

**PENERAPAN ALGORITMA *FEATURE IMPORTANCE*
UNTUK SELEKSI ATRIBUT PADA C4.5 DALAM
KLASIFIKASI WAKTU KELULUSAN
MAHASISWA
(Studi Kasus : Universitas Ichsan Gorontalo)**

**Oleh
ALAN LUAWO
T3119059**

SKRIPSI

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



**PROGRAM SARJANA
TEKNIK INFORMATIKA
UNIVERSITAS ICHSAN GORONTALO
GORONTALO
2023**

HALAMAN PERSETUJUAN SKRIPSI
PENERAPAN ALGORITMA *FEATURE IMPORTANCE*
UNTUK SELEKSI ATRIBUT PADA C4.5 DALAM
KLASIFIKASI WAKTU KELULUSAN
MAHASISWA
(Studi Kasus : Universitas Ichsan Gorontalo)

Oleh
ALAN LUAWO
T3119059

SKRIPSI

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

Telah disetujui dan siap diseminarkan
Gorontalo, November 2023

Pembimbing I



Irma Surva Kumala Idris, M.kom
NIDN.0921128801

Pembimbing II



Zulfrianto Y. Lamasigi, M.kom
NIDN.0914089101

PENGESAHAN SKRIPSI
PENERAPAN ALGORITMA *FEATURE IMPORTANCE*
UNTUK SELEKSI ATRIBUT PADA C4.5 DALAM
KLASIFIKASI WAKTU KELULUSAN
MAHASISWA
(Studi Kasus : Universitas Ichsan Gorontalo)

Oleh
ALAN LUAWO
T3119059

SKRIPSI

Di Periksa Oleh Panitia Ujian Strata Satu (SI)

Universitas Ichsan Gorontalo

1. Ketua Penguji
Amiruddin, M.Kom, MCF
2. Anggota
Hastuti Dalai, M.Kom
3. Anggota
Yusrianto Malago, M.kom
4. Anggota
Irma Surya Kumala Idris, M.Kom
5. Anggota
Zulfrianto Y. Lamasigi, M.kom

Mengetahui,



Dekan Fakultas Ilmu Komputer



Irvan A. Salihi, M.kom
NIDN.0928028101

Ketua Program Studi



Sudirman S. Panna, M.kom
NIDN.0924038205

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 tim pembimbing.
3. Dalam karya tulis (Skripsi) saya ini tidak terdapat karya atau pendapat yang telah di publikasikan orang lain, kecuali secara tertulis di cantumkan sebagai acuan/sitasi dalam naskah dan di cantumkan pula dalam daftar pustaka.
4. Pernyataan ini saya buat dengan sesungguhnya dan apabila dikemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka saya bersedia menerima sanksi akademik berupa pencabutan gelar yang telah di peroleh karena karya tulis ini, serta sanksi lainnya sesuai dengan norma-norma yang berlaku di Universitas Ichsan Gorontalo.

Gorontalo, November 2023
Yang membuat pernyataan



Alan Luawo

ABSTRACT

ALAN LUAWO, T3119059 PENERAPAN ALGORITMA FEATURE IMPORTANCE UNTUK SELEKSI ATRIBUT PADA C,45 DALAM KLASIFIKASI WAKTU KELULUSAN MAHASISWA.

In this study, the Feature Importance algorithm was applied to attribute selection on C4.5 in the classification of student graduation time. The data used was student data from the University of Gorontalo consisting of 6 attributes, namely IPS1, IPS2, IPS3, IPS4, GPA, and Graduation Status. The results showed that the Feature Importance algorithm was able to select 4 attributes that had an influence on the final classification results, namely IPS1, IPS2, IPS3, and IPS4. And 8 decision rules were obtained. The application of the Feature Importance algorithm also increased the classification accuracy by 11%. Where the accuracy rate before attribute selection and model optimization was obtained an accuracy of 78% after optimization and attribute selection increased to 89%.


Keywords: Feature Importance, C4.5, classification, student graduation time

ABSTRAK

ALAN LUAWO, T3119059 PENERAPAN ALGORITMA FEATURE IMPORTANCE UNTUK SELEKSI ATRIBUT PADA C,45 DALAM KLASIFIKASI WAKTU KELULUSAN MAHASISWA.

Dalam penelitian ini, dilakukan penerapan algoritma Feature Importance untuk seleksi atribut pada C4.5 dalam klasifikasi waktu kelulusan mahasiswa. Data yang digunakan adalah data mahasiswa dari Universitas Gorontalo yang terdiri dari 6 atribut, yaitu IPS1, IPS2, IPS3, IPS4, Kelas dan Status Kelulusan. Hasil penelitian menunjukkan bahwa algoritma Feature Importance mampu menyeleksi 4 atribut yang memiliki pengaruh terhadap hasil akhir klasifikasi, yaitu IPS1, IPS2, IPS3, dan IPS4. Serta didapatkan rule keputusan sebanyak 8 rule. Penerapan algoritma Feature Importance juga meningkatkan akurasi klasifikasi sebesar 11%. Dimana tingkat akurasi sebelum dilakukan seleksi atribut dan optimalisasi model didapatkan hasil akurasi 78% setelah dilakukan optimalisasi dan seleksi atribut meningkat menjadi 89%.

Kata kunci: Feature Importance, C4.5, klasifikasi, waktu kelulusan mahasiswa



KATA PENGANTAR

Alhamdulillah, penulis dapat menyelesaikan skripsi ini dengan judul **“Penerapan Algoritma *Feature Importance* Untuk Seleksi Atribut Pada C4.5 Dalam Klasifikasi Waktu Kelulusan Mahasiswa”**, untuk memenuhi salah satu syarat ujian guna untuk memperoleh gelar sarjana 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. Ibu Irma Surya Kumala Idris, M.Kom, selaku Pembimbing I yang telah banyak membimbing penulis selama ini;
8. Bapak Zulfrianto Y. Lamasigi, 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. Sahabat penulis yakni : Frengki, Ferdiansyah, Friska Miftaghul, Ali Fikri, yang telah memberikan dukungan dan motivasi kepada penulis;
13. Kepada semua pihak yang ikut membantu dan mendukung penulis dalam penyelesaian proposal 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 2023

Alan Luawo

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PERSETUJUAN SKRIPSI	ii
PENGESAHAN SKRIPSI.....	iii
PERNYATAAN SKRIPSI.....	iv
ABSTRACT	v
KATA PENGANTAR.....	vii
DAFTAR ISI.....	ix
DAFTAR TABEL	xii
DAFTAR GAMBAR.....	xiii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Identifikasi Masalah	4
1.3 Rumusan Masalah	4
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	4
1.5.1 Manfaat Teoritis	4
1.5.2 Manfaat Praktis.....	4
BAB II LANDASAN TEORI	5
2.1 Tinjauan Studi	5
2.2 Tinjauan Pustaka	8
2.2.1 Mahasiswa	8
2.2.2 Data Mining.....	8
2.2.3 Klasifikasi.....	10
2.2.4 Algoritma C4.5	11
2.2.5 Penerapan Algoritma C4.5	12
2.2.6 Feature Importance	17

2.2.7	Python.....	17
2.2.8	Confussion Matrix	18
2.2.9	Perangkat Lunak	19
2.2.10	Kerangka Pikir	20
BAB III METODE PENELITIAN		21
3.1	Jenis, Metode, Subjek, Objek, Waktu, dan Lokasi Penelitian	21
3.2	Pengumpulan Data	21
3.3	Pemodelan	23
3.3.1	Pra Pengolahan Data.....	23
3.3.2	Validasi Data	23
3.3.3	Pengembangan Model	24
3.3.4	Evaluasi Model	26
BAB IV HASIL PENELITIAN.....		27
4.1	Hasil Pengumpulan Data	27
4.2	Hasil Pemodelan.....	29
4.3	Hasil Pengembangan Model.....	32
4.3.1	Tahapan Seleksi Data	32
4.3.2	Tahapan Preprocessing.....	33
4.3.3	Tahapan Transformasi	35
4.3.4	Tahapan Data Mining	36
4.3.5	Tahapan Evaluasi.....	40
4.3.6	Tahapan Perbaikan Model	43
4.3.7	Tahapan Klasifikasi Data Testing Baru	50
BAB V PEMBAHASAN		53
5.1	Pembahasan Kinerja Model	53
5.2	Pembahasan Hasil Pemodelan.....	57
5.2.1	Hasil Pemodelan Sebelum Optimalisasi.....	57

5.2.2 Hasil Pemodelan Setelah Optimalisasi & Seleksi Atribut.....	57
BAB VI KESIMPULAN DAN SARAN.....	60
6.1 Kesimpulan.....	60
6.2 Saran.....	60
DAFTAR PUSTAKA.....	61
LAMPIRAN	

DAFTAR TABEL

Tabel 2.1 Penelitian Terkait	5
Tabel 2.2 Kelompok Dataset[14].	12
Tabel 2.3 Atribut Klasifikasi Potensi mahasiswa Drop Out[14]	13
Tabel 2.4 Hasil Perhitungan pada Dataset[14].	14
Tabel 2.5 Rule berdasarkan node akhir[14].	15
Tabel 2.6 Fungsi Perangkat Lunak Pendukung	19
Tabel 3.1 Variabel Data.....	22
Tabel 3.2 Data Alumni Mahasiswa Universitas Ichsan Gorontalo	22
Tabel 4. 1 Hasil Pengumpulan Data Set.....	27
Tabel 4. 2 DataSet Data Excel.....	28
Tabel 4. 3 Dataset Pemodelan	30
Tabel 4. 4 Data Tidak Konsisten	31
Tabel 4. 9 Dataset Training	37
Tabel 4. 10 Dataset Testing	38
Tabel 4. 11 Entropi untuk Setiap Atribut	39
Tabel 4. 12 Hasil Perhitungan Confussion Matriks 1.	42
Tabel 4. 13 Hasil akurasi pemodelan kedua 2	49
Tabel 5. 1 Hasil <i>Confussion Matrix</i> Sebelum Optimalisasi	53
Tabel 5. 2 Hasil Perhitungan <i>Confussion Matrix</i> Sesudah Optimalisasi.....	55
Tabel 5. 3 Rule Keputusan.	59

DAFTAR GAMBAR

Gambar 2.1 Proses Knowledge Discovery in Database (KDD)[11].	9
Gambar 2.2 Node Keputusan Terakhir[14].	14
Gambar 2.3 Kerangka Pikir	20
Gambar 3. 1 Sistem Yang di Usulkan	24
Gambar 4. 1 Grafik Jumlah Kelas Output	31
Gambar 4. 2 Grafik Jumlah Kelas Setelah Perbaikan	32
Gambar 4. 3 Hasil Pembacaan Dataset Dari File Excel	33
Gambar 4. 4 Data Tidak Konsisten	33
Gambar 4. 5 Hasil Perbaikan Kelas Yang Berbeda.	34
Gambar 4. 6 Hasil Perhitungan jumlah kategori pada Colom ‘Status’	35
Gambar 4. 7 Hasil Konversi Nilai String Ke Numerik.	36
Gambar 4. 8 Hasil Pembagian Data Training & Data Testing	37
Gambar 4. 9 Hasil Confusion Matrix	41
Gambar 4. 10 Hasil Pemodelan 1	43
Gambar 4. 11 Hasil Mengganti Kategori kelas Sesuai Kondisi	44
Gambar 4. 12 Hasil Mengganti Kategori kelas Sesuai Kondisi ke 2	44
Gambar 4. 13 Hasil Pengukuran Kedalaman Pohon	45
Gambar 4. 14 Grafik Presentase atribut.	46
Gambar 4. 15 Hasil Pembagian Data set	47
Gambar 4. 16 Hasil Confussion Matriks 2	49
Gambar 4. 17 Model Hasil Perbaikan Model	50
Gambar 4. 18 Hasil Klasifikasi Dengan Data Baru.	51
Gambar 4. 19 Hasil Konversi Data .xlsx ke .csv	51
Gambar 4. 20 Hasil Cetak Data Prediksi	51
Gambar 4. 21 Hasil Klasifikasi Dengan Data Baru.	52
Gambar 5. 1 Hasil <i>Confussion Matrix</i> Sebelum Optimalisasi.	53
Gambar 5. 2 Hasil <i>Confussion Matrix</i> Sesudah Optimalisasi & Seleksi Atribut	55
Gambar 5. 3 Visualisasi Pohon Keputusan Sebelum Optimalisasi.	57
Gambar 5. 4 Hasil Seleksi Atribut.	58

Gambar 5. 5 Pohon Setelah Optimalisasi & Seleksi *Feature Importance*. 58

BAB I

PENDAHULUAN

1.1 Latar Belakang

Waktu kelulusan mahasiswa merupakan salah satu indikator keberhasilan suatu institusi pendidikan. Mahasiswa yang lulus tepat waktu memiliki peluang yang lebih besar untuk mendapatkan pekerjaan yang sesuai dengan bidang studinya. Oleh karena itu, penting bagi perguruan tinggi untuk dapat memprediksi waktu kelulusan mahasiswa secara akurat.

Prediksi waktu kelulusan mahasiswa dapat dilakukan dengan menggunakan metode data mining, salah satunya adalah metode klasifikasi. Metode klasifikasi memprediksi kelas atau kategori dari suatu objek berdasarkan atribut-atribut yang dimilikinya. Dalam kasus prediksi waktu kelulusan mahasiswa, atribut-atribut yang dapat digunakan antara lain adalah nilai mata kuliah, IPK, lama studi, dan sebagainya.

Atribut-atribut yang digunakan dalam metode klasifikasi memiliki pengaruh yang berbeda-beda terhadap akurasi model. Atribut yang memiliki pengaruh yang lebih besar terhadap akurasi model disebut sebagai atribut penting. Pemilihan atribut yang tepat dapat meningkatkan akurasi model klasifikasi.

Metode adalah pendekatan atau prosedur sistematis yang digunakan untuk mencapai tujuan atau menyelesaikan suatu masalah. beberapa metode yang dapat digunakan pada proses klasifikasi seperti naive baiyes, K-nearest neighbors (KNN), Decision Trees C4.5, Random Forest, Support Vector Machine (SVM) untuk klasifikasi waktu kelulusan mahasiswa. Metode klasifikasi dalam pembelajaran mesin memiliki kelebihan dan kelemahan yang perlu dipertimbangkan sebelum memilih metode yang tepat untuk suatu tugas naive baiyes memiliki kelebihan pada kinerja yang baik pada data yang banyak fiturnya tapi memiliki kelemahan tidak mampu menangani interaksi fitur. K-nearest neighbors (KNN) memiliki kelebihan kinerja yang tinggi pada data yang besar dan memiliki kelemahan seperti tidak efisien untuk data berkategori tinggi. Decision Trees C4.5 memiliki kelebihan penanganan data non-linearity dan

mempunyai kekurangan pada pemilihan fitur yang tidak optimal. Support Vector Machine (SVM) mempunyai kelebihan mampu menangani data non-linearity dan memiliki kekurangan seperti sensitif terhadap noise.

Decision tree C4.5, dalam konteks klasifikasi, adalah algoritma pembelajaran mesin yang mengambil keputusan berdasarkan serangkaian aturan hierarkis. Model ini memecah data menjadi subset yang lebih kecil dan lebih mudah dikelola berdasarkan fitur-fitur tertentu. Setiap pembagian diwakili oleh node dalam pohon keputusan, dengan cabang-cabang yang mewakili kemungkinan hasil dari keputusan tersebut. Algoritma decision tree C4.5 memilih fitur terbaik pada setiap langkah berdasarkan kriteria tertentu, seperti Gini Index atau Entropy, untuk meminimalkan ketidak pastian dan memaksimalkan akurasi klasifikasi. Keunggulan utama decision tree adalah kemampuannya dalam menangani data yang kompleks dan non-linear dengan cara yang intuitif. Pohon keputusan yang dihasilkan oleh algoritma ini juga sangat mudah dipahami dan diinterpretasikan oleh manusia, memungkinkan para pengguna untuk mengidentifikasi pola dalam data dengan cepat.

Untuk kekurangan Metode *Decision Tree C4.5* tidak dapat menangani dengan baik data yang memiliki nilai yang hilang untuk suatu atribut. Jika data yang hilang signifikan, atribut tersebut mungkin tidak dievaluasi secara akurat. Meskipun algoritma C4.5 memiliki keterbatasan ini, ada teknik pengembangan seperti penggunaan algoritma pengganti yang lebih canggih (seperti Feature Importance) atau teknik preprocessing data yang lebih canggih (seperti feature engineering) yang dapat membantu mengatasi beberapa dari kendala ini. Sebagai alternatif, juga mungkin untuk menggunakan metode seleksi atribut khusus (seperti algoritma genetika atau pencarian grid) untuk menemukan kombinasi atribut yang optimal untuk tugas klasifikasi tertentu.

Metode *Feature Importance* adalah teknik analisis dalam pembelajaran mesin yang bertujuan untuk mengidentifikasi dan menilai kontribusi relatif dari setiap fitur atau variabel dalam model terhadap hasil prediksi. Tujuan utama dari metode ini adalah untuk memahami mana-mana fitur yang paling berpengaruh dalam membuat keputusan oleh model. Dengan menganalisis feature

importance, pengembang model dapat menentukan variabel-variabel yang memiliki dampak signifikan terhadap hasil prediksi, serta variabel-variabel yang mungkin tidak berpengaruh sama sekali.

Berdasarkan penelitian yang dilakukan oleh Eugenius Edsel Barito¹, Jap Tji Beng², Desi Arisandi³ dengan judul “Penerapan Algoritma C4.5 Untuk Klasifikasi Mahasiswa Penerima Bantuan Sosial *Covid-19*”, memperoleh nilai akurasi sebesar 89%, nilai *Precision* sebesar 90.16% dan *Recall* sebesar 83.27% dari jumlah data sebanyak 500 data yang di dapatkan dari hasil pembagian 80% data pelatihan dan 20% data uji[1]. Selanjutnya penelitian terkait yang dilakukan oleh Anik Andriani dengan judul “Penerapan Algoritma C4.5 Pada Program Klasifikasi Mahasiswa *Dropout*”, mendapatkan hasil evaluasi dan validasi dengan *confusion matrix* dengan tingkat akurasi sebesar 97,75%[2]. Serta penelitian yang dilakukan oleh Dimas Bayu Febriyanto¹, Lovi Handoko², Wahyuli³, Hanif Aisyah⁴ dan Rumini⁵ dengan topik penelitian adalah “Implementasi Algoritma C4.5 Untuk Klasifikasi Tingkat Kepuasan Pembeli Online Shop”, mendapatkan nilai keakuratan sebesar 91% dengan nilai presisi prediksi puas sebesar 66,67% dan nilai presisi pada prediksi tidak puas sebesar 33,3%[3].

Berdasarkan dengan hasil dari penelitian diatas, maka penggunaan algoritma feature importance pada C4.5 ini sangat cocok digunakan pada penelitian ini, Salah satu metode untuk memilih atribut penting adalah menggunakan algoritma feature importance. Algoritma feature importance menghitung nilai pentingnya setiap atribut terhadap kelas atau kategori yang diprediksi. Nilai pentingnya dapat dihitung dengan berbagai cara, salah satunya adalah menggunakan metode Information Gain. Adanya permasalahan diatas, maka peneliti sangat tertarik untuk mengangkat topik penelitian dengan judul **“Penerapan Algoritma Feature Importance Untuk Seleksi Atribut Pada C4.5 Dalam Klasifikasi Waktu Kelulusan Mahasiswa Tepat Waktu Di Universitas Ichsan Gorontalo”**.

1.2 Identifikasi Masalah

Bahwa algoritma *C4.5* tidak dapat menyeleksi atribut yang optimum terhadap hasil klasifikasi.

1.3 Rumusan Masalah

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

1. Bagaimana hasil penerepan algoritma *Feature Importance* dalam melakukan seleksi atribut klasifikasi waktu kelulusan mahasiswa tepat waktu yang optimum ?.
2. Seberapa meningkat akurasi metode *Decision Tree C4.5* apabila algoritma *feature importance* di terapkan dalam proses seleksi atribut klasifikasi?.

1.4 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah :

1. Menerapkan algoritma *Feature Importance* dalam seleksi atribut klasifikasi waktu kelulusan yang optimum.
2. Menerapkan algoritma *Feature Importance* pada *C4.5* dalam seleksi atribut klasifikasi kelulusan mahasiswa sehingga hasil klasifikasi lebih akurat.

1.5 Manfaat Penelitian

1.5.1 Manfaat Teoritis

Sebagai rekomendasi model klasifikasi waktu kelulusan mahasiswa tepat waktu yang bisa diterapkan dalam pembuatan aplikasi sistem informasi akademik kampus khususnya pada Universitas Ichsan Gorontalo.

1.5.2 Manfaat Praktis

Sebagai sumbansi dalam ilmu pengetahuan dan teknologi terkait algoritma *C4.5* dan *feature importance* yang terbaik dalam melakukan klasifikasi kelulusan mahasiswa tepat waktu.

BAB II LANDASAN TEORI

2.1 Tinjauan Studi

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

Tabel 2.1 Penelitian Terkait

No	PENELITI	JUDUL	TAHUN	METODE	HASIL
1.	Ardi Ramdani ¹ , Christian Dwi Sofyan ² , Fauzi Ramdani ³ , Muhamad Fauzi Arya Tama ⁴ , Muhammad Angga Rachmatsyah ⁵ [4].	Algoritma Klasifikasi Data Mining Untuk Memprediksi Masyarakat Dalam Menerima Bantuan Sosial[4].	2022	Menggunakan Algoritma C4.5[4].	Pada penelitian ini dilakukan klasifikasi terhadap mahasiswa penerima bantuan covid-19, dengan melakukan penerapan algoritma C4.5 dengan menggunakan data yang bersumber dari masyarakat kecamatan Binong, Kabupaten Subang mendapatkan hasil berupa nilai akurasi sebesar 100%, nilai presisi 100% dan nilai recall 100%[4].

No	PENELITI	JUDUL	TAHUN	METODE	HASIL
2.	Ibnu Ubaedi ¹ , Yan Mitha Djaksana ² [5].	Optimisasi Algoritma C4.5 Menggunakan Metode Forward Selection dan Stratified Sampling Untuk Prediksi Kelayakan Kredit[5].	2022	Menggunakan Algoritma C4.5 dan Metode Forward Feature Selections[5].	Dari hasil peneliti dengan menggunakan metode <i>forward selection</i> dan <i>stratified sampling</i> terbukti menghasilkan akurasi algoritma C4.5 sebesar 9,2% dalam memprediksi kelayakan kredit[5].
3.	Putu Gede Surya Cipta Nugraha ¹ , Gede Surya Mahendra ² [6].	Explorasi Algoritma C4.5 Dan Forward Feature Selection Untuk Menentukan Debitur Baik Dan Debitur Bermasalah Pada Produk Kredit Tanpa Agunan (KTA)[6].	2020	Menggunakan Algoritma C4.5 dan Metode Forward Feature Selection[6].	Dari hasil yang dilakukan oleh peneliti didapatkan hasil dalam hal ini algoritma C4.5 memanfaatkan fitur <i>selection</i> untuk pemilihan parameter data sehingga dapat membantu C4.5 meningkatkan <i>accuracy</i> sebesar 93.60%, <i>recall</i> 93.60%, Dan <i>precision</i> sebesar 93.60%. Dengan memperoleh parameter yang berpengaruh yaitu jangka waktu, maksimum kredit, Dan pekerjaan[6].

No	PENELITI	JUDUL	TAHUN	METODE	HASIL
4.	Muhamad Yunus ¹ , Hanandriya Ramadhan ² , Dimas Rizki Aji ³ , Agus Yulianto ⁴ [7].	Penerapan Metode Data Mining C4.5 Untuk Pemilihan Penerima Kartu Indonesia Pintar (KIP)[7].	2021	Menggunakan Algoritma C4.5[7].	Dari penelitian, peneliti mendapatkan hasil berupa nilai akurasi sebesar 90.24%, nilai presisi sebesar 85,71% dan nilai recall sebesar 96,88% yang didapatkan dari hasil uji data training dan data uji yang berjumlah sebanyak 102 data[7].
5.	Siti Badriah ¹ , Muhammad Fajar Estu Nugroho ² , Nurlana Sanjaya ³ , Imas Rismawati ⁴ , Betha Nurina Sari ⁵ , Chaerur Rozikin ⁶ [8].	Klasifikasi Algoritma C4.5 dalam Menentukan Penerima Bantuan Covid-19 (Studi Kasus: Desa di Karawang)[8].	2021	Menggunakan Algoritma C4.5[8].	Dari hasil yang dilakukan oleh peneliti didapatkan hasil rule dari algoritma C4.5 dengan nilai akurasi terbaik sebesar 79,54% dari perbandingan data training 90% dan data testing 10% Pohon keputusan yang didapat terdapat atribut yang sangat berpengaruh yaitu atribut jumlah anggota keluarga yang dapat dijadikan sebagai bahan acuan diterima[8].

2.2 Tinjauan Pustaka

2.2.1 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 (Depdiknas, 2012)[9].

Mahasiswa mempunyai peranan penting dalam mewujudkan cita-cita pembangunan nasional, sementara itu Perguruan Tinggi merupakan lembaga pendidikan yang secara formal disertai 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, (UU RI Nomor 12 tahun 2012)[9].

2.2.2 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 [10].

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 [10].



Gambar 2.1 Proses Knowledge Discovery in Database (KDD)[11].

1. Data Selection

Seleksi data adalah proses pemilihan subset dari dataset yang lebih besar atau pemilihan variabel tertentu dari dataset, berdasarkan kriteria tertentu, untuk analisis lebih lanjut. Tujuan dari seleksi data adalah untuk mengurangi kompleksitas, meningkatkan efisiensi, dan memperbaiki kualitas hasil analisis data. Dalam konteks data mining, seleksi data dilakukan untuk memilih variabel atau fitur yang paling relevan dan signifikan untuk membangun model yang akurat dan bermakna.

2. Pre – Processing / Cleaning

Pre-processing, atau pra-pemrosesan, adalah tahap awal dalam analisis data di mana data mentah diubah, diperbaiki, atau disiapkan agar sesuai untuk analisis lebih lanjut. Tujuan dari pre-processing adalah untuk meningkatkan kualitas data, mengurangi kekacauan (noise), mengatasi nilai yang hilang, menormalkan variabel, dan mempersiapkan data untuk model atau algoritma yang akan digunakan dalam proses analisis data.

3. Transformation

Transformasi data merujuk pada proses mengubah variabel atau data mentah menjadi bentuk atau format yang lebih sesuai untuk analisis atau pemodelan. Tujuan dari transformasi data adalah untuk meningkatkan interpretabilitas, mengurangi variabilitas, memenuhi asumsi statistik tertentu, atau membuat data cocok dengan persyaratan algoritma khusus.

4. Data Mining

Data mining adalah proses menemukan pola-pola tersembunyi atau pengetahuan yang berguna dari dataset yang besar atau kompleks. Tujuannya adalah untuk menggali wawasan berharga dari data yang tersembunyi di dalamnya. Dalam konteks bisnis, data mining digunakan untuk menganalisis perilaku pelanggan, mengoptimalkan proses bisnis, memprediksi tren pasar, dan membuat keputusan bisnis yang lebih cerdas.

5. Interpretation / Evaluation

Interpretasi melibatkan penguraian hasil analisis data mining sehingga pemangku kepentingan dapat memahami dan menggunakan wawasan yang ditemukan. Ini melibatkan mengartikan pola, hubungan, atau tren yang ditemukan dalam data. Evaluasi melibatkan penilaian kualitas dan kinerja model atau hasil analisis data mining. Ini melibatkan penggunaan metrik dan teknik evaluasi yang sesuai untuk mengukur sejauh mana model atau hasil analisis memenuhi tujuan bisnis yang telah ditetapkan.

2.2.3 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[12] :

1. Proses Training

Pada proses ini akan digunakan data training set atau data sampel yang telah diketahui label atau atribut dari data sampel tersebut untuk membangun model [12].

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 [12].

2.2.4 Algoritma C4.5

Algoritma C4.5 adalah salah satu algoritma induksi pohon keputusan yaitu ID3 (*Iterative Dichotomiser 3*). ID3 dikembangkan oleh J. Ross Quinlan. Dalam prosedur algoritma ID3, input berupa sampel *training*, label *training* dan atribut. Algoritma C4.5 merupakan pengembangan dari ID3. Beberapa pengembangan yang dilakukan pada C4.5 adalah sebagai antara lain bisa mengatasi missing value, bisa mengatasi continue data, dan pruning [13].

Ada beberapa tahapan dalam membuat sebuah pohon keputusan dalam algoritma C4.5 (Larose, 2005), yaitu:

1. Mempersiapkan data training. Data training biasanya diambil dari data histori yang pernah terjadi sebelumnya atau disebut data masa lalu dan sudah dikelompokkan dalam kelas-kelas tertentu [13].
2. Menghitung akar dari pohon. Akar akan diambil dari atribut yang akan terpilih, dengan cara menghitung nilai gain dari masing-masing atribut, nilai gain yang paling tinggi yang akan menjadi akar pertama. Sebelum menghitung nilai gain dari atribut, hitung dahulu nilai entropy. Untuk menghitung nilai entropy digunakan rumus [13]:

$$Entropy(S) = \sum_{i=1}^n -p_i \log_2(p_i) \dots\dots\dots (1)$$

Keterangan:

S = Himpunan kasus

n = Jumlah partisi S

p_i = Proporsi S_i terhadap S

3. Menghitung nilai Gain menggunakan Persamaan [13]:

$$Gain(S, A) = entropy(S) - \sum_{i=1}^n \frac{|S_i|}{|S|} Entropy(S_i) \dots\dots\dots (2)$$

Keterangan: S = Himpunan kasus

A = Fitur

n = Jumlah partisi atribut A

$|S_i|$ = Proporsi S_i terhadap S

$|S|$ = jumlah kasus dalam S

4. Ulangi langkah ke 2 dan langkah ke 3 hingga semua record terpartisi [13].
5. Proses partisi pohon keputusan akan berhenti saat [13]:
 - a. Semua record dalam simpul N mendapat kelas yang sama.
 - b. Tidak ada atribut di dalam record yang dipartisi lagi. Tidak ada record di dalam cabang yang kosong.

2.2.5 Penerapan Algoritma C4.5

Berikut merupakan penerapan algoritma C4.5 dari penelitian yang dilakukan oleh Asmaul Husnah Nasrullah dengan judul “Penerapan Metode C4.5 Untuk Klasifikasi Mahasiswa Berpotensi Drop Out”[14].

Pada penelitian ini data set yang digunakan adalah data mahasiswa FEKON UNISAN Gorontalo yang di peroleh dari BAAK UNISAN Gorontalo tahun akademik 2016/2017 [14].

1. Persiapan Data Set

Data set yang digunakan dalam penelitian ini di komposisikan sebagai berikut :

Tabel 2.2 Kelompok Dataset[14].

Kelas Target	Data yang digunakan			Jumlah Data
	Data Training 50%	Data Validasi 25%	Data Testing 25%	
Non DO	120	50	50	220
DO	100	50	50	200
Jumlah	220	100	100	420

Selanjutnya data disiapkan dengan melakukan seleksi dan transformasi data set. Seleksi data bertujuan untuk mengidentifikasi variable-variable relevan yang digunakan dalam penelitian ini. Dan transformasi data digunakan untuk mengubah data set sehingga konten informasi terbaik

diambil dan dimasukan pada tool mining yang di gunakan dalam format yang tepat.

Tahapan berikutnya yang digunakan pada penelitian ini yaitu mengikuti cara kerja metode C4.5 mulai dari training data, menghitung entropi hingga menghasilkan rule yang dijadikan sebagai pola untuk penentuan mahasiswa yang berpotensi Drop Out. Atribut yang digunakan dalam penelitian ini diambil berdasarkan referensi dari penelitian sebelumnya.

Tabel 2.3 Atribut Klasifikasi Potensi mahasiswa Drop Out[14] .

No	Atribut	Niali Atribut
1	Jenis Kelamin	Laki-laki perempuan
2	Umur	<20 Tahun 20 s/d 25 Tahun >25 tahun
3	Agama	Muslim Non Muslim
4	Asal Daerah	Dalam Kota Gorontalo luar kota Gorontalo Luar Provinsi
5	Kelas	Kela Reguler kelas Karyawan
6	Nilai IPS Semester I	<2,75 2,75 - 3,00 >3,00
7	Nilai IPS Semester II	<2,75 2,75 - 3,00 >3,00
8	Nilai IPS Semester III	<2,75 2,75 - 3,00 >3,00
9	Nilai IPS Semester IV	<2,75 2,75 - 3,00 >3,00

Ket: Nilai IPS (Nilai mata pelajaran Ilmu Pengetahuan Sosial) Sembilan(9) atribut tersebut kemudian diolah menggunakan algoritma C4.5 berdasarkan dataset yang telah di seleksi.

2. Penentuan Akar (Node)

Akar akan diambil dari atribut yang terpilih, dengan cara menghitung nilai gain dari masing-masing atribut, nilai gain yang paling tinggi yang akan menjadi akar pertama. Sebelum menghitung nilai gain dari atribut, hitung dahulu nilai entropy. Nilai entropy yang diperoleh berdasarkan persamaan(1) adalah sebagai berikut :


$$Entropi(S) = \left(-\left(\frac{41}{98}\right) \times \log_2 \left(\frac{41}{98}\right) \right) + \left(-\left(\frac{57}{98}\right) \times \log_2 \left(\frac{57}{98}\right) \right) = 0.9806857 \dots\dots (3)$$

Tabel 2.4 Hasil Perhitungan pada Dataset[14].

Total Kasus	Sum(DO)	Sum (TIDAK DO)	Entropi Total
98	41	57	0.9806857

Setelah nilai entropi didapatkan dari keseluruhan kasus, dilakukan analisis pada setiap atribut dan nilai-nilainya, Hasil perhitungan nilai entropi setiap atribut dapat dilihat pada (lampiran b), Nilai Gain berdasarkan persamaan (2) dihitung untuk setiap atribut yang digunakan (lampiran b).

Selanjutnya dibuat pohon keputusan berdasarkan node yang telah di tentukan, hingga menghasilkan node keputusan terakhir seperti dibawah ini;



Gambar 2.2 Node Keputusan Terakhir[14].

Pada node keputusan terakhir dapat dilihat bahwa atribut agama tidak lagi dijadikan lagi sebagai Node sebab nilai gain yang diperoleh untuk atribut agama pada perhitungan gain atribut agama sebesar -4.53.

<< 200 dari dataset

<< 98 data yang telah di cleaning

3. Klasifikasi (Rules)

Selanjutnya hasil dari pohon keputusan tersebut di ekstrasi menjadi rule seperti pada tabel di bawah ini :

Tabel 2.5 Rule berdasarkan node akhir[14].

No	Rule
1	JIKA Nilai IPS IV = 2.75 – 3.00 DAN Nilai IPS I = 2.75 – 3.00 MAKA Klasifikasi = TIDAK DO
2	JIKA NILAI IPS IV = 2.75 – 3.00 DAN Nilai IPS I = <2.75 MAKA Klasifikasi = DO
3	JIKA Nilai IPS IV = 2.75 – 3.00 DAN Nilai IPS I = >3.00 MAKA Klasifikasi = TIDAK DO
4	JIKA NILAI IPS IV = <2.75 – 3.00 DAN Nilai IPS II = 2.75 – 3.00 MAKA Klasifikasi = DO
5	JIKA NILAI IPS IV = <2.75 DAN Nilai IPS II = <2.75 MAKA Klasifikasi = DO
6	JIKA NILAI IPS IV = >3.00 DAN Asal Daerah = Luar Provinsi MAKA Klasifikasi = TIDAK DO
7	JIKA NILAI IPS IV = <2.75 DAN Nilai IPS II = >3.00 DAN Asal Daerah Luar Provinsi MAKA Klasifikasi = DO
8	JIKA NILAI IPS IV = >3.00 DAN Asal Daerah = >3.00 DAN Asal Daerah Dalam Kota Gorontalo dan Nilai IPS III = <2.75 MAKA Klasifikasi = TIDAK DO

9	JIKA NILAI IPS IV = >3.00 DAN Asal Daerah = >3.00 DAN Asal Daerah Dalam Kota Gorontalo dan Nilai IPS III = >3.00 MAKA Klasifikasi = TIDAK DO
10	JIKA NILAI IPS IV = >3.00 DAN Asal Daerah = Luar Kota Gorontalo DAN Jenis Kelamin = Laki-Laki MAKA Klasifikasi = TIDAK DO
11	JIKA NILAI IPS IV = >3.00 DAN Asal Daerah = Luar Kota Gorontalo DAN Jenis Kelamin = Perempuan MAKA Klasifikasi = DO
12	JIKA NILAI IPS IV = <2.75 DAN Nilai IPS II = >3.00 DAN Asal Daerah = Dalam Kota Gorontalo DAN Jenis Kelamin = Laki-Laki MAKA Klasifikasi = TIDAK DO
13	JIKA NILAI IPS IV = <2.75 DAN Nilai IPS II = >3.00 DAN Asal Daerah = Dalam Kota Gorontalo DAN Jenis Kelamin = Perempuan MAKA Klasifikasi = DO
14	JIKA NILAI IPS IV = <2.75 DAN Nilai IPS II = >3.00 DAN Asal Daerah = Luar Kota Gorontalo DAN Jenis Kelamin = Laki-Laki MAKA Klasifikasi = DO
15	JIKA NILAI IPS IV = <2.75 DAN Nilai IPS II = >3.00 DAN Asal Daerah = Luar Kota Gorontalo DAN Jenis Kelamin = Perempuan MAKA Klasifikasi = TIDAK DO
16	JIKA NILAI IPS IV = >3,00 DAN Asal Daerah = Dalam Kota Gorontalo DAN Nilai IPS III = 2.75 – 3.00 DAN kelas = Karyawan MAKA Klasifikasi = TIDAK DO
17	JIKA NILAI IPS IV = >3,00 DAN Asal Daerah = Dalam Kota Gorontalo DAN Nilai IPS III = 2.75 – 3.00 DAN kelas = Reguler MAKA Klasifikasi = DO

Tujuh belas rule tersebut merupakan 17 kelas yang di hasilkan dalam mengelompokan mahasiswa yang berpotensi Drop Out, Selajutnya Ke 17 rule tersebut dapat di jadikan sebagai kelas/kelompok dalam menentukan

mahasiswa yang berpotensi drop out sebelum di terima menjadi mahasiswa di fakultas ekonomi UNISAN Gorontalo. Akurasi dan tingkat error tidak dihitung di karenakan hasil klasifikasi mahasiswa yang drop out dan tidak drop out.

4. Kesimpulan

Kesimpulan yang diperoleh dari penelitian tersebut yang dilakukan adalah :

1. Metode algoritma C4,5 yang telah digunakan dalam klasifikasi mahasiswa yang berpotensi drop out menghasilkan 17 rule,
2. Dari tujuh belas rule tersebut dapat dijadikan pola dalam menentukan mahasiswa yang berpotensi mengalami drop out.

2.2.6 Feature Importance

Metode Feature Importance adalah suatu nilai mutlak dari pentingnya kesalahan prediksi peningkatan suatu model dan untuk mengubah nilai tidak penting nilai-nilai relative yang ada, dan untuk itu kita gunakan metode ini untuk menentukan fitur yang paling relevan untuk suatu tugas. Metode ini juga dapat menggunakan impor fitur untuk seleksi fitur dengan menghapus fitur yang tidak penting[15].

2.2.7 Python

Python merupakan bahasa pemrograman tingkat tinggi yang dibuat oleh Guido Van Rossum dan dirilis pada tahun 1991 *Python* juga merupakan bahasa yang sangat populer belakangan ini. Selain itu python juga merupakan bahasa pemrograman yang multi fungsi contohnya python dapat digunakan untuk *Machine Learning* dan *Deep Learning*. Python dipilih sebagai penelitian karena python memiliki penulisan sintaksis yang mudah selain itu python juga memiliki library yang lengkap dan memiliki dukungan komunitas yang kuat karena python bersifat open source. Untuk menuliskan source code python anda dapat menggunakan IDE seperti vs code, sublime text, PyCharm atau anda juga dapat menggunakan IDE online seperti *Jupyter notebook* dan *google colab* [16].

2.2.8 Confussion 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 [17].

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

1. Accuracy

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \dots\dots\dots(Persaman 1)$$

2. Precision

$$Precision = \frac{TP}{TP+FP} \times 100\% \dots\dots\dots(Persamaan 2)$$

3. Recall

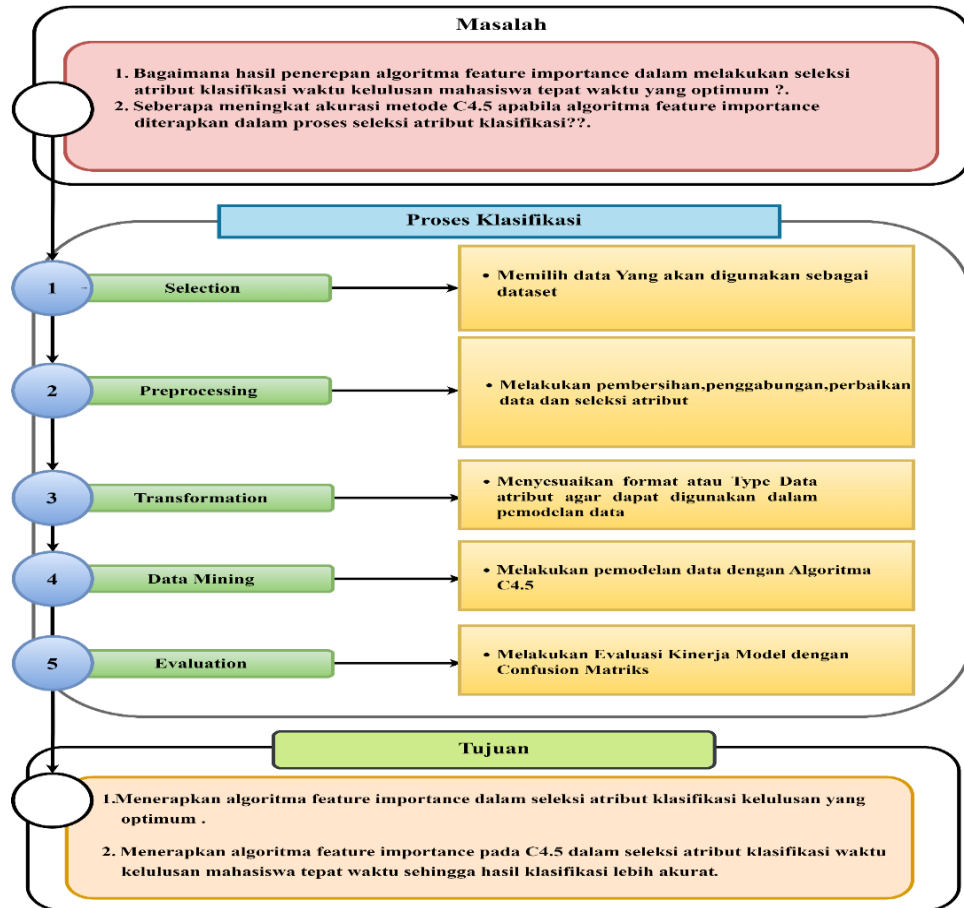
$$Precision = \frac{TP}{TP+FN} \times 100\% \dots\dots\dots(Persamaan 3)$$

2.2.9 Perangkat Lunak

Tabel 2.6 Fungsi Perangkat Lunak Pendukung

No.	Perangkat Lunak Pendukung	Fungsi
1	Python	Python adalah bahasa pemrograman tingkat tinggi yang sering digunakan untuk pengembangan perangkat lunak, analisis data, kecerdasan buatan, pengembangan web, dan banyak keperluan lainnya[16] .
2	Google Collabs	Google Collabs adalah layanan gratis yang memungkinkan pengguna menjalankan kode Python di Internet tanpa harus menginstal apa pun. Itu sangat berguna untuk menulis dan berbagi kode, terutama dalam proyek data science dan machine learning.

2.2.10 Kerangka Pikir



Gambar 2.3 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 Universitas Ichsan Gorontalo. sedangkan topik penelitian ini adalah Peneraparan Algoritma *Feature Importance* pada *C4.5* dalam klasifikasi predikat kelulusan mahasiswa tepat waktu di Universitas Ichsan Gorontalo yang beralamatkan di jl. Drs. Achmad Nadjamuddin, Limba U Dua, Kota Selatan Kota Gorontalo dari bulan Juli sampai Oktober 2023.

3.2 Pengumpulan Data

Untuk mendapatkan data mahasiswa, peneliti datang langsung ke pihak Baak unisan gorontalo untuk meminta data berupa data mahasiswa alumni , data yang di dapatkan adalah berupa data alumni mahasiswa Universitas Ichsan Gorontalo angkatan tahun 2016 sampai dengan tahun 2017 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	JK	Tuple	Variabel Input
2	IPS 1	Float	Variabel Input
3	IPS 2	Float	Variabel Input
4	IPS 3	Float	Variabel Input
5	IPS 4	Float	Variabel Input
6	kelas	Varchar	Variabel Input
7	Status Kelulusan	Varchar	Output

Tabel 3.2 Data Alumni Mahasiswa Universitas Ichsan Gorontalo

No	Jenis Kelamin	kelas	IPS1	IPS2	IPS3	IPS4	Status
1	L	R	3,48	3,26	2,7	3	Tidak tepat waktu
2	P	R	3,76	3,58	3,74	3,33	Tidak tepat waktu
3	L	N	3,38	2,95	3,6	3,42	Tepat waktu
4	P	N	3,67	3,11	3,8	3,58	Tidak tepat waktu
5	P	R	3,67	3,58	3,91	3,42	Tepat waktu
6	L	R	3,05	3,21	3	3	Tepat waktu
7	L	R	3,24	3,11	3	2,78	Tepat waktu
...	...		...	...	...	...	...
1692	L	N	3,81	3,79	3,17	3,92	Tidak tepat waktu

3.3 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, 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.

3.3.3 Pengembangan Model



Gambar 3. 1 Sistem Yang di Usulkan

1. Dataset Alumni : Tahap pertama adalah mengumpulkan data alumni mahasiswa yang akan digunakan untuk melatih dan menguji model klasifikasi. Data ini harus mencakup atribut atau fitur yang relevan serta label kelas atau kategori yang sesuai untuk setiap objek atau sampel data. Evaluasi Model.
2. Pra – Processing : Mengubah format atau skala data agar sesuai dengan kebutuhan analisis atau model. Contoh transformasi meliputi normalisasi (mengubah nilai data ke dalam rentang tertentu), diskritisasi (mengubah data kontinu menjadi data kategori), dan transformasi logaritmik.
3. Seleksi Fitur (Feature Importance) : Seleksi fitur (Feature Importance) dalam konteks klasifikasi waktu kelulusan (time to graduation) adalah proses seleksi atribut atau fitur yang paling penting dan relevan.

Memilih fitur yang tepat adalah kunci untuk menghasilkan model klasifikasi waktu kelulusan yang akurat.

4. Split : Dalam algoritma pohon keputusan seperti C4.5, split dilakukan dengan memilih atribut yang paling informatif. Atribut ini kemudian digunakan untuk memisahkan data ke dalam subset-subset yang lebih kecil. Proses ini dilakukan secara rekursif pada setiap subset, membangun pohon keputusan yang lebih dalam dengan setiap langkah.
5. Training : Proses pelatihan ini melibatkan menyajikan data pelatihan ke dalam algoritma C4.5 sehingga model dapat menyesuaikan parameter dan variabel internalnya sesuai dengan data tersebut. Tujuannya adalah untuk membuat model yang dapat melakukan prediksi dengan tingkat akurasi yang tinggi pada data baru yang belum pernah dilihat sebelumnya.
6. Testing : Proses pengujian melibatkan menggunakan data pengujian (testing data) yang terpisah dari data pelatihan. Data ini memiliki atribut yang serupa dengan data pelatihan, tetapi label atau nilai targetnya biasanya disembunyikan selama proses pelatihan. Setelah model dilatih, ia kemudian diuji menggunakan data pengujian untuk melihat sejauh mana model mampu memprediksi nilai target dengan akurat.
7. Algoritma C4.5 : Dengan kemampuannya memahami dan menggali pola-pola dalam data pelatihan, C4.5 memungkinkan pembangunan model prediktif yang cerdas untuk mengklasifikasi waktu kelulusan mahasiswa. Dengan mempertimbangkan atribut-atribut kunci seperti jenis kelamin, IPS 1, IPS 2, IPS 3, IPS 4, dan keterangan status kelulusan, algoritma C4.5 membangun pohon keputusan yang menyusun langkah-langkah klasifikasi dengan akurat.
8. Pengujian Model : Proses pengujian model melibatkan menggunakan data pengujian (testing data) yang biasanya terpisah dari data pelatihan. Data ini memiliki atribut yang serupa dengan data pelatihan, tetapi label atau nilai targetnya biasanya disembunyikan selama proses pelatihan.

Setelah model dilatih, ia kemudian diuji menggunakan data pengujian untuk melihat sejauh mana model mampu memprediksi nilai target dengan akurat.

9. Evaluasi Kinerja Model (Confusion Matrix) : Evaluasi kinerja model melibatkan sejumlah metrik untuk mengukur sejauh mana model C4.5 mampu membuat prediksi yang akurat. Salah satu alat evaluasi yang paling umum digunakan adalah Confusion Matrix (Matriks Confusion). Confusion matrix adalah tabel yang digunakan untuk mengevaluasi kinerja suatu model klasifikasi, membandingkan prediksi model dengan nilai sebenarnya dari data uji.

3.3.4 Evaluasi Model

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

BAB IV

HASIL PENELITIAN

4.1 Hasil Pengumpulan Data

Dataset atau data penelitian yang digunakan pada penelitian ini adalah merupakan data private yang diambil dari BAAK Universitas Ichsan Gorontalo terkait data alumni mahasiswa angkatan tahun 2016 & 2017. Adapun dataset yang dikumpulkan dapat dilihat pada tabel 4.1 berikut ini :

Tabel 4. 1 Hasil Pengumpulan Data Set

NO	Tahun	Program Studi	Jumlah Mahasiswa
1	2016 s.d 2017	S1 Agribisnis	87
2	2016 s.d 2017	S1 Agroteknologi	96
3	2016 s.d 2017	S1 Akuntansi	190
4	2016 s.d 2017	S1 Ilmu Hukum	335
5	2016 s.d 2017	S1 Ilmu Komunikasi	47
6	2016 s.d 2017	S1 Ilmu Pemerintahan	223
7	2016 s.d 2017	S1 Manajemen	206
8	2016 s.d 2017	S1 Teknik Arsitektur	48
9	2016 s.d 2017	S1 Teknik Elektro	29
10	2016 s.d 2017	S1 Teknik Informatika	396
11	2016 s.d 2017	S1 Teknologi Hasil Pangan	35
Total			1692

Adapun berikut merupakan data yang telah di olah dan diatur untuk digunakan pada penelitian ini yang dimana nantinya data mahasiswa ini akan di olah di dalam python yang dimuat dalam Tabel 4.2 dibawah ini :

Tabel 4. 2 DataSet Data Excel

No	NIM	Nama	Kelamin	Prodi
1	E1116005	NITRA DZAKARIA	P	S1 INFORMATIKA
2	E1116006	SRI WAHYUNI LATABILA	P	S1 INFORMATIKA
3	E1116007	DIAN SP WARTABONE	P	S1 INFORMATIKA
4	E1116009	TOMY A. LAIDINGO	L	S1 INFORMATIKA
5	E1116010	RAMDAN HIDAYAT YUNUS	L	S1 INFORMATIKA
6	E1116011	JULIANTI M. DATU	P	S1 INFORMATIKA
7	E1116013	LAILA NINGSI SULEMAN	L	S1 INFORMATIKA
8	E1116014	NUR AINUN SUAIB	P	S1 INFORMATIKA
9	E1116016	NURNANINGSIH PARAMANI	P	S1 INFORMATIKA
10	E1116017	RIFKI RINALDI ONGI	L	S1 INFORMATIKA
11	E1116018	RENALDI LIMBERD	L	S1 INFORMATIKA
12	E1116019	RIZKA NOVIA KHAN	P	S1 INFORMATIKA
13	E1116021	ASNAWATI A. D. UNINI	P	S1 INFORMATIKA
14	E1116023	NIRVAN YAHYA	L	S1 INFORMATIKA
15	E1116024	MIRANTI MUHARAM	P	S1 INFORMATIKA
16	E1116027	MUCHTAR GUSASI	L	S1 INFORMATIKA
17	E1116030	IDHAM YAKUP A SAMUDA	L	S1 INFORMATIKA
18	E1116032	TIYA RESTY ABDULLAH	P	S1 INFORMATIKA
19	E1116033	ISMAWATI	P	S1 INFORMATIKA
20	E1116034	NURISMA KURNIATI MATANI	P	S1 INFORMATIKA
...	...	...	...	...
1692	E1116044	AGUNG ANDARESTA	L	S1 INFORMATIKA

No	Status	IPS1	IPS2	IPS3	IPS4	IPS5	IPS6	IPS7	IPS8	IPS9
1	LULUS	3.6	3.5	3.3	3.5	3.2	3.2	3.6	4	
2	LULUS	3.3	3.3	2.1	2.3	2.6	3.3	2.6	3	4
3	LULUS	4	4	3.7	3.8	3.8	3.7	4	4	
4	LULUS	3.7	3.5	3.4	3.5	3.5	3.5	4	4	
5	LULUS	3.4	2.5	2.0	3.1	3	3.4	3.3	3.2	4
6	LULUS	3.3	2.6	2.8	3.5	3.1	3.3	3.7	1.3	4
7	LULUS	3.5	3.7	3.2	3.3	3.5	3.7	4	4	
8	LULUS	3.6	3.8	3.3	3.5	3.3	3.7	4	4	
9	LULUS	3.5	3.4	3.2	3.5	3	2.8	4	4	
10	LULUS	4	4	4	4	3.8	3.5	4	4	
11	LULUS	3.8	4	3.8	4	3.8	4	4	4	
12	LULUS	3.8	3.2	3.5	3.3	2.7	3.4	1.3	4	
13	LULUS	3.8	3.2	3.3	3.6	3.1	3.4	4	1.3	4
14	LULUS	3.7	3.7	3.4	3.5	4	3.8	4	4	
15	LULUS	3.6	3.5	3.3	3.4	3.1	3.2	3.7	4	
16	LULUS	3.7	3.7	2.7	3.1	2.8	2.7	1.3	4	
17	LULUS	3.6	3.5	3.0	2.8	3.2	3.4	4	4	
18	LULUS	3.6	3.7	3.4	3.1	3	3.3	3.7	1.3	4
19	LULUS	3.7	3.5	3.1	3.5	3.6	3.8	4	4	
20	LULUS	3.8	3.6	3.3	3.4	3.3	3.7	3.7	4	
...	...	...	...	...	...	...	...	...	...	...
1692	LULUS	3.5	3.6	3.3	3.4	3.5	2.8	0.4	0	4

4.2 Hasil Pemodelan


Berdasarkan dataset pada tabel 4.2 di atas dilakukan beberapa pengolahan data sebelum diterapkan pada model *Decision Tree C4.5* diantaranya dilakukan tahapan pengolahan data.

Hasil pengumpulan dataset pada Tabel 4.2 di atas terdapat atribut NIM, NAMA, PRODI, JK, KELAS, IPS1 sampai dengan IPS9, Dan Status, terdapat beberapa atribut yang diperlukan dalam pemodelan, sehingga perlu dilakukan pemilihan atribut target yang sesuai dengan model yang akan digunakan. Adapaun hasil pemilihan atribut target yang digunakan dapat dilihat pada tabel 4.3 berikut :

Tabel 4. 3 Dataset Pemodelan

No	JK	Kelas	IPS1	IPS2	IPS3	IPS4	Status
1	P	R	3.64	3.64	3.58	3.36	Tidak Tepat
2	P	R	3.36	3.36	3.37	2.18	Tidak Tepat
3	P	R	4	4	4	3.73	Tepat Waktu
4	L	R	3.73	3.73	3.58	3.45	Tidak Tepat
5	L	R	3.4	3.4	2.53	2.05	Tidak Tepat
6	P	N	3.36	3.36	2.63	2.83	Tidak Tepat
7	L	R	3.59	3.59	3.79	3.23	Tidak Tepat
8	P	R	3.64	3.64	3.89	3.32	Tidak Tepat
9	P	N	3.5	3.5	3.47	3.23	Tidak Tepat
10	L	N	4	4	4	4	Tepat Waktu
11	L	N	3.86	3.86	4	3.86	Tepat Waktu
12	P	N	3.86	3.86	3.26	3.5	Tepat Waktu
13	P	N	3.86	3.86	3.26	3.32	Tidak Tepat
14	L	R	3.73	3.73	3.79	3.45	Tepat Waktu
15	P	N	3.64	3.64	3.58	3.36	Tepat Waktu
16	L	N	3.77	3.77	3.74	2.77	Tidak Tepat
17	L	R	3.64	3.64	3.58	3.05	Tepat Waktu
18	P	N	3.64	3.64	3.74	3.45	Tidak Tepat
....							
1607	L	N	3.6	3.88	3.88	3.71	Tepat Waktu

Berdasarkan tabel 4.3 di atas dilakukan perhitungan jumlah data untuk masing-masing kelas hasilnya berjumlah 890 untuk mahasiswa tepat waktu dan tidak tepat waktu berjumlah 717 mahasiswa dapat dilihat pada gambar 4.1 berikut :




Gambar 4. 1 Grafik Jumlah Kelas Output

Pada tahapan preprocessing ini dilakukan pengecekan data yang kosong atau data yang tidak konsisten terhadap hasil akhir atau kelas output. Berikut contoh sampel data yang tidak konsisten dapat dilihat pada Tabel 4.4 berikut :

Tabel 4. 4 Data Tidak Konsisten

JK	KELAS	IPS1	IPS2	IPS3	IPS4	STATUS
L	N	3,6	3,88	3,88	3,71	TIDAK TEPAT,TEPAT WAKTU
L	N	3,86	3,86	4	3,86	TIDAK TEPAT,TEPAT WAKTU
L	N	4	4	3,88	3,88	TIDAK TEPAT,TEPAT WAKTU
L	R	3,9	3,9	3,52	3,45	TIDAK TEPAT,TEPAT WAKTU
L	R	4	4	4	4	TIDAK TEPAT,TEPAT WAKTU
P	N	3,57	3,57	3,75	3,63	TIDAK TEPAT,TEPAT WAKTU
P	N	3,87	3,87	3,88	4	TIDAK TEPAT,TEPAT WAKTU
P	R	3,64	3,64	3,89	3,32	TIDAK TEPAT,TEPAT WAKTU
P	R	3,71	3,71	4	3,75	TIDAK TEPAT,TEPAT WAKTU
P	R	3,73	3,73	3,89	3,32	TIDAK TEPAT,TEPAT WAKTU

Setelah dilakukan perbaikan data kemudian dihitung kembali jumlah data mahasiswa yang lulus tepat waktu berjumlah 906 mahasiswa lulus tepat waktu dan 701 mahasiswa yang tidak tepat waktu masing-masing kelas dapat dilihat pada Gambar 4.2 berikut :



Gambar 4. 2 Grafik Jumlah Kelas Setelah Perbaikan

4.3 Hasil Pengembangan Model

Pengembangan Model *Decision Tree C4.5* menggunakan bahasa pemrograman Python dengan tools Google Colaboratory dengan tahapan-tahapan berikut :

4.3.1 Tahapan Seleksi Data

Pada Tahapan Seleksi Data ini dilakukan beberapa proses yakni:

1. Tahapan Pengaitan Dengan Google Drive

Pada tahapan ini mengaktifkan penggunaan goole drive sebagai tempat penyimpanan, adapun coding dengan python sebagai berikut :

```
#Proses Pengaitan dengan Google Drive
from google.colab import drive
drive.mount('/content/drive')
```

2. Membaca File Data Excel

Pada tahapan ini proses membaca dataset excel dengan menjalankan perintah sebagai berikut :

```
#Membaca Dataset File Excel
df = pd.read_excel("/content/drive/MyDrive/skripsi
alan/data fixx.xlsx")
df.head()
```

Hasil Outputnya sebgai berikut :



	JK	Kelas	IPS1	IPS2	IPS3	IPS4	Status
0	P	R	3.64	3.64	3.58	3.36	Tidak Tepat
1	P	R	3.36	3.36	3.37	2.18	Tidak Tepat
2	P	R	4.00	4.00	4.00	3.73	Tepat Waktu
3	L	R	3.73	3.73	3.58	3.45	Tidak Tepat
4	L	R	3.40	3.40	2.53	2.05	Tidak Tepat




Gambar 4. 3 Hasil Pembacaan Dataset Dari File Excel

4.3.2 Tahapan Preprocessing

Pada tahap preprocessing dilakukan beberapa tahap yaitu :

1. Tahapan Mengelompokkan Data Atribut Yang Ingin Di Periksa

Pada tahap ini dilakukan pengecekan dataset yang kosong atau data yang tidak konsisten terhadap hasil akhir atau kelas output dengan melakukan perintah sebagai berikut :

```
# Mengelompokkan data berdasarkan atribut yang ingin
diperiksa
grouped_data = df.groupby(['JK', 'Kelas', 'IPS1',
'IPS2', 'IPS3', 'IPS4'])

# Memeriksa kategori kelas untuk setiap kelompok
for key, group in grouped_data:
    unique_classes = group['Status'].unique()
    if len(unique_classes) > 1:
        print(f"Kelompok {key}: Kelas yang berbeda =
{unique_classes}")
```

Hasil Outputnya Sebagai Berikut :

```
Kelompok ('L', 'N', 3.6, 3.88, 3.88, 3.71): Kelas yang berbeda = ['Tidak Tepat' 'Tepat Waktu']
Kelompok ('L', 'N', 3.86, 3.86, 4.0, 3.86): Kelas yang berbeda = ['Tepat Waktu' 'Tidak Tepat']
Kelompok ('L', 'N', 4.0, 4.0, 3.88, 3.88): Kelas yang berbeda = ['Tidak Tepat' 'Tepat Waktu']
Kelompok ('L', 'R', 3.9, 3.9, 3.52, 3.45): Kelas yang berbeda = ['Tepat Waktu' 'Tidak Tepat']
Kelompok ('L', 'R', 4.0, 4.0, 4.0, 4.0): Kelas yang berbeda = ['Tepat Waktu' 'Tidak Tepat']
Kelompok ('P', 'N', 3.57, 3.57, 3.75, 3.63): Kelas yang berbeda = ['Tepat Waktu' 'Tidak Tepat']
Kelompok ('P', 'N', 3.87, 3.87, 3.88, 4.0): Kelas yang berbeda = ['Tepat Waktu' 'Tidak Tepat']
Kelompok ('P', 'R', 3.64, 3.64, 3.89, 3.32): Kelas yang berbeda = ['Tidak Tepat' 'Tepat Waktu']
Kelompok ('P', 'R', 3.71, 3.71, 4.0, 3.75): Kelas yang berbeda = ['Tepat Waktu' 'Tidak Tepat']
Kelompok ('P', 'R', 3.73, 3.73, 3.89, 3.32): Kelas yang berbeda = ['Tidak Tepat' 'Tepat Waktu']
Kelompok ('P', 'R', 3.75, 4.0, 4.0, 4.0): Kelas yang berbeda = ['Tidak Tepat' 'Tepat Waktu']
Kelompok ('P', 'R', 3.77, 3.77, 3.89, 3.32): Kelas yang berbeda = ['Tidak Tepat' 'Tepat Waktu']
Kelompok ('P', 'R', 3.87, 3.87, 3.63, 3.33): Kelas yang berbeda = ['Tepat Waktu' 'Tidak Tepat']
Kelompok ('P', 'R', 4.0, 4.0, 3.87, 3.88): Kelas yang berbeda = ['Tidak Tepat' 'Tepat Waktu']
```

Gambar 4. 4 Data Tidak Konsisten

Dari dari hasil ouputnya ini dapat dilihat untuk kolom status kelulusan masih terdapat status kelulusan yang tidak konsisten, maka kita perlu melakukan perbaikan data pada kategori kolom Status.

2. Tahap Mengganti Kategori Kelas Sesuai Kondisi.

Pada tahap ini ini dilakukan proses pengelompokan data, karna masih terdapat data yang tidak konsisten untuk mengganti kategori kelas sesuai kondisi, untuk status nya dapat diganti menjadi tepat waktu berdasarkan nilai IPS1 s.d IPS4, untuk menggantinya kita dapat menjalankan kode program sebagai berikut :

```
# Mengganti kategori kelas sesuai kondisi

df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'N') & (df['IPS1'] == 3.6) & (df['IPS2'] == 3.88) & (df['IPS3'] == 3.88) & (df['IPS4'] == 3.71), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'N') & (df['IPS1'] == 3.86) & (df['IPS2'] == 3.86) & (df['IPS3'] == 4.0) & (df['IPS4'] == 3.86), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'N') & (df['IPS1'] == 4.0) & (df['IPS2'] == 4.0) & (df['IPS3'] == 3.88) & (df['IPS4'] == 3.88), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.9) & (df['IPS2'] == 3.9) & (df['IPS3'] == 3.52) & (df['IPS4'] == 3.45), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'R') & (df['IPS1'] == 4.0) & (df['IPS2'] == 4.0) & (df['IPS3'] == 4.0) & (df['IPS4'] == 4.0), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'N') & (df['IPS1'] == 3.57) & (df['IPS2'] == 3.57) & (df['IPS3'] == 3.75) & (df['IPS4'] == 3.63), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'N') & (df['IPS1'] == 3.87) & (df['IPS2'] == 3.87) & (df['IPS3'] == 3.88) & (df['IPS4'] == 4.0), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.64) & (df['IPS2'] == 3.64) & (df['IPS3'] == 3.89) & (df['IPS4'] == 3.32), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.71) & (df['IPS2'] == 3.71) & (df['IPS3'] == 4.0) & (df['IPS4'] == 3.75), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.73) & (df['IPS2'] == 3.73) & (df['IPS3'] == 3.89) & (df['IPS4'] == 3.32), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.75) & (df['IPS2'] == 4.0) & (df['IPS3'] == 4.0) & (df['IPS4'] == 4.0), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.77) & (df['IPS2'] == 3.77) & (df['IPS3'] == 3.89) & (df['IPS4'] == 3.32), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.87) & (df['IPS2'] == 3.87) & (df['IPS3'] == 3.63) & (df['IPS4'] == 3.33), 'Status'] = 'Tepat Waktu'

df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 4.0) & (df['IPS2'] == 4.0) & (df['IPS3'] == 3.87) & (df['IPS4'] == 3.88), 'Status'] = 'Tepat Waktu'

# Menampilkan DataFrame setelah perubahan

print(df)
```

Hasil Outputnya Sebagai Berikut :

	JK	Kelas	IPS1	IPS2	IPS3	IPS4	Status
0	P	R	3.64	3.64	3.58	3.36	Tidak Tepat
1	P	R	3.36	3.36	3.37	2.18	Tidak Tepat
2	P	R	4.00	4.00	4.00	3.73	Tepat Waktu
3	L	R	3.73	3.73	3.58	3.45	Tidak Tepat
4	L	R	3.40	3.40	2.53	2.05	Tidak Tepat
...	...	...	...	...	...	...	...
1602	P	R	3.60	3.88	3.58	3.58	Tepat Waktu
1603	P	R	3.35	2.63	2.94	3.78	Tepat Waktu
1604	P	N	3.70	2.83	3.10	3.70	Tepat Waktu
1605	L	R	1.94	2.71	2.62	2.17	Tidak Tepat
1606	L	N	3.60	3.88	3.88	3.71	Tepat Waktu

[1607 rows x 7 columns]

Gambar 4. 5 Hasil Perbaikan Kelas Yang Berbeda

3. Tahapan Menghitung Jumlah Kategori Dalam Kolom ‘Status’

Pada tahap ini dilakukan proses menghitung kembali dalam kategori ‘Status’ setelah melakukan perbaikan data untuk dapat mengetahui jumlah status kelulusan dapat menjalankan kode program sebagai berikut :

```
# Menghitung jumlah setiap kategori dalam kolom
'Status'
df['Status'].value_counts()
```

Hasil Outputnya Sebagai Berikut :

```
Tepat Waktu      906
Tidak Tepat      701
Name: Status, dtype: int64
```

Gambar 4. 6 Hasil Perhitungan jumlah kategori pada Colom ‘Status’

Dari hasil output tersebut dapat kita lihat bahwa jumlah mahasiswa yang lulus tepat waktu sebanyak 906 dan tidak tepat sebanyak 701.

4.3.3 Tahapan Transformasi

Pada tahapan ini dilakukan konversi nilai string ke numerik, karena pada atribut JK dan KELAS masih terdapat nilai string, untuk mengkonversi atribut yang bernilai string diperlukan perintah sebagai berikut:

```
#Proses Konversi Nilai String ke Numerik
df['JK'].replace(['L', 'P'], [1, 2], inplace=True)
df.head()
df['Kelas'].replace(['R', 'N'], [1, 2], inplace=True)
df.head()
```

Pada atribut jenis kelamin terdapat nilai string yaitu L dan P kedua nilai ini akan di konversi dalam nilai numerik sehingga nilai akhir menjadi 1 dan 2 dimana L akan dikonversi ke angka 1 dan P dikonversi ke angka 2, begitupun nilai string yang terdapat pada atribut kelas dimana R akan di ubah menjadi angka 1 dan R akan di ubah menjadi angka 2.

Hasil Outputnya Sebagai Berikut :

	JK	Kelas	IPS1	IPS2	IPS3	IPS4	Status
0	2	1	3.64	3.64	3.58	3.36	Tidak Tepat
1	2	1	3.36	3.36	3.37	2.18	Tidak Tepat
2	2	1	4.00	4.00	4.00	3.73	Tepat Waktu
3	1	1	3.73	3.73	3.58	3.45	Tidak Tepat
4	1	1	3.40	3.40	2.53	2.05	Tidak Tepat

Gambar 4. 7 Hasil Konversi Nilai String Ke Numerik

Dapat dilihat dari hasil output diatas bahwa jenis kelamin dan kelas sudah berubah datanya dari yang awalnya string ke numerik.

4.3.4 Tahapan Data Mining

Pada tahap ini akan dilakukan proses data mining yang dimana akan ada beberapa tahapan data mining diantaranya adalah sebagai berikut :

1. Tahapan Pemisahan Atribut dan Label

Sebelum masuk ke proses membagi data training dan data testing perlu dilakukan langkah awal yaitu dengan memisahkan atribut dan label dari data asli data excel, dengan menjalankan kode program sebagai berikut :

```
# memisahkan atribut dan label
X = df[['JK', 'Kelas', 'IPS1', 'IPS2', 'IPS3', 'IPS4' ]]
y = df['Status']
```

2. Tahapan Membagi Data Trainig & Data Testing

Pada tahap selanjutnya dilakukan proses pembagian data, Dimana data akan dibagi menjadi 2 bagian yaitu data training dan data testing, untuk pembagian nya dengan membagi data training sebesar 70% dan data testing sebesar 30%, untuk proses pembagian nya dilakukan dengan perintah berikut :

```
# Membagi dataset menjadi data latih & data uji
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X,
y, test_size=0.3, random_state=0)
print ('Train set:', X_train.shape,  y_train.shape)
print ('Test set:', X_test.shape,  y_test.shape)
```

```
Train set: (1124, 6) (1124,)
Test set: (483, 6) (483,)
```

Gambar 4. 8 Hasil Pembagian Data Training & Data Testing

Dari hasil output dapat dilihat bahwa terdapat jumlah data training sebanyak 1124 dan data testing sebanyak 483 data.

Adapun juga data training dan data testing dapat disajikan pada Tabel 4.9 Tabel 4.10 berikut

Tabel 4. 5 Dataset Training

IPS1	IPS2	IPS3	IPS4	Status
3,9	3,88	3,67	3,92	Tepat Waktu
3,81	3	3,91	3,17	Tepat Waktu
4	3,53	3,78	3,67	Tepat Waktu
2,96	2,96	3,76	3,71	Tidak Tepat
3,76	4	4	3,92	Tepat Waktu
3,38	3,5	3,52	3,88	Tepat Waktu
3,32	3,32	2,6	2,35	Tidak Tepat
3,7	3,88	3,88	3,88	Tepat Waktu
3,86	3,86	3,89	3,86	Tepat Waktu
3,58	3,58	3,6	3,52	Tepat Waktu
...	...	...	...	...
4	4	3,78	3,67	Tepat Waktu

Tabel 4. 6 Dataset Testing

IPS1	IPS2	IPS3	IPS4	Status
3,71	3,71	3,88	4	Tepat Waktu
3,9	3,9	4	4	Tepat Waktu
3,2	3,33	3,29	2,96	Tidak Tepat
3,87	3,87	3,79	3,71	Tepat Waktu
3,57	3,57	3,13	2,17	Tidak Tepat
4	4	3,58	3,33	Tepat Waktu
3,65	3,67	2,83	3	Tidak Tepat
3,74	3,74	3,35	3,74	Tidak Tepat
4	4	4	4	Tepat Waktu
3,78	3,78	3,67	3,71	Tepat Waktu
...	...	...	...	...
4	3,79	4	4	Tepat Waktu

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

Tahap 1 : Menghitung nilai entropi total untuk seluruh atribut

Atribut	Jumlah	LULUS	TIDAK LULUS	Entropy
Total	1124	676	448	0,970112

$$\begin{aligned}
 Entropy(S) &= \left(-\frac{448}{1124} \times \log_2 \left(\frac{448}{1124} \right) \right) + \left(-\frac{676}{1124} \times \log_2 \left(\frac{676}{1124} \right) \right) \\
 &= 0,970112
 \end{aligned}$$

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

Tabel 4. 7 Entropi untuk Setiap Atribut

Atribut		Jumlah	LULUS	TIDAK LULUS	Entrophy	Gain
JK	Gain					0,033574365
	<=1	613	310	303	0,999905935	
	>1	511	366	145	0,86052007	
KELAS	Gain					0,003732619
	<=1	574	365	209	0,946043203	
	>1	550	311	239	0,987602578	
IPS1	Gain					0,181278795
	<= 3,61	467	190	277	0,974818043	
	> 3,67	557	430	127	0,774521164	
IPS2	Gain					0,220915769
	<= 3,59	469	182	287	0,963535984	
	> 3,67	535	426	109	0,729342017	
IPS3	Gain					0,320072478
	<= 3,54	467	141	362	0,806467354	
	> 3,63	561	472	89	0,631058753	
IPS4	Gain					0,377615237
	<= 3,45	488	127	361	0,827117215	
	> 3,50	558	502	56	0,470130739	

Pada Tabel 4.11 diatas dapat dilihat bahwa, setelah seluruh untuk mencari nilai entropi selanjutnya menghitung dan mencari nilai gain tertinggi dari seluruh atribut.

$$\begin{aligned}\text{Gain (IPS4)} &= 0,970112 - \left(\left(\frac{488}{1124} \right) * 0,827117215 \right) + \left(\left(\frac{558}{1124} \right) * 0,470130739 \right) \\ &= 0,377615237\end{aligned}$$

Dan dipatkan nilai gain tertinggi yaitu 0,377615237 sehingga yang menjadi root (node) awal dari pohon keputusan adalah IPS4.

3. Tahapan Pemodelan Pertama

Setelah dilakukan pembagian data training dan testing, maka membuat model pohon pertama dengan melatih model dengan data training dengan menjalankan perintah sebagai berikut :

```
#membuat model decision tree
clf = DecisionTreeClassifier()
# Melatih model dengan menggunakan data latih
tree_model1 = clf.fit(X_train, y_train)
```


4.3.5 Tahapan Evaluasi

Pada tahap ini, akan dilakukan evaluasi kinerja model dari *Decision Tree* menggunakan metode *Confusion Matrix*, dimana proses ini akan dilakukan proses evaluasi dari model sebelumnya. Dataset yang diprediksi akan menggunakan data hasil uji coba 1 sebelumnya. Dengan menggunakan perintah sebagai berikut :

1. Tahapan Evaluasi Model

```
from sklearn.metrics import confusion_matrix,
classification_report
from sklearn.metrics import confusion_matrix
import seaborn as sns
import matplotlib.pyplot as plt
# 6. Evaluasi Model
y_pred = tree_model1.predict(X_test)
labels=y
# Membuat confusion matrix
cm = confusion_matrix(y_test, y_pred)
# Mencetak confusion matrix
labels = [ 'Tepat Waktu', 'Tidak Tepat', ]
plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt='d', xticklabels=labels ,
yticklabels=labels, cmap='viridis')
plt.xlabel('Predicted')
plt.ylabel('Actual')
plt.title('Confusion Matrix')
plt.show()
# Menghitung precision, recall, f1-score, dan support
report = classification_report(y_test, y_pred,
target_names=labels)
print(report)
```

Setelah perintah di jalan maka hasil ouputnya dapat dilihat pada Gambar 4.8 dan hasil perhitungan akurasi dapat disajikan pada Tabel 4.12 berikut :



Gambar 4. 9 Hasil Confusion Matrix

Tabel 4. 8 Hasil Perhitungan Confussion Matriks 1.

Status	Precission	Recall	Fi-score	Jumlah Data
Tepat waktu	0,80	0,77	0,79	251
Tidak Tepat	0,76	0,79	0,78	232
Accuracy	0,78			483

Dari hasil tabel 4.12 diatas dapat dilihat bahwa nilai akurasi yang diperoleh sebesar 78%.


2. Tahapan Visualisasi.

Pada tahap ini dilakukan proses pemodelan dengan metode *Decision tree C4.5*, dimana nantinya pemodelan ini akan menghasilkan pohon keputusan awal. untuk perintah yang digunakan dalam proses pemodelan ini adalah sebagai berikut :

```
from six import StringIO
import pydotplus
import matplotlib.image as mpimg
from sklearn import tree

%matplotlib inline
dot_data = StringIO()
filename = "/content/drive/MyDrive/skripsi
alan/pohon1.png"
featureNames = ['JK', 'Kelas', 'IPS1', 'IPS2',
'IPS3', 'IPS4']
targetNames = ['Tepat Waktu', 'Tidak Tepat']
out = tree.export_graphviz(tree_model1,
feature_names=featureNames, out_file=dot_data,
class_names= np.unique(y_train),
filled=True, special_characters=True, rotate=False)
graph =
pydotplus.graph_from_dot_data(dot_data.getvalue())
graph.write_png(filename)
img = mpimg.imread(filename)
plt.figure(figsize=(200, 100))
plt.imshow(img, interpolation='nearest')
```

Hasil Outputnya Sebagai Berikut :



Gambar 4. 10 Hasil Pemodelan 1

Dari hasil output Gambar 4. di atas dapat dilihat bahwa pohon keputusan yang terbentuk belum maksimal dan masih terlalu banyak jalur keputusan yang tidak signifikan yaitu terdapat lebih dari 20 jalur keputusan, hal ini terjadi karena masih terdapat data yang tidak konsisten terhadap kelas output, sehingga untuk mengatasi masalah tersebut perlu dilakukan proses optimalisasi model.

4.3.6 Tahapan Perbaikan Model

Pada proses perbaikan model akan dilakukan beberapa tahapan dengan menjalankan beberapa perintah sebagai berikut :

1. Tahapan Pemangkasan Pohon

Untuk melakukan pemangkasan pohon disini kita akan mengganti kategori ke kelas sesuai kondisi dimana nilai IPS1, IPS2, IPS3, dengan nilai $\leq 2,5$ dan IPS4 dengan nilai $\leq 2,89$ untuk kolom kategori status akan digantikan dengan status Tidak Tepat dengan menjalankan kode program sebagai berikut :

```
# Mengganti kategori kelas sesuai kondisi
df.loc[ (df['IPS1'] <= 2.5), 'Status'] = 'Tidak Tepat'
df.loc[ (df['IPS2'] <= 2.5), 'Status'] = 'Tidak Tepat'
df.loc[ (df['IPS3'] <= 2.5), 'Status'] = 'Tidak Tepat'
df.loc[ (df['IPS4'] <= 2.89), 'Status'] = 'Tidak Tepat'
# Menampilkan DataFrame setelah perubahan
print(df)
```

Hasil Outputnya Sebagai Berikut :



	JK	Kelas	IPS1	IPS2	IPS3	IPS4	Status
0	2	1	3.64	3.64	3.58	3.36	Tidak Tepat
1	2	1	3.36	3.36	3.37	2.18	Tidak Tepat
2	2	1	4.00	4.00	4.00	3.73	Tepat Waktu
3	1	1	3.73	3.73	3.58	3.45	Tidak Tepat
4	1	1	3.40	3.40	2.53	2.05	Tidak Tepat
...	..	...	...	...	...	...	...
1602	2	1	3.60	3.88	3.58	3.58	Tepat Waktu
1603	2	1	3.35	2.63	2.94	3.78	Tepat Waktu
1604	2	2	3.70	2.83	3.10	3.70	Tepat Waktu
1605	1	1	1.94	2.71	2.62	2.17	Tidak Tepat
1606	1	2	3.60	3.88	3.88	3.71	Tepat Waktu

[1607 rows x 7 columns]

Gambar 4. 11 Hasil Mengganti Kategori kelas Sesuai Kondisi

Kemudian masuk pada tahapan yang sama yaitu dengan mengganti kategori kelas sesuai kondisi, tetapi yang diganti hanya IPS4, dengan nilai > 3,75 untuk kategori kolom status akan diubah menjadi Tepat Waktu semua, dengan menjalankan kode perintah sebagai berikut :

```
# Mengganti kategori kelas sesuai kondisi
df.loc[ (df['IPS4'] > 3.75), 'Status'] = 'Tepat Waktu'

# Menampilkan DataFrame setelah perubahan
print(df)
```

Hasil Outputnya Sebagai Berikut :



	JK	Kelas	IPS1	IPS2	IPS3	IPS4	Status
0	2	1	3.64	3.64	3.58	3.36	Tidak Tepat
1	2	1	3.36	3.36	3.37	2.18	Tidak Tepat
2	2	1	4.00	4.00	4.00	3.73	Tepat Waktu
3	1	1	3.73	3.73	3.58	3.45	Tidak Tepat
4	1	1	3.40	3.40	2.53	2.05	Tidak Tepat
...	..	...	...	...	...	...	...
1602	2	1	3.60	3.88	3.58	3.58	Tepat Waktu
1603	2	1	3.35	2.63	2.94	3.78	Tepat Waktu
1604	2	2	3.70	2.83	3.10	3.70	Tepat Waktu
1605	1	1	1.94	2.71	2.62	2.17	Tidak Tepat
1606	1	2	3.60	3.88	3.88	3.71	Tepat Waktu

[1607 rows x 7 columns]

Gambar 4. 12 Hasil Mengganti Kategori kelas Sesuai Kondisi ke 2

2. Tahapan Mengukur Kedalam Pohon

Pada tahapan ini untuk mendapatkan pohon dengan model yang minimalis dilakukan proses pengukuran kedalaman pohon yang maksimal berdasarkan tingkat akurasi tertinggi yang didapatkan dengan menjalankan perintah sebagai berikut :

```

from sklearn.tree import DecisionTreeClassifier
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
# Mencoba berbagai nilai kedalaman pohon
for max_depth in range(1, 11):
    clf = DecisionTreeClassifier(max_depth=max_depth)
    clf.fit(X_train, y_train)
    y_pred = clf.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)
    print(f"Max Depth = {max_depth}, Accuracy = {accuracy:.2f}")
# Mencoba berbagai nilai minimum sampel untuk percabangan
for min_samples_split in range(2, 11):
    clf = DecisionTreeClassifier(min_samples_split=min_samples_split)
    clf.fit(X_train, y_train)
    y_pred = clf.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)
    print(f"Min Samples Split = {min_samples_split}, Accuracy = {accuracy:.2f}")

```

Hasil Outputnya Sebagai Berikut :

```

Max Depth = 1, Accuracy = 0.86
Max Depth = 2, Accuracy = 0.87
Max Depth = 3, Accuracy = 0.89
Max Depth = 4, Accuracy = 0.90
Max Depth = 5, Accuracy = 0.90
Max Depth = 6, Accuracy = 0.89
Max Depth = 7, Accuracy = 0.88
Max Depth = 8, Accuracy = 0.88
Max Depth = 9, Accuracy = 0.87
Max Depth = 10, Accuracy = 0.86
Min Samples Split = 2, Accuracy = 0.85
Min Samples Split = 3, Accuracy = 0.85
Min Samples Split = 4, Accuracy = 0.84
Min Samples Split = 5, Accuracy = 0.85
Min Samples Split = 6, Accuracy = 0.83
Min Samples Split = 7, Accuracy = 0.85
Min Samples Split = 8, Accuracy = 0.85
Min Samples Split = 9, Accuracy = 0.86
Min Samples Split = 10, Accuracy = 0.85

```

Gambar 4.13 Hasil Pengukuran Kedalaman Pohon

Berdasarkan hasil pengukuran kedalaman, terdapat nilai akurasi tertinggi senilai 90% sebagai pemilihan perbaikan pemodelan.

3. Tahapan Seleksi Atribut

Pada tahapan ini akan dilakukan proses evaluasi terhadap variable atau atribut penting dengan penerapan metode *Feature Importance* untuk


mengetahui hasil seleksi atribut yang berpengaruh terhadap hasil akhir dalam pembuatan model ke dua dengan kode perintah sebagai berikut :

```
from sklearn.ensemble import ExtraTreesClassifier
import matplotlib.pyplot as plt
model = ExtraTreesClassifier()
model.fit(X,y)

print(model.feature_importances_) #use inbuilt class
feature_importances of tree based classifiers

#plot graph of feature importances for better
visualization
feat_importances =
pd.Series(model.feature_importances_, index=X.columns)
feat_importances.nlargest(10).plot(kind='barh')
plt.show()
```

Hasil outputnya ditampilkan pada grafik berikut ini :



Gambar 4. 14 Grafik Presentase atribut

Berdasarkan Gambar 4.5 diatas, terdapat atribut jenis kelamin dan IPS1, IPS2, IPS3, dan IPS4 yang menjadi atribut penting dalam proses pembuatan model ke dua.

4. Tahap Mengambil Atribut Berpengaruh

Pada tahapan ini dilakukan pengambilan atribut penting berupa IPS1, IPS2, IPS3, dan IPS4 yang menjadi hasil akhir pemodelan ke dua dengan kode perintah sebagai berikut :

```
# Mengambil atribut yang berpengaruh ke hasil
X1 = df[['IPS1', 'IPS2', 'IPS3', 'IPS4' ]]
y1 = df['Status']
```

5. Tahap Membagi Dataset

Pada tahapan ini sebelum masuk ke pembuatan model kedua, kita perlu membagi data menjadi dua bagian yaitu data training dan data testing dengan menjalankan kode perintah sebagai berikut :

```
# Membagi dataset menjadi data latih & data uji
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X,
y, test_size=0.3, random_state=0)
print ('Train set:', X_train.shape, y_train.shape)
print ('Test set:', X_test.shape, y_test.shape)
```

Hasil Outputnya Sebagai Berikut :

```
Train set: (1124, 4) (1124,)
Test set: (483, 4) (483,)
```

Gambar 4. 15 Hasil Pembagian Data set

Dari hasil berikut dapat kita lihat bahwa data dibagi menjadi dua bagian yaitu data training sebanyak 1124 dan data testing sebanyak 483, dimana yang akan dilakukan untuk pemodelan ke dua yaitu data training.

6. Tahapan Pemodelan Ke Dua

Pada tahapan dapat dilakukan pemodelan kedua dengan Metode *Decision Tree C4.5* dengan kode perintah sebagai berikut :


```
# membuat model Decision Tree
#tree_model = DecisionTreeClassifier()
clf = DecisionTreeClassifier(max_depth=4,
min_samples_split=5, min_samples_leaf=5,
criterion="entropy")
#clf = DecisionTreeClassifier(max_depth=5,
```

7. Tahapan Evaluasi Model ke Dua

Pada Tahapan ini akan dilakukan proses evaluasi kinerja model dari *Decision Tree* kembali menggunakan metode *Confusion Matrix* dengan menggunakan kode program sebagai berikut :

```
from sklearn.metrics import confusion_matrix,
classification_report
from sklearn.metrics import confusion_matrix
import seaborn as sns
import matplotlib.pyplot as plt
# 6. Evaluasi Model
y_pred = tree_model2.predict(X_test)
labels=y
# Membuat confusion matrix
cm = confusion_matrix(y_test, y_pred)
# Mencetak confusion matrix
labels = [ 'Tepat Waktu', 'Tidak Tepat', ]
plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt='d', xticklabels=labels
, yticklabels=labels, cmap='viridis')
plt.xlabel('Predicted')
plt.ylabel('Actual')
plt.title('Confusion Matrix')
plt.show()
# Menghitung precision, recall, f1-score, dan support
report = classification_report(y_test, y_pred,
target_names=labels)
print(report)
```

Untuk Hasil Outputnya hasil confussion matrix dan nilai akurasi dapat dilihat pada Gambar 4.6 dan Tabel Sebagai Berikut :



Gambar 4. 16 Hasil Confussion Matriks 2

Tabel 4. 9 Hasil akurasi pemodelan kedua 2

Status	Precission	Recall	Fi-score	Jumlah Data
Tepat waktu	0,83	1,00	0,91	251
Tidak Tepat	1,00	0,76	0,87	232
Accuracy	0,89			483


Dari tabel diatas dapat kita lihat bawah hasil akurasi pemodelan kedua setelah optimalisasi dan seleksi atribut menggunakan *Feature Importance* nilai akurasi yang di peroleh sebesar 89%, dimana terjadi peningkatan akurasi sebesar 11% dari hasil pemodelan pertama yang dapat kita lihat pada Tabel 4.13.

8. Tahapan Visualisasi Model Ke 2

Pada tahapan setelah dilakukan hasil evualsai, kita dapt melihat hasil visualisasi pada Gambar dengan menggunakan kode python sebagai berikut:

```
dot_data = StringIO()
filename = "/content/drive/MyDrive/skripsi/pohon3.png"
featureNames = ['IPS1', 'IPS2', 'IPS3', 'IPS4']
targetNames = ['Tepat Waktu', 'Tidak Tepat']
out = tree.export_graphviz(tree_model2,
feature_names=featureNames, out_file=dot_data,
class_names= np.unique(y_train),
filled=True, special_characters=True, rotate=False)
graph =
pydotplus.graph_from_dot_data(dot_data.getvalue())
graph.write_png(filename)
img = mpimg.imread(filename)
plt.figure(figsize=(200, 100))
plt.imshow(img, interpolation='nearest')
```

Hasil Outputnya Sebagai Berikut :



Gambar 4. 17 Model Hasil Perbaikan Model

Berdasarkan Gambar 4.17 di atas dapat dilihat bahwa pohon keputusan yang terbentuk sudah lebih sederhana dan jumlah jalur atau rule keputusan yang terbentuk sisa 8 rule.

4.3.7 Tahapan Klasifikasi Data Testing Baru

Pada tahap ini, Setelah didapatkan hasil pemodelan yang optimal, maka model tersebut dapat digunakan untuk melakukan klasifikasi data testing baru dengan memasukkan nilai atribut sesuai dengan model yang sudah dilatih. Adapun hasil ujicoba klasifikasi data baru dapat dilakukan dengan menjalankan kode perintah sebagai berikut :

1. Tahapan Seleksi Data

Pada tahap ini dilakukan proses pembacaan dataset data dari excel .xlsx dengan kode perintah sebagai berikut:

```
#Klasifikasi model dengan data baru dengan data dari
Excel
data_tes =
pd.read_excel("/content/drive/MyDrive/skripsi/pr/datap
r.xlsx")
data_tes.head()
```

Hasil Outputnya Sebagai Berikut :

	No	IPS1	IPS2	IPS3	IPS4	Status
0	175	3.71	3.71	3.88	4.00	Tepat Waktu
1	317	3.90	3.90	4.00	4.00	Tepat Waktu
2	1478	3.20	3.33	3.29	2.96	Tidak Tepat
3	746	3.87	3.87	3.79	3.71	Tepat Waktu
4	182	3.57	3.57	3.13	2.17	Tidak Tepat

Gambar 4. 18 Hasil Klasifikasi Dengan Data Baru

2. Tahapan Konversi Data

Pada Tahap ini dilakukan proses konversi data .xlsx ke .csv dengan menjalankan kode perintah sebagai berikut :

```
#Mengkonversi File Excel .xlsx ke .csv
data_tes.to_csv("/content/drive/MyDrive/skripsi/pr/dat
apr.csv", index=False)
data_tes.info()
```

Hasil Outoput Nya Sebagai Berikut :

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 5 entries, 0 to 4
Data columns (total 6 columns):
#   Column      Non-Null Count  Dtype
---  ---
0   No           5 non-null      int64
1   IPS1         5 non-null      float64
2   IPS2         5 non-null      float64
3   IPS3         5 non-null      float64
4   IPS4         5 non-null      float64
5   Status       5 non-null      object
dtypes: float64(4), int64(1), object(1)
memory usage: 368.0+ bytes
```

Gambar 4. 19 Hasil Konversi Data .xlsx ke .csv

3. Proses Cetak Data Prediksi

Pada tahap ini setelah file dikonversi ke format csv, kemudian dilakukan langkah selanjutnya yaitu proses mencetak dataset prediksi dengan melakukan perintah Sebagai berikut :

```
dataX = data_tes[['IPS1', 'IPS2', 'IPS3', 'IPS4']]
```

Hasil Ouputnya Nya Sebagai berikut :

	IPS1	IPS2	IPS3	IPS4
0	3.71	3.71	3.88	4.00
1	3.90	3.90	4.00	4.00
2	3.20	3.33	3.29	2.96
3	3.87	3.87	3.79	3.71
4	3.57	3.57	3.13	2.17

Gambar 4. 20 Hasil Cetak Data Prediksi

Berdasarkan hasil output tersebut belum diketahui prediksi status kelulusan.

4. Tahapan Prediksi Model Dengan Data Baru

Pada tahap ini dilakukan akan hasil prediksi dari pemodelan dengan data baru dengan menjalankan kode perintah sebagai berikut :

```
# klasifikasi model dengan data baru (IPS1,  
IPS2,IPS3,IPS4)  
hasil=tree_model2.predict(dataX)
```

Hasil Output Nya Sebagai berikut :

```
['Tepat Waktu' 'Tidak Tepat' 'Tepat Waktu' ... 'Tepat Waktu' 'Tidak Tepat'  
'Tepat Waktu']
```

Gambar 4. 21 Hasil Klasifikasi Dengan Data Baru

BAB V


PEMBAHASAN

5.1 Pembahasan Kinerja Model

Pemodelan *Decision Tree C4.5* dalam klasifikasi waktu kelulusan mahasiswa dilakukan uji coba pemodelan dilakukan sebanyak 2 kali pemodelan, yaitu sebelum optimalisasi dan setelah optimalisasi seleksi atribut menggunakan metode *Feature Importance*.

1. Kinerja Model Sebelum Optimalisasi

Setelah dilakukan pemodelan *Decision Tree C4.5* selanjutnya dilakukan pengujian model dengan menggunakan data testing sebanyak 483 data, Adapun hasil pengujian akurasi model menggunakan confusion matriks sebagaimana yang di tampilkan pada Gambar 5.1 berikut:



Gambar 5. 1 Hasil *Confussion Matrix* Sebelum Optimalisasi

Berdasarkan Gambar 5.1 diatas dapat dilakukan perhitungan lebih lanjut terkait Akurasi, Presisi, Dan Recall sebagai berikut :

Tabel 5. 1 Hasil *Confussion Matrix* Sebelum Optimalisasi

Status	Precission	Recall	Fi-score	Jumlah Data
Tepat waktu	0,80	0,77	0,79	251
Tidak Tepat	0,76	0,79	0,78	232
Accuracy	0,78			483

Berdasarkan hasil tabel di atas dapat di lihat bahwa akurasi pemodelan sebelum dilakukan seleksi atribut di dapatkan nilai akurasi sebesar 0,78%.

Pada gambar 5.1 diatas, terdapat hasil nilai akurasi dari proses prediksi mahasiswa menggunakan *Confusion Matrix* sebelum optimalisasi dengan nilai akurasi sebesar 78% yang diperoleh dari data testing yang berjumlah 483 data, dengan jumlah mahasiswa tepat waktu sebanyak 194 orang, jumlah mahasiswa tidak lulus tepat waktu sebanyak 183 orang, dan jumlah mahasiswa yang seharusnya tidak lulus tepat waktu tetapi diprediksi tepat waktu sebanyak 49 orang serta jumlah mahasiswa yang seharusnya lulus tepat waktu tetapi diprediksi sebagai tidak tepat waktu sebanyak 57 orang. Untuk mengukur performance metrics dari model evaluasi dengan *Confusion Matix*, dapat menggunakan *accuracy*, *preciission*, dan *recall*. perhitungan manualnya menggunakan persamaan berikut :

1. *Accuracy*

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

$$Accuracy = \frac{194+183}{196+183+49+57} \times 100 \% = \frac{379}{483} \times 100 \%$$

$$= 0,78 * 100 \% = 78 \%$$

2. *Precision*

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

$$Precision = \frac{194}{194+49} = \frac{193}{243} \times 100 \%$$

$$= 0,79 * 100 \% = 79 \%$$

3. *Recall*

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


$$Recall = \frac{194}{194+57} = \frac{194}{251} \times 100 \%$$

$$= 0,77 * 100 \% = 77 \%$$

Berdasarkan perhitungan manual *Confussion Matriks* sebelum optimalisasi diatas, maka bisa disimpulkan bahwa didapati nilai *Accuracy* 78%, *Precision* 79%, dan nilai *recall* 77%.

2. Kinerja Model Sesudah Optimalisasi Dan Seleksi Atribut

Berikut adalah hasil pengujian *Confussion Matrix* sesudah dilakukan optimalisasi dan seleksi atribut seperti yang di tampilkan pada Gambar 5.2 sebagai berikut :



Gambar 5. 2 Hasil *Confussion Matrix* Sesudah Optimalisasi & Seleksi Atribut

Berdasarkan Gambar 5.2 diatas dapat dilakukan perhitungan lebih lanjut terkait Akurasi, Presisi, Dan Recall di tampilkan pada Tabel berikut :

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

Status	Precission	Recall	Fi-score	Jumlah Data
Tepat waktu	0,83	1,00	0,91	251
Tidak Tepat	1,00	0,76	0,87	232
Accuracy	0,89			483

Pada gambar 5.2 diatas, terdapat hasil nilai akurasi dari proses prediksi mahasiswa menggunakan *Confussion Matrix* setelah optimalisasi dan seleksi atribut menggunakan Metode *Feature Importance* dengan nilai akurasi sebesar 89% yang diperoleh dari data testing yang berjumlah 483 data, dengan jumlah mahasiswa tepat waktu sebanyak 262 orang, jumlah mahasiswa tidak lulus tepat waktu sebanyak 169 orang, dan jumlah mahasiswa yang seharusnya tidak lulus tepat waktu tetapi diprediksi tepat waktu sebanyak 52 orang serta jumlah mahasiswa yang seharusnya lulus tepat waktu tetapi diprediksi sebagai tidak tepat waktu sebanyak 0 orang/tidak ada. Untuk mengukur performance metrics dari model

evaluasi dengan *Confusion Matix*, dapat menggunakan *accuracy*, *preciission*, dan *recall*. perhitungan manualnya menggunakan persamaan berikut :

1. Accuracy

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

$$Accuracy = \frac{262+169}{262+169+52+0} \times 100 \% = \frac{431}{483} \times 100\%.$$

$$= 0,89 * 100 \% = 89 \%$$

2. Preciission

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

$$Preciission = \frac{262}{262+52} = \frac{262}{314} \times 100 \%.$$

$$= 0,83 * 100 \% = 83 \%$$

3. Recall

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

$$Recall = \frac{262}{262+0} = \frac{262}{262} \times 100 \%.$$

$$= 1 * 100 \% = 1 \%$$


Berdasarkan pengujian kinerja model *Decision Tree C4.5* yang dilakukan dengan 2 kali ujicoba yaitu sebelum optimilasi model didapatkan hasil akurasi sebesar 78% bagaimana dapat dilihat pada Tabel 5.1 di atas dan setelah dilakukan optimalisasi dan seleksi atribut menggunakan metode Feature Importance model didapatkan hasil akurasi sebesar 89% seperti pada Tabel 5.2 di atas dapat dilihat bahwa terjadi peningkatan akurasi sebesar 11% setelah optimalisasi model dan seleksi atribut menggunakan metode *Feature Importance* dilakukan.

5.2 Pembahasan Hasil Pemodelan

Hasil pemodelan *Decision Tree C4.5* pada klasifikasi kelulusan mahasiswa dilakukan 2 kali tahapan ujicoba yaitu pemodelan sebelum adanya optimalisasi dan sesudah optimalisasi dan seleksi atribut, mengukur kedalaman pohon dan pemangkasan pohon. Adapun hasil masing-masing ujicoba tersebut diuraikan pada pembahasan berikut.

5.2.1 Hasil Pemodelan Sebelum Optimalisasi

Hasil pemodelan *Decision Tree C4.5* sebelum dilakukan optimalisasi didapatkan hasil visualisasi pohon keputusan sebagaimana ditampilkan pada Gambar 5.3 berikut ini :



Gambar 5. 3 Visualisasi Pohon Keputusan Sebelum Optimalisasi.

Berdasarkan Gambar 5.3 di atas dapat dilihat bahwa pohon keputusan yang terbentuk belum maksimal dan masih terlalu banyak jalur keputusan yang tidak signifikan yaitu terdapat lebih dari 20 jalur keputusan, hal ini terjadi karena masih terdapat data yang tidak konsisten terhadap kelas output, sehingga untuk mengatasi masalah tersebut perlu dilakukan proses optimalisasi model.


5.2.2 Hasil Pemodelan Setelah Optimalisasi & Seleksi Atribut

Hasil pemodelan *Decision Tree C4.5* setelah dilakukan optimalisasi model terkait pemangkasan pohon, mengukur kedalaman pohon, seleksi atribut menggunakan Metode *Feature Importance*.

Pada optimalisasi pemangkasan pohon dilakukan pemangkasan pada $IPS4 > 3,75$ dijadikan kelasnya menjadi Tepat Waktu semua, untuk $IPS1$, $IPS2$, $IPS3 < 2,5$ dan $IPS4 < 2,89$ dijadikan kelasnya menjadi tidak tepat waktu.


Pada optimalisasi pengukuran kedalaman didapatkan hasil kedalaman pohon 4 yang memiliki tingkat akurasi tertinggi, sehingga nilai kedalaman ini yang digunakan dalam pemodelan *Decision Tree C4.5*.

Pada optimalisasi seleksi atribut terpilih atribut $IPS1$, $IPS2$, $IPS3$ dan $IPS4$ sesuai hasil pengukuran menggunakan metode Feature Importance berdasarkan perhitungan nilai gain tertinggi dapat dituangkan dengan Gambar 5.4 berikut ini :



Gambar 5. 4 Hasil Seleksi Atribut

Berdasarkan hasil optimalisasi dan seleksi atribut *Feature Importance* tersebut di atas dijadikan sebagai pemodelan *Decision Tree C4.5* yang digunakan dalam penelitian ini dengan hasil visualisasi pohon keputusan dapat dilihat pada Gambar 5.5 berikut ini :



Gambar 5. 5 Pohon Setelah Optimalisasi & Seleksi *Feature Importance*.

Berdasarkan Gambar 5.5 di atas dapat dilihat bahwa pohon keputusan yang terbentuk sudah lebih sederhana dan jumlah jalur atau rule keputusan yang terbentuk sisa 8 rule. Adapun jalur atau rule keputusan secara detail diuraikan pada Tabel 5.3 berikut ini :

Tabel 5. 3 Rule Keputusan.

No	RULE KEPUTUSAN
1	JIKA IPS4 $\leq$ 3,49 DAN IPS3 $\leq$ 3,49 MAKA TIDAK TEPAT
2	JIKA IPS4 $\leq$ 3,49 DAN IPS3 $\leq$ 3,49 DAN IPS4 $\leq$ 2,895 MAKA TIDAK TEPAT
3	JIKA IPS4 $\leq$ 3,49 DAN IPS3 $\leq$ 3,49 DAN IPS4 $\geq$ 2,895 DAN IPS1 $\leq$ 3,755 MAKA TEPAT WAKTU
4	JIKA IPS4 $\leq$ 3,49 DAN IPS3 $\leq$ 3,49 DAN IPS4 $\geq$ 2,895 DAN IPS1 $\geq$ 3,755 MAKA TEPAT WAKTU
5	JIKA IPS4 $\geq$ 3,49 DAN IPS4 $\leq$ 3,755 DAN IPS1 $\leq$ 2,98 MAKA TIDAK TEPAT
6	JIKA IPS4 $\geq$ 3,49 DAN IPS4 $\geq$ 3,755 DAN IPS1 $\geq$ 2,98 DAN IPS2 $\leq$ 3,785 MAKA TEPAT WAKTU
7	JIKA IPS4 $\geq$ 3,49 DAN IPS4 $\geq$ 3,755 DAN IPS1 $\geq$ 2,98 DAN IPS2 $\geq$ 3,785 MAKA TEPAT WAKTU
8	JIKA IPS4 $\geq$ 3,49 DAN IPS4 $\geq$ 3,755 MAKA TEPAT WAKTU

Berdasarkan hasil rule dari Tabel 5.3 terdapat 8 aturan yang didapatkan untuk memprediksi status kelulusan mahasiswa. Selanjutnya 8 aturan tersebut dapat digunakan sebagai kelas/kelompok untuk memprediksi mahasiswa yang lulus tepat waktu ataupun tidak tepat waktu di Universitas Ichsan gorontalo.

BAB VI

KESIMPULAN DAN SARAN

6.1 Kesimpulan

Dari hasil penelitian dengan sistem untuk mengklasifikasi kelulusan mahasiswa tepat waktu menggunakan metode *Decision Tree C4.5* pada Universitas Ichsan Gorontalo, maka pada akhir laporan penelitian ini penulis menyimpulkan bahwa :

1. Hasil penerepan algoritma *Feature Importance* dalam melakukan seleksi atribut pada klasifikasi waktu kelulusan mahasiswa didapatkan hasil dari 6 atribut terseleksi 4 atribut yang memiliki pengaruh terhadap hasil akhir klasifikasi yaitu atribut IPS1, IPS2, IPS3, dan IPS4. Serta didapatkan rule keputusan sebanyak 8 rule.
2. Penerapan algortima *Feature Importance* pada *Decision Tree C4.5* dalam klasifikasi kelulusan mahasiswa terjadi peningkatan akurasi sebesar 11%, Dimana tingkat akurasi sebelum dilakukan seleksi atribut dan optimalisasi model didapatkan hasil akurasi 78% setelah dilakukan optimalisasi dan seleksi atribut meningkat menjadi 89% .

6.2 Saran

Berdasarkan kesimpulan laporan tersebut diatas, peneliti dapat memberikan saran untuk peneliti selanjutnya, yaitu :

1. Bahwa untuk penelitian selanjutnya dapat menggunakan Metode *Fitur Selection* selain menggunakan *Metode Feature Importance* dalam mengukur tingkat akurasi.
2. Dapat mengkombinasikan *Feature Importance* dengan *fitur selection* lainnya dalam melakukan perbandingan akurasi untuk melakukan seleksi atribut dalam mengukur tingkat akurasi.

DAFTAR PUSTAKA

- [1] E. E. Barito,) Jap, T. Beng, and D. Arisandi, "Penerapan Algoritma C4.5 Untuk Klasifikasi Mahasiswa Penerima Bantuan Sosial Covid-19," *J. Ilmu Komput. dan Sist. Inf.*, 2019.
- [2] A. Andriani, "Penerapan Algoritma C4.5 Pada Program Klasifikasi," 2012.
- [3] D. Bayu Febriyanto, L. Handoko, and H. Aisyah, "Implementasi Algoritma C4.5 Untuk Klasifikasi Tingkat Kepuasan Pembeli Online Shop," 2018. [Online]. Available: <http://ejurnal.stmik-budidarma.ac.id/index.php/jurikom%7CPage%7C569>
- [4] A. Ramdani, C. Dwi Sofyan, F. Ramdani, M. F. Arya Tama, and A. Rachmatsyah, "Algoritma Klasifikasi Data Mining Untuk Memprediksi Masyarakat Dalam Menerima Bantuan Sosial," *J. Ilm. Sist. Inf.*, vol. 1, 2022.
- [5] I. Ubaedi and Y. M. Djaksana, "OPTIMASI ALGORITMA C4.5 MENGGUNAKAN METODE FORWARD SELECTION DAN STRATIFIED SAMPLING UNTUK PREDIKSI KELAYAKAN KREDIT," *Sist. Inf. |*, vol. 9, no. 1, 2022.
- [6] P. Gede Surya Cipta Nugraha and G. Surya Mahendra, "EXPLORASI ALGORITMA C4.5 DAN FORWARD FEATURE SELECTION UNTUK MENENTUKAN DEBITUR BAIK DAN DEBITUR BERMASALAH PADA PRODUK KREDIT TANPA AGUNAN (KTA)".
- [7] M. Yunus, H. Ramadhan, D. R. Aji, and A. Yulianto, "Penerapan Metode Data Mining C4.5 Untuk Pemilihan Penerima Kartu Indonesia Pintar (KIP)," *Paradig. - J. Komput. dan Inform.*, vol. 23, no. 2, Oct. 2021, doi: 10.31294/p.v23i2.11395.
- [8] S. Badriah *et al.*, "JIP (Jurnal Informatika Polinema) Klasifikasi Algoritma C4.5 dalam Menentukan Penerima Bantuan Covid-19 (Studi Kasus: Desa di

- Karawang),” *JIP (Jurnal Inform. Polinema)* , vol. 7, 2021.
- [9] D. A. N. Wulan and S. M. Abdullah, “Prokrastinasi Akademik Dalam Penyelesaian Skripsi,” *J. Sosio-Humaniora*, vol. 5, 2014.
 - [10] Y. Mardi, “Klasifikasi Menggunakan Algoritma C4.5,” *J. Edik Inform.*, 2019.
 - [11] A. Fahlevi, “Proses Data Mining KDD,” *Binus*, Oct. 11, 2021. <https://sis.binus.ac.id/2021/09/30/proses-data-mining-kdd/> (accessed Oct. 11, 2023).
 - [12] R. Yendra *et al.*, “Klasifikasi Data Mining Untuk Seleksi Penerimaan Calon Pegawai Negeri Sipil Tahun 2017 Menggunakan Metode Naïve Bayes,” *J. Sains Mat. dan Stat.*, vol. 6, no. 1, 2020.
 - [13] N. Azwanti, “Algoritma C4.5 Untuk Memprediksi Mahasiswa Yang Mengukang Mata Kuliah (Studi Kasus Di AMIK Labuhan Batu),” *J. SIMETRIS*, vol. 9, no. 1, 2018.
 - [14] A. Husnah Nasrullah, “PENERAPAN METODE C4.5 UNTUK KLASIFIKASI MAHASISWABERPOTENSI DROP OUT,” 2018.
 - [15] G. Arther Sandag, “Prediksi Rating Aplikasi App Store Menggunakan Algoritma Random Forest Application Rating Prediction on App Store using Random Forest Algorithm,” *Cogito Smart J. |*, vol. 6, no. 2, 2020, [Online]. Available: <https://www.kaggle.com/>
 - [16] M. Riziq sirfatullah Alfarizi, M. Zidan Al-farish, M. Taufiqurrahman, G. Ardiansah, and M. Elgar, “Penggunaan Python Sebagai Bahasa Pemrograman Untuk Machine Learning dan Deep Learning,” 2023.
 - [17] M. Fluorida Fibrianda and A. Bhawiyuga, “Analisis Perbandingan Akurasi Deteksi Serangan Pada Jaringan Komputer Dengan Metode Naïve Bayes Dan Support Vector Machine (SVM),” 2018. [Online]. Available: <http://j-ptiik.ub.ac.id>

LAMPIRAN DATASET

NO	JK	Kelas	IPS1	IPS2	IPS3	IPS4	Status
1	P	R	3,64	3,64	3,58	3,36	Tidak Tepat
2	P	R	3,36	3,36	3,37	2,18	Tidak Tepat
3	P	R	4	4	4	3,73	Tepat Waktu
4	L	R	3,73	3,73	3,58	3,45	Tidak Tepat
5	L	R	3,4	3,4	2,53	2,05	Tidak Tepat
6	P	N	3,36	3,36	2,63	2,83	Tidak Tepat
7	L	R	3,59	3,59	3,79	3,23	Tidak Tepat
8	P	R	3,64	3,64	3,89	3,32	Tidak Tepat
9	P	N	3,5	3,5	3,47	3,23	Tidak Tepat
10	L	N	4	4	4	4	Tepat Waktu
11	L	N	3,86	3,86	4	3,86	Tepat Waktu
12	P	N	3,86	3,86	3,26	3,5	Tepat Waktu
13	P	N	3,86	3,86	3,26	3,32	Tidak Tepat
14	L	R	3,73	3,73	3,79	3,45	Tepat Waktu
15	P	N	3,64	3,64	3,58	3,36	Tepat Waktu
16	L	N	3,77	3,77	3,74	2,77	Tidak Tepat
17	L	R	3,64	3,64	3,58	3,05	Tepat Waktu
18	P	N	3,64	3,64	3,74	3,45	Tidak Tepat
19	P	N	3,73	3,73	3,58	3,18	Tepat Waktu
20	P	N	3,86	3,86	3,68	3,36	Tepat Waktu
21	P	N	3,64	3,64	3,58	3,23	Tidak Tepat
22	L	N	3,5	3,5	3,63	3,32	Tidak Tepat
23	L	R	3,64	3,64	3,47	2,82	Tidak Tepat
24	L	N	3,86	3,86	4	3,86	Tidak Tepat
25	P	N	3,5	3,5	3,58	3,09	Tepat Waktu
26	L	N	3,86	3,86	3,84	3,59	Tepat Waktu
27	P	R	3,91	3,91	3,89	3,18	Tidak Tepat
28	P	R	4	4	4	3,86	Tepat Waktu
29	P	R	3,77	3,77	3,89	3,32	Tidak Tepat
30	P	R	3,77	3,77	3,79	3,23	Tidak Tepat
31	P	R	3,91	3,91	3,79	3,73	Tepat Waktu
32	P	R	3,91	3,91	4	3,14	Tepat Waktu
33	L	N	3,73	3,73	3,84	3,59	Tepat Waktu
34	L	R	4	4	4	3,73	Tepat Waktu
35	P	R	3,77	3,77	3,79	3	Tepat Waktu
36	P	R	3,86	3,86	4	3,45	Tepat Waktu
37	L	R	3,86	3,86	3,74	3,18	Tepat Waktu
38	L	R	3,64	3,64	4	3,45	Tepat Waktu
39	P	R	3,91	3,91	3,89	3,45	Tidak Tepat
40	P	R	3,86	3,86	3,89	3,14	Tidak Tepat
41	L	R	3,77	3,77	4	3,45	Tidak Tepat
42	L	R	3,5	3,5	3,47	2,32	Tidak Tepat
43	P	R	3,77	3,77	3,74	3,45	Tepat Waktu
44	P	R	4	4	4	3,23	Tepat Waktu
45	P	R	3,73	3,73	3,89	3,32	Tidak Tepat
46	P	R	3,77	3,77	3,89	3,32	Tepat Waktu
47	L	R	3,73	3,73	4	3,32	Tidak Tepat

48	P	N	3,73	3,73	4	3,73	Tidak Tepat
49	L	R	3,73	3,73	3,84	3,32	Tidak Tepat
50	L	R	3,5	3,5	4	2,86	Tidak Tepat
51	P	R	3,73	3,73	3,89	3,32	Tepat Waktu
52	P	R	3,77	3,77	3,89	3,36	Tepat Waktu
53	L	R	3,77	3,77	3,84	3,59	Tidak Tepat
54	P	R	3,91	3,91	3,89	3,32	Tidak Tepat
55	P	R	3,86	3,86	4	3,59	Tepat Waktu
56	P	R	3,77	3,77	4	3,45	Tepat Waktu
57	L	R	2,73	2,73	2,58	1,17	Tidak Tepat
58	P	R	3,86	3,86	4	4	Tepat Waktu
59	P	R	3,86	3,86	4	3,86	Tepat Waktu
60	P	R	3,86	3,86	4	3,86	Tepat Waktu
61	P	R	3,73	3,73	4	3,86	Tepat Waktu
62	P	R	3,86	3,86	3,89	3,86	Tepat Waktu
63	P	N	3,86	3,86	4	4	Tepat Waktu
64	L	N	4	4	3,74	3,86	Tepat Waktu
65	L	R	4	4	4	3,86	Tepat Waktu
66	P	N	4	4	4	3,86	Tepat Waktu
67	P	N	3,59	3,59	3,84	3,86	Tidak Tepat
68	P	R	3,91	3,91	3,74	3,45	Tepat Waktu
69	P	R	3,77	3,77	4	3,59	Tepat Waktu
70	P	R	4	4	3,42	3,68	Tepat Waktu
71	P	R	3,86	3,86	3,42	3,55	Tepat Waktu
72	P	R	3,73	3,73	3,42	3,55	Tepat Waktu
73	P	R	3,86	3,86	3,42	3,55	Tepat Waktu
74	P	R	3,86	3,86	3,32	3,55	Tepat Waktu
75	P	R	3,86	3,86	3,32	3,55	Tepat Waktu
76	L	R	3,86	3,86	2,95	3,21	Tidak Tepat
77	L	R	3,86	3,86	3,53	3,41	Tepat Waktu
78	P	R	3,86	3,86	3,84	3,68	Tepat Waktu
79	L	N	3,86	3,86	3,47	3,27	Tidak Tepat
80	P	N	3,86	3,86	3,42	3,55	Tepat Waktu
81	P	N	3,86	3,86	3,32	3,55	Tepat Waktu
82	P	N	3,77	3,77	3,21	3,41	Tidak Tepat
83	P	N	3,86	3,86	3,58	3,55	Tepat Waktu
84	P	N	3,86	3,86	3,21	3,55	Tepat Waktu
85	L	N	4	4	3,26	3,55	Tepat Waktu
86	P	N	3,77	3,77	3,32	3,41	Tidak Tepat
87	P	R	3,64	3,64	4	3,18	Tepat Waktu
88	P	R	4	4	4	3,45	Tidak Tepat
89	P	R	4	4	3,89	3,73	Tidak Tepat
90	P	R	3,86	3,86	3,63	4	Tepat Waktu
91	P	R	3,64	3,64	3,89	3,32	Tepat Waktu
92	P	R	4	4	4	3,59	Tepat Waktu
93	P	N	3,77	3,77	3,53	3,45	Tepat Waktu
94	P	N	3,36	3,36	3,47	2,86	Tidak Tepat
95	L	R	4	4	3,58	3,59	Tepat Waktu
96	L	N	2,32	2,32	3,35	3,63	Tidak Tepat
97	P	N	3,57	3,57	3,75	3,63	Tepat Waktu

98	P	R	3,14	3,14	3,38	3	Tidak Tepat
99	P	N	3,86	3,86	4	3,88	Tidak Tepat
100	L	N	3,83	3,83	3,13	3,13	Tidak Tepat
101	L	N	4	4	3,75	3,5	Tidak Tepat
102	L	R	3,29	3,29	3,38	2,75	Tidak Tepat
103	P	R	3,14	3,14	3,88	3,25	Tidak Tepat
104	P	R	3,29	3,29	4	3	Tidak Tepat
105	P	R	3,71	3,71	3,5	3,25	Tepat Waktu
106	L	R	3,71	3,71	3,75	2,88	Tepat Waktu
107	P	R	3,14	3,14	3,75	3,38	Tepat Waktu
108	P	R	3,86	3,86	3,88	3,5	Tidak Tepat
109	P	R	3,57	3,57	3,75	3,13	Tepat Waktu
110	P	R	3,71	3,71	3,88	3,38	Tidak Tepat
111	L	R	3,71	3,71	3,75	3	Tepat Waktu
112	P	N	3,71	3,71	3,63	3,25	Tidak Tepat
113	P	N	3,57	3,57	3,75	3,63	Tidak Tepat
114	L	N	3,29	3,29	3	1,71	Tidak Tepat
115	L	N	3,71	3,71	3,5	3,38	Tidak Tepat
116	L	N	3,71	3,71	3,5	3,38	Tidak Tepat
117	P	R	3,43	3,43	4	3,38	Tidak Tepat
118	L	N	3,71	3,71	3,88	3,5	Tidak Tepat
119	P	N	3,43	3,43	3,75	3,63	Tepat Waktu
120	L	N	4	4	3,75	3,5	Tidak Tepat
121	L	N	2,71	2,71	2,63	2,67	Tidak Tepat
122	P	N	4	4	3,88	3,63	Tepat Waktu
123	P	N	3,71	3,71	3,88	3,63	Tidak Tepat
124	P	N	3,43	3,43	3,63	3	Tidak Tepat
125	L	N	3,29	3,29	3,38	2,38	Tidak Tepat
126	P	N	3,29	3,29	3,38	3	Tidak Tepat
127	P	N	3,29	3,29	3,5	3,38	Tidak Tepat
128	P	N	3,86	3,86	3,63	3	Tepat Waktu
129	L	N	3,14	3,14	3,5	3,13	Tidak Tepat
130	L	N	3	3	3,75	2,88	Tidak Tepat
131	P	R	3,71	3,71	3,88	3,13	Tidak Tepat
132	P	R	4	4	4	3,75	Tepat Waktu
133	P	R	3,86	3,86	4	3,5	Tidak Tepat
134	P	R	3,86	3,86	4	3,38	Tepat Waktu
135	P	R	3,71	3,71	3,63	3	Tidak Tepat
136	L	N	3,86	3,86	3,5	3,25	Tidak Tepat
137	P	R	3,57	3,57	3,75	3,88	Tepat Waktu
138	P	R	3,86	3,86	3,75	3,88	Tepat Waktu
139	L	N	3,71	3,71	3,88	3,75	Tepat Waktu
140	L	N	3,71	3,71	3,75	3,25	Tidak Tepat
141	P	R	3,71	3,71	3,88	3,5	Tidak Tepat
142	P	R	4	4	4	3,88	Tidak Tepat
143	L	R	4	4	4	3,75	Tepat Waktu
144	P	N	3,86	3,86	3,63	3,75	Tidak Tepat
145	L	N	3,86	3,86	3,88	2	Tidak Tepat
146	P	R	3,71	3,71	4	3,75	Tepat Waktu
147	L	N	2,17	2,17	3,25	2,88	Tidak Tepat

148	L	N	3,43	3,43	3,75	3,5	Tidak Tepat
149	L	N	3,57	3,57	3,75	3,88	Tepat Waktu
150	P	R	3,71	3,71	3,88	3,88	Tepat Waktu
151	P	R	3,57	3,57	3,88	3,38	Tepat Waktu
152	P	R	3,43	3,43	3,5	3,5	Tepat Waktu
153	L	R	3,14	3,14	3,5	3,38	Tidak Tepat
154	L	R	3,29	3,29	2,75	2,83	Tidak Tepat
155	P	N	3,43	3,43	3,63	3,5	Tidak Tepat
156	P	N	3,57	3,57	3,63	3,13	Tidak Tepat
157	L	R	3,57	3,57	3,75	3,13	Tidak Tepat
158	L	N	3,5	3,5	3,25	3,13	Tidak Tepat
159	P	N	2,86	2,86	3	2,17	Tidak Tepat
160	P	N	3,29	3,29	2,13	3,5	Tidak Tepat
161	L	R	4	4	3,88	3,5	Tepat Waktu
162	L	N	4	4	4	3,75	Tepat Waktu
163	L	R	3,29	3,29	3,5	3,38	Tidak Tepat
164	P	N	2,29	2,29	3	2,25	Tidak Tepat
165	L	R	3,71	3,71	4	3,63	Tidak Tepat
166	P	R	3,86	3,86	4	4	Tepat Waktu
167	P	N	4	4	3,75	3,88	Tepat Waktu
168	P	R	3,71	3,71	4	4	Tepat Waktu
169	P	R	3,86	3,86	4	4	Tepat Waktu
170	P	R	3,86	3,86	4	4	Tepat Waktu
171	L	R	4	4	4	4	Tepat Waktu
172	P	R	3,86	3,86	3,88	4	Tepat Waktu
173	L	R	3,86	3,86	4	4	Tepat Waktu
174	P	R	3,86	3,86	4	4	Tepat Waktu
175	P	N	3,86	3,86	3,25	3,63	Tepat Waktu
176	P	R	3,71	3,71	3,88	4	Tepat Waktu
177	P	N	3,86	3,86	3,88	4	Tepat Waktu
178	P	R	3,71	3,71	3,75	4	Tepat Waktu
179	P	N	3,29	3,29	3,25	3,75	Tepat Waktu
180	L	R	4	4	4	4	Tepat Waktu
181	P	R	3,57	3,57	3,5	3,25	Tidak Tepat
182	P	R	3,86	3,86	4	3,5	Tidak Tepat
183	P	N	3,57	3,57	3,13	2,17	Tidak Tepat
184	L	N	3,86	3,86	4	4	Tepat Waktu
185	P	R	3,71	3,71	4	3,75	Tidak Tepat
186	P	R	3,71	3,71	4	3,63	Tepat Waktu
187	P	N	3,86	3,86	3,88	3,75	Tidak Tepat
188	P	N	3,29	3,29	3,75	3,5	Tidak Tepat
189	P	R	3,71	3,71	4	3,63	Tepat Waktu
190	P	N	3,71	3,71	3,88	3,5	Tepat Waktu
191	L	N	3,57	3,57	2,13	2,6	Tidak Tepat
192	L	N	4	4	4	4	Tepat Waktu
193	L	R	3,29	3,29	4	3,5	Tepat Waktu
194	P	N	4	4	3,89	3,3	Tepat Waktu
195	L	N	4	4	3,47	3,35	Tidak Tepat
196	L	R	3,19	3,19	2,26	2,6	Tidak Tepat
197	P	N	4	4	3,58	3,61	Tepat Waktu

198	L	R	2,58	2,58	3,11	2,29	Tidak Tepat
199	L	N	3,67	3,67	3,26	2,83	Tidak Tepat
200	L	N	3,33	3,33	2,79	3,32	Tidak Tepat
201	P	R	3,86	3,86	3,89	3,83	Tepat Waktu
202	L	R	4	4	3,68	3,83	Tepat Waktu
203	L	N	3,9	3,9	3,58	3,65	Tidak Tepat
204	P	R	4	4	4	4	Tepat Waktu
205	L	N	3,71	3,71	3,58	3,35	Tidak Tepat
206	L	R	3,76	3,76	3,26	3,35	Tidak Tepat
207	P	N	3,9	3,9	3,58	3,83	Tepat Waktu
208	P	N	3,62	3,62	3,79	3,83	Tepat Waktu
209	L	R	3,81	3,81	3,79	3,7	Tepat Waktu
210	L	N	4	4	3,58	3,74	Tepat Waktu
211	L	R	3,71	3,71	3,16	3,47	Tidak Tepat
212	L	N	3,14	3,14	3,11	2,91	Tidak Tepat
213	L	N	3,33	3,33	3,58	3,09	Tidak Tepat
214	L	N	2,86	2,86	3	3,17	Tidak Tepat
215	L	N	3,33	3,33	3,16	3,21	Tidak Tepat
216	L	N	3,81	3,81	4	3,43	Tepat Waktu
217	P	N	3,67	3,67	4	3,83	Tepat Waktu
218	L	N	3,48	3,48	3,16	3,52	Tepat Waktu
219	L	N	3,9	3,9	3,37	3,17	Tidak Tepat
220	P	N	3,24	3,24	2,89	3,11	Tidak Tepat
221	P	N	3,86	3,86	3,68	3,43	Tepat Waktu
222	P	N	3,76	3,76	3,26	3,43	Tidak Tepat
223	L	N	4	4	3,68	3,43	Tepat Waktu
224	P	N	3,57	3,57	3,37	3,26	Tidak Tepat
225	L	N	3	3	3,58	3,61	Tidak Tepat
226	L	N	3,52	3,52	3,79	3,19	Tidak Tepat
227	L	N	3,19	3,19	3,68	3,24	Tidak Tepat
228	L	N	3,76	3,76	3,58	3,61	Tepat Waktu
229	L	N	3,9	3,9	4	3,83	Tepat Waktu
230	P	R	3,33	3,33	3,16	3,39	Tidak Tepat
231	P	N	4	4	3,89	3,35	Tepat Waktu
232	L	N	3,19	3,19	3,11	3,17	Tidak Tepat
233	L	R	3,76	3,76	3,68	3,74	Tidak Tepat
234	L	R	3,81	3,81	2,89	3,17	Tidak Tepat
235	P	N	3,62	3,62	3,05	3,17	Tidak Tepat
236	L	R	3,9	3,9	3,89	3,83	Tepat Waktu
237	L	R	4	4	3,79	3,83	Tepat Waktu
238	P	R	3,62	3,62	3,47	3,39	Tidak Tepat
239	P	R	4	4	3,68	3,83	Tepat Waktu
240	L	R	3,81	3,81	3,68	3,52	Tepat Waktu
241	L	N	3,76	3,76	3,37	3,26	Tidak Tepat
242	L	R	3,48	3,48	3,26	2,83	Tidak Tepat
243	L	R	4	4	3,79	3,7	Tepat Waktu
244	L	R	4	4	2,89	3,47	Tidak Tepat
245	L	R	3,9	3,9	3,58	3,35	Tepat Waktu
246	L	R	3,57	3,57	3,68	3,52	Tidak Tepat
247	L	N	3,43	3,43	4	3,83	Tepat Waktu

248	L	N	3,57	3,57	3,47	3,52	Tidak Tepat
249	L	R	3,29	3,29	2,05	2,67	Tidak Tepat
250	L	N	3,52	3,52	3,26	3,52	Tidak Tepat
251	P	N	3,52	3,52	3,68	3,74	Tepat Waktu
252	L	R	4	4	3,79	3,43	Tidak Tepat
253	L	R	4	4	3,26	3,52	Tepat Waktu
254	P	R	3,52	3,52	2,89	3	Tidak Tepat
255	L	R	3,81	3,81	3,42	4	Tidak Tepat
256	L	R	4	4	3,16	2,04	Tidak Tepat
257	L	N	3,86	3,86	4	3,83	Tepat Waktu
258	L	R	3,67	3,67	3,05	2,7	Tidak Tepat
259	L	N	3,62	3,62	4	3,74	Tidak Tepat
260	P	N	3,57	3,57	3,89	4	Tidak Tepat
261	P	R	3,9	3,9	3,79	3,7	Tidak Tepat
262	P	N	3,86	3,86	3,79	2,91	Tepat Waktu
263	P	R	4	4	4	3,91	Tepat Waktu
264	P	R	3,67	3,67	3,89	3,57	Tidak Tepat
265	L	N	3,52	3,52	3,11	3,83	Tidak Tepat
266	L	R	4	4	2,42	3,47	Tidak Tepat
267	L	N	4	4	3,16	3,17	Tidak Tepat
268	L	N	3,71	3,71	3,16	2,91	Tidak Tepat
269	L	R	3,05	3,05	2,43	2,78	Tidak Tepat
270	L	N	3,33	3,33	1,89	3,17	Tidak Tepat
271	L	N	3,71	3,71	3,16	3,52	Tidak Tepat
272	L	N	3,71	3,71	3,32	3,87	Tepat Waktu
273	L	N	3,81	3,81	3,21	3,83	Tepat Waktu
274	P	R	3,86	3,86	3,79	3,83	Tepat Waktu
275	L	N	3,19	3,19	3,16	3,61	Tepat Waktu
276	L	R	3,62	3,62	2,63	3,6	Tidak Tepat
277	L	R	3,62	3,62	3,89	3,83	Tepat Waktu
278	P	R	4	4	4	4	Tepat Waktu
279	L	R	3,62	3,62	2,84	3,71	Tepat Waktu
280	P	R	4	4	4	4	Tepat Waktu
281	P	R	4	4	4	4	Tepat Waktu
282	L	N	3,52	3,52	3,53	3,26	Tepat Waktu
283	P	R	4	4	4	4	Tepat Waktu
284	L	N	3,14	3,14	3,53	3,57	Tepat Waktu
285	P	N	3,9	3,9	4	4	Tepat Waktu
286	L	R	3,62	3,62	4	4	Tepat Waktu
287	P	N	3,71	3,71	3,89	4	Tepat Waktu
288	P	R	4	4	4	4	Tepat Waktu
289	L	N	3,9	3,9	3,84	3,65	Tepat Waktu
290	L	N	4	4	4	4	Tepat Waktu
291	L	N	3,86	3,86	3,89	4	Tepat Waktu
292	L	R	3,48	3,48	3,74	4	Tepat Waktu
293	L	R	3,71	3,71	4	4	Tepat Waktu
294	L	N	3,62	3,62	3,42	3,39	Tidak Tepat
295	L	N	3,38	3,38	3,74	3,17	Tepat Waktu
296	L	N	3,76	3,76	3,79	3,65	Tepat Waktu

298	L	N	3,67	3,67	3,21	3,17	Tidak Tepat
299	L	N	3,1	3,1	3,37	3	Tidak Tepat
300	P	N	3,9	3,9	4	3,87	Tepat Waktu
301	P	R	4	4	3,68	3,87	Tepat Waktu
302	L	R	3,38	3,38	3,32	3,61	Tepat Waktu
303	L	R	3,9	3,9	3,84	3,61	Tepat Waktu
304	P	N	4	4	3,89	4	Tepat Waktu
305	L	R	3,9	3,9	4	4	Tepat Waktu
306	L	N	4	4	3,32	4	Tepat Waktu
307	L	N	3,62	3,62	3,47	3,78	Tepat Waktu
308	L	N	3,33	3,33	3,05	2,7	Tidak Tepat
309	P	N	3,57	3,57	2,32	1,24	Tidak Tepat
310	L	N	3,76	3,76	3,32	3,09	Tidak Tepat
311	L	R	4	4	3,74	3,78	Tepat Waktu
312	P	N	3,9	3,9	3,79	3,87	Tepat Waktu
313	P	R	3,76	3,76	3,89	3,87	Tepat Waktu
314	L	R	3,76	3,76	3,89	3,78	Tepat Waktu
315	L	N	4	4	3,32	3,7	Tepat Waktu
316	L	N	3,19	3,19	3,47	3	Tidak Tepat
317	L	R	3,48	3,48	3,32	3,87	Tepat Waktu
318	L	N	3,9	3,9	4	4	Tepat Waktu
319	L	N	3,9	3,9	3,32	3,91	Tepat Waktu
320	L	N	3,9	3,9	3,74	3,61	Tepat Waktu
321	L	R	3,71	3,71	3,68	3,26	Tidak Tepat
322	L	R	4	4	3,68	3,91	Tepat Waktu
323	L	R	3,57	3,57	3,68	4	Tepat Waktu
324	P	R	4	4	3,68	4	Tepat Waktu
325	L	R	4	4	3,68	3,91	Tepat Waktu
326	L	N	3,43	3,43	3,68	3,74	Tepat Waktu
327	L	N	3,86	3,86	3,68	4	Tepat Waktu
328	L	N	4	4	3,68	3,52	Tepat Waktu
329	L	N	3,81	3,81	2,63	3,75	Tepat Waktu
330	P	N	4	4	3,68	3,43	Tepat Waktu
331	L	N	3,29	3,29	3,68	3,35	Tepat Waktu
332	L	N	3,14	3,14	3,68	3,35	Tepat Waktu
333	L	N	3,29	3,29	3,26	3	Tidak Tepat
334	P	N	4	4	3,89	3,87	Tidak Tepat
335	L	N	3,67	3,67	3,58	3,26	Tidak Tepat
336	L	N	3,9	3,9	4	4	Tepat Waktu
337	L	R	3,05	3,05	3,63	3,87	Tepat Waktu
338	L	R	3,67	3,67	3,16	2,96	Tidak Tepat
339	P	R	3,67	3,67	3,58	3,7	Tepat Waktu

340	P	N	3,86	3,86	3,68	4	Tepat Waktu
341	L	N	3,14	3,14	3,11	3	Tidak Tepat
342	L	R	3,76	3,76	3,58	3,65	Tepat Waktu
343	P	N	4	4	3,68	3,91	Tidak Tepat
344	L	N	3,62	3,62	3,11	2,74	Tidak Tepat
345	L	N	3,62	3,62	3,53	3,3	Tepat Waktu
346	L	N	4	4	3,68	3,52	Tepat Waktu
347	P	N	2,95	2,95	2,04	3,33	Tidak Tepat
348	L	N	1,43	1,43	3,21	3,04	Tidak Tepat
349	P	N	3,86	3,86	4	4	Tepat Waktu
350	L	N	3,52	3,52	2,42	2,33	Tidak Tepat
351	L	R	3,57	3,57	2,32	2,6	Tidak Tepat
352	P	N	3,43	3,43	3,16	3,17	Tidak Tepat
353	P	N	3,48	3,48	3,68	4	Tepat Waktu
354	L	N	4	4	3,89	4	Tepat Waktu
355	P	N	2,43	2,43	3,16	3,35	Tidak Tepat
356	P	N	2,9	2,9	3,16	3,35	Tidak Tepat
357	L	N	3,52	3,52	3,63	3,83	Tepat Waktu
358	L	N	3,76	3,76	3,68	3,83	Tepat Waktu
359	L	N	3,71	3,71	3,58	3,74	Tepat Waktu
360	P	R	3,81	3,81	3,58	3,61	Tidak Tepat
361	L	N	3,9	3,9	3,6	3,83	Tepat Waktu
362	L	N	3,76	3,76	3,65	3,33	Tepat Waktu
363	L	R	3,52	3,52	3,7	2,71	Tidak Tepat
364	L	N	3,76	3,76	3,65	3,38	Tepat Waktu
365	L	R	3,9	3,9	3,8	3,91	Tepat Waktu
366	L	N	3,9	3,9	3,75	3,79	Tepat Waktu
367	L	R	3,24	3,24	3,33	2,35	Tidak Tepat
368	L	N	3,48	3,48	3,5	3,25	Tepat Waktu
369	L	N	3,48	3,48	3,65	3,33	Tepat Waktu
370	L	N	3,24	3,24	3,5	3,17	Tepat Waktu
371	L	N	3,52	3,52	3,55	3,46	Tidak Tepat
372	P	R	3,81	3,81	3,8	3,67	Tepat Waktu
373	L	R	3,67	3,67	3,65	2,71	Tidak Tepat
374	L	R	3,29	3,29	3,25	3,08	Tidak Tepat
375	P	R	3,43	3,43	3,6	3,54	Tidak Tepat
376	L	R	3,38	3,38	2,8	3	Tidak Tepat
377	L	R	3,67	3,67	3,35	3,42	Tidak Tepat
378	P	R	3,43	3,43	3,8	3,38	Tidak Tepat
379	L	R	3,81	3,81	3,75	3,75	Tepat Waktu
380	L	R	3,67	3,67	3,55	3,63	Tepat Waktu
381	P	R	3,52	3,52	3,55	3,25	Tidak Tepat
382	L	N	3,29	3,29	3,1	3,13	Tidak Tepat
383	L	R	3,14	3,14	2,65	2,7	Tidak Tepat

384	L	R	4	4	4	3,67	Tepat Waktu
385	P	R	4	4	3,55	3,71	Tepat Waktu
386	P	R	4	4	3,55	4	Tepat Waktu
387	L	R	3,86	3,86	3,7	3,71	Tepat Waktu
388	L	R	3,86	3,86	4	3,63	Tepat Waktu
389	L	R	4	4	4	3,88	Tepat Waktu
390	P	N	4	4	3,55	3,88	Tepat Waktu
391	P	R	3,43	3,43	4	3,79	Tidak Tepat
392	P	N	4	4	4	3,88	Tepat Waktu
393	L	R	3,67	3,67	3,8	2,71	Tidak Tepat
394	L	R	3,67	3,67	3,9	2,5	Tidak Tepat
395	P	R	3,9	3,9	4	3,33	Tepat Waktu
396	L	R	3,86	3,86	3,85	3,21	Tepat Waktu
397	P	R	4	4	3,85	3,46	Tepat Waktu
398	L	R	3,9	3,9	3,85	2,75	Tidak Tepat
399	L	N	3,62	3,62	3,75	2,38	Tidak Tepat
400	P	N	3,33	3,33	3,1	1,88	Tidak Tepat
401	P	N	3,48	3,48	3,7	3,33	Tepat Waktu
402	P	N	3,48	3,48	3,5	2,71	Tidak Tepat
403	P	N	3,9	3,9	3,75	2,83	Tidak Tepat
404	L	N	3,81	3,81	2,15	2,06	Tidak Tepat
405	P	R	3,9	3,9	3,8	3,92	Tepat Waktu
406	L	N	3,57	3,57	3,9	3,58	Tepat Waktu
407	P	N	3,57	3,57	3,5	2,63	Tepat Waktu
408	L	N	3,48	3,48	3,2	2,63	Tidak Tepat
409	P	N	3,62	3,62	3,75	2,83	Tepat Waktu
410	P	N	3,84	3,84	3,85	4	Tepat Waktu
411	L	R	3,21	3,21	3,15	3,65	Tidak Tepat
412	P	R	3,89	3,89	3,85	4	Tepat Waktu
413	L	R	3,26	3,26	2,5	2	Tidak Tepat
414	L	N	3,11	3,11	4	3,17	Tidak Tepat
415	L	R	3,89	3,89	4	4	Tepat Waktu
416	P	R	3,26	3,26	3,5	3,65	Tidak Tepat
417	L	R	3,89	3,89	3,35	3,65	Tidak Tepat
418	L	N	3,74	3,74	3,4	3,65	Tidak Tepat
419	P	R	3,58	3,58	3,85	3,87	Tepat Waktu
420	P	R	3,74	3,74	3,7	4	Tidak Tepat
421	L	R	3,21	3,21	3,2	3,74	Tidak Tepat
422	P	R	3,53	3,53	3,6	4	Tepat Waktu
423	L	R	3,37	3,37	3,35	3,78	Tidak Tepat
424	P	R	3,74	3,74	4	4	Tepat Waktu
425	P	R	3,74	3,74	3,7	3,78	Tepat Waktu
426	L	R	3,74	3,74	3,35	3,74	Tidak Tepat
427	P	R	3,89	3,89	3,65	3,91	Tepat Waktu

428	P	R	3,37	3,37	3,2	3,78	Tidak Tepat
429	L	R	3,37	3,37	3,3	3,09	Tidak Tepat
430	P	R	3,63	3,63	3,45	3,83	Tepat Waktu
431	L	R	3,58	3,58	3,6	3,87	Tidak Tepat
432	P	R	3,58	3,58	3,6	3,52	Tepat Waktu
433	L	R	1,91	1,91	2,55	2,73	Tidak Tepat
434	L	R	3	3	1,2	3,36	Tidak Tepat
435	L	R	3,32	3,32	2,6	2,35	Tidak Tepat
436	L	R	3,47	3,47	3,41	2,78	Tidak Tepat
437	L	R	3,11	3,11	3,39	3,91	Tepat Waktu
438	L	R	3,89	3,89	3,5	3,92	Tepat Waktu
439	L	R	4	4	3,83	3,92	Tepat Waktu
440	P	R	4	4	3,67	4	Tepat Waktu
441	L	R	3,84	3,84	3,39	4	Tepat Waktu
442	L	R	3,26	3,26	3,11	3,33	Tidak Tepat
443	P	R	3,89	3,89	3,67	3,42	Tepat Waktu
444	L	R	3	3	3,11	1,95	Tidak Tepat
445	L	R	3,63	3,63	3,11	3,25	Tidak Tepat
446	L	N	3,47	3,47	3,1	3,26	Tidak Tepat
447	L	R	2,82	2,82	3	1,65	Tidak Tepat
448	P	R	3,26	3,26	3,45	3,52	Tepat Waktu
449	P	N	3,89	3,89	3,85	4	Tepat Waktu
450	L	N	3,53	3,53	3,8	4	Tepat Waktu
451	P	R	3,63	3,63	3,5	3,7	Tepat Waktu
452	P	N	3,74	3,74	3,4	3,39	Tidak Tepat
453	L	N	3,53	3,53	2,7	3,2	Tidak Tepat
454	L	N	3,74	3,74	3,75	4	Tepat Waktu
455	P	N	3,53	3,53	3,05	3,3	Tidak Tepat
456	P	N	3,63	3,63	3,65	4	Tepat Waktu
457	L	N	3,11	3,11	3,45	3,91	Tepat Waktu
458	P	R	3,89	3,89	3,75	4	Tidak Tepat
459	P	R	3,89	3,89	3,9	3,78	Tepat Waktu
460	L	N	3,42	3,42	3	2,05	Tidak Tepat
461	L	R	3,63	3,63	4	4	Tepat Waktu
462	L	R	3,57	3,57	3,65	3,04	Tidak Tepat
463	L	R	3,43	3,43	3,15	2,87	Tidak Tepat
464	L	R	3,37	3,37	2,55	2,39	Tidak Tepat
465	P	R	3,9	3,9	3,8	3,48	Tepat Waktu
466	P	N	4	4	3,55	3,74	Tepat Waktu
467	L	N	3,57	3,57	3,04	3,67	Tidak Tepat
468	P	R	3,9	3,9	3,43	3,35	Tidak Tepat
469	L	R	3,24	3,24	2,75	2,28	Tidak Tepat
470	L	R	3,14	3,14	3,1	2,72	Tidak Tepat
471	L	R	3,9	3,9	3,7	3,78	Tepat Waktu

472	L	R	4	4	3,7	3,91	Tepat Waktu
473	P	R	4	4	3,85	3,91	Tepat Waktu
474	L	N	3,57	3,57	2,45	2,33	Tidak Tepat
475	P	R	3,57	3,57	4	3,7	Tepat Waktu
476	P	R	3,48	3,48	3,6	3,43	Tepat Waktu
477	P	N	3,76	3,76	3,75	3,13	Tepat Waktu
478	P	N	3,57	3,57	3,9	4	Tepat Waktu
479	P	R	3,57	3,57	3,4	3,91	Tepat Waktu
480	P	N	4	4	4	3,78	Tepat Waktu
481	L	R	3,54	3,54	3,29	3,65	Tepat Waktu
482	L	R	3,13	3,13	2,83	2,05	Tidak Tepat
483	P	R	3,46	3,46	3,63	3,48	Tepat Waktu
484	P	N	3,92	3,92	3,33	4	Tepat Waktu
485	L	R	3,71	3,71	3,25	2,85	Tidak Tepat
486	P	N	3,88	3,88	3,33	3,87	Tepat Waktu
487	L	N	3,67	3,67	3,67	4	Tepat Waktu
488	L	R	3,67	3,67	3,88	4	Tepat Waktu
489	P	R	3,54	3,54	3,46	2,83	Tidak Tepat
490	L	R	3,79	3,79	3,67	3,43	Tidak Tepat
491	L	R	3,63	3,63	3,71	3,3	Tepat Waktu
492	L	R	3,79	3,79	3,79	3,7	Tepat Waktu
493	L	N	3,25	3,25	3,79	4	Tepat Waktu
494	L	R	3,88	3,88	3,5	3,3	Tepat Waktu
495	L	R	3,79	3,79	3,79	3,91	Tepat Waktu
496	P	R	3,71	3,71	3,67	3,48	Tidak Tepat
497	P	N	4	4	3,75	3,87	Tepat Waktu
498	P	N	4	4	3,42	3,87	Tepat Waktu
499	P	N	3,71	3,71	3,88	4	Tidak Tepat
500	P	N	3,88	3,88	3,75	4	Tepat Waktu
501	L	N	3,79	3,79	2,88	3,47	Tidak Tepat
502	L	R	3,63	3,63	3,54	4	Tepat Waktu
503	L	R	3,46	3,46	3,42	2,91	Tidak Tepat
504	L	R	3,13	3,13	2,83	2,15	Tidak Tepat
505	L	R	3,63	3,63	3,79	3,61	Tidak Tepat
506	P	N	4	4	3,21	3,87	Tepat Waktu
507	P	N	3,54	3,54	3,42	3,87	Tepat Waktu
508	L	N	3,92	3,92	3,67	3,87	Tepat Waktu
509	P	N	3,5	3,5	3,75	4	Tepat Waktu
510	L	N	3,58	3,58	3,21	3,78	Tepat Waktu
511	P	R	3,21	3,21	2,96	3,32	Tidak Tepat
512	L	R	3,63	3,63	3,54	3	Tidak Tepat
513	L	N	3,21	3,21	3,08	3,22	Tidak Tepat
514	P	R	3,58	3,58	3,42	3,17	Tidak Tepat
515	L	R	3,21	3,21	2,71	2,15	Tidak Tepat

516	L	R	3,75	3,75	3,88	3,65	Tidak Tepat
517	L	R	4	4	4	3,91	Tepat Waktu
518	P	R	3,88	3,88	4	3,78	Tepat Waktu
519	L	R	4	4	3,79	3,87	Tepat Waktu
520	P	R	3,88	3,88	4	3,91	Tepat Waktu
521	L	R	3,88	3,88	4	4	Tepat Waktu
522	P	R	3,88	3,88	4	3,78	Tepat Waktu
523	P	R	3,88	3,88	3,88	3,87	Tepat Waktu
524	P	R	4	4	4	4	Tepat Waktu
525	P	R	3,75	3,75	3,75	3,83	Tepat Waktu
526	L	R	3,21	3,21	2,88	2,7	Tidak Tepat
527	L	N	3,5	3,5	3,21	3,3	Tidak Tepat
528	P	N	3,79	3,79	3,92	3,67	Tepat Waktu
529	L	R	3,63	3,63	3,54	3,54	Tepat Waktu
530	L	R	3,67	3,67	3,54	3,33	Tidak Tepat
531	L	N	3,83	3,83	3,79	4	Tepat Waktu
532	L	N	3,79	3,79	3,46	3,33	Tidak Tepat
533	P	N	4	4	3,67	3,63	Tepat Waktu
534	L	N	3,42	3,42	3,46	3,58	Tepat Waktu
535	P	N	4	4	3,83	3,46	Tepat Waktu
536	L	N	3,46	3,46	3,46	3,08	Tidak Tepat
537	P	N	3,71	3,71	3,46	3,63	Tepat Waktu
538	P	R	3,54	3,54	3,92	3,75	Tepat Waktu
539	P	R	3,67	3,67	3,67	3,54	Tepat Waktu
540	L	R	3,63	3,63	3,63	3,63	Tepat Waktu
541	L	N	3,46	3,46	3,25	3,08	Tidak Tepat
542	L	N	3,63	3,63	3,83	3,79	Tepat Waktu
543	P	N	3,75	3,75	3,92	3,46	Tepat Waktu
544	P	N	3,38	3,38	3,92	3,79	Tepat Waktu
545	P	N	3,67	3,67	3,79	3,54	Tepat Waktu
546	P	N	3,71	3,71	3,46	3,42	Tidak Tepat
547	P	N	3,92	3,92	3,79	3,42	Tepat Waktu
548	P	N	3,83	3,83	3,71	3,29	Tepat Waktu
549	L	R	3,67	3,67	3,92	3,21	Tepat Waktu
550	L	N	3,58	3,58	3,21	3	Tidak Tepat
551	P	N	3,92	3,92	3,75	4	Tepat Waktu
552	P	R	3,88	3,88	3,88	3,91	Tepat Waktu
553	P	R	3,88	3,88	3,75	3,91	Tepat Waktu
554	L	N	3,67	3,67	3,46	3,39	Tidak Tepat
555	L	N	3,67	3,67	3,63	3	Tepat Waktu
556	L	N	3,46	3,46	3,42	3,3	Tidak Tepat
557	L	N	3,54	3,54	3,33	3,09	Tidak Tepat
558	L	N	3,42	3,42	3,08	3	Tidak Tepat
559	L	N	3,67	3,67	3,54	3	Tepat Waktu

560	L	N	3,33	3,33	3,21	3	Tidak Tepat
561	L	N	3,54	3,54	3,67	3,09	Tepat Waktu
562	P	N	3,67	3,67	3,5	3,39	Tepat Waktu
563	P	N	3,67	3,67	3,17	3,09	Tidak Tepat
564	P	N	2,67	2,67	3,41	2,88	Tidak Tepat
565	L	N	3,5	3,5	3,33	3	Tidak Tepat
566	L	N	3,67	3,67	3,21	3	Tidak Tepat
567	L	N	3,29	3,29	3,42	3	Tidak Tepat
568	L	N	3,79	3,79	3,75	3,78	Tepat Waktu
569	L	N	3,71	3,71	3,79	3,65	Tepat Waktu
570	P	N	3,46	3,46	3,46	3,67	Tepat Waktu
571	L	N	3,5	3,5	3,13	3	Tidak Tepat
572	P	N	3,75	3,75	3,46	3	Tidak Tepat
573	L	N	3,13	3,13	3,13	2,67	Tidak Tepat
574	L	N	3,38	3,38	3,58	3,38	Tepat Waktu
575	L	N	2,88	2,88	2,17	3	Tidak Tepat
576	P	R	3,79	3,79	3,42	3,48	Tidak Tepat
577	L	R	3,83	3,83	3,42	3,35	Tidak Tepat
578	L	R	3,71	3,71	3,13	3,09	Tidak Tepat
579	L	R	3,67	3,67	3,38	3,22	Tidak Tepat
580	L	N	4	4	3,88	3,78	Tepat Waktu
581	P	N	3,79	3,79	3,88	3,39	Tepat Waktu
582	L	R	3,29	3,29	3,46	3,61	Tidak Tepat
583	L	N	4	4	3,92	3,65	Tepat Waktu
584	L	R	3,88	3,88	3,75	3,22	Tidak Tepat
585	P	R	3,46	3,46	3,67	2,96	Tidak Tepat
586	P	R	3,58	3,58	3,33	3,22	Tidak Tepat
587	L	N	3,67	3,67	3,88	3,52	Tepat Waktu
588	P	N	3,63	3,63	4	3,61	Tepat Waktu
589	L	N	4	4	3,63	3,61	Tidak Tepat
590	P	R	3,88	3,88	3,67	3,48	Tepat Waktu
591	P	N	3,88	3,88	3,88	3,61	Tepat Waktu
592	L	N	3,79	3,79	3,88	3,35	Tepat Waktu
593	P	R	3,92	3,92	3,42	1,83	Tidak Tepat
594	P	N	3,67	3,67	4	3,61	Tepat Waktu
595	P	R	3,88	3,88	3,42	2	Tidak Tepat
596	L	R	3,75	3,75	3,67	3,61	Tidak Tepat
597	P	R	3,71	3,71	3	2,87	Tidak Tepat
598	L	R	3,71	3,71	4	3,32	Tidak Tepat
599	L	R	3,33	3,33	3,35	3,35	Tidak Tepat
600	L	R	3,67	3,67	3,15	3,35	Tidak Tepat
601	L	R	3,29	3,29	2,65	3,25	Tidak Tepat
602	L	N	3,67	3,67	3,4	3,5	Tidak Tepat
603	L	N	3,67	3,67	2,8	3,4	Tidak Tepat

604	P	R	3,52	3,52	3,55	3,75	Tidak Tepat
605	L	N	3,9	3,9	3,3	4	Tidak Tepat
606	L	N	3,48	3,48	2,7	1,7	Tidak Tepat
607	L	N	3,38	3,38	3,6	3,55	Tidak Tepat
608	L	R	3,9	3,9	4	3,7	Tidak Tepat
609	L	N	4	4	3,7	3,85	Tidak Tepat
610	L	R	4	4	4	4	Tidak Tepat
611	L	R	4	4	3,8	4	Tidak Tepat
612	L	R	4	4	4	4	Tidak Tepat
613	L	R	3,9	3,9	3,6	3,4	Tidak Tepat
614	L	R	3,62	3,62	1,85	2,57	Tidak Tepat
615	L	R	3,48	3,48	3,6	3,8	Tidak Tepat
616	L	R	3,62	3,62	2,65	3,25	Tidak Tepat
617	L	R	3,76	3,76	3,3	3,9	Tidak Tepat
618	L	R	3,52	3,52	3	3,25	Tidak Tepat
619	L	R	3,9	3,9	3,9	3,75	Tidak Tepat
620	L	R	3,38	3,38	2,5	3,6	Tidak Tepat
621	L	R	3,29	3,29	2,95	3,35	Tidak Tepat
622	L	R	3,71	3,71	3,25	3,17	Tidak Tepat
623	L	R	3,33	3,33	3	3,08	Tidak Tepat
624	L	R	3,33	3,33	3,55	2,92	Tidak Tepat
625	L	R	3,33	3,33	3,4	2,79	Tidak Tepat
626	P	R	3,81	3,81	2,59	2,55	Tidak Tepat
627	P	R	4	4	2,77	3,1	Tidak Tepat
628	L	N	3,48	3,48	3,61	3,7	Tepat Waktu
629	L	R	3,48	3,48	3,3	3,65	Tepat Waktu
630	L	R	3,38	3,38	3,74	3,78	Tepat Waktu
631	L	R	3,38	3,38	3,57	3,65	Tepat Waktu
632	L	N	3,14	3,14	3,43	3,7	Tidak Tepat
633	L	N	3,43	3,43	3,78	3,78	Tepat Waktu
634	L	N	3,62	3,62	3,7	3,48	Tidak Tepat
635	L	N	3,24	3,24	3,7	3,04	Tepat Waktu
636	L	N	2,95	2,95	2,85	1,11	Tidak Tepat
637	L	R	2,9	2,9	2,4	3,59	Tidak Tepat
638	L	R	3	3	2,65	3,25	Tidak Tepat
639	L	R	3,48	3,48	3,26	3,52	Tidak Tepat
640	L	N	3,76	3,76	3,65	3,6	Tepat Waktu
641	L	R	3,9	3,9	3,52	3,45	Tepat Waktu
642	L	R	3,9	3,9	3,52	3,45	Tidak Tepat
643	L	N	3,19	3,19	3,35	3,48	Tidak Tepat
644	P	N	3,65	3,65	3,5	3,46	Tidak Tepat
645	L	R	2,96	2,96	3,76	3,71	Tidak Tepat
646	P	N	3,57	3,57	3,79	3,58	Tepat Waktu
647	L	N	3,43	3,43	4	3,17	Tidak Tepat

648	P	R	3,78	3,78	3,67	3,58	Tepat Waktu
649	P	R	3,65	3,65	3,67	3,38	Tepat Waktu
650	L	N	2,83	2,83	2,86	2,4	Tidak Tepat
651	L	N	3,22	3,22	3,04	3,04	Tidak Tepat
652	P	R	4	4	3,75	3,71	Tepat Waktu
653	L	R	3,52	3,52	3,29	1,42	Tidak Tepat
654	L	N	3,78	3,78	3,42	3,25	Tidak Tepat
655	L	R	3,78	3,78	3,79	3	Tidak Tepat
656	L	N	3,87	3,87	2,92	3,3	Tidak Tepat
657	L	R	2,91	2,91	2,54	3	Tidak Tepat
658	L	N	3,52	3,52	3,58	2,92	Tidak Tepat
659	L	N	3,78	3,78	3,88	3,67	Tidak Tepat
660	L	N	2,52	2,52	1,88	3,36	Tidak Tepat
661	L	R	3,3	3,3	3,29	1,58	Tidak Tepat
662	L	R	3,78	3,78	3,88	3,92	Tepat Waktu
663	L	N	3,43	3,43	3,79	3,29	Tidak Tepat
664	P	N	3,61	3,61	3,92	3,21	Tidak Tepat
665	L	N	3,65	3,65	3,71	3,67	Tepat Waktu
666	L	R	3,78	3,78	3,54	3,63	Tepat Waktu
667	L	R	2,87	2,87	2,63	1,63	Tidak Tepat
668	L	N	3,35	3,35	3,92	3,38	Tidak Tepat
669	L	N	3,09	3,09	3,04	2,42	Tidak Tepat
670	L	N	2,83	2,83	3	3	Tidak Tepat
671	L	R	3,48	3,48	3,42	2,75	Tidak Tepat
672	L	N	3,57	3,57	3,92	3,46	Tepat Waktu
673	L	N	3,87	3,87	4	3,79	Tidak Tepat
674	L	R	3,52	3,52	3,54	3,54	Tidak Tepat
675	L	N	3,87	3,87	3,08	3,25	Tidak Tepat
676	P	N	3,7	3,7	3,58	3,63	Tidak Tepat
677	L	N	3,52	3,52	3,88	3,88	Tidak Tepat
678	L	N	3,43	3,43	3,33	3,08	Tidak Tepat
679	P	R	3,35	3,35	3,71	2,21	Tidak Tepat
680	P	N	3,3	3,3	3,79	3,79	Tidak Tepat
681	L	N	3,57	3,57	3,92	3,5	Tepat Waktu
682	L	N	3,78	3,78	3,42	3,54	Tidak Tepat
683	L	N	3,65	3,65	3,71	3,46	Tidak Tepat
684	L	N	3,09	3,09	3,46	2,67	Tidak Tepat
685	L	R	3,17	3,17	2,62	2,06	Tidak Tepat
686	L	N	3,57	3,57	3,38	3,38	Tidak Tepat
687	L	N	3,65	3,65	3,79	3,88	Tidak Tepat
688	L	N	3,48	3,48	3,79	3,58	Tidak Tepat
689	L	N	3,61	3,61	2,79	3,3	Tidak Tepat
690	P	N	3,78	3,78	4	3,79	Tepat Waktu
691	L	N	3,57	3,57	3,79	3,79	Tepat Waktu

692	L	R	3,65	3,65	3,67	3,5	Tidak Tepat
693	L	N	3,39	3,39	3,88	3,67	Tidak Tepat
694	L	N	3,65	3,65	3,79	3,67	Tidak Tepat
695	L	R	3,65	3,65	3	3,58	Tepat Waktu
696	L	R	3,39	3,39	3,21	2,73	Tidak Tepat
697	L	N	3,65	3,65	4	3,88	Tidak Tepat
698	L	N	3,43	3,43	4	3,54	Tidak Tepat
699	L	N	3,7	3,7	4	3,75	Tepat Waktu
700	L	N	3,3	3,3	2,96	3	Tidak Tepat
701	P	N	3,74	3,74	4	3,88	Tepat Waktu
702	L	N	3,57	3,57	4	3,79	Tidak Tepat
703	L	N	3,87	3,87	3,88	3,46	Tepat Waktu
704	L	N	3,22	3,22	3,58	3,33	Tidak Tepat
705	L	R	3,39	3,39	3,75	2,75	Tidak Tepat
706	P	R	3,78	3,78	3,88	3,54	Tidak Tepat
707	L	N	3,78	3,78	3,79	3,71	Tidak Tepat
708	L	R	2,96	2,96	3,9	3,5	Tidak Tepat
709	L	R	3,22	3,22	2,88	2,84	Tidak Tepat
710	P	R	4	4	3,88	3,58	Tepat Waktu
711	P	R	3,87	3,87	3,67	3,5	Tepat Waktu
712	L	R	3,57	3,57	3,62	3,83	Tidak Tepat
713	L	N	3,78	3,78	3,67	3,71	Tepat Waktu
714	L	N	4	4	3,88	3,88	Tidak Tepat
715	P	R	3,87	3,87	3,88	3,92	Tepat Waktu
716	P	R	3,87	3,87	3,75	3,13	Tepat Waktu
717	P	R	3,48	3,48	3,67	3,58	Tepat Waktu
718	L	N	3,22	3,22	3,75	3,33	Tidak Tepat
719	L	N	3,43	3,43	3,92	3,75	Tidak Tepat
720	P	R	3,78	3,78	3,75	3,5	Tidak Tepat
721	L	N	3,65	3,65	3,79	3,33	Tidak Tepat
722	P	R	3,7	3,7	3,54	3,46	Tepat Waktu
723	L	R	3,57	3,57	3,29	3,38	Tidak Tepat
724	L	R	3,39	3,39	3,67	3,46	Tepat Waktu
725	L	N	2,96	2,96	3	2	Tidak Tepat
726	L	R	3,78	3,78	3,67	3,79	Tepat Waktu
727	P	R	3,87	3,87	3,79	3,71	Tepat Waktu
728	P	R	3,87	3,87	3,63	3,33	Tepat Waktu
729	P	R	3,52	3,52	3,79	3,67	Tidak Tepat
730	P	R	3,57	3,57	3,75	3,58	Tidak Tepat
731	L	R	3,39	3,39	3,63	3,21	Tidak Tepat
732	P	R	3,22	3,22	3,21	2,75	Tidak Tepat
733	L	R	3,26	3,26	2,88	2,85	Tidak Tepat
734	L	N	3,7	3,7	3,54	3,21	Tepat Waktu
735	P	R	3,52	3,52	3,58	2,63	Tidak Tepat

736	P	R	4	4	3,79	3,67	Tepat Waktu
737	L	R	3,91	3,91	3,79	3,79	Tepat Waktu
738	L	R	4	4	3,79	3,79	Tepat Waktu
739	P	N	4	4	3,79	3,71	Tepat Waktu
740	L	N	3,7	3,7	3,5	3,58	Tepat Waktu
741	P	R	3,83	3,83	3,67	3,54	Tidak Tepat
742	P	R	3,87	3,87	3,63	3,33	Tidak Tepat
743	P	N	3,91	3,91	3,79	3,38	Tidak Tepat
744	L	R	3,26	3,26	2,58	2,7	Tidak Tepat
745	L	N	3,78	3,78	3,58	3,25	Tepat Waktu
746	P	R	3,78	3,78	3,79	3,71	Tepat Waktu
747	L	N	3,87	3,87	3,79	3,71	Tepat Waktu
748	P	R	4	4	3,88	3,71	Tepat Waktu
749	L	R	3,91	3,91	3,46	3,08	Tidak Tepat
750	L	R	3,83	3,83	3,79	3,79	Tepat Waktu
751	L	R	3,65	3,65	3,46	3,46	Tidak Tepat
752	L	R	3,87	3,87	3,79	3,67	Tepat Waktu
753	L	R	3,43	3,43	3,54	3,25	Tepat Waktu
754	L	R	3,7	3,7	3,54	3,25	Tepat Waktu
755	L	N	3,83	3,83	3,21	3,21	Tidak Tepat
756	L	N	3,91	3,91	3,79	3,79	Tepat Waktu
757	L	R	4	4	3,17	3,54	Tepat Waktu
758	L	R	4	4	3,58	3,33	Tepat Waktu
759	L	N	3,61	3,61	2,5	3,4	Tidak Tepat
760	L	N	3,74	3,74	3	3,42	Tidak Tepat
761	P	N	2,13	2,13	2,92	3	Tidak Tepat
762	P	N	4	4	3,67	3,63	Tepat Waktu
763	P	N	3,87	3,87	3,79	3,92	Tepat Waktu
764	P	N	3,74	3,74	3,67	3,63	Tepat Waktu
765	P	R	3,65	3,65	3,54	3,75	Tepat Waktu
766	P	R	3,52	3,52	3,46	3,08	Tidak Tepat
767	P	R	3,87	3,87	3,88	3,54	Tepat Waktu
768	L	N	3,65	3,65	3,13	2,27	Tidak Tepat
769	P	R	3,09	3,09	2,75	2,85	Tidak Tepat
770	P	R	2,81	2,81	3,17	3,17	Tidak Tepat
771	L	N	3,65	3,65	3,42	3,67	Tepat Waktu
772	P	N	4	4	3,54	3,92	Tepat Waktu
773	L	R	3,65	3,65	3,88	3,63	Tepat Waktu
774	P	N	3,52	3,52	3,58	3,21	Tepat Waktu
775	L	N	3,87	3,87	3,79	4	Tepat Waktu
776	P	N	3,65	3,65	3,46	3,29	Tidak Tepat
777	P	R	3,65	3,65	3,21	3,04	Tidak Tepat
778	P	R	3,61	3,61	3,46	3,38	Tidak Tepat
779	P	R	3,52	3,52	3,46	2,63	Tepat Waktu

780	L	N	2,7	2,7	2,71	3,39	Tidak Tepat
781	L	N	3,61	3,61	3,21	3,17	Tidak Tepat
782	L	R	3,17	3,17	2,79	2,5	Tidak Tepat
783	L	N	3,52	3,52	3,21	3,5	Tepat Waktu
784	L	N	4	4	4	3,46	Tepat Waktu
785	L	N	3,17	3,17	3	2,79	Tidak Tepat
786	P	N	3,52	3,52	3,13	3,08	Tidak Tepat
787	L	N	3,74	3,74	3,58	3,33	Tepat Waktu
788	P	N	3,74	3,74	3,88	3,79	Tepat Waktu
789	P	R	3,65	3,65	3,5	3,54	Tepat Waktu
790	L	R	3,52	3,52	3,13	3,42	Tidak Tepat
791	P	R	3,52	3,52	3,38	2,96	Tidak Tepat
792	P	R	3,52	3,52	3,25	3,04	Tidak Tepat
793	P	R	3,74	3,74	3,5	3,63	Tepat Waktu
794	P	R	3,87	3,87	3,83	4	Tepat Waktu
795	P	R	3,87	3,87	3,71	3,79	Tepat Waktu
796	L	N	3,3	3,3	2,88	2,85	Tidak Tepat
797	P	R	3,78	3,78	2,79	2,85	Tidak Tepat
798	P	R	3,52	3,52	3,46	3,17	Tidak Tepat
799	P	R	3,57	3,57	3,13	3,13	Tidak Tepat
800	P	N	3,57	3,57	3,29	3,45	Tidak Tepat
801	P	N	3,52	3,52	3,13	2,21	Tidak Tepat
802	P	R	3,52	3,52	3,46	3,17	Tidak Tepat
803	P	N	3,65	3,65	4	3,75	Tepat Waktu
804	L	R	3,35	3,35	3,75	3,92	Tidak Tepat
805	P	R	3,74	3,74	3,67	3,29	Tidak Tepat
806	L	R	3,65	3,65	3,67	4	Tidak Tepat
807	P	R	4	4	3,88	4	Tepat Waktu
808	P	R	4	4	3,88	4	Tepat Waktu
809	P	R	3,65	3,65	3,75	3,54	Tidak Tepat
810	L	N	3,87	3,87	3,75	4	Tepat Waktu
811	L	N	3,74	3,74	3,54	3,5	Tidak Tepat
812	L	N	3,65	3,65	3,75	3,79	Tepat Waktu
813	L	N	3,65	3,65	3,42	3,79	Tidak Tepat
814	P	N	3,61	3,61	3,42	3,42	Tidak Tepat
815	P	N	3,87	3,87	3,75	3,42	Tidak Tepat
816	P	N	3,87	3,87	3,88	4	Tepat Waktu
817	L	N	3,65	3,65	3,54	3,08	Tidak Tepat
818	P	N	3,65	3,65	3,54	2,23	Tidak Tepat
819	L	N	3,65	3,65	3,75	3,46	Tidak Tepat
820	P	N	4	4	3,75	3,63	Tidak Tepat
821	L	N	3,48	3,48	3,21	2,13	Tidak Tepat
822	P	N	3,35	3,35	3,58	3	Tidak Tepat
823	L	R	3,65	3,65	3,63	3,71	Tepat Waktu

824	L	N	3,52	3,52	3,46	3,13	Tidak Tepat
825	L	N	3,04	3,04	2,42	2,33	Tidak Tepat
826	L	N	3,26	3,26	2,79	2,71	Tidak Tepat
827	P	N	3,61	3,61	3,46	3,42	Tidak Tepat
828	P	R	3,3	3,3	3,38	3,25	Tidak Tepat
829	L	R	3,87	3,87	3,79	3,75	Tidak Tepat
830	L	N	3,13	3,13	2,75	3,15	Tidak Tepat
831	P	N	3,57	3,57	3,58	3	Tepat Waktu
832	P	N	3,87	3,87	3,88	4	Tidak Tepat
833	L	N	3,74	3,74	3,88	4	Tidak Tepat
834	L	N	3,65	3,65	3,75	3	Tidak Tepat
835	P	N	3,91	3,91	3,79	3,71	Tepat Waktu
836	P	N	3,91	3,91	3,79	3,79	Tepat Waktu
837	L	N	3,52	3,52	3,21	3,42	Tidak Tepat
838	L	N	3,48	3,48	3,67	3,25	Tidak Tepat
839	L	N	3,73	3,74	3,65	2,25	Tidak Tepat
840	P	N	3,5	3,89	4	3,88	Tepat Waktu
841	P	N	3,55	4	3,87	3,88	Tepat Waktu
842	L	N	3,73	3,89	3,61	3,88	Tepat Waktu
843	L	N	3,5	3	3,22	3,5	Tepat Waktu
844	L	R	3,45	3,63	3,35	3,5	Tepat Waktu
845	P	R	3,32	3,42	3,09	3,63	Tepat Waktu
846	P	R	4	4	3,87	4	Tepat Waktu
847	L	N	3,55	3,84	2,87	3,86	Tepat Waktu
848	P	N	3,91	4	4	3,88	Tepat Waktu
849	L	R	3,27	2,95	2,71	2,86	Tidak Tepat
850	P	R	2,73	3	2,57	3,14	Tidak Tepat
851	L	R	3,23	3,47	3,26	3,63	Tepat Waktu
852	P	R	3,91	3,89	3,65	3,75	Tepat Waktu
853	P	R	3,14	2,79	3,29	3,38	Tidak Tepat
854	P	R	3,77	4	3,39	3,63	Tidak Tepat
855	P	R	3,36	4	3,61	3,63	Tepat Waktu
856	L	R	3,23	3,84	3,87	3,75	Tepat Waktu
857	P	R	3,77	3,89	3,74	3,88	Tidak Tepat
858	P	R	3,77	4	4	3,88	Tepat Waktu
859	L	R	3,73	3,74	3,61	3,75	Tepat Waktu
860	P	R	3,77	3,63	3,35	3,63	Tepat Waktu
861	L	N	3,14	2,84	3,29	3,38	Tidak Tepat
862	P	N	3,23	3	3,22	3,88	Tepat Waktu
863	L	R	3,77	3,89	3,78	4	Tepat Waktu
864	P	R	2,5	3,05	2,57	3,29	Tidak Tepat
865	L	R	3,64	3,74	3,61	3,88	Tepat Waktu
866	P	R	3,73	4	3,61	3,63	Tepat Waktu
867	P	R	3,23	3,89	3,61	3,75	Tepat Waktu

868	P	R	3,86	4	3,87	3,75	Tepat Waktu
869	P	R	3,27	3,47	3,22	3,5	Tepat Waktu
870	P	R	3,5	3,84	3,22	3,63	Tepat Waktu
871	P	R	3,64	3,63	3	3,5	Tepat Waktu
872	L	R	2,95	2,53	3,29	3,39	Tidak Tepat
873	P	R	3,5	4	3,61	3,75	Tepat Waktu
874	P	R	3,45	3,16	3,13	3,38	Tidak Tepat
875	P	R	3,5	3,63	3,74	3,88	Tepat Waktu
876	L	R	2,73	1,56	2,25	2,5	Tidak Tepat
877	P	R	3,64	3,84	3,87	4	Tepat Waktu
878	P	N	3,64	4	3,22	2,86	Tidak Tepat
879	P	N	3,5	3,68	3,87	3,75	Tepat Waktu
880	P	R	3,5	3,37	3,74	3,13	Tepat Waktu
881	P	R	4	4	3,87	3,88	Tidak Tepat
882	P	R	3,91	4	4	3,63	Tepat Waktu
883	P	R	3,77	4	3,65	3,63	Tepat Waktu
884	P	R	3,14	3,58	3,39	3,63	Tidak Tepat
885	L	N	3,64	3,74	3,61	3,75	Tepat Waktu
886	P	R	3,55	3,63	3,26	3,63	Tepat Waktu
887	P	R	3,18	3,74	4	3,63	Tepat Waktu
888	P	R	3,86	3,84	3,87	3,25	Tepat Waktu
889	P	R	3,91	3,68	3,87	3,75	Tepat Waktu
890	P	R	3,91	3,79	3,87	3,88	Tepat Waktu
891	P	R	4	3,79	4	3,88	Tepat Waktu
892	P	R	3,91	3,89	3,87	3,88	Tepat Waktu
893	L	R	3,77	3,79	3,61	3,25	Tepat Waktu
894	P	N	4	3,89	3,87	3,88	Tepat Waktu
895	P	N	3,91	3,42	3,87	3,75	Tepat Waktu
896	L	N	3,55	3,79	3,39	3,63	Tepat Waktu
897	P	R	3,86	4	3,39	3,75	Tepat Waktu
898	P	R	3,86	3,53	3,17	3,63	Tepat Waktu
899	P	R	3,73	3,68	3	3,38	Tidak Tepat
900	P	R	3,86	4	3,26	3,88	Tepat Waktu
901	P	R	3,73	3,58	3,22	3,25	Tidak Tepat
902	P	R	3,86	4	3,65	4	Tepat Waktu
903	L	R	3,73	3,68	3,13	3,63	Tepat Waktu
904	P	R	3,86	3,84	3,39	3,75	Tepat Waktu
905	P	N	3,86	3,53	3,26	3,25	Tidak Tepat
906	P	N	3,86	3,84	3,39	3,88	Tepat Waktu
907	P	N	3,86	3,84	3,39	3,63	Tepat Waktu
908	L	N	3,86	3,84	3,35	3,75	Tepat Waktu
909	P	N	4	4	4	3,88	Tepat Waktu
910	P	R	3,86	3,84	3,39	3,75	Tepat Waktu
911	P	N	3,86	3,84	3,39	4	Tepat Waktu

912	L	N	3,27	3,53	3,39	3,38	Tidak Tepat
913	P	N	3,86	3,84	3,39	3,63	Tepat Waktu
914	P	N	2,59	1,96	2	3,5	Tidak Tepat
915	L	N	3,86	3,75	3,88	3,88	Tepat Waktu
916	L	R	3,29	3	3,38	3	Tidak Tepat
917	P	N	3,71	3,75	3,13	3	Tidak Tepat
918	L	N	3,57	3,5	3,5	3,63	Tepat Waktu
919	P	N	3,71	3,63	3,5	3,5	Tepat Waktu
920	L	N	3,71	3,75	3,5	3,75	Tepat Waktu
921	P	R	3,86	3,25	3,25	3,13	Tidak Tepat
922	P	R	3,57	3,88	4	3,75	Tidak Tepat
923	L	N	3,86	3,63	3,5	3,25	Tidak Tepat
924	P	N	3,57	3,38	3,38	3,25	Tidak Tepat
925	P	N	3,57	3,75	3,5	3	Tidak Tepat
926	L	N	3,43	3,63	3,63	4	Tepat Waktu
927	L	R	3,71	3,75	3,5	3,75	Tepat Waktu
928	P	N	3,86	3,75	3,88	3,5	Tepat Waktu
929	P	N	3,57	3,75	3,5	3,13	Tepat Waktu
930	P	R	3,57	3,75	3,75	3,38	Tepat Waktu
931	P	R	1,5	2,75	2,57	2,33	Tidak Tepat
932	P	N	3,43	3,88	3,5	3,5	Tepat Waktu
933	P	R	3,71	3,63	3,63	3,38	Tepat Waktu
934	P	R	2,71	3,5	2,88	3,29	Tidak Tepat
935	P	R	3,86	3,13	3,5	3,13	Tepat Waktu
936	P	N	3,71	3,63	3,5	3,5	Tepat Waktu
937	L	N	3,71	3,88	3,75	4	Tepat Waktu
938	P	N	3,14	3,63	3,38	2,88	Tidak Tepat
939	P	R	3,71	3,88	3,63	3,25	Tepat Waktu
940	P	R	3,71	3,75	4	3,88	Tepat Waktu
941	P	R	3	3,5	3,75	3,38	Tepat Waktu
942	P	R	3,57	3	3,5	3	Tepat Waktu
943	L	R	3,29	3,63	3,63	3,5	Tepat Waktu
944	L	N	3,71	3,38	3,5	3,13	Tepat Waktu
945	P	R	3,43	3,25	2,5	3,14	Tidak Tepat
946	P	N	3,71	3,63	2,63	3,29	Tidak Tepat
947	P	R	3	3,5	3,5	3,25	Tepat Waktu
948	L	N	3,71	4	3,63	3,88	Tepat Waktu
949	P	R	2,86	3,38	3,63	3,13	Tepat Waktu
950	P	N	3,57	2,71	3,71	3,63	Tepat Waktu
951	P	N	3,71	3,63	3,63	3,38	Tepat Waktu
952	P	N	2,86	2,86	3	2,75	Tidak Tepat
953	L	N	3,71	3,63	3,5	3,13	Tepat Waktu
954	L	R	2,14	3,13	3,5	2,88	Tidak Tepat
955	P	R	2,14	3,38	3,13	3,13	Tidak Tepat

956	P	R	3,43	3,38	3,38	3,38	Tidak Tepat
957	P	R	3,43	3,63	3,75	3	Tepat Waktu
958	L	R	3,57	3,5	3,75	3,63	Tepat Waktu
959	P	N	2,86	3,88	4	3,25	Tepat Waktu
960	P	R	3,86	2,5	3	3,38	Tidak Tepat
961	L	N	3,14	3	2,86	1,43	Tidak Tepat
962	L	R	3	3	2,71	2,43	Tidak Tepat
963	L	R	3,57	3,38	3,63	3,63	Tidak Tepat
964	L	R	3,29	3,5	3,63	3	Tepat Waktu
965	L	R	3,86	3,75	3,75	3,63	Tidak Tepat
966	L	R	3,86	3,75	3,88	3,75	Tepat Waktu
967	P	R	4	3,38	3,88	3,63	Tepat Waktu
968	P	R	3,86	3,25	3,5	3,13	Tepat Waktu
969	P	R	3,71	3,88	4	3,88	Tepat Waktu
970	P	R	3,71	3,75	4	3,88	Tepat Waktu
971	P	N	3,71	3,38	3,13	2	Tidak Tepat
972	L	N	3,57	3,63	3,25	3,25	Tidak Tepat
973	L	N	3,86	3,63	4	3,5	Tepat Waktu
974	L	R	2,86	2,5	2,43	2	Tidak Tepat
975	P	R	2,71	3,63	3,63	3	Tepat Waktu
976	P	R	3,71	3,13	3,63	3,63	Tidak Tepat
977	P	R	3,71	3,5	3,38	3	Tidak Tepat
978	L	N	3,14	3,63	4	2,88	Tidak Tepat
979	P	N	3	2,25	2,83	2,17	Tidak Tepat
980	L	R	3,86	3,88	3,88	3,38	Tepat Waktu
981	P	R	3,71	3,88	3,63	3,5	Tepat Waktu
982	P	N	3,29	3,5	3,88	3,63	Tepat Waktu
983	P	R	3,86	3,88	3,5	3,38	Tepat Waktu
984	P	R	3,71	3,88	3,5	3,5	Tepat Waktu
985	P	R	3,86	3,88	3,63	3,25	Tepat Waktu
986	L	R	3,86	3,88	3,63	3,63	Tepat Waktu
987	P	R	3,57	3,63	4	3,38	Tepat Waktu
988	L	R	3,57	3,88	3,88	3,5	Tepat Waktu
989	P	R	3,71	3,88	3,5	3,38	Tepat Waktu
990	P	R	4	4	3,88	3,75	Tepat Waktu
991	P	R	3,43	3,75	3,75	3	Tepat Waktu
992	L	R	3,86	3,88	3,88	4	Tepat Waktu
993	L	N	3,14	3	3	3	Tidak Tepat
994	P	N	3,86	3,88	3,63	3,25	Tepat Waktu
995	P	N	4	3,88	3,88	3,75	Tepat Waktu
996	P	N	3,29	3,13	3	3	Tidak Tepat
997	P	N	3,86	3,88	3,75	3,13	Tepat Waktu
998	L	R	3,86	3,5	3,5	3,25	Tepat Waktu
999	P	N	3,71	3,88	3,88	3,13	Tepat Waktu

1000	P	N	3,29	3,5	3,63	2,75	Tepat Waktu
1001	P	R	3,29	3,75	3,75	3,5	Tepat Waktu
1002	P	N	3,43	3,38	3,38	2,63	Tepat Waktu
1003	P	N	3,14	3,5	3,13	3,13	Tidak Tepat
1004	P	R	3,71	3,25	3,88	3,63	Tepat Waktu
1005	P	N	3,43	3,25	3,25	3,57	Tepat Waktu
1006	P	R	3,86	3,75	3,88	3,25	Tepat Waktu
1007	P	R	3,14	3,5	3,75	3,5	Tepat Waktu
1008	L	N	3,86	3,53	2,83	3,56	Tepat Waktu
1009	L	N	3,67	3,21	3	3,08	Tidak Tepat
1010	L	N	3,76	3,21	2,91	3,11	Tidak Tepat
1011	L	N	3,86	3,89	3,7	3,92	Tepat Waktu
1012	P	N	3,33	2,68	2,9	2,88	Tidak Tepat
1013	L	N	3,57	3,79	3,57	3,67	Tepat Waktu
1014	P	N	3,43	3,58	3,74	3,92	Tepat Waktu
1015	L	N	3,52	3,47	3,52	3,58	Tepat Waktu
1016	P	R	4	4	4	4	Tepat Waktu
1017	L	R	3,9	3,58	3,91	3,67	Tepat Waktu
1018	P	R	4	3,79	4	3,67	Tepat Waktu
1019	L	N	3,52	3,58	3,87	3,42	Tepat Waktu
1020	L	R	3,67	3,79	3,83	3,33	Tepat Waktu
1021	L	N	3,9	3,37	3,1	2,83	Tidak Tepat
1022	L	R	3,9	2,58	3,27	3,22	Tidak Tepat
1023	L	N	3,57	3,79	3,7	3,42	Tepat Waktu
1024	P	R	3,71	3,58	3,91	3,83	Tepat Waktu
1025	L	R	3,76	3,58	3,83	3,58	Tepat Waktu
1026	P	R	3,9	3,79	3,91	3,75	Tepat Waktu
1027	L	R	3,33	2,89	3,57	3,33	Tepat Waktu
1028	L	N	4	3,79	3,87	4	Tepat Waktu
1029	L	N	4	3,79	3,43	3,17	Tidak Tepat
1030	L	N	4	3,89	3,91	3,75	Tepat Waktu
1031	L	N	3,86	3,89	4	4	Tepat Waktu
1032	L	N	3,57	2,79	3,83	3,08	Tepat Waktu
1033	L	N	4	4	4	3,92	Tepat Waktu
1034	P	R	3,76	4	4	4	Tepat Waktu
1035	L	N	2,86	3,79	3,7	3,58	Tepat Waktu
1036	L	N	3,1	3,16	3,7	3,42	Tidak Tepat
1037	L	N	4	4	3,7	2,08	Tepat Waktu
1038	L	N	4	4	3,78	3,83	Tepat Waktu
1039	P	R	3,62	3,58	3,7	3,75	Tepat Waktu
1040	P	R	3,57	3,47	3,7	3,75	Tepat Waktu
1041	L	N	3,62	3,26	3,78	2,67	Tidak Tepat
1042	L	N	3,86	3,11	3,17	2,75	Tidak Tepat
1043	P	N	3,86	4	3,7	3,83	Tepat Waktu

1044	L	N	3,19	3,37	2,71	2,86	Tidak Tepat
1045	P	N	3,67	3	2,81	3,3	Tidak Tepat
1046	L	R	3,05	3,47	3,61	3,5	Tepat Waktu
1047	L	N	3,9	3,26	3,38	3	Tidak Tepat
1048	P	N	3,81	3	3,65	3,58	Tepat Waktu
1049	L	N	2,86	3,5	3,25	3,13	Tidak Tepat
1050	L	R	3,86	4	3,87	3,67	Tepat Waktu
1051	P	R	3,48	2,68	2,73	3,2	Tidak Tepat
1052	L	R	3,52	3,37	3,48	3,42	Tidak Tepat
1053	P	R	4	3,58	3,43	3,42	Tidak Tepat
1054	P	N	3,38	3	3,36	3	Tidak Tepat
1055	L	R	3,76	3,26	3,39	3,17	Tidak Tepat
1056	L	R	3	3,68	3,3	3,17	Tidak Tepat
1057	P	R	3,9	3,79	4	4	Tepat Waktu
1058	P	N	3,67	3,58	3,43	3,67	Tepat Waktu
1059	L	R	3	3,11	3,29	2,9	Tidak Tepat
1060	L	N	3,33	3,21	2,81	2,89	Tidak Tepat
1061	L	R	3,52	3,21	3,38	3,67	Tepat Waktu
1062	P	N	3,05	4	4	4	Tepat Waktu
1063	L	N	3,76	3,79	3,35	3,25	Tidak Tepat
1064	L	R	3,38	3,37	3,74	3,58	Tepat Waktu
1065	P	R	4	4	3,91	4	Tepat Waktu
1066	L	R	3,67	3,58	3,74	3,33	Tepat Waktu
1067	L	R	4	3,47	3,67	3,67	Tepat Waktu
1068	L	R	3,43	3,79	3,22	3,6	Tidak Tepat
1069	P	R	3,81	4	4	3,75	Tidak Tepat
1070	P	N	3,81	2,63	3,19	3	Tidak Tepat
1071	L	N	4	2,68	3,78	3,92	Tepat Waktu
1072	P	R	3,81	3,79	3,7	3,83	Tepat Waktu
1073	P	R	4	3,79	4	4	Tepat Waktu
1074	L	R	3	3	3,67	3,38	Tepat Waktu
1075	L	R	4	3,79	4	4	Tepat Waktu
1076	L	R	3,71	3	3,17	3,33	Tidak Tepat
1077	P	R	4	4	4	3,92	Tepat Waktu
1078	L	N	3,86	3,79	3,87	4	Tepat Waktu
1079	P	R	4	3,79	4	3,92	Tepat Waktu
1080	P	R	3,9	3,79	4	3,92	Tepat Waktu
1081	L	N	3,76	3,37	3,61	3,83	Tepat Waktu
1082	P	N	4	3,79	4	3,92	Tepat Waktu
1083	L	R	3,76	3,74	3,83	3,42	Tepat Waktu
1084	L	R	3,76	4	3,87	3,67	Tepat Waktu
1085	L	R	3,76	3,63	3,57	2,92	Tepat Waktu
1086	P	R	3,76	4	3,74	3,92	Tepat Waktu
1087	L	R	3,76	3,84	3,26	3,67	Tepat Waktu

1088	P	R	3,86	4	3,74	3,75	Tepat Waktu
1089	P	R	3,86	4	3,83	3,92	Tepat Waktu
1090	P	R	3,76	4	4	3,92	Tepat Waktu
1091	P	N	3,76	4	3,35	3,67	Tepat Waktu
1092	L	N	3,81	4	4	3,58	Tepat Waktu
1093	P	N	3,86	4	3,91	3,92	Tepat Waktu
1094	P	N	3,57	3,42	3,83	3,42	Tepat Waktu
1095	L	N	3,33	3,32	3,83	3,33	Tepat Waktu
1096	L	N	3,67	3	3,61	3,42	Tepat Waktu
1097	L	N	3,86	3,84	3,48	3,33	Tidak Tepat
1098	P	R	3,67	3,37	3,39	3,5	Tepat Waktu
1099	L	N	3,57	3,32	3,83	3,33	Tepat Waktu
1100	P	N	3,86	3,74	3,52	3,5	Tepat Waktu
1101	L	N	3,57	3,42	3,83	3,33	Tepat Waktu
1102	L	R	3	2,21	2,67	2,19	Tidak Tepat
1103	P	R	4	4	3,91	4	Tepat Waktu
1104	P	R	4	4	4	4	Tepat Waktu
1105	P	R	4	3,68	3,78	1,92	Tepat Waktu
1106	L	N	4	4	3,78	3,67	Tepat Waktu
1107	P	N	4	4	4	4	Tepat Waktu
1108	L	R	4	4	4	4	Tepat Waktu
1109	L	N	3,9	3,21	3,7	3,33	Tepat Waktu
1110	P	N	4	4	3,91	4	Tepat Waktu
1111	P	N	4	4	3,78	3,58	Tepat Waktu
1112	L	N	4	3,32	3,87	4	Tepat Waktu
1113	L	N	3,71	3,68	3,83	3,67	Tepat Waktu
1114	P	R	4	4	4	4	Tepat Waktu
1115	L	R	3,71	3,68	4	3,67	Tepat Waktu
1116	P	R	3,71	3,68	3,83	3,83	Tepat Waktu
1117	L	N	3,62	3,42	3,09	3,33	Tidak Tepat
1118	P	N	4	3,89	4	3,83	Tepat Waktu
1119	P	N	4	3,53	4	4	Tepat Waktu
1120	L	N	3,52	3,11	2,65	3	Tidak Tepat
1121	P	N	3,81	3,79	4	3,92	Tepat Waktu
1122	P	R	4	3,89	4	3,83	Tepat Waktu
1123	L	N	3,62	2,47	4	2,58	Tepat Waktu
1124	L	R	3,52	3,89	3,74	3,67	Tepat Waktu
1125	L	N	3,62	3	2,83	3	Tidak Tepat
1126	L	R	3,71	3,58	4	3,67	Tepat Waktu
1127	L	N	3,81	4	4	4	Tepat Waktu
1128	P	N	3,52	3,11	3,74	3,5	Tepat Waktu
1129	L	R	3,52	3,32	3,78	3,92	Tidak Tepat
1130	L	N	3,62	3,32	3,26	3,5	Tepat Waktu
1131	L	N	4	3	3,57	3,58	Tepat Waktu

1132	L	N	3,9	3,11	3,43	3	Tidak Tepat
1133	L	N	4	3,53	3,78	3,67	Tepat Waktu
1134	L	N	3,52	3	3	3	Tidak Tepat
1135	L	N	3,52	3	3	3	Tidak Tepat
1136	L	N	3,52	3	3,65	3	Tepat Waktu
1137	P	N	3,62	3,32	3,74	3	Tepat Waktu
1138	P	N	3,62	3,21	3,48	3	Tidak Tepat
1139	L	N	3,38	3	3,17	3	Tidak Tepat
1140	P	N	3,62	3	3,1	2,83	Tidak Tepat
1141	P	N	3,52	3,21	3	3	Tidak Tepat
1142	P	R	3,81	3,53	3,48	3,17	Tidak Tepat
1143	L	N	3,33	3,42	3,61	3,33	Tidak Tepat
1144	L	N	2,1	3	2,5	3	Tidak Tepat
1145	L	N	3,71	3,21	3,17	3,17	Tidak Tepat
1146	P	N	3,86	3,84	3,65	3,92	Tepat Waktu
1147	L	N	4	4	4	4	Tepat Waktu
1148	L	N	4	4	4	4	Tepat Waktu
1149	P	N	4	4	4	4	Tepat Waktu
1150	L	N	3,33	3,32	3,65	3,42	Tepat Waktu
1151	L	N	3,14	3,21	3,7	3,42	Tepat Waktu
1152	L	N	3,86	3,42	3,09	2,5	Tidak Tepat
1153	L	N	3,76	3,53	3,3	3,67	Tepat Waktu
1154	P	N	4	3,32	3,61	3,42	Tepat Waktu
1155	L	R	3,86	3,53	3,17	3	Tidak Tepat
1156	L	N	3,9	4	3,91	4	Tepat Waktu
1157	L	N	4	4	4	4	Tepat Waktu
1158	L	R	3,43	3,38	3,31	3,7	Tepat Waktu
1159	L	N	3,81	3	3,91	3,17	Tepat Waktu
1160	L	N	3,14	3,21	3,52	3,42	Tepat Waktu
1161	L	N	3,71	3,58	2,83	3,3	Tidak Tepat
1162	P	N	4	4	4	4	Tepat Waktu
1163	L	N	3,57	3,4	3,39	3,54	Tepat Waktu
1164	L	R	3,19	3,5	3,22	3,58	Tidak Tepat
1165	L	R	3,29	3,35	3,61	3,88	Tepat Waktu
1166	P	R	3,57	3,55	3,35	2,92	Tidak Tepat
1167	L	R	2,43	2,88	2,8	3,17	Tidak Tepat
1168	P	R	3,62	3	2,48	3,67	Tepat Waktu
1169	P	N	3,57	3,75	3,74	3,75	Tepat Waktu
1170	P	R	3,81	3,85	4	3,92	Tepat Waktu
1171	L	N	3,38	3,25	3,35	3,71	Tepat Waktu
1172	P	N	3,81	3,85	3,87	4	Tepat Waktu
1173	L	R	3,05	3,55	3,35	3,71	Tepat Waktu
1174	L	R	2,57	2,85	3,07	2,83	Tidak Tepat
1175	L	R	2,81	3,4	3,61	3,92	Tepat Waktu

1176	P	N	3,24	3,35	3	3,48	Tidak Tepat
1177	L	R	3	3,25	3,09	3,58	Tepat Waktu
1178	L	R	3,19	3,6	3,09	3,88	Tepat Waktu
1179	L	R	3,19	3,5	3,35	3,67	Tepat Waktu
1180	P	R	3,62	3,45	3,88	3,88	Tidak Tepat
1181	L	R	3,86	4	3,88	3,79	Tepat Waktu
1182	P	R	3,71	3,85	4	4	Tidak Tepat
1183	L	R	3,76	3,85	3,67	3,38	Tidak Tepat
1184	P	R	3,71	4	4	4	Tepat Waktu
1185	P	R	3,67	3,6	3,5	3,58	Tepat Waktu
1186	P	R	3,57	3,55	3,63	3,58	Tepat Waktu
1187	P	R	3,52	3,6	3,5	3,5	Tepat Waktu
1188	L	R	3,81	4	3,75	3,58	Tepat Waktu
1189	L	R	3,24	3,1	3,17	3,3	Tidak Tepat
1190	P	R	3,43	3,1	3,33	3,17	Tidak Tepat
1191	P	R	3,33	3,35	3,46	3,5	Tepat Waktu
1192	P	R	3,57	3,45	3,5	3,38	Tepat Waktu
1193	P	R	3,24	3,35	3,42	3,38	Tidak Tepat
1194	L	N	3,48	3,3	3,5	2,87	Tidak Tepat
1195	L	N	3,29	3,1	3,21	2,65	Tidak Tepat
1196	P	N	3,48	3,55	3,5	3,35	Tepat Waktu
1197	P	N	3,81	3,6	3,75	3,88	Tepat Waktu
1198	L	N	3,48	3,2	3,42	2,65	Tidak Tepat
1199	P	N	3,9	3,9	3,92	4	Tepat Waktu
1200	P	R	3,81	3,8	3,83	3,92	Tepat Waktu
1201	P	R	4	3,9	4	4	Tepat Waktu
1202	P	R	3,9	4	3,92	4	Tepat Waktu
1203	P	R	3,9	3,9	3,92	4	Tepat Waktu
1204	L	N	3,1	3,6	2,71	2,14	Tidak Tepat
1205	L	N	3,67	3,6	3,42	3,46	Tidak Tepat
1206	P	N	3,71	3,6	3,46	3,54	Tepat Waktu
1207	P	R	3,85	4	4	4	Tepat Waktu
1208	L	N	3,1	3,67	3,46	3,35	Tidak Tepat
1209	L	R	3,25	3,22	3,46	4	Tepat Waktu
1210	L	R	2,83	2	2,5	3	Tidak Tepat
1211	P	R	3,85	3,83	4	4	Tepat Waktu
1212	P	R	3,75	3,89	3,88	3,74	Tidak Tepat
1213	P	R	3,85	3,89	3,88	3,87	Tepat Waktu
1214	P	R	3,6	4	4	4	Tepat Waktu
1215	L	R	3,65	3,89	3,63	3,74	Tepat Waktu
1216	L	R	3,4	3	2,88	2,8	Tidak Tepat
1217	L	R	3,65	3,83	3,88	3,74	Tepat Waktu
1218	L	R	3,25	3,11	3,17	2,7	Tidak Tepat
1219	L	N	3,3	3,5	3,5	3,75	Tepat Waktu

1220	L	R	3,3	3,28	3,38	3,5	Tepat Waktu
1221	L	R	3,5	3,72	3,46	3,38	Tidak Tepat
1222	P	R	3,55	3,83	3,42	3,63	Tepat Waktu
1223	P	N	3,8	4	4	4	Tepat Waktu
1224	P	R	3,75	3,5	3,79	3,74	Tepat Waktu
1225	L	R	3,75	3,55	3,79	3,87	Tepat Waktu
1226	P	R	4	4	3,92	3,87	Tepat Waktu
1227	P	R	4	3,8	3,75	3,87	Tepat Waktu
1228	L	N	2,2	2,05	3	2,42	Tidak Tepat
1229	L	N	2,35	2,3	3,17	2,71	Tidak Tepat
1230	L	N	2,1	1,95	2,8	2,85	Tidak Tepat
1231	P	R	3,75	3,6	3,88	4	Tepat Waktu
1232	L	N	3,55	3,82	3,67	3,25	Tepat Waktu
1233	P	N	3,35	3,3	3,88	4	Tepat Waktu
1234	L	N	3	3,35	3,88	3,35	Tidak Tepat
1235	L	N	1,56	3,1	3,75	3,35	Tidak Tepat
1236	P	N	2,35	3,7	3,88	4	Tepat Waktu
1237	L	N	3,5	3,83	3,54	4	Tepat Waktu
1238	L	R	3,6	3,83	4	3,88	Tepat Waktu
1239	L	N	3,8	3,83	3,63	3,75	Tepat Waktu
1240	P	R	3,5	2,4	3,5	4	Tepat Waktu
1241	L	R	3,05	2,9	2,35	3,13	Tidak Tepat
1242	L	N	3,29	3,15	3,68	3,88	Tidak Tepat
1243	L	N	3,38	3,25	3,62	3,75	Tidak Tepat
1244	L	R	3,62	3,3	2,64	3,38	Tidak Tepat
1245	L	R	3,71	3,9	4	3,63	Tepat Waktu
1246	L	R	3,43	3,65	4	3,63	Tepat Waktu
1247	L	R	3,81	3,85	3,86	3,63	Tepat Waktu
1248	P	R	3,81	3,55	3,9	3,71	Tepat Waktu
1249	P	R	3,86	4	4	3,71	Tepat Waktu
1250	P	N	4	4	4	3,71	Tepat Waktu
1251	P	R	3,9	3,75	3,86	4	Tepat Waktu
1252	P	R	3,81	3,9	4	4	Tepat Waktu
1253	L	N	3,81	2,8	3	3,27	Tidak Tepat
1254	L	N	3,71	3,2	3	3,27	Tidak Tepat
1255	L	N	3,29	3,75	4	3,63	Tepat Waktu
1256	L	N	3,33	3,54	3,57	3,38	Tepat Waktu
1257	P	N	3,92	3,54	3,74	2,5	Tepat Waktu
1258	L	N	3,63	3,67	3,43	3,63	Tepat Waktu
1259	L	N	3	3,67	3,74	3,5	Tepat Waktu
1260	L	R	2,67	2,5	3,76	3	Tidak Tepat
1261	L	N	3,25	3,42	3,13	2,63	Tepat Waktu
1262	L	R	3,63	3,67	3,83	3,75	Tidak Tepat
1263	P	R	3,88	3,92	4	4	Tepat Waktu

1264	P	R	3,54	3,83	3,79	3,38	Tepat Waktu
1265	P	R	3,08	3,58	3,61	3,13	Tepat Waktu
1266	L	R	3,29	3,67	3,78	3,38	Tepat Waktu
1267	L	R	2,5	3,33	3,65	3,38	Tepat Waktu
1268	L	R	3,46	3,38	3,58	3,5	Tepat Waktu
1269	L	R	3	3	3,24	3,38	Tidak Tepat
1270	L	N	3,5	3,67	3,48	3,63	Tepat Waktu
1271	L	R	2,58	3,58	3,5	3,13	Tepat Waktu
1272	L	N	3,75	3,67	3,48	3,63	Tepat Waktu
1273	L	R	3,42	3	3,5	3,25	Tidak Tepat
1274	L	N	3,88	3,79	4	4	Tepat Waktu
1275	L	R	3,71	3,54	4	3,63	Tepat Waktu
1276	L	R	2,88	2,75	3,52	3,25	Tidak Tepat
1277	L	R	3,08	2,71	3,62	3,13	Tidak Tepat
1278	L	R	3,71	3,5	3,79	3,63	Tidak Tepat
1279	L	R	3	2,46	3,67	3,25	Tidak Tepat
1280	L	N	3,54	3,75	3,87	3,88	Tepat Waktu
1281	P	N	3,75	3,54	4	3,25	Tepat Waktu
1282	L	N	3,38	3,5	3,52	3,88	Tepat Waktu
1283	L	N	3,75	3,54	3,74	3,5	Tepat Waktu
1284	L	R	3,25	3,38	3,79	3,5	Tepat Waktu
1285	L	R	3,67	3,67	3,75	3,63	Tepat Waktu
1286	L	R	2,88	3	2,87	3	Tidak Tepat
1287	L	N	3,08	3,67	3,57	3,13	Tepat Waktu
1288	P	R	3,88	3,67	4	3,63	Tepat Waktu
1289	L	R	2	2,21	3	2,75	Tidak Tepat
1290	L	N	3,75	3,67	3,87	3,75	Tepat Waktu
1291	L	N	3,29	3,67	3,43	3,25	Tidak Tepat
1292	P	R	3,58	2,46	3,82	3,5	Tepat Waktu
1293	L	R	2,96	2,79	3,65	2,88	Tidak Tepat
1294	P	R	3,29	2,96	3,71	3,63	Tepat Waktu
1295	L	R	3,21	2,75	3,24	2,38	Tidak Tepat
1296	L	R	3,67	3,33	3,78	3,38	Tepat Waktu
1297	L	R	2,13	2	2,2	1,67	Tidak Tepat
1298	P	R	3,71	3,38	3,79	3,5	Tepat Waktu
1299	L	R	3,88	3,92	4	4	Tepat Waktu
1300	L	R	3,88	4	4	4	Tepat Waktu
1301	P	R	3,88	4	4	4	Tepat Waktu
1302	P	R	3,88	4	3,91	4	Tepat Waktu
1303	P	R	4	4	4	4	Tepat Waktu
1304	L	R	3,88	3,79	3,09	3,75	Tepat Waktu
1305	P	N	3,88	3,88	4	3,88	Tepat Waktu
1306	P	N	3,58	2,79	2,76	3	Tidak Tepat
1307	L	R	4	3,92	3,87	4	Tepat Waktu

1308	P	R	4	3,33	3,7	3,88	Tepat Waktu
1309	L	R	4	3,13	3,7	4	Tepat Waktu
1310	L	R	3,92	3	3,7	3,25	Tepat Waktu
1311	L	R	4	3,67	3,86	4	Tepat Waktu
1312	L	R	3,92	3,54	3,87	4	Tepat Waktu
1313	P	R	4	3,25	3,78	3,25	Tepat Waktu
1314	P	R	4	3,33	3,78	3,25	Tepat Waktu
1315	P	N	3,71	3,58	3,78	3,25	Tepat Waktu
1316	P	N	3,75	3,58	3,78	3,25	Tepat Waktu
1317	P	N	3,75	3,46	3,87	3,25	Tepat Waktu
1318	L	N	3,75	3,92	3,65	3,25	Tepat Waktu
1319	L	N	3,63	3,25	3,3	2,88	Tidak Tepat
1320	L	N	3	4	3,5	3,48	Tepat Waktu
1321	P	N	3,13	3,33	3,43	4	Tepat Waktu
1322	P	N	3,63	3,5	3,78	3,25	Tepat Waktu
1323	P	N	3,5	3,5	3,65	3,5	Tepat Waktu
1324	P	N	4	3,83	3,78	4	Tepat Waktu
1325	P	N	3,63	3,25	3,57	4	Tepat Waktu
1326	P	N	3,13	3	3,09	3,5	Tepat Waktu
1327	L	N	3,5	3,33	3,43	3,25	Tidak Tepat
1328	P	N	3,54	2,63	3	3,25	Tidak Tepat
1329	L	N	3,63	3,25	3,57	3,5	Tepat Waktu
1330	L	N	3,13	3,13	3	3	Tidak Tepat
1331	P	N	3,88	3,88	4	4	Tepat Waktu
1332	P	N	3,79	3,88	4	4	Tepat Waktu
1333	P	N	3,88	4	4	4	Tepat Waktu
1334	L	N	4	3,92	3,91	3,88	Tepat Waktu
1335	L	N	3,79	3,04	3,13	2,88	Tidak Tepat
1336	P	R	3,54	3,88	3,65	3,75	Tepat Waktu
1337	L	N	4	3,88	4	3,88	Tepat Waktu
1338	P	N	3,75	3,75	4	3,5	Tepat Waktu
1339	P	R	3,63	3,67	4	3,88	Tepat Waktu
1340	L	R	3,71	3,88	3,7	4	Tepat Waktu
1341	P	R	3,92	3,58	3,43	3,63	Tepat Waktu
1342	L	R	3,75	3,88	3,87	3,88	Tepat Waktu
1343	L	N	3,92	3,71	3,78	3,88	Tepat Waktu
1344	P	N	4	3,67	3,52	3,63	Tepat Waktu
1345	P	R	4	4	3,87	3,88	Tepat Waktu
1346	P	R	3,67	3,71	4	3,88	Tepat Waktu
1347	P	N	3,88	3,79	3,91	3,38	Tepat Waktu
1348	L	N	3,88	4	3,7	3,63	Tepat Waktu
1349	L	N	3,88	3,54	3,78	3,38	Tepat Waktu
1350	L	R	3,54	3,79	3,7	3,63	Tepat Waktu
1351	P	R	3,75	3,79	4	2,63	Tepat Waktu

1352	P	N	3,92	4	3,91	3,63	Tepat Waktu
1353	L	N	3,71	3,17	3,3	3	Tidak Tepat
1354	P	R	3,75	3,88	4	3,75	Tepat Waktu
1355	P	N	3,67	3,67	3,78	3,38	Tepat Waktu
1356	L	N	3,88	3,63	3,87	3,88	Tepat Waktu
1357	P	N	4	4	4	3,63	Tepat Waktu
1358	P	N	4	4	4	3,75	Tepat Waktu
1359	L	N	3,29	2,71	2,57	2,86	Tidak Tepat
1360	L	N	3,71	3,58	3,43	3,5	Tepat Waktu
1361	L	N	3,42	3,54	3,74	3,5	Tepat Waktu
1362	L	R	3,29	3,67	3,7	3,5	Tepat Waktu
1363	L	R	1,71	2,38	3	3,13	Tidak Tepat
1364	P	N	3,88	3,25	3,65	4	Tepat Waktu
1365	L	R	4	3,83	3,87	3,5	Tepat Waktu
1366	L	N	3,88	3,58	3,65	3,13	Tepat Waktu
1367	L	N	3,38	3,13	3,09	3	Tidak Tepat
1368	L	N	3,25	3,13	3,09	3	Tidak Tepat
1369	L	N	3,25	3,25	3,09	3	Tidak Tepat
1370	L	N	3,25	2,71	3,38	3,25	Tidak Tepat
1371	L	N	3,5	2,75	3,1	1,13	Tidak Tepat
1372	L	R	3	2,54	4	3,63	Tepat Waktu
1373	L	N	3,92	3,54	3,22	3,13	Tidak Tepat
1374	P	R	4	4	3,74	4	Tepat Waktu
1375	P	R	3,83	3,88	3,87	3,88	Tepat Waktu
1376	L	R	3,17	3,21	3	3,13	Tidak Tepat
1377	P	N	3,88	3,75	3,74	4	Tepat Waktu
1378	L	N	3,17	2,71	3,15	1,75	Tidak Tepat
1379	L	N	3,92	3,58	3,87	3,5	Tidak Tepat
1380	P	N	3,83	3,21	3,61	3,25	Tidak Tepat
1381	P	R	3,88	3,88	3,87	3,88	Tidak Tepat
1382	P	R	3,92	4	3,87	3,38	Tepat Waktu
1383	L	N	3,75	3,46	3,35	3,25	Tidak Tepat
1384	P	N	3,88	3,21	3,87	3,88	Tepat Waktu
1385	L	N	3,71	3,33	3,61	3	Tepat Waktu
1386	L	N	3	2,71	2,85	2,71	Tidak Tepat
1387	L	R	3,46	3,46	3,26	2,75	Tidak Tepat
1388	P	R	3,88	4	4	3,88	Tepat Waktu
1389	P	R	4	4	3,87	4	Tepat Waktu
1390	P	R	4	4	3,87	4	Tepat Waktu
1391	L	R	3,63	2,96	2,4	2,33	Tidak Tepat
1392	P	N	3,88	3,33	3,48	3	Tidak Tepat
1393	P	R	2,88	3,46	3	2,5	Tidak Tepat
1394	L	N	3,46	3,08	3,22	2,88	Tidak Tepat
1395	L	R	4	4	3,87	4	Tepat Waktu

1396	L	N	4	4	3,74	4	Tidak Tepat
1397	L	R	3,29	2,75	2,14	3,39	Tidak Tepat
1398	P	R	4	4	3,22	2,92	Tidak Tepat
1399	L	R	4	3,85	3,24	3,08	Tidak Tepat
1400	L	R	3,71	3,85	3,24	3,92	Tepat Waktu
1401	L	R	3,76	3,4	2,71	3,3	Tidak Tepat
1402	L	R	3,81	3,15	2,71	3	Tidak Tepat
1403	P	R	3,86	3,7	3,26	3,92	Tepat Waktu
1404	L	R	3,86	3,85	3,24	3,58	Tepat Waktu
1405	L	R	3,57	3,4	3,5	3,55	Tidak Tepat
1406	P	R	4	3,7	3,63	3,83	Tepat Waktu
1407	L	R	4	3,55	3,63	3,83	Tepat Waktu
1408	L	R	4	3,7	3,63	3,54	Tidak Tepat
1409	L	N	3,62	3,1	2,33	3,17	Tidak Tepat
1410	P	R	3,9	3,7	3,25	3	Tidak Tepat
1411	L	R	4	4	3,88	3,88	Tepat Waktu
1412	L	N	3,04	2	3,11	3,1	Tidak Tepat
1413	L	N	3,79	3,55	3,87	2,92	Tepat Waktu
1414	L	R	2,75	2,59	3,25	3,13	Tidak Tepat
1415	L	R	3,67	3,18	3,5	3,76	Tepat Waktu
1416	L	R	3,88	3,59	3,71	3,22	Tepat Waktu
1417	P	R	3,79	3,64	3,79	3,33	Tepat Waktu
1418	L	R	3,63	2,91	3,45	3,19	Tidak Tepat
1419	L	R	3,58	3,64	2,7	3,55	Tepat Waktu
1420	L	N	3,92	2,27	3,06	3,32	Tidak Tepat
1421	P	N	4	4	3,75	4	Tepat Waktu
1422	L	N	3,25	3,67	2,17	3	Tidak Tepat
1423	L	N	3,5	3,42	2,71	3,45	Tidak Tepat
1424	L	N	4	3,83	4	4	Tepat Waktu
1425	L	N	3,5	3,71	3,92	3,67	Tepat Waktu
1426	L	R	3,25	3,33	3	3,64	Tepat Waktu
1427	L	N	3,4	3,25	3,79	3,08	Tidak Tepat
1428	L	N	3	3,17	3,17	2,75	Tidak Tepat
1429	L	R	3,65	3,67	2,83	3	Tidak Tepat
1430	L	R	3,8	3,63	3,5	3,21	Tepat Waktu
1431	L	N	3,65	3,29	3,42	2,67	Tidak Tepat
1432	P	R	3,9	4	4	4	Tepat Waktu
1433	L	R	3,25	3,17	3,21	2,55	Tidak Tepat
1434	L	N	3,25	3,21	1,88	1,8	Tidak Tepat
1435	P	R	3,75	4	4	4	Tidak Tepat
1436	L	N	2,9	2,83	2,95	2,75	Tidak Tepat
1437	L	R	3,65	3,5	3	3,45	Tidak Tepat
1438	L	N	2,95	3	2,4	2,25	Tidak Tepat
1439	P	R	3,75	3,75	4	3,88	Tepat Waktu

1440	P	R	3,25	3,63	2,88	3,85	Tidak Tepat
1441	L	R	3,8	3,88	3,63	3,67	Tepat Waktu
1442	P	N	3,9	3,88	3,75	4	Tepat Waktu
1443	L	N	3,35	2,88	2,76	2,81	Tidak Tepat
1444	L	N	3,4	3,29	2,88	3,25	Tidak Tepat
1445	L	R	3,65	4	3,33	3,71	Tepat Waktu
1446	P	R	3,9	3,75	3,63	3,75	Tepat Waktu
1447	P	R	3,9	3,88	3,67	3,92	Tidak Tepat
1448	L	R	3,9	3,88	3,13	3,33	Tidak Tepat
1449	L	R	3,4	4	3,5	4	Tepat Waktu
1450	L	R	3,5	3,71	3,17	3,23	Tidak Tepat
1451	P	R	3,9	3,88	3,79	3,71	Tepat Waktu
1452	P	N	3,1	3,13	3,25	2,75	Tidak Tepat
1453	L	N	3,2	3,42	3,33	3,08	Tidak Tepat
1454	L	R	3,4	4	4	4	Tepat Waktu
1455	P	R	3,75	2,92	1,05	3,08	Tidak Tepat
1456	L	R	3,2	2,86	2,12	3	Tidak Tepat
1457	L	N	2,82	2,67	3	1,8	Tidak Tepat
1458	P	R	3,65	3,88	3,38	3,59	Tepat Waktu
1459	L	R	3,15	3,29	1,54	2,2	Tidak Tepat
1460	P	R	3,4	3,42	3,13	3,91	Tepat Waktu
1461	L	N	3,1	2,79	2,71	3,3	Tidak Tepat
1462	L	N	3,18	3,21	3,33	2,63	Tidak Tepat
1463	L	N	3,1	2,19	1,75	2,18	Tidak Tepat
1464	P	R	3,9	3,88	3,88	3,79	Tepat Waktu
1465	P	R	3,8	3,88	3,58	3,71	Tidak Tepat
1466	L	N	3,1	3,08	3	2,59	Tidak Tepat
1467	L	R	3,6	3,79	3,38	3,46	Tidak Tepat
1468	P	R	3,65	3,83	3,75	4	Tidak Tepat
1469	P	R	3,1	2,76	1,83	2,93	Tidak Tepat
1470	L	R	3,5	3,54	3,29	3,05	Tidak Tepat
1471	L	R	2,6	3,79	3,04	3,5	Tidak Tepat
1472	L	R	3,25	3,42	3	3,5	Tidak Tepat
1473	L	R	3,65	3,42	3,08	3,5	Tidak Tepat
1474	L	R	3,1	3,08	3,42	3,42	Tidak Tepat
1475	L	R	3,4	3,75	3,33	3,54	Tepat Waktu
1476	P	N	3,85	3,58	3,92	3,58	Tepat Waktu
1477	L	N	3,35	3,46	3,04	3,04	Tidak Tepat
1478	L	N	4	3,92	3,92	4	Tepat Waktu
1479	L	R	3,2	3,33	3,29	2,96	Tidak Tepat
1480	P	N	3,35	3,83	3,29	2,54	Tidak Tepat
1481	L	R	3,7	3,25	2,42	3,5	Tepat Waktu
1482	L	N	3,35	3,25	3,08	2,96	Tidak Tepat
1483	L	N	3,35	3,25	3	3,21	Tidak Tepat

1484	L	R	3,24	3,79	3,5	3,63	Tepat Waktu
1485	L	R	3,65	3,54	3,79	3,46	Tidak Tepat
1486	L	N	3,2	3,46	3,04	2,25	Tidak Tepat
1487	L	R	3,55	3,54	3,17	3,17	Tidak Tepat
1488	P	R	3,5	3	3,75	3,5	Tepat Waktu
1489	L	R	3,7	3,88	3,75	3,67	Tepat Waktu
1490	P	R	3,9	3,75	3,29	3,33	Tidak Tepat
1491	L	R	3,45	3,63	3,42	3,38	Tidak Tepat
1492	P	R	3,2	3,88	3,67	3,5	Tepat Waktu
1493	L	R	3,75	3,38	3,21	2,96	Tidak Tepat
1494	L	R	3,75	4	4	3,73	Tepat Waktu
1495	L	R	3,75	2,75	3,38	3,08	Tidak Tepat
1496	P	R	3,5	3,75	3,25	3,14	Tidak Tepat
1497	L	R	3,6	3,75	3,88	3,45	Tepat Waktu
1498	P	R	3,45	3,88	3,46	3,32	Tidak Tepat
1499	P	R	3,65	3,88	3,79	3,67	Tepat Waktu
1500	P	R	3,3	3,88	3,46	3,36	Tidak Tepat
1501	L	R	3,45	3,75	3,58	3,45	Tepat Waktu
1502	P	R	3,45	4	4	3,59	Tepat Waktu
1503	P	R	3,5	3,67	3,42	3,14	Tidak Tepat
1504	P	R	3,9	4	3,88	3,75	Tepat Waktu
1505	P	R	3,6	3,88	3,33	3,36	Tidak Tepat
1506	L	R	3,75	3,63	3,46	3,45	Tidak Tepat
1507	P	R	3,75	3,75	3,67	3,05	Tidak Tepat
1508	P	R	3,6	3,88	3,42	3,29	Tidak Tepat
1509	P	N	3,75	3,88	3,92	3,73	Tepat Waktu
1510	L	R	3,75	3,67	3,88	3,73	Tepat Waktu
1511	P	N	3,6	3,54	3,33	2,86	Tidak Tepat
1512	L	N	3,5	3,88	3,79	3,79	Tepat Waktu
1513	P	N	3,6	4	3,88	3,88	Tepat Waktu
1514	P	R	4	4	3,88	3,88	Tepat Waktu
1515	P	N	4	4	3,88	3,88	Tepat Waktu
1516	P	R	3,6	4	3,88	3,88	Tepat Waktu
1517	L	N	3,9	3,75	3,33	3,59	Tidak Tepat
1518	P	R	4	4	3,88	3,88	Tepat Waktu
1519	P	N	4	4	3,88	3,88	Tepat Waktu
1520	L	N	3,9	3,88	3,88	3,71	Tepat Waktu
1521	L	N	4	4	3,88	3,88	Tidak Tepat
1522	L	N	3,6	3,88	3,88	3,67	Tepat Waktu
1523	L	N	3,6	3,88	3,88	3,71	Tidak Tepat
1524	P	N	4	4	3,88	3,79	Tepat Waktu
1525	L	N	4	4	3,88	3,88	Tepat Waktu
1526	L	N	3,75	3,88	3,88	3,79	Tepat Waktu
1527	L	N	3,9	3,88	3,88	3,88	Tepat Waktu

1528	L	N	3,6	3,88	3,88	3,79	Tidak Tepat
1529	L	N	3,7	3,88	3,88	3,88	Tidak Tepat
1530	P	N	4	3,88	3,88	3,88	Tepat Waktu
1531	L	N	4	3,88	3,88	3,79	Tepat Waktu
1532	P	N	3,7	3,88	3,88	3,88	Tepat Waktu
1533	P	N	4	3,88	3,88	3,88	Tepat Waktu
1534	P	N	4	3,88	3,88	3,88	Tepat Waktu
1535	L	N	3,6	3,88	3,88	3,88	Tepat Waktu
1536	P	N	3,9	3,88	3,88	3,88	Tepat Waktu
1537	L	N	3,2	3,25	3,29	3,33	Tidak Tepat
1538	P	R	3,35	3,67	3,29	3,25	Tidak Tepat
1539	P	R	3,2	3,71	3,29	3,29	Tidak Tepat
1540	P	R	2,95	3,25	2,67	2,95	Tidak Tepat
1541	L	N	3,1	3,33	3	3,04	Tidak Tepat
1542	P	N	3,35	3,67	3,54	3,5	Tepat Waktu
1543	P	R	3,45	3,92	3,54	3,75	Tepat Waktu
1544	P	R	3,35	3,67	3,33	3,54	Tepat Waktu
1545	L	N	3,2	3	3,29	2,83	Tidak Tepat
1546	P	R	3,35	3,88	2,96	3,7	Tepat Waktu
1547	P	R	3,25	3,67	3,17	3,5	Tepat Waktu
1548	P	R	3,2	3,67	3,54	3,38	Tidak Tepat
1549	P	R	3,5	3,67	3,42	3,5	Tepat Waktu
1550	P	N	3,5	3,33	3,25	3,25	Tidak Tepat
1551	L	N	3,5	3,71	3,88	4	Tepat Waktu
1552	L	N	3,5	3,54	3,33	3,17	Tidak Tepat
1553	L	N	3,35	3,67	3,29	3,08	Tidak Tepat
1554	L	R	3,1	3,33	2,88	3,05	Tidak Tepat
1555	P	R	3,75	3,88	3,88	3,88	Tepat Waktu
1556	P	R	3,6	3,92	3,88	3,75	Tepat Waktu
1557	L	N	3,5	3,71	3,13	2,91	Tidak Tepat
1558	L	N	3,6	3,54	3,67	3,54	Tepat Waktu
1559	L	R	3,6	3,79	3,29	3,36	Tidak Tepat
1560	L	R	3,2	3,38	3	3,29	Tidak Tepat
1561	P	N	3,55	3,88	3,38	3,42	Tidak Tepat
1562	P	R	3,6	3,79	3,88	3	Tidak Tepat
1563	P	N	3,1	3,04	2,79	3	Tidak Tepat
1564	L	R	3,1	3,46	3,29	3,54	Tepat Waktu
1565	P	R	3,35	3,67	3,33	3,38	Tidak Tepat
1566	P	N	3,45	3,79	3,88	3,73	Tepat Waktu
1567	P	R	3,35	3,67	3,54	3,63	Tepat Waktu
1568	P	N	3,7	4	4	3,88	Tepat Waktu
1569	P	R	3,75	3,83	3,54	3,38	Tidak Tepat
1570	P	N	4	4	4	3,63	Tepat Waktu
1571	P	N	4	4	4	4	Tepat Waktu

1572	P	N	3,5	3,58	3,5	3,29	Tidak Tepat
1573	P	R	3,5	3,83	3,54	3,63	Tepat Waktu
1574	P	N	3,15	3,25	3,5	3,42	Tidak Tepat
1575	P	N	3,2	3,67	3,92	3,88	Tepat Waktu
1576	P	N	3,35	3,67	2,88	3,4	Tidak Tepat
1577	L	R	3,55	3,46	3,67	3,63	Tepat Waktu
1578	P	N	3,25	3,54	3,54	3,32	Tidak Tepat
1579	L	R	3,6	3,54	3,71	3,91	Tepat Waktu
1580	L	N	3,35	3,46	3,21	3,27	Tidak Tepat
1581	P	R	3,6	3,38	3,33	3,73	Tepat Waktu
1582	P	R	3,45	3,17	3,21	3,36	Tidak Tepat
1583	P	N	3,15	3,25	3,46	3,09	Tidak Tepat
1584	L	R	3,6	3,46	3,42	3,77	Tepat Waktu
1585	L	R	3,2	3,5	3,42	3,63	Tepat Waktu
1586	P	R	3,6	3,88	4	3,63	Tepat Waktu
1587	L	R	3,75	3,79	3,83	3,75	Tepat Waktu
1588	L	R	3,7	3,79	3,46	3	Tidak Tepat
1589	L	N	3,35	3,42	3,54	3,21	Tidak Tepat
1590	L	N	3,35	3,67	3,75	3,42	Tidak Tepat
1591	P	R	3,35	3,5	3,54	3,63	Tepat Waktu
1592	P	R	4	3,92	4	3,88	Tepat Waktu
1593	L	N	3,45	3,67	3,58	3,32	Tidak Tepat
1594	P	N	3,1	3,42	3,54	3,38	Tepat Waktu
1595	P	R	3,75	4	4	4	Tepat Waktu
1596	P	R	3,35	3,04	3	3,5	Tepat Waktu
1597	P	N	3,6	3,75	3,63	3,23	Tidak Tepat
1598	L	R	2,95	3,17	3,04	3,36	Tidak Tepat
1599	P	R	3,2	3,21	3,42	3,54	Tepat Waktu
1600	L	N	3,35	3,63	3,67	3,58	Tepat Waktu
1601	P	R	4	4	4	4	Tepat Waktu
1602	P	N	2,85	3,17	3,29	2,95	Tidak Tepat
1603	P	R	3,6	3,88	3,58	3,58	Tepat Waktu
1604	P	R	3,35	2,63	2,94	3,78	Tepat Waktu
1605	P	N	3,7	2,83	3,1	3,7	Tepat Waktu
1606	L	R	1,94	2,71	2,62	2,17	Tidak Tepat
1607	L	N	3,6	3,88	3,88	3,71	Tepat Waktu

LAMPIRAN KODE PROGRAM

```
#Mengimport Library
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.tree import DecisionTreeClassifier

%matplotlib inline

#Proses Pengaitan dengan Google Drive
from google.colab import drive
drive.mount('/content/drive')

# 1. SELEKSI DATA
#Membaca Dataset File Excel
df =
pd.read_excel("/content/drive/MyDrive/skripsi/DATAFIX.xlsx")
df.head()

#Mengkonversi File Excel .xlsx ke .csv
df.to_csv("/content/drive/MyDrive/skripsi/DATAFIX.csv",
index=False)
df.info()

# Menghitung jumlah setiap kategori dalam kolom 'Keterangan
Lulus'
countplot = sns.countplot(data=df, x='Status',
palette=['#FF0000', "#0000FF"])

# Menambahkan label pada sumbu x dan y
plt.xlabel('Status Lulus')
plt.ylabel('Jumlah Data')

# Menambahkan judul
plt.title('Distribusi Waktu Kelulusan ')

# Menampilkan grafik
plt.show()
```

```
# Menghitung jumlah setiap kategori dalam kolom 'Keterangan
Lulus'
df['Status'].value_counts()

# 2. PREPROCESSING

# Mengelompokkan data berdasarkan atribut yang ingin
diperiksa
grouped_data = df.groupby(['JK', 'Kelas', 'IPS1', 'IPS2',
'IPS3', 'IPS4'])

# Memeriksa kategori kelas untuk setiap kelompok
for key, group in grouped_data:
    unique_classes = group['Status'].unique()
    if len(unique_classes) > 1:
        print(f"Kelompok {key}: Kelas yang berbeda =
{unique_classes}")
```

```

# Mengganti kategori kelas sesuai kondisi

df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'N') & (df['IPS1'] == 3.6) & (df['IPS2'] ==
3.88) & (df['IPS3'] == 3.88) & (df['IPS4'] == 3.71), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'N') & (df['IPS1'] == 3.86) & (df['IPS2'] ==
3.86) & (df['IPS3'] == 4.0) & (df['IPS4'] == 3.86), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'N') & (df['IPS1'] == 4.0) & (df['IPS2'] ==
4.0) & (df['IPS3'] == 3.88) & (df['IPS4'] == 3.88), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.9) & (df['IPS2'] ==
3.9) & (df['IPS3'] == 3.52) & (df['IPS4'] == 3.45), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'L') & (df['Kelas'] == 'R') & (df['IPS1'] == 4.0) & (df['IPS2'] ==
4.0) & (df['IPS3'] == 4.0) & (df['IPS4'] == 4.0), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'N') & (df['IPS1'] == 3.57) & (df['IPS2'] ==
3.57) & (df['IPS3'] == 3.75) & (df['IPS4'] == 3.63), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'N') & (df['IPS1'] == 3.87) & (df['IPS2'] ==
3.87) & (df['IPS3'] == 3.88) & (df['IPS4'] == 4.0), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.64) & (df['IPS2'] ==
3.64) & (df['IPS3'] == 3.89) & (df['IPS4'] == 3.32), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.71) & (df['IPS2'] ==
3.71) & (df['IPS3'] == 4.0) & (df['IPS4'] == 3.75), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.73) & (df['IPS2'] ==
3.73) & (df['IPS3'] == 3.89) & (df['IPS4'] == 3.32), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.75) & (df['IPS2'] ==
4.0) & (df['IPS3'] == 4.0) & (df['IPS4'] == 4.0), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.77) & (df['IPS2'] ==
3.77) & (df['IPS3'] == 3.89) & (df['IPS4'] == 3.32), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 3.87) & (df['IPS2'] ==
3.87) & (df['IPS3'] == 3.63) & (df['IPS4'] == 3.33), 'Status'] = 'Tepat Waktu'
df.loc[(df['JK'] == 'P') & (df['Kelas'] == 'R') & (df['IPS1'] == 4.0) & (df['IPS2'] ==
4.0) & (df['IPS3'] == 3.87) & (df['IPS4'] == 3.88), 'Status'] = 'Tepat Waktu'

# Menampilkan DataFrame setelah perubahan

print(df)

```

```

# Menghitung jumlah setiap kategori dalam kolom 'Keterangan
Lulus'
df['Status'].value_counts()

# Menghitung jumlah setiap kategori dalam kolom 'Keterangan
Lulus'
countplot = sns.countplot(data=df, x='Status',
palette=['#FF0000', "#0000FF"])

# Menambahkan label pada sumbu x dan y
plt.xlabel('Status Lulus')
plt.ylabel('Jumlah Data')

# Menambahkan judul
plt.title('Distribusi Waktu Kelulusan ')

# Menampilkan grafik
plt.show()

#Menghitung data statistik
df.describe()

# 3. TRANSFORMASI
#Proses Konversi Nilai String ke Numerik
df['JK'].replace(['L','P'],[1,2], inplace=True)
df.head()
df['Kelas'].replace(['R','N'],[1,2], inplace=True)
df.head()

# 4. PROSES DATA MINING
# memisahkan atribut dan label
X = df[['JK','Kelas','IPS1','IPS2', 'IPS3','IPS4' ]]
y = df['Status']

# Membagi dataset menjadi data latih & data uji
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.3, random_state=0)
print ('Train set:', X_train.shape, y_train.shape)
print ('Test set:', X_test.shape, y_test.shape)

```

```

#membuat model decision tree
clf = DecisionTreeClassifier()
# Melatih model dengan menggunakan data latih
tree_model1 = clf.fit(X_train, y_train)

# 5. Evaluasi MODEL
from sklearn.metrics import confusion_matrix,
classification_report
from sklearn.metrics import confusion_matrix
import seaborn as sns
import matplotlib.pyplot as plt

# 6. Evaluasi Model
y_pred = tree_model1.predict(X_test)
labels=y
# Membuat confusion matrix
cm = confusion_matrix(y_test, y_pred)

# Mencetak confusion matrix
labels = [ 'Tepat Waktu', 'Tidak Tepat' ]
plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt='d', xticklabels=labels ,
yticklabels=labels, cmap='viridis')
plt.xlabel('Predicted')
plt.ylabel('Actual')
plt.title('Confussion matrix')
plt.show()

# Menghitung precision, recall, f1-score, dan support
report = classification_report(y_test, y_pred,
target_names=labels)
print(report)

# 6. VISUALISASI POHON

from six import StringIO
import pydotplus
import matplotlib.image as mpimg
from sklearn import tree

%matplotlib inline

```

```

dot_data = StringIO()
filename = "/content/drive/MyDrive/skripsi/POHON1.png"
featureNames = ['JK', 'Kelas', 'IPS1', 'IPS2', 'IPS3', 'IPS4']
targetNames = ['Tepat Waktu', 'Tidak Tepat']
out = tree.export_graphviz(tree_model1,
feature_names=featureNames, out_file=dot_data, class_names=
np.unique(y_train), filled=True, special_characters=True,
rotate=False)
graph = pydotplus.graph_from_dot_data(dot_data.getvalue())
graph.write_png(filename)
img = mpimg.imread(filename)
plt.figure(figsize=(200, 100))
plt.imshow(img, interpolation='nearest')

```

PEMANGKASAN POHON

Mengganti kategori kelas sesuai kondisi

```

df.loc[ (df['IPS1'] <= 2.5), 'Status'] = 'Tidak Tepat'
df.loc[ (df['IPS2'] <= 2.5), 'Status'] = 'Tidak Tepat'
df.loc[ (df['IPS3'] <= 2.5), 'Status'] = 'Tidak Tepat'
df.loc[ (df['IPS4'] <= 2.89), 'Status'] = 'Tidak Tepat'

```

Menampilkan DataFrame setelah perubahan

```
print(df)
```

Mengganti kategori kelas sesuai kondisi

```
df.loc[ (df['IPS4'] > 3.75), 'Status'] = 'Tepat Waktu'
```

Menampilkan DataFrame setelah perubahan

```
print(df)
```

7. MENGUKUR KEDALAMAN POHON

```

X = df[['IPS1', 'IPS2', 'IPS3', 'IPS4']]
y = df['Status']

```

Membagi dataset menjadi data latih & data uji

```

from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.3, random_state=0)
print ('Train set:', X_train.shape, y_train.shape)
print ('Test set:', X_test.shape, y_test.shape)

```

```

from sklearn.tree import DecisionTreeClassifier
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
# Mencoba berbagai nilai kedalaman pohon
for max_depth in range(1, 11):
    clf = DecisionTreeClassifier(max_depth=max_depth)
    clf.fit(X_train, y_train)
    y_pred = clf.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)
    print(f"Max Depth = {max_depth}, Accuracy = {accuracy:.2f}")

# Mencoba berbagai nilai minimum sampel untuk percabangan
for min_samples_split in range(2, 11):
    clf = DecisionTreeClassifier(min_samples_split=min_samples_split)
    clf.fit(X_train, y_train)
    y_pred = clf.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)
    print(f"Min Samples Split = {min_samples_split}, Accuracy = {accuracy:.2f}")

# SELEKSI ATRIBUT
from sklearn.ensemble import ExtraTreesClassifier
import matplotlib.pyplot as plt
model = ExtraTreesClassifier()
model.fit(X, y)

print(model.feature_importances_) #use inbuilt class
feature_importances of tree based classifiers

#plot graph of feature importances for better visualization
feat_importances = pd.Series(model.feature_importances_,
index=X.columns)
feat_importances.nlargest(10).plot(kind='barh')
plt.show()

# Mengambil atribut yang berpengaruh ke hasil
X1 = df[['IPS1', 'IPS2', 'IPS3', 'IPS4']]
y1 = df['Status']

```

```

# Membagi dataset menjadi data latih & data uji
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.3, random_state=0)
print ('Train set:', X_train.shape,  y_train.shape)
print ('Test set:', X_test.shape,  y_test.shape)

# membuat model Decision Tree
#tree_model = DecisionTreeClassifier()
clf = DecisionTreeClassifier(max_depth=4,
min_samples_split=5, min_samples_leaf=5,
criterion="entropy")
#clf = DecisionTreeClassifier(max_depth=5,
min_samples_split=5)
# Melatih model dengan menggunakan data latih
tree_model2 = clf.fit(X_train, y_train)

# Evaluasi Model 2
from sklearn.metrics import confusion_matrix,
classification_report
from sklearn.metrics import confusion_matrix
import seaborn as sns
import matplotlib.pyplot as plt

# 6. Evaluasi Model
y_pred = tree_model2.predict(X_test)
labels=y
# Membuat confusion matrix
cm = confusion_matrix(y_test, y_pred)

# Mencetak confusion matrix
labels = [ 'Tepat Waktu','Tidak Tepat', ]
plt.figure(figsize=(8, 6))
sns.heatmap(cm, annot=True, fmt='d', xticklabels=labels ,
yticklabels=labels, cmap='plasma')
plt.xlabel('Predicted')
plt.ylabel('Actual')
plt.title('Confusion Matrix')
plt.show()

# Menghitung precision, recall, f1-score, dan support
report = classification_report(y_test, y_pred,
target_names=labels)

```


VISUALISASI POHON 2

```
dot_data = StringIO()
filename = "/content/drive/MyDrive/skripsi/pohon3.png"
featureNames = ['IPS1','IPS2', 'IPS3','IPS4']
targetNames = ['Tepat Waktu', 'Tidak Tepat']
out = tree.export_graphviz(tree_model2,
feature_names=featureNames, out_file=dot_data, class_names=
np.unique(y_train), filled=True, special_characters=True,
rotate=False)
graph = pydotplus.graph_from_dot_data(dot_data.getvalue())
graph.write_png(filename)
img = mpimg.imread(filename)
plt.figure(figsize=(200, 100))
plt.imshow(img,interpolation='nearest')
```

KLASIFIKASI DATA TESTING BARU

```
# Klasifikasi model dengan Data Baru (['IPS1',
'IPS2','IPS3','IPS4'])
hasil=tree_model2.predict([[3,3.8,3.6,4]])
print(hasil)

# Klasifikasi model dengan Data Baru (['IPS1',
'IPS2','IPS3','IPS4'])
hasil=tree_model2.predict([[3,2.8,3,4]])
print(hasil)

# Klasifikasi model dengan Data Baru (['IPS1',
'IPS2','IPS3','IPS4'])
hasil=tree_model2.predict([[2,2.5,3.5,2]])
print(hasil)

# Klasifikasi model dengan Data Baru (['IPS1',
'IPS2','IPS3','IPS4'])
hasil=tree_model2.predict([[3,4,4,4]])
print(hasil)

# Klasifikasi model dengan Data Baru (['IPS1',
'IPS2','IPS3','IPS4'])
hasil=tree_model2.predict([[4,2.5,2,2.5]])
print(hasil)
```

```
#Klasifikasi model dengan data baru dengan data dari Excel
data_tes = pd.read_excel("/content/drive/MyDrive/skripsi
alan/PR/DATAPR.xlsx")
data_tes.head()

#Mengkonversi File Excel .xlsx ke .csv
data_tes.to_csv("/content/drive/MyDrive/skripsi
alan/PR/DATAPR.csv", index=False)
data_tes.info()

dataX = data_tes[['IPS1', 'IPS2', 'IPS3', 'IPS4']]

print(dataX)

# klasifikasi model dengan data baru (IPS1, IPS2, IPS3, IPS4)
hasil=tree_model2.predict(dataX)
print(hasil)
```



**KEMENTERIAN PENDIDIKAN, KEBUDAYAAN,
RISET DAN TEKNOLOGI
UNIVERSITAS ICHSAN
(UNISAN) GORONTALO**

SURAT KEPUTUSAN MENDIKNAS RI NO. 84/D/O/2001
JL. Achmad Nadjamuddin No. 17 Telp. (0435) 829975 Fax (0435) 829976 Gorontalo

SURAT KETERANGAN
NO : 168/UNISAN-G/SKT/XI/2023

Yang bertanda tangan dibawah ini :

Nama : Amiruddin, S.Kom., M.Kom, MCF
NIDN : 0910097601
Jabatan : Wakil Rektor Bidang Akademik, Tata Kelola & Sistem Informasi

Menyatakan,

Nama : Alan Luawo
Nim : T3119059
Prodi : Teknik Informatika
Fakultas : Ilmu Komputer

Bahwa yang bersangkutan diberikan izin penelitian di Universitas Ichsan Gorontalo dengan judul penelitian **"PENERAPAN ALGORITMA FEATURE IMPORTANCE UNTUK SELEKSI ATRIBUT PADA C4.5 DALAM KLASIFIKASI WAKTU KELULUSAN MAHASISWA"**

Kepada caolon peneliti diharapkan:

1. Mematuhi segala ketentuan dan peraturan yang berlaku di Universitas Ichsan Gorontalo
2. Data penelitian bersifat rahasia dan tidak di izinkan menyampaikan informasi kepada pihak-pihak lain yang tidak berkepentingan.

Demikian surat keterangan ini dibuat untuk dapat dipergunakan sebagaimana mestinya,

Gorontalo, 21 November 2023

An. Rektor
Wakil Rektor Bidang Akademik, Tata Kelola &
Sistem Informasi



Amiruddin, S.Kom., M.Kom, MCF
NIDN. 0910097601

Tembusan:

1. Rektor Universitas Ichsan Gorontalo
2. Wakil Rektor I Bidang Akademik, Tata Kelola & Sistem Informasi
3. Mahasiswa yang bersangkutan
4. Arsip



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

SURAT REKOMENDASI BEBAS PLAGIASI
No. 484/FIKOM-UIG/R/XI/2023

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 : Alan Luawo
 NIM : T3119059
 Program Studi : Teknik Informatika (S1)
 Fakultas : Fakultas Ilmu Komputer
 Judul Skripsi : Penerapan Algoritma Feature Importance Untuk Seleksi Atribut Pada C4.5 Dalam Klasifikasi Waktu Kelulusan Mahasiswa Tepat Waktu

Sesuai hasil pengecekan tingkat kemiripan skripsi melalui aplikasi **Turnitin** untuk judul skripsi di atas diperoleh hasil *Similarity* sebesar **12%**, berdasarkan Peraturan Rektor No. 32 Tahun 2019 tentang Pendeteksian Plagiat pada Setiap Karya Ilmiah di Lingkungan Universitas Ichsan 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, 20 November 2023
 Tim Verifikasi,


Zulfrianto Y. Lamasiqi, M.Kom
 NIDN. 0944089101

Terlampir :
 Hasil Pengecekan Turnitin



Similarity Report ID: oid:25211:43656404

PAPER NAME

AUTHOR

PROPOSAL_T3119059_ALAN LUAWO.pdf
f

ALAN LUAWO alanluawo53@gmail.com

WORD COUNT

1670 Words

CHARACTER COUNT

9780 Characters

PAGE COUNT

31 Pages

FILE SIZE

2.6MB

SUBMISSION DATE

Sep 20, 2023 10:16 PM GMT+8

REPORT DATE

Sep 20, 2023 10:16 PM GMT+8

● 11% Overall Similarity

The combined total of all matches, including overlapping sources, for each database.

- 11% Internet database
- 1% Publications database
- Crossref database
- Crossref Posted Content database
- 1% Submitted Works database

● Excluded from Similarity Report

- Bibliographic material
- Quoted material
- Cited material
- Small Matches (Less than 10 words)



**KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET, DAN TEKNOLOGI
UNIVERSITAS ICHSAN GORONTALO**

FAKULTAS ILMU KOMPUTER

UPT. PERPUSTAKAAN FAKULTAS

SK. MENDIKNAS RI NO. 84/D/0/2001

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

SURAT KETERANGAN BEBAS PUSTAKA

No : 025/Perpustakaan-Fikom/XI/2023

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

Nama Anggota : Alan Luawo
No. Induk : T3119059
No. Anggota : M202387

Terhitung mulai hari, tanggal : Senin, 20 November 2023, dinyatakan telah bebas pinjam buku dan koleksi perpustakaan lainnya.

Demikian keterangan ini di buat untuk di digunakan sebagaimana mestinya.



Gorontalo, 20 November 2023

**Mengetahui,
Kepala Perpustakaan**

Apriyanto Alhamad, M.Kom

NIDN : 0924048601

RIWAYAT HIDUP PENELITI



Nama	: Alan Luawo
NIM	: T3119059
Tempat, Tgl Lahir	: Gorontalo, 31 Agustus 2001
Agama	: Islam
Jenis Kelamin	: Laki-Laki
Fakultas/Jurusan	: Ilmu Komputer / Teknik Informatika
Konsentrasi	: Software Engineering
Alamat	: Jl.Kh.Ahmad Dahlan, Kelurahan Limba B, Kota Selatan

Riwayat Pendidikan :

2016-2019	: SMK NEGERI 3 GORONTALO
Jurusan	: Teknik Otomotif
2013-2016	: SMP NEGERI 2 KOTA GORONTALO
2007-2013	: SDN No. 61 KOTA TIMUR
2006-2007	: TK Mawar Kota Timur