

**PERBANDINGAN ALGORITMA NAÏVE BAYES DAN  
DECISION TREE DALAM KLASIFIKASI MAHASISWA  
TEPAT WAKTU**

(Studi Kasus : Prodi Informatika Fakultas Ilmu Komputer Unisan Gorontalo)

**Oleh**  
**SANDI KISMAN**  
**T3119075**

**SKRIPSI**

**Untuk memenuhi salah satu syarat ujian  
Guna memperoleh gelar sarjana**



**PROGRAM SARJANA  
TEKNIK INFORMATIKA  
UNIVERSITAS IHSAN GORONTALO  
GORONTALO  
2024**

**HALAMAN PERSETUJUAN SKRIPSI**

**PERBANDINGAN *ALGORITMA NAÏVE BAYES DAN DECISION TREE DALAM KLASIFIKASI MAHASISWA TEPAT WAKTU***

(Studi Kasus : Prodi Informatika Fakultas Ilmu Komputer Unisan Gorontalo)

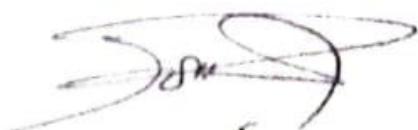
Oleh  
SANDI KISMAN  
T3119075

**SKRIPSI**

Untuk memenuhi salah satu syarat ujian  
Guna untuk memperoleh gelar sarjana  
Program Studi Teknik Informatika

Telah disetujui dan siap diseminarkan  
Gorontalo, Desember 2024

Pembimbing I



Irvan Abraham Salih, M.Kom  
NIDN : 0924038205

Pembimbing II



Abd. Rahmat Karim Haba, M. Kom  
NIDN : 0923118703

**PENGESAHAN SKRIPSI**  
**PERBANDINGAN *ALGORITMA NAÏVE BAYES DAN***  
***DECISION TREE DALAM KLASIFIKASI MAHASISWA***  
**TEPAT WAKTU**

(Studi Kasus : Prodi Informatika Fakultas Ilmu Komputer Unisan Gorontalo)

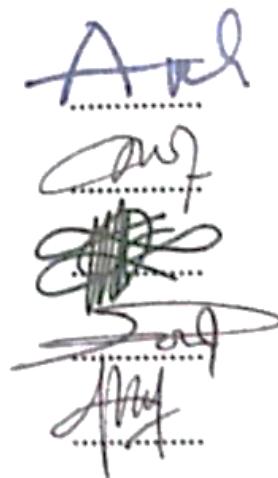
Oleh  
SANDI KISMAN  
T3119075

**SKRIPSI**

Di Periksa Oleh Panitia Ujian Strata Satu (S1)

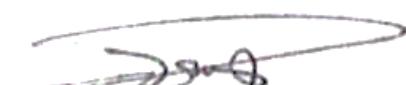
Universitas Ichsan Gorontalo

1. Ketua Pengaji  
Amiruddin, M.Kom, MCF
2. Anggota  
Hariati Husain, Sh., S.kom.,M.kom
3. Anggota  
Zulfrianto Y Lamasigi, M.Kom
4. Anggota  
Irvan Abraham Salihi, M.Kom
5. Anggota  
Abd. Rahmat Karim Haba, M.Kom



Mengetahui,

Dekan Fakultas Ilmu Komputer



Irvan Abraham Salihi, M.kom  
NIDN : 0924038205

Ketua Program Studi



Sudirman S. Pauna, M.Kom  
NIDN : 0924038025

### **PERNYATAAN SKRIPSI**

Dengan ini saya menyatakan bahwa :

1. Karya tulis (Skripsi) saya ini adalah asli dan belum pernah di ajukan untuk mendapatkan gelar akademik (Sarjana) baik di Universitas Ichsan Gorontalo maupun di perguruan tinggi lainnya
2. Karya tulis (Skripsi) saya ini adalah murni gagasan, rumusan dan penelitian saya sendiri, tanpa bantuan pihak lain, kecuali arahan dari pembimbing.
3. Dalam karya tulis (Skripsi) saya ini tidak terdapat karya atau pendapat yang telah dipublikasikan orang lain, kecuali secara tertulis di cantumkan sebagai acuan/situs dalam naskah dan di cantumkan pula dalam daftar pustaka.
4. Pernyataan ini saya buat dengan sesungguhnya dan apabila dikemudian hari terdapat penyimpanan dan ketidakbenaran dalam pernyataan ini, maka saya bersedia menerima sanksi akademik berupa pencabutan gelar yang telah diperoleh karena karya tulis ini, serta sanksi lainnya sesuai dengan norma-norma yang telah berlaku di Universitas Ichsan Gorontalo

Gorontalo, Desember 2024

Yang membuat pernyataan



Sandi Kisman

## **ABSTRACT**

**SANDI KISMAN. T3119075. THE COMPARISON OF NAIVE BAYES AND DECISION TREE ALGORITHMS IN THE CLASSIFICATION OF ON-TIME STUDENTS**

*This study applies the Naive Bayes and Decision Tree algorithms for attribute selection in classifying on-time student graduation. The data used were student data from the Informatics Study Program of Universitas Ichsan Gorontalo consisting of 8 attributes, namely IPS1, IPS2, IPS3, IPS4, IPS5, Gender, Class, and Graduation Status. The results of this study indicate that the Decision Tree algorithm is superior in classifying on-time students with an accuracy of 97.87%, and the Naive Bayes algorithm has an accuracy of 97.70%. Both algorithms are implemented using RapidMiner software to carry out the classification and model evaluation process. Although both algorithms show very well performance, the Decision Tree is slightly more accurate in predicting the status of on-time student graduation. These results can be used to help decision-making in academic management, especially in predicting students with the potential to graduate on time.*

*Keywords:* Decision Tree, Naive Bayes, classification, student graduation time



## **ABSTRAK**

**SANDI KISMAN. T3119075. PERBANDINGAN ALGORITMA NAIVE BAYES DAN DECISION TREE DALAM KLASIFIKASI MAHASISWA TEPAT WAKTU**

Dalam penelitian ini, dilakukan penerapan algoritma Naive Bayes dan Decision Tree untuk seleksi atribut dalam klasifikasi kelulusan mahasiswa tepat waktu. Data yang digunakan adalah data mahasiswa Universitas Ichsan Gorontalo Program Studi Informatika yang terdiri dari 8 atribut, yaitu IPS1, IPS2, IPS3, IPS4, IPS5, Jenis Kelamin, Kelas, dan Status Kelulusan. Hasil penelitian ini menunjukkan bahwa algoritma Decision Tree lebih unggul dalam mengklasifikasi mahasiswa tepat waktu dengan akurasi mencapai 97.87%, sementara algoritma Naive Bayes memiliki akurasi sebesar 97.70%. Kedua algoritma ini diterapkan menggunakan perangkat lunak RapidMiner untuk melakukan proses klasifikasi dan evaluasi model. Meskipun kedua algoritma menunjukkan performa yang sangat baik, Decision Tree sedikit lebih akurat dalam memprediksi status kelulusan mahasiswa tepat waktu. Hasil ini dapat digunakan untuk membantu pengambilan keputusan dalam manajemen akademik, terutama dalam memprediksi mahasiswa yang berpotensi lulus tepat waktu.

Kata kunci: Decision Tree, Naive Bayes, klasifikasi, waktu kelulusan mahasiswa



## KATA PENGANTAR

Alhamdulillah, penulis dapat menyelesaikan Skripsi ini dengan judul **“Perbandingan algoritma *Naïve Bayes* dan *Decision Tree* dalam klasifikasi mahasiswa tepat waktu (Studi Kasus : Prodi Informatika Fakultas Ilmu Komputer Unisan Gorontalo”**, untuk memenuhi salah satu syarat penyusunan Skripsi Program Studi Teknik Informatika Fakultas Ilmu Komputer Universitas Ichsan Gorontalo.

Penulis menyadari sepenuhnya bahwa Skripsi ini tidak mungkin terwujud tanpa bantuan dan dorongan dari berbagai pihak, baik bantuan moril maupun materil. Untuk itu, dengan segala keikhlasan dan kerendahan hati, penulis mengucapkan banyak terima kasih dan penghargaan yang setinggi-tingginya kepada:

1. Ibu Dr. Dra. Juriko Abdussamad, M.Si, selaku ketua Yayasan Pengembangan Ilmu Pengetahuan dan Teknologi (YPIPT) Ichsan Gorontalo;
2. Bapak Dr. Abdul Gaffar La Tjokke, M.Si, selaku Rektor Universitas Ichsan Gorontalo;
3. Bapak Irvan A. Salihi, S.Kom, M.Kom, selaku Dekan Fakultas Ilmu Komputer Universitas Ichsan Gorontalo;
4. Bapak Sudirman Melangi, M.Kom, selaku Wakil Dekan I Bidang Akademik Fakultas Ilmu Komputer;
5. Ibu Irma Surya Kumala, M.Kom, selaku Wakil Dekan II Bidang Administrasi Umum dan Keuangan Fakultas Ilmu Komputer;
6. Bapak Sudirman S. Panna, M.Kom, selaku Ketua Jurusan Teknik Informatika Fakultas Ilmu Komputer Universitas Ichsan Gorontalo;
7. Bapak Irvan A. Salihi, S.Kom, M.Kom, selaku Pembimbing I yang telah banyak membimbing penulis selama ini;
8. Abd. Rahmat Karim Haba, M. Kom, selaku Pembimbing II yang telah banyak membimbing penulis selama ini;
9. Bapak dan Ibu Dosen Universitas Ichsan Gorontalo yang telah mendidik dan mengajarkan berbagai disiplin ilmu kepada penulis;

10. Kepada Orang tua yang telah memberikan doa, dukungan yang sangat-sangat besar kepada penulis;
11. Rekan-rekan seperjuangan yang telah banyak memberikan bantuan dan dukungan moril yang sangat besar kepada penulis;
12. Kepada semua pihak yang ikut membantu dan mendukung penulis dalam penyelesaian Skripsi ini yang tak sempat penulis sebutkan satu persatu.

Semoga Allah, SWT melimpahkan balasan atas jasa-jasa mereka kepada kami. Penulis menyadari sepenuhnya bahwa apa yang telah dicapai ini masih jauh dari kesempurnaan dan masih banyak terdapat kekurangan, oleh karena itu, penulis sangat mengharapkan adanya kritik dan saran yang konstruktif. Akhirnya penulis berharap semoga hasil yang telah dicapai ini dapat bermanfaat bagi kita semua, Amiin.

Gorontalo, November 2024

Penulis

## DAFTAR ISI

<b>HALAMAN JUDUL .....</b>	<b>i</b>
<b>HALAMAN PERSETUJUAN SKRIPSI.....</b>	Error! Bookmark not defined.
<b>KATA PENGANTAR.....</b>	<b>vii</b>
<b>DAFTAR ISI .....</b>	<b>ix</b>
<b>DAFTAR TABEL .....</b>	<b>xi</b>
<b>DAFTAR GAMBAR.....</b>	<b>xii</b>
<b>BAB I PENDAHULUAN .....</b>	<b>1</b>
1.1    Latar Belakang.....	1
1.2    Identifikasi Masalah.....	3
1.3    Rumusan Masalah.....	3
1.4    Tujuan Penelitian .....	3
1.5    Manfaat Penelitian .....	3
1.5.1    Manfaat Teoritis .....	3
1.5.2    Manfaat Praktis.....	3
<b>BAB II LANDASAN TEORI.....</b>	<b>4</b>
2.1    Tinjauan Studi .....	4
2.1    Tinjauan Pustaka.....	5
2.1.1    Mahasiswa.....	5
2.1.2    Data Mining.....	6
2.1.3    Klasifikasi .....	6
2.1.4    Algoritma Decesion Tree .....	7
2.1.5    Algoritma <i>Naive Bayes</i> .....	8

2.1.6	Penerapan Algoritma <i>Naive Bayes</i> Dan <i>Decision tree</i> .....	9
2.1.7	<i>RapidMiner</i> .....	16
2.1.8	Confussion Matrix .....	17
2.1.9	Perangkat Lunak .....	18
2.1.10	Kerangka Pikir.....	19
<b>BAB III METODE PENELITIAN.....</b>		<b>20</b>
3.1	Jenis, Metode, Subjek, Objek, Waktu, dan Lokasi Penelitian .....	20
3.2	Pengumpulan Data.....	20
3.3	Pemodelan .....	22
<b>BAB IV HASIL PENELITIAN .....</b>		<b>24</b>
4.1	Data Penelitian.....	24
4.2	Hasil Pemodelan .....	25
4.3	Prapengelolahan Data .....	27
<b>BAB V.....</b>		<b>42</b>
5.1	Analisis Data .....	42
<b>BAB VI KESIMPULAN DAN SARAN.....</b>		<b>56</b>
6.1	Kesimpulan.....	56
6.2	Saran .....	56

## DAFTAR TABEL

<b>Tabel 2. 1</b> Penelitian Terkait.....	4
<b>Tabel 2. 2</b> Hasil Perhitungan Nilai Akurasi dari Decision Tree .....	13
<b>Tabel 2. 3</b> Hasil Perhitungan Nilai Akurasi dari Naïve Bayes .....	14
<b>Tabel 2. 4</b> Perbandingan metode Decision Tree dan Naïve Bayes .....	15
<b>Tabel 2. 5</b> Fungsi Perangkat Lunak Pendukung .....	18
<b>Tabel 3. 1</b> Variabel Data.....	21
<b>Tabel 3. 2</b> Data Alumni Mahasiswa Universitas Ichsan Gorontalo .....	21
<b>Tabel 4. 1</b> Hasil Pengumpulan Data Set.....	24
<b>Tabel 4. 2</b> DataSet Excel .....	24
<b>Tabel 4. 3</b> Dataset Pemodelan.....	26
<b>Tabel 4. 4</b> Dataset Training .....	32
<b>Tabel 4. 5</b> Dataset Testing .....	33
<b>Tabel 4. 6</b> Menentukan Entropy.....	34
<b>Tabel 4. 7 Tabel</b> Entropy dan Gain Setiap Atribut .....	35
<b>Tabel 4. 8</b> Data Training .....	37
<b>Tabel 4. 9</b> Data Rata-Rata Tepat Waktu.....	38
<b>Tabel 4. 10</b> Data Rata-Rata Tidak Tepat Waktu.....	39
<b>Tabel 4. 11</b> Data Rata-Rata Tidak Tepat Waktu.....	40
<b>Tabel 5. 1</b> Dataset Excel.....	42
<b>Tabel 5. 2</b> Hasil Perhitungan Confussion Matrix.....	48
<b>Tabel 5. 3</b> Perhitungan Confussion Matrix.....	53
<b>Tabel 5. 4</b> Perbandingan Tingkat Akurasi Decision Tree dan Naive Bayes .....	55

## DAFTAR GAMBAR

<b>Gambar 2. 1</b> Proses Knowledge Discovery in Database (KDD) .....	6
<b>Gambar 2. 2</b> Data Mahasiswa .....	10
<b>Gambar 2. 3</b> Proses Transformasi Data .....	11
<b>Gambar 2. 4</b> Pohon Keputusan .....	12
<b>Gambar 2. 5</b> Kerangka Pikir. ....	19
<b>Gambar 3. 1</b> Pemodelan.....	22
<b>Gambar 4. 1</b> Import Data RapidMiner .....	27
<b>Gambar 4. 2</b> Hasil Pembacaan Dataset Dari Rapidminer.....	28
<b>Gambar 4. 3</b> Seleksi Atribut .....	28
<b>Gambar 4. 4</b> Hasil Seleksi Atribut .....	29
<b>Gambar 4. 5</b> Kode Program Menentukan Status Kelulusan .....	29
<b>Gambar 4. 6</b> Hasil Perhitungan jumlah kategori pada Colom “Status” .....	30
<b>Gambar 4. 7</b> Proses Pembagian Data Training Dan Data Testing Rapidminer ...	31
<b>Gambar 4. 8</b> Output Proses Pembagian Data Training Dan Data Testing .....	32
<b>Gambar 4. 9</b> Pohon Keputusan .....	36
<b>Gambar 5. 1</b> Proses Seleksi Atribut .....	43
<b>Gambar 5. 2</b> Hasil Seleksi Atribut .....	44
<b>Gambar 5. 3</b> Diagram Status Kelulusan Mahasiswa .....	45
<b>Gambar 5. 4</b> Hasil Penentuan Atribut status kelulusan pada dataset .....	46
<b>Gambar 5. 5</b> Proses Pemodelan Decision Tree .....	47
<b>Gambar 5. 6</b> Hasil Confussion Matrix Decision Tree .....	48
<b>Gambar 5. 7</b> Data Mining Accuracy Results Decision Tree.....	50
<b>Gambar 5. 8</b> Pohon Keputusan .....	50
<b>Gambar 5. 9</b> Proses Pemodelan Naive Bayes .....	51
<b>Gambar 5. 10</b> Hasil Confussion Matrix Naive Bayes .....	52
<b>Gambar 5. 11</b> Data Mining Accuracy Results Naive Bayes.....	54

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Dalam dunia pendidikan tinggi, baik Perguruan Tinggi Negeri (PTN) maupun Perguruan Tinggi Swasta (PTS) terus meningkatkan kualitas layanan mereka untuk mencetak lulusan yang kompeten dan tepat waktu [1]. Institusi pendidikan memiliki peran penting dalam menyediakan fasilitas dan bimbingan yang mendukung keberhasilan mahasiswa dalam menyelesaikan studi sesuai jadwal. Namun demikian, beberapa mahasiswa sering kali menghadapi tantangan yang menghambat kelulusan tepat waktu, yang pada akhirnya dapat berdampak pada reputasi akademik dan performa institusi secara keseluruhan [2]. Sistem prediksi kelulusan mahasiswa tepat waktu dapat menjadi solusi strategis untuk membantu pihak universitas dalam mengidentifikasi mahasiswa yang memerlukan perhatian khusus. Beragam faktor, seperti prestasi akademik, situasi finansial, dan kondisi sosial, sering kali menjadi penghambat utama bagi mahasiswa untuk lulus sesuai jadwal. Penelitian ini bertujuan untuk mengklasifikasikan mahasiswa yang berpotensi lulus tepat waktu dan menganalisis faktor-faktor yang berkontribusi terhadap kelulusan tersebut. Dengan demikian, kebijakan kampus dapat lebih terfokus dan efektif dalam membantu mahasiswa. Kemajuan teknologi informasi memberikan peluang untuk menerapkan machine learning dalam pengolahan data akademik. Algoritma seperti Naïve Bayes dan Decision Tree telah banyak digunakan untuk memecahkan masalah klasifikasi. Keduanya memiliki pendekatan yang berbeda dalam menganalisis data, sehingga menarik untuk dibandingkan.

Naïve Bayes adalah algoritma berbasis probabilitas yang memanfaatkan Teorema Bayes dengan asumsi independensi antar atribut. Metode ini dikenal karena kesederhanaannya dan kemampuannya dalam menangani dataset besar. Sebaliknya, Decision Tree menggunakan pendekatan berbasis pohon keputusan yang membagi dataset ke dalam kelompok berdasarkan aturan tertentu. Algoritma

ini mudah dipahami dan hasilnya dapat divisualisasikan, meskipun memiliki risiko overfitting jika tidak diatur dengan baik [1].

Penelitian sebelumnya oleh Eka Putra dan Siti Nurhaliza menunjukkan bahwa Naïve Bayes memiliki tingkat akurasi hingga 92,50% dalam klasifikasi data akademik mahasiswa [2]. Di sisi lain, penelitian yang dilakukan oleh Fahmi Ramadhan dan Linda Ayu mengungkapkan bahwa Decision Tree mampu menghasilkan model klasifikasi yang intuitif dan efektif dalam data terstruktur [3]. Selain itu, studi dari Daniel Setiawan dan Rika Amelia menyimpulkan bahwa Decision Tree lebih unggul dalam menangani dataset dengan banyak atribut saling terkait, sedangkan Naïve Bayes lebih efisien untuk data yang atributnya independen [4].

Pemilihan Naïve Bayes dan Decision Tree sebagai algoritma dalam penelitian ini didasarkan pada karakteristiknya yang efisien, cepat, dan mudah diinterpretasikan. Naïve Bayes sangat cocok untuk data dengan atribut yang independen, sementara Decision Tree menawarkan keunggulan dalam menangani data kompleks dengan hubungan antar atribut. Kombinasi kedua metode ini memungkinkan analisis yang komprehensif terhadap pola data akademik mahasiswa.

Penelitian ini bertujuan untuk membandingkan performa antara algoritma Naïve Bayes dan Decision Tree dalam mengklasifikasikan mahasiswa yang lulus tepat waktu. Dengan membandingkan metrik seperti akurasi, presisi, recall, dan F1-score, penelitian ini diharapkan dapat memberikan panduan algoritma mana yang lebih sesuai untuk diterapkan. Hasilnya akan membantu pihak universitas dalam mengambil langkah preventif dan strategis untuk mendukung mahasiswa mencapai kelulusan tepat waktu. Maka peneliti sangat tertarik untuk mengangkat topik penelitian dengan judul **“Perbandingan algoritma Naïve Bayes dan Decision Tree dalam klasifikasi mahasiswa tepat waktu”**.

## 1.2 Identifikasi Masalah

Perguruan tinggi membutuhkan metode yang dapat membantu memprediksi kelulusan mahasiswa secara tepat untuk mendukung pengambilan keputusan dalam meningkatkan kualitas layanan akademik.

## 1.3 Rumusan Masalah

Dari pengertian dan penjelasan masalah di latar belakang, maka diperoleh rumusan masalah berupa :

1. Bagaimana performa algoritma *Naïve Bayes* dan *Decision Tree* dalam mengklasifikasikan mahasiswa yang lulus tepat waktu?
2. Algoritma mana yang memiliki kinerja lebih baik dalam memprediksi kelulusan tepat waktu berdasarkan hasil analisis data?

## 1.4 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah :

1. Menganalisis performa algoritma *Naïve Bayes* dan *Decision Tree* dalam memprediksi kelulusan mahasiswa tepat waktu.
2. Membandingkan hasil prediksi antara algoritma Naïve Bayes dan Decision Tree untuk menentukan algoritma yang paling efektif.

## 1.5 Manfaat Penelitian

### 1.5.1 Manfaat Teoritis

Penelitian ini dapat menjadi referensi untuk pengembangan studi lebih lanjut mengenai penerapan algoritma machine learning dalam klasifikasi dan prediksi data akademik.

### 1.5.2 Manfaat Praktis

Penelitian ini berkontribusi dalam menambah wawasan mengenai keunggulan dan kekurangan algoritma Naïve Bayes dan Decision Tree dalam konteks klasifikasi data akademik mahasiswa.

## **BAB II**

### **LANDASAN TEORI**

#### **2.1 Tinjauan Studi**

Berikut merupakan daftar penelitian terdahulu yang berkaitan dengan judul dan metode yang digunakan :

**Tabel 2. 1Penelitian Terkait**

No	PENELITI	JUDUL	TAHUN	METODE	HASIL
1	Agus Budiyantara, Irwansyah, dan Egi Prengki	Komparasi Algoritma Decision Tree, Naive Bayes Dan K-Nearest Neighbor Untuk Memprediksi Mahasiswa Lulus Tepat Waktu	2020	Decision Tree, Naïve Bayes, dan K-Nearest Neighbor	Naïve Bayes mencapai akurasi 96%, KNN 90%, dan Decision Tree 94% [5].
2	Rasi Nuraeni	Perbandingan Algoritma Naïve Bayes Classifier Dan Algoritma Decision Tree Untuk Memprediksi Lama Studi Mahasiswa	2021	Naïve Bayes dan Decision Tree	Decision Tree memiliki akurasi 55%, sedangkan Naïve Bayes 30% [6].

3	Kusrini & Prasetyo	Prediksi Tingkat Kelulusan Mahasiswa menggunakan Algoritma Naïve Bayes, Decision Tree, ANN, KNN, dan SVM Kelulusan Mahasiswa Algoritma C4.5	2021	algoritma Naïve Bayes, Decision Tree, ANN, KNN, dan SVM	Naïve Bayes menunjukkan akurasi 86,36% dalam memprediksi kelulusan mahasiswa tepat waktu. Decision Tree memiliki akurasi 81,25%, sementara algoritma lain (ANN, SVM) menunjukkan hasil yang lebih bervariasi [7].
---	--------------------	---	------	---	---

## 2.1 Tinjauan Pustaka

### 2.1.1 Mahasiswa

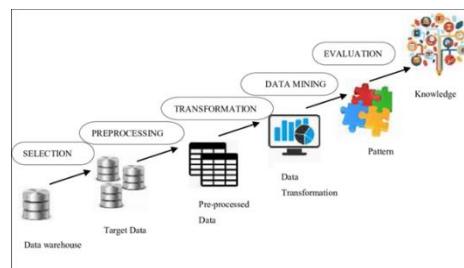
Mahasiswa adalah peserta didik pada jenjang Perguruan Tinggi. Pengertian mahasiswa dalam Kamus Besar Bahasa Indonesia (KBBI) mahasiswa adalah siswa yang belajar pada Perguruan Tinggi [8].

Mahasiswa mempunyai peranan penting dalam mewujudkan cita-cita pembangunan nasional, sementara itu Perguruan Tinggi merupakan lembaga pendidikan yang secara formal diserahi tugas dan tanggung jawab mempersiapkan mahasiswa sesuai dengan tujuan pendidikan tinggi. Tujuan pendidikan tinggi dapat tercapai apabila Tridharma Perguruan Tinggi dapat terlaksana, yaitu mampu menyelenggarakan pendidikan, melakukan penelitian dan melakukan pengabdian pada masyarakat, [8].

### **2.1.2 Data Mining**

Menurut Gartner Group, data mining adalah proses menemukan hubungan baru yang mempunyai arti, pola dan kebiasaan dengan memilah-milah sebagian besar data yang disimpan dalam media penyimpanan dengan menggunakan teknologi pengenalan pola seperti teknik statistik dan matematika. Data mining merupakan gabungan dari beberapa disiplin ilmu yang menyatukan teknik dari pembelajaran mesin, pengenalan pola, statistik, database, dan visualisasi untuk penanganan permasalahan pengambilan informasi dari database yang besar [9].

Data mining adalah proses mencari pola atau informasi menarik dalam data terpilih dengan menggunakan teknik atau metode tertentu. Teknik-teknik, metode-metode, atau algoritma dalam data mining sangat bervariasi. Pemilihan metode atau algoritma yang tepat sangat bergantung pada tujuan dan proses *Knowledge Discovery in Database* (KDD) secara keseluruhan [9].



**Gambar 2. 1 Proses Knowledge Discovery in Database (KDD)**

### **2.1.3 Klasifikasi**

Nugroho & Subanar mengatakan bahwa klasifikasi merupakan proses untuk menemukan fungsi dan model yang dapat membedakan atau menjelaskan konsep

atau kelas data dengan tujuan memperkirakan kelas yang tidak diketahui dari suatu objek. Dalam proses pengklasifikasian biasa terdapat dua proses yang harus dilakukan yaitu [10]:

1. Proses Training

Pada proses ini akan digunakan data training set atau data sampel yang telah diketahui labellabel atau atribut dari data sampel tersebut untuk membangun model [20].

2. Proses Testing

Pada proses testing ini dilakukan untuk mengetahui keakuratan model yang telah dibuat pada proses training maka dibangun data yang disebut dengan data testing untuk mengklasifikasi label-labelnya [10].

#### **2.1.4 Algoritma Decesion Tree**

Algoritma *Decision Tree* merupakan salah satu metode klasifikasi yang memanfaatkan struktur pohon untuk mengambil keputusan berdasarkan pembagian data berdasarkan fitur tertentu. Pada struktur ini, setiap node merepresentasikan sebuah fitur, cabang menggambarkan hasil pemisahan dari fitur tersebut, dan daun menunjukkan label kelas. Proses pembentukan pohon keputusan dilakukan dengan memilih fitur yang mampu memisahkan kelas secara optimal, biasanya dengan menggunakan metrik seperti **Gini Index** atau **Information Gain**.

Algoritma Decision Tree menghasilkan model yang mudah diinterpretasikan dan intuitif karena representasi grafis yang menyerupai alur logis. Namun, algoritma ini rentan terhadap overfitting, terutama jika pohon terlalu dalam dan mengakomodasi noise dalam data.

##### **1. Gain Index**

Gini Index adalah salah satu metode untuk mengukur impuritas dalam decision tree. Formula untuk menghitung Gini Index adalah sebagai berikut:

Dimana  $pi$  adalah proporsi elemen dalam kelas  $i$ . Impuritas yang rendah menunjukkan bahwa node tersebut lebih murni, atau lebih homogen dalam hal kelas.

$$Gini = 1 - \sum_{i=1}^n (pi)^2$$

## 2. Gain

Information Gain adalah perbedaan antara entropi sebelum dan sesudah suatu pemisahan pada data. Entropi adalah ukuran ketidakpastian atau kekacauan dalam data, dan Information Gain bertujuan untuk memaksimalkan pemisahan yang mengurangi ketidakpastian. Rumus untuk menghitung Information Gain adalah sebagai berikut:

$$IG(T, X) = Entropy(T) - \sum \frac{T_v}{T} Entropy(T_v)$$

Dimana :

- $T$  adalah total dataset,
- $X$  adalah fitur yang di pilih,
- $T_v$  adalah subset dari  $T$  yang memiliki nilai tertentu pada fitur  $X$ .

### 2.1.5 Algoritma Naive Bayes

Algoritma Naive Bayes adalah algoritma klasifikasi yang berdasarkan pada Teorema Bayes, yang menghitung probabilitas posterior dari sebuah kelas berdasarkan fitur yang ada. Algoritma ini disebut "naive" karena mengasumsikan bahwa setiap fitur saling independen satu sama lain, meskipun dalam banyak kasus kenyataannya tidak demikian Teorema Bayes dapat dijelaskan sebagai berikut :

$$P(C|X) = \frac{P(X|C) \cdot P(C)}{P(X)}$$

Dimana :

- $P(C|X)$  adalah probalitas dari kelas  $C$  yang diberikan fitur  $X$ ,
- $P(X | C)$  adalah probalitas munculnya fitur  $X$  dalam kelas  $C$ ,
- $P(C)$  adalah probalitas prior dari kelas  $C$ ,

- $P(X)$  adalah probalitas dari fitur X.

Algoritma Naive Bayes memiliki keunggulan dalam hal kesederhanaan dan efisiensi komputasi, terutama ketika bekerja dengan dataset besar. Algoritma ini juga sering digunakan dalam klasifikasi teks, seperti dalam pengelompokan email menjadi spam atau non-spam. Namun, kelemahan utama dari Naive Bayes adalah asumsi independensi antar fitur, yang seringkali tidak realistik dalam situasi nyata.

### **2.1.6 Penerapan Algoritma *Naive Bayes* Dan *Decision tree***

Berikut merupakan penerapan algoritma Algoritma Naive Bayes dan Decision Tree dari penelitian yang dilakukan Salmawati, Yuyun, Hazriani dengan judul “Perbandingan Algoritma Decision Tree dan Naive Bayes Pada Lulusan Tepat Waktu Mahasiswa” [11].

Data yang dikumpulkan merupakan data alumni mahasiswa UIN Raden Fatah Palembang tahun 2016 – 2019 dan data mahasiswa baru tahun 2008– 2015, adapun data yang digunakan sebanyak 2861 di UIN Raden Fatah Palembang Untuk data Training dan Testing yaitu data alumni mahasiswa konsentrasi Mahasiswa lulusan tepat waktu dan Tidak tepat waktu, jenis dan jurusan sekolah tahun 2016 sampai dengan 2019 dengan IPK diatas 2.51 sampai 4.00 dimana data yang dibutuhkan yaitu data NIM, Jenis Sekolah, Jurusan Sekolah, IPK, Masa Studi dimana yang layak masa studi yaitu dari 3.5 tahun sampai 6 tahun untuk diteliti dan untuk data masa studi diubah menjadi keterangan Tetap Waktu dan Tidak Tepat Waktu. Data dalam penelitian ini merupakan data awal sebelum dilakukan praproses data [11].

#### *1. Cleaning Data*

Data yang diambil data alumni dari tahun 2016 – 2019 dimana atributnya mempunyai 23 atribut dimana didalam didalam atribut ada yang missing value, redundant dan nilainya kosong dihapus. Pada tahapan ini

dilakukan menghapusan data yang tidak diperlukan untuk peneliti atau data yang kosong. Data yang dihapus adalah atribut No, Nama, No Hp, Tempat Tanggal Lahir, Judul Skripsi Angkatan, Tanggal Masuk, Tanggal Lulus, Beasiswa, Angkatan Wisuda, dan Tanggal Wisuda. Dimana data alumni yang sudah dicleaning. Data alumni sudah dicleaning mendapatkan 6 atribut yang akan digunakan didalam penelitian dimana atribut tersebut adalah Nim, Jenis Kelamin, Kota , Jenis Sekolah, IPK, dan Masa Studi. Untuk data mahasiswa yang diambil hanya data Jurusan sekolah, Pekerjaan Ortu.

No	Nim	Jurusan Sekolah	Pekerjaan Ortu
1	10422036	IPS	Petani
2	10422067	IPS	PNS/TNI/Polri
3	11140002	IPS	PNS/TNI/Polri
4	11160002	KEAGAMAAN	Petani
5	11210037	MAK	Wiraswasta
6	11210042	IPA	PNS/TNI/Polri
7	11210092	IPA	Wirausaha
8	11210113	IPA	PNS/TNI/Polri
9	11210116	IPA	Petani
10	11210130	KEAGAMAAN	Sudah Meninggal
11	11210142	IPS	Wiraswasta
12	11210145	IPA	Pensiunan
13	11221077	IPS	Petani
14	11221007	IPA	Wiraswasta
15	11221008	IPA	Petani
16	11221014	IPA	Petani
17	11221019	IPA	Pedagang Kecil
18	112221033	IPA	Petani
19	112221034	IPA	Petani
20	112222003	IPA	Petani
21	112222702	IPA	Buruh
22	11260006	KEAGAMAAN	Petani
23	11260019	KEAGAMAAN	PNS/TNI/Polri
24	11260034	KEAGAMAAN	Petani

Gambar 2. 2 Data Mahasiswa [11]

## 2. Data *Itegration*

Data yang telah bersih dari mising value dan redundant data selanjutnya digabungan kedalam satu tabel utama yang dapat digunakan sebagai data akhir alumni mahasiswa dimana data tersebut berkunci pada NIM sebagai primary key. Data yang sudah diintegrasikan akan dilakukan seleksi atribut untuk memilih data yang relevan sesuai pada kebutuhan yang akan dicapai.

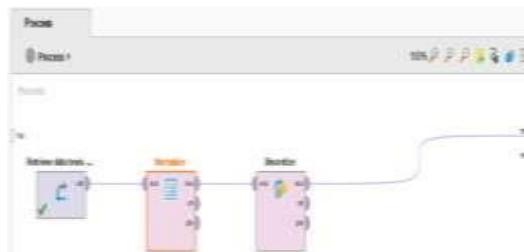
## 3. Data *Selection*

Data –data alumni mahasiswa UIN Raden Fatah Palembang tahun 2016-2019 dan data mahasiswa baru tahun 2008–2015, adapun data yang digunakan sebanyak 2861 di UIN Raden Fatah Palembang. Untuk data Training dan Testing yaitu data alumni mahasiswa konsentrasi Mahasiswa lulusan tepat waktu dan Ttdak tepat waktu, jenis dan jurusan sekolah tahun 2016 sampai dengan 2019 dengan IPK diatas 2.51 sampai 4.00 dimana

data yang dibutuhkan yaitu data NIM, Jenis Sekolah, Jurusan Sekolah, IPK, Masa Studi dimana yang layak masa studi yaitu dari 3.5 tahun sampai 6 tahun untuk diteliti dan untuk data masa studi diubah menjadi keterangan Tetap Waktu dan Tidak Tepat Waktu.

#### 4. Transformation

Pada tahapan ini yaitu melakukan konversi atribut yang bekerja di nilai atribut disetiap instans dari dataset. Tujuan dari konversi atribut yaitu merubah atribut bernilai kontinu (tidak terhingga) menjadi atribut dengan nilai nominal (berhingga). Terdapat dua cara untuk melakukan normalisasi data dengan membagi range data dari data yang terkecil sampai data yang digunakan yaitu dalam penelitian ini range datanya min 2.11 sampai 4.00 dimana salanjutnya difilterisasi pada tahapan selanjutnya. Tahapan sanjutnya yaitu diskritisasi nilai atribut. Tahapan ini yaitu melakukan binning. Binning merupakan proses menjelaskan kelompok kelas nominal pada semua atribut, kemudian membuat setiap nilai atribut pada salah satu kelas. Dimana dilakukan pembagian range interval terhadap nilai IPK. Prosesnya dapat dilihat dibawah ini.



**Gambar 2. 3** Proses Transformasi Data [11].

Didalam proses diatas melakukan binning 3 interval yaitu rangenya terbagi menjadi 3 yaitu IPK dari 0 sampai 2.7, 2.7 sampai 3.4 dan 3.4 sampai 4.00. dimana berikut Gambar hasil transformasi data berupa discretize by binning. Teknik data transformation yaitu *descretize* yang digunakan untuk merubah data dengan tipe continuous menjadi data dengan tipe diskrit. Descretize adalah salah satu metode yang digunakan saat *preprocessing* input. Teknik diskritisasi data dapat digunakan untuk mengurangi jumlah nilai atribut numeric dengan cara membagi range atribut ke dalam

interval. Label interval kemudian dapat digunakan untuk menggantikan nilai-nilai aktual data.

### 5. Data Mining

Proses setelah transformasi data sudah sesuai untuk digunakan pada tahapan data mining. Selanjutnya menggunakan metode klasifikasi algoritma C4.5 dan Naive Bayes dalam melakukan analisis data, dimana proses analisis data mining ini hanya dilakukan untuk mempermudah dan mengerti penggunaan teknik klasifikasi pada metode algoritma C4.5 dan Naive Bayes menggunakan aplikasi Rapid Miner. Klasifikasi masa studi mahasiswa berdasarkan data alumni memakai algoritma C4.5 dan Naïve Bayes serta memanfaatkan tools RapidMiner sebagai Software untuk membantu menentukan klasifikasi jurusan sekolah dan jenis sekolah.

### 6. Pattern Evaluation

Tahapan ini implementasi identifikasi pola menggunakan metode algoritma C4.5 dan Naïve Bayes. Adapun implementasinya.

#### a. Hasil Algoritma Decision Tree

Hasil implementasi algoritma C4.5 yang telah di proses oleh Tool RapidMiner mendapatkan hasil dalam bentuk pola pemodelan pohon keputusan pada gambar ini [11].



**Gambar 2. 4** Pohon Keputusan [11]

Pada pola diatas dihasilkan dari aplikasi Rapidminer dan menghasilkan keputusan yang didapat bawag akar node dari pohon

keputusan adalah IPK, dimana IPK didapat dari perhitungan nilai gain ratio tertinggi dan untuk akar selanjutnya turun dari nilai gain tertinggi selanjutnya. Selain pola pemodelan pohon keputusan dapat juga mengetahui tingkat akurasi, recall, dan *precision*. Adapun hasil keakuratan data yang digunakan dengan metode *Decision Tree* terdapat pada Tabel 4

**Tabel 2. 2** Hasil Perhitungan Nilai Akurasi dari Decision Tree [11].

	True tepat waktu	True tidak tepat waktu	Class precision
pred. Tepat Waktu	289	109	72.61%
pred. Tidak Tepat Waktu	152	307	66.88%
Class recall	65.53%	73.80%	

Dari tabel diatas diketahui nilai akurasi pada metode C4.5 yaitu sebesar 69,54% class recall pada true tidak tepat waktu sebesar 65,53%, dan true tepat waktu sebesar 73,80%. Sedangkan untuk nilai class precision pada tepat waktu sebesar 72,61% dan untuk tidak tepat waktu 66,88%. Data yang di masukan 2681 pada saat sudah diolah oleh aplikasi rapidminer menjadi 857 yang diprediksi masa studi tepat waktu sebanyak 441 data dan yang diprediksi tidak tepat waktu sebanyak 416 data.

Hasil hitungan nilai akurasi, precision dan recall dari hasil implementasi metode Algoritma C4.5 adalah sebagai berikut :

$$\begin{aligned}
 Akurasi &= \frac{\frac{TP+TN}{TP+TN+FP+FN} * 100\%}{\frac{289+307}{289+307+152+109} * 100\%} \\
 &= \frac{\frac{596}{857} * 100\%}{69,54\%} \\
 Presisi &= \frac{\frac{TP}{FP+TP} * 100\%}{\frac{289}{152+289} * 100\%} \\
 &= \frac{\frac{289}{441} * 100\%}{65,53\%} \\
 Recall &= \frac{\frac{TP}{FN+TP} * 100\%}{\frac{289}{109+289} * 100\%} \\
 &= \frac{\frac{289}{398} * 100\%}{72,61\%}
 \end{aligned}$$

b. Hasil dari Algoritma *Naïve Bayes*

Hasil permodelan yang telah di proses oleh Tool *RapidMiner* menggunakan metode naïve bayes dapat diketahui nilai akurasi data tersebut pada Tabel di bawah ini.

**Tabel 2. 3** Hasil Perhitungan Nilai Akurasi dari Naïve Bayes [11]

	True tepat waktu	True tidak tepat waktu	Class precision
pred. Tepat Waktu	288	118	70.94%
pred. Tidak Tepat Waktu	153	298	66.08%
Class recall	65.31%	71.63%	

Dari tabel diatas diketahui nilai akurasi pada metode naive bayes yaitu sebesar 68,38%. Dimana class recall untuk true tepat waktu yaitu 65,31% dan class recall untuk true tidak tepat waktu yaitu 71,63%. Sedangkan untuk class precision pada tepat waktu yaitu sebesar 70,94% dan class precision pada tidak tepat waktu yaitu sebesar 66,08%. Data yang di masukan 2681 pada saat sudah diolah oleh aplikasi rapidminer menjadi 857 yang diprediksi masa studi tepat waktu sebanyak 416 data dan yang diprediksi tidak tepat waktu sebanyak 306 data.

$$\begin{aligned}
 Akurasi &= \frac{TP+TN}{TP+TN+FP+FN} * 100\% \\
 &= \frac{288 + 298}{288 + 298 + 153 + 118} * 100\% \\
 &= \frac{586}{857} * 100\% \\
 &= 68,38\%
 \end{aligned}$$

$$\begin{aligned}
 Presisi &= \frac{TP}{FP + TP} * 100\% \\
 &= \frac{288}{153+288} * 100\% \\
 &= \frac{288}{441} * 100\% \\
 &= 65,31\%
 \end{aligned}$$

$$\begin{aligned}
 Recall &= \frac{TP}{FN + TP} * 100\% \\
 &= \frac{288}{118+288} * 100\% \\
 &= \frac{288}{406} * 100\% = 70,94\%
 \end{aligned}$$

## 7. Hasil Perbandingan

Hasil Perbandingan dari Implementasi metode Algoritma C4.5 dan Naïve Bayes menggunakan aplikasi Rapidminer dapat dilihat dibawah ini.

**Tabel 2. 4** Perbandingan metode Decision Tree dan Naïve Bayes [11].

No	Metode	Akurasi	Persisi	Recal
1	Decision Tree	69,54%	65,53%	72,61%
2	Naïve Bayes	68,38%	65,31%	70,94%

## 8. Kesimpulan

Dari hasil observasi terhadap dataset alumni mahasiswa UIN Raden Fatah Palembang melalui prose dengan metode algoritma Decision Tree dan Naïve Bayes menggunakan Aplikasi RapidMiner. Dari 8 atribut yang digunakan, variable yang paling tinggi nilai gainnya yaitu IPK sebagai node akar. Menurut Implementasi Decision Tree variable yang mempengaruhi dalam klasifikasi masa studi yaitu IPK, Pekerjaan Ortu, Jenis Sekolah dan Jenis Kelamin. Berdasarkan prediksi data mining pada algoritma Decision Tree dan Naïve Bayes bisa ditarik kesimpulan bahwa masing-masing metode telah memprediksi klasifikasi konsentrasi dengan perbandingan keakurasian metode masing-masing yaitu Decision Tree 69,54%

sedangkan Naïve Bayes 68,38% . Selisih nilai akurasi antara kedua metode tersebut sebesar 1,16% [11].

### 2.1.7 *RapidMiner*

RapidMiner adalah platform perangkat lunak sumber terbuka yang menyediakan lingkungan terintegrasi untuk analisis data, pembelajaran mesin, penambangan teks, dan analisis prediktif. Dikembangkan menggunakan bahasa pemrograman Java, RapidMiner dapat dijalankan di berbagai sistem operasi. Awalnya dikenal sebagai YALE (Yet Another Learning Environment), perangkat lunak ini mulai dikembangkan pada tahun 2001 oleh Ralf Klinkenberg, Ingo Mierswa, dan Simon Fischer dari Unit Kecerdasan Buatan Universitas Teknik Dortmund. Pada tahun 2007, namanya diubah menjadi RapidMiner. [12]

### 2.1.8 Confusion Matrix

Confusion matrix menurut Han dan Kamber (2011) dapat diartikan sebagai suatu alat yang memiliki fungsi untuk melakukan analisis apakah classifier tersebut baik dalam mengenali tuple dari kelas yang berbeda. Nilai dari True-Positive dan True-Negative memberikan informasi ketika classifier dalam melakukan klasifikasi data bernilai benar, Sedangkan False-Positive dan False-Negative memberikan informasi ketika classifier salah dalam melakukan klasifikasi data [13].

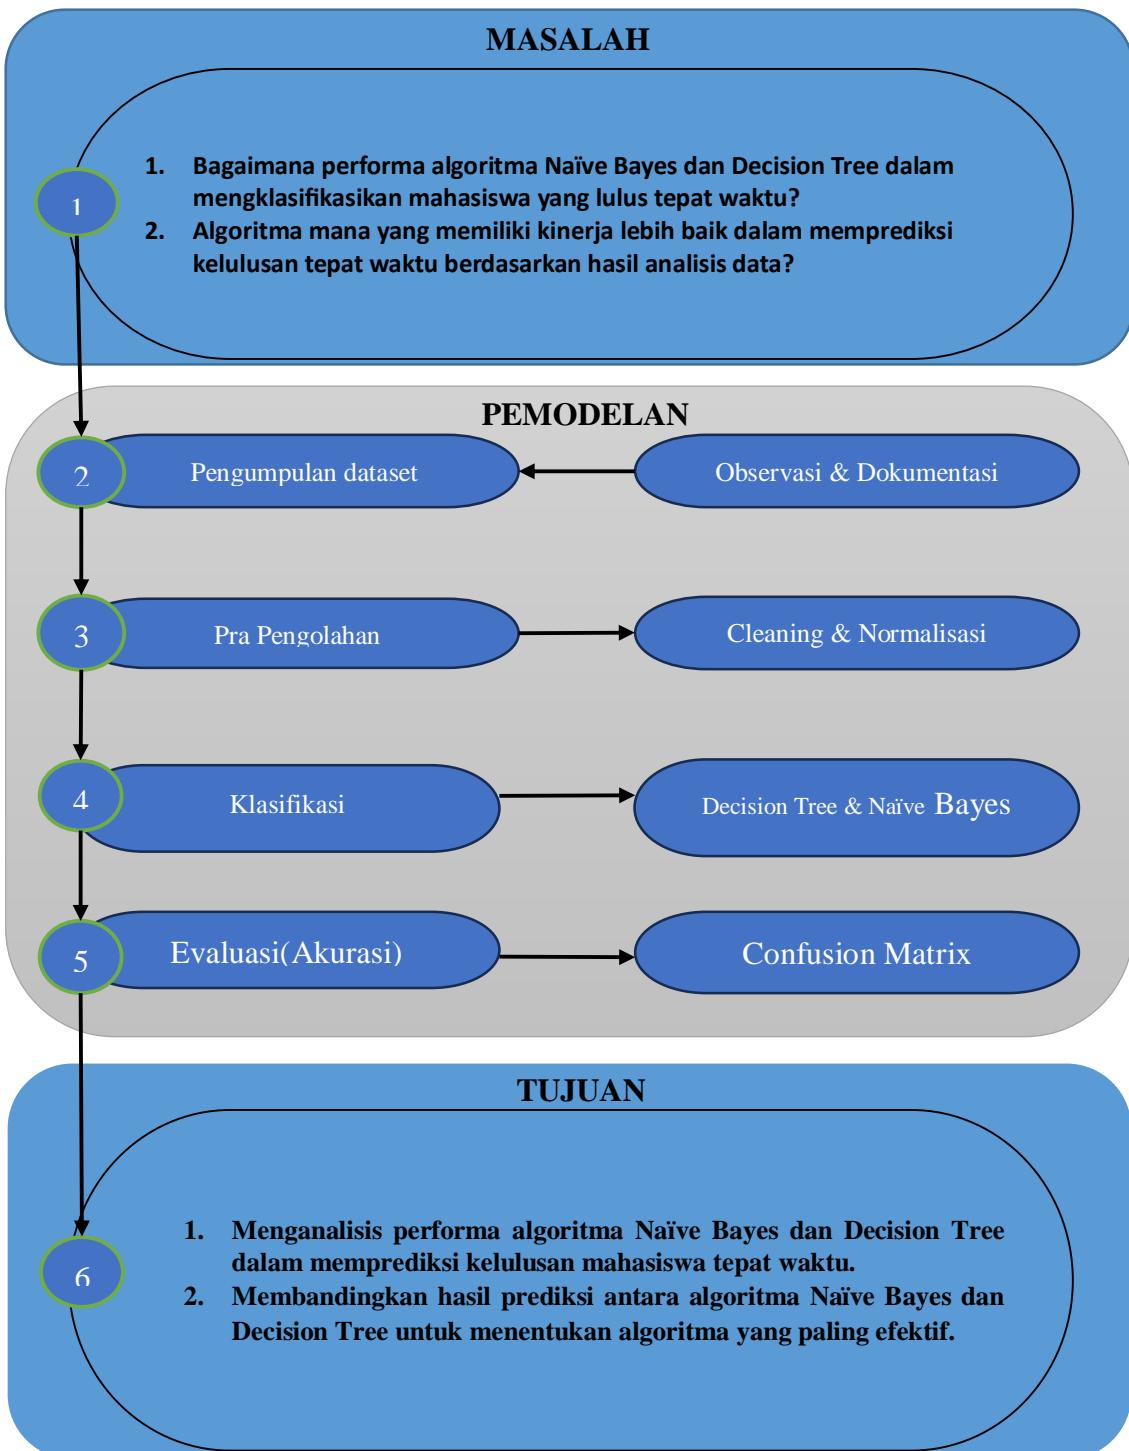
- True Positive (TP): Jumlah data aktual positif yang diprediksi positif dengan benar.
- False Positive (FP): Jumlah data aktual negative yang diprediksi positif dengan salah.
- False Negative (FN): Jumlah data aktual positif yang diprediksi negative dengan salah.
- True Negative (TN): Jumlah data aktual positif yang diprediksi negative dengan benar.

### 2.1.9 Perangkat Lunak

**Tabel 2. 5** Fungsi Perangkat Lunak Pendukung

No.	Perangkat Lunak Pendukung	Fungsi
1	Rapid Miner	RapidMiner berfungsi untuk memproses data, membuat model prediktif menggunakan pembelajaran mesin, mengevaluasi kinerja model, dan memvisualisasikan hasil analisis secara efisien melalui antarmuka drag-and-drop [12].
2	Ms.Office Excel	Microsoft Excel berfungsi sebagai alat pendukung dalam RapidMiner untuk mengimpor data mentah dalam format .xls atau .xlsx yang akan dianalisis lebih lanjut. Selain itu, Excel juga digunakan untuk menyimpan hasil analisis dari RapidMiner, sehingga memudahkan pembuatan laporan atau presentasi. Excel dapat dimanfaatkan untuk transformasi data awal, seperti pembersihan atau pengolahan sederhana, sebelum data diolah menggunakan algoritma di RapidMiner. [12]

### 2.1.10 Kerangka Pikir



Gambar 2. 5 Kerangka Pikir.

## **BAB III**

### **METODE PENELITIAN**

#### **3.1 Jenis, Metode, Subjek, Objek, Waktu, dan Lokasi Penelitian**

Penelitian ini merupakan penelitian terapan berdasarkan tingkat penerapannya. Sedangkan penelitian kuantitatif digunakan untuk mengolah jenis informasi dalam penelitian ini. Seperti yang dapat diamati dari penanganan data, penelitian ini bersifat konfirmatori.

Penelitian ini memiliki studi kasus di Program Studi Teknik Informatika. topik penelitian ini adalah Perbandingan Algoritma Naive Bayes Dan Decision Tree Dalam Klasifikasi Mahasiswa Tepat Waktu, Pada Program Studi Informatika Fakultas Ilmu Komputer Unisan Gorontalo Penelitian ini akan berlangsung di Universitas Ichsan Gorontalo yang beralamatkan di jl. Drs. Achmad Nadjamuddin, Limba U Dua, Kota Selatan Kota Gorontalo dari bulan Oktober sampai November 2024.

#### **3.2 Pengumpulan Data**

Untuk mendapatkan data mahasiswa, peneliti datang langsung ke Prodi Jurusan unisan Gorontalo untuk meminta data berupa data alumni mahasiswa Universitas Ichsan Gorontalo Angkatan 2015 sampai 2016 dalam bentuk file excel dimana dalam file excel tersebut berisi sejumlah informasi terkait mahasiswa-mahasiswa yang terdaftar pada Universitas Ichsan Gorontalo.

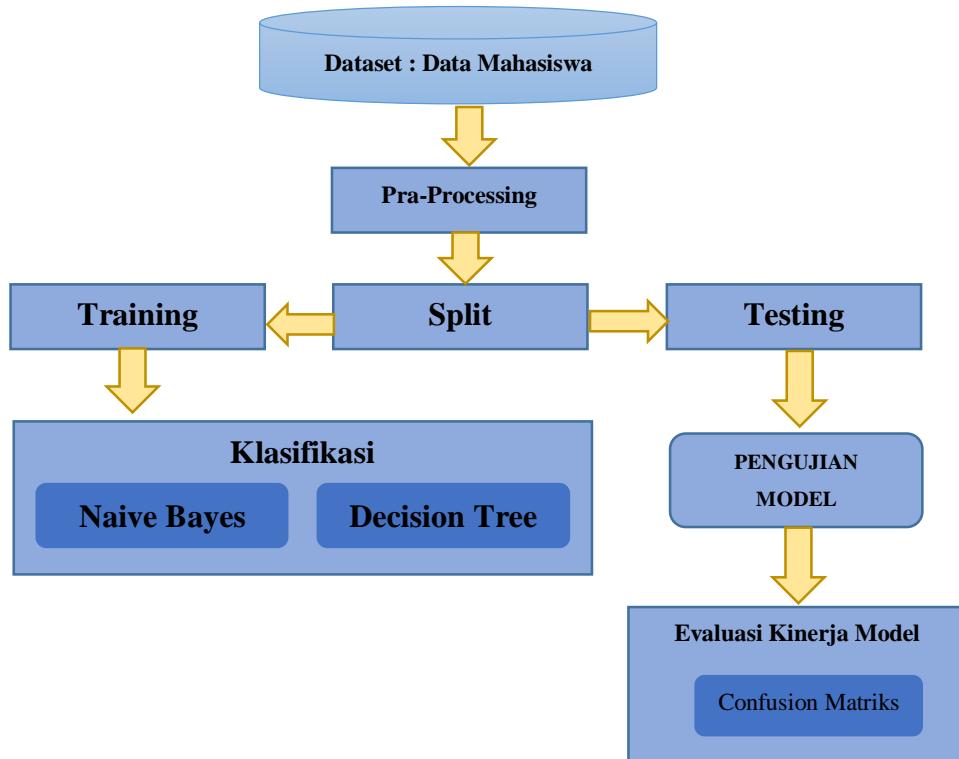
**Tabel 3. 1** Variabel Data

No	Name	Type	Keterangan
1	Jenis Kelamin	Tuple	Laki-laki Perempuan
2	IPS 1	Float	< 2.75
3	IPS 2	Float	2.75 – 3.00
4	IPS 3	Float	> 3.00
5	IPS 4	Float	< 2.75
6	IPS 5	Float	2.75 – 3.00
6	Kelas	Varchar	Variabel Input
7	Status Kelulusan	Varchar	Output

**Tabel 3. 2** Data Alumni Mahasiswa Universitas Ichsan Gorontalo

No	JK	Kelas	IPS1	IPS2	IPS3	IPS4	IPS5	Status
1	L	N	3.23	3.26	3.88	3.74	3.25	Tidak Tepat Waktu
2	P	R	1.31	4.00	2.08	4.00	3.75	Tidak Tepat Waktu
3	L	N	3.23	3.57	3.54	3.22	3.38	Tepat Waktu
4	P	R	3.77	3.87	3.08	3.87	3.63	Tepat Waktu
5	P	R	3.45	3.61	3.71	3.87	3.88	Tidak Tepat Waktu
6	P	R	3.55	3.87	2.88	3.85	3/75	Tepat Waktu
7	L	R	3.59	3.60	3.00	3.26	3.13	Tidak Tepat Waktu
...	....	.....	.....	.....	.....	.....	.....	....
387	L	N	2.90	3.50	3.33	3.26	3.13	Tidak Tepat Waktu

### 3.3 Pemodelan



**Gambar 3. 1** Pemodelan

#### 3.3.1 Pra Pengolahan Data

Seleksi dan transformasi data dilakukan pada data yang akan diolah nantinya. Hal ini dilakukan untuk menentukan kriteria atribut seperti IPS1, IPS2, IPS3, IPS4, IPS5, jenis kelamin dan status kelulusan, yang nantinya akan menjadi nilai ukur dari setiap atribut untuk proses kategorisasi data. Sedangkan untuk atribut yang menjadi hasil keluaran dari pengukuran adalah keterangan status kelulusan.

#### 3.3.2 Validasi Data

Validasi membagi data awal menjadi dua bagian: data training dan data testing. Data training adalah informasi yang akan diproses oleh algoritma klasifikasi, sedangkan data testing digunakan dalam tahap pengujian oleh program komputer. Pada level ini, pendekatan validasi yang digunakan adalah split validation, yaitu membagi data menjadi dua bagian berdasarkan jumlah data.

### **3.3.4 Evaluasi Model**

Akurasi, presisi, dan recall dari model yang dihasilkan kemudian ditentukan menggunakan Confusion Matrix.

## **BAB IV**

### **HASIL PENELITIAN**

#### **4.1 Data Penelitian**

Data yang digunakan dalam penelitian ini adalah merupakan data private yang diambil dari Prodi Jurusan Informatika Ichsan Gorontalo terkait data alumni Angkatan 2015 s.d 2016. Adapun dataset yang dikumpulkan dapat dilihat pada table 4.1 berikut ini:

**Tabel 4. 1** Hasil Pengumpulan Data Set

No	Tahun	Program Studi	Jumlah Mahasiswa
1	2015	S1 Teknik Informatika	390
2	2016	S1 Teknik Informatika	372

Adapun berikut merupakan data yang telah diolah dan diatur untuk digunakan pada penelitian ini yang dimana nantinya data mahasiswa ini akan diolah menggunakan Aplikasi *RapidMiner* yang dimuat dalam Tabel 4.2 dibawah ini :

**Tabel 4. 2** DataSet Excel

No	Jenis Kelamin	Umur	Kelas	Tahun Masuk
1	Laki-laki	29	Reguler Sore	2015
2	Perempuan	30	Reguler Sore	2015
3	Laki-laki	30	Reguler Sore	2015
4	Perempuan	27	Reguler Sore	2015
5	Laki-laki	44	Reguler Sore	2015
6	Laki-laki	29	Reguler Sore	2015
7	Perempuan	26	Reguler Sore	2015
8	Laki-laki	27	Reguler Sore	2015
9	Perempuan	32	Reguler Sore	2015
10	Laki-laki	29	Reguler Sore	2015
11	Perempuan	29	Reguler Sore	2015
12	Perempuan	26	Reguler Pagi	2015
13	Laki-laki	29	Reguler Pagi	2015
14	Laki-laki	30	Reguler Pagi	2015
15	Laki-laki	30	Reguler Sore	2015
16	Laki-laki	27	Reguler Sore	2015
17	Laki-laki	41	Reguler Sore	2015
...	...	...	...	...
762	Perempuan	46	Reguler Pagi	2016

No	IPS1	IPS2	IPS3	IPS4	IPS5
1	3,04	3,25	3,42	3,61	3,22
2	3,35	3,67	3,29	3,22	3,09
3	3,43	3,54	2,88	2	2,33
4	3,78	4	2,88	3,53	3,64
5	3,39	3,79	3,54	3,65	3,22
6	3,52	0	0	0	0
7	3,13	2,95	2,25	1,6	1,3
8	2,7	3,17	2,75	1,65	3
9	3,74	4	3,88	3,87	3,87
10	0	0	0	0	0
11	2,26	2,61	0	0	0
12	4	4	4	3,83	3,87
13	3,17	3,75	2,83	1,95	1,86
14	3,57	3,25	3	3,3	3,26
15	3,65	3,79	3,42	3,78	3,48
16	3,65	3,88	3,58	3,78	3,61
17	1,35	0	0	0	0
18	3,04	3,25	3,42	3,61	3,22
...	...	...	...	...	...
762	0	2,53	3,15	3,26	2,65

#### 4.2 Hasil Pemodelan

Berdasarkan dataset table 4.2 di atas dilakukan beberapa pengelolahan data sebelum diterapkan pada model *Decision Tree* dan *Naïve Bayes* diantaranya dilakukan tahapan pengelolahan data.

Hasil pengumpulan dataset pada Tabel 4.2 di atas terdapat atribut Nim, Nama, Jenis Kelamin, Umur, Kelas, tahun masuk, IPS1 sampai dengan IPS5, Dan Status, terdapat beberapa atribut yang diperlukan dalam pemodelan, sehingga perlu dilakukan pemilihan atribut target yang sesuai dengan model yang akan digunakan. Adapun hasil pemilihan atribut target yang digunakan dapat dilihat pada table 4.3 berikut :

**Tabel 4. 3** Dataset Pemodelan

No	JK	Kelas	IPS1	IPS2	IPS3	IPS4	IPS5	Status
1	Laki-laki	Reguler Sore	3,04	3,25	3,42	3,61	3,22	Tepat Waktu
2	Perempuan	Reguler Sore	3,35	3,67	3,29	3,22	3,09	Tepat Waktu
3	Laki-laki	Reguler Sore	3,43	3,54	2,88	2	2,33	Tepat Waktu
4	Perempuan	Reguler Sore	3,78	4	2,88	3,53	3,64	Tepat Waktu
5	Laki-laki	Reguler Sore	3,39	3,79	3,54	3,65	3,22	Tepat Waktu
6	Laki-laki	Reguler Sore	3,52	0	0	0	0	Tidak Tepat Waktu
7	Perempuan	Reguler Sore	3,13	2,95	2,25	1,6	1,3	Tidak Tepat Waktu
8	Laki-laki	Reguler Sore	2,7	3,17	2,75	1,65	3	Tidak Tepat Waktu
9	Perempuan	Reguler Sore	3,74	4	3,88	3,87	3,87	Tepat Waktu
10	Laki-laki	Reguler Sore	0	0	0	0	0	Tidak Tepat Waktu
11	Perempuan	Reguler Sore	2,26	2,61	0	0	0	Tidak Tepat Waktu
12	Perempuan	Reguler Pagi	4	4	4	3,83	3,87	Tepat Waktu
13	Laki-laki	Reguler Pagi	3,17	3,75	2,83	1,95	1,86	Tidak Tepat Waktu
14	Laki-laki	Reguler Pagi	3,57	3,25	3	3,3	3,26	Tepat Waktu
15	Laki-laki	Reguler Sore	3,65	3,79	3,42	3,78	3,48	Tepat Waktu
16	Laki-laki	Reguler Sore	3,65	3,88	3,58	3,78	3,61	Tepat Waktu
17	Laki-laki	Reguler Sore	1,35	0	0	0	0	Tidak Tepat Waktu
18	Laki-laki	Reguler Pagi	3,04	3,25	3,42	3,61	3,22	Tepat Waktu
...	...	...	...	...	...	...	...	...
763	Perempuan	Reguler Pagi	2,53	3,15	3,26	2,53	3,15	Tepat Waktu

Berdasarkan table 4.3 diatas dilakukan perhitungan jumlah data untuk masing-masing kelas hasilnya berjumlah 470 untuk mahasiswa tepat waktu dan tidak tepat waktu berjumlah 292 mahasiswa.

### 4.3 Prapengelolahan Data

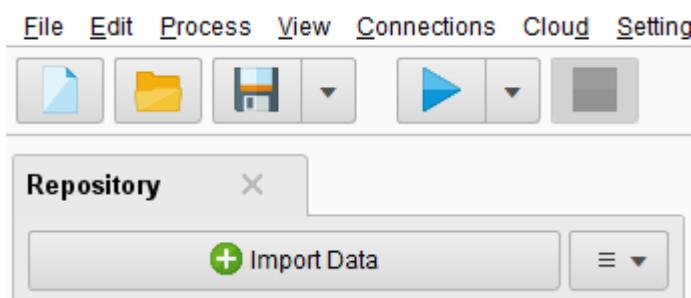
mempersiapkan dataset yang berisi informasi mahasiswa yang akan digunakan untuk membandingkan algoritma Naïve Bayes dan Decision Tree dalam memprediksi kelulusan tepat waktu mahasiswa. Proses prapengelolahan data dilakukan menggunakan RapidMiner untuk memastikan data yang digunakan bersih, relevan, dan siap untuk dianalisis lebih lanjut dengan tahapan-tahapan berikut :

#### 4.3.1 Tahapan Seleksi Data

Pada tahapan seleksi data ini dilakukan beberapa proses yakni:

##### 1. Import Data

Pada tahapan ini memasukkan data ke dalam RapidMiner. Dengan mengimpor data mahasiswa dalam format Excel, dengan rapidminer sebagai berikut:



**Gambar 4. 1 Import Data RapidMiner**

Proses pada gambar 4.1 adalah proses mengimpor data Excel ke RapidMiner, dengan memilih direktori dimana file Excel disimpan.

##### 2. Membaca File Data Excel

Pada tahapan ini proses membaca dataset excel dengan rapidminer sebagai berikut:

Data Mahasiswa 2015-2016 update2 - Salin										
Add new data sets on the left. Details for the selected data are shown below. You can change the data with the following actions.										
<input checked="" type="checkbox"/> TRANSFORM <input type="checkbox"/> CLEANSE <input type="checkbox"/> GENERATE <input type="checkbox"/> PIVOT <input type="checkbox"/> MERGE										
no	nim	nama	Jenis Kelamin	Umur	Kelas	tahun masuk	IPS1	IPS2	IPS3	IPS4
5	T3115005	ADRIYANTO HKA	Laki-laki	29	Regular Sore	2015	3.520	0	0	0
7	T3115007	SYAHABUDI AH.	Perempuan	26	Regular Sore	2015	3.130	2.890	2.250	1.600
8	T3115008	MELDI ABAS	Laki-laki	27	Regular Sore	2015	2.700	3.170	2.750	1.650
9	T3115009	TIKA NOVITA CIA	Perempuan	32	Regular Sore	2015	3.740	4	3.880	3.870
10	T3115010	RINTO LAJUANNI	Laki-laki	29	Regular Sore	2015	0	0	0	0
11	T3115011	DEWI CHINTHA E.	Perempuan	29	Regular Sore	2015	2.200	2.610	0	0
12	T3115012	MARYOHAY INDY	Perempuan	26	Regular Pagi	2015	4	4	3.830	3.870
13	T3115013	ALAN USMAN	Laki-laki	29	Regular Pagi	2015	3.170	3.750	2.830	1.950
14	T3115014	RAMON USMAN	Laki-laki	30	Regular Pagi	2015	3.570	3.250	3	3.350
15	T3115015	RACHMAT DEYY	Laki-laki	30	Regular Sore	2015	3.650	3.790	3.420	3.780
16	T3115016	MARTIAS SUITYO	Laki-laki	27	Regular Sore	2015	3.650	3.880	3.580	3.780
17	T3115017	RAHYAWANTO TAN	Laki-laki	41	Regular Sore	2015	1.350	0	0	0
18	T3115018	ABDUL LATIF O.	Laki-laki	29	Regular Pagi	2015	2.910	3.330	2.880	2.250
19	T3115019	MUHAMMAD AHD	Laki-laki	27	Regular Pagi	2015	3.780	3.670	3.540	3.780
20	T3115020	ANDRI PALAUTI	Laki-laki	27	Regular Pagi	2015	3.910	3.920	3.590	4
21	T3115021	SANIUDIN	Laki-laki	28	Regular Sore	2015	3.300	3.750	3.080	2.960
22	T3115022	SUSANTI KUSE	Perempuan	27	Regular Pagi	2015	3.780	3.780	3.880	4
23	T3115023	RANDY FAISAL	Laki-laki	28	Regular Pagi	2015	3	3.580	3.040	2.090
24	T3115024	MUHAMMAD FIR	Laki-laki	27	Regular Sore	2015	3.650	1.920	2.600	2.880

Gambar 4. 2 Hasil Pembacaan Dataset Dari Rapidminer

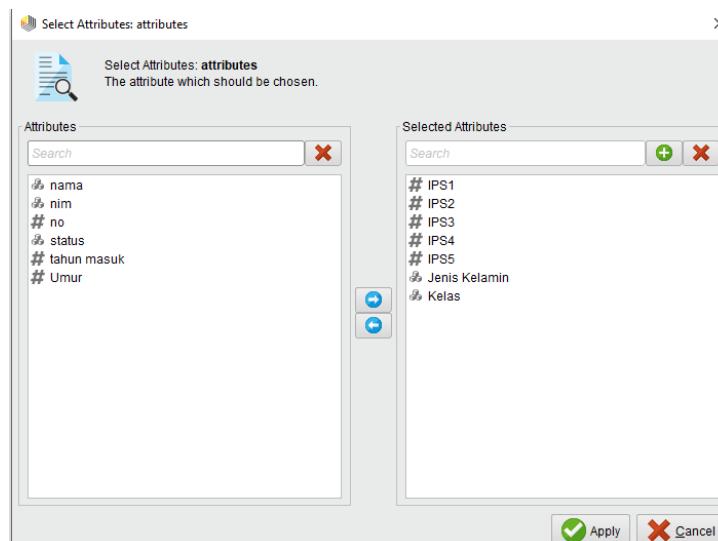
Pada gambar diatas hasil dari pembacaan dataset yang telah diimport ke Rapidminer.

#### 4.3.2 Tahapan preprocessing

Pada tahapan preprocessing dilakukan beberapa tahap yaitu :

##### 1. Tahapan Seleksi Atribut Menggunakan RapidMiner

Seleksi atribut dilakukan untuk memilih atribut yang relevan dan menghapus atribut yang tidak diperlukan, untuk meningkatkan kinerja model dan mengurangi kompleksitas data. Salah satu cara untuk melakukan seleksi atribut adalah menggunakan operator "Select Attributes" dengan sebagai berikut :



Gambar 4. 3 Seleksi Atribut

Berikut gambar diatas untuk seleksi atribut IPS1, IPS2, IPS3, IPS3, IPS4, IPS5, Jenis Kelamin, dan Kelas.

Hasil Outputnya Sebagai berikut :

Row No.	Jenis Kelamin	Kelas	IPS1	IPS2	IPS3	IPS4	IPS5
1	Laki-laki	Reguler Sore	3.040	3.250	3.420	3.610	3.220
2	Perempuan	Reguler Sore	3.350	3.670	3.290	3.220	3.090
3	Laki-laki	Reguler Sore	3.430	3.540	2.880	2	2.330
4	Perempuan	Reguler Sore	3.780	4	2.880	3.530	3.640

**Gambar 4. 4 Hasil Seleksi Atribut**

Gambar 4.4 adalah hasil dari seleksi atribut pada gambar 4.3 untuk menseleksi atribut yang akan di proses.

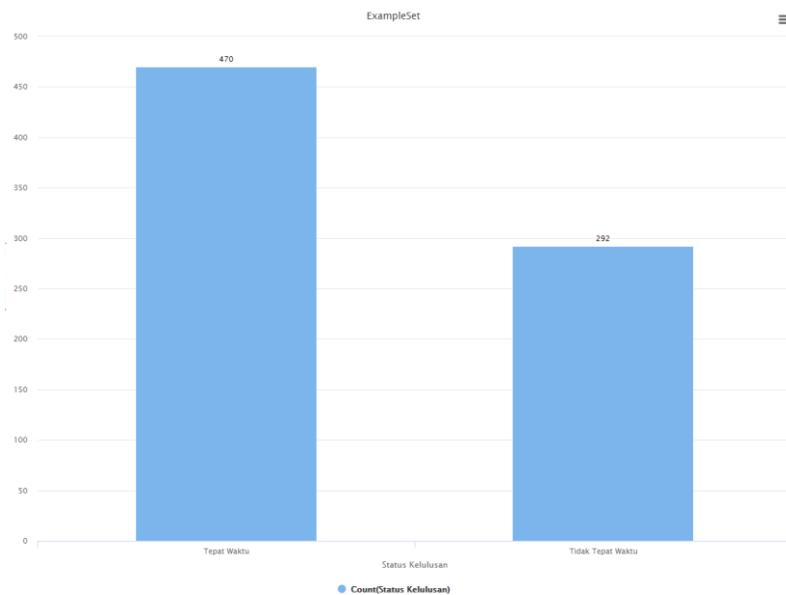
2. Tahapan Menentukan Status Kelulusan Tepat Waktu dan Tidak Tepat Waktu.

Tahapan untuk menentukan status kelulusan tepat waktu dan tidak tepat waktu berdasarkan nilai rata-rata IPS1-IPS5 menggunakan RapidMiner dimulai dengan memuat data yang berisi nilai IPS menggunakan operator Read Excel. Setelah itu, langkah selanjutnya adalah menghitung rata-rata nilai dari kolom IPS1, IPS2, IPS3, IPS4, dan IPS5 menggunakan operator Generate Attribute. dan memberikan status kelulusan, yaitu jika rata-rata nilai  $\text{IPS} \geq 2.75$ , maka statusnya adalah "Tepat Waktu", dan jika kurang dari 2.75, statusnya adalah "Tidak Tepat Waktu". Dan menjalankan kode program pada operator Generate Attribute sebagai berikut :

```
1 if((IPS1+IPS2+IPS3+IPS4+IPS5)/ 5 >= 2.75, "Tepat Waktu", "Tidak Tepat Waktu")
```

**Gambar 4. 5 Kode Program Menentukan Status Kelulusan**

Hasil Outputnya Sebagai Berikut :



**Gambar 4. 6** Hasil Perhitungan jumlah kategori pada Colom “Status”

Pada gambar di atas terdapat hasil output tersebut dapat kita lihat bahwa jumlah mahasiswa yang lulus tepat waktu sebanyak 470 dan tidak tepat waktu 292.

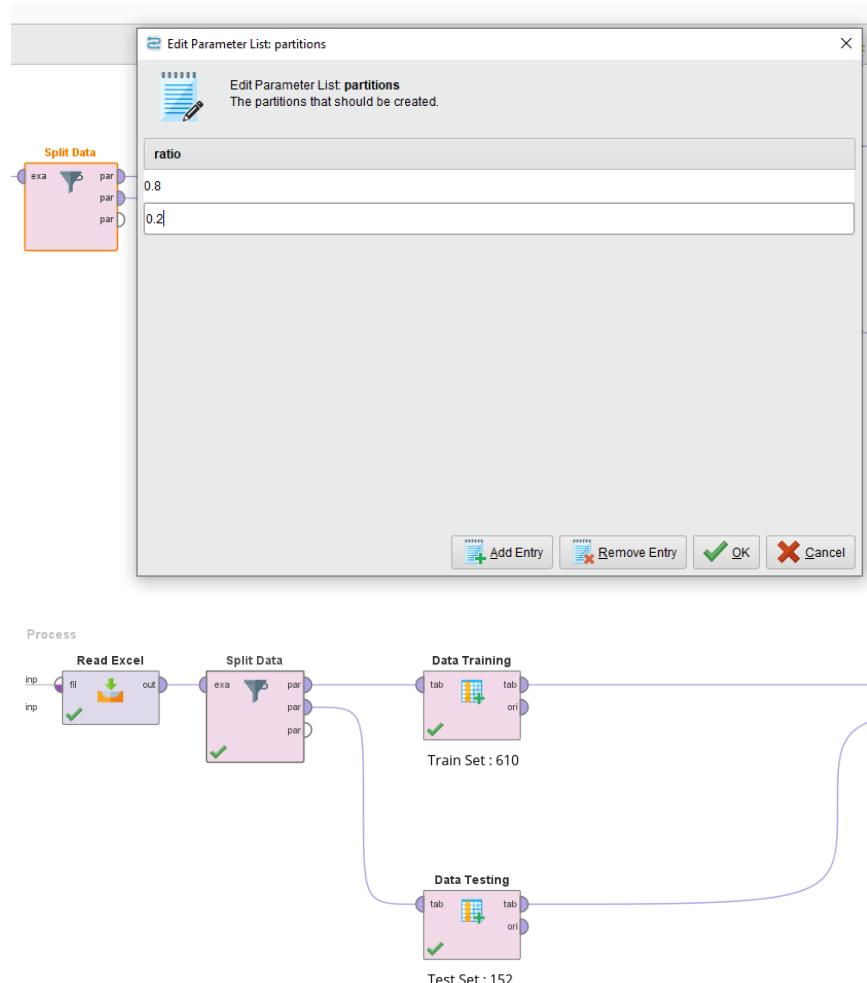
#### 4.3.3 Tahapan Data Mining

Pada tahapan ini akan dilakukan proses data mining yang dimana akan ada beberapa tahapan data mining di antaranya sebagai berikut :

- Tahapan Membagi Data Training dan Data Testing

Pada tahap ini dilakukan pembagian data, dimana data akan dibagi dibagi menjadi 2 bagian yaitu data training dan data testing, untuk pembagianya dengan membagi data training sebesar 80% dan data testing

sebesar 20% untuk proses pembagiannya dilakukan pada rapidminer sebagai berikut :



**Gambar 4. 7** Proses Pembagian Data Training Dan Data Testing Rapidminer

proses ini dilakukan menggunakan operator Split Data, di mana parameter pembagian data di atur 0.8 (80%) untuk training dan 0.2 (20%) untuk testing.

Hasil Outputnya Sebagai Berikut :

**Gambar 4. 8 Output Proses Pembagian Data Training Dan Data Testing**

Jenis Data	Jumlah Data
Data Training	610
Data Testing	152

Dari hasil output dapat dilihat bahwa terdapat jumlah data training sebanyak 610 data testing dan data testing sebanyak 152 data.

Adapun juga data training dan data testing dapat disajikan pada Tabel 4.4  
Tabel 4.5

**Tabel 4. 4 Dataset Training**

Jenis Kelamin	Kelas	IPS1	IPS2	IPS3	IPS4	IPS5	Status
Laki-laki	Reguler Sore	3.04	3.25	3.42	3.61	3.22	Tepat Waktu
Laki-laki	Reguler Sore	3.43	3.54	2.88	2	2.33	Tepat Waktu
Perempuan	Reguler Sore	3.78	4	2.88	3.53	3.64	Tepat Waktu
Laki-laki	Reguler Sore	3.39	3.79	3.54	3.65	3.22	Tepat Waktu
Laki-laki	Reguler Sore	3.52	0	0	0	0	Tidak Tepat Waktu
Perempuan	Reguler Sore	3.13	2.95	2.25	1.6	1.3	Tidak Tepat Waktu
Laki-laki	Reguler Sore	2.7	3.17	2.75	1.65	3	Tidak Tepat Waktu
Laki-laki	Reguler Sore	0	0	0	0	0	Tidak Tepat Waktu
Laki-laki	Reguler Sore	3.65	3.79	3.42	3.78	3.48	Tepat Waktu
Laki-laki	Reguler Sore	1.35	0	0	0	0	Tidak Tepat Waktu
...	...	...	...	...	...	...	...
Perempuan	Reguler Pagi	0	2.53	3.15	3.26	2.65	Tidak Tepat Waktu

**Tabel 4. 5** Dataset Testing

Jenis Kelamin	Kelas	IPS1	IPS2	IPS3	IPS4	IPS5	Status
Perempuan	Reguler Sore	3.35	3.67	3.29	3.22	3.09	Tepat Waktu
Perempuan	Reguler Sore	3.74	4	3.88	3.87	3.87	Tepat Waktu
Laki-laki	Reguler Pagi	3.57	3.25	3	3.3	3.26	Tepat Waktu
Laki-laki	Reguler Sore	3.65	3.88	3.58	3.78	3.61	Tepat Waktu
Laki-laki	Reguler Pagi	2.91	3.33	2.88	2.26	1.83	Tidak Tepat Waktu
Laki-laki	Reguler Pagi	1.13	1.92	1.6	0	0.8	Tidak Tepat Waktu
Laki-laki	Reguler Pagi	3.39	3.13	2.29	2.06	3	Tepat Waktu
Laki-laki	Reguler Pagi	3.3	3.33	3.13	2.91	2.95	Tepat Waktu
Laki-laki	Reguler Pagi	3.39	1.83	0	0	0	Tidak Tepat Waktu
Laki-laki	Reguler Pagi	1.9	0.95	1.6	3.4	2.29	Tidak Tepat Waktu
...	...	...	...	...	...	...	...
Laki-laki	Reguler Sore	0	0.29	0	0	0	Tidak Tepat Waktu

Untuk menentukan root (node) awal dari pohon keputusan, langkah pertama dengan menghitung nilai entrophy dan gain tertinggi untuk tiap-tiap atributnya. Berikut adalah langkah-langkah penyelesaiannya :

#### 4.3.4 Implementasi Metode Decision Tree

1. Menghitung nilai entropi total seluruh atribut

**Tabel 4. 6** Menentukan Entropy

Atribut	Jumlah	Tepat Waktu	Tidak Tepat Waktu	Entropy
Total	610	380	230	0.9565018033

- Hitung proporsi masing-masing kelas :

$$\text{Proporsi Tepat Waktu} = \frac{380}{610} = 0.62295$$

$$\text{Proporsi Tidak Tepat Waktu} = \frac{230}{610} = 0.37705$$

- Hitung entropy dengan rumus :

$$H(S) = -[0.62295 \log_2(0.62295) + 0.37705 \log_2(0.37705)]$$

- Hitung lagoritma :

$$\log_2(0.62295) = -0.684$$

$$\log_2(0.37705) = -1.400$$

- Hasil Entropy :

$$H(S) = -[0.62295 \times (-0.684) + 0.37705 \times (-1.400)]$$

$$H(S) = -[-0.4267 + (-0.5279)]$$

$$H(S) = 0.9565018033$$

Hasil :

Entropy dari dataset ini adalah 0.9565018033

Setelah menghitung nilai entropi total dari semua atribut, masuk ke tahap 2 menghitung nilai entropi tiap-tiap atribut, sebagai berikut :

**Tabel 4. 7 Tabel Entropy dan Gain Setiap Atribut**

Atribut		Jumlah	Tepat Waktu	Tidak Tepat Waktu	Entropy	Gain
<b>Jenis Kelamin</b>	<b>Gain</b>					0.1864707643
	Laki-Laki	376	203	173	0.9858	
	Perempuan	234	177	57	0.7993	
<b>Kelas</b>	<b>Gain</b>					0.0572817685
	Reguler Pagi	270	180	90	0.918	
	Reguler Sore	340	200	140	0.976	
<b>IPS1</b>	<b>Gain</b>					0.4616000000
	$\geq 2.75$	488	372	116	0.7936	
	< 2.75	122	8	114	0.3320	
<b>IPS2</b>	<b>Gain</b>					0.3899000000
	$\geq 2.75$	458	374	89	0.6926	
	< 2.75	152	6	141	0.3027	
<b>IPS3</b>	<b>Gain</b>					0.1313000000
	$\geq 2.75$	377	360	33	0.3718	
	< 2.75	233	20	197	0.5031	
<b>IPS4</b>	<b>Gain</b>					0.2473000000
	$\geq 2.75$	367	350	24	0.3260	
	< 2.75	243	30	206	0.5733	
<b>IPS5</b>	<b>Gain</b>					0.2735000000
	$\geq 2.75$	366	348	21	0.3048	
	< 2.75	244	32	209	0.5783	

Pada Tabel 4.7 diatas dapat dilihat bahwa, setelah seluruh untuk mencari nilai entropi selanjutnya menghitung dan mencari nilai gain tertinggi dari seluruh atribut.

$$\begin{aligned}
 \text{Gain (IPS1)} &= 0.9565018033 - \left( \left( \frac{488}{610} \right) * 0.7936 \right) + \left( \left( \frac{122}{610} * 0.3320 \right) \right) \\
 &= 0.2607118033
 \end{aligned}$$

Dan didapatkan nilai gain tertinggi yaitu 0.2607118033 sehingga menjadi root (node) awal dari pohon keputusan adalah IPS1

### 3. Tahapan Pemodelan

Setelah dilakukan pembagian data training dan testing, maka membuat model pohon keputusan Setelah dilakukan perhitungan metode algoritma C4.5 pada RapidMiner, maka terbentuk pohon keputusan seperti gambar di bawah ini :



#### Gambar 4. 9 Pohon Keputusan

Pada gambar 4.9 merupakan pohon keputusan yang dibangun untuk memprediksi status kelulusan mahasiswa tepat waktu atau tidak tepat waktu berdasarkan nilai IPS (IPS1 hingga IPS5) dan jenis kelamin mengilustrasikan serangkaian keputusan yang diambil berdasarkan atribut akademik. Node pertama pohon keputusan adalah IPS1, yang memiliki gain tertinggi, dan digunakan untuk membagi data menjadi dua kelompok. Selanjutnya, atribut lain seperti IPS5, IPS4, IPS3, dan IPS2 digunakan untuk menyaring lebih lanjut berdasarkan nilai-nilai tertentu, yang masing-masing mengarah pada keputusan apakah mahasiswa tersebut Tepat Waktu atau Tidak Tepat Waktu.

#### 4.3.5 Implementasi Metode Naive Bayes

##### 1. Menghitung Probabilitas Prior

Proses untuk menghitung kelulusan mahasiswa tepat waktu dilakukan menggunakan data yang telah dipilih. Langkah pertama adalah mencari nilai prior probabilitas untuk semua kasus, yaitu Tepat dan Terlambat. Jumlah data Tepat adalah 380, sedangkan jumlah data Terlambat adalah 230, sehingga total data yang digunakan adalah 610.

$$P(\text{Tepat Waktu}) \frac{380}{610} = 0.6238$$

$$P(\text{Tepat Waktu}) \frac{230}{610} = 0.3770$$

##### Hasil Probabilitas Prior

- $P(\text{Tepat Waktu}) = 0.6238$
- $P(\text{Tidak Tepat Waktu}) = 0.3770$

##### 2. Rata-rata dan Variansi

**Tabel 4. 8** Data Training

IPS1	IPS2	IPS3	IPS4	IPS5	Status Kelulusan
3.04	3.25	3.42	3.61	3.22	Tepat Waktu
3.43	3.54	2.88	2	2.33	Tepat Waktu
3.78	4	2.88	3.53	3.64	Tepat Waktu
3.39	3.79	3.54	3.65	3.22	Tepat Waktu
3.52	0	0	0	0	Tidak Tepat Waktu
3.13	2.95	2.25	1.6	1.3	Tidak Tepat Waktu
2.7	3.17	2.75	1.65	3	Tidak Tepat Waktu
0	0	0	0	0	Tidak Tepat Waktu
3.65	3.79	3.42	3.78	3.48	Tepat Waktu

Pada tabel 4.8 Merupakan Data yang berisi nilai-nilai dari fitur-fitur yang digunakan untuk prediksi, dalam hal ini adalah nilai IPS1, IPS2, IPS3, IPS4, dan IPS5 dari mahasiswa. Berikut adalah langkah untuk menghitung rata-rata dan variansi dari setiap fitur (IPS1, IPS2, IPS3, IPS4, IPS5) untuk masing-masing kelas (Tepat Waktu dan Tidak Tepat Waktu).

- Rata-rata data **Tepat Waktu**

**Tabel 4. 9** Data Rata-Rata Tepat Waktu

IPS1	IPS2	IPS3	IPS4	IPS5
3.04	3.25	3.42	3.61	3.22
3.43	3.54	2.88	2	2.33
3.78	4	2.88	3.53	3.64
3.39	3.79	3.54	3.65	3.22
3.65	3.79	3.42	3.78	3.89

Jumlah data Tepat Waktu : 5 Data

$$\text{Rata-rata IPS1} = \frac{3.04+3.43+3.78+3.39+3.65}{5} = 3.458$$

$$\text{Rata-rata IPS2} = \frac{3.25+3.54+4+3.79+3.79}{5} = 3.674$$

$$\text{Rata-rata IPS3} = \frac{3.42+2.88+2.88+3.54+3.42}{5} = 3.228$$

$$\text{Rata-rata IPS4} = \frac{3.61+2+3.53+3.65+3.78}{5} = 3.314$$

$$\text{Rata-rata IPS5} = \frac{3.22+2.33+3.64+3.22+3.48}{5} = 3.378$$

- Variansi IPS untuk Tepat Waktu

Variansi IPS1 =

$$\frac{(3.04 - 3.458)^2 + (3.43 - 3.458)^2 + (3.78 - 3.458)^2 + (3.39 - 3.458)^2 + (3.65 - 3.458)^2}{5} = 0.0609$$

Variansi IPS2 =

$$\frac{(3.25 - 3.674)^2 + (3.54 - 3.674)^2 + (4 - 3.674)^2 + (3.79 - 3.674)^2 + (3.79 - 3.674)^2}{5} = 0.0721$$

Variansi IPS3 =

$$\frac{(3.42 - 3.228)^2 + (2.88 - 3.228)^2 + (2.88 - 3.228)^2 + (3.54 - 3.228)^2 + (3.42 - 3.228)^2}{5} = 0.0737$$

Variansi IPS4 =

$$\frac{(3.61 - 3.314)^2 + (2 - 3.314)^2 + (3.53 - 3.314)^2 + (3.65 - 3.314)^2 + (3.78 - 3.314)^2}{5} = 0.1068$$

Variansi IPS5 =

$$\frac{(3.22 - 3.378)^2 + (2.33 - 3.378)^2 + (3.64 - 3.378)^2 + (3.22 - 3.378)^2 + (3.48 - 3.378)^2}{5} = 0.0314$$

- Rata-rata dan **Tidak Tepat Waktu**

**Tabel 4. 10** Data Rata-Rata Tidak Tepat Waktu

IPS1	IPS2	IPS3	IPS4	IPS5
3.52	0	0	0	0
3.13	2.95	2.25	1.6	1.3
2.7	3.17	2.75	1.65	3
0	0	0	0	0

Jumlah Tidak Tepat Waktu : 4 Data

$$\text{Rata-rata IPS1} = \frac{3.52+3.13+2.7+0}{4} = 2.0875$$

$$\text{Rata-rata IPS2} = \frac{0+2.95+3.17+0}{4} = 1.78$$

$$\text{Rata-rata IPS3} = \frac{0+2.25+2.75+0}{4} = 1.5$$

$$\text{Rata-rata IPS4} = \frac{0+1.6+1.65+0}{4} = 0.8125$$

$$\text{Rata-rata IPS5} = \frac{0+1.3+3+0}{4} = 1.075$$

- Variansi IPS untuk Tidak Tepat Waktu

Variansi IPS1 =

$$\frac{(3.52 - 2.0875)^2 + (3.13 - 2.0875)^2 + (2.7 - 2.0875)^2 + (0 - 2.0875)^2}{4} = 3.192$$

Variansi IPS2 =

$$\frac{(0 - 1.78)^2 + (2.95 - 1.78)^2 + (3.17 - 1.78)^2 + (0 - 1.78)^2}{4} = 2.019$$

Variansi IPS3 =

$$\frac{(0 - 1.5)^2 + (2.25 - 1.5)^2 + (2.75 - 1.5)^2 + (0 - 1.5)^2}{4} = 2.1875$$

Variansi IPS4 =

$$\frac{(0 - 0.8125)^2 + (1.6 - 0.8125)^2 + (1.65 - 0.8125)^2 + (0 - 0.8125)^2}{4} = 0.6625$$

Variansi IPS5 =

$$\frac{(0 - 1.075)^2 + (1.3 - 1.075)^2 + (3 - 1.075)^2 + (0 - 1.075)^2}{4} = 1.013$$

- Ringkasan Rata-rata dan Variansi

**Tabel 4. 11** Data Rata-Rata Tidak Tepat Waktu

Fitur	Kelas "Tepat Waktu" (Rata-rata)	Kelas "Tepat Waktu" (Variansi)	Kelas "Tidak Tepat Waktu" (Rata-rata)	Kelas "Tidak Tepat Waktu" (Variansi)
IPS1	3.458	0.0609	2.0875	3.192
IPS2	3.674	0.0721	1.78	2.019
IPS3	3.228	0.0737	1.5	2.1875
IPS4	3.314	0.1068	0.8125	0.6625
IPS5	3.378	0.0314	1.075	1.013

### 3. Posterior Probabilitas

Langkah selanjutnya terdapat kasus dengan nilai IPS1 sebesar 3.5, IPS2 sebesar 3.6, IPS3 sebesar 3.3, IPS4 sebesar 3.4, dan IPS5 sebesar 3.3, maka dapat dihitung nilai posterior probabilitas untuk masing-masing kelas, yaitu 'Tepat Waktu' dan 'Tidak Tepat Waktu'. Proses perhitungan dilakukan dengan cara mengalikan likelihood masing-masing fitur yang dihitung berdasarkan distribusi normal pada tiap kelas dengan prior probabilitas kelas tersebut. Likelihood dihitung menggunakan rata-rata dan variansi dari data masing-masing kelas. Setelah diperoleh nilai likelihood total untuk setiap kelas, hasil ini dikalikan dengan prior probabilitas untuk mendapatkan nilai posterior. Berdasarkan hasil perhitungan, nilai posterior untuk kelas 'Tepat Waktu' lebih besar dibandingkan dengan kelas 'Tidak Tepat Waktu', sehingga dapat disimpulkan bahwa data tersebut diprediksi termasuk dalam kelas 'Tepat Waktu'."

- Menghitung Likelihood Total untuk kelas "Tepat Waktu":

$$P(\text{Data}|\text{Tepat Waktu}) = P(\text{IPS1}|\text{Tepat Waktu}) \times P(\text{IPS2}|\text{Tepat Waktu})$$

$$\begin{aligned} P(\text{Data}|\text{Tepat Waktu}) &= 1.609 \times 1.481 \times 1.470 \times 1.225 \times 2.241 \\ &= 7.6766 \end{aligned}$$

- Posterior untuk kelas "Tepat Waktu":

$$P(\text{Tepat Waktu} | \text{Data}) = 7.6766 \times 0.6238 = 4.7877$$

- Menghitung Likelihood Total untuk kelas "Tidak Tepat Waktu":

$$P(\text{Data}|\text{Tepat Waktu}) = P(\text{IPS1}|\text{Tepat Waktu}) \times P(\text{IPS2}|\text{Tepat Waktu})$$

$$\begin{aligned}P(\text{Data}|\text{Tepat Waktu}) &= 0.512 \times 0.469 \times 0.481 \times 0.607 \times 0.851 \\&= 0.0626\end{aligned}$$

- Posterior untuk kelas "Tidak Tepat Waktu":

$$P(\text{Tepat Waktu} | \text{Data}) = 0.0626 \times 0.3770 = 0.0236$$

Sehingga didapat nilai sebagai berikut :

- Posterior untuk Kelas "Tepat Waktu" = 4.7877
- Posterior untuk Kelas "Tidak Tepat Waktu" = 0.0236

Karena nilai Posterior untuk Kelas "Tepat Waktu" lebih besar daripada Posterior untuk Kelas "Tidak Tepat Waktu", kita dapat menyimpulkan bahwa Data yang diberikan lebih mungkin termasuk dalam kelas "Tepat Waktu".

## **BAB V**

### **HASIL DAN PEMBAHASAN**

#### **5.1 Analisis Data**

##### **1. Pengumpulan data**

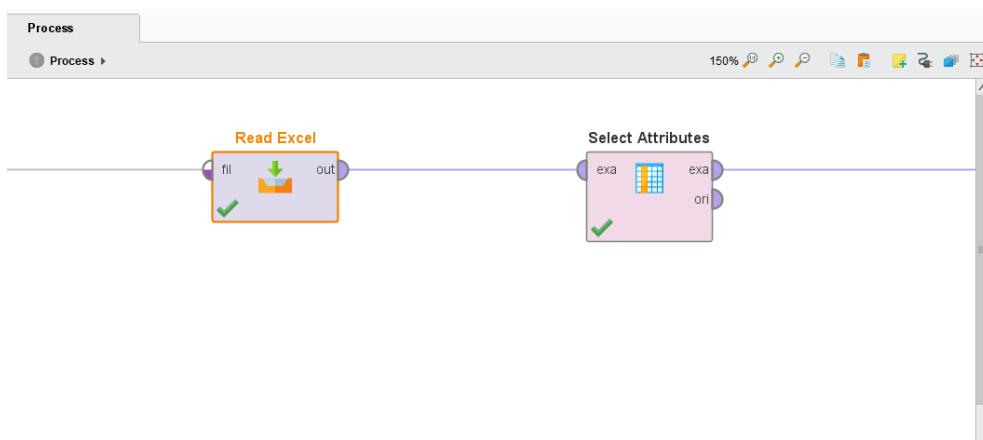
**Tabel 5. 1 Dataset Excel**

No	Jenis Kelamin	Umur	Kelas	Tahun Masuk	IPS1	IPS2	IPS3	IPS4	IPS5
1	Laki-laki	29	Reguler Sore	2015	3,04	3,25	3,42	3,61	3,22
2	Perempuan	30	Reguler Sore	2015	3,35	3,67	3,29	3,22	3,09
3	Laki-laki	30	Reguler Sore	3,43	3,54	2,88	2	2,33	3,43
4	Perempuan	27	Reguler Sore	3,78	4	2,88	3,53	3,64	3,78
5	Laki-laki	44	Reguler Sore	3,39	3,79	3,54	3,65	3,22	3,39
6	Laki-laki	29	Reguler Sore	3,52	0	0	0	0	3,52
7	Perempuan	26	Reguler Sore	3,13	2,95	2,25	1,6	1,3	3,13
8	Laki-laki	27	Reguler Sore	2,7	3,17	2,75	1,65	3	2,7
9	Perempuan	32	Reguler Sore	3,74	4	3,88	3,87	3,87	3,74
10	Laki-laki	29	Reguler Sore	0	0	0	0	0	0
11	Perempuan	29	Reguler Sore	2,26	2,61	0	0	0	2,26
12	Perempuan	26	Reguler Pagi	4	4	4	3,83	3,87	4
13	Laki-laki	29	Reguler Pagi	3,17	3,75	2,83	1,95	1,86	3,17
14	Laki-laki	30	Reguler Pagi	3,57	3,25	3	3,3	3,26	3,57
15	Laki-laki	30	Reguler Sore	3,65	3,79	3,42	3,78	3,48	3,65
16	Laki-laki	27	Reguler Sore	3,65	3,88	3,58	3,78	3,61	3,65
17	Laki-laki	41	Reguler Sore	1,35	0	0	0	0	1,35
18	Laki-laki	29	Reguler Pagi	2,91	3,33	2,88	2,26	1,83	2,91
19	Laki-laki	27	Reguler Pagi	3,78	3,67	3,54	3,78	3,35	3,78
...	...	...	...	...	...	...	...	...	...
762	Perempuan	46	Reguler Pagi	2016	0	2,53	3,15	3,26	2,65

Berdasarkan Dataset yang di peroleh merupakan data yang diambil data alumni dari tahun 2015-2016 sebanyak 762 data. Pada penelitian ini, digunakan software RapidMiner untuk mengolah dan menganalisis data yang memiliki 12 atribut. Namun, hanya beberapa atribut yang digunakan dalam analisis, yaitu jenis kelamin, kelas, serta lima variabel Indeks Prestasi Semester (IPS), yaitu IPS1, IPS2, IPS3, IPS4, dan IPS5. Atribut-atribut ini dipilih karena relevan dalam menggambarkan faktor-faktor yang mempengaruhi status kelulusan tepat waktu mahasiswa. Sedangkan lima atribut IPS digunakan untuk mengevaluasi perkembangan akademik mahasiswa dari semester ke semester. Selanjutnya, atribut-atribut ini diolah untuk proses klasifikasi dengan membandingkan dua metode, yaitu Decision Tree dan Naive Bayes. Perbandingan ini bertujuan untuk menentukan metode yang lebih efektif dalam memprediksi status kelulusan mahasiswa, sehingga hasil analisis dapat memberikan rekomendasi yang akurat dan informatif.

## 2. Seleksi Data

Setelah dataset yang diperlukan tersedia, tahap selanjutnya adalah seleksi atribut menggunakan RapidMiner, seperti gambar diagram proses rapidminer di bawah ini :



**Gambar 5. 1 Proses Seleksi Atribut**

Dalam tahapan seleksi atribut menggunakan RapidMiner, langkah pertama adalah membaca dataset yang disimpan dalam format Excel menggunakan operator "Read Excel". Setelah data berhasil diimpor, langkah berikutnya adalah melakukan

seleksi atribut dengan menggunakan operator "Select Attributes". Pada tahap ini, hanya atribut yang relevan untuk analisis yang dipilih, yaitu Jenis Kelamin, Kelas, dan lima variabel Indeks Prestasi Semester (IPS1, IPS2, IPS3, IPS4, IPS5). Berikut hasil dataset yang sudah di seleksi atribut pada gambar di bawah ini.

Row No.	Jenis Kelamin	Kelas	IPS1	IPS2	IPS3	IPS4	IPS5
1	Laki-laki	Reguler Sore	3.040	3.250	3.420	3.610	3.220
2	Perempuan	Reguler Sore	3.350	3.670	3.290	3.220	3.090
3	Laki-laki	Reguler Sore	3.430	3.540	2.880	2	2.330
4	Perempuan	Reguler Sore	3.780	4	2.880	3.530	3.640
5	Laki-laki	Reguler Sore	3.390	3.790	3.540	3.650	3.220
6	Laki-laki	Reguler Sore	3.520	0	0	0	0
7	Perempuan	Reguler Sore	3.130	2.950	2.250	1.600	1.300
8	Laki-laki	Reguler Sore	2.700	3.170	2.750	1.650	3
9	Perempuan	Reguler Sore	3.740	4	3.880	3.870	3.870
10	Laki-laki	Reguler Sore	0	0	0	0	0
11	Perempuan	Reguler Sore	2.260	2.610	0	0	0
12	Perempuan	Reguler Pagi	4	4	4	3.830	3.870
13	Laki-laki	Reguler Pagi	3.170	3.750	2.830	1.950	1.860
14	Laki-laki	Reguler Pagi	3.570	3.250	3	3.300	3.260
15	Laki-laki	Reguler Sore	3.650	3.790	3.420	3.780	3.480
16	Laki-laki	Reguler Sore	3.650	3.880	3.580	3.780	3.610
17	Laki-laki	Reguler Sore	1.350	0	0	0	0
18	Laki-laki	Reguler Pagi	2.910	3.330	2.880	2.260	1.830
19	Laki-laki	Reguler Pagi	3.780	3.670	3.540	3.780	3.350
20	Laki-laki	Reguler Pagi	3.910	3.920	3.590	4	3.330
21	Laki-laki	Reguler Sore	3.300	3.750	3.080	2.960	0.200
22	Perempuan	Reguler Pagi	3.780	3.790	3.880	4	4
23	Laki-laki	Reguler Pagi	3	3.580	3.040	2.090	0
24	Laki-laki	Reguler Sore	3.650	1.920	2.600	2.890	3.300
25	Laki-laki	Reguler Sore	3.040	2.460	2.170	1	0
26	Laki-laki	Reguler Pagi	3.910	3.920	3.880	3.870	3.220
27	Laki-laki	Reguler Pagi	0.610	0	0	0	0

ExampleSet (762 examples, 0 special attributes, 7 regular attributes)

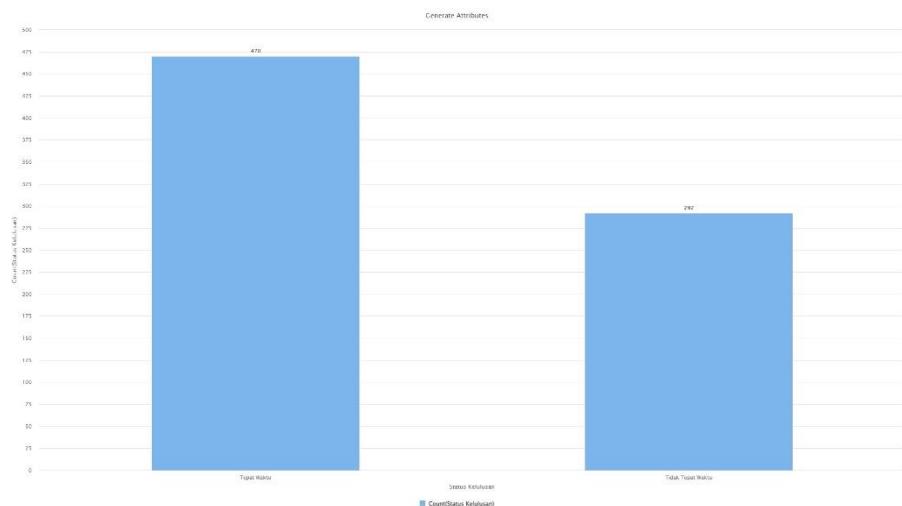
**Gambar 5. 2 Hasil Seleksi Atribut**

Setelah proses seleksi atribut selesai, dataset yang telah dipilih hanya mencakup atribut yang relevan untuk analisis, yaitu Jenis Kelamin, Kelas, serta lima variabel Indeks Prestasi Semester (IPS1 hingga IPS5). Atribut-atribut ini dianggap memiliki kontribusi signifikan terhadap prediksi status kelulusan tepat waktu mahasiswa. Dengan mengeliminasi atribut yang tidak diperlukan, dataset menjadi lebih sederhana dan lebih terfokus pada faktor-faktor yang benar-benar mempengaruhi hasil analisis. Dan setelah melakukan seleksi atribut, penentuan status kelulusan tepat waktu dilakukan dengan menggunakan operator **Generate**

**Attributes** di RapidMiner. Operator ini digunakan untuk menghitung rata-rata nilai IPS mahasiswa dari semester 1 hingga semester 5 dengan formula:

```
1 if((IPS1+IPS2+IPS3+IPS4+IPS5)/ 5 >= 2.75, "Tepat Waktu", "Tidak Tepat Waktu")
```

Setelah rata-rata IPS dihitung, operator yang sama juga digunakan untuk menentukan status kelulusan berdasarkan kriteria yang sudah ditetapkan, yaitu jika rata-rata IPS lebih besar dari atau sama dengan 2.75, status kelulusan mahasiswa adalah "Tepat Waktu", sedangkan jika kurang dari 2.75, statusnya adalah "Tidak Tepat Waktu". Dengan menggunakan **Generate Attributes**, atribut baru untuk rata-rata IPS dan status kelulusan ini kemudian ditambahkan ke dataset. Berikut Output dari proses penentuan status kelulusan.



**Gambar 5. 3** Diagram Status Kelulusan Mahasiswa

Pada gambar 5.3 merupakan hasil dari penentuan status kelulusan berdasarkan kriteria yang sudah ditetapkan dan data mahasiswa tepat waktu sebanyak 470 data dan 292 data mahasiswa tidak tepat waktu berikut gambar hasil tabel dari penentuan

atribut baru untuk status kelulusan yang ditambahkan ke dataset. Berikut tabel hasil dari rapidminer penentuan status kelulusan kedataset.

Row No.	Jenis Kelamin	Kelas	IPS1	IPS2	IPS3	IPS4	IPS5	Status Kelul...
1	Laki-laki	Reguler Sore	3.040	3.250	3.420	3.810	3.220	Tepat Waktu
2	Perempuan	Reguler Sore	3.350	3.670	3.290	3.220	3.090	Tepat Waktu
3	Laki-laki	Reguler Sore	3.430	3.540	2.880	2	2.330	Tepat Waktu
4	Perempuan	Reguler Sore	3.780	4	2.880	3.530	3.640	Tepat Waktu
5	Laki-laki	Reguler Sore	3.390	3.790	3.540	3.650	3.220	Tepat Waktu
6	Laki-laki	Reguler Sore	3.520	0	0	0	0	Tidak Tepat ...
7	Perempuan	Reguler Sore	3.130	2.950	2.250	1.600	1.300	Tidak Tepat ...
8	Laki-laki	Reguler Sore	2.700	3.170	2.750	1.650	3	Tidak Tepat ...
9	Perempuan	Reguler Sore	3.740	4	3.880	3.870	3.870	Tepat Waktu
10	Laki-laki	Reguler Sore	0	0	0	0	0	Tidak Tepat ...
11	Perempuan	Reguler Sore	2.260	2.610	0	0	0	Tidak Tepat ...
12	Perempuan	Reguler Pagi	4	4	4	3.830	3.870	Tepat Waktu
13	Laki-laki	Reguler Pagi	3.170	3.750	2.830	1.950	1.860	Tidak Tepat ...
14	Laki-laki	Reguler Pagi	3.570	3.250	3	3.300	3.280	Tepat Waktu
15	Laki-laki	Reguler Sore	3.650	3.790	3.420	3.780	3.480	Tepat Waktu
16	Laki-laki	Reguler Sore	3.650	3.880	3.580	3.780	3.610	Tepat Waktu
17	Laki-laki	Reguler Sore	1.350	0	0	0	0	Tidak Tepat ...
18	Laki-laki	Reguler Pagi	2.910	3.330	2.880	2.260	1.830	Tidak Tepat ...
19	Laki-laki	Reguler Pagi	3.780	3.670	3.540	3.780	3.350	Tepat Waktu
20	Laki-laki	Reguler Pagi	3.910	3.920	3.590	4	3.330	Tepat Waktu
21	Laki-laki	Reguler Sore	3.300	3.750	3.080	2.960	0.200	Tidak Tepat ...
22	Perempuan	Reguler Pagi	3.780	3.790	3.880	4	4	Tepat Waktu
23	Laki-laki	Reguler Pagi	3	3.580	3.040	2.090	0	Tidak Tepat ...
24	Laki-laki	Reguler Sore	3.650	1.920	2.600	2.890	3.300	Tepat Waktu
25	Laki-laki	Reguler Sore	3.040	2.460	2.170	1	0	Tidak Tepat ...
26	Laki-laki	Reguler Pagi	3.910	3.920	3.880	3.870	3.220	Tepat Waktu
27	Laki-laki	Reguler Pagi	0.610	0	0	0	0	Tidak Tepat ...

ExampleSet (762 examples, 0 special attributes, 8 regular attributes)

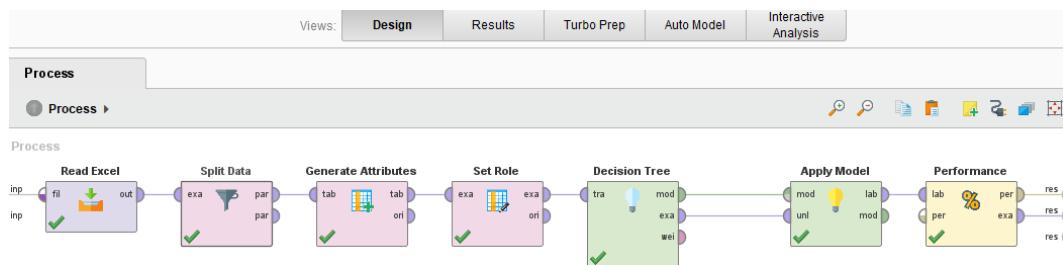
**Gambar 5. 4** Hasil Penentuan Atribut status kelulusan pada dataset

Setelah proses penentuan atribut status kelulusan selesai, hasilnya adalah sebuah tabel yang menunjukkan status kelulusan setiap mahasiswa berdasarkan rata-rata nilai IPS dari semester 1 hingga semester 5. Tabel ini memberikan gambaran yang jelas mengenai status kelulusan tepat waktu atau tidak tepat waktu untuk setiap mahasiswa, yang selanjutnya dapat digunakan untuk analisis lebih lanjut dalam model klasifikasi.

## 5.2 Implementasi Model Decision Tree

Pemodelan menggunakan Decision Tree untuk memprediksi status kelulusan mahasiswa berdasarkan data uji. Proses dimulai dengan membagi dataset menjadi dua bagian: data latih (training) untuk membangun model dan data uji (testing) untuk menguji akurasi model. Menggunakan operator "Decision Tree" di RapidMiner, model dibangun dengan mempelajari hubungan antara atribut seperti

Jenis Kelamin, Kelas, dan rata-rata IPS dengan status kelulusan (Tepat Waktu atau Tidak Tepat Waktu). Setelah model dilatih dengan data latih, model tersebut kemudian diuji dengan data uji untuk memprediksi status kelulusan mahasiswa. Evaluasi kinerja model dilakukan menggunakan metrik seperti *akurasi*, *precision*, dan *recall*. Adapun model decision tree pada rapidminer pada gambar di bawah berikut :



**Gambar 5. 5** Proses Pemodelan Decision Tree

*Diagram Process : [Read Excel] → [Split Data] → [Generate Attributes] → [Set Role] → [Decision Tree] → [Apply Model] → [Performance]*

Pada gambar 5.4 Proses pemodelan menggunakan Decision Tree dimulai dengan *Read Excel*, yang digunakan untuk mengimpor dataset dari file Excel ke dalam RapidMiner. Setelah data dibaca, tahap selanjutnya adalah *Split Data*, yang membagi dataset menjadi dua bagian: data latih 80% (training) dan data uji 20% (testing). Data latih digunakan untuk membangun model, sedangkan data uji digunakan untuk menguji akurasi model. Setelah pembagian data, langkah berikutnya adalah *Generate Attributes*, yang digunakan untuk menghitung rata-rata nilai IPS dan menentukan status kelulusan mahasiswa berdasarkan kriteria tertentu. Setelah itu, *Set Role* dilakukan untuk menetapkan peran atribut, seperti atribut target (status kelulusan) dan atribut input (nilai IPS, Jenis Kelamin, dan Kelas). Kemudian, operator *Decision Tree* diterapkan untuk membangun model klasifikasi berdasarkan data latih, diikuti dengan *Apply Model*, yang memprediksi status kelulusan pada data uji menggunakan model yang telah dibangun. Terakhir,

*Performance* digunakan untuk mengevaluasi kinerja model dengan menghitung metrik seperti akurasi, precision, dan recall, yang menunjukkan seberapa efektif model dalam memprediksi status kelulusan mahasiswa. Adapun hasil pengujian akurasi model menggunakan rapidminer sebagaimana yang di tampilkan pada gambar 5.5 berikut :

	<b>PerformanceVector</b>
Performance	<pre>PerformanceVector: accuracy: 97.87% ConfusionMatrix: True: Tepat Waktu      Tidak Tepat Waktu Tepat Waktu:    373      6 Tidak Tepat Waktu:   7     224 precision: 96.97% (positive class: Tidak Tepat Waktu) ConfusionMatrix: True: Tepat Waktu      Tidak Tepat Waktu Tepat Waktu:    373      6 Tidak Tepat Waktu:   7     224 recall: 97.39% (positive class: Tidak Tepat Waktu) ConfusionMatrix: True: Tepat Waktu      Tidak Tepat Waktu Tepat Waktu:    373      6 Tidak Tepat Waktu:   7     224 AUC (optimistic): 0.998 (positive class: Tidak Tepat Waktu) AUC: 0.984 (positive class: Tidak Tepat Waktu) AUC (pessimistic): 0.970 (positive class: Tidak Tepat Waktu)</pre>
Description	
Annotations	

**Gambar 5. 6** Hasil Confussion Matrix Decision Tree

Berdasarkan gambar 5.5 diatas dapat dilakukan perhitungan lebih lanjut terkait Akurasi, Presisi, Dan Recall sebagai berikut :

**Tabel 5. 2** Hasil Perhitungan Confussion Matrix

Status	Precission	Recall	Jumlah Data
Tepat Waktu	98.42%	98.16%	379
Tidak Tepat	96.97%	97.39%	231
Accuracy	97.87%		610

Pada tabel 5.2 diatas, terdapat hasil nilai akurasi dari proses prediksi mahasiswa menggunakan *Confussion Matrix* dengan nilai akurasi sebesar 97.87% yang diperoleh dari data testing yang berjumlah 610 data, dengan jumlah mahasiswa tepat waktu sebanyak 379 orang, jumlah mahasiswa tidak lulus tepat waktu

sebanyak 231 orang serta jumlah mahasiswa. Untuk mengukur performance metrics dari model evaluasi dengan *Confussion Matrix*, dapat menggunakan *accuracy*, *precision* dan *recall*. Perhitungan manualnya menggunakan persamaan berikut :

### 1. Accuracy

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

$$Akurasi = \frac{373 + 224}{610} = \frac{597}{610} \times 100\% = 97.87\%$$

### 2. Precision

$$Precision = \frac{TP}{TP + FP} \times 100\%$$

$$Precision = \frac{373}{373 + 6} = \frac{373}{379} \times 100\% = 98.42\%$$

### 3. Recall

$$Recall = \frac{TP}{TP + FN} \times 100\%$$

$$Recall = \frac{373}{373 + 7} = \frac{373}{380} \times 100\% = 98.16\%$$

Berdasarkan perhitungan manual *Confussion Matrix*, maka bisa disimpulkan bahwa nilai *Accuracy* 97.87%, *Precision* 98.42%, dan nilai *Recall* 98.16%. Berikut gambar 5.6 hasil Data Mining Accuracy Results pada *rapidminner*

accuracy: 97.87%

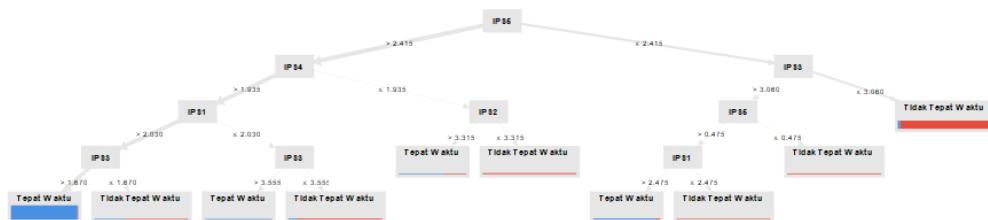
	true Tepat Waktu	true Tidak Tepat Waktu	class precision
pred. Tepat Waktu	373	6	98.42%
pred. Tidak Tepat Waktu	7	224	96.97%
class recall	98.16%	97.39%	

**Gambar 5. 7 Data Mining Accuracy Results Decision Tree**

Pada gambar 5.7 hasil evaluasi model menggunakan RapidMiner menunjukkan performa yang sangat baik dengan akurasi 97.87%, yang berarti model berhasil memprediksi status kelulusan mahasiswa dengan benar pada hampir 98% data yang diuji. Confusion Matrix mengungkapkan bahwa model memprediksi 376 mahasiswa sebagai "Tepat Waktu" dan 228 mahasiswa sebagai "Tidak Tepat Waktu", dengan hanya sedikit kesalahan prediksi. Nilai Precision untuk kelas "Tepat Waktu" adalah 98.42% dan untuk "Tidak Tepat Waktu" adalah 96.97%, yang menunjukkan bahwa model sangat akurat dalam memprediksi kedua kelas tersebut. Recall untuk kelas "Tepat Waktu" mencapai 98.16%, dan untuk kelas "Tidak Tepat Waktu" adalah 97.39%, yang menunjukkan kemampuan model dalam menangkap sebagian besar data yang relevan.

- **Hasil Pemodelan Decision Tree**

Hasil pemodelan *Decision Tree* didapatkan hasil visualisasi pohon keputusan sebagaimana ditampilkan pada *Rapidminer* pada gambar 5.8 berikut ini



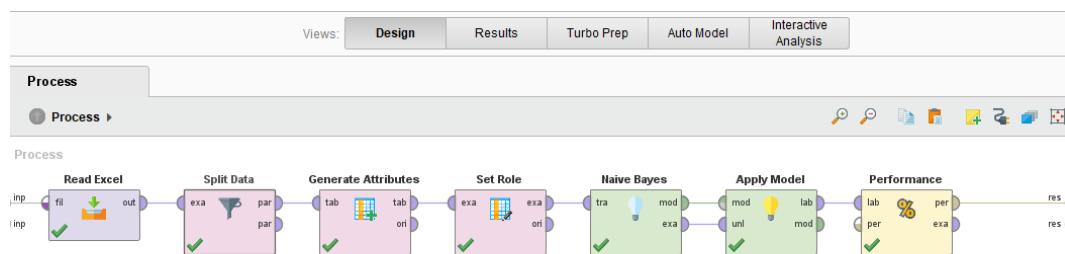
**Gambar 5. 8 Pohon Keputusan**

Berdasarkan gambar 5.8 Pohon keputusan yang diberikan memiliki 19 jalur keputusan untuk memprediksi status kelulusan mahasiswa berdasarkan nilai IPS5,

IPS4, IPS1, IPS3, dan IPS2. Dimulai dengan evaluasi IPS5, jika nilai IPS5 lebih besar dari 2.415, model akan melanjutkan ke IPS4, dan selanjutnya ke IPS1 dan IPS3 untuk menentukan apakah mahasiswa lulus tepat waktu atau tidak, dengan pemisahan yang semakin mendalam berdasarkan nilai-nilai atribut tersebut. Jika nilai IPS5 lebih kecil atau sama dengan 2.415, model akan memeriksa IPS3 dan kemudian melanjutkan ke IPS5 dan IPS1 untuk memprediksi status kelulusan. Jalur keputusan ini mencakup berbagai kombinasi nilai, seperti  $\text{IPS1} > 2.030$  atau  $\text{IPS3} \leq 3.060$ , yang pada akhirnya menghasilkan prediksi "Tepat Waktu" atau "Tidak Tepat Waktu" berdasarkan nilai-nilai atribut.

### 5.3 Implementasi Model Naive Bayes

Pemodelan menggunakan Naive Bayes untuk memprediksi status kelulusan mahasiswa berdasarkan data uji. Menggunakan operator Naive Bayes di *RapidMiner*, model dibangun dengan mempelajari hubungan antara atribut seperti Jenis Kelamin, Kelas, dan rata-rata IPS dengan status kelulusan (Tepat Waktu atau Tidak Tepat Waktu). Setelah model dilatih dengan data latih, model tersebut kemudian diuji dengan data uji untuk memprediksi status kelulusan mahasiswa. Untuk menampilkan nilai seperti akurasi, precision, dan recall. Adapun model decision tree pada rapidminer pada gambar di bawah berikut :



**Gambar 5. 9** Proses Pemodelan Naive Bayes

*Diagram Process : [Read Excel] → [Split Data] → [Generate Attributes] → [Set Role] → [Decision Tree] → [Apply Model] → [Performance]*

Pada gambar 5.9, proses pemodelan menggunakan Naive Bayes dimulai dengan Read Excel, yang digunakan untuk mengimpor dataset dari file Excel ke dalam RapidMiner. Setelah data dibaca, tahap selanjutnya adalah Split Data, yang

membagi dataset menjadi dua bagian: data latih (training) dan data uji (testing). Data latih digunakan untuk membangun model, sedangkan data uji digunakan untuk menguji akurasi model. Setelah pembagian data, langkah berikutnya adalah Generate Attributes, yang digunakan untuk menghitung rata-rata nilai IPS dan menentukan status kelulusan mahasiswa berdasarkan kriteria tertentu. Setelah itu, Set Role dilakukan untuk menetapkan peran atribut, seperti atribut target (status kelulusan) dan atribut input (nilai IPS, Jenis Kelamin, dan Kelas). Kemudian, operator Naive Bayes diterapkan untuk membangun model klasifikasi berdasarkan data latih, diikuti dengan Apply Model, yang memprediksi status kelulusan pada data uji menggunakan model yang telah dibangun. Terakhir, Performance digunakan untuk mengevaluasi kinerja model dengan menghitung metrik seperti akurasi, precision, dan recall, yang menunjukkan seberapa efektif model dalam memprediksi status kelulusan mahasiswa. Adapun hasil pengujian akurasi model menggunakan RapidMiner sebagaimana yang ditampilkan pada gambar 5.10 berikut:

```

PerformanceVector
PerformanceVector:
accuracy: 97.70%
ConfusionMatrix:
True: Tepat Waktu      Tidak Tepat Waktu
Tepat Waktu:    371      5
Tidak Tepat Waktu:   9     225
precision: 96.15% (positive class: Tidak Tepat Waktu)
ConfusionMatrix:
True: Tepat Waktu      Tidak Tepat Waktu
Tepat Waktu:    371      5
Tidak Tepat Waktu:   9     225
recall: 97.83% (positive class: Tidak Tepat Waktu)
ConfusionMatrix:
True: Tepat Waktu      Tidak Tepat Waktu
Tepat Waktu:    371      5
Tidak Tepat Waktu:   9     225
AUC (optimistic): 0.997 (positive class: Tidak Tepat Waktu)
AUC: 0.997 (positive class: Tidak Tepat Waktu)
AUC (pessimistic): 0.997 (positive class: Tidak Tepat Waktu)

```

**Gambar 5. 10** Hasil Confussion Matrix Naive Bayes

Berdasarkan gambar 5.10 diatas dapat dilakukan perhitungan lebih lanjut terkait Akurasi, Presisi, Dan Recall sebagai berikut :

Status	Precision	Recall	Jumlah Data
Tepat Waktu	98.67%	97.63%	371
Tidak Tepat	96.15%	97.83%	225
Accuracy	97.70%	610	

**Tabel 5.3** Perhitungan Confussion Matrix

Pada tabel 5.3 diatas, terdapat hasil nilai akurasi dari proses prediksi mahasiswa menggunakan *Confussion Matrix* dengan nilai akurasi sebesar 97.70% yang diperoleh dari data testing yang berjumlah 610 data, dengan jumlah mahasiswa tepat waktu sebanyak 376 orang, jumlah mahasiswa tidak lulus tepat waktu sebanyak 234 orang serta jumlah mahasiswa. Untuk mengukur performance metrics dari model evaluasi dengan *Confussion Matrix*, dapat menggunakan *accuracy*, *precision* dan *recall*. Perhitungan manualnya menggunakan persamaan berikut :

### 1. Accuracy

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

$$Akurasi = \frac{371 + 225}{373 + 225 + 9 + 5} = \frac{596}{610} \times 100\% = 97.70\%$$

### 2. Precision

$$Precision = \frac{TP}{TP + FP} \times 100\%$$

$$Precision = \frac{373}{373 + 5} \times 100\% = 98.67\%$$

### 3. Recall

$$Recall = \frac{TP}{TP + FN} \times 100\%$$

$$Recall = \frac{373}{373 + 9} = \frac{371}{380} \times 100\% = 97.63\%$$

Berdasarkan perhitungan manual *Confussion Matrix*, maka bisa disimpulkan bahwa nilai *Accuracy* 97.70%, *Precision* 98.67%, dan nilai *Recall* 97.63%. Berikut gambar 5.6 hasil Data Mining Accuracy Results pada *rapidminner*

accuracy: 97.70%			
	true Tepat Waktu	true Tidak Tepat Waktu	class precision
pred. Tepat Waktu	371	5	98.67%
pred. Tidak Tepat Waktu	9	225	96.15%
class recall	97.63%	97.83%	

**Gambar 5. 11** Data Mining Accuracy Results Naive Bayes

Pada hasil evaluasi model menggunakan RapidMiner yang ditampilkan dalam gambar, model menunjukkan akurasinya 97.70%, yang berarti model berhasil memprediksi status kelulusan mahasiswa dengan benar pada sekitar 97.7% data yang diuji. Confusion Matrix menunjukkan bahwa model memprediksi 371 mahasiswa sebagai "Tepat Waktu" dan 225 mahasiswa sebagai "Tidak Tepat Waktu", dengan sedikit kesalahan prediksi yaitu 5 kesalahan untuk kelas "Tepat Waktu" dan 9 kesalahan untuk kelas "Tidak Tepat Waktu". Nilai Precision untuk kelas "Tidak Tepat Waktu" adalah 96.15%, yang berarti model sangat akurat dalam memprediksi kelas ini, sedangkan Recall untuk kelas "Tidak Tepat Waktu" mencapai 97.83%.

#### 5.4 Evaluasi Dan Validasi

Pengujian dilakukan dengan menggunakan RapidMiner untuk mengolah 610 data testing yang terdiri dari atribut akademik mahasiswa, dengan dua metode, yaitu Decision Tree dan Naive Bayes, untuk memprediksi status kelulusan mahasiswa tepat waktu. Kedua algoritma ini diuji pada dataset mahasiswa untuk menentukan apakah mahasiswa akan lulus tepat waktu atau tidak berdasarkan nilai IPS mereka. Algoritma Naive Bayes menggunakan operator Naive Bayes di RapidMiner dan berhasil mencapai akurasi sebesar 97.70%, sementara Decision Tree yang menggunakan operator Decision Tree di RapidMiner memperoleh akurasi sebesar 97.87%. Meskipun kedua model menunjukkan hasil yang sangat

baik, Decision Tree sedikit lebih unggul dalam hal akurasi dibandingkan Naive Bayes. Kedua model ini terbukti efektif dalam memprediksi status kelulusan mahasiswa dengan akurasi yang sangat tinggi dapat dilihat dibawah ini.

**Tabel 5. 4** Perbandingan Tingkat Akurasi Decision Tree dan Naive Bayes

Metode Data Mining	Nilai Akurasi
Decision Tree	97.87%
Naive Bayes	97.70%

Pada tabel di atas, algoritma Decision Tree lebih unggul dengan akurasi 97.87%, dibandingkan dengan Naive Bayes yang memperoleh akurasi 97.70%. Meskipun perbedaan akurasi keduanya tidak terlalu besar, Decision Tree menunjukkan hasil yang sedikit lebih baik dalam memprediksi status kelulusan mahasiswa tepat waktu. Performa ini menunjukkan bahwa Decision Tree lebih efektif dalam menangani kompleksitas dan variasi data dalam dataset yang diuji. Hal ini bisa disebabkan oleh kemampuan Decision Tree dalam membangun pohon keputusan yang lebih terstruktur dan mudah diinterpretasikan berdasarkan pembagian atribut yang jelas. Sementara itu, meskipun Naive Bayes memiliki kelebihan dalam hal kesederhanaan dan kecepatan dalam pemrosesan, model ini mungkin kurang optimal dalam menangani hubungan yang lebih kompleks antar atribut dibandingkan dengan Decision Tree. Namun, kedua algoritma ini tetap memberikan kinerja yang sangat baik dalam memprediksi kelulusan tepat waktu mahasiswa.

## **BAB VI**

### **KESIMPULAN DAN SARAN**

#### **6.1 Kesimpulan**

Berdasarkan hasil evaluasi dan pengujian yang dilakukan menggunakan RapidMiner, dua algoritma yang diuji, yaitu Decision Tree dan Naive Bayes, menunjukkan kinerja yang sangat baik dalam memprediksi status kelulusan mahasiswa tepat waktu. Model Decision Tree menghasilkan akurasi 97.87%, sedangkan Naive Bayes memperoleh akurasi 97.70%. Hasil ini menunjukkan bahwa kedua algoritma dapat diandalkan untuk memprediksi apakah seorang mahasiswa akan lulus tepat waktu berdasarkan data akademik mereka, seperti nilai IPS. Decision Tree terbukti sedikit lebih unggul karena kemampuannya dalam menangani kompleksitas data dan menghasilkan aturan yang lebih terstruktur dan mudah diinterpretasikan. Oleh karena itu, Decision Tree dapat menjadi pilihan yang lebih baik dalam model klasifikasi status kelulusan mahasiswa tepat waktu.

#### **6.2 Saran**

Agar prediksi kelulusan mahasiswa dapat lebih akurat dan dapat diandalkan, disarankan untuk memperluas cakupan data yang digunakan, termasuk menambahkan variabel-variabel lain yang relevan seperti aktivitas ekstrakurikuler, tingkat kehadiran, dan latar belakang sosial. Penting untuk rutin memperbarui data agar model tetap relevan dan akurat. Mengintegrasikan hasil prediksi ke dalam sistem akademik akan membantu pengambilan keputusan yang lebih cepat dan mendukung kelulusan mahasiswa.

## DAFTAR PUSTAKA

- [1] H. Salmawati, Yuyun, "Klasifikasi Mahasiswa Berpotensi Drop Out Menggunakan Algoritma Decision Tree C4 . 5 Dan Naive Bayes Di Universitas Jambi," *J. Ilm. Ilmu Komput.*, vol. 8, no. 2, p. 115032, 2021, [Online]. Available: <https://repository.unja.ac.id/25341/>
- [2] A. Supriyadi, "Perbandingan Algoritma Naive Bayes dan Decision Tree (C4.5) dalam Klasifikasi Dosen Berprestasi," *Jurnal Teknologi Informasi dan Komputer*, vol. 9, no. 2, pp. 112-120, 2023.
- [3] I. Hariyanti, M. Al-Husaini, and A. R. Raharja, "Perbandingan Algoritma Decision Tree dan Naive Bayes dalam Klasifikasi Data Pengaruh Media Sosial dan Jam Tidur Terhadap Prestasi Akademik Siswa," *Jurnal Informatika*, vol. 6, no. 1, pp. 50-57, 2023.
- [4] R. Maulana, R. Narasati, R. Herdiana, R. Hamonangan, and S. Anwar, "Komparasi Algoritma Decision Tree dan Naive Bayes dalam Klasifikasi Penyakit Diabetes," *Jurnal Kesehatan dan Teknologi Informasi*, vol. 4, no. 3, pp. 123-130, 2024.
- [5] Agus Budiyantara, Irwansyah, dan Egi Prengki. (2020). Komparasi Algoritma Decision Tree, Naive Bayes Dan K-Nearest Neighbor Untuk Memprediksi Mahasiswa Lulus Tepat Waktu. *Jurnal Teknologi dan Sistem Informasi*, 9(2), 120-130. Diakses dari [jurnal.univrab.ac.id](http://jurnal.univrab.ac.id).
- [6] Rasi Nuraeni. (2021). Perbandingan Algoritma Naïve Bayes Classifier Dan Algoritma Decision Tree Untuk Memprediksi Lama Studi Mahasiswa. *Jurnal Informatika dan Teknologi*, 7(1), 45-56. Diakses dari [e-journal.hamzanwadi.ac.id](http://e-journal.hamzanwadi.ac.id).
- [7] Kusrini & Prasetio. (2020). Prediksi Tingkat Kelulusan Mahasiswa menggunakan Algoritma Naïve Bayes, Decision Tree, ANN, KNN, dan SVM. *Jurnal Sistem Informasi dan Teknologi*, 10(4), 215-225. Diakses dari [media.neliti.com](http://media.neliti.com).
- [8] S. Imran, B. Susetyo, and A. P. Wigena, "Analisis Faktor-Faktor yang Mempengaruhi Drop Out Mahasiswa di Perguruan Tinggi," *Jurnal Pendidikan dan Pembelajaran*, vol. 12, no. 3, pp. 180-188, 2013

- [9] M. Arham, A. Rahmat, and R. Ridfah, "Drop Out Mahasiswa dan Faktor-Faktor Penyebabnya," *Jurnal Pendidikan Islam*, vol. 6, no. 2, pp. 200-210, 2017.
- [10] A. Nurhayati, Y. Permadi, and A. Iskandar, "Analisis Drop Out Mahasiswa pada Fakultas Teknik dengan Metode Naive Bayes," *Jurnal Sistem Informasi dan Rekayasa Perangkat Lunak*, vol. 9, no. 2, pp. 45-52, 2015.
- [11] Kamil, M., & Cholil, W. (2020). Perbandingan Algoritma C4.5 dan Naive Bayes Pada Lulusan Tepat Waktu Mahasiswa. *Jurnal* 7(2), 97-106.
- [12] RapidMiner. (2020). *RapidMiner Studio 9.9 User Guide*. RapidMiner. Diakses dari <https://docs.rapidminer.com>.
- [13] M. Tripathy, A. Agrawal, and S. Rath, "F-Measure pada Evaluasi Model Machine Learning," *International Journal of Advanced Computer Science and Applications*, vol. 7, no. 1, pp. 110-117, 2016.

## LAMPIRAN

no	nim	JK	Umur	Kelas	tahun masuk	IPS1	IPS2	IPS3	IPS4	IPS5	status
1	T31150 01	Laki-laki	29	Reguler Sore	2015	3,04	3,25	3,42	3,61	3,22	Tepat Waktu
3	T31150 03	Laki-laki	30	Reguler Sore	2015	3,43	3,54	2,88	2	2,33	Tepat Waktu
5	T31150 05	Laki-laki	44	Reguler Sore	2015	3,39	3,79	3,54	3,65	3,22	Tepat Waktu
14	T31150 14	Laki-laki	30	Reguler Pagi	2015	3,57	3,25	3	3,3	3,26	Tepat Waktu
15	T31150 15	Laki-laki	30	Reguler Sore	2015	3,65	3,79	3,42	3,78	3,48	Tepat Waktu
16	T31150 16	Laki-laki	27	Reguler Sore	2015	3,65	3,88	3,58	3,78	3,61	Tepat Waktu
19	T31150 19	Laki-laki	27	Reguler Pagi	2015	3,78	3,67	3,54	3,78	3,35	Tepat Waktu
20	T31150 20	Laki-laki	27	Reguler Pagi	2015	3,91	3,92	3,59	4	3,33	Tepat Waktu
24	T31150 24	Laki-laki	27	Reguler Sore	2015	3,65	1,92	2,6	2,89	3,3	Tepat Waktu
26	T31150 26	Laki-laki	25	Reguler Pagi	2015	3,91	3,92	3,88	3,87	3,22	Tepat Waktu
30	T31150 30	Laki-laki	27	Reguler Pagi	2015	3,39	3,13	2,29	2,06	3	Tepat Waktu
31	T31150 31	Laki-laki	26	Reguler Pagi	2015	3,74	3,88	3,88	3,74	3,48	Tepat Waktu
35	T31150 35	Laki-laki	32	Reguler Pagi	2015	3,22	3,54	3,58	3,17	3	Tepat Waktu
46	T31150 46	Laki-laki	26	Reguler Pagi	2015	3	3,5	3,09	2,14	3	Tepat Waktu
48	T31150 48	Laki-laki	27	Reguler Pagi	2015	3,3	3,33	3,13	2,91	2,95	Tepat Waktu
50	T31150 50	Laki-laki	29	Reguler Sore	2015	3,3	3,88	3,67	3,52	3,61	Tepat Waktu
52	T31150 52	Laki-laki	28	Reguler Pagi	2015	3,57	3,63	3,54	3,71	3,35	Tepat Waktu
56	T31150 56	Laki-laki	29	Reguler Sore	2015	3,13	3,54	3,54	2,87	3,55	Tepat Waktu
57	T31150 57	Laki-laki	27	Reguler Pagi	2015	3,43	3,92	3,42	3,57	3,22	Tepat Waktu
61	T31150 61	Laki-laki	26	Reguler Pagi	2015	3,7	3,46	3	3,3	2,83	Tepat Waktu
62	T31150 62	Laki-laki	27	Reguler Pagi	2015	3,35	3,75	3,75	3,39	3,22	Tepat Waktu
65	T31150 65	Laki-laki	28	Reguler Pagi	2015	3,43	3,88	3,13	2,91	3,05	Tepat Waktu

68	T31150 68	Laki-laki	27	Reguler Pagi	2015	3,91	3,67	3,79	3,7	3,87	Tepat Waktu
69	T31150 69	Laki-laki	28	Reguler Pagi	2015	3,57	3,21	3,27	2,61	3,2	Tepat Waktu
73	T31150 73	Laki-laki	27	Reguler Sore	2015	3,43	3,71	3,71	3,61	3,74	Tepat Waktu
75	T31150 75	Laki-laki	30	Reguler Sore	2015	3,57	3,58	3,25	3	2,7	Tepat Waktu
78	T31150 78	Laki-laki	28	Reguler Sore	2015	3,74	3,79	3,88	3,61	3,48	Tepat Waktu
79	T31150 79	Laki-laki	29	Reguler Pagi	2015	3,39	3,08	3,17	3,17	3,09	Tepat Waktu
80	T31150 80	Laki-laki	31	Reguler Sore	2015	3,74	3,79	3,79	3,78	3,87	Tepat Waktu
83	T31150 84	Laki-laki	30	Reguler Sore	2015	3,7	4	3,63	3,17	3,61	Tepat Waktu
84	T31150 85	Laki-laki	30	Reguler Pagi	2015	3,83	3,29	3,38	3,17	3,05	Tepat Waktu
88	T31150 89	Laki-laki	30	Reguler Sore	2015	3,35	3,29	3,08	3,26	3,61	Tepat Waktu
89	T31150 90	Laki-laki	28	Reguler Sore	2015	3,3	3,54	3,21	3,09	3,4	Tepat Waktu
95	T31150 96	Laki-laki	28	Reguler Pagi	2015	3,52	3,79	3,29	3,09	3,22	Tepat Waktu
96	T31150 97	Laki-laki	27	Reguler Pagi	2015	3,09	3,21	2,85	2,7	2,67	Tepat Waktu
99	T31151 00	Laki-laki	30	Reguler Sore	2015	3,48	3,21	3,21	2,57	3,25	Tepat Waktu
101	T31151 02	Laki-laki	30	Reguler Sore	2015	2,7	3,13	2,08	3	3,35	Tepat Waktu
103	T31151 04	Laki-laki	27	Reguler Pagi	2015	3,61	3,33	2,79	3,2	2,96	Tepat Waktu
105	T31151 06	Laki-laki	28	Reguler Pagi	2015	3,48	3,21	2,71	3,05	3,22	Tepat Waktu
108	T31151 09	Laki-laki	29	Reguler Sore	2015	3,61	3,92	3,5	3,52	3,48	Tepat Waktu
109	T31151 10	Laki-laki	28	Reguler Pagi	2015	3,61	3,33	2,63	3,25	2,83	Tepat Waktu
110	T31151 11	Laki-laki	26	Reguler Sore	2015	2,48	3,42	3,04	2,65	2,65	Tepat Waktu
111	T31151 12	Laki-laki	30	Reguler Pagi	2015	3,87	3,79	3,88	4	2,83	Tepat Waktu
115	T31151 16	Laki-laki	26	Reguler Pagi	2015	3,7	3,67	3,59	3	3,33	Tepat Waktu
116	T31151 17	Laki-laki	27	Reguler Pagi	2015	4	3,92	4	3,87	3,87	Tepat Waktu

122	T31151 23	Laki-laki	28	Reguler Sore	2015	3,04	3,67	3,58	3,26	3,61	Tepat Waktu
124	T31151 25	Laki-laki	27	Reguler Sore	2015	3,13	2,83	3,3	3,04	3,42	Tepat Waktu
125	T31151 26	Laki-laki	28	Reguler Sore	2015	3,43	3,67	3,54	3,78	3,48	Tepat Waktu
128	T31151 29	Laki-laki	33	Reguler Sore	2015	3,3	3,79	3,46	3,39	3,48	Tepat Waktu
138	T31151 39	Laki-laki	27	Reguler Sore	2015	2,95	3,54	2,71	2,33	3	Tepat Waktu
141	T31151 42	Laki-laki	28	Reguler Pagi	2015	2,87	3,33	2,68	3,3	3,13	Tepat Waktu
142	T31151 43	Laki-laki	27	Reguler Sore	2015	3,39	3,21	3,5	3,3	3,35	Tepat Waktu
143	T31151 44	Laki-laki	27	Reguler Sore	2015	3,65	3,79	3,75	3,17	3,35	Tepat Waktu
145	T31151 46	Laki-laki	38	Reguler Sore	2015	3,61	4	3,92	3,48	3,35	Tepat Waktu
146	T31151 47	Laki-laki	29	Reguler Sore	2015	3,17	3,42	3,21	2,61	1,85	Tepat Waktu
147	T31151 48	Laki-laki	30	Reguler Sore	2015	3,65	4	3,67	3,78	3,61	Tepat Waktu
148	T31151 49	Laki-laki	32	Reguler Sore	2015	3,65	3,67	3,33	3,48	3,61	Tepat Waktu
149	T31151 50	Laki-laki	29	Reguler Sore	2015	2,91	2,58	2,83	3,05	2,47	Tepat Waktu
157	T31151 58	Laki-laki	27	Reguler Pagi	2015	3,91	3,79	3,29	3,48	3,35	Tepat Waktu
160	T31151 61	Laki-laki	28	Reguler Pagi	2015	3,3	3,33	2,96	3,55	3,22	Tepat Waktu
161	T31151 62	Laki-laki	31	Reguler Sore	2015	3,52	3,75	3,21	3,39	3,48	Tepat Waktu
162	T31151 63	Laki-laki	27	Reguler Pagi	2015	2,96	3,54	3,63	3,65	3,35	Tepat Waktu
166	T31151 67	Laki-laki	29	Reguler Pagi	2015	3,87	3,79	3,75	3,65	3,35	Tepat Waktu
169	T31151 70	Laki-laki	33	Reguler Sore	2015	3,78	4	3,71	3,3	3,35	Tepat Waktu
174	T31151 75	Laki-laki	31	Reguler Pagi	2015	3,57	3,75	3,67	3,22	3,22	Tepat Waktu
178	T31151 79	Laki-laki	27	Reguler Pagi	2015	3,09	3,42	2,7	3,06	3	Tepat Waktu
179	T31151 80	Laki-laki	27	Reguler Sore	2015	3,43	3,54	3,13	2,65	2,85	Tepat Waktu
181	T31151 82	Laki-laki	30	Reguler Sore	2015	3,22	3,67	3,25	2,91	1,89	Tepat Waktu

182	T31151 83	Laki-laki	28	Reguler Pagi	2015	3,04	3,21	2,79	2,88	1,85	Tepat Waktu
185	T31151 86	Laki-laki	34	Reguler Sore	2015	3,13	3,46	2,79	2,47	2,83	Tepat Waktu
190	T31151 91	Laki-laki	27	Reguler Pagi	2015	3,48	3,54	3,54	3,09	3,09	Tepat Waktu
194	T31151 95	Laki-laki	28	Reguler Sore	2015	3,48	3,67	3,13	3,57	3,48	Tepat Waktu
196	T31151 97	Laki-laki	27	Reguler Sore	2015	3,57	3,67	2,75	2,42	2	Tepat Waktu
197	T31151 99	Laki-laki	40	Reguler Sore	2015	3,52	3,67	3,63	3,35	3,35	Tepat Waktu
198	T31152 00	Laki-laki	29	Reguler Sore	2015	3,43	3,88	3,83	4	3,87	Tepat Waktu
201	T31152 03	Laki-laki	27	Reguler Pagi	2015	3,17	3,33	1,92	2,42	3,17	Tepat Waktu
203	T31152 05	Laki-laki	26	Reguler Pagi	2015	3,43	3,29	3	3,26	3,22	Tepat Waktu
204	T31152 06	Laki-laki	29	Reguler Pagi	2015	3,35	3,67	3,13	3,04	2,83	Tepat Waktu
211	T31152 13	Laki-laki	27	Reguler Pagi	2015	3	3,67	3,54	2,78	3,05	Tepat Waktu
216	T31152 18	Laki-laki	28	Reguler Sore	2015	3,43	3,08	3,1	3,39	3,35	Tepat Waktu
219	T31152 21	Laki-laki	28	Reguler Sore	2015	3,61	3,88	3,67	3,7	3,35	Tepat Waktu
222	T31152 24	Laki-laki	31	Reguler Sore	2015	3,3	3,67	3,71	3,52	3,35	Tepat Waktu
223	T31152 25	Laki-laki	28	Reguler Sore	2015	3,43	3,46	3,71	3,87	3,35	Tepat Waktu
225	T31152 27	Laki-laki	27	Reguler Pagi	2015	3,57	3,54	3	2,65	3,17	Tepat Waktu
227	T31152 29	Laki-laki	27	Reguler Pagi	2015	4	4	4	4	3,74	Tepat Waktu
229	T31152 31	Laki-laki	28	Reguler Pagi	2015	3,43	3,79	3,58	2,78	3,05	Tepat Waktu
231	T31152 33	Laki-laki	26	Reguler Pagi	2015	3,09	3,21	2,79	2,28	3	Tepat Waktu
233	T31152 35	Laki-laki	27	Reguler Pagi	2015	3,65	3,5	3	3	3,25	Tepat Waktu
237	T31152 39	Laki-laki	28	Reguler Pagi	2015	3,35	3,67	3,21	3	2,35	Tepat Waktu
238	T31152 40	Laki-laki	27	Reguler Pagi	2015	3,39	3,71	2,54	3,1	2,91	Tepat Waktu
240	T31152 42	Laki-laki	33	Reguler Sore	2015	3,22	3,67	3	2,96	3,45	Tepat Waktu

245	T31152 48	Laki-laki	28	Reguler Pagi	2015	4	4	3,88	4	3,61	Tepat Waktu
246	T31152 49	Laki-laki	33	Reguler Sore	2015	3,35	3,75	3,67	3,04	3,74	Tepat Waktu
247	T31152 50	Laki-laki	26	Reguler Pagi	2015	3,17	3,79	3,09	3,57	2,96	Tepat Waktu
250	T31152 53	Laki-laki	27	Reguler Pagi	2015	3,78	3,79	3,86	3,78	3,21	Tepat Waktu
267	T31152 70	Laki-laki	38	Reguler Sore	2015	3,87	3,92	3,5	3,3	3,48	Tepat Waktu
272	T31152 76	Laki-laki	27	Reguler Pagi	2015	3,43	3,42	3,46	3,57	3,35	Tepat Waktu
273	T31152 77	Laki-laki	28	Reguler Pagi	2015	3,61	3,75	3,88	3,65	3,39	Tepat Waktu
277	T31152 81	Laki-laki	27	Reguler Pagi	2015	3,65	2,67	3,55	2,83	3,25	Tepat Waktu
279	T31152 83	Laki-laki	36	Reguler Sore	2015	3,7	3,42	3,54	3,3	3,09	Tepat Waktu
281	T31152 85	Laki-laki	30	Reguler Pagi	2015	3,61	3,46	3,75	3,52	3,35	Tepat Waktu
284	T31152 88	Laki-laki	34	Reguler Sore	2015	3,91	4	3,67	3,78	3,09	Tepat Waktu
287	T31152 91	Laki-laki	34	Reguler Pagi	2015	3,74	3,79	3,63	3,09	3,13	Tepat Waktu
288	T31152 92	Laki-laki	29	Reguler Pagi	2015	3,39	3,21	3,21	2,17	3,12	Tepat Waktu
293	T31152 97	Laki-laki	31	Reguler Sore	2015	3,52	3,33	2,42	2,28	3	Tepat Waktu
298	T31153 02	Laki-laki	27	Reguler Sore	2015	3,43	3,17	2,45	2,65	2,65	Tepat Waktu
316	T31153 22	Laki-laki	29	Reguler Pagi	2015	3	3,08	2,76	2,89	3	Tepat Waktu
317	T31153 23	Laki-laki	28	Reguler Sore	2015	3,3	3,21	3,08	2,61	3,4	Tepat Waktu
324	T31153 32	Laki-laki	28	Reguler Sore	2015	4	3,92	3,79	3,7	3,74	Tepat Waktu
330	T31153 38	Laki-laki	28	Reguler Sore	2015	4	4	4	3,57	3,87	Tepat Waktu
333	T31153 41	Laki-laki	28	Reguler Sore	2015	3,22	3,08	3,21	3,13	3	Tepat Waktu
336	T31153 44	Laki-laki	27	Reguler Pagi	2015	3,3	3,88	3,33	3,13	3,35	Tepat Waktu
338	T31153 46	Laki-laki	26	Reguler Pagi	2015	3,48	3,71	2,92	2,8	2,95	Tepat Waktu
340	T31153 48	Laki-laki	29	Reguler Pagi	2015	3,43	4	3,29	3,35	3,61	Tepat Waktu

341	T31153 49	Laki-laki	28	Reguler Sore	2015	3,39	3,83	3,71	3,43	2,96	Tepat Waktu
345	T31153 53	Laki-laki	35	Reguler Sore	2015	0	3,78	3,83	2,83	3,55	Tepat Waktu
346	T31153 54	Laki-laki	28	Reguler Pagi	2015	3,43	3,42	2,79	2,9	2,95	Tepat Waktu
355	T31153 63	Laki-laki	27	Reguler Pagi	2015	3,87	3,88	3,29	3,04	3,35	Tepat Waktu
369	T31153 77	Laki-laki	30	Reguler Pagi	2015	3,65	4	3,67	3,74	3,87	Tepat Waktu
373	T31153 81	Laki-laki	41	Reguler Sore	2015	0	3,21	3,14	4	4	Tepat Waktu
374	T31153 82	Laki-laki	29	Reguler Pagi	2015	3,78	3,79	3,88	3	3,35	Tepat Waktu
375	T31153 83	Laki-laki	27	Reguler Pagi	2015	3,87	3,92	3,92	3,52	3,61	Tepat Waktu
386	T31153 94	Laki-laki	39	Reguler Sore	2015	3,09	3,54	3,63	3,87	3,35	Tepat Waktu
392	T31160 02	Laki-laki	26	Reguler Pagi	2016	2,96	3,76	3,71	3,54	3,52	Tepat Waktu
393	T31160 03	Laki-laki	26	Reguler Pagi	2016	3,78	3,79	3,92	3,04	3,22	Tepat Waktu
396	T31160 06	Laki-laki	25	Reguler Sore	2016	3,43	4	3,17	3	3,74	Tepat Waktu
403	T31160 13	Laki-laki	25	Reguler Sore	2016	3,22	3,04	3,04	3,33	3,26	Tepat Waktu
407	T31160 17	Laki-laki	25	Reguler Pagi	2016	3,65	3,67	3,33	3,67	3,74	Tepat Waktu
409	T31160 19	Laki-laki	27	Reguler Pagi	2016	3,52	3,29	1,42	3	2,75	Tepat Waktu
410	T31160 20	Laki-laki	27	Reguler Sore	2016	3,78	3,42	3,25	3,13	3	Tepat Waktu
411	T31160 21	Laki-laki	29	Reguler Pagi	2016	3,87	3,79	0,71	2,9	3,57	Tepat Waktu
412	T31160 22	Laki-laki	26	Reguler Pagi	2016	3,78	3,79	3	3,42	3,13	Tepat Waktu
414	T31160 24	Laki-laki	30	Reguler Pagi	2016	4	3,88	3,71	3,29	3	Tepat Waktu
415	T31160 25	Laki-laki	27	Reguler Sore	2016	3,87	2,92	3,3	3,58	3,48	Tepat Waktu
417	T31160 27	Laki-laki	25	Reguler Sore	2016	3,52	3,58	2,92	1,65	3	Tepat Waktu
419	T31160 29	Laki-laki	26	Reguler Sore	2016	3,78	3,88	3,67	3,54	3,61	Tepat Waktu
421	T31160 31	Laki-laki	26	Reguler Sore	2016	3,43	3,46	2,79	2,65	3,14	Tepat Waktu

422	T31160 32	Laki-laki	25	Reguler Sore	2016	2,52	1,88	3,36	2,79	4	Tepat Waktu
426	T31160 36	Laki-laki	26	Reguler Pagi	2016	3,78	3,88	3,92	3,63	3,48	Tepat Waktu
427	T31160 37	Laki-laki	26	Reguler Sore	2016	3,43	3,79	3,29	3,29	3,61	Tepat Waktu
432	T31160 42	Laki-laki	26	Reguler Sore	2016	3,65	3,71	3,67	3,58	3,52	Tepat Waktu
433	T31160 43	Laki-laki	27	Reguler Pagi	2016	3,78	3,54	3,63	3,58	3,22	Tepat Waktu
436	T31160 46	Laki-laki	25	Reguler Sore	2016	3,35	3,92	3,38	2,71	1,91	Tepat Waktu
438	T31160 48	Laki-laki	26	Reguler Sore	2016	2,83	3	3	2,83	2,83	Tepat Waktu
440	T31160 50	Laki-laki	30	Reguler Pagi	2016	3,48	3,42	2,75	3,55	3,13	Tepat Waktu
441	T31160 51	Laki-laki	26	Reguler Sore	2016	3,57	3,92	3,46	3,29	3,35	Tepat Waktu
442	T31160 52	Laki-laki	26	Reguler Sore	2016	3,87	4	3,79	3,42	3,74	Tepat Waktu
443	T31160 53	Laki-laki	25	Reguler Pagi	2016	3,52	3,54	3,54	3,46	3,39	Tepat Waktu
447	T31160 57	Laki-laki	25	Reguler Sore	2016	3,22	3,38	2,63	2,9	3	Tepat Waktu
448	T31160 58	Laki-laki	32	Reguler Sore	2016	3,87	3,08	3,25	3,21	3,26	Tepat Waktu
449	T31160 59	Laki-laki	28	Reguler Sore	2016	3,35	3,79	3,5	3,08	3	Tepat Waktu
451	T31160 61	Laki-laki	27	Reguler Pagi	2016	3,52	3,58	3,5	3,33	3,48	Tepat Waktu
452	T31160 62	Laki-laki	26	Reguler Sore	2016	3,48	3,67	3,42	3,46	3,61	Tepat Waktu
453	T31160 63	Laki-laki	26	Reguler Sore	2016	3,57	3,5	3,08	3	1,17	Tepat Waktu
457	T31160 67	Laki-laki	26	Reguler Sore	2016	3,52	3,88	3,88	3,71	3,65	Tepat Waktu
458	T31160 68	Laki-laki	27	Reguler Sore	2016	3,43	3,33	3,08	3,42	3,35	Tepat Waktu
461	T31160 71	Laki-laki	26	Reguler Sore	2016	3,57	3,92	3,5	3,42	3,61	Tepat Waktu
462	T31160 72	Laki-laki	27	Reguler Sore	2016	3,78	3,42	3,54	3,63	3,13	Tepat Waktu
464	T31160 74	Laki-laki	30	Reguler Sore	2016	3,65	3,71	3,46	3,08	3,13	Tepat Waktu
465	T31160 75	Laki-laki	25	Reguler Sore	2016	3,09	3,46	2,67	2,84	1,91	Tepat Waktu

467	T31160 77	Laki-laki	27	Reguler Sore	2016	3,57	3,38	3,38	3,38	3,52	Tepat Waktu
469	T31160 79	Laki-laki	26	Reguler Sore	2016	3,65	3,79	3,88	3,71	3,52	Tepat Waktu
473	T31160 83	Laki-laki	27	Reguler Sore	2016	3,48	3,79	3,58	3,5	3,48	Tepat Waktu
474	T31160 84	Laki-laki	26	Reguler Sore	2016	3,61	2,79	3,3	3,46	3,22	Tepat Waktu
476	T31160 86	Laki-laki	26	Reguler Sore	2016	3,57	3,79	3,79	3,33	3,61	Tepat Waktu
477	T31160 87	Laki-laki	26	Reguler Pagi	2016	3,65	3,67	3,5	3,38	3,48	Tepat Waktu
478	T31160 88	Laki-laki	25	Reguler Sore	2016	3,39	3,88	3,67	3,79	3,39	Tepat Waktu
479	T31160 89	Laki-laki	26	Reguler Sore	2016	3,65	3,79	3,67	3,5	3,65	Tepat Waktu
482	T31160 92	Laki-laki	26	Reguler Pagi	2016	3,65	3	3,58	3,75	3,29	Tepat Waktu
483	T31160 93	Laki-laki	26	Reguler Pagi	2016	3,39	3,21	2,73	2,95	2,43	Tepat Waktu
488	T31160 98	Laki-laki	46	Reguler Sore	2016	3,65	4	3,88	3,54	3,48	Tepat Waktu
491	T31161 01	Laki-laki	26	Reguler Sore	2016	3,43	4	3,54	3,54	3,74	Tepat Waktu
492	T31161 02	Laki-laki	27	Reguler Sore	2016	3,7	4	3,75	3,79	3,87	Tepat Waktu
493	T31161 03	Laki-laki	26	Reguler Sore	2016	3,3	2,96	3	3,21	3,13	Tepat Waktu
496	T31161 06	Laki-laki	26	Reguler Sore	2016	3,57	3,29	2,29	2,5	3,43	Tepat Waktu
497	T31161 07	Laki-laki	32	Reguler Sore	2016	3,57	4	3,79	3,42	3,87	Tepat Waktu
499	T31161 09	Laki-laki	34	Reguler Sore	2016	3,87	3,88	3,46	3,75	3,71	Tepat Waktu
503	T31161 13	Laki-laki	26	Reguler Sore	2016	3,22	3,58	3,33	3,17	2,22	Tepat Waktu
504	T31161 14	Laki-laki	26	Reguler Pagi	2016	3,39	3,75	2,75	3,11	3	Tepat Waktu
509	T31161 20	Laki-laki	26	Reguler Sore	2016	3,78	3,79	3,71	3	3,29	Tepat Waktu
512	T31161 23	Laki-laki	26	Reguler Pagi	2016	2,96	3,9	3,5	3,46	3,26	Tepat Waktu
513	T31161 24	Laki-laki	28	Reguler Pagi	2016	3,22	2,88	2,84	2,5	2,67	Tepat Waktu
519	T31161 30	Laki-laki	25	Reguler Pagi	2016	3,57	3,62	3,83	2,83	3,29	Tepat Waktu

520	T31161 31	Laki-laki	26	Reguler Sore	2016	3,78	3,67	3,71	3,33	3,61	Tepat Waktu
521	T31161 32	Laki-laki	27	Reguler Sore	2016	4	3,88	3,88	3,67	3,52	Tepat Waktu
528	T31161 39	Laki-laki	27	Reguler Sore	2016	3,22	3,75	3,33	3,42	3,48	Tepat Waktu
529	T31161 40	Laki-laki	26	Reguler Sore	2016	3,43	3,92	3,75	3,33	3,74	Tepat Waktu
536	T31161 47	Laki-laki	26	Reguler Sore	2016	3,65	3,79	3,33	2,96	3,57	Tepat Waktu
538	T31161 49	Laki-laki	27	Reguler Pagi	2016	3,57	3,29	3,38	3,54	3,35	Tepat Waktu
539	T31161 50	Laki-laki	27	Reguler Pagi	2016	3,39	3,67	3,46	3,13	3,13	Tepat Waktu
543	T31161 54	Laki-laki	28	Reguler Pagi	2016	3,78	3,67	3,79	3,5	3,22	Tepat Waktu
557	T31161 68	Laki-laki	31	Reguler Pagi	2016	3,04	3,29	3,58	3	3,26	Tepat Waktu
559	T31161 70	Laki-laki	26	Reguler Pagi	2016	3,39	3,63	3,21	2,21	3	Tepat Waktu
565	T31161 76	Laki-laki	26	Reguler Pagi	2016	3,26	2,88	2,85	2,9	3,43	Tepat Waktu
570	T31161 81	Laki-laki	28	Reguler Sore	2016	3,7	3,54	3,21	3,21	3,52	Tepat Waktu
574	T31161 85	Laki-laki	27	Reguler Pagi	2016	3,91	3,79	3,79	3,67	3,87	Tepat Waktu
575	T31161 86	Laki-laki	26	Reguler Pagi	2016	4	3,79	3,79	3,54	3,87	Tepat Waktu
577	T31161 88	Laki-laki	27	Reguler Sore	2016	3,7	3,5	3,58	2,75	2,71	Tepat Waktu
588	T31161 99	Laki-laki	26	Reguler Pagi	2016	3,26	2,58	2,7	2,85	2,86	Tepat Waktu
590	T31162 01	Laki-laki	27	Reguler Sore	2016	3,78	3,58	3,25	2,88	2,86	Tepat Waktu
592	T31162 03	Laki-laki	26	Reguler Sore	2016	3,87	3,79	3,71	3,75	3,87	Tepat Waktu
595	T31162 06	Laki-laki	29	Reguler Pagi	2016	3,91	3,46	3,08	3,33	2,7	Tepat Waktu
596	T31162 07	Laki-laki	27	Reguler Pagi	2016	3,83	3,79	3,79	3,46	4	Tepat Waktu
597	T31162 08	Laki-laki	32	Reguler Pagi	2016	3,65	3,46	3,46	3,38	3,39	Tepat Waktu
598	T31162 09	Laki-laki	28	Reguler Pagi	2016	3,87	3,79	3,67	3,21	3,13	Tepat Waktu
601	T31162 12	Laki-laki	31	Reguler Pagi	2016	3,43	3,54	3,25	3,21	2,52	Tepat Waktu

602	T31162 13	Laki-laki	26	Reguler Pagi	2016	3,7	3,54	3,25	3,21	2,78	Tepat Waktu
605	T31162 16	Laki-laki	27	Reguler Sore	2016	3,83	3,21	3,21	2,75	2,86	Tepat Waktu
608	T31162 19	Laki-laki	30	Reguler Sore	2016	3,91	3,79	3,79	3	2,78	Tepat Waktu
609	T31162 20	Laki-laki	31	Reguler Pagi	2016	4	3,17	3,54	3,22	3,26	Tepat Waktu
610	T31162 21	Laki-laki	33	Reguler Pagi	2016	4	3,58	3,33	3,21	2,91	Tepat Waktu
611	T31162 22	Laki-laki	42	Reguler Sore	2016	3,61	2,5	3,4	3,38	3,65	Tepat Waktu
612	T31162 23	Laki-laki	33	Reguler Sore	2016	3,74	3	3,42	3,63	3,71	Tepat Waktu
624	T31162 36	Laki-laki	27	Reguler Pagi	2016	3,52	2,67	2,5	2,8	3	Tepat Waktu
636	T31162 48	Laki-laki	27	Reguler Sore	2016	3,65	3,13	2,27	2,67	3,29	Tepat Waktu
641	T31162 53	Laki-laki	41	Reguler Sore	2016	3,65	3,42	3,67	3,63	3,86	Tepat Waktu
643	T31162 55	Laki-laki	26	Reguler Pagi	2016	3,65	3,88	3,63	3,75	3,71	Tepat Waktu
646	T31162 58	Laki-laki	25	Reguler Sore	2016	3,52	3,13	3,17	3,29	3,57	Tepat Waktu
647	T31162 59	Laki-laki	27	Reguler Sore	2016	3,78	3,79	4	4	4	Tepat Waktu
648	T31162 60	Laki-laki	26	Reguler Sore	2016	3,87	3,79	4	3,88	4	Tepat Waktu
655	T31162 67	Laki-laki	27	Reguler Sore	2016	2,7	2,71	3,39	3,29	3	Tepat Waktu
656	T31162 68	Laki-laki	27	Reguler Sore	2016	3,61	3,21	3,17	3,21	3,29	Tepat Waktu
663	T31162 75	Laki-laki	28	Reguler Sore	2016	3,52	3,21	3,5	4	3,71	Tepat Waktu
664	T31162 76	Laki-laki	26	Reguler Sore	2016	4	4	3,46	3,63	4	Tepat Waktu
665	T31162 77	Laki-laki	28	Reguler Sore	2016	3,17	3	2,79	3,15	3,14	Tepat Waktu
668	T31162 80	Laki-laki	28	Reguler Sore	2016	3,74	3,58	3,33	3,5	3,71	Tepat Waktu
670	T31162 82	Laki-laki	27	Reguler Pagi	2016	3,65	3	3,5	2,92	3	Tepat Waktu
673	T31162 85	Laki-laki	26	Reguler Pagi	2016	3,52	3,13	3,42	3	2,57	Tepat Waktu
679	T31162 91	Laki-laki	27	Reguler Sore	2016	3,3	2,88	2,85	3	3,39	Tepat Waktu

690	T31163 02	Laki- laki	26	Reguler Pagi	2016	3,52	3,08	3,04	2,83	3,43	Tepat Waktu
695	T31163 07	Laki- laki	29	Reguler Pagi	2016	3,35	3,75	3,92	3,79	3,91	Tepat Waktu
698	T31163 10	Laki- laki	27	Reguler Pagi	2016	3,65	3,67	4	3,67	4	Tepat Waktu
700	T31163 14	Laki- laki	26	Reguler Pagi	2016	3,74	3,88	3,54	3,25	3,87	Tepat Waktu
701	T31163 15	Laki- laki	28	Reguler Pagi	2016	3,74	3,63	3,79	3,67	3,74	Tepat Waktu
703	T31163 17	Laki- laki	28	Reguler Pagi	2016	3,87	3,88	3,71	3,67	2,57	Tepat Waktu
708	T31163 23	Laki- laki	26	Reguler Pagi	2016	3,78	3,63	3,42	3,67	3,48	Tepat Waktu
709	T31163 24	Laki- laki	27	Reguler Sore	2016	3,87	3,75	4	3,75	4	Tepat Waktu
710	T31163 25	Laki- laki	33	Reguler Sore	2016	3,74	3,54	3,5	3,5	3,61	Tepat Waktu
711	T31163 26	Laki- laki	28	Reguler Sore	2016	3,65	3,17	3,21	3,33	3,87	Tepat Waktu
712	T31163 27	Laki- laki	26	Reguler Sore	2016	3,65	3,75	3,79	3,75	3,87	Tepat Waktu
713	T31163 28	Laki- laki	27	Reguler Sore	2016	3,65	3,42	3,79	2,88	3,29	Tepat Waktu
718	T31163 35	Laki- laki	26	Reguler Sore	2016	3,65	3,54	3,08	3,25	3,48	Tepat Waktu
720	T31163 38	Laki- laki	30	Reguler Sore	2016	3,65	3,75	3,46	3,75	3,48	Tepat Waktu
722	T31163 40	Laki- laki	38	Reguler Sore	2016	3,48	3,21	2,13	3,67	3,13	Tepat Waktu
723	T31163 42	Laki- laki	29	Reguler Pagi	2016	2,7	3,1	2,8	3,33	2,6	Tepat Waktu
725	T31163 44	Laki- laki	27	Reguler Pagi	2016	3,65	3,63	3,71	3,46	3,35	Tepat Waktu
726	T31163 45	Laki- laki	28	Reguler Sore	2016	3,52	3,46	3,13	3,42	3,13	Tepat Waktu
730	T31163 49	Laki- laki	28	Reguler Sore	2016	3,26	2,79	2,71	2,84	2,76	Tepat Waktu
732	T31163 51	Laki- laki	28	Reguler Pagi	2016	3,74	3,25	3,88	3,75	3,86	Tepat Waktu
737	T31163 56	Laki- laki	31	Reguler Pagi	2016	3,87	3,79	3,75	3,54	3,86	Tepat Waktu
738	T31163 57	Laki- laki	29	Reguler Sore	2016	3,13	2,75	3,15	3,25	3,14	Tepat Waktu
740	T31163 59	Laki- laki	27	Reguler Sore	2016	3,74	3,75	4	3,54	3,61	Tepat Waktu

741	T31163 60	Laki- laki	18	Reguler Sore	2016	3,78	3,54	3,04	2,58	3,7	Tepat Waktu
743	T31163 63	Laki- laki	26	Reguler Sore	2016	3,74	3,88	4	3,75	4	Tepat Waktu
744	T31163 64	Laki- laki	28	Reguler Sore	2016	3,65	3,75	3	3,23	4	Tepat Waktu
749	T31163 70	Laki- laki	26	Reguler Sore	2016	3,52	3,21	3,42	3,17	3,14	Tepat Waktu
758	T31163 80	Laki- laki	32	Reguler Sore	2016	3,48	3,67	3,25	3	3,26	Tepat Waktu



**KEMENTERIAN PENDIDIKAN TINGGI, SAINS, DAN TEKNOLOGI  
UNIVERSITAS ICHSAN GORONTALO**

**FAKULTAS ILMU KOMPUTER**

SURAT KEPUTUSAN MENDIKNAS RI NOMOR 84/D/O/2001

Jl. Ahmad Nadjamuddin No. 17 Telp (0435) 829975 Fax (0435) 829976 Gorontalo

**SURAT KETERANGAN PENELITIAN**

Nomor :SKP/FIKOM-UIG/SKP/XII/2024

Yang bertanda tangan dibawah ini :

N a m a	:	Sudirman S. Panna, M.Kom
Jabatan	:	Ketua Program Studi Teknik Informatika

Dengan ini Menerangkan bahwa :

N a m a Mahasiswa	:	Sandi Kisman
N I M	:	T3119075
Program Studi	:	Teknik Informatika

Bahwa yang bersangkutan benar-benar telah melakukan penelitian tentang "**PERBANDINGAN ALGORITMA NAIVE BAYES DAN DECISION TREE DALAM KLASIFIKASI MAHASISWA TEPAT WAKTU**" Guna untuk meyelesaikan Studi pada Program Studi Teknik Informatika Fakultas Ilmu Komputer, dan bersangkutan telah menyelesaikan penelitian Tersebut pada **TGL 25 November 2024** sesuai dengan waktu yang telah di tentukan.

Demikian Surat Keterangan ini dibuat dan digunakan untuk seperlunya.

Gorontalo, 2 Desember 2024





KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET, DAN TEKNOLOGI  
**UNIVERSITAS IHSAN GORONTALO**  
**FAKULTAS ILMU KOMPUTER**  
**SURAT KEPUTUSAN MENDIKNAS RI NOMOR 84/D/O/2001**  
**Jl. Ahmad Najamuddin No. 17 Telp. (0435) 829975 Fax (0435) 829976 Gorontalo**

**SURAT REKOMENDASI BEBAS PLAGIASI**  
No. 517/FIKOM-UIG/R/XII/2024

Yang bertanda tangan di bawah ini :

Nama	:	Irvan Abraham Salihi, M.Kom
NIDN	:	0928028101
Jabatan	:	Dekan Fakultas Ilmu Komputer

Dengan ini menerangkan bahwa :

Nama Mahasiswa	:	Sandi Kisman
NIM	:	T3119075
Program Studi	:	Teknik Informatika (S1)
Fakultas	:	Fakultas Ilmu Komputer
Judul Skripsi	:	Perbandingan Algoritma Naive Bayes Dan Decision Tree Dalam Klasifikasi Mahasiswa Tepat Waktu

Sesuai hasil pengecekan tingkat kemiripan skripsi melalui aplikasi **Turnitin** untuk judul skripsi di atas diperoleh hasil *Similarity* sebesar **27%**, berdasarkan Peraturan Rektor No. 32 Tahun 2019 tentang Pendekripsi Plagiat pada Setiap Karya Ilmiah di Lingkungan Universitas Ihsan Gorontalo dan persyaratan pemberian surat rekomendasi verifikasi calon wisudawan dari LLDIKTI Wil. XVI, bahwa batas kemiripan skripsi maksimal 30%, untuk itu skripsi tersebut di atas dinyatakan **BEBAS PLAGIASI** dan layak untuk diujikan.

Demikian surat rekomendasi ini dibuat untuk digunakan sebagaimana mestinya.

  
Mengetahui  
Dekan,  
  
Irvan Abraham Salihi, M.Kom  
NIDN. 0928028101

Gorontalo, 04 Desember 2024  
Tim Verifikasi,  
  
  
Zulfrianto M. Lamasigi, M.Kom  
NIDN. 0914089101

Terlampir :  
Hasil Pengecekan Turnitin



KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET, DAN TEKNOLOGI  
**UNIVERSITAS ICHSAN GORONTALO**  
 FAKULTAS ILMU KOMPUTER  
 UPT. PERPUSTAKAAN FAKULTAS  
 SK. MENDIKNAS RI NO. 84/D/6/2001  
 Jl. Achmad Nadjamuddin No.17 Telp(0435) 829975 Fax. (0435) 829976 Gorontalo

**SURAT KETERANGAN BEBAS PUSTAKA**

No : 012/Perpustakaan-Fikom/XI/2024

Perpustakaan Fakultas Ilmu Komputer (FIKOM) Universitas Ichsan Gorontalo dengan ini menerangkan bahwa :

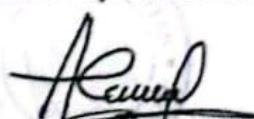
Nama Anggota : Sandi Kisman  
 No. Induk : T3119075  
 No. Anggota : M202477

Terhitung mulai hari, tanggal : Sabtu, 30 November 2024, dinyatakan telah bebas pinjam buku dan koleksi perpustakaan lainnya.

Demikian keterangan ini di buat untuk di pergunakan sebagaimana mestinya.

Gorontalo, 30 November 2024

Mengetahui,  
**Kepala Perpustakaan**

Apriyanto Alhamad, M.Kom

NIDN : 0924048601

## RIWAYAT HIDUP PENELITI



Nama : Sandi Kisman  
NIM : T3119075  
Tempat, Tgl Lahir : Ginunggung, 6 Maret 2001  
Pekerjaan : Mahasiswa  
Agama : Islam  
Jenis Kelamin : Laki Laki  
Fakultas/Jurusan : Ilmu Komputer/Teknik Informatika  
Konsentrasi : Software Engineering  
Email : [tutorialsandi02@gmail.com](mailto:tutorialsandi02@gmail.com)  
Alamat : Jl. Kalimantan

### Riwayat Pendidikan:

1. SD Negeri Ginunggung (2006 – 2012)
2. Madrasah Ginunggung (2012 – 2015)
3. SMA Negeri 1 Galang (2015 – 2018)
4. Universitas Ichsan Gorontalo (2019 – Sekarang)