siswa. Deskripsi hasil respon siswa terhadap media pembelajaran *e-Learning* juga dapat ditunjukkan pada grafik pada Gambar 3.3.



Gambar 3.3 Respon siswa terhadap media pembelajaran *e-Learning*.

### 3.2.2. Validasi fasilitas proses evaluasi

Fasilitas proses evaluasi dari *e-Learning* ini mengandung konten berupa *ujian on-line* untuk pelajaran MIPA khususnya Fisika. Konten dari fasilitas ini telah



melalui beberapa proses validasi sebelum diujicobakan secara masal oleh siswa. Beberapa validasi tersebut antara lain:

### Validasi Rencana Pelaksanaan Pembelajaran (RPP)

Hasil validasi oleh validator terhadap RPP akan diuraikan dalam Tabel 3.12 dan divisualisasikan pada gambar 3.4.

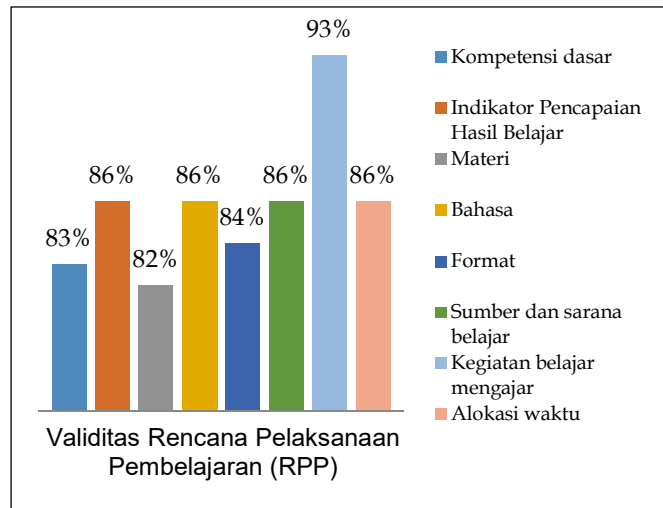
Tabel 3.12 Hasil Validasi Rencana Pelaksanaan Pembelajaran

No.	Aspek	Skala Penilaian					$\Sigma$ Validator	Hasil Rating
		1	2	3	4	5		
1.	Kompetensi dasar							
	Kejelasan rumusan kompetensi dasar dan indikator				3		3	80 %
	Kejelasan kompetensi dasar dengan silabus			2	1		3	86 %
	Rata-rata jumlah hasil rating							83 %
2.	Indikator Pencapaian Hasil Belajar							
	Kesesuaian rumusan indikator terhadap pencapaian hasil belajar			2	1		3	86 %
	Rata-rata jumlah hasil rating							86 %
No.	Aspek	Skala Penilaian					$\Sigma$ Validator	Hasil Rating
		1	2	3	4	5		
	Rata-rata jumlah hasil rating							86 %
3.	Materi							
	Relevansi materi dengan kompetensi dasar pembelajaran				3		3	80 %
	Urutan penyajian materi dikelompokkan dalam bagian-bagian yang logis (ketertarikan topik, sub topik dan penyajian sistematis)				3		3	80 %
	Kesesuaian tugas/latihan soal yang mendukung konsep			2	1			86 %
	Rata-rata jumlah hasil rating							82 %
4.	Bahasa							
	Kebenaran tata bahasa yang digunakan, sesuai				1	2	3	93 %

	dengan kaidah bahasa Indonesia yang baku							
	Kesederhanaan sruktur kalimat			2	1	3		86 %
	Bahasa yang digunakan bersifat komunikatif			3		3		80 %
Rata-rata jumlah hasil rating								86 %
5.	Format							
	Kejelasan pembagian materi			3		3		80 %
	Kesesuaian jenis dan ukuran huruf sehingga mudah dibaca			1	2	3		93%
	Format penulisan isi saling terkait			3		3		80 %
Rata-rata jumlah hasil rating								84 %
No.	Aspek	Skala Penilaian					Σ Validator	Hasil Rating
		1	2	3	4	5		
6.	Sumber dan sarana belajar							
	Kesesuaian dengan kompetensi yang ingin dicapai			2	1	3		86%
Rata-rata jumlah hasil rating								86 %
7.	Kegiatan belajar mengajar							
	Kesesuaian dengan sintaks pembelajaran			1	2	3		93 %
Rata-rata jumlah hasil rating								93 %
8.	Alokasi waktu							
	Kesesuaian alokasi waktu dengan durasi penyampaian materi			2	1	3		86 %
Rata-rata jumlah hasil rating								86 %

$$\frac{\sum \text{rata-rata hasil}}{\sum \text{aspek}} = \frac{83+86+82+86+84+86+93+86}{8} = \frac{686}{8} = 85,75\%$$

Berdasarkan validasi RPP yang tersaji pada Tabel 3.12, RPP tersebut dikategorikan sangat valid dengan hasil rating sebesar 85,75%, sehingga layak untuk diterapkan di SMK Negeri Surabaya.



Gambar 3.4 Hasil validasi RPP

### Validasi Lembar Kerja Siswa (LKS)

Hasil validasi oleh validator terhadap LKS diuraikan dalam Tabel 3.13 dan dideskripsikan pada Gambar 3.5.

Tabel 3.13 Penilaian Data Hasil Validasi LKS


No.	Aspek	Skala Penilaian					$\Sigma$ Validator	Hasil Rating
		1	2	3	4	5		
1.	Isi							
	a. Kesesuaian materi ajar dengan Kompetensi Dasar yang akan digunakan.				3		3	80 %
	b. Materi disampaikan secara urut, singkat, jelas dan efektif.				3		3	80 %
	c. Kesesuaian kunci jawaban dengan pertanyaan.				3		3	80 %
Rata-rata jumlah hasil rating								80 %
2.	Konstruksi							
	Teks dan gambar seimbang				3		3	80 %
	b. Gambar, tabel dilengkapi dengan identitas lengkap mulai dari no gambar dan keterangan gambar.				2	1	3	86%
	c. Gambar menggunakan warna yang menarik			1	2		3	73%

Rata-rata jumlah hasil rating						79 %	
3.	Bahasa						
	Menggunakan bahasa Indonesia yang benar sesuai dengan EYD.			2	1	3	86 %
	Tidak menggunakan kalimat yang dapat menimbulkan penafsiran ganda.			3		3	80 %
Rata-rata jumlah hasil rating						83 %	

Hasil keseluruhan validasi rencana pelaksanaan pembelajaran dilihat dari 3 aspek diatas adalah:

$$\frac{\sum \text{rata-rata hasil}}{\sum \text{aspek}} = \frac{80 + 79 + 83}{3} = \frac{242}{3} = 80,6\%$$

Dari Tabel 3.13, hasil validasi LKS menunjukkan bahwa LKS tersebut dikategorikan valid dengan hasil rating sebesar 80,6 %, sehingga layak untuk digunakan di SMK Negeri Surabaya.



Gambar 3.5 Hasil validasi kelayakan LKS

### Validasi Soal Evaluasi

Hasil validasi oleh validator terhadap soal evaluasi disajikan dalam Tabel 3.14 dan diilustrasikan pada Gambar 3.6.


Tabel 3.14 Penilaian Data Hasil Validasi Soal Evaluasi

No.	Aspek Yang Divalidasi	Skala Penilaian					$\Sigma$ Validator	Hasil Rating
		1	2	3	4	5		
1.	Isi							
	Soal sesuai dengan indikator				3		3	80 %
	Pilihan jawaban homogen dan logis				3		3	80 %
	Hanya ada satu kunci jawaban				1	2	3	86 %
	Rata-rata jumlah hasil rating							82 %
2.	Materi							
	Pokok soal dirumuskan dengan singkat, jelas, dan tegas				3		3	80 %
	Rumusan pokok soal dan pilihan jawaban merupakan pernyataan yang diperlukan saja				3		3	80 %
	Pokok soal tidak mempertunjukkan kunci jawaban				3		3	80 %
	Pokok soal bebas sesuai dengan materi yang sudah disampaikan				2	1	3	86 %
	Pilihan jawaban homogen dan logis				3		3	80 %
	Rata-rata jumlah hasil rating							81,32%
	Skala Penilaian							
	1							
	2							
	3							
	4							
	5							
	$\Sigma$ Validator							
	Hasil Rating							
	Rata-rata jumlah hasil rating							81,32%
3.	Konstruksi							
	Soal dirumuskan dengan jelas, singkat dan tegas				3		3	80 %
	Ada petunjuk yang jelas untuk mengerjakan soal				3		3	80 %
	Disajikan tabel, gambar, grafik dan sejenisnya dengan jelas dan terbaca				3		3	80 %
	Menggunakan kata Tanya atau perintah yang menuntut jawaban				1	2	3	86 %
	Rata-rata jumlah hasil rating							81,86%
4.	Bahasa							
	Menggunakan bahasa sesuai EYD				2	1	3	86
	Menggunakan bahasa yang komunikatif				3		3	80
	Tidak menggunakan bahasa yang berlaku setempat/tabu				3		3	80
	Rata-rata jumlah hasil rating							82 %

Sehingga hasil keseluruhan validasi soal evaluasi dari 4 aspek diatas adalah sebagai berikut:

$$\frac{\sum \text{rata-rata hasil}}{\sum \text{aspek}} = \frac{82 + 81,32 + 81,86 + 82}{4} = \frac{686}{4} = 81,8\%$$

Hasil validasi soal evaluasi menunjukkan bahwa soal evaluasi tersebut dikategorikan valid dengan hasil rating sebesar 81,8 %, sehingga layak untuk digunakan di SMK Negeri Surabaya.



Gambar 3.6 Hasil validasi soal evaluasi


### Validasi Respon Siswa

Hasil validasi oleh validator terhadap respon siswa dalam penelitian ini akan diuraikan dalam Tabel 3.15 dan divisualisasikan pada Gambar 3.7.

Hasil keseluruhan respon siswa dilihat dari 2 aspek diatas adalah sebagai berikut:

$$\frac{\sum \text{rata-rata hasil}}{\sum \text{aspek}} = \frac{86\% + 84\%}{2} = \frac{170}{2} = 85\%$$

Hasil validasi respon siswa menunjukkan bahwa respon siswa tersebut dikategorikan sangat valid dengan hasil rating sebesar 85 %, sehingga layak untuk digunakan untuk mengambil respon di SMK Negeri Surabaya.



Gambar 3.7 Hasil validasi respon siswa

Tabel 3.15 Penilaian Data Hasil Validasi Respon Siswa

No.	Aspek	Skala Penilaian					Σ Validator	Hasil Rating
		1	2	3	4	5		
1.	Konstruksi							
	Pertanyaan dirumuskan dengan singkat, jelas, dan tegas				2	1	3	86 %
	Pertanyaan yang dirumuskan merupakan pertanyaan atas respon/hasil yang didapat				2	1	3	86 %
Rata-rata jumlah hasil rating								86 %
2.	Bahasa							
	Menggunakan bahasa yang sesuai dengan kaidah bahasa Indonesia				2	1	3	86 %
	Menggunakan bahasa yang komunikatif				3		3	80 %
	Kesederhanaan struktur kalimat				2	1	3	86 %
Rata-rata jumlah hasil rating								84 %

### 3.3. Intisari pengembangan perangkat pembelajaran berbasis TIK

Dalam penelitian ini, sistem *e-Learning* yang dikembangkan ini dapat dikatakan sebagai sistem *e-Learning* yang efektif. Hal ini didasarkan pada hasil validasi yang telah dilakukan oleh ahli media, ahli materi dan respon siswa.

Untuk fasilitas proses belajar mengajar, media pembelajaran *e-Learning* berada pada kategori interpretasi skala penilaian kualitas sangat layak menurut penilaian pakar media yaitu 89,5%. Kemudian, media pembelajaran *e-Learning* berada pada kategori interpretasi skala penilaian sangat efektif menurut penilaian ahli materi yaitu sebesar 86%. Terakhir, media pembelajaran *e-Learning* berada pada kriteria sangat baik pada tanggapan atau respon siswa sebesar 90,6%.

Untuk fasilitas proses evaluasi, RPP dikategorikan sangat valid dengan hasil rating sebesar 85,75%, LKS dikategorikan valid dengan hasil rating sebesar 80,6 %, dan soal evaluasi tersebut dikategorikan valid dengan hasil rating sebesar 81,8 %, sehingga secara keseluruhan ujian online ini layak untuk digunakan SMK Negeri Surabaya.

Efektifitas pembelajaran menggunakan sistem ini telah dipublikasikan pada *The 6th International Conference on Educational, Management, Administration and Leadership (6th ICEMAL 2016)* “yang dilaksanakan di Bandung, 28 Agustus 2016 (Wanarti et al., 2016).





- Halaman ini sengaja dibiarkan kosong -



## **BAB 4**

### **DATA RANAH KOGNITIF SISWA MIPA**

Proses pengumpulan data ranah kognitif siswa MIPA dan deskripsi dari data dibahas pada bab ini.

#### **4.1. Proses pengumpulan data ranah kognitif siswa MIPA**

Proses pengumpulan data ranah kognitif MIPA ini pada dasarnya terdiri dari 2 proses, yaitu: proses pengumpulan data ranah kognitif Matematika dan data ranah kognitif IPA. Namun, pembahasan detail yang dilakukan didalam penelitian disertasi ini hanya terkait pada proses pengumpulan data ranah kognitif IPA menggunakan media *e-Learning*. Sementara, proses pengumpulan data dari data ranah kognitif Matematika yang dieksplorasi dalam penelitian disertasi ini telah dijelaskan secara detail pada penelitian yang telah dipublikasikan pada "*Intelligent classification of learner's cognitive domain using bayes net, nai've bayes, and j48 utilizing bloom's taxonomy-based serious game*", pada *International Journal of Emerging Technologies in Learning*.(Nyoman Sukajaya et al., 2015)

Berkaitan dengan proses pengumpulan data ranah kognitif melalui sistem *e-Learning*, populasi pengambilan data adalah siswa SMK Negeri Kota Surabaya. Sampel penelitian ini adalah siswa kelas XI Teknik Instalasi Tenaga Listrik SMK Negeri 3 Surabaya dengan Akreditasi A dan SMK Negeri 5 Surabaya dengan Akreditasi A pada tahun pelajaran 2016-2017. Teknik pengumpulan data merupakan langkah yang paling strategis dalam penelitian ini, karena tujuan utama dari penelitian adalah mendapatkan data. Adapun proses pengumpulan data pada penelitian ini adalah sebagai berikut:

##### **a. Observasi**

Metode ini digunakan untuk mengumpulkan data penelitian yang berkaitan dengan keterlaksanaan pembelajaran yang sedang berlangsung. Data diperoleh melalui pengamatan terhadap guru ketika proses pembelajaran berlangsung yang dilakukan oleh pengamat selama dua kali pertemuan. Instrumen yang digunakan adalah instrumen lembar observasi keterlaksanaan pembelajaran.

b. Tes

Metode ini digunakan mengetahui tingkat kompetensi belajar siswa. Tes hasil belajar disusun berdasarkan indikator dan tujuan pembelajaran yang telah ditentukan. Tes tersebut diberikan diakhir pelajaran berupa tes kognitif yang dilakukan secara *on-line*.

c. Angket

Angket digunakan untuk mengumpulkan informasi tentang validasi perangkat pembelajaran.

Untuk tahap ujicoba sistem *e-Learning*, penelitian ini membagi dalam 2 tahap yaitu: tahap uji coba produk secara terbatas dan tahap uji coba produk secara masal.


1. Tahap Uji Coba Produk Secara Terbatas

Uji coba produk secara terbatas ini bertujuan untuk mengukur respon siswa terhadap media pembelajaran *e-Learning* dan keterlaksanaan pembelajaran menggunakan *e-learning*. Uji coba produk secara terbatas dilakukan bersamaan dengan validasi produk, sebagai acuan bagi peneliti untuk merevisi *e-Learning* yang telah dikembangkan sebelum dilakukannya uji coba secara masal. Uji coba terbatas ini dilakukan di SMKN 3 Surabaya, tepatnya pada kelas X TAV 3 dengan mata pelajaran Teknik Listrik khususnya pada Kompetensi Dasar Transformator yang dilakukan dalam tiga kali pertemuan. Hasil dari uji coba tersebut yang meliputi respon siswa dan keterlaksanaan pembelajaran.

2. Tahap Uji Coba Produk Secara Masal

Tahap uji coba masal ini bertujuan mengetahui efektifitas media pembelajaran melalui hasil belajar siswa dan mengambil data login yang besar. Untuk mencapai tujuan tersebut, peneliti mengambil sampel penelitian sejumlah dua buah sekolah, yaitu SMKN 3 Surabaya dan SMKN 5 Surabaya, dengan populasi seluruh SMKN di Surabaya. Siswa yang menjadi objek penelitian adalah siswa kelas XI Teknik Instalasi Tenaga Listrik sejumlah 6 kelas, yang tersebar 3 kelas di masing-masing sekolah dengan rincian 1 buah kelas kontrol dan 2 buah kelas eksperimen. Mata pelajaran yang digunakan sebagai sampel adalah fisika, dengan materi medan magnet dan hukum Faraday.

Proses pengambilan data dilakukan selama dua pertemuan di masing-masing kelas. Pada pertemuan pertama, siswa diberi soal pretest untuk mengetahui kemampuan awal siswa serta memastikan bahwa antara kelas kontrol dan eksperimen memiliki kemampuan yang tidak jauh berbeda. Setelah selesai mengerjakan soal pretest, siswa diberi pembelajaran sesuai dengan pemberian perilaku di masing-masing kelas. Untuk kelas kontrol, siswa diberi pembelajaran menggunakan model pembelajaran langsung tanpa bantuan *e-Learning*. Sedangkan pada kelas eksperimen, pembelajaran dilaksanakan menggunakan model pembelajaran langsung dengan bantuan *e-Learning*. Selanjutnya siswa di masing-masing kelas diberi tugas yang sama yang mengacu pada materi medan magnet dan hukum Faraday sebagai persiapan pelaksanaan posttest pada pertemuan selanjutnya. Pada pertemuan kedua, guru memastikan bahwa siswa tidak mendapatkan masalah terhadap tugas yang telah diberikan pada pertemuan sebelumnya. *Post test* pada kelas kontrol dilakukan menggunakan metode manual dengan menggunakan soal di atas kertas, sedangkan pada kelas eksperimen dilakukan secara *online* melalui *e-Learning* yang diakses melalui laptop maupun *smartphone*. Proses pengumpulan data ini diperlihatkan pada Gambar 4.1.



Gambar 4.1. Proses pengumpulan data ranah kognitif siswa MIPA

## 4.2. Deskripsi data ranah kognitif siswa MIPA

### 4.2.1. Data siswa yang berkaitan dengan ranah kognitif Matematika

Dalam penelitian ini, kami menggunakan kumpulan data yang diperoleh dari aktivitas siswa, yaitu, siswa memainkan permainan serius berbasis taksonomi yang disebut BoTySeGa. Data diambil pada saat siswa bermain sambil belajar dengan di laboratorium Universitas Pendidikan Ganesha. Seperti yang ditentukan oleh bloom taksonomi, ada 3 tingkat kompetensi siswa: tingkat kompetensi yang pertama, kedua, ketiga yang direpresentasikan sebagai C1, C2, C3, masing-masing. Masing-masing level terdiri dari 3 pertanyaan di mana beberapa evaluasi diterapkan: skor, waktu eksekusi, dan pembantu yang digunakan. Dalam hal ini, skor adalah jawaban dari setiap pertanyaan; waktu eksekusi adalah waktu yang diambil untuk setiap pertanyaan; penggunaan bantuan yang digunakan adalah kondisi bahwa seorang siswa mengakses bantuan. Secara khusus, ada 85 siswa sekolah dasar sebagai subyek penelitian (Nyoman Sukajaya et al., 2015). Prestasi belajar siswa (*achievement*) diambil berdasarkan tes berbasis kertas. Data dikumpulkan pada hari yang sama setelah para pemain bermain BoTySeGa. Karena setiap siswa melakukan 3 pertanyaan dari setiap tingkat kompetensi, maka terekam 85 *record* yang terdiri dari 27 fitur yang berkaitan dengan ranah kognitif siswa Matematika, yaitu: score, Time, dan AccessToHelp dari setiap pertanyaan, seperti yang disajikan pada Tabel 4.1. BoTySeGa mencatat data sebagai berikut: Score1,..., Score9, Time1,...,Time9, AccessToHelp1,...AccesToHelp9.

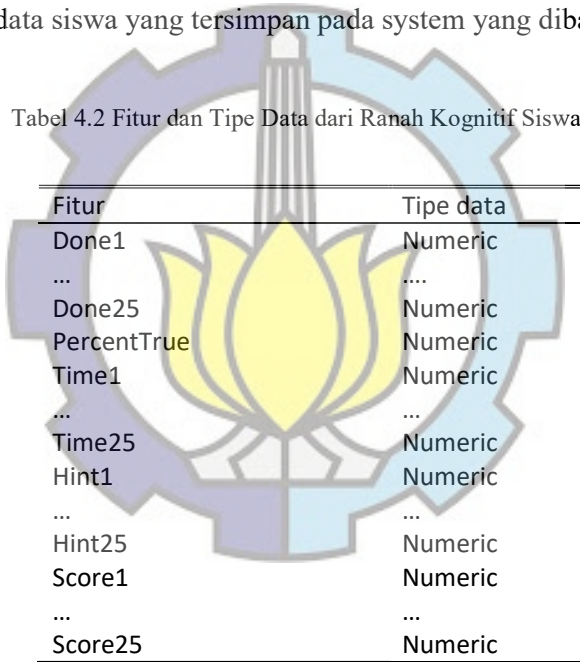
Tabel 4.1 Fitur dan Tipe Data dari Ranah Kognitif Siswa Matematika

Fitur	Tipe data
Score1	Numerik
...	'''
Score9	Numerik
Time1	Numerik
...	...
Time9	Numerik
AccessToHelp1	Numerik
...	...
AccessToHelp9	Numerik

#### 4.2.2. Data siswa yang berkaitan dengan ranah kognitif IPA

Data ranah kognitif IPA ini berkaitan dengan interaksi siswa pada proses evaluasi (ujian online) dari sistem *e-Learning* Siswa. Siswa yang terlibat adalah 113 siswa. Mereka secara bersamaan mengakses sistem *e-Learning* berdasarkan waktu yang ditentukan. Ada 25 pertanyaan yang dimasukkan oleh guru ke sistem. Dalam tes ini, setiap pertanyaan memberikan petunjuk yang membantu siswa dalam menyelesaikan soal tes. Waktu yang dibutuhkan untuk menyelesaikan setiap item dicatat. Oleh karena itu, ada 101 fitur dengan struktur sebagai berikut: Done1, ..., Done25, PercenTrue, Time1, ..., Time25, Hint1, ..., Hint25, Score1, ..., Score25. . Sehingga dalam database tersimpan 101 fitur dataset mentah. Tabel 4.2 menunjukkan data siswa yang tersimpan pada system yang dibangun.

Tabel 4.2 Fitur dan Tipe Data dari Ranah Kognitif Siswa IPA



Fitur	Tipe data
Done1	Numeric
...	...
Done25	Numeric
PercenTrue	Numeric
Time1	Numeric
...	...
Time25	Numeric
Hint1	Numeric
...	...
Hint25	Numeric
Score1	Numeric
...	...
Score25	Numeric

#### 4.3. Intisari data ranah kognitif siswa MIPA

Proses pengumpulan data dan deskripsi data ranah kognitif siswa MIPA terdiri dari 2 data siswa. Proses pengumpulan data ini melalui prosedur ilmiah. Data ranah kognitif siswa Matematika hanya dieksploitasi pada saat mencari strategi terbaik berkaitan dengan penyederhanaan fitur ranah kognitif siswa MIPA dengan metode ekstraksi fitur. Untuk pencarian strategi pada tahap-tahap selanjutnya, penelitian ini menggali data ranah kognitif siswa IPA.

- Halaman ini sengaja dibiarkan kosong -



## **BAB 5**

### **TRANSFORMASI DATA UNTUK MENINGKATKAN KINERJA PADA PEMODELAN RANAH KOGNITIF SISWA MIPA**

Penentuan prestasi belajar (*achievement*) siswa dalam dunia pendidikan saat ini bukan merupakan hal yang mudah untuk dilakukan. Banyaknya fitur dari data siswa merupakan salah satu tantangan yang harus diselesaikan. Beberapa penelitian mencoba membangun model untuk mengatasi ini. Namun, penelitian yang ada saat ini masih perlu ditingkatkan kinerjanya. Salah satu penyebabnya adalah data siswa ini seringkali mengandung *redundansi*, *noise*, antar fitur terdapat hubungan, fitur yang tidak relevan terhadap target dan sebagainya. Akibatnya, model yang dibangun tidak mencapai kinerja yang optimal. Padahal, kinerja model yang rendah akan menghasilkan banyaknya siswa yang salah dalam penentuan prestasi belajarnya, khususnya pada ranah kognitifnya. Untuk itu, peningkatan kinerja dari pemodelan ranah kognitif siswa, khususnya ranah kognitif siswa MIPA, sangat diperlukan. Salah satu caranya adalah menerapkan metode-metode pada tahap pra-pemrosesan sebelum data tersebut digali. Metode-metode ini antara lain: ekstraksi, diskritisasi, seleksi fitur dan sebagainya, yang semuanya terangkum dalam domain transformasi data.

Oleh karena itu, bab ini membahas upaya-upaya yang telah dilakukan untuk menemukan strategi terbaik dalam rangka meningkatkan kinerja dari model yang berkaitan dengan ranah kognitif siswa MIPA.

#### **5.1. Ekstraksi fitur**

Penelitian ini memecahkan masalah kinerja proses pengelompokan yang masih rendah, terutama: pengelompokan ranah kognitif siswa MIPA pada permainan yang serius. Hal ini dilakukan dengan ekstraksi fitur-fitur yang berkaitan dengan ranah kognitif siswa MIPA. Ekstraksi fitur ini dilandasi oleh kaidah bahwa rendahnya kinerja system dapat disebabkan oleh data yang tidak berada dalam kondisi ideal atau data yang tidak cocok (Tan, Steinbach, & Kumar, 2005). Penelitian ini



mengusulkan pengestrakan fitur berdasarkan kategori dan taksonomi bloom kemudian hasilnya dievaluasi dengan metode Fuzzy C Means. Hasil yang diharapkan dari ekstraksi fitur ini adalah kinerja yang lebih baik yang ditandai dengan meningkatnya tingkat akurasi dan pengurangan waktu eksekusi.

### **5.1.1. Arsitektur sistem ekstraksi fitur yang diusulkan**

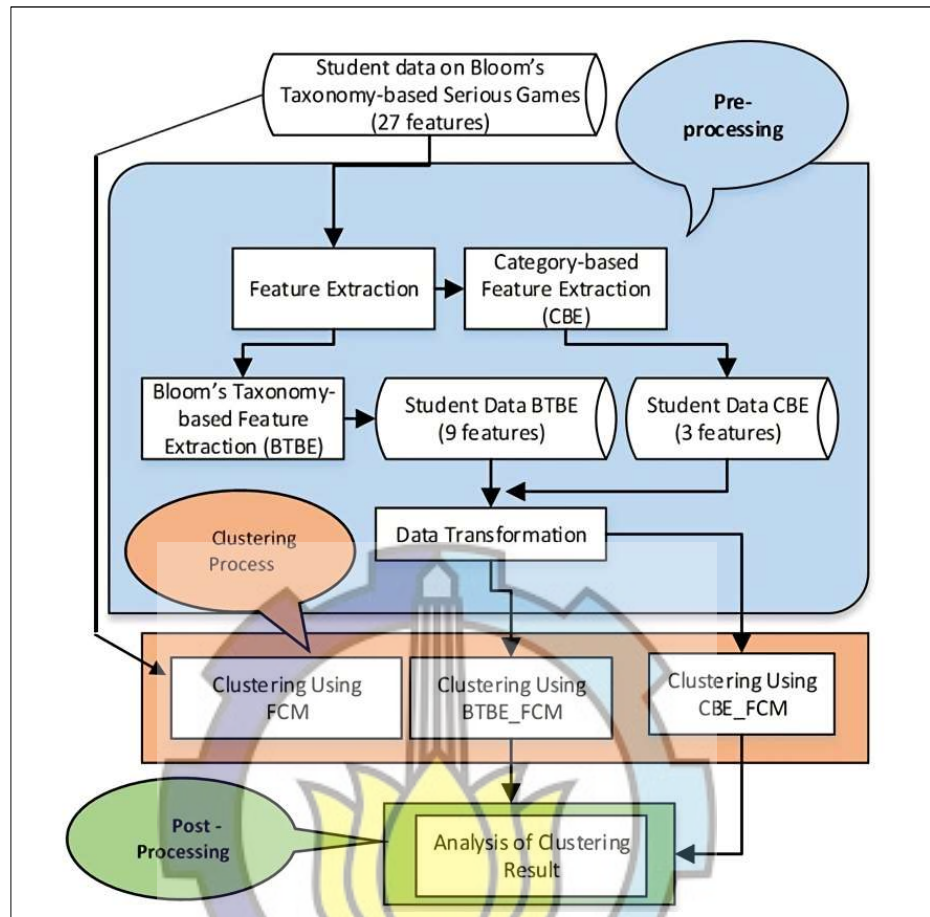
Keseluruhan sistem yang diusulkan digambarkan pada Gambar 5.1. Gambar ini menunjukkan bahwa ada 3 tahap, yaitu: pra-pemrosesan, pengelompokan dan pasca-pemrosesan. Pada tahap pertama, kami mengusulkan 2 metode ekstraksi: ekstraksi berbasis kategori (CBE) dan ekstraksi berbasis taksonomi (BTBE) bloom. Di sini, kedua metode dan metode asli dibandingkan untuk mendapatkan hasil terbaik.

Dalam proses pengelompokan ini, kami tidak membandingkan metode kami dengan yang lain. Ini karena, sejauh yang kami tahu, hanya ada sedikit penelitian dalam domain yang sama. Berbeda dari yang lain, kami melihat proses pengelompokan dari sudut pandang komputasi. Selain itu, kami tidak menggabungkan dua metode yang kami usulkan karena memiliki latar belakang yang berbeda.

Setelah fitur diekstraksi, fitur-fitur diubah. Ini dimaksudkan untuk menormalkan data yang dihasilkan. Selanjutnya, proses pengelompokan diterapkan. Kemudian, analisis kluster dilakukan pada tahap pasca-pemrosesan. Di sini, pengukuran akurasi dan waktu eksekusi dilakukan pada kinerja semua metode pengelompokan diperoleh.

#### **Ekstraksi Fitur Berbasis Kategori (CBE=*Category-Based feature Extraction*)**

Fitur dalam dataset asli harusnya memiliki informasi penting tetapi kadang-kadang memiliki bentuk yang tidak sesuai untuk diterapkan algoritma data mining. Salah satu cara yang bisa diterapkan adalah ekstraksi fitur yang dapat dilakukan dengan membuat fitur baru dari data mentah asli. Dalam hal ini, satu atau lebih fitur baru dibuat dari fitur asli dan mereka lebih berguna daripada fitur asli.



Gambar 5.1 Arsitektur sistem ekstraksi fitur yang diusulkan

Ekstraksi fitur pertama disebut CBE karena didasarkan pada kategori fitur. Sebenarnya, ada 3 kategori dalam data siswa pada bab sebelumnya (Tabel 4.1). Mereka adalah *Score*, *Time* dan *AccessToHelp*. Jadi, ekstraksi fitur dapat dilakukan berdasarkan pada kategori ini dan ditunjukkan hasilnya pada Tabel 5.1. Nilai fitur kategori diperoleh dari rata-rata nilai fitur penggabungan. Transformasi nilai fitur-fitur kategori diformulasikan dalam persamaan (5.1), (5.2) dan (5.3), dimana  $n$  adalah banyaknya item soal. Dalam penelitian ini, banyaknya item soal adalah 9, jadi  $n = 9$ .

$$Score = \frac{\sum_{j=1}^n Score_j}{n} \quad (5.1)$$

$$Time = \frac{\sum_{j=1}^n Time_j}{n} \quad (5.2)$$

$$AccessToHelp = \frac{\sum_{j=1}^n AccessToHelp_j}{n} \quad (5.3)$$

Tabel 5.1 Fitur dan Tipe Data dari Data Siswa yang Diekstrak Berbasis Kategori

Fitur	Tipe data
Score	Numerik
Time	Numerik
AccessToHelp	Numerik

Tabel 5.2 Fitur dan Tipe Data dari Data Siswa yang Diekstrak Berbasis Taksonomi Bloom

Fitur	Tipe data
Score C1	Numerik
Score C2	Numerik
Score C3	Numerik
Time C1	Numerik
Time C2	Numerik
Time C3	Numerik
AccessToHelp C1	Numerik
AccessToHelp C2	Numerik
AccessToHelp C3	Numerik

### Ekstraksi Fitur Berbasis Taksonomi (BTBE=*Bloom Taxonomy Based feature Extraction*)

Ekstraksi fitur kedua juga dapat dibuat dengan menggunakan taksonomi bloom, yang disebut BTBE. Hal ini sesuai dengan *serious game* berbasis taksonomi bloom yang digunakan untuk mengambil proses pengumpulan data siswa. Dari langkah ini, kami memperoleh data siswa yang terdiri dari 85 *record* dan 9 fitur Seperti yang disediakan pada Tabel 5.2 ini adalah *Score\_C1*, *Score\_C2*, *Score\_C3*, *Time\_C1*, *Time\_C2*, *Time\_C3*, *AccesToHelp\_C1*, *AccesToHelp\_C2*, *AccesToHelp\_C3*. Nilai-nilai fitur BTBE diperoleh dengan menghitung rata-rata setiap tiga fitur, seperti yang dijelaskan dalam persamaan (5.4) - (5.12):

$$Score\_C1 = \frac{\sum_{j=1}^{n_{C1}} Score_j}{n_{C1}} \quad (5.4)$$

$$Score\_C2 = \frac{\sum_{j=1}^{n_{C2}} Score_j}{n_{C2}} \quad (5.5)$$

$$Score\_C3 = \frac{\sum_{j=1}^{n_{C3}} Score_j}{n_{C3}} \quad (5.6)$$

$$Time\_C1 = \frac{\sum_{j=1}^{n_{C1}} Time_j}{n_{C1}} \quad (5.7)$$

$$Time\_C2 = \frac{\sum_{j=1}^{n_{C2}} Time_j}{n_{C2}} \quad (5.8)$$

$$Time\_C3 = \frac{\sum_{j=1}^{n_{C3}} Time_j}{n_{C3}} \quad (5.9)$$

$$AccessToHelp\_C1 = \frac{\sum_{j=1}^{n_{C1}} AccessToHelp_j}{n_{C1}} \quad (5.10)$$

$$AccessToHelp\_C2 = \frac{\sum_{j=1}^{n_{C2}} AccessToHelp_j}{n_{C2}} \quad (5.11)$$

$$AccessToHelp\_C3 = \frac{\sum_{j=1}^{n_{C3}} AccessToHelp_j}{n_{C3}} \quad (5.12)$$

Dimana,  $n_{C1}=3$  item soal C1,  $n_{C2}=3$  item soal C2 dan  $n_{C3} =3$  item soal C3. Penggunaan nilai-nilai tersebut masih mewakili nilai-nilai asli. Selain itu, metode ini lebih sederhana daripada yang sebelumnya, misalnya: memilih nilai baru dari fitur yang tersedia dengan menggunakan metode yang ditentukan. Ini mungkin menghasilkan akurasi yang lebih baik tetapi membutuhkan waktu eksekusi lebih banyak.

Sebelum digunakan sebagai input untuk proses pengelompokan, data yang diekstraksi ditransformasikan untuk mengurangi waktu perhitungan. Normalisasi ini menghasilkan data yang lebih kecil. Seperti yang digambarkan dalam langkah 1-3 dengan n adalah banyaknya data dan  $X_i$  adalah nilai tiap data ke-i, proses ini dilakukan sebagai berikut.

**Langkah 1:** Menghitung mean dari data original,

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (5.13)$$

**Langkah 2:** Menghitung standar deviasi

$$SD_x = \sqrt{\frac{1}{n-1} \sum_i (X - \bar{X}_i)} \quad (5.14)$$

**Langkah 3:** Ubah data ke data standar dengan menggunakan rumus Z-score seperti pada persamaan 2.1.

Dalam penelitian ini, proses ekstraksi fitur yang diusulkan ini dikombinasikan dengan algoritma FCM umum dari penelitian (Bezdek, 1984).

### 5.1.2. Hasil uji coba dan pembahasan dari metode ekstraksi fitur

Bagian ini membahas implementasi metode yang diusulkan. Pada langkah pertama, kami mengamati hasil eksperimen pengelompokan pada prestasi siswa untuk ketiga metode yang hasilnya divisualisasi dalam Gambar. 5.2, 5.3 dan 5.4. Hasil visualisasi menunjukkan bahwa metode CBE\_FCM memiliki visualisasi hasil clustering terbaik. Dalam penelitian ini, kami menganalisis tingkat akurasi dan waktu eksekusi.

Tabel 5.3 Matrik *Confusion* dari 3 Metode

	Fitur	Predicted: No	Predicted: Yes
FCM	Actual: No	42	15
	Actual: Yes	15	13
CBE_FCM	Actual: No	43	14
	Actual: Yes	14	14
BTBE_FCM	Actual: No	44	13
	Actual: Yes	13	15

### Tingkat akurasi

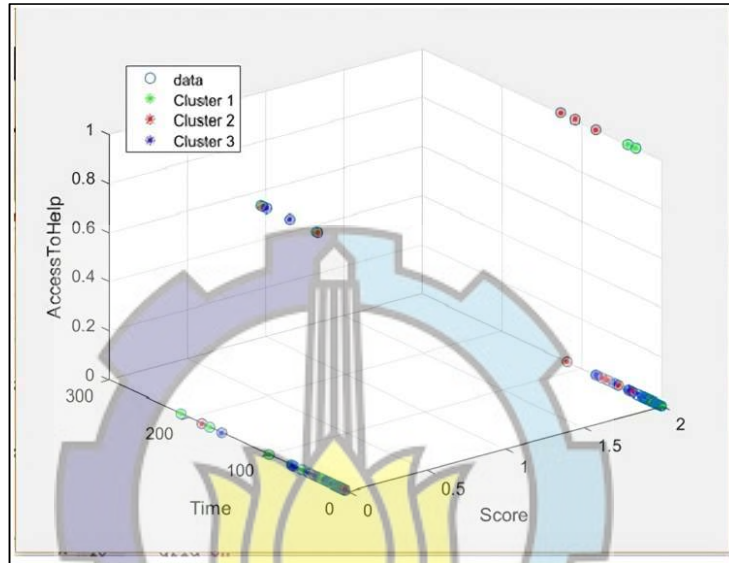
Untuk mengukur akurasi, kami mendefinisikan tiga langkah yang harus dilakukan.

Yaitu:

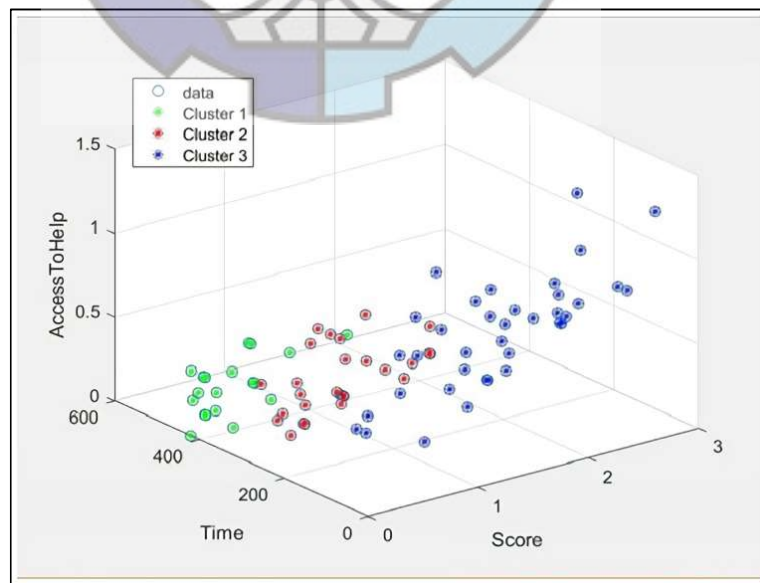
**Langkah 1:** Jalankan FCM, CBE\_FCM dan BTBE\_FCM 10 kali

**Langkah 2:** Simpan label masing-masing klaster


**Langkah 3:** Kalkulasi akurasi dari tiap *running*



Gambar 5.2 Luaran FCM pada pengklasteran ranah kognitif siswa MIPA



Gambar 5.3 Luaran CBE\_FCM pada pengklasteran ranah kognitif siswa MIPA



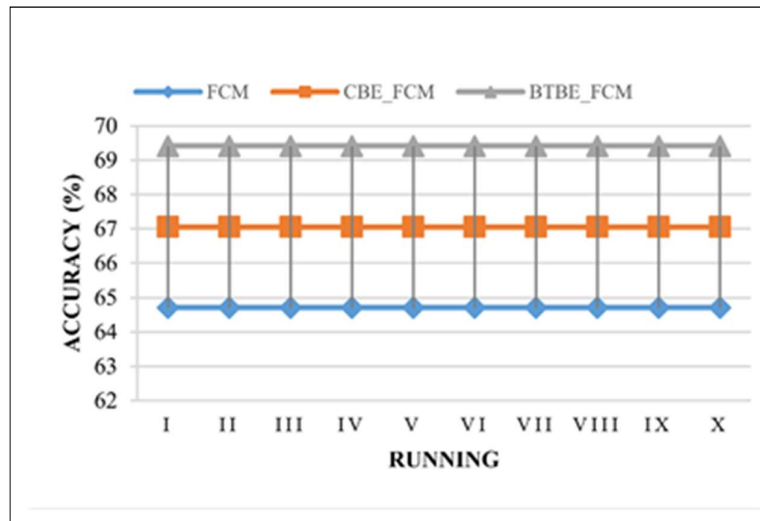
Gambar 5.4 Luaran BTBE\_FCM pada pengklasteran ranah kognitif siswa MIPA

Dari percobaan, kami memperoleh bahwa untuk semua *running*, keakuratan FCM, CBE\_FCM dan BTBE\_FCM masing-masing adalah 0.64705, 0.67058 dan 0.69411 yang dihitung dari matrik *confusion* pada Tabel 5.3. Di sini, banyaknya siswa (N) adalah 85.

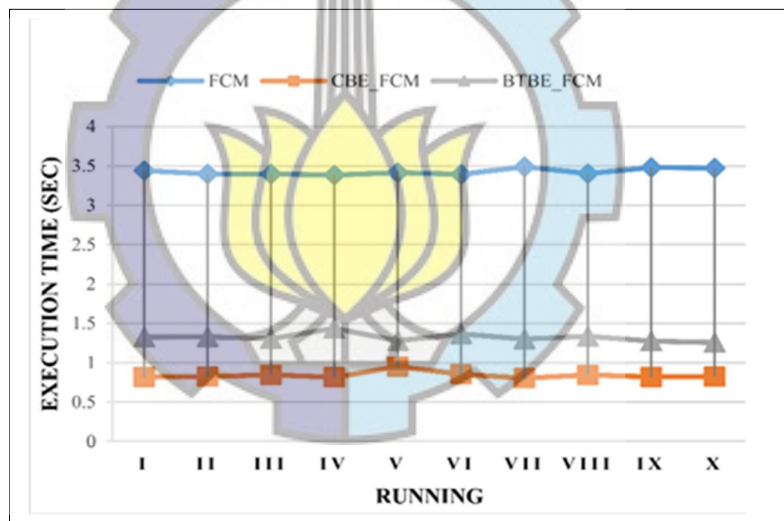
Akurasi dalam bentuk prosentasi (%) dideskripsikan pada Gambar 5.5. Gambar ini membandingkan akurasi 3 metode dengan sepuluh kali *running*. FCM dengan fitur asli memiliki akurasi terendah, yaitu sekitar 64.7%; BTBE\_FCM menghasilkan akurasi yang tertinggi, yaitu sekitar 69.4%. Sementara, CBE\_FCM berada level akurasi dengan posisi di tengah. Jadi, dalam hal level akurasi, BTBE\_FCM dapat meningkatkan kinerja sekitar 4.7%. Sementara, CBE\_FCM meningkat sekitar 2.3%.

### Waktu eksekusi

Penelitian ini juga mengukur waktu eksekusi. Hasil dari sepuluh kali disediakan pada Gambar 5.6. Gambar ini memvisualisasikan waktu eksekusi dari ketiga metode. Hasil memperlihatkan bahwa waktu eksekusi rata-rata CBE\_FCM adalah sekitar 0,8 detik dan ini merupakan yang waktu eksekusi terendah.



Gambar 5.5 Level akurasi dari 3 metode

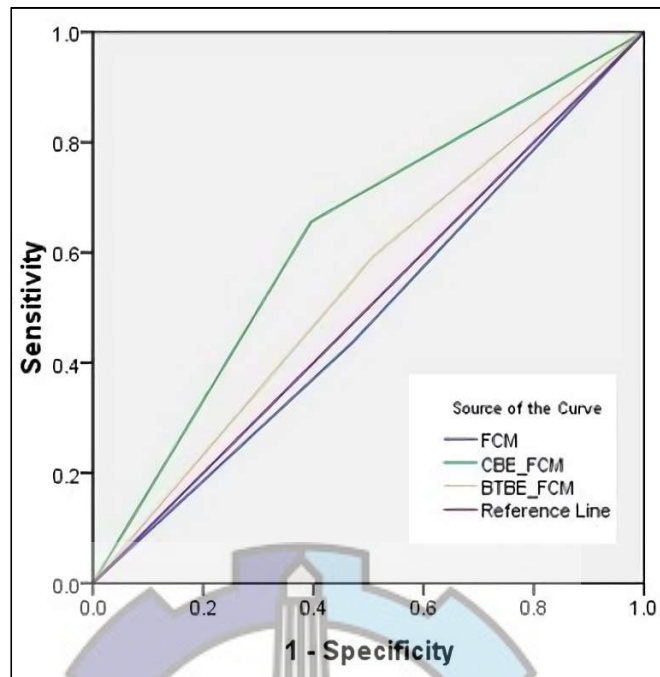


Gambar 5.6 Waktu Eksekusi dari 3 Metode

Tabel 5.4 Area Under Curve (AUC) dari 3 Metode

Test Result Variable	Area	Std. Error	Asymptotic Sig.	Asymptotic 95% Confidence Interval	
				Lower Bound	Upper Bound
FCM	0.483	0.065	0.793	0.356	0.610
CBE_FCM	0.630	0.063	0.045	0.507	0.753
BTBE_FCM	0.542	0.065	0.517	0.415	0.669





Gambar 5.7 ROC-1-Specificity dan Sensitivity dari 3 Metode

Tabel 5.5 Koordinat Kurva dari 3 Metode

Test Result Variable(s)	Positive if Greater Than or Equa Tol	Sensitivity	1-Specificity
FCM	-1.00	1.000	1.000
	0.50	0.438	0.472
	2.00	0.000	0.000
CBE_FCM	-1.00	1.000	1.000
	0.50	0.656	0.396
	2.00	0.000	0.000
BTBE_FCM	-1.00	1.000	1.000
	0.50	0.594	0.509
	2.00	0.000	0.000

Di sisi lain, waktu eksekusi tertinggi ditunjukkan oleh FCM, yaitu sekitar 3.5 detik. Di sini, BTBE\_FCM memiliki nilai yang lebih baik, yaitu sekitar 1.3 detik. Secara keseluruhan, BTBE\_FCM dan CBE\_FCM mengurangi waktu eksekusi sekitar 2.2 dan 2.7 detik.

Selain itu, data tersebut dapat digunakan untuk melakukan plot dalam ROC (*Receiver Operating Characteristic*). Gambar ini menunjukkan *trade-off* antara sensitivitas dan spesifisitas. Area di bawah kurva (AUC) dari masing-masing metode ditunjukkan pada Gambar 5.7 yang kurva koordinatnya ditampilkan pada Tabel 5.5. Tabel ini menunjukkan bahwa CBE\_FCM mencapai kinerja terbaik di antara yang lainnya. Ini dapat ditunjukkan oleh area di bawah kurva (AUC) = 0.630. ROC ini juga memperlihatkan bahwa CBE\_FCM dan BTBE\_FCM mempunyai AUC yang lebih luas dari FCM\_fitur asli, yaitu: 0.542 and 0.483.

### 5.1.3. Intisari ekstraksi fitur pada ranah kognitif siswa MIPA


Dalam studi ini, kami mengusulkan metode untuk ekstraksi fitur. Ini terutama digunakan dalam kumpulan data pendidikan. Ekstraksi fitur berdasarkan kategori (CBE\_FCM) dan Bloom's Taxonomy (BTBE\_FCM) terbukti mampu meningkatkan kinerja proses pengelompokan pada ranah kognitif siswa MIPA, dalam hal tingkat akurasi dan waktu *running* dan telah dipublikasikan oleh (Yuni Yamasari et al., 2016)

## 5.2. Diskritisasi fitur

Penelitian ini mengeksplorasi diskritisasi fitur yang berkaitan dengan ranah kognitif siswa MIPA. Hasil diskritisasi dikombinasikan dengan metode regresi logistik. Penelitian ini dilatarbelakangi oleh penelitian sebelumnya (Yuni Yamasari et al., 2018) yang telah terbukti meningkatkan proses prediksi sehingga lebih akurat dengan penggabungan diskritisasi dan regresi logistik ini. Namun, penelitian sebelumnya ini, metode ini diterapkan pada ranah kognitif *engineering*, khususnya bahasa pemrograman. Untuk itu, penelitian ini menerapkan metode diskritisasi pada ranah kognitif siswa MIPA

### 5.2.1. Kerangka kerja diskritisasi fitur yang diusulkan

Pada bagian ini, kerangka kerja yang diusulkan dideskripsikan dan terdiri dari beberapa langkah, sebagai berikut:



Gambar 5.8 Kerangka kinerja diskritisasi fitur yang diusulkan

**Langkah 1:** Mengekstrak fitur berdasarkan kategori

Ekstraksi ini didasarkan dari penelitian sebelumnya yang telah terbukti meningkatkan kinerja model ranah kognitif siswa MIPA (Yuni Yamasari et al., 2016). Fitur baru hasil dari ekstraksi menggunakan rumus yang disajikan pada persamaan (5.15) – (5.19) dengan  $n = 25$  item soal. Hasil ekstraksi disajikan pada Tabel 5.6.

$$Done = \sum_{i=1}^n question_i \tag{5.15}$$

$$PercentTrue = \frac{\sum_{i=1}^n question_i = true}{n} \tag{5.16}$$

$$Time = \sum_{i=1}^n time_i \tag{5.17}$$

$$Hint = \sum_{i=1}^n hint_i \tag{5.18}$$

$$Score = \sum_{i=1}^n score_i \tag{5.19}$$

**Langkah 2:** Melakukan diskritisasi

Data siswa adalah variabel kontinu yang telah diekstraksi, kemudian diskritisasi dilakukan ke banyak interval: tiga interval, empat interval, dan lima interval. Di sini, kami menggunakan metode diskritisasi yang disebut interval lebar

yang sama (*Equal width interval*). Metode ini ditujukan untuk mengkategorikan data yang sebelumnya kontinyu.

Tabel 5.6 Domain Kognitif Siswa MIPA dengan Fitur yang Terekstraksi Berbasis Kategori

Fitur	Tipe data	Deskripsi
Done	Numerik	Banyaknya soal yang dikerjakan
PercentTrue	Numerik	Prosentasi soal yang dijawab benar
Time	Numerik	Waktu yang dibutuhkan untuk menyelesaikan masing-masing soal
Hint	Numerik	Banyaknya petunjuk yang dipergunakan dalam pengerjaan tes
Score	Numerik	Skor yang diperoleh

### **Langkah 3:** Mengkombinasikan hasil diskritisasi dengan regresi logistik

Kami mengusulkan regresi logistik sebagai kombinasi dari metode diskritisasi yang telah dilakukan. Fitur target kami adalah *score* yang diasumsikan sebagai capaian pengetahuan siswa MIPA. Langkah ini dilakukan untuk mengetahui berapa interval yang paling optimal. Regresi logistik mempelajari model regresi logistik dari data. Jadi, algoritma pembelajaran regresi logistik adalah sebagai pembelajar.

Regresi logistik adalah model regresi dengan variabel dependen kategori (Freedman, 2009). Selanjutnya, regresi logistik yang dieksploitasi oleh penelitian ini menerapkan 2 regularisasi, yaitu: lasso (Tibshirani, 1996) dan ridge (Swindel, 1981)(Draper & van Nostrand, 1979) untuk meningkatkan akurasi dari prediksi.

### **Langkah 4:** Menganalisis hasil

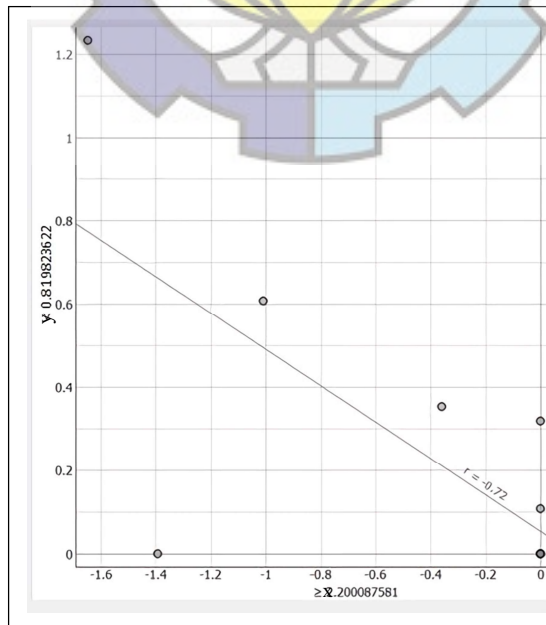
Pada langkah ini, kami menganalisis hasil eksperimen. Kami membandingkan satu sama lain untuk menemukan hasil terbaik yang ditunjukkan oleh nilai optimal dalam istilah akurasi level.

## **5.2.2. Hasil uji coba dan pembahasan dari metode diskritisasi fitur**

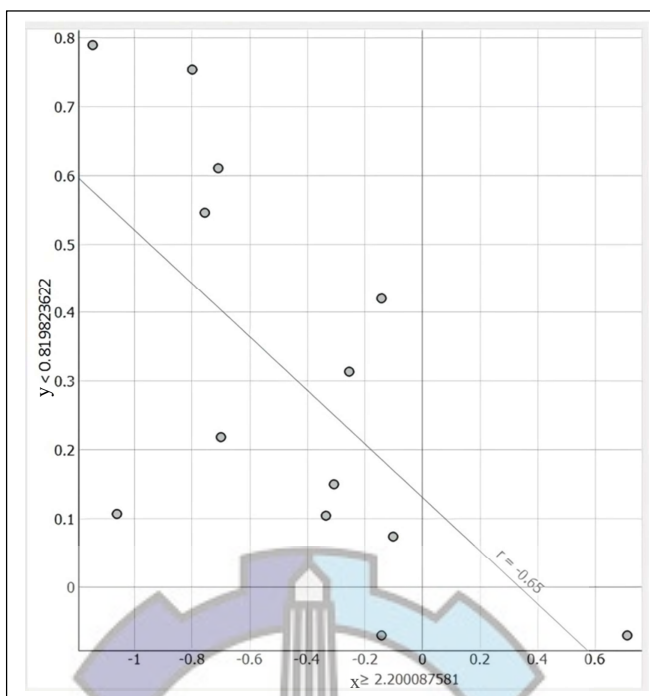
Eksekusi kerangka kerja yang diusulkan dijelaskan di bagian ini. Selanjutnya, kami menganalisis hasil eksperimen. Kami mengukur kinerja model dari kombinasi

diskritisasi pada 3 interval, 4 interval dan 5 interval dengan regresi logistik. Di sini, kami menerapkan 2 regulasi pada regresi logistik, yaitu: lasso dan ridge.

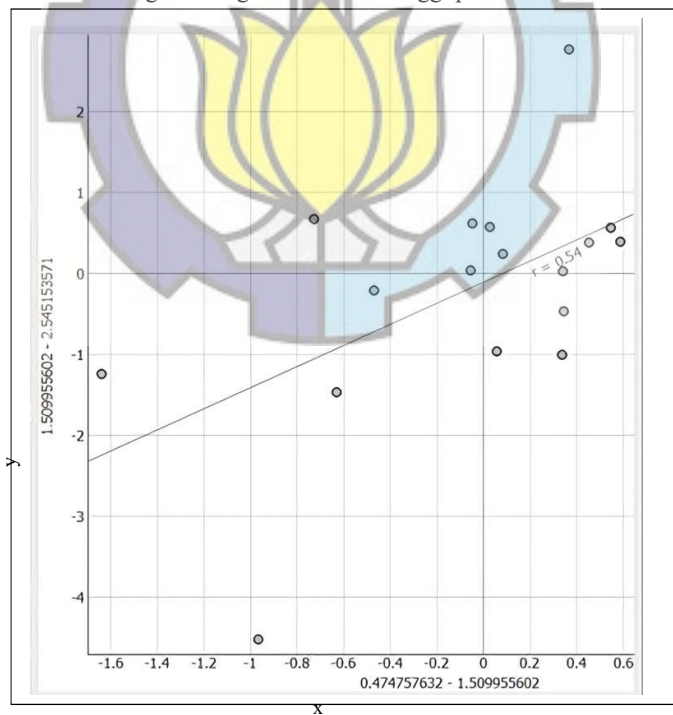
Pembahasan pertama difokuskan pada garis regresi yang terbentuk setelah hasil diskritisasi dikombinasikan dengan regresi logistic. Kami sajikan pada Gambar 5.9-5.14 yang menggambarkan korelasi tertinggi dari garis regresi pada semua regulasi dan semua interval. Dalam Gambar ini, kita dapat melihat bahwa Gambar 5.9-5.10, Gambar 5.11-5.12, dan Gambar 5.13-5.14 diperoleh dari diskritisasi-3 interval, diskritisasi-4 interval, dan diskritisasi-5 interval, masing-masingnya. Secara keseluruhan, garis regresi mencapai korelasi tertinggi pada diskritisasi 3 interval dengan regulasi lasso yang ditunjukkan dengan  $r=-0.72$  untuk sumbu  $x \geq 2.200087581$  dan sumbu  $y < 0.819823622$ . Sebaliknya, garis regresi mengalami korelasi terendah terjadi pada diskritisasi 5 interval dengan regulasi ridge yang ditunjukkan dengan  $r=0.03$  untuk sumbu  $1.095876414 < x < 1.924034789$ . Untuk detailnya, garis regresi mencapai korelasi tertinggi pada regulasi lasso untuk masing-masing diskritisasi-3 interval, diskritisasi-4 interval, dan diskritisasi-5 interval adalah  $r=-0.72$ ,  $r=0.54$ , dan  $r=0.44$ . Sementara, korelasi tertinggi pada regulasi ridge untuk masing-masing diskritisasi-3 interval, diskritisasi-4 interval, dan diskritisasi-5 interval adalah sebagai berikut:  $r=-0.65$ ,  $r=-0.58$  dan  $r=-0.62$ .



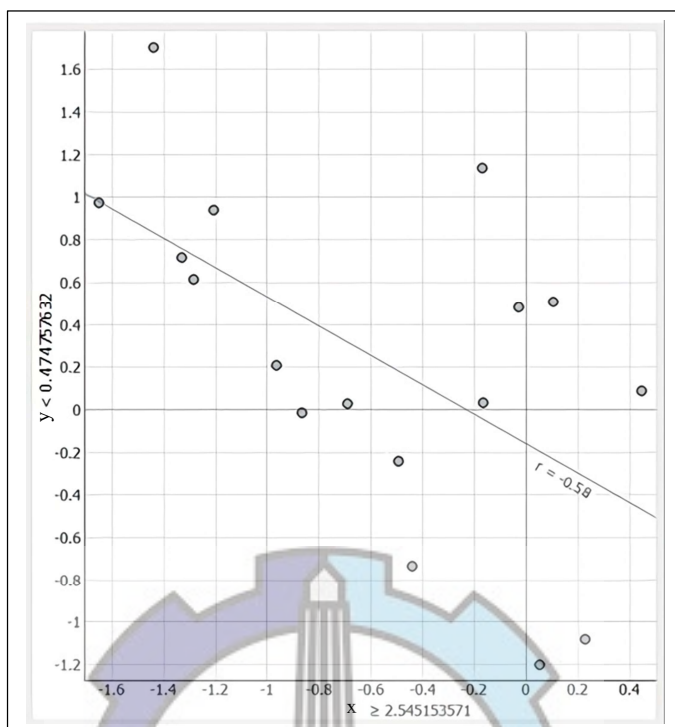
Gambar 5.9 Garis regresi dengan korelasi tertinggi pada diskritisasi-3 interval-lasso



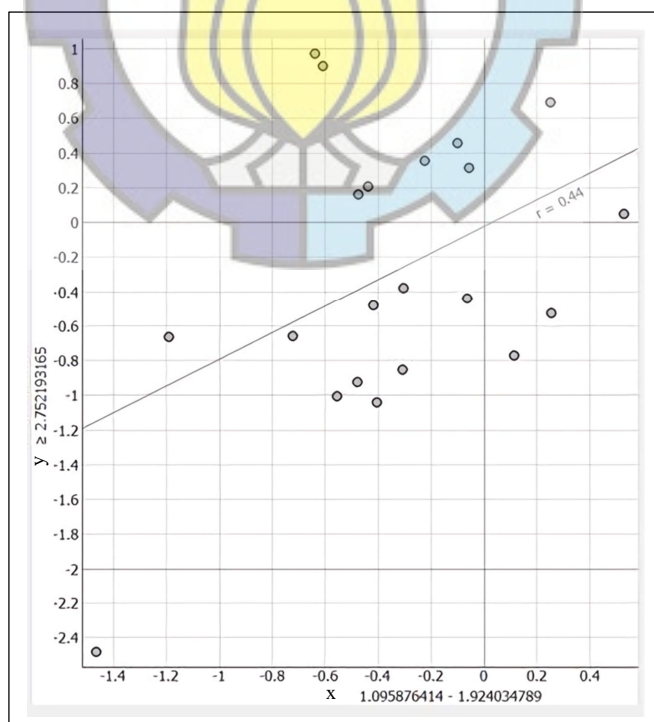
Gambar 5.10 Garis regresi dengan korelasi tertinggi pada diskritisasi-3 interval-ridge



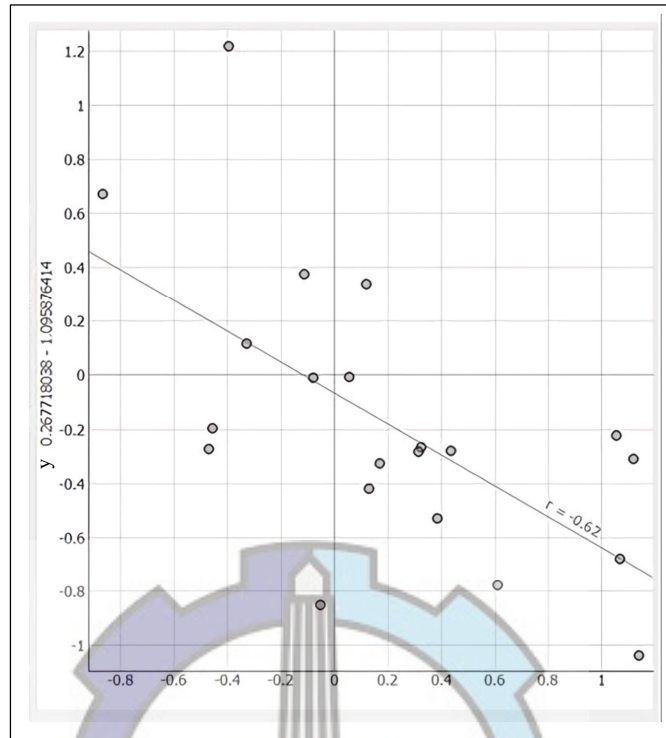
Gambar 5.11 Garis regresi dengan korelasi tertinggi pada diskritisasi-4 interval-lasso



Gambar 5.12 Garis regresi dengan korelasi tertinggi pada diskritisasi-4 interval-ridge



Gambar 5.13 Garis regresi dengan korelasi tertinggi pada diskritisasi-5 interval-lasso



Gambar 5.14 Garis regresi dengan korelasi tertinggi pada diskritisasi-5 interval-ridge

Pembahasan selanjutnya mengenai kinerja regresi logistik, dalam istilah akurasi level. Metode diskritisasi pada semua interval dan semua regulasi disajikan pada Tabel 5.7 –Tabel 5.9. Langkah ini dilakukan untuk menganalisa interval dan regulasi yang mana yang mempunyai kinerja pada regresi logistik terbaik. Ujicoba dilakukan pada ukuran *training set* kelipatan 10 dari 10%-60% dan perulangan train 2, 3, 5, 10 dan 20.

Hasil uji coba dari kombinasi diskritisasi 3 interval dan regresi logistik regulasi lasso dan ridge disajikan pada Tabel 5.7. Tabel tersebut memperlihatkan level akurasi tertinggi adalah sebesar 85.3% terjadi pada skenario ujicoba ukuran *training set* 10% dan 40% dengan semua setting *repeat train* untuk regulasi lasso. Sedangkan pada regulasi ridge, skenario ujicoba adalah ukuran *training set* 40% dengan *repeat train* 2, 3, 5 dan ukuran *training set* 50% dengan *repeat train* 5. Sebaliknya, pada diskritisasi 3 interval, regresi logistik dengan regulasi lasso mengalami level akurasi terendah sebesar 84.2% terjadi pada skenario ujicoba ukuran *training set* 50% untuk semua *repeat train*. Sedangkan pada regresi logistik



dengan regulasi ridge mengalami level akurasi terendah sebesar 83% pada ukuran *training set* 60% dan *repeat train* 3.

Tabel 5.7 Akurasi Level dari Kombinasi Regresi Logistik Semua Regulasi dan Diskritisasi 3 Interval

Training set size	3-interval-lasso					3-interval-ridge				
	Repeat train									
	2	3	5	10	20	2	3	5	10	20
10%	85.3	85.3	85.3	85.3	85.3	84.8	85	84.9	84.7	84.5
20%	84.6	84.6	84.6	84.6	84.6	84.6	84.6	84.6	84.4	84.4
30%	85	85	85	85	85	85	85	84.8	84.9	84.9
40%	85.3	85.3	85.3	85.3	85.3	85.3	85.3	85.3	85.1	85.2
50%	84.2	84.2	84.2	84.2	84.2	84.2	83	85.3	83.9	83.9
60%	84.8	84.8	84.8	84.8	84.8	84.8	84.8	84.8	84.8	84.8

Tabel 5.8 Akurasi Level dari Kombinasi Regresi Logistik dan Diskritisasi 4 Interval Semua Regulasi

Training set size	4-interval-lasso					4-interval-ridge				
	Repeat train									
	2	3	5	10	20	2	3	5	10	20
10%	79.4	80.1	80.6	81	81.2	79.9	80.4	80.8	80.5	80.3
20%	80.2	80.6	80.9	81.1	81.1	80.8	81	80.7	81	80.9
30%	78.7	79.6	80.2	80.7	80.9	80.6	80.4	80.5	80.9	80.7
40%	79.4	79.9	79.7	80	80.4	79.4	79.4	80	80.1	80.5
50%	78.9	79.5	80	80.4	80.3	80.7	80.7	80.7	80.5	80.4
60%	82.6	82.6	82.6	82.6	82.6	80.4	81.2	81.7	82	82

Hasil uji coba dari kombinasi diskritisasi 4 interval dan regresi logistik regulasi lasso dan ridge pada Tabel 5.8. Tabel tersebut memperlihatkan level akurasi tertinggi pada kedua regulasi terjadi pada scenario ujicoba ukuran *training set* 60%. Untuk lasso, level akurasi tertinggi sebesar 82.6% pada semua *repeat train*. Sedangkan, ridge mencapai level akurasi tertinggi sebesar 82% pada skenario ujicoba pada *repeat train* 10 dan 20. Sedangkan, level akurasi terendah sebesar 78.7% dialami oleh regulasi lasso pada skenario ujicoba adalah ukuran *training set* 30% dengan *repeat train* 2. Untuk ridge, level akurasi terendahnya sebesar 79.4%

dialami pada scenario ujicoba dengan ukuran *training set* 40% dengan *repeat train* 2 dan 3.

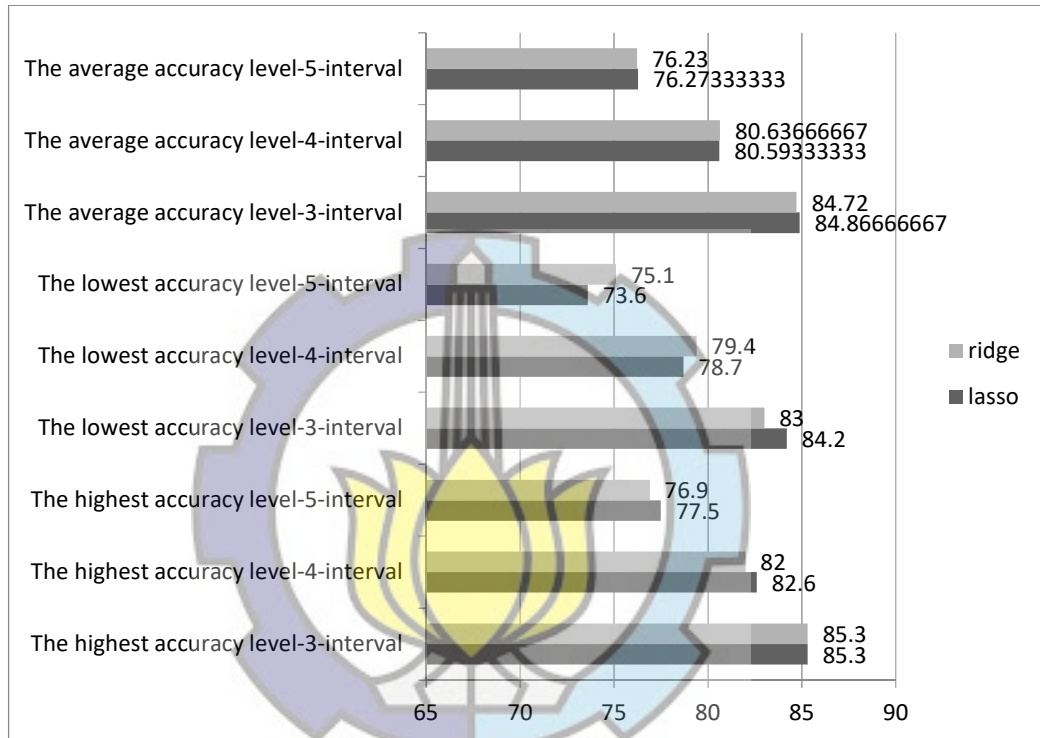
Tabel 5.9 Akurasi Level dari Kombinasi Regresi Logistik dan Diskritisasi 5 Interval Semua Regulasi

Training set size	5-interval-lasso					5-interval-ridge				
	Repeat train									
	2	3	5	10	20	2	3	5	10	20
10%	77.5	77.5	77.3	77.5	77.3	76	76.8	76.5	76.7	76.5
20%	75.3	73.6	74.9	75.9	76.3	75.8	75.1	75.8	76.3	76.5
30%	76.9	76.7	76	75.7	75.7	76.9	76.7	76.7	76.5	76.4
40%	76.5	76.5	75.6	76	76.2	76.5	76.5	75.6	75.9	75.9
50%	77.2	76	76.5	76.3	76.8	76.3	76	76.1	76.1	76.7
60%	76.1	76.1	76.1	76.1	76.1	76.1	76.1	76.1	75.9	75.9

Hasil uji coba dari kombinasi diskritisasi 5 interval dan regresi logistik regulasi lasso dan ridge pada Tabel 5.9. Tabel tersebut memperlihatkan level akurasi tertinggi adalah sebesar 77.5% terjadi pada skenario ujicoba ukuran *training set* 10% pada hampir semua setting *repeat train* untuk regulasi lasso. Sedangkan, pada regulasi ridge, level akurasi tertinggi sebesar 76.9% dicapai pada scenario ujicoba dengan ukuran *training set* 30% dan *repeat train* 2. Sebaliknya, regresi logistik dengan regulasi lasso mengalami level akurasi terendah sebesar 73.6% terjadi pada skenario ujicoba ukuran *training set* 20% dan *repeat train* 3. Sedangkan pada regresi logistik dengan regulasi ridge mengalami level akurasi terendah sebesar 75.1% pada ukuran *training set* 20% dan *repeat train* 2.

Keseluruhan hasil ujicoba yang disajikan pada Tabel 5.7 –Tabel 5.9 memperlihatkan kondisi khusus, yaitu: pencapaian akurasi yang cukup tinggi dengan ukuran *training set* yang sedikit (10%). Hal ini terjadi kemungkinan karena data siswa yang terpilih dalam pembangunan model cukup mewakili. Lebih dari itu, data yang terpilih untuk *training set* ini sangat mungkin paling berpengaruh terhadap target. Sehingga, data ini cukup mewakili data secara keseluruhan walaupun hanya sedikit ukurannya.

Untuk lebih memperjelas hasil yang diperoleh, rerata level akurasi, level akurasi terendah dan level akurasi tertinggi disajikan pada gambar 5.15. Diskritisasi 3 interval mendominasi hasil tertinggi diantara yang lainnya, kemudian diikuti dengan diskritisasi 4 interval dan terakhir 5 interval pada semua regulasi dari regresi logistik.



Gambar 5.15 Perbandingan dari akurasi level pada semua interval

### 5.2.3. Intisari diskritisasi fitur pada ranah kognitif siswa

Metode diskritisasi interval lebar yang sama (*Equal width interval*) dapat dikombinasikan dengan regresi logistik dengan regulasi lasso dan ridge pada data ranah kognitif MIPA. Diantara interval yang telah dilakukan, kombinasi antara diskritisasi 3 interval pada ranah ini dan regresi logistik semua regulasi telah terbukti mencapai hasil terbaik, dalam istilah level akurasi tertinggi.

### 5.3. Pemilihan fitur

Studi tentang pemilihan fitur ini memberikan perhatian yang lebih dari para peneliti untuk meningkatkan kinerja pengklasteran. (Y. Yamasari et al., 2018) berupaya mencari strategi untuk meningkatkan kinerja sistem dengan pemilihan fitur secara random. Kemudian, (Yuni Yamasari & Qoiriah, 2017) menggunakan pemilihan fitur gain informasi. Hibrida fitur seleksi metode untuk menemukan fitur dominan (Yuni Yamasari, Nugroho, Yoshimoto, Takahashi, & Purnomo, 2020). Pemilihan fitur ini sendiri dilakukan untuk mengeliminasi fitur-fitur yang tidak relevan. Demikian juga, dengan penelitian ini, kami menerapkan pemilihan fitur Gini Index pada ranah kognitif MIPA pada siswa. Secara lebih rinci, disini, kami mengeksplorasi Gini Index. Kemudian, proses dilanjutkan dengan pengklasteran menggunakan K-means. Untuk mengukur kinerja yang dicapai, kami menggunakan evaluasi tanpa pengawasan: koefisien *silhouette*, uji-t dan ANOVA.

#### 5.3.1. Kerangka kerja pemilihan fitur yang diusulkan

Kerangka kerja keseluruhan dari metode yang diusulkan disediakan pada Gambar 5.16. Kerangka kerja ini menunjukkan bahwa ada lima langkah, yang dapat dijelaskan sebagai berikut:

**Langkah 1:** Ekstraksi fitur berbasis kategori. Hasil ekstraksi fitur ini telah ditunjukkan pada Tabel 5.6.

**Langkah 2:** Penentuan banyaknya kluster dengan fungsi koefisien *silhouette*. Fungsi ini dieksploitasi untuk menentukan jumlah kluster yang paling optimal. Rumus fungsi ini disajikan pada persamaan (5.21)

**Langkah 3:** Pemilihan fitur menggunakan Gini Index

Pada langkah ini, kami menerapkan metode pemilihan fitur untuk mengoptimalkan pengklasteran ranah kognitif siswa MIPA. Di sini, kami menemukan fitur yang relevan untuk proses pengelompokan dengan menggunakan gini index dari partisi data  $t$  yang mempunyai formula seperti pada persamaan (5.20)


$$Gini(t) = 1 - \sum_{i=0}^{c-1} [p_i]^2 \quad (5.20)$$

Dimana,  $c$  adalah banyaknya kelas dan  $p_i$  adalah probabilitas tuple  $t$  yang dimiliki oleh kelas  $c_i$ .

**Langkah 4:** Proses pengelompokkan dengan K-means

Untuk proses pengklasteran, kami menerapkan salah satu metode populer (Peña-Ayala, 2014), yaitu K-means. Metode ini sering digunakan dalam *Educational Data Mining*.

**Langkah 5:** Analisa hasil dengan Koefisien *silhouette*, Anova dan uji-t.



Gambar 5.16 Kerangka kerja pemilihan fitur yang diusulkan

Untuk mengevaluasi pengklasteran, kami menerapkan metode tanpa pengawasan yang hanya menggunakan informasi internal. Pada langkah ini, kami mengeksplorasi nilai *silhouette* (Rousseeuw, 1987) pada setiap titik (Starczewski & Krzyzak, 2015). Ini adalah rasio titik cocok dengan titik-titik lain dalam sebuah cluster ketika dihadapkan dengan titik-titik di cluster lain. Dalam konteks ini, tingkat kesamaan tergantung pada jarak antar titik. Semakin mirip suatu titik dengan titik lain, semakin dekat suatu titik dengan titik lainnya. Nilai silhouette dari titik ke- $i$ ,  $S_i$ , dinyatakan dalam persamaan (5.21).

$$S_i = \frac{(b_i - a_i)}{\max(a_i, b_i)} \quad (5.21)$$

Di mana,  $a_i$  adalah jarak rata-rata yang dihitung antara titik ke- $i$  dan titik-titik lain yang berada di cluster  $i$ . Selain itu,  $b_i$  mewakili jarak minimum yang diukur antara titik ke titik lain di cluster lain. Nilai *silhouette* adalah dari -1 hingga +1, di mana nilai yang lebih tinggi berarti bahwa titik ke- $i$  lebih cocok untuk klasternya daripada ke klaster lain.

Lebih dari itu, kami juga melakukan analisis hasil pengklasteran dengan ANOVA sebagai evaluasi lainnya. Dalam penelitian ini, ANOVA digunakan untuk menyelidiki apakah klaster yang dihasilkan oleh masing-masing metode berbeda secara signifikan berdasarkan nilai *silhouette*-nya. Terakhir, evaluasi dilakukan menggunakan uji-t untuk melihat kualitas klaster antar 2 metode berdasarkan nilai *silhouette*-nya.

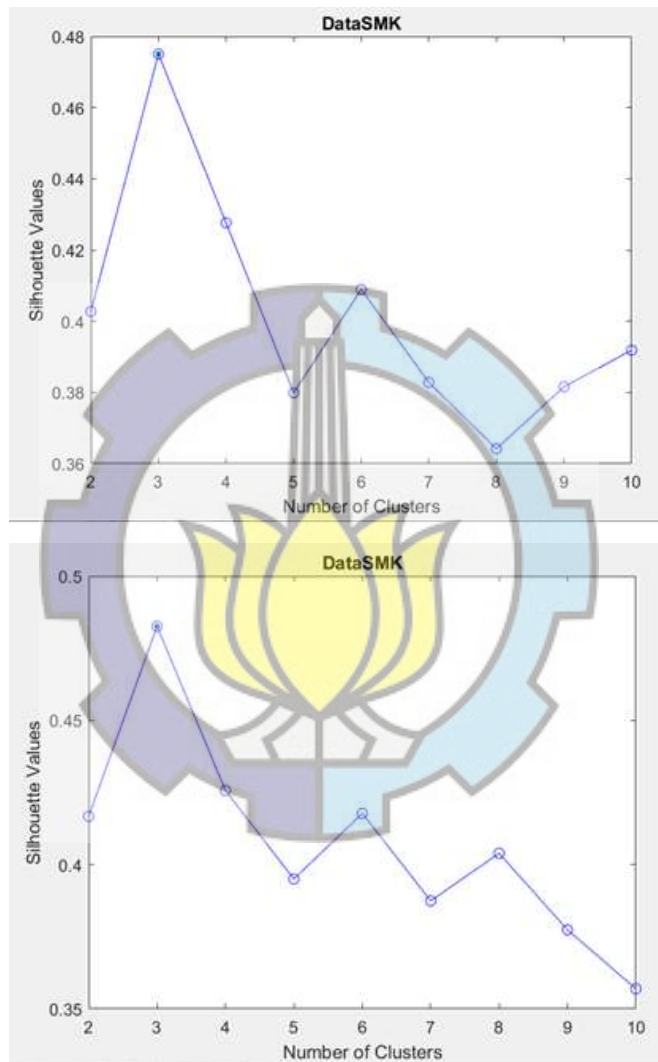
### 5.3.2. Hasil uji coba dan pembahasan dari metode diskritisasi fitur

Di bagian ini, kami menyelidiki eksekusi kerangka sistem yang diusulkan. Setelah fitur asli selesai diekstrak, kami mengeksploitasi koefisien *silhouette* yang mengacu untuk mengetahui banyaknya klaster yang paling optimal. Hasil dari 10 kali *running* menunjukkan bahwa banyaknya klaster yang paling optimal adalah 3 seperti terlihat pada Gambar 5.17. Keoptimalan ditunjukkan pada array nilai *silhouette* berikut ini: [NaN 0.4167 0.4826 0.4257 0.3950 0.4178 0.3874 0.4039 0.3774 0.3569].

Tahap selanjutnya, kami memilih fitur menggunakan Gini Index yang menghasilkan dua fitur yang terpilih: *done* dan *percenTrue*. Kemudian, kami menerapkan metode populer K-means dalam proses pengklasteran pada kedua set fitur, yaitu: set fitur asli dan set fitur terpilih. Visualisasi hasil pengklasteran diperlihatkan pada Gambar 5.18-5.19. Hasil pengklasteran menggunakan K-means pada set fitur asli ditunjukkan pada Gambar 5.18. Sedangkan, hasil pengklasteran menggunakan K-means pada set fitur terpilih disajikan pada Gambar 5.19. Dari visualisasi tersebut, hasil K-means pada set fitur terpilih mempunyai kualitas yang lebih baik dari hasil K-means pada set fitur asli yang ditinjau dari *intra* dan *between* klaster. *Intra* berkaitan kedekatan dalam satu klaster dan *between* berkaitan dengan keterjauhan antar klaster.

Langkah terakhir, kami menganalisa hasil dengan nilai *silhouette*, ANOVA dan uji-t. Nilai *silhouette* sendiri dapat digunakan untuk melihat validitas dari klaster yang dihasilkan, seperti yang dijelaskan di awal. Semakin sedikit nilai *silhouette* dibawah 0 maka validitas klaster itu semakin tinggi. Karena nilai 0 menunjukkan level kognitif siswa berada di antara 2 klaster dan nilai - (negatif) pada nilai *silhouette* yang menunjukkan ketidaktepatan siswa berada pada klaster


tersebut. Hasil *silhouette* menunjukkan bahwa validitas pada kombinasi K-means dan set fitur terpilih lebih tinggi dari kombinasi K-means pada set fitur yang asli. Hal ini dikarenakan nilai *silhouette* yang lebih kecil dari 0 pada kombinasi fitur yang terpilih dan K-means lebih sedikit pada kombinasi set fitur asli dan K-means seperti ditunjukkan pada Gambar 5.20.



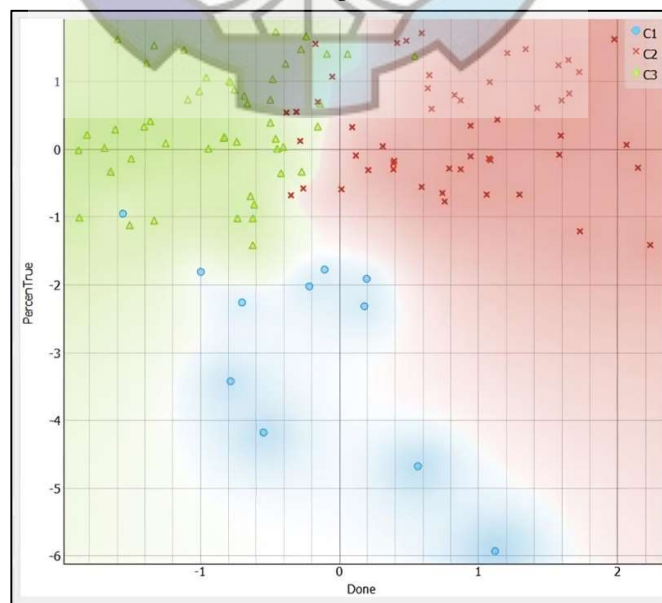
Gambar 5.17 Nilai *silhouette* yang menunjukkan banyaknya kluster yang paling optimal pada 2 dari 10 kali *running*

Lebih jauh, kami mengevaluasi hasil dari kluster dengan menggunakan ANOVA untuk menyelidiki apakah kluster yang dihasilkan oleh masing-masing metode berbeda secara signifikan berdasarkan nilai *silhouette*-nya. Jadi, evaluasi

menggunakan ANOVA ini dilakukan dua kali, yang pertama: hasil kluster pada kombinasi set fitur yang terpilih dan K-means dan yang kedua: hasil kluster pada kombinasi set fitur yang asli dan K-means.

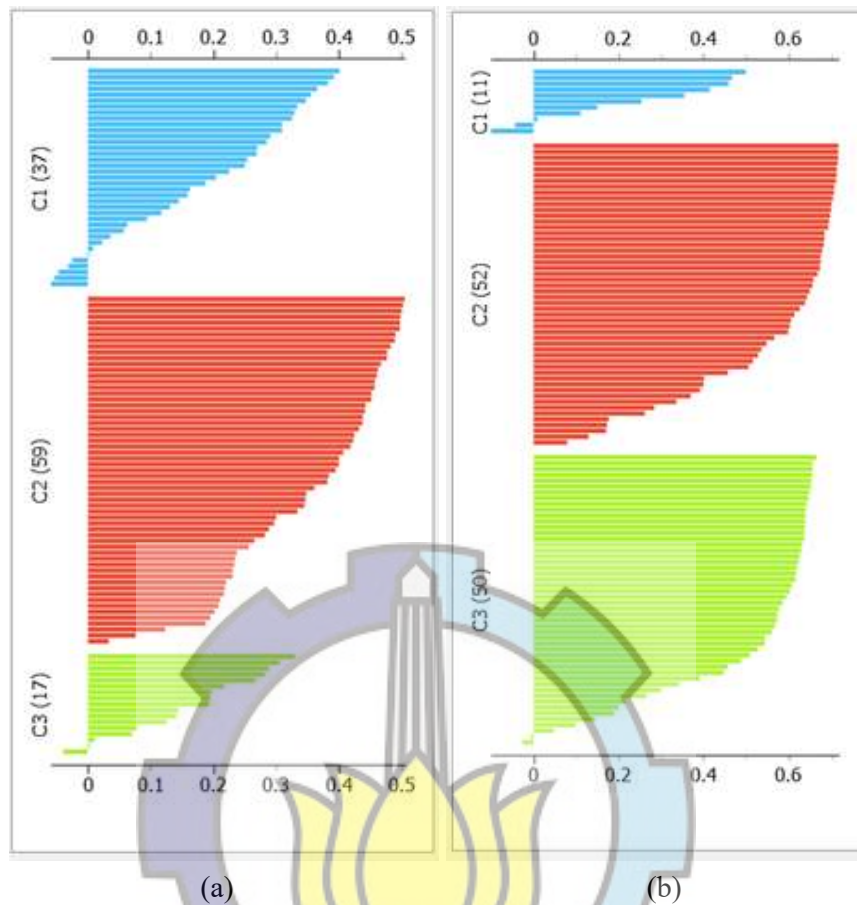


Gambar 5.18 Visualisasi hasil pengklasteran dengan set fitur asli & K-mean



Gambar 5.19 Visualisasi hasil pengklasteran dengan set fitur yang terpilih & K-means





Gambar 5.20 Gambar kiri (a) visualisasi nilai *silhouette* dari set fitur asli\_K-means dan Gambar kanan (b) visualisasi nilai *silhouette* dari set fitur terpilih\_K-means

Hipotesa dari uji ANOVA ini adalah sebagai berikut: rerata berdasarkan nilai *silhouette* dari hasil pengklasteran pada kombinasi K-means dan set fitur asli dan set fitur terpilih adalah:

H0: tidak ada perbedaan rerata nilai *silhouette* pada semua klaster yang dihasilkan (rerata *Silhouette* C1= rerata *Silhouette* C2= rerata *Silhouette* C3)

H1: ada perbedaan dari rerata nilai *silhouette* pada semua klaster yang dihasilkan (rerata *Silhouette* C1  $\neq$  rerata *Silhouette* C2  $\neq$  rerata *Silhouette* C3)

Dengan penetapan level *confidence* 95% dan alfa = 0.05. Ini berarti jika P-Value < alfa maka tolak H0.

Tabel 5.10 Analisis hasil kluster pada masing-masing kombinasi dengan ANOVA

Klaster 1	Klaster 2	Klaster 3	Klaster 1	Klaster 2	Klaster 3
0.584	0.568	0.546	0.503	0.525	0.676
0.511	0.59	0.54	0.625	0.541	0.673
0.541	0.572	0.587	0.647	0.556	0.634
0.584	0.511	0.561	0.639	0.555	0.677
0.52	0.566	0.522	0.548	0.582	0.666
0.621	0.603	0.544	0.468	0.554	0.678
0.612	0.583	0.503	0.486	0.603	0.679
0.603	0.573	0.602	0.535	0.613	0.684
0.619	0.606	0.561	0.579	0.622	0.681
0.616	0.573	0.568	0.637	0.588	0.681
0.55	0.616	0.594	0.609	0.637	0.637
0.485	0.626	0.562		0.649	0.681
0.481	0.606	0.583		0.655	0.687
0.551	0.568	0.525		0.66	0.667
0.596	0.574	0.501		0.664	0.681
0.601	0.569	0.59		0.657	0.684
0.492	0.565	0.487		0.672	0.681
0.483	0.642			0.675	0.664
0.609	0.645			0.678	0.685
...	...		...	...	

(a) Nilai silhouette dari kombinasi set fitur asli dan K-means

(b) Nilai silhouette dari kombinasi set fitur terpilih dan K-means

Hasil analisa pengklasteran dari kombinasi K-means dan set fitur asli disajikan pada Gambar 5.21. Anggota masing-masing kluster c1, c2, c3 adalah berturut-turut 37, 59 dan 17 siswa. Kemudian P-Value yang dihasilkan adalah 0, jadi tolak H0 dan terima H1. Ini berarti bahwa ada perbedaan yang signifikan dari nilai *silhouette* pada kluster yang dihasilkan oleh kombinasi K-means dan set fitur asli.

Sementara, hasil analisa pengklasteran dari kombinasi K-means dan set fitur terpilih disajikan pada Gambar 5.22. Member masing-masing kluster c1, c2, c3 adalah berturut-turut 11, 52 dan 50 siswa. Kemudian P-Value yang dihasilkan adalah 0, jadi tolak H0 dan terima H1. Ini berarti bahwa ada perbedaan yang signifikan dari nilai *silhouette* pada kluster yang dihasilkan oleh kombinasi K-means dan set fitur terpilih. Ini berarti validitas kluster dari kedua kombinasi pada

dasarnya tinggi karena kluster-kluster mempunyai perbedaan yang signifikan dari segi rerata nilai *silhouette* nya.

Level	N	Mean	StDev	Individual 95% CIs For Mean Based on Pooled StDev
c1	37	0.55732	0.04517	(-----*-----)
c2	59	0.60734	0.03506	(---*---)
c3	17	0.55153	0.03492	(-----*-----)

P  
0.000

Gambar 5.21 Hasil analisa pengklasteran dari kombinasi K-means dan set fitur asli dengan ANOVA

Level	N	Mean	StDev	Individual 95% CIs For Mean Based on Pooled StDev
c1	11	0.57055	0.06592	(-----*-----)
c2	52	0.65960	0.04808	(---*---)
c3	50	0.64422	0.05501	(-----*-----)

0.560    0.595    0.630    0.665

P  
0.000

Gambar 5.22 Hasil analisa pengklasteran dari kombinasi K-means dan set fitur terpilih dengan ANOVA

Terakhir, kami menganalisa kualitas hasil pengklasteran dari kedua metode. Kami melakukan uji-t pada rerata nilai *silhouette* dari kedua metode (kombinasi K-means & set fitur asli (OF) dan kombinasi K-means & set fitur terpilih (FS)) seperti diperlihatkan pada Tabel 5.11. Hipotesa dari uji-t ini adalah sebagai berikut: rerata berdasarkan nilai *silhouette* dari kedua metode adalah sebagai berikut:

H0: rerata nilai *silhouette* OF ((kombinasi K-means & set fitur asli) > rerata nilai *silhouette* FS (kombinasi K-means & set fitur terpilih).

Ini berarti bahwa (rerata *Silhouette* OF > rerata *Silhouette* FS)

H1: rerata nilai *silhouette* OF ((kombinasi K-means & set fitur asli) < rerata nilai *silhouette* FS (kombinasi K-means & set fitur terpilih)

Ini berarti bahwa (rerata *Silhouette* OF < rerata *Silhouette* FS)

Tabel 5.11 Nilai *silhouette* dari kombinasi K-means & set fitur asli(OF) dan kombinasi K-means & set fitur terpilih (FS)

<i>silhouette</i> OF	<i>silhouette</i> FS
0.584	0.503
0.511	0.625
0.541	0.647
0.584	0.639
0.52	0.548
0.621	0.468
0.612	0.486
0.603	0.535
0.619	0.579
0.616	0.637
0.55	0.609
0.485	0.525
0.481	0.541
0.551	0.556
0.596	0.555
0.601	0.582
0.492	0.554
0.483	0.603
0.609	0.613
0.537	0.622
0.578	0.588
0.507	0.637

	N	Mean	StDev	SE Mean
<i>silhouette</i> OF	113	0.5826	0.0463	0.0044
<i>silhouette</i> FS	113	0.6441	0.0584	0.0055

Difference = mu (*silhouette* OF) - mu (*silhouette* FS)  
 Estimate for difference: -0.06156  
 95% upper bound for difference: -0.04998  
 T-Test of difference = 0 (vs <): T-Value = -8.78 P-Value = 0.000 DF = 213

Gambar 5.23 Uji-t dari rerata nilai *silhouette* dari kedua metode

Dengan penetapan level *confidence* 95% dan alfa = 0.05 serta alternative less than Ini berarti jika P-Value < alfa maka tolak H0.

Hasil uji-t menunjukkan bahwa P-Value = 0. Ini berarti bahwa tolak H0 dan terima H1 seperti tersaji pada Gambar 5.23. Dengan demikian, kombinasi K-means & set

fitur terpilih (FS) lebih berkualitas dari kombinasi K-means & set fitur asli (OF) karena (rerata *Silhouette* OF < rerata *Silhouette* FS).

### 5.3.3. Intisari pemilihan fitur pada ranah kognitif siswa MIPA

Pemilihan fitur dengan menggunakan Gini Index dapat meningkatkan validitas klaster. Hasil pengukuran menunjukkan bahwa siswa yang memiliki level *silhouette* yang rendah berkurang. Hal ini juga didukung dengan hasil investigasi dari uji-t dan ANOVA yang menggambarkan hasil yang sama bahwa pemiliha fitur dapat meningkatkan level *silhouette* pada siswa.



## **BAB 6**

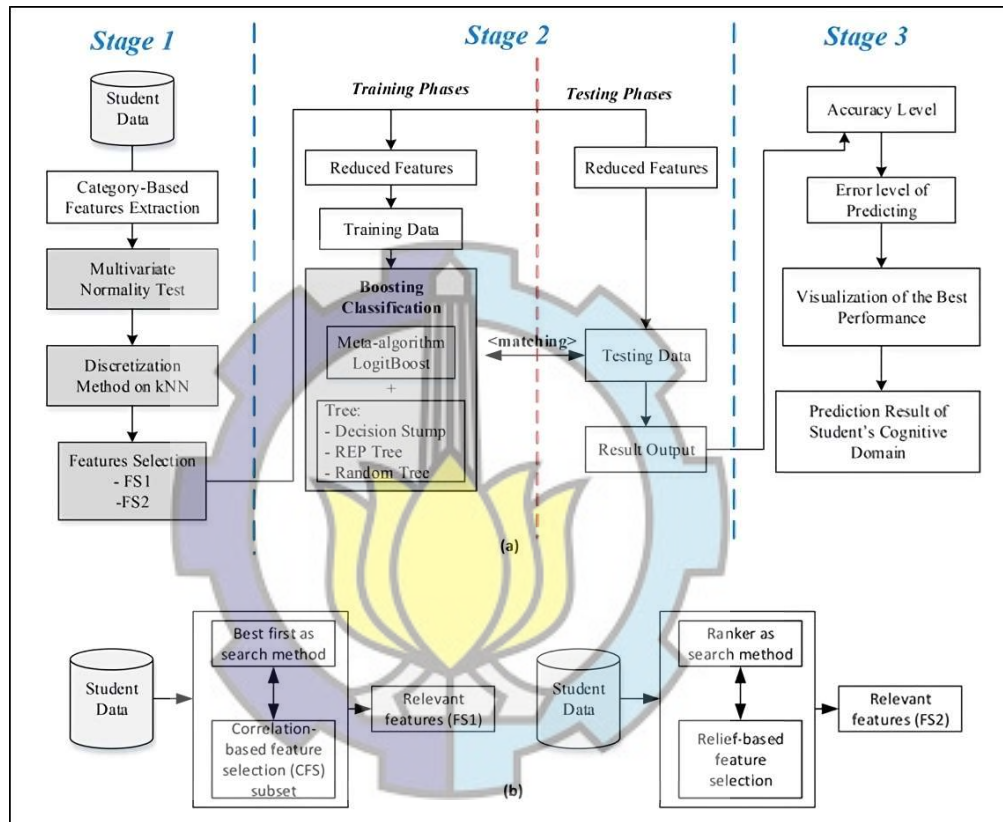
### **HIBRIDA DARI TRANSFORMASI DATA DAN LOGITBOOST UNTUK IDENTIFIKASI LEVEL KOGNITIF SISWA MIPA**

Penelitian ini bertujuan untuk meningkatkan kinerja pada proses identifikasi level kognitif siswa MIPA. Peningkatan ini dilakukan dengan penerapan meta-algoritma *Boosting*, yaitu: LogitBoost, yang dipadukan dengan Decision Stump, REP tree, dan Random tree. Selain itu, beberapa metode diusulkan dalam fase pra-pemrosesan. Diawali, analisa statistik uji normalitas multivariat untuk mendeteksi apakah data ranah kognitif siswa MIPA berasal dari distribusi populasi normal multivariat. Dilanjutkan, eskplorasi metode-metode yang berkaitan dengan transformasi data dengan cara mengembangkan dari penelitian-penelitian kami sebelumnya. Metode tersebut adalah ekstraksi fitur (Yuni Yamasari et al., 2016); metode diskritisasi yang dikombinasikan dengan k-NN yang mengembangkan dari penelitian kami sebelumnya (Yuni Yamasari et al., 2018) untuk mengubah data kontinyu ke data kategorikal. Metode ini diterapkan untuk mengetahui banyaknya tingkat kognitif siswa; dan metode pemilihan fitur untuk menghasilkan fitur yang paling berpengaruh terhadap target yang termotivasi oleh penelitian kami sebelumnya (Y. Yamasari et al., 2018), (Yuni Yamasari & Qoiriah, 2017); (Yuni Yamasari et al., 2020).

Setelah sistem terbangun, kinerja dari sistem yang diusulkan dievaluasi dalam konteks EDM. Dengan melakukan hibrida metode-metode tersebut, penelitian ini dimaksudkan untuk memperoleh kinerja yang tinggi sehingga sistem dapat mengidentifikasi level kognitif siswa MIPA secara lebih tepat.

## 6.1. Meta-algoritma LogitBoost (*Logistic Boosting*)

Pada bagian ini, kami menggambarkan arsitektur yang diusulkan dalam 3 tahap, yaitu tahap 1: fase pra-pemrosesan, tahap 2: fase penambangan data dan tahap 3: fase pasca-pemrosesan, yang secara keseluruhan digambarkan pada Gambar 6.1.



Gambar 6.1 (a) Arsitektur dari sistem yang diusulkan untuk mengidentifikasi tingkat kognitif siswa MIPA, (b) Desain metode pemilihan fitur

Tahap pertama adalah tahap pra-pemrosesan dan dibagian inilah, kami mengeksplorasi metode-metode transformasi data. Pada langkah pertama, kami mengadopsi fitur ekstraksi berdasarkan kategori (Yuni Yamasari et al., 2016) untuk meningkatkan proses penambangan. Di sini, data siswa diasumsikan mengandung 2 variabel dependen, yaitu: *percenTrue* dan *Score*. Oleh karena itu, pada langkah berikutnya, kami melakukan uji normalitas multivariat untuk mengetahui apakah data siswa berada pada populasi yang berdistribusi normal atau tidak. Asumsi yang

harus dipenuhi oleh analisis multivariat adalah bahwa data dapat diproses lebih lanjut ketika data memiliki distribusi populasi normal (Johnson & Wichern, 1988) dengan hipotesis sebagai berikut:

H0: Data berasal dari populasi yang memiliki distribusi normal multivariat.

H1: Data tidak berasal dari populasi yang memiliki distribusi normal multivariate

Uji normalitas multivariat dilakukan dengan membuat *scatter plot* antara jarak Mahalanobis dan Chi-Square. Jika *scatter plot* ini cenderung membentuk garis lurus maka H0 diterima, artinya data pada distribusi normal multivariate dan dapat diolah lebih lanjut.

Selanjutnya, kami menggabungkan metode diskritisasi dan k-NN yang ditujukan untuk menentukan berapa tingkat domain kognitif siswa. Kami memperluas pekerjaan sebelumnya (Yuni Yamasari et al., 2018) dengan menggunakan metode diskritisasi interval lebar yang sama (*equal width interval*). Domain fitur kontinyu dibagi menjadi interval dengan lebar yang sama. Data siswa yang berkaitan dengan ranah kognitif siswa MIPA didiskritisasi dalam 3-interval dan 4-interval dan dievaluasi oleh k-NN. Proses ini sangat mendasar bagi guru untuk mengetahui gambaran tentang berapa level ranah kognitif siswa MIPA yang terbaik. Sebagai contoh: jika interval terbaik adalah 3 interval, maka level kognitif terdiri dari *Poor*, *Fair*, *Good*. Jika 4-interval adalah yang terbaik, maka level domain kognitif terdiri dari *Poor*, *Fair*, *Good* dan *very Good*. Metode ini diukur dengan dua teknik evaluasi, yaitu: validasi silang dan persentase split.

Kemudian, kami menerapkan dua metode pemilihan fitur berdasarkan korelasi dan relief, yaitu: FS1 dan FS2, untuk menghilangkan fitur yang tidak relevan yang digambarkan dalam Gambar 1 (b). Keduanya dikategorikan sebagai pemilihan fitur berbasis filter (Hall, 1999) diusulkan untuk menyelesaikan masalah fitur yang tidak relevan (Solorio-Fernández et al., 2016). Dalam edukasi data mining (EDM), khususnya penambangan data prestasi siswa terkait ranah kognitif, data ganda dari siswa seharusnya dihindari agar proses pemetaan dapat dilakukan dengan tepat dan akurat.

Metode pertama mengadopsi pemilihan fitur berbasis korelasi yang diusulkan dalam penelitian [(Hall, 1999): Dalam penelitian kami, pemilihan fitur



berbasis korelasi dikombinasikan dengan Best first sebagai metode pencarian yang diimplementasikan oleh penelitian sebelumnya (Rich & Knight, 1991).

Kemudian, metode pemilihan fitur kedua adalah pemilihan fitur berbasis relief yang dikombinasikan dengan metode ranker sebagai metode pencarian atribut peringkat oleh evaluasi individu mereka. Di sini, relief diterapkan sebagai evaluator atribut yang mengevaluasi dengan berulang kali mengambil contoh dari nilai atribut, dan nilai kualitas yang diberikan dianggap sebagai contoh terdekat dari perbedaan dan kelas yang sama. Relief yang diadopsi memiliki langkah yang sama dengan penelitian dari (Fisher & Kononenko, 1997), (Kononenko, 1994).

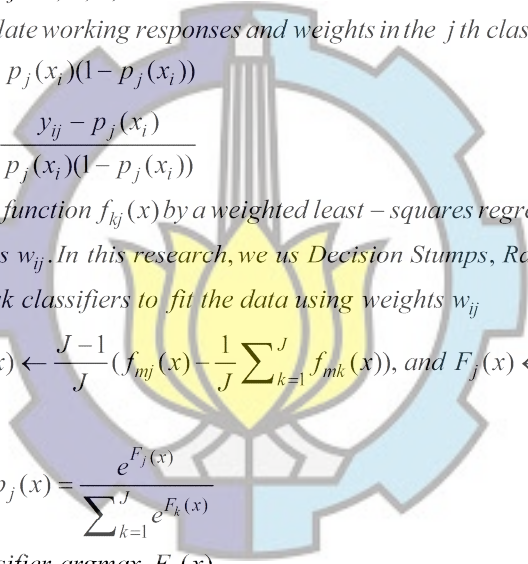
### **6.1.1. Meta-algoritma yang diusulkan.**

Pada tahap penambangan, kami menggabungkan pengklasifikasi berbasis Tree dan meta-algoritma LogitBoost. Kami mengusulkan metode ini untuk meningkatkan kinerja klasifikasi agar sistem dapat mengidentifikasi tingkat kognitif siswa secara lebih tepat. Dalam penelitian kami, satu set data pelatihan dengan sampel  $M$  dianggap dibagi menjadi 3 kelas, yaitu: *good*, *fair* dan *poor*. Proses ini didasarkan pada hasil dari metode diskritisasi pada k-NN. Tiga kelas didefinisikan sebagai  $y \in \{1, 2, 3\}$ . Set data pelatihan berada pada  $\{(x_1, y_1), \dots, (x_i, y_i), \dots, (x_m, y_m)\}$ , di mana  $y_m$  kelas target dan  $x_i$  merupakan vektor fitur. Penelitian ini mengadopsi algoritma LogitBoost untuk kelas  $J$  yang terdiri dari langkah-langkah (Friedman et al., 1998) yang disajikan pada *pseudo-code*, Gambar 6.2.

### **6.1.2. Tahap pasca pemrosesan.**

Pada tahap ini, kami mengevaluasi kerangka yang kami usulkan menggunakan beberapa metrik. Kappa didefinisikan sebagai ukuran kesepakatan yang diperbaiki secara kebetulan antara klasifikasi dan kelas aktual. Area Di Bawah Kurva (AUC) adalah probabilitas bahwa instance positif yang dipilih secara acak dalam data uji diberi peringkat di atas *instance* negatif yang dipilih secara acak, berdasarkan peringkat yang dihasilkan oleh pengklasifikasi. Metrik lainnya adalah tingkat Precision, Recall, F-Measure, dan Accuracy. Selain itu, *Mean Absolute Error* (MAE) dieksploitasi untuk mengukur tingkat kesalahan prediksi model yang

didefinisikan sebagai rata-rata atas sampel verifikasi dari nilai absolut dari perbedaan antara perkiraan dan pengamatan yang sesuai. Kemudian, kinerja terbaik pada semua kombinasi metode divisualisasikan. Akhirnya, hasil identifikasi sistem dianalisis.



```

1. Input data set  $M = \{(x_1, y_1), \dots, (x_i, y_i), \dots, (x_m, y_m)\}$ , where  $x_i \in X$  and  $y_i \in Y = \{1, 2, 3\}$ 
   Input number of iterations  $K$ 
   Input  $J = 3$ 
2. Initialized the weights  $w_{ij} = 1 / M, i = 1, 2, \dots, M; j = 1, \dots, J$ , start function  $F(x) = 0$  and
   probabilities estimates  $P(x_j) = 1 / 3$ 
3. Repeat for  $k = 1, 2, \dots, K;$ 
   (a). Repeat for  $j = 1, \dots, J;$ 
       i. Calculate working responses and weights in the  $j$ th class
           
$$w_{ij} = p_j(x_i)(1 - p_j(x_i))$$

           
$$z_{ij} = \frac{y_{ij} - p_j(x_i)}{p_j(x_i)(1 - p_j(x_i))}$$

       ii. Fit the function  $f_{kj}(x)$  by a weighted least – squares regression of  $z_{ij}$  to  $x_i$  with
           weights  $w_{ij}$ . In this research, we use Decision Stumps, Random Tree, REP Tree
           as weak classifiers to fit the data using weights  $w_{ij}$ 
   (b). set  $f_{mj}(x) \leftarrow \frac{J-1}{J} (f_{mj}(x) - \frac{1}{J} \sum_{k=1}^J f_{mk}(x))$ , and  $F_j(x) \leftarrow F_j(x) + f_{mj}(x)$ 
   (c). Update  $p_j(x) = \frac{e^{F_j(x)}}{\sum_{k=1}^J e^{F_k(x)}}$ 
4. Output the classifier  $\operatorname{argmax}_j F_j(x)$ 

```

Gambar 6.2 Pseudo-code dari LogitBoost


## 6.2. Hasil uji coba dan pembahasan

### 6.2.1. Pra-pemrosesan data siswa yang fitur-fiturnya diekstraksi berdasarkan kategori.

Bagian ini dimulai dengan uji normalitas multivariat pada data siswa. Di sini, setiap instance dihitung oleh jarak Mahalanobis dan chi-square dan kemudian dilakukan *scatter-plot* yang diilustrasikan dalam Gambar 6.3. Ditemukan bahwa data siswa cenderung membuat garis lurus. Selanjutnya, korelasi kedua jarak

Mahalanobis dan chi-square dihitung dan diperoleh korelasi  $r$  sekitar 0,965 yang ditunjukkan pada Tabel 6.1. Hasil ini menunjukkan bahwa keduanya memiliki korelasi positif yang tinggi dan  $H_0$  diterima. Oleh karena itu, data siswa ini mempunyai distribusi populasi yang normal, sehingga data dapat diproses lebih lanjut berdasarkan penelitian (Johnson & Wichern, 1988).

Kemudian, penentuan jumlah level kognitif dilakukan dengan hasil evaluasi kombinasi metode diskritisasi dan k-NN menggunakan cross-validation pada Fold 2, 3, 5, 10, 20 dan persentase split pada Split 5, 10, 20, 30, 40, 50, 60 .. Sementara, k-NN ditentukan dengan parameter sebagai berikut: jumlah tetangga = 5 dan jarak = Euclidean. Hasil percobaan menunjukkan bahwa interval 3 mencapai rata-rata tingkat akurasi yang lebih tinggi daripada interval 4 pada semua teknik evaluasi yang digambarkan dalam Gambar 6.4. Tingkat akurasi pada *cross-validation* dan *percentage split* dari interval 3 lebih tinggi sekitar 3.78% dan 3.38% dari interval 4. Ini berarti bahwa jumlah terbaik dari ranah kognitif siswa adalah dibagi menjadi tiga tingkatan, yaitu: *poor*, *fair*, dan *good*.




Gambar 6.3 Uji normalitas multivariat pada data ranah kognitif IPA siswa (SMKUO)

Tabel 6.1 Korelasi antara Jarak Mahalanobis dan Chi-square

Correlations			
		Mahalanobis Distance	Chi_SQ
Mahalanobis Distance	Pearson Correlation	1	.965**
	Sig. (2-tailed)		.000
	N	113	113
Chi_SQ	Pearson Correlation	.965**	1
	Sig. (2-tailed)	.000	
	N	113	113

\*\* . Correlation is significant at the 0.01 level (2-tailed).



Gambar 6.4 Perbandingan tingkat akurasi semua interval dari metode diskritisasi pada k-NN

Tabel 6.2 Hasil Metode Pemilihan Fitur

Pendekatan seleksi fitur	Banyaknya fitur	Fitur terpilih
Original Features extracted from the raw 101 features	5	Done, PercentTrue, Time, Hint, Score
Features Selection I (FS1)	2	Done, Hint
Feature Selection II (FS2)	4	Hint, PercentTrue, Time, Done

Pada langkah berikutnya, metode pemilihan fitur diterapkan untuk menghasilkan fitur yang relevan sebagai berikut: FS1 menghasilkan dua fitur yang relevan, yaitu: Done dan Hint. FS2 memilih empat fitur yang relevan, yaitu: Hint, PercentTrue, Time, Done. Mereka digambarkan dalam Tabel 6.2.

## 6.2.2. LogitBoost sebagai pendekatan meta-algoritma untuk mengidentifikasi tingkat kognitif siswa.

Hasil pengukuran kinerja dari sistem yang diusulkan, visualisasi, dan proses identifikasi disajikan sebagai berikut:

Tabel 6.3 Rerata dari Kappa, Precision, Recall, F-Measure and AUC pada Fold 3-12


Methods	Kappa	Precision	Recall	F-Measure	AUC
Average on Fold 3-12					
Original_DecisionStump	0.6249	0.6207	0.7691	0.6793	0.8564
Original_Logit_DecisionStump	0.9687	0.9794	0.9793	0.9794	0.9886
FS1_DecisionStump	0.6249	0.6207	0.7691	0.6793	0.8564
FS1_Logit_DecisionStump	0.9687	0.9794	0.9793	0.9794	0.9886
FS2_DecisionStump	0.6249	0.6207	0.7691	0.6793	0.8564
FS2_Logit_DecisionStump	0.9687	0.9794	0.9793	0.9794	0.9886
Original_REPTree	0.9497	0.9679	0.9671	0.9676	0.9790
Original_Logit_REPTree	0.9551	0.9715	0.9706	0.9707	0.9808
FS1_REPTree	0.9497	0.9679	0.9671	0.9676	0.9790
FS1_Logit_REPTree	0.9551	0.9715	0.9706	0.9707	0.9804
FS2_REPTree	0.9497	0.9679	0.9671	0.9676	0.9790
FS2_Logit_REPTree	0.9551	0.9715	0.9706	0.9707	0.9808
Original_RandomTree	0.9026	0.9403	0.9363	0.9372	0.9547
Original_Logit_RandomTree	0.9565	0.9722	0.9714	0.9722	0.9906
FS1_RandomTree	0.9579	0.9731	0.9722	0.9731	0.9803
FS1_Logit_RandomTree	0.9565	0.9722	0.9714	0.9722	0.9813
FS2_RandomTree	0.9188	0.9503	0.9470	0.9477	0.9625
FS2_Logit_RandomTree	0.9565	0.9722	0.9714	0.9722	0.9897

**Pertama**, hasil evaluasi LogitBoost pada Decision Stump, REP Tree dan Random Tree menggunakan teknik cross-validation pada Fold 3 - Fold 12 pada lima metrik yang tersaji dalam Tabel 6.3. Di sini, secara keseluruhan, *classifier* berbasis Tree menggunakan LogitBoost dapat meningkatkan kinerja sistem identifikasi secara signifikan. Sementara, pemilihan fitur umumnya meningkatkan klasifikasi kinerja; Namun, peningkatan tidak terjadi di semua kombinasi.

Rata-rata tertinggi dari empat metrik, yaitu: Kappa, Precision, Recall, dan F-Measure, dicapai oleh tiga kombinasi, yaitu: Original\_Logit\_DecisionStump,

FS1\_Logit\_DecisionStump, dan FS2\_Logit\_DecisionStump. Secara terperinci, level tertinggi Kappa, Precision, Recall, F-Measure dalam kombinasi kombinasi ini adalah masing-masing sekitar 0.9687, 0.9794, 0.9793, dan 0.9794. Sebaliknya, rata-rata terendah Kappa, Precision, Recall, dan F-Measure dicapai oleh Original\_DecisionStump, FS1\_DecisionStump, dan FS2\_DecisionStump masing-masing sekitar 0.6249, 0.6207, 0.7691 dan 0.6793. Secara khusus, AUC terluas dicapai oleh Original\_Logit\_RandomTree.

Lebih lanjut, ditemukan bahwa LogitBoost dapat meningkatkan level tertinggi dari lima metrik pada Decision Stump untuk semua kombinasi. Kappa, Precision, Recall, F-Measure dan AUC masing-masing adalah 0.344, 0.359, 0.210, 0.3001 dan 0.1322. Sebaliknya, LogitBoost hanya dapat sedikit meningkatkan pada lima metrik dari Original\_Logit\_RandomTree ke FS1\_Logit\_RandomTree, yaitu: Kappa sekitar 0.0001, Presisi sekitar 0.0009, Recall sekitar 0.008, F-Measure tentang 0.0009 dan AUC tentang 0.001.



Gambar 6.5 Perbandingan tingkat akurasi pada semua metode

Untuk mengevaluasi metode pemilihan fitur yang diterapkan, kami membandingkan Kappa, Precision, Recall, dan F-Measure dari

Original\_DecisionStump, FS1\_DecisionStump, dan FS2\_DecisionStump. Selain itu, kami juga membandingkan Original\_Logit\_DecisionStump, FS1\_Logit\_DecisionStump, dan FS2\_Logit\_DecisionStump. Ini juga dilakukan pada REP Treedan Random Tree. Hasil evaluasi menunjukkan bahwa pemilihan fitur dapat meningkat secara optimal untuk Kappa, Precision, Recall, F-Measure, dan AUC pada FS1\_RandomTree masing-masing sekitar 0.055, 0.033, 0.036, 0.036, 0.036, dan 0.055. Sebaliknya, Kappa, Precision, Recall, F-Measure, AUC dapat ditingkatkan dengan pemilihan fitur pada FS2\_RandomTree masing-masing sekitar 0.016, 0.01, 0.011, 0.011, 0.011, dan 0.016.

**Kedua**, kami mengevaluasi model dengan menggunakan tingkat akurasi yang diilustrasikan dalam Gambar 6.5-6.8. Sebagian besar kombinasi menunjukkan bahwa LogitBoost dapat meningkatkan kinerja *classifier* berbasis *Tree*. Tingkat akurasi cenderung acak pada semua *fold* yang dijelaskan dalam Gambar 6.5. Pada Decision Stump yang digambarkan dalam Gambar 6.6, LogitBoost dapat meningkatkan secara signifikan tingkat akurasi sekitar 21.07% yang dijelaskan pada kombinasi LogitBoost dengan fitur asli, FS1 dan FS2. Hasil ini dapat dilacak dari rata-rata tingkat akurasi sebelumnya di Original\_DecisionStump, FS1\_DecisionStump dan FS2\_DecisionStump sekitar 76.903%. Setelah LogitBoost dieksploitasi, tingkat akurasi rata-rata pada Original\_Logit\_DecisionStump, FS1\_Logit\_DecisionStump dan FS2\_Logit\_DecisionStump naik sekitar 97.965%. Meskipun metode pemilihan fitur tidak membuat tingkat akurasi yang lebih tinggi pada Original\_DecisionStump, FS1\_DecisionStump, dan FS2\_DecisionStump, ditemukan bahwa fitur yang dominan adalah Done dan Hint.

Pada REP Treedyang dijelaskan dalam Gambar 6.7, dalam hal tingkat akurasi, kinerja yang diperoleh dengan penerapan LogitBoost dan metode pemilihan fitur pada REP Treehampir sama dengan pada Decision Stump. Di sini, LogitBoost juga dapat sedikit meningkatkan tingkat akurasi sekitar 0.35% yang ditemukan pada perubahan tingkat akurasi rata-rata pada Original\_REPTree, FS1\_REPTree, FS2\_REPTree sekitar 96.726% ke Original\_Logit\_REPTree, FS1\_Logit\_REPTree, FS2\_Logit\_REPTree sekitar 97.080%. Sementara itu, metode pemilihan fitur tidak

menyebabkan kinerja yang lebih baik yang ditunjukkan oleh level yang sama pada pohon FS2\_REP, pohon FS1\_REP dan original\_REPTree sekitar 96.73%.

Kemudian, LogitBoost dapat meningkatkan akurasi rata-rata level fitur Asli dan fitur FS2 pada Random Tree sekitar 3.54% dan 2.48%, masing-masing digambarkan dalam Gambar 6.8. Ini dapat ditunjukkan pada Original\_RandomTree = 93.628% dan FS2\_RandomTree = 94.690% untuk Original\_Logit\_RandomTree dan FS2\_Logit\_RandomTree = 97.169%. Secara khusus, tingkat akurasi rata-rata tidak berubah pada kombinasi FS1\_RandomTree dan FS1\_Logit\_RandomTree, yaitu: 97.257%. Kondisi ini berarti bahwa LogitBoost tidak membuat kinerja pengklasifikasi yang lebih baik.

Selain itu, pemilihan fitur hanya berfungsi secara optimal untuk meningkatkan kinerja klasifikasi pada Original\_RandomTree yang levelnya lebih rendah dari FS1\_RandomTree dan FS2\_RandomTree. Ini berarti bahwa metode pemilihan fitur dapat meningkatkan kinerja klasifikasi pada FS1\_RandomTree = 3.63% dan FS2\_RandomTree = 1.06%.


Oleh karena itu, dalam hal tingkat akurasi rata-rata, LogitBoost dapat meningkatkan pencapaian tertinggi dari pengklasifikasi berbasis pohon di Original\_Logit\_DecisionStump, FS1\_Logit\_DecisionStump, dan FS2\_Logit\_DecisionStump sekitar 21.07%. Kinerja terendah ada di Original\_Logit\_REPTree, FS1\_Logit\_REPTree, dan FS2\_Logit\_REPTree sekitar 0.35%. Lebih lanjut, meskipun metode pemilihan fitur tidak membuat tingkat akurasi yang lebih tinggi pada semua kombinasi, ditemukan bahwa fitur yang dominan adalah Done dan Hint. Selanjutnya, dalam penelitian kami, pengklasifikasi berbasis pohon menggunakan LogitBoost sebagai meta-algoritma dapat mencapai tingkat akurasi yang lebih tinggi secara signifikan sekitar 97.965% dari penelitian sebelumnya sekitar 50% (Al-Malaise, Malibari, & Alkhozae, 2014).

**Ketiga**, tingkat kesalahan dari model identifikasi diukur dengan *Mean Absolute Error* (MAE) yang digambarkan dalam Gambar 6.9. Secara umum, semua kombinasi dengan LogitBoost dapat mengurangi rata-rata tingkat kesalahan. Pada Decision Stump, LogitBoost dapat menurunkan level MAE secara signifikan di sekitar 0,181 untuk semua kombinasi. Namun, metode pemilihan fitur masih belum




berfungsi untuk menurunkan level MAE yang ditunjukkan oleh rata-rata level MAE yang sama pada Original\_DecisionStump, FS1\_DecisionStump, dan FS2\_DecisionStump sekitar 0.013. Selanjutnya, LogitBoost menurunkan sedikit level MAE dari Original\_REPTree, FS1\_REPTree, dan FS2\_REPTree sekitar 0.031 ke Original\_Logit\_REPTree, FS1\_Logit\_Tree, dan FS2\_Logit\_Tree sekitar 0.025. Jadi, LogitBoost dapat mengurangi tingkat kesalahan sekitar 0.006 di semua kombinasi. Namun demikian, metode pemilihan fitur masih tidak mengubah level MAE di Original\_REPTree, FS1\_REP tree dan FS2\_REPTree tentang 0.025.


Sementara itu, LogitBoost yang diterapkan pada Random Tree dapat mengurangi tingkat MAE sekitar 0.022 dari Original\_Random Tree = 0.041 ke Original\_Logit\_Random Tree = 0.019. Selain itu, tingkat MAE FS2\_RandomTree = 0.036 juga turun menjadi FS2\_Logit\_RandomTree = 0.019, menunjukkan bahwa LogitBoost dapat mengurangi tingkat MAE di sekitar 0.017. Sebaliknya, pada FS1, LogitBoost belum memberikan efek untuk menurunkan level MAE karena FS1\_Random Tree memiliki level yang sama dengan FS1\_Logit\_Random Tree, yaitu: 0.018.



Gambar 6.6. Perbandingan rerata tingkat akurasi pada Decision Stump



Gambar 6.7 Perbandingan rerata tingkat akurasi pada REP Tree



Gambar 6.8 Perbandingan rerata tingkat akurasi pada Random Tree


Lebih lanjut, metode pemilihan fitur berfungsi secara optimal untuk mengurangi level MAE yang ditunjukkan oleh rata-rata level MAE pada *Original\_RandomTree* lebih tinggi dari *FS1\_RandomTree* sekitar 0.023 dan *FS2\_RandomTree* sekitar 0.05. Dalam penelitian ini, metode pemilihan fitur masih sedikit berpengaruh untuk meningkatkan kinerja klasifikasi dalam mengidentifikasi tingkat kognitif siswa. Karena metode pemilihan fitur yang dieksploitasi dalam penelitian kami dikategorikan sebagai metode pemilihan fitur berbasis filter yang ditujukan untuk menghilangkan redundansi (Solorio-Fernández et al., 2016). Metode pemilihan fitur berbasis *wrapper* mungkin lebih tepat jika penelitian ini berfokus pada peningkatan kinerja (Sasi Regha et al., 2016).

Di sini, masing-masing, siswa ditandai dengan tambah, segitiga, dan lingkaran untuk siswa yang baik, siswa yang *Poor*, siswa yang *Fair*. Selain itu, kotak menggambarkan siswa yang salah identifikasi. Hasil perbandingan menggambarkan bahwa *LogitBoost* dapat mengurangi jumlah kesalahan identifikasi siswa secara signifikan. Ditemukan bahwa perbandingan antara *Original\_DecisionStump* dan *Original\_Logit\_DecisionStump*, antara *FS1\_DecisionStump* dan *FS1\_Logit\_DecisionStump*, antara *FS2\_DecisionStump* dan *FS2\_Logit\_DecisionStump*.

Sebaliknya, perbandingan *Original\_DecisionStump*, *FS1\_DecisionStump*, dan *FS2\_DecisionStump* tidak menunjukkan perbedaan. Selain itu, perbandingan *Original\_Logit\_DecisionStump*, *FS1\_Logit\_DecisionStump*, dan *FS2\_Logit\_DecisionStump* juga menunjukkan jumlah siswa yang salah diidentifikasi sama. Hasil ini berarti bahwa metode pemilihan fitur tidak memberikan dampak pada pengurangan jumlah siswa yang salah identifikasi berdasarkan tingkat kognitif mereka.

Secara rinci, *Original\_DecisionStump* hanya mengenali siswa pada dua tingkat: tingkat yang *Good* dan tingkat yang *Fair*, seperti yang ditunjukkan pada Gambar 6.10 a). Di sini, siswa *Poor* diklasifikasikan ke tingkat lain. Jadi, komposisi level dapat digambarkan sebagai berikut: level yang *Good*, level yang *Fair*, dan level yang *Poor* masing-masing terdiri dari 45, 68 dan 0 siswa. Pengamatan menemukan bahwa indeks siswa 100 adalah siswa *Poor* tetapi diidentifikasi sebagai siswa yang *Good*. Selain itu, indeks siswa = 5, 6, 15, 16, 25, 26, 35, 36, 45, 46, 55,

56, 64, 65, 72, 73, 74, 81, 82, 83, 83, 90, 91, 99, 108, 109 diidentifikasi sebagai siswa yang *Fair*. Mereka adalah siswa *Poor*.



Gambar 6.9 Perbandingan rata-rata tingkat kesalahan dalam metrik MAE

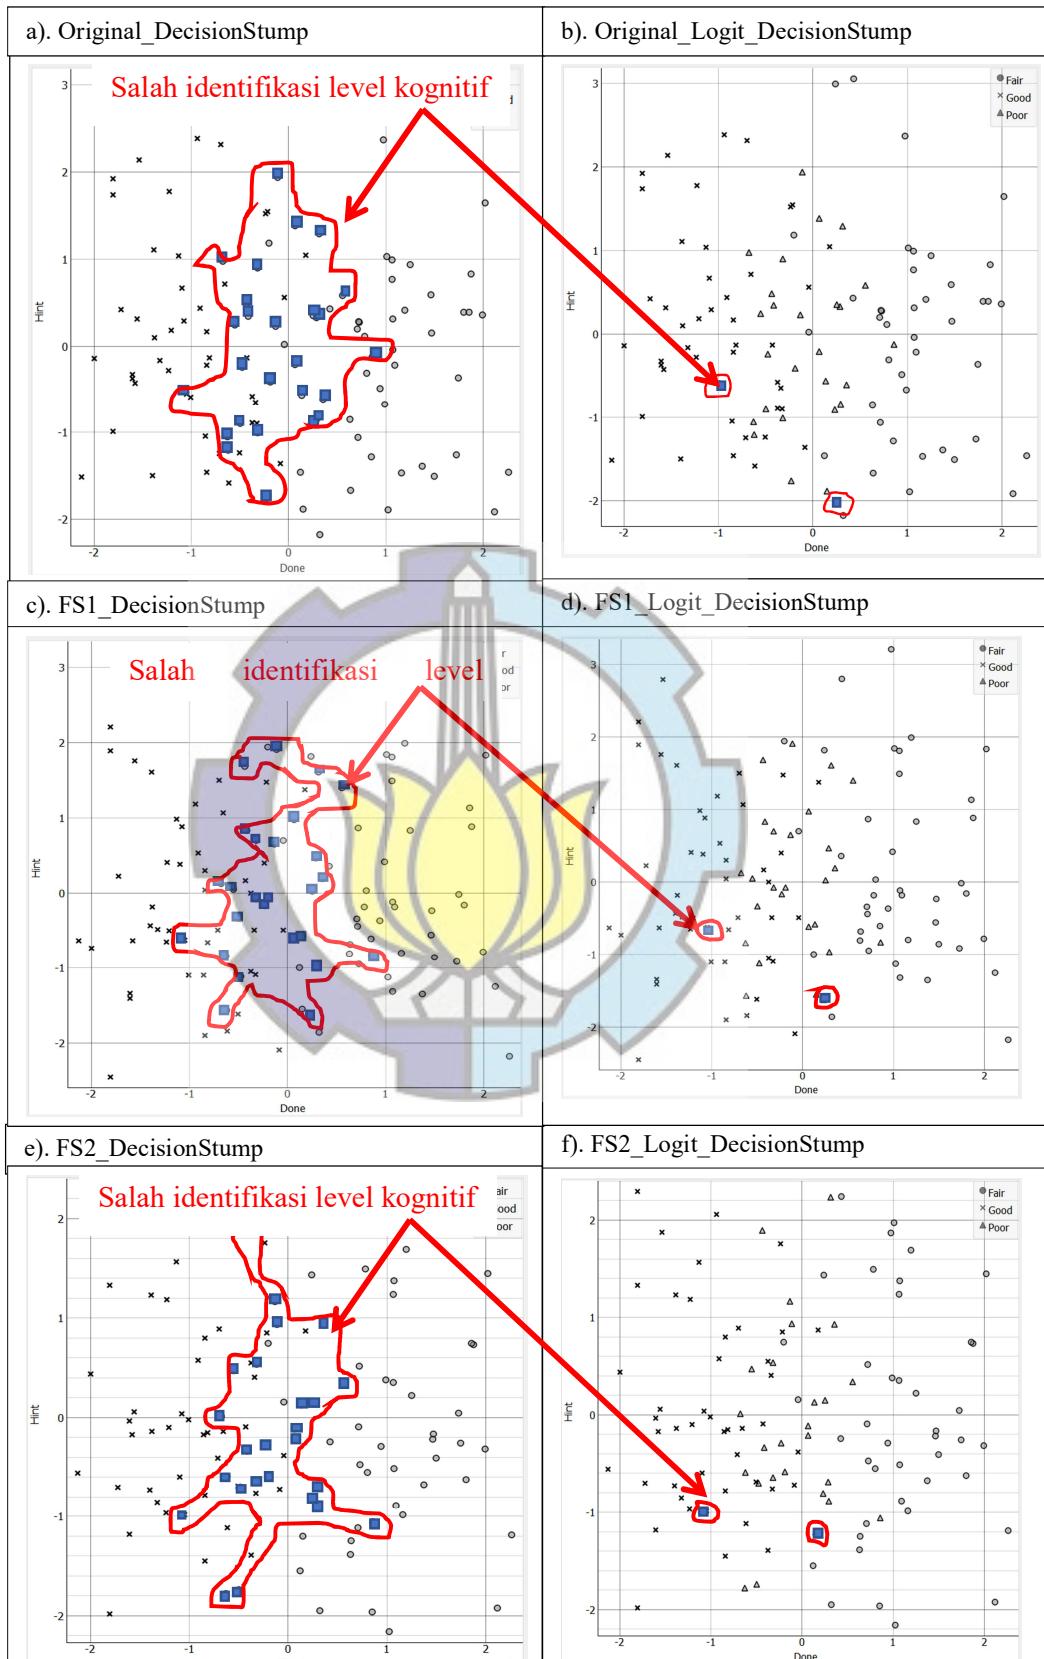
Jadi, `Original_DecisionStump` menghasilkan jumlah siswa yang salah diidentifikasi = 26 siswa. Sementara itu, komposisi level berdasarkan `Original_Logit_DecisionStump` adalah sebagai berikut: tingkat yang *Good* = 45 siswa, tingkat yang *Fair* = 42 siswa dan tingkat yang *Poor* = 26 siswa yang diilustrasikan pada Gambar 6.10 b). Dalam metode ini, jumlah kesalahan identifikasi adalah dua siswa, yaitu: indeks siswa 100 adalah siswa *Poor*, tetapi hasil identifikasi adalah siswa yang *Good*. Kemudian, indeks siswa 79 diakui sebagai siswa *Poor*, padahal siswa adalah siswa yang *Fair*. Hasil ini menunjukkan bahwa LogitBoost dapat menurunkan jumlah siswa yang salah identifikasi sebanyak 24, dari 26 menjadi 2 siswa.

Juga, `FS1_DecisionStump` hanya memetakan siswa pada dua tingkat: tingkat yang *Good* dan tingkat yang *Fair* seperti yang ditunjukkan pada Gambar 6.10 c). Di sini, siswa *Poor* dikelompokkan pada tingkat yang salah. Jadi, komposisi level dapat digambarkan sebagai berikut: level yang *Good*, level yang *Fair*, dan

level yang *Poor*, masing-masing, terdiri dari 45, 68 dan 0 siswa. Di sini, ditemukan bahwa indeks siswa 100 adalah siswa *Poor* tetapi disajikan sebagai siswa yang *Good*. Selain itu, indeks siswa = 5, 6, 15, 16, 25, 26, 35, 36, 45, 46, 55, 56, 64, 65, 72, 73, 74, 81, 82, 83, 83, 90, 91, 99, 108, 109 diidentifikasi sebagai siswa yang *Fair*. Mereka adalah siswa *Poor*. Jadi, FS1\_DecisionStump menghasilkan jumlah siswa yang salah dikenali = 26 siswa. Sementara itu, komposisi level berdasarkan FS1\_Logit\_DecisionStump adalah sebagai berikut: tingkat yang *Good* = 45 siswa, tingkat yang *Fair* = 42 siswa dan tingkat yang *Poor* = 26 siswa yang digambarkan dalam Gambar 6.10 d). Dalam metode ini, jumlah kesalahan identifikasi adalah dua siswa, yaitu: pada kenyataannya, indeks siswa 100 adalah siswa *Poor* tetapi diakui sebagai siswa yang *Good*. Kemudian, indeks siswa 79 diidentifikasi sebagai siswa *Poor*; sebenarnya, siswa ke-79 adalah siswa yang *Fair*. Hasil ini menunjukkan bahwa LogitBoost dapat mengurangi jumlah siswa yang salah identifikasi sebanyak 24, dari 26 menjadi 2 siswa.

Secara rinci, FS2\_DecisionStump juga hanya menemukan siswa di dua tingkat: tingkat yang *Good* dan tingkat yang *Fair* seperti yang disajikan dalam Gambar 6.10 e). Di sini, siswa yang salah diidentifikasi adalah siswa *Poor*. Jadi, komposisi level dapat digambarkan sebagai berikut: level yang *Good*, level yang *Fair*, dan level yang *Poor* masing-masing terdiri dari 45, 68 dan 0 siswa. Diketahui bahwa indeks siswa 100, pada kenyataannya, adalah siswa *Poor* tetapi diidentifikasi sebagai siswa yang *Good*.

Selain itu, indeks siswa = 5, 6, 15, 16, 25, 26, 35, 36, 45, 46, 55, 56, 64, 65, 72, 73, 74, 81, 82, 83, 83, 90, 91, 99, 108, 109 diidentifikasi sebagai siswa yang *Fair*. Pada kenyataannya, mereka adalah siswa *Poor*. Jadi, FS2\_DecisionStump menghasilkan jumlah siswa yang salah dikenali = 26 siswa. Sementara itu, komposisi level berdasarkan FS2\_Logit\_DecisionStump adalah sebagai berikut: tingkat yang *Good* = 45 siswa, tingkat yang *Fair* = 42 siswa dan tingkat yang *Poor* = 26 siswa yang diilustrasikan dalam Gambar 6.10 f). Dalam metode ini, jumlah kesalahan identifikasi adalah 2 siswa, yaitu: sebenarnya, indeks siswa 100 adalah siswa *Poor* tetapi diidentifikasi sebagai siswa yang *Good*. Kemudian, indeks siswa 79 diidentifikasi sebagai siswa *Poor*, pada kenyataannya; siswa ini adalah siswa yang *Fair*.



Gambar 6.10 Visualisasi kinerja terbaik dari sistem identifikasi pada Decision Stump menggunakan hibrida transformasi data dan LogitBoost sebagai meta-algoritma

Hasil ini menunjukkan bahwa LogitBoost dapat mengurangi jumlah siswa yang salah identifikasi sebanyak 24, dari 26 menjadi 2 siswa.

Langkah-langkah yang sama juga dijalankan pada REP Tree dan Random Tree. Di REP Tree, LogitBoost dapat mengurangi jumlah siswa yang salah klasifikasi sebanyak 2, dari 5 menjadi 3 siswa pada semua kombinasi. Kami dapat melacak efek dari hasil eksperimen ini sebagai berikut:

- Original\_REPTree menghasilkan siswa dalam tiga level, yaitu: level *Good* = 43 siswa, level *Fair* = 43 siswa dan level *Poor* = 27 siswa. Di sini, indeks siswa 100 adalah siswa *Poor* tetapi diidentifikasi sebagai siswa yang *Good*. Sebaliknya, indeks siswa 38 dan 85 adalah siswa yang *Good* tetapi diidentifikasi sebagai siswa *Poor*. Kemudian, indeks siswa 79 adalah siswa yang *Fair* tetapi diidentifikasi sebagai siswa yang *Poor*. Sebaliknya, indeks siswa 36 *Poor* tetapi diidentifikasi sebagai siswa yang *Fair*. Jadi, Original\_REPTree menghasilkan jumlah siswa yang salah identifikasi = 5 siswa. Sementara itu, komposisi level berdasarkan pada Original\_Logit\_REPTree adalah sebagai berikut: level yang *Good* = 44 siswa, level yang *Fair* = 42 siswa dan level yang *Poor* = 27 siswa. Dalam metode ini, jumlah yang salah dikenali adalah tiga siswa, yaitu: indeks siswa 15 dan 95 adalah siswa *Fair* tetapi diidentifikasi sebagai siswa *Poor*. Kemudian, indeks siswa 89 diidentifikasi sebagai siswa yang *Fair*, sedangkan siswa adalah siswa *Poor*.
- FS1\_REPTree memetakan siswa di tiga tingkat, yaitu: tingkat yang *Good*, tingkat yang *Fair*, dan tingkat yang *Poor* yang terdiri dari 43, 43 dan 27 siswa. Di sini, kami menemukan bahwa indeks siswa 100 adalah siswa *Poor* tetapi diidentifikasi sebagai siswa yang *Good*. Begitu pula sebaliknya, indeks siswa 38 dan 85 adalah siswa yang *Good*, tetapi mereka dikenal sebagai siswa *Poor*. Selain itu, indeks siswa 79 *Fair* tetapi diidentifikasi sebagai siswa *Poor*. Sebaliknya, indeks siswa 36 *Poor* tetapi diidentifikasi sebagai siswa yang *Fair*. Jadi, FS1\_REPTree menghasilkan jumlah siswa yang salah identifikasi = 5 siswa. Sedangkan, komposisi level berdasarkan FS1\_Logit\_REPTree adalah sebagai berikut: level yang *Good* = 45 siswa, level yang *Fair* = 44 siswa dan level yang *Poor* = 25 siswa. Dalam metode ini, jumlah kesalahan identifikasi adalah tiga siswa, yaitu: indeks siswa 100 adalah siswa *Poor* tetapi

diidentifikasi sebagai siswa yang *Good*. Indeks siswa 38 adalah siswa yang *Good* tetapi ditemukan sebagai siswa yang *Poor*. Kemudian, indeks siswa 64 adalah siswa *Poor* tetapi diidentifikasi sebagai siswa yang *Fair*.

- FS2\_REPTree melakukan pemetaan siswa dalam tiga tingkatan: tingkat yang *Good* = 44, tingkat yang *Fair* = 43 dan tingkat yang *Poor* = 26 siswa. Secara rinci, siswa dengan indeks 59 adalah siswa *Poor* tetapi ditemukan sebagai siswa yang *Good*. Siswa dengan indeks 8 dan 85 adalah siswa yang *Good*, tetapi mereka dikenal sebagai siswa *Poor*. Selain itu, indeks siswa 29 dikelompokkan dalam tingkat yang *Fair*; pada kenyataannya, siswa ini *Poor*. Sebaliknya, siswa yang memiliki indeks 87 adalah siswa yang *Fair* tetapi diatur pada siswa yang *Poor*. Jadi, FS2\_REPTree menghasilkan jumlah siswa yang salah identifikasi = lima siswa. Sementara, komposisi level pada FS2\_Logit\_REPTree adalah sebagai berikut: tingkat yang *Good* = 44 siswa, tingkat yang *Fair* = 43 siswa dan tingkat yang *Poor* = 26 siswa. Jumlah kesalahan identifikasi adalah tiga siswa, yaitu: indeks siswa 8 dan 68 ada di kelas yang *Poor* tetapi diidentifikasi sebagai kelas yang *Fair*. Sebaliknya, indeks siswa 29 adalah *Fair* tetapi diklasifikasikan sebagai siswa *Poor*.

Pada Random Tree, hasil eksperimen menunjukkan bahwa LogitBoost dapat bekerja secara optimal ketika diterapkan pada Random Tree dengan data siswa asli karena LogitBoost dapat menurunkan jumlah siswa yang salah identifikasi paling tinggi sebanyak 9 dari 12 menjadi 3 siswa. Kami dapat menemukan efek ini dengan membandingkan Original\_RandomTree dan Original\_Logit\_RandomTree. Original\_RandomTree menghasilkan komposisi sebagai berikut: tingkat yang *Good* = 42, tingkat yang *Fair* = 39 dan tingkat yang *Poor* = 32 siswa. Di sini, indeks siswa 6, 42, 96, 100, 102 adalah siswa yang *Fair* tetapi diakui sebagai siswa *Poor*. Sebaliknya, indeks siswa 12 dan 68 adalah siswa *Poor* tetapi diidentifikasi sebagai siswa yang *Fair*. Kemudian, indeks siswa 66 adalah siswa *Poor* tetapi diakui sebagai siswa yang *Good*. Indeks siswa 16, 57 dan 72 adalah siswa yang *Good* tetapi diakui sebagai siswa yang *Poor*. Jadi, Original\_RandomTree menghasilkan jumlah siswa yang salah identifikasi = 12 siswa.

Sedangkan komposisi level pada Original\_Logit\_RandomTree adalah sebagai berikut: tingkat yang *Good* = 43 siswa, tingkat yang *Fair* = 43 siswa dan tingkat



yang *Poor* = 27. Di sini, jumlah kesalahan identifikasi adalah tiga siswa. Indeks siswa 42 adalah siswa yang *Fair* tetapi hasil identifikasi adalah siswa yang *Poor*. Sebaliknya, indeks siswa 68 adalah siswa *Poor* tetapi dikenal sebagai siswa yang *Fair*. Indeks siswa 72 adalah siswa yang *Good* tetapi diakui sebagai siswa yang *Poor*. Jadi, *Original\_Logit\_RandomTree* menghasilkan jumlah siswa yang salah identifikasi = 3 siswa.

Sebaliknya, *LogitBoost* tidak memicu untuk meningkatkan kinerja model identifikasi pada FS1. Hasil ini dapat ditemukan dengan membandingkan antara *FS1\_RandomTree* dan *FS1\_Logit\_RandomTree*. Di sini, *FS1\_RandomTree* melakukan pemetaan siswa di tingkat yang *Good* = 43 siswa, tingkat yang *Fair* = 43 siswa, dan tingkat yang *Poor* = 27 siswa. Selanjutnya, kami menemukan bahwa indeks siswa 79 adalah siswa yang *Fair* tetapi diidentifikasi sebagai siswa yang *Poor*. Indeks siswa 36 adalah siswa *Fair* tetapi diakui sebagai siswa *Poor*.

Selain itu, indeks siswa 38 adalah siswa yang *Good* tetapi diakui sebagai siswa yang *Poor*. Jadi, *FS1\_RandomTree* menghasilkan jumlah siswa yang salah identifikasi = 3 siswa. Sementara itu, komposisi level pada *FS1\_Logit\_RandomTree* adalah sebagai berikut: tingkat yang *Good* = 43 siswa, tingkat yang *Fair* = 43 siswa dan tingkat yang *Poor* = 27 siswa. Di sini, level-levelnya memiliki komposisi yang sama dengan *FS1\_Logit\_RandomTree*. Jadi, metode ini menghasilkan siswa yang salah diidentifikasi sama dengan *FS1\_RandomTree*.

Secara keseluruhan, pengklasifikasi berbasis Tree menggunakan meta-algoritma yang disebut "*LogitBoost*" dapat melakukan identifikasi tingkat kognitif siswa yang lebih akurat. Kami dapat menyimpulkan dari **Tabel 6.4** bahwa pendekatan kami dapat mengurangi tingkat kognitif siswa yang salah identifikasi. Kinerja terbaik dicapai oleh *LogitBoost* yang diterapkan pada *Decision Stump* untuk fitur Asli, fitur FS1, dan fitur FS2. Kombinasi ini mencapai akurasi 97.965% dan hanya melakukan kesalahan identifikasi pada 2 siswa.

Kemudian, *LogitBoost* mengerjakan kesalahan identifikasi untuk 3 siswa di *Random Tree* dengan fitur Asli dan fitur FS2 yang akurasinya adalah 97.169%. Jumlah siswa yang salah diidentifikasi sama dengan *LogitBoost* pada fitur *REP Tree for Original*, fitur FS1, dan fitur FS2 dengan akurasi sedikit lebih rendah, yaitu

97.080%. Namun, LogitBoost tidak berdampak mengurangi siswa yang salah mengidentifikasi fitur FS1 di Random Tree.

Tabel 6.4 Rerata Level Akurasi, MAE, Banyaknya Siswa yang Salah Identifikasi pada Semua Kombinasi Metode

Metode	Rerata akurasi (%)	Rerata MAE	Banyaknya siswa yang salah identifikasi
Original_DecisionStump	76.903	0.194	26
Original_Logit_DecisionStump	97.965	0.013	2
FS1_DecisionStump	76.903	0.194	26
FS1_Logit_DecisionStump	97.965	0.013	2
FS2_DecisionStump	76.903	0.194	26
FS2_Logit_DecisionStump	97.965	0.013	2
Original_REPTree	96.726	0.031	5
Original_Logit_REPTree	97.080	0.025	3
FS1_REPTree	96.726	0.031	5
FS1_Logit_REPTree	97.080	0.025	3
FS2_REPTree	96.726	0.031	5
FS2_Logit_REPTree	97.080	0.025	3
Original_RandomTree	93.628	0.041	12
Original_Logit_RandomTree	97.169	0.019	3
FS1_RandomTree	97.257	0.018	3
FS1_Logit_RandomTree	97.257	0.018	3
FS2_RandomTree	94.690	0.036	9
FS2_Logit_RandomTree	97.169	0.019	3

Sedangkan pada FS2, LogitBoost dapat menurunkan jumlah siswa yang salah klasifikasi sebanyak 6, dari 9 menjadi 3 siswa. Secara rinci, FS2\_RandomTree dari komposisi level dapat digambarkan sebagai berikut: level yang *Good*, level yang *Fair*, dan level yang *Poor* yang masing-masing terdiri dari 42, 40 dan 31 siswa. Selanjutnya, kami menemukan siswa dengan indeks 38 dan 85 adalah siswa yang *Good* tetapi diidentifikasi sebagai siswa *Poor*. Selain itu, indeks siswa 24, 52, 53, 54, 79 adalah siswa yang *Fair* tetapi dikelompokkan pada tingkat yang *Poor*. Sebaliknya, siswa yang memiliki indeks 36 dan 46 adalah siswa *Poor* tetapi dikelompokkan dalam kelas yang *Fair*. Jadi, FS2\_RandomTree menghasilkan jumlah siswa yang salah identifikasi = 9 siswa. Sementara itu, komposisi level FS2\_Logit\_RandomTree adalah sebagai berikut: tingkat yang *Good* = 43, tingkat yang *Fair* = 43 dan kelas yang *Poor* = 27 siswa. Dalam metode ini, jumlah kesalahan identifikasi adalah 3 siswa, yaitu: indeks siswa 79 adalah tingkat yang

*Poor* tetapi diidentifikasi sebagai tingkat yang *Fair*. Kemudian, indeks siswa 36 adalah siswa yang *Poor* tetapi diakui sebagai siswa yang *Fair*.

Akhirnya, sistem yang menghasilkan identifikasi hasil yang lebih akurat dapat mendukung guru untuk memilih metode terbaik dalam proses belajar mengajar. Jika komposisi level siswa mengandung jumlah siswa *Poor* lebih tinggi daripada jumlah siswa *Good* atau siswa *Fair*, seorang guru akan memberikan materi pelajaran secara terperinci. Sebaliknya, jika hasil identifikasi memiliki jumlah siswa *Poor* yang lebih rendah daripada yang lain, seorang guru tidak perlu mengajarkan bagian materi langkah demi langkah.

### **6.3. Intisari hibrida transformasi data dan meta-algoritma logitboost pada identifikasi prestasi belajar siswa**

Dalam penelitian ini, kami membangun model baru untuk mengidentifikasi tingkat kognitif siswa MIPA secara lebih tepat. Pada proses penambangan, kami memadukan classifier berdasarkan Tree menggunakan LogitBoost. Kami juga melakukan uji normalitas multivariat pada data ranah kognitif siswa; ekstraksi fitur berbasis kategori, mengusulkan kombinasi metode diskritisasi dan k-NN, dan mengadopsi metode seleksi fitur berbasis korelasi dan relief pada fase pra-pemrosesan. Hasil pengukuran menunjukkan bahwa kinerja model meningkat dalam mengidentifikasi tingkat kognitif siswa MIPA. Selain itu, metode yang diusulkan secara drastis mengurangi kesalahan identifikasi tingkat kognitif siswa MIPA dan hasilnya telah kami publikasikan (Yuni Yamasari et al., 2019). Manfaat yang diharapkan adalah ketepatan seorang guru dalam memotivasi dan mengoptimalkan potensi belajar siswa MIPA agar siswa mencapai prestasi belajarnya yang tertinggi. Keoptimalan ini dapat dicapai oleh seorang guru melalui perbaikan rencana pelaksanaan pembelajaran, perbaikan proses belajar mengajar dan proses evaluasi dan seterusnya. Akhirnya, kesemuanya bermuara pada menciptakan lingkungan pendidikan yang lebih baik.

## BAB 7

### KESIMPULAN DAN PENELITIAN LANJUTAN

#### 7.1. Kesimpulan

Berdasarkan hasil eksperimen yang telah dipublikasikan dalam forum-forum ilmiah, pengembangan metode hibrida transformasi data dan meta-algoritma ini dapat meningkatkan kinerja proses identifikasi level kognitif siswa MIPA. Peningkatan secara optimal ini dicapai dengan masing-masing tahap menggunakan strategi terbaik sebagai berikut:

1. Metode ekstraksi fitur terbaik untuk pembentukan fitur baru dari beberapa fitur asli, yaitu: ekstraksi fitur berdasarkan kategorinya. Fitur baru yang terbentuk dapat meningkatkan kinerja proses pemetaan prestasi belajar siswa, khususnya ranah kognitif, dan sekaligus mereduksi konsumsi waktu eksekusi ketika dikombinasikan dengan Fuzzy-C-Mean.
2. Metode diskritisasi fitur terbaik untuk penentuan banyaknya level kognitif siswa MIPA, yaitu: metode diskritisasi fitur berbasis pada interval lebar yang sama (*Equal width interval*) untuk tiga interval yang dikombinasikan dengan regresi logistik.
3. Metode seleksi fitur terbaik untuk penentuan karakteristik siswa yang paling berpengaruh dalam proses identifikasi, yaitu: Gini Index yang dikombinasikan dengan K-means.
4. Meta-algoritma terbaik untuk meningkatkan kinerja dari sistem identifikasi yaitu: LogitBoost (logistic Boosting) yang diterapkan pada *classifier* berbasis tree.

Tentu saja, sistem ini sangat membantu guru untuk mengoptimalkan potensi dan memotivasi siswa untuk mencapai prestasi belajar terbaiknya.

#### 7.2. Penelitian lanjutan

Identifikasi prestasi belajar siswa pada penelitian-penelitian sebelumnya belum mempertimbangkan perilaku siswa ketika mereka berinteraksi dengan perangkat pembelajaran, khususnya *serious game*. Padahal, perilaku ini

menunjukkan respon siswa terhadap perangkat pembelajaran berbasis TIK yang sangat berpengaruh terhadap keberhasilan dari proses belajar mengajar. Sehingga, penelitian lanjutan kami adalah deteksi perilaku abnormal siswa kemudian identifikasi perilaku abnormal ini berbasis pada emosi yang memanfaatkan data log dari *eye tracking* siswa pada saat bermain serious game. Untuk itu, sebagai penelitian awal ini, kami telah mempublikasikan 2 makalah pada konferensi internasional terindek scopus tentang **desain dan implementasi serious game** serta **peningkatan kinerja dari klasifikasi perilaku siswa berbasis serious game menggunakan kombinasi metode diskritisasi dan k-NN**. Lebih dari itu, kami sudah melakukan eksperimen untuk deteksi perilaku abnormal berbasis pada metode-metode deteksi anomali.



## DAFTAR PUSTAKA

- Al-Malaise, A., Malibari, A., & Alkhozae, M. (2014). Students' Performance Prediction System Using Multi Agent Data Mining Technique. *International Journal of Data Mining & Knowledge Management Process (IJDKP)*, 4(5). <https://doi.org/10.5121/ijdkp.2014.4501>
- Anusha, M., & Sathiaseelan, J. G. R. (2015). Feature Selection Using K-Means Genetic Algorithm for Multi-objective Optimization. In *Procedia Computer Science* (Vol. 57, pp. 1074–1080). Elsevier Masson SAS. <https://doi.org/10.1016/j.procs.2015.07.387>
- Berkhin, P. (2006). *Survey of Clustering Data Mining Techniques*.
- Bezdek, J. C. (1984). FCM : The Fuzzy C-Means Clustering Algorithm, *10*(2), 191–203.
- Bharti, K. K., & Singh, P. K. (2015). Expert Systems with Applications Hybrid dimension reduction by integrating feature selection with feature extraction method for text clustering. *Expert Systems With Applications*, 42(6), 3105–3114. <https://doi.org/10.1016/j.eswa.2014.11.038>
- Bravo, C. B., Ojeda-Castelo, J. J., & Piedra-Fernandez, J. A. (2017). Art activities with Kinect to students with cognitive disabilities: Improving all motor skills. *Procedia -Social and Behavioral Sciences EDUHEM*, 237(2016), 1148–1151. <https://doi.org/10.1016/j.sbspro.2017.02.170>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Buniamin, N., Mat, U. bin, & Arshad, P. M. (2015). Educational data mining for prediction and classification of engineering students achievement. In *2015 IEEE 7th International Conference on Engineering Education (ICEED)* (pp. 49–53). IEEE. <https://doi.org/10.1109/ICEED.2015.7451491>
- Calvet Liñán, L., & Juan Pérez, Á. A. (2015). Educational Data Mining and Learning Analytics: differences, similarities, and time evolution. *RUSC. Universities and Knowledge Society Journal*, 12(3), 98. <https://doi.org/10.7238/rusc.v12i3.2515>
- Cerezo, R., Sánchez-Santillán, M., Paule-Ruiz, M. P., & Núñez, J. C. (2016).

- Students' LMS interaction patterns and their relationship with achievement: A case study in higher education. *Computers & Education*, 96, 42–54. <https://doi.org/10.1016/j.compedu.2016.02.006>
- Chau, M., Cheng, R., Kao, B., & Ng, J. (2006). Uncertain Data Mining: An Example in Clustering Location Data (pp. 199–204). [https://doi.org/10.1007/11731139\\_24](https://doi.org/10.1007/11731139_24)
- Chrysafiadi, K., & Virvou, M. (2014). K.E.M.Cs: A set of student's characteristics for modeling in adaptive programming tutoring systems. In *IISA 2014 - 5th International Conference on Information, Intelligence, Systems and Applications*. <https://doi.org/10.1109/IISA.2014.6878786>
- De Gagne, J. C., Hall, K., Conklin, J. L., Yamane, S. S., Roth, N. W., Chang, J., & Kim, S. S. (2018). Uncovering cyberincivility among nurses and nursing students on twitter: A data mining study. *International Journal of Nursing Studies*. <https://doi.org/10.1016/J.IJNURSTU.2018.09.009>
- de Morais, A. M., Araujo, J. M. F. R., & Costa, E. B. (2014). Monitoring student performance using data clustering and predictive modelling. *2014 IEEE Frontiers in Education Conference (FIE) Proceedings*, 1–8. <https://doi.org/10.1109/FIE.2014.7044401>
- Deepika, K., & Sathyanarayana, N. (2019). Relief-F and Budget Tree Random Forest Based Feature Selection for Student Academic Performance Prediction. *International Journal of Intelligent Engineering & System*, 12(1), 30–39. <https://doi.org/10.22266/ijies2019.0228.04>
- Dillenbourg, P. (2016). The Evolution of Research on Digital Education. *International Journal of Artificial Intelligence in Education*, 26(2), 544–560. <https://doi.org/10.1007/s40593-016-0106-z>
- Dougherty, J., Kohavi, R., & Sahami, M. (1995). *Supervised and Unsupervised Discretization of Continuous Features*. Morgan Kaufmann Publishers. Retrieved from <http://ai.stanford.edu/~ronnyk/disc.pdf>
- Draper, N. R., & van Nostrand, R. C. (1979). Ridge Regression and James-Stein Estimation: Review and Comments. *Technometrics*, 21(4), 451. <https://doi.org/10.2307/1268284>
- Fan, Z., & Sun, Y. (2016). Clustering of College Students Based on Improved K-

- Means Algorithm. In *2016 International Computer Symposium (ICS)* (pp. 676–679). IEEE. <https://doi.org/10.1109/ICS.2016.0139>
- Fayyad, U. M., & Irani, K. B. (1993). Multi-Interval Discretization of Continuous-Valued Attributes for Classification Learning. In *Proceedings of the Thirteenth International Joint Conference on Artificial Intelligence*.
- Fisher, D. H., & Kononenko, I. (1997). An adaptation of Relief for attribute estimation in regression. In *Proceedings of the Fourteenth International Conference on Machine Learning* (p. 430). Morgan Kaufmann Publishers. Retrieved from <https://dl.acm.org/citation.cfm?id=657141>
- Freedman, D. (2009). *Statistical models: theory and practice*. Cambridge University Press.
- Freund, Y., & Schapire, R. E. (1997). A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 55(1), 119–139. <https://doi.org/10.1006/jcss.1997.1504>
- Friedman, J., Hastie, T., Tibshirani, R., & Stanford, Y. (1998). Additive Logistic Regression: a Statistical View of Boosting. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=488191F7F19E095C96570B94F139502F?doi=10.1.1.51.9525&rep=rep1&type=pdf>
- Gagne, R. M. (1985). *The conditions of Learning and theory of instruction* (4th ed.). New York: CBS College Publishing.
- Hall, M. A. (1999). *Correlation-based Feature Selection for Machine Learning*.
- Hardoon, D. R., Szedmak, S., & Shawe-Taylor, J. (2003). *Canonical correlation analysis; An overview with application to learning methods*.
- Hong, T. P., Lin, K. Y., & Wang, S. L. (2003). Fuzzy data mining for interesting generalized association rules. *Fuzzy Sets and Systems*, 138(2), 255–269. [https://doi.org/10.1016/S0165-0114\(02\)00272-5](https://doi.org/10.1016/S0165-0114(02)00272-5)
- Imtiyaz, M. (2015). Evaluating the Quality of Teaching in Higher Education Institutes using Clustering Approach and Set Pair Analysis. In *1st International Conference on Next Generation Computing Technologies (NGCT-2015)* (pp. 4–5).
- Jeno, L. M., Grytnes, J.-A., & Vandvik, V. (2017). The effect of a mobile-application tool on biology students' motivation and achievement in species



- identification: A Self-Determination Theory perspective. *Computers & Education*, 107, 1–12. <https://doi.org/10.1016/j.compedu.2016.12.011>
- Johnson, R. A. (Richard A., & Wichern, D. W. (1988). *Applied multivariate statistical analysis*. Prentice-Hall. Retrieved from <https://dl.acm.org/citation.cfm?id=59551>
- Kebritchi, M., Hirumi, A., & Bai, H. (2010). The effects of modern mathematics computer games on mathematics achievement and class motivation. *Computers and Education*, 55(2), 427–443. <https://doi.org/10.1016/j.compedu.2010.02.007>
- Kira, K., & Rendell, L. A. (1992). A practical approach to feature selection. In *Proceedings of the ninth international workshop on Machine learning* (pp. 249–256). Morgan Kaufmann Publishers Inc. Retrieved from <https://dl.acm.org/citation.cfm?id=142034>
- Kononenko, I. (1994). Estimating attributes: Analysis and extensions of RELIEF (pp. 171–182). Springer, Berlin, Heidelberg. [https://doi.org/10.1007/3-540-57868-4\\_57](https://doi.org/10.1007/3-540-57868-4_57)
- Kourakli, M., Altanis, I., Retalis, S., Boloudakis, M., Zbainos, D., & Antonopoulou, K. (2017). Towards the improvement of the cognitive, motoric and academic skills of students with special educational needs using Kinect learning games. *International Journal of Child-Computer Interaction*, 11, 28–39. <https://doi.org/10.1016/j.ijcci.2016.10.009>
- Landwehr, N., Hall, M., & Frank, E. (2005). Logistic model trees. *Machine Learning*, 59(1–2), 161–205. <https://doi.org/10.1007/s10994-005-0466-3>
- Langley, P., & Langley, P. (1994). Selection of Relevant Features in Machine Learning. In *Proceedings of the AAAI Fall Symposium on Relevance*, 140–144. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.54.9852>
- Law, E. L.-C. (2012). Evaluating the Learning Effect of Adaptive Digital Educational Games with Eye-Tracking. In *2012 IEEE 12th International Conference on Advanced Learning Technologies* (pp. 656–657). IEEE. <https://doi.org/10.1109/ICALT.2012.155>
- Liang, L., Liu, F., Li, M., He, K., & Xu, G. (2016). Feature selection for machine

fault diagnosis using clustering of non-negation matrix factorization, *94*, 295–305.

- Lo, J. J., & Lin, F. M. (2012). A study of 2nd grade students' attitude on a mathematics game. *Proceedings 2012 4th IEEE International Conference on Digital Game and Intelligent Toy Enhanced Learning, DIGITEL 2012*, (Figure 1), 111–113. <https://doi.org/10.1109/DIGITEL.2012.29>
- M, A. F. (2016). The Effects of Conversation-Gambits Visual-Novel Game on Students' English Achievement and Motivation. In *International Electronics Symposium* (pp. 481–486).
- Nguyen, H.-Q., Pham, T., Vo, V., Vo, B., & Quan, T. (2018). The predictive modeling for learning student results based on sequential rules. *International Journal of Innovative Computing, Information and Control*, *14*(6), 2129–2140. <https://doi.org/0.24507/ijic.14.06.2129>
- Nyoman Sukajaya, I., Ketut Eddy Purnama, I., & Purnomo, M. H. (2015). Intelligent classification of learner's cognitive domain using bayes net, naive bayes, and j48 utilizing bloom's taxonomy-based serious game. *International Journal of Emerging Technologies in Learning*, *10*(2), 46–52. <https://doi.org/10.3991/ijet.v10i1.4451>
- Ocampo Orona, H. M., Maldonado, G. S., Salinas Martínez, N. P., & Ocampo, H. (2015). ScienceDirect Kinect TEAM: Kinesthetic Learning Applied to Mathematics Using Kinect. *Procedia Computer Science*, *75*(75), 169–172. <https://doi.org/10.1016/j.procs.2015.12.234>
- Opitz, D., & Maclin, R. (1999). Popular Ensemble Methods: An Empirical Study. *Journal of Artificial Intelligence Research*, *11*, 169–198. <https://doi.org/10.1613/jair.614>
- Pang, N. T., Steinbach, M., & Kumar, V. (2006). *Introduction to Data mining*. Boston: Pearson Addison Wesley.
- Peña-Ayala, A. (2014). Educational data mining: A survey and a data mining-based analysis of recent works. *Expert Systems with Applications*, *41*(4), 1432–1462. <https://doi.org/10.1016/j.eswa.2013.08.042>
- Peña-Ayala, A. (2014). *Educational data mining: Applications and trends*. <https://doi.org/10.1007/978-3-319-02738-8>

- Polikar, R. (2006). Ensemble based systems in decision making. *IEEE Circuits and Systems Magazine*. <https://doi.org/10.1109/MCAS.2006.1688199>
- Pong-Inwong, C., & Kaewmak, K. (2016). Improved sentiment analysis for teaching evaluation using feature selection and voting ensemble learning integration. In *2016 2nd IEEE International Conference on Computer and Communications (ICCC)* (pp. 1222–1225). IEEE. <https://doi.org/10.1109/CompComm.2016.7924899>
- Punlumjeak, W., & Rachburee, N. (2015). A comparative study of feature selection techniques for classify student performance. In *2015 7th International Conference on Information Technology and Electrical Engineering (ICITEE)* (pp. 425–429). IEEE. <https://doi.org/10.1109/ICITEED.2015.7408984>
- Purwaningsih, J. N., & Suwarno, Y. (2016). Predicting students achievement based on motivation in vocational school using data mining approach. In *2016 4th International Conference on Information and Communication Technology (ICoICT)* (pp. 1–5). IEEE. <https://doi.org/10.1109/ICoICT.2016.7571880>
- Rachburee, N., & Punlumjeak, W. (2015). A comparison of feature selection approach between greedy, IG-ratio, Chi-square, and mRMR in educational mining. In *2015 7th International Conference on Information Technology and Electrical Engineering (ICITEE)* (pp. 420–424). IEEE. <https://doi.org/10.1109/ICITEED.2015.7408983>
- Rahman, L., Setiawan, N. A., & Permanasari, A. E. (2017). Feature selection methods in improving accuracy of classifying students' academic performance. In *2017 2nd International conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE)* (pp. 267–271). IEEE. <https://doi.org/10.1109/ICITISEE.2017.8285509>
- Rana, S., & Garg, R. (2016). Application of Hierarchical Clustering Algorithm to Evaluate Students Performance of an Institute. In *2016 Second International Conference on Computational Intelligence & Communication Technology (CICT)* (pp. 692–697). IEEE. <https://doi.org/10.1109/CICT.2016.143>
- Rich, E., & Knight, K. (1991). *Artificial intelligence*. McGraw-Hill. Retrieved from <https://dl.acm.org/citation.cfm?id=574820>
- Rodrigues, M. W., Zárate, L. E., & Isotani, S. (2018). Educational Data Mining: A

- review of evaluation process in the e-learning. *Telematics and Informatics*.  
<https://doi.org/10.1016/j.tele.2018.04.015>
- Rokach, L. (2010). Ensemble-based classifiers. *Artificial Intelligence Review*,  
 33(1–2), 1–39. <https://doi.org/10.1007/s10462-009-9124-7>
- Rousseeuw, P. J. (1987). *Silhouettes*: a graphical aid to the interpretation and  
 validation of cluster analysis, *20*, 53–65.
- Sardiman, A. M. (2005). *Interaksi dan Motivasi Belajar Mengajar*. Jakarta: Raja  
 Grafindo Persada.
- Sasi Regha, R., Uma, R., & Associate, R. (2016). Optimization Feature Selection  
 for classifying student in Educational Data Mining. *International Journal of  
 Innovations in Engineering and Technology (IJJET)*, 490(4). Retrieved from  
<http://ijiet.com/wp-content/uploads/2017/01/65.pdf>
- Shahriarpour, N., & kafi, Z. (2014). On the Effect of Playing Digital Games on  
 Iranian Intermediate EFL Learners' Motivation toward Learning English  
 Vocabularies. *Procedia - Social and Behavioral Sciences*, 98, 1738–1743.  
<https://doi.org/10.1016/j.sbspro.2014.03.601>
- Solorio-Fernández, S., Carrasco-Ochoa, J. A., & Martínez-Trinidad, J. F. (2016). A  
 new hybrid filter–wrapper feature selection method for clustering based on  
 ranking. *Neurocomputing*, 214, 866–880.  
<https://doi.org/10.1016/J.NEUCOM.2016.07.026>
- Starczewski, A., & Krzyżak, A. (2015). Performance Evaluation of the *Silhouette*  
 Index (pp. 49–58). Springer, Cham. [https://doi.org/10.1007/978-3-319-19369-4\\_5](https://doi.org/10.1007/978-3-319-19369-4_5)
- Stella, L., Pedrozo, R., Rodríguez-artacho, M., & Member, I. S. (2013). A cluster-  
 based analysis to diagnose students' learning achievements (pp. 1118–1123).
- Sukajaya, I. ., Nugroho, S. M. S., Ketut Eddy Purnama, I., & Purnomo, M. H.  
 (2015). A NEW APPROACH OF LEARNERS' ASSESSMENT USING  
 BLOOM'S TAXONOMY-BASED SERIOUS GAME. *Kursor*, 8(2), 51–66.  
<https://doi.org/10.21107/KURSOR.V8I2.2305>
- Swindel, B. F. (1981). Geometry of Ridge Regression Illustrated. *The American  
 Statistician*, 35(1), 12. <https://doi.org/10.2307/2683577>
- Tan, P.-N., Steinbach, M., & Kumar, V. (2005). *Introduction to data mining*.

Pearson Addison Wesley.

- Tibshirani, R. (1996). Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*. WileyRoyal Statistical Society. <https://doi.org/10.2307/2346178>
- Troussas, C., Virvou, M., & Mesaretzidis, S. (2015). Comparative Analysis of algorithms for student characteristics classification using a Methodological Framework. In *6th International Conference on Information, Intelligence, Systems and Applications (IISA)*. IEEE.
- Wanarti, P., Ismayanti, E., Peni, H., & Yamasari, Y. (2016). The Enhancement of Teaching-Learning Process Effectiveness through The Development of Instructional Media Based on E-learning of Surabaya's Vocational Student. In *Proceedings of the 6th International Conference on Educational, Management, Administration and Leadership* (pp. 342–346). Paris, France: Atlantis Press. <https://doi.org/10.2991/icemal-16.2016.71>
- Winkel, W. . (2007). *Psikologi Pengajaran*. Yogyakarta: Media Abadi.
- Witten, I. H., Frank, E., & Hall, M. a. (2011). *Data Mining: Practical Machine Learning Tools and Techniques, Third Edition. Annals of Physics* (Vol. 54). [https://doi.org/10.1002/1521-3773\(20010316\)40:6<9823::AID-ANIE9823>3.3.CO;2-C](https://doi.org/10.1002/1521-3773(20010316)40:6<9823::AID-ANIE9823>3.3.CO;2-C)
- Yamasari, Y., Mardiyanto, S., Nugroho, S., Yoshimoto, K., Takahashi, H., & Purnomo, M. H. (2019). Information and Control ICIC International ©2019 ISSN. *International Journal of Innovative Computing*, 15(6), 2085–2107. <https://doi.org/10.24507/ijicic.15.06.2085>
- Yamasari, Y., Nugroho, S. M. S., Harimurti, R., & Purnomo, M. H. (2018). Improving the cluster validity on student's psychomotor domain using feature selection. In *2018 International Conference on Information and Communications Technology (ICOI ACT)* (pp. 460–465). IEEE. <https://doi.org/10.1109/ICOI ACT.2018.8350744>
- Yamasari, Y., Nugroho, S. M. S., Sukajaya, I. N., & Purnomo, M. H. (2016). Features extraction to improve performance of clustering process on student achievement. In *2016 International Computer Science and Engineering Conference (ICSEC)* (pp. 1–5). IEEE.

<https://doi.org/10.1109/ICSEC.2016.7859946>

- Yamasari, Y., Nugroho, S. M. S., Yoshimoto, K., Takahashi, H., & Purnomo, M. H. (2020). Identifying Dominant Characteristics of Students' Cognitive Domain on Clustering-based Classification. *International Journal of Intelligent Engineering and Systems*, 13(1). <https://doi.org/10.22266/ijies2020.0229.16>
- Yamasari, Y., & Qoiriah, A. (2017). Enhancing the similarity level using features selection on student achievement clustering. In - *2nd International Symposium Of Information And Internet Technology (SYMINTeCH)* (p. Transferred to JAMT).
- Yamasari, Y., Rusimamto, P. W., Rochmawati, N., Suyatno, D. F., Wibawa, S. C., Nugroho, S. M. S., & Purnomo, M. H. (2018). Discretization method to optimize logistic regression on classification of student's cognitive domain. *MATEC Web of Conferences*, 197, 03006. <https://doi.org/10.1051/mateconf/201819703006>
- Yildirim, I. (2017). The effects of gamification-based teaching practices on student achievement and students' attitudes toward lessons ☆. *The Internet and Higher Education*, 33, 86–92. <https://doi.org/10.1016/j.iheduc.2017.02.002>
- Zaffar, M., Hashmani, M. A., & Savita, K. S. (2017). Performance analysis of feature selection algorithm for educational data mining. In *2017 IEEE Conference on Big Data and Analytics (ICBDA)* (pp. 7–12). IEEE. <https://doi.org/10.1109/ICBDAA.2017.8284099>
- Zhou, J., Chen, L., Chen, C. L. P., Zhang, Y., & Li, H. (2016). Neurocomputing Fuzzy clustering with the entropy of attribute weights, *198*, 125–134.

- Halaman ini sengaja dibiarkan kosong -



## APENDIKS 1 RIWAYAT HIDUP

Nama : YUNI YAMASARI  
Tempat dan Tanggal Lahir : TULUNGAGUNG, 2 JUNI 1975

### Kantor:

Kampus Unesa  
Jl. Ketintang Wiyata VIII No.18,  
Ketintang, Kec. Gayungan, Kota SBY,  
Jawa Timur 60231, Surabaya  
Telp: +6231-99423002  
Fax: +6231-99424002  
E-mail: [yuniyamasari@unesa.ac.id](mailto:yuniyamasari@unesa.ac.id)  
Homepage:  
<https://www.unesa.ac.id/>

### Rumah:

Perum YKP, Wisma Medokan F-6, Rungkut, Surabaya  
Cellphone: 08123072197  
E-mail: [yamasari2010@gmail.com](mailto:yamasari2010@gmail.com)  
[yamasari16@mhs.ce.its.ac.id](mailto:yamasari16@mhs.ce.its.ac.id)  
Linkedin:<https://www.linkedin.com/in/yuni-yamasari-b20120139/?originalSubdomain=id>  
Scholar google:  
<https://scholar.google.co.id/citations?hl=en&user=hn5jrnAAAAAJ>  
Scopus:  
<https://www.scopus.com/authid/detail.uri?authorId=57193733535>

### Pendidikan

S2-Teknik Informatika, Institut Teknologi Sepuluh Nopember, 2005 – 2008  
S1-Teknik Informatika, Institut Teknologi Sepuluh Nopember, 1995-2001

### Pekerjaan

Dosen Universitas Negeri Surabaya, 2003-sekarang

### Pelatihan dan Penghargaan

Beasiswa Peningkatan Kualitas Publikasi Internasional (PKPI) atau Sandwich like sept-  
desember 2018, Osaka, Japan.  
Dana Insentif Jurnal bereputasi internasional Q2 untuk 2 jurnal dari BUDI-DN/LPDP  
tahun 2019  
Dana Konferensi Internasional untuk 2 makalah dari BUDI-DN/LPDP tahun 2016 dan  
2019



- Halaman ini sengaja dibiarkan kosong -



## APENDIKS 2 DAFTAR PUBLIKASI

No.	Judul	Pengarang	Tipe>Nama Publikasi	Status
<b>Jurnal Internasional bereputasi terindek scopus</b>				
1	Expanding Tree-based Classifiers using Meta-Algorithm Approach: An Application for Identifying Students' Cognitive Level	<b>Yuni Yamasari</b> , Supeno M. S. Nugroho, Kayo Yoshimoto, Hideya Takahashi and Mauridhi H. Purnomo	The International Journal of Innovative Computing, Information and Control (IJICIC), ICIC International, Japan	Published
2	Identifying Dominant Characteristics of Students' Cognitive Domain on Clustering-based Classification	<b>Yuni Yamasari</b> , Supeno M. S. Nugroho, Kayo Yoshimoto, Hideya Takahashi, Mauridhi H. Purnomo	International Journal of Intelligent Engineering and Systems (IJIES), the Intelligent Networks and Systems Society, Japan	Published
<b>Jurnal terakreditasi Nasional</b>				
3	Meta-Algoritma Adaptive Boosting untuk Meningkatkan Kinerja dari Metode Klasifikasi pada Prestasi Belajar Mahasiswa	<b>Yuni Yamasari</b> , Supeno M. S. Nugroho, Dwi F. Suyatno, Mauridhi H. Purnomo	Jurnal Nasional Terakreditasi Jurnal Nasional Teknik Elektro dan Teknologi Informasi (JNTETI), Vol 6, No. 3, 2017	Published
<b>Konferensi Internasional</b>				
4.	Features Extraction to Improve Performance of Clustering Process on Student Achievement	<b>Yuni Yamasari</b> ; <u>Supeno M. S. Nugroho</u> ; <u>I.N. Sukajaya</u> ; <u>Mauridhi H. Purnomo</u>	<i>Conferences Proceeding – IEEE in 2016 International Computer Science and Engineering Conference (ICSEC), Thailand, Chiangmai, 14 - 17 December 2016</i>	Published
5.	Improving the cluster validity on student's psychomotor domain using feature selection	<b>Y. Yamasari</b> ; S. M. S. Nugroho ; R. Harimurti ; M. H. Purnomo	<i>Conferences Proceeding - International Conference on Information and Communications Technology (ICOIAC), Yogyakarta, 6-7 March 2018</i>	Published
6.	Enhancing the Classification Performance of Students' Behavior on Serious Game using Discretization-based k-NN	<b>Yuni. Yamasari</b> , M. H. Garry, Supeno. M. S. Nugroho, M. H. Purnomo	<i>Conferences Proceeding – TALE (Teaching, Assessment, Learning and Engineering), The IEEE Education Society's flagship Asia-Pacific (IEEE Region 10), Yogyakarta, 10-13 December 2019.</i>	Presented
7.	Discretization Method to Optimize Logistic Regression on Classification of	<b>Yuni Yamasari</b> , Puput W. Rusimamto, Naim Rochmawati, Dwi F. Suyatno, Setya C. Wibawa,	<i>Conferences Proceeding –the 3rd Annual Applied Science and Engineering</i>	Published

No.	Judul	Pengarang	Tipe/Nama Publikasi	Status
	Student's Cognitive Domain	Supeno M. S. Nugroho and Mauridhi H. Purnomo	Conference (AASEC), Bandung, 18 April 2018.	
8.	Improving the Performance of Kernel Selection-based SVM for Student's Cognitive Classification	<b>Yuni Yamasari</b> , Supeno M.S. Nugroho, Hapsari P.A. Tjahyaningtjasa, Anita Qoiriah, Mauridhi H. Purnomo	<i>Conferences Proceeding</i> – Annual Conference on Engineering and Applied Science (ACEAT), Osaka, Japan, November 27-29, 2018.	Published
9.	Enhancing the Similarity Level using Features Selection on Student Achievement Clustering	<b>Y. Yamasari</b> , S. M. S. Nugroho, A. Qoiriah, A. I. Nurhidayat, R. E. Putra, H. P. A. Tjahyaningtjasa, M. H. Purnomo	<i>Conferences Proceeding</i> - 2nd International Symposium Of Information And Internet Technology (SYMINTECH), Phuket, Thailand 10 – 12 October 2017.	Transferred to JAMT (Journal of Advanced Manufacturing Technology).
10.	Improving the Classification Performance of Students' Pattern on E-Learning System using Bagging Algorithm	A. Qoiriah, R.E. Putra, <b>Y. Yamasari</b> , A.I. Nurhidayat, Y. Anistyasari, R. Harimurti, A.Y. Wicaksono	<i>Conferences Proceeding</i> - 2nd International Symposium Of Information And Internet Technology (SYMINTECH), Phuket, Thailand 10 – 12 October 2017.	Transferred to JAMT (Journal of Advanced Manufacturing Technology).
11.	<u>Predicting student's psychomotor domain on the vocational senior high school using linear regression</u>	R.Harimurti ; <b>Y. Yamasari</b> ; Ekohariadi ; Munoto ; B. I. G. P. Asto	<i>Conferences Proceeding</i> - <u>International Conference on Information and Communications Technology (ICOLACT)</u> , Yogyakarta, 6-7 March 2018	Published
12.	Design and Implementation Serious Game "Tic Tac Toe Math"	Muhammad H. Garry, <b>Yuni Yamasari</b> , Supeno Mardi Susiki Nugroho, Mauridhi H. Purnomo	<i>Conferences Proceeding</i> – International Conference on Computer Engineering Network and Intelligent Multimedia (CENIM), Surabaya, 19 - 20 November, 2019.	Published

