



Implementasi Support Vector Machine untuk Klasifikasi Laporan Gangguan Layanan Pelanggan Korporat

Syahrul Ramadhan, Heri Suroyo*

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Bina Darma, Palembang, Indonesia

Email: ¹syahrul27121999@gmail.com, ^{2,*}herisuroyo@binadarma.ac.id

Email Penulis Korespondensi: herisuroyo@binadarma.ac.id

Abstrak—Penelitian ini bertujuan membangun model klasifikasi berbasis *Support Vector Machine* (SVM) untuk mengidentifikasi dan mengelompokkan tingkat pengerjaan gangguan layanan pelanggan korporat PT. Telkom Indonesia Wilayah Telekomunikasi Sumatera Selatan. Data penelitian diperoleh secara langsung dari *Helpdesk Assurance* Unit CCAN selama periode Oktober 2023 hingga Januari 2024 dengan total 854 entri. Variabel target yang digunakan adalah tingkat pengerjaan, sedangkan variabel fitur meliputi jenis layanan, jenis perbaikan, dan durasi pengerjaan. Seluruh proses penelitian mengikuti kerangka kerja *Cross Industry Standard Process for Data Mining* (CRISP-DM) yang mencakup tahapan pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, hingga penyebaran model. Tahap persiapan data meliputi seleksi fitur, pengkodean label, normalisasi menggunakan standarisasi skala, serta pembagian data dengan proporsi 80:20. Model dibangun menggunakan SVM dengan fungsi inti linier dan konfigurasi probabilitas aktif. Hasil evaluasi menunjukkan akurasi sebesar 98,25%, nilai *log loss* sebesar 0,0200, serta nilai *Area Under Curve* sempurna mencapai 1,00 untuk seluruh kelas. Variabel durasi pengerjaan terbukti menjadi faktor paling berpengaruh dengan nilai korelasi 0,91 terhadap variabel target. Model yang dihasilkan telah disimpan dalam format berkas biner sehingga siap digunakan untuk implementasi praktis di lingkungan operasional nyata.

Kata Kunci: *Support Vector Machine*; CRISP-DM; Klasifikasi; Akurasi; *Log Loss*

Abstract—This study aims to develop a classification model based on *Support Vector Machine* (SVM) to identify and categorize service completion levels of corporate customer service disruptions at PT. Telkom Indonesia, South Sumatra Telecommunication Region. Research data was obtained directly from the *Helpdesk Assurance* CCAN Unit during the period of October 2023 to January 2024, comprising a total of 854 entries. The target variable used is the service completion level, while the feature variables include service type, repair type, and work duration. The entire research process follows the *Cross Industry Standard Process for Data Mining* (CRISP-DM) framework, covering business understanding, data understanding, data preparation, modeling, evaluation, and deployment stages. Data preparation included feature selection, label encoding, scale normalization, and an 80:20 data split. The model was built using SVM with a linear kernel and active probability configuration. Evaluation results demonstrate an accuracy of 98.25%, a *log loss* value of 0.0200, and a perfect *Area Under Curve* value of 1.00 for all classes. The work duration variable proved to be the most influential factor with a correlation value of 0.91 against the target variable. The resulting model has been saved in binary file format, making it ready for practical implementation in real operational environments.

Keywords: Support Vector Machine; CRISP-DM; Classification; Accuracy; Log Loss

1. PENDAHULUAN

PT. Telekomunikasi Indonesia Tbk. (Telkom) merupakan salah satu penyedia layanan telekomunikasi dan internet terbesar di Indonesia yang melayani jutaan pelanggan, termasuk segmen korporat dengan kebutuhan konektivitas yang sangat tinggi dan bersifat kritis. Dalam operasional sehari-hari, gangguan layanan pada pelanggan korporat menjadi permasalahan yang tidak dapat dihindari, mengingat kompleksitas infrastruktur jaringan yang dikelola secara masif di berbagai wilayah. Data laporan gangguan layanan pelanggan korporat di Wilayah Telekomunikasi (*Witel*) Sumatera Selatan mencapai 854 entri dalam rentang Oktober 2023 hingga Januari 2024, mencerminkan tingginya volume permasalahan yang harus ditangani secara sistematis dan efisien (Nasrum & Zulkarnain, 2022). Kondisi ini menuntut adanya pendekatan analitik berbasis data yang mampu mengklasifikasikan tingkat penyelesaian gangguan secara otomatis agar respons terhadap pelanggan dapat lebih cepat, terstruktur, dan tepat sasaran.

Permasalahan utama yang dihadapi terletak pada pengelolaan data laporan gangguan yang selama ini masih dilakukan secara manual dan konvensional, sehingga menyulitkan identifikasi pola serta penentuan prioritas penanganan gangguan secara tepat waktu. Pertumbuhan volume data laporan yang terus meningkat dari waktu ke waktu semakin memperparah kondisi tersebut, mengakibatkan respons layanan yang tidak optimal dan berpotensi menurunkan tingkat kepuasan pelanggan korporat secara signifikan. Kualitas layanan yang baik terbukti berkorelasi positif terhadap kepuasan dan kepercayaan pelanggan dalam jangka panjang (Sari et al., 2023), sehingga penanganan gangguan yang lambat dan tidak terstruktur dapat berdampak langsung pada loyalitas pelanggan. Oleh karena itu, dibutuhkan suatu solusi berbasis kecerdasan buatan yang mampu memproses dan mengklasifikasikan laporan gangguan secara otomatis dengan tingkat akurasi yang dapat diandalkan dalam skala operasional nyata.

Dalam konteks penanganan data berskala besar, teknik *data mining* telah terbukti menjadi pendekatan yang efektif untuk menemukan pola tersembunyi dalam kumpulan data yang kompleks dan heterogen (Ahmad et al., 2022). Salah satu metode *data mining* yang banyak digunakan untuk keperluan klasifikasi adalah *Support Vector Machine* (SVM). Metode ini bekerja dengan mengidentifikasi *hyperplane* terbaik yang memisahkan kelas-kelas data dalam ruang berdimensi tinggi, sehingga unggul dalam menangani data dengan fitur yang beragam sekaligus memiliki kemampuan generalisasi yang baik terhadap data baru (Haryatmi & Pramita Hervianti, 2021; Irmanda & Astriratma, 2021). Keunggulan SVM dalam menghasilkan batas keputusan yang optimal menjadikannya pilihan yang sangat relevan untuk



permasalahan klasifikasi pada data layanan telekomunikasi yang memiliki karakteristik multikelas dan multifitur.

Sejumlah penelitian terdahulu telah mengeksplorasi penerapan SVM pada berbagai domain klasifikasi. Nurul Kanaka et al. (2024) membandingkan SVM dengan *Decision Tree* pada aplikasi ruang guru dan menemukan bahwa SVM menghasilkan akurasi sebesar 96,15%, melampaui *Decision Tree* yang hanya mencapai 89,74%, namun penelitian tersebut terbatas pada domain pendidikan dan tidak menyentuh konteks layanan telekomunikasi. Sani et al. (2022) menerapkan SVM untuk klasifikasi berita *hoax* pada media daring Indonesia dan memperoleh akurasi sebesar 86,11%, lebih unggul dibandingkan algoritma *Naive Bayes Classifier*, meskipun fokusnya masih pada teks media sosial yang berbeda jauh dari data operasional perusahaan. Ramadhan & Triyudi (2022) melakukan perbandingan antara *K-Nearest Neighbor* dan SVM pada klasifikasi data calon pendonor darah, di mana SVM memperoleh akurasi 96,34% sekaligus nilai *F1-score* tertinggi, namun domain yang digunakan adalah kesehatan publik yang tidak berkaitan dengan layanan korporat. Sani et al. (2022) menerapkan SVM untuk klasifikasi pencemaran nama baik di media sosial *Twitter* dan berhasil memperoleh akurasi sebesar 77%, akan tetapi data yang digunakan merupakan data teks tidak terstruktur yang berbeda karakteristiknya dengan data laporan gangguan layanan. Dari keseluruhan kajian tersebut, belum ada penelitian yang secara spesifik menerapkan SVM pada data laporan gangguan layanan pelanggan korporat perusahaan telekomunikasi, sehingga penelitian ini hadir untuk mengisi kesenjangan tersebut secara langsung pada konteks operasional PT. Telkom Indonesia Witel Sumsel. Dhewayani et al. (2022) menerapkan metode klasifikasi *Naive Bayes* pada sistem prediksi di lingkungan Telkom dan memperoleh hasil yang cukup baik, namun pendekatan tersebut tidak secara spesifik menangani data laporan gangguan layanan pelanggan korporat sebagaimana yang menjadi fokus utama penelitian ini.

Guna memastikan proses analisis berjalan secara sistematis dan dapat dipertanggungjawabkan, penelitian ini mengadopsi kerangka kerja *Cross Industry Standard Process for Data Mining (CRISP-DM)* yang telah terbukti efektif dalam berbagai penelitian berbasis *data mining* (Saputra et al., 2024). Kerangka kerja ini mencakup enam tahapan mulai dari pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, hingga penyebaran model. Implementasi seluruh tahapan tersebut dilakukan menggunakan bahasa pemrograman *Python* yang dikenal memiliki ekosistem *library* kecerdasan buatan yang lengkap, fleksibel, dan telah banyak digunakan secara luas dalam penelitian *machine learning* (Alfarizi et al., 2023).

Penelitian ini bertujuan membangun model klasifikasi berbasis SVM untuk menganalisis dan mengklasifikasikan tingkat penyelesaian gangguan layanan pada data laporan pelanggan korporat PT. Telkom Indonesia Witel Sumsel, sekaligus menguji akurasi model menggunakan metrik evaluasi yang komprehensif meliputi akurasi, presisi, *recall*, dan *F1-score*. Kontribusi utama penelitian ini adalah menghasilkan model klasifikasi yang dapat diimplementasikan secara praktis oleh tim *helpdesk* PT. Telkom Indonesia Witel Sumsel sebagai alat bantu pengambilan keputusan dalam penanganan gangguan layanan pelanggan korporat, sehingga efisiensi operasional dan kualitas respons layanan dapat ditingkatkan secara signifikan dan berkelanjutan.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

Penelitian ini merupakan penelitian terapan berbasis komputasi yang menggunakan pendekatan klasifikasi pada data laporan gangguan layanan pelanggan korporat PT. Telekomunikasi Indonesia Tbk., *Witel Sumatera Selatan*. Data yang digunakan berjumlah 854 entri yang diperoleh langsung dari *Helpdesk Assurance* Unit CCAN selama periode Oktober 2023 hingga Januari 2024. Variabel target dalam penelitian ini adalah tingkat pengerjaan gangguan, sedangkan variabel independen mencakup jenis layanan, jenis perbaikan, dan durasi pengerjaan yang masing-masing merepresentasikan karakteristik operasional penanganan gangguan di lapangan.

2.2 Objek Penelitian

Data yang menjadi objek penelitian diperoleh dari *Helpdesk Assurance* Unit CCAN PT. Telekomunikasi Indonesia Tbk., *Witel Sumsel* dan mencakup periode Oktober 2023 hingga Januari 2024, dengan total 854 entri. Variabel yang dianalisis meliputi jenis layanan, jenis perbaikan, dan durasi pengerjaan sebagai fitur independen, serta tingkat pengerjaan sebagai variabel target. Untuk konteks operasional disertakan atribut pendukung seperti zona kerja, nama, waktu laporan dan penyelesaian, jarak lokasi, dan kategori pelanggan. Seluruh data dianonimkan sebelum analisis dan digunakan atas izin internal unit terkait untuk keperluan penelitian.


2.3 Metode Penelitian

Metode penelitian yang digunakan yaitu *Support Vector Machine* yang merupakan metode untuk memperkirakan hasil dalam skenario regresi dan klasifikasi. Dengan memasukkan gagasan kernel dalam ruang kerja berdimensi tinggi, SVM telah berevolusi untuk berfungsi pada permasalahan non-linier, meskipun masih beroperasi pada ide dasar pengklasifikasi linier yaitu kasus klasifikasi yang dapat dipisahkan secara linier (Wurijanto et al., 2022).

2.4 Tahapan Penelitian

Penelitian ini mengadopsi kerangka kerja *Cross Industry Standard Process for Data Mining (CRISP-DM)* sebagai alur metodologi utama yang telah dikembangkan sejak tahun 1996 dan ditetapkan sebagai standar proses dalam penelitian

berbasis penambangan data. Kerangka ini dipilih karena mampu menyediakan struktur proses yang sistematis, terukur, fleksibel, dan dapat diterapkan secara berulang pada berbagai domain penelitian (Alfarizi et al., 2023). Alur tahapan penelitian secara keseluruhan ditampilkan pada Gambar 1.




Gambar 1. Diagram Alur CRISP-DM

Fase pertama adalah pemahaman bisnis, yaitu tahap identifikasi mendalam terhadap kebutuhan dan tujuan operasional perusahaan sebagai landasan utama perancangan model penambangan data (Arif & Faisal, 2023). Pada fase ini ditetapkan bahwa tujuan teknis penelitian adalah membangun model klasifikasi tingkat pengerjaan gangguan layanan agar perusahaan dapat merespons setiap laporan secara lebih cepat, terstruktur, dan terencana sesuai prioritas penanganan yang telah ditentukan. Fase kedua adalah pemahaman data. Pada tahap ini dilakukan pengumpulan, penelaahan, dan validasi data mentah yang diperoleh dari sumber resmi perusahaan. Pendekatan analisis berbasis data seperti yang diterapkan dalam penelitian ini sejalan dengan prinsip pemanfaatan informatika sebagai alat bantu pengambilan keputusan yang telah terbukti efektif dalam berbagai domain penelitian komputasi. Proses validasi mencakup pemeriksaan terhadap tiga jenis kendala, yaitu keterbatasan tipe data, batasan rentang nilai, serta batasan wajib yang memastikan tidak ada kolom data yang dibiarkan kosong sehingga integritas dataset dapat terjaga sepenuhnya. Struktur atribut data yang digunakan ditampilkan secara lengkap pada Tabel 1.

Tabel 1. Atribut Data Laporan Gangguan Pelanggan Telkom 2023–2024

Kolom	Tipe Data
Zona Kerja	Objek (Teks/String)
Nama	Objek (Teks/String)
Pelanggan	Objek (Teks/String)
Jenis Layanan	Objek (Teks/String)
Jenis Gangguan	Objek (Teks/String)
Perbaikan	Objek (Teks/String)
Tanggal	<i>Datetime</i> (Format Tanggal)
Waktu Laporan	Objek (Teks/String)
Waktu Penyelesaian	Objek (Teks/String)
Durasi Pengerjaan	<i>Time</i>
Tingkat Pelayanan	<i>String</i>
Jarak/KM	<i>Float</i> (Angka Desimal)
Kategori Pelanggan	Objek (Teks/String)

Fase ketiga adalah persiapan data yang mencakup serangkaian proses meliputi pemilahan, pembersihan, konstruksi, pelabelan, hingga pengintegrasian data secara menyeluruh. Proses pembersihan bertujuan menghilangkan data duplikat, nilai kosong, serta inkonsistensi yang berpotensi menurunkan kualitas pemodelan. Rekayasa fitur kemudian dilakukan untuk memastikan representasi data yang optimal sebelum dimasukkan ke dalam algoritma klasifikasi, termasuk penentuan label kelas pada variabel target (Shedriko & Firdaus, 2022). Data yang telah bersih selanjutnya dibagi menjadi data latih dan data uji dengan proporsi yang telah ditetapkan sebelumnya. Fase keempat adalah pemodelan menggunakan algoritma *Support Vector Machine* (SVM). Algoritma ini bekerja dengan mencari *hyperplane* terbaik yang mampu memisahkan kelas-kelas data secara optimal dalam ruang berdimensi tinggi dengan cara memaksimalkan margin antarkelas secara konsisten (Haryatmi & Pramita Hervianti, 2021). Pendekatan ini menjadikan SVM sangat andal dalam menghasilkan batas keputusan yang kuat dan tahan terhadap variasi data baru. Seluruh proses pemodelan diimplementasikan menggunakan bahasa pemrograman *Python* yang memiliki kelengkapan pustaka komprehensif untuk kebutuhan pembelajaran mesin. Pemanfaatan pustaka seperti *Scikit-Learn* memungkinkan pengaturan parameter SVM secara lebih fleksibel guna mencapai tingkat akurasi yang diinginkan. Setelah model berhasil dibangun, tahapan berikutnya yaitu melakukan pengujian menggunakan data uji untuk memvalidasi efektivitas model melakukan klasifikasi.



Gambar 2. Hyperplane SVM

Secara matematis SVM merumuskan masalah sebagai optimasi terikat untuk meminimalkan norma bobot $\|w\|^2$ dengan kendala klasifikasi $y_i(w \cdot x_i + b) \geq 1 - \xi_i$, di mana ξ_i adalah variabel slack untuk mengizinkan pelanggaran margin dan parameter regularisasi C mengatur trade-off antara lebar margin dan kesalahan klasifikasi. Untuk data yang tidak dapat dipisahkan secara linier, SVM memanfaatkan kernel trick (mis. *linear*, *polynomial*, RBF) yang secara implisit memetakan data ke ruang berdimensi lebih tinggi sehingga pemisahan linier menjadi mungkin tanpa menghitung transformasi eksplisit (Laili et al., 2025).

Fase kelima adalah evaluasi model yang dilakukan menggunakan empat metrik utama yaitu akurasi, presisi, *recall*, dan *F1-score*, yang seluruhnya dihitung berdasarkan hasil matriks konfusi. Matriks konfusi memuat empat komponen penilaian meliputi *True Positive*, *True Negative*, *False Positive*, dan *False Negative* yang secara bersama-sama memberikan gambaran menyeluruh dan komprehensif tentang kemampuan model dalam mengklasifikasikan data secara benar maupun tidak benar pada setiap kelasnya (Sani et al., 2022). Fase keenam adalah penyebaran model. Model yang telah dievaluasi dan dinyatakan memenuhi standar performa kemudian diterapkan pada data sampel baru sebagai bentuk uji prediksi akhir untuk memverifikasi kemampuan generalisasi model. Hasil dari proses penyebaran ini kemudian disusun dalam bentuk laporan terstruktur yang dapat dimanfaatkan langsung oleh tim *helpdesk* PT. Telkom Indonesia Witel Sumsel sebagai acuan pengambilan keputusan operasional dalam penanganan gangguan layanan pelanggan korporat secara lebih efisien.

3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan secara menyeluruh hasil implementasi model klasifikasi berbasis *Support Vector Machine* (SVM) pada data laporan gangguan layanan pelanggan korporat PT. Telkom Indonesia Witel Sumsel. Seluruh proses dilaksanakan menggunakan kerangka kerja *Cross Industry Standard Process for Data Mining* (CRISP-DM) yang mencakup enam tahapan berurutan yaitu pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan penyebaran model. Pemaparan hasil pada setiap tahapan dilakukan secara rinci dan sistematis agar memberikan gambaran komprehensif mengenai proses penelitian dan capaian yang diperoleh secara keseluruhan (Singgalen, 2023).

3.1 Pemahaman Bisnis

Tahap pemahaman bisnis merupakan fondasi awal penelitian yang bertujuan menetapkan arah, sasaran, dan rencana kerja penelitian berdasarkan kebutuhan nyata operasional perusahaan. Pada tahap ini dilakukan identifikasi mendalam terhadap permasalahan yang dihadapi oleh PT. Telkom Indonesia Witel Sumsel dalam mengelola laporan gangguan layanan pelanggan korporat yang volumenya terus meningkat setiap periode. Objek bisnis yang ditetapkan adalah membangun model klasifikasi dengan variabel target berupa tingkat pengerjaan gangguan, sedangkan variabel fitur yang digunakan dalam pemodelan mencakup tiga atribut utama yaitu jenis layanan, jenis perbaikan, dan durasi pengerjaan. Penetapan ketiga variabel fitur ini didasarkan pada tingkat relevansinya yang tinggi terhadap proses penanganan gangguan layanan di lapangan serta ketersediaan datanya dalam sistem pencatatan *helpdesk* perusahaan (Arif & Faisal, 2023).

Tujuan teknis yang ditetapkan adalah menghasilkan model klasifikasi yang mampu mengklasifikasikan kualitas dan efektivitas pengerjaan layanan berdasarkan pola historis data yang telah tersedia. Rencana proyek disusun dengan menetapkan metrik keberhasilan yang mencakup akurasi, presisi, *recall*, dan *F1-score* sebagai tolok ukur utama kualitas model. Dengan keberhasilan model ini, perusahaan diharapkan mampu mengidentifikasi jenis gangguan secara lebih akurat, memprioritaskan penanganan berdasarkan tingkat urgensi, serta mempersingkat waktu respons terhadap pelanggan korporat secara signifikan dan berkelanjutan.

3.2 Pemahaman Data

Proses pemahaman data diawali dengan pengumpulan dataset secara langsung dari sumber resmi, yaitu *Helpdesk Assurance* Unit CCAN PT. Telkom Indonesia Witel Sumsel. Data dikirimkan melalui aplikasi pesan instan dalam format berkas lembar sebar yang kemudian diunggah ke lingkungan komputasi berbasis *cloud* untuk diolah lebih lanjut menggunakan bahasa pemrograman *Python*. Dataset yang berhasil terkumpul berjumlah 854 entri yang mencakup periode Oktober 2023 hingga Januari 2024, dengan 13 atribut yang merepresentasikan berbagai aspek operasional

penanganan gangguan layanan (Arif & Faisal, 2023). Atribut tersebut meliputi zona kerja, nama teknisi, data pelanggan, jenis layanan, jenis gangguan, jenis perbaikan, tanggal laporan, waktu pelaporan, waktu penyelesaian, durasi pengerjaan, tingkat pelayanan, jarak lokasi, dan kategori pelanggan.

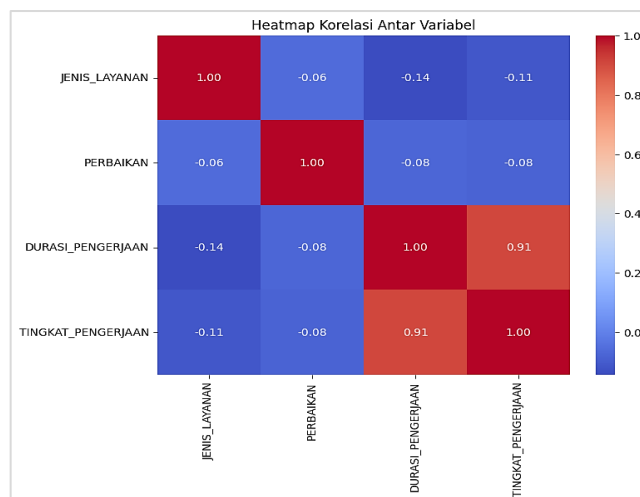
Proses penelaahan data dilakukan untuk memahami struktur dan karakteristik dataset secara menyeluruh sebelum memasuki tahap pemrosesan lebih lanjut. Hasil eksplorasi menunjukkan bahwa dataset memiliki dimensi 854 baris dan 13 kolom dengan beragam tipe data meliputi teks, tanggal, waktu, dan angka desimal. Analisis statistik deskriptif yang dilakukan mengungkapkan informasi penting mengenai karakteristik data numerik dalam dataset. Variabel durasi pengerjaan memiliki nilai rata-rata 11.561 menit dengan standar deviasi 8.153 menit serta rentang nilai antara 193 hingga 35.827 menit. Rentang nilai yang sangat lebar ini mengindikasikan adanya variasi durasi pengerjaan yang cukup signifikan antar laporan gangguan, yang mencerminkan kompleksitas berbeda-beda pada setiap kasus gangguan layanan yang ditangani oleh tim teknisi di lapangan.

Proses validasi data kemudian dilakukan secara sistematis untuk memastikan integritas dan kualitas data sebelum digunakan dalam pemodelan. Validasi mencakup pemeriksaan terhadap tiga jenis kendala utama, yaitu keterbatasan tipe data yang memastikan setiap kolom menyimpan jenis data yang sesuai, batasan rentang nilai yang memverifikasi bahwa angka berada dalam kisaran yang logis dan wajar, serta batasan wajib yang memastikan tidak ada kolom penting yang dibiarkan kosong (Qirani & Sukarsih, 2024). Proses validasi ini merupakan langkah kritis yang menentukan kualitas pemodelan pada tahap selanjutnya, karena data yang tidak valid akan langsung berdampak negatif terhadap kemampuan model dalam menghasilkan prediksi yang akurat dan dapat diandalkan.

3.3 Persiapan Data

Tahap persiapan data mencakup serangkaian proses kompleks meliputi pemilahan, pembersihan, konstruksi fitur, pelabelan, dan pengintegrasian data. Pada proses pemilahan, dilakukan seleksi fitur secara selektif dengan memilih tiga atribut utama sebagai variabel independen yaitu jenis layanan, jenis perbaikan, dan durasi pengerjaan, sedangkan tingkat pengerjaan ditetapkan sebagai variabel dependen yang menjadi target klasifikasi. Seleksi fitur ini dilakukan berdasarkan pertimbangan relevansi domain dan hasil analisis awal terhadap karakteristik data yang tersedia (Shedriko & Firdaus, 2022).

Analisis korelasi dilakukan untuk mengukur dan memahami kekuatan hubungan antar variabel dalam dataset secara kuantitatif. Hasil visualisasi peta panas korelasi sebagaimana ditampilkan pada Gambar 2 menunjukkan bahwa sebagian besar variabel memiliki korelasi yang relatif rendah satu sama lain, yang mengindikasikan independensi yang cukup baik antar fitur. Namun demikian, terdapat satu hubungan yang sangat kuat dan signifikan, yaitu antara variabel durasi pengerjaan dan tingkat pengerjaan dengan nilai korelasi mencapai 0,91. Korelasi positif yang sangat tinggi ini memiliki implikasi penting dalam pemodelan karena menunjukkan bahwa semakin lama durasi pengerjaan suatu gangguan, semakin tinggi pula tingkat penyelesaian yang dicapai oleh teknisi di lapangan. Temuan ini menegaskan posisi durasi pengerjaan sebagai indikator utama dan paling determinatif dalam proses klasifikasi yang akan dilakukan.

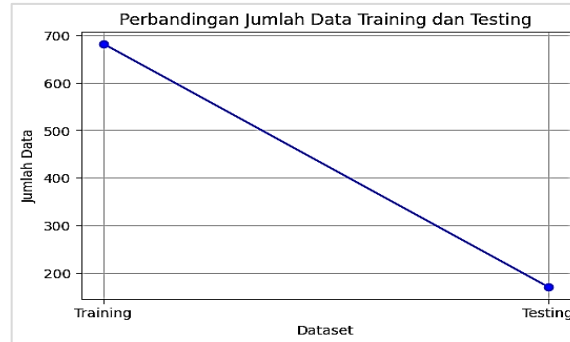


Gambar 3. Peta Panas Korelasi Antar Variabel Dataset

Proses pembersihan data dilakukan secara menyeluruh untuk memastikan kualitas data yang optimal sebelum pemodelan. Nilai kosong pada variabel durasi pengerjaan ditangani dengan pengisian menggunakan nilai rata-rata kolom tersebut agar tidak mengurangi jumlah data yang digunakan dalam pelatihan model. Baris data terduplikasi dihapus untuk menghindari bias dalam proses pembelajaran model. Data pencilan yang nilainya jauh menyimpang dari distribusi normal juga ditangani untuk mencegah pengaruh yang tidak proporsional terhadap performa model. Variabel kategorikal yang mencakup jenis layanan, jenis perbaikan, dan tingkat pengerjaan kemudian dikonversi ke dalam representasi numerik menggunakan metode pengkodean label, sehingga seluruh variabel dapat diproses secara komputasional oleh algoritma SVM (Singgalan, 2023).

3.4 Pemodelan

Tahap pemodelan diawali dengan pembagian dataset menjadi dua subset secara proporsional, yaitu data latih dan data uji. Proporsi pembagian yang diterapkan adalah 80% untuk data latih dan 20% untuk data uji, menghasilkan 683 data untuk proses pelatihan model dan 171 data untuk pengujian. Visualisasi perbandingan jumlah data latih dan data uji ditampilkan pada Gambar 3 untuk memverifikasi secara visual bahwa proporsi pembagian telah sesuai dengan metodologi penelitian yang ditetapkan.



Gambar 4. Grafik Perbandingan Jumlah Data Latih dan Data Uji


Sebelum proses pemodelan dimulai, seluruh variabel fitur dinormalisasi menggunakan metode standarisasi skala. Proses normalisasi ini bertujuan memastikan bahwa setiap variabel memiliki skala dan distribusi yang sebanding satu sama lain. Normalisasi merupakan langkah yang sangat kritis dalam penerapan algoritma SVM karena metode ini sangat sensitif terhadap perbedaan skala antar fitur, di mana fitur dengan rentang nilai yang jauh lebih besar dapat mendominasi perhitungan dan menghasilkan model yang tidak optimal (Haryatmi & Pramita Hervianti, 2021). Objek standarisasi yang digunakan untuk normalisasi data latih disimpan agar dapat diterapkan secara konsisten pada data uji maupun data baru di masa mendatang.

Model klasifikasi kemudian dibangun menggunakan algoritma *Support Vector Classifier* dengan fungsi inti linier. Pemilihan fungsi inti linier didasarkan pada asumsi bahwa data laporan gangguan layanan dapat dipisahkan secara linier dalam ruang fitur yang tersedia, mengingat kuatnya korelasi yang telah teridentifikasi antara variabel fitur dan variabel target. Fungsi inti linier juga dipilih karena menghasilkan model yang lebih mudah diinterpretasikan dan lebih efisien secara komputasional dibandingkan fungsi inti non-linier. Model dikonfigurasi dengan parameter probabilitas yang diaktifkan agar dapat menghasilkan estimasi probabilitas prediksi yang lebih kaya dan informatif untuk keperluan analisis performa komprehensif pada tahap evaluasi (Palisoa et al., 2023).

3.5 Evaluasi

Tahap evaluasi merupakan tahap terpenting yang menentukan kelayakan model untuk digunakan dalam lingkungan nyata. Evaluasi dilakukan secara komprehensif menggunakan empat instrumen pengukuran utama yaitu akurasi keseluruhan, *log loss*, matriks konfusi, dan kurva ROC *multiclass*. Penggunaan kombinasi keempat instrumen ini memberikan gambaran yang jauh lebih lengkap dan mendalam tentang kemampuan model dibandingkan hanya mengandalkan satu metrik tunggal.

Hasil evaluasi utama menunjukkan bahwa model SVM dengan fungsi inti linier mampu mencapai tingkat akurasi sebesar 98,25% pada data pengujian yang belum pernah dilihat sebelumnya oleh model. Nilai akurasi yang sangat tinggi ini mengindikasikan bahwa model mampu mengklasifikasikan tingkat pengerjaan gangguan dengan ketepatan luar biasa, yaitu mampu memprediksi kelas yang benar pada 98 dari setiap 100 data uji yang diberikan. Capaian akurasi ini merupakan indikator awal yang sangat menjanjikan tentang kualitas dan keandalan model yang telah dibangun. Evaluasi lanjutan menggunakan *log loss* dilakukan untuk mengukur kualitas probabilitas prediksi model secara lebih mendalam. Visualisasi nilai *log loss* ditampilkan pada Gambar 4 dalam bentuk grafik batang yang menggambarkan besaran nilai *log loss* model SVM secara visual dan mudah dipahami.



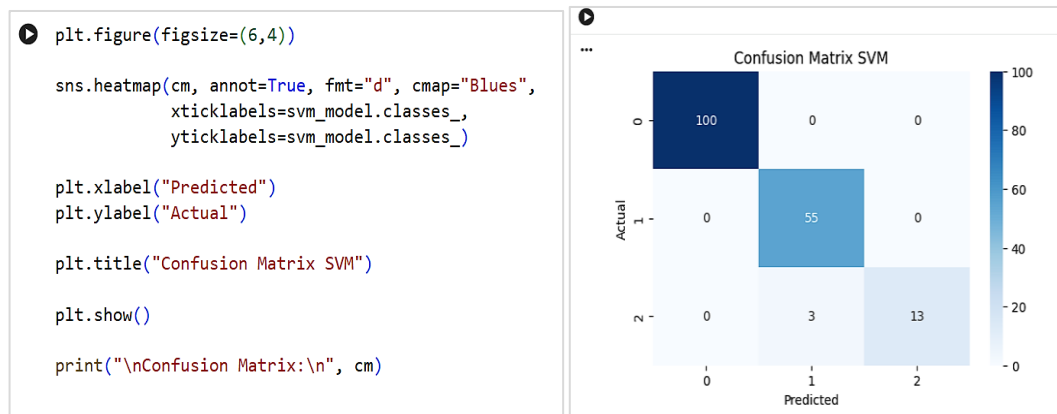
Gambar 5. Grafik Log Loss Model SVM

Hasil perhitungan *log loss* menghasilkan nilai sebesar 0,0200, yang mendekati nol sebagai nilai ideal. Nilai *log loss* yang sangat rendah ini mengindikasikan bahwa probabilitas prediksi yang dihasilkan oleh model sangat baik, konsisten, dan terkalibrasi dengan baik terhadap label kelas sebenarnya. Artinya model tidak hanya menghasilkan prediksi kelas yang benar, tetapi juga memiliki tingkat keyakinan prediksi yang sangat tinggi pada setiap keputusan klasifikasi yang dibuat. Temuan ini secara bersama-sama dengan nilai akurasi 98,25% memberikan bukti ganda yang saling memperkuat tentang kualitas model yang dihasilkan. Ringkasan seluruh hasil metrik evaluasi model disajikan secara terstruktur pada Tabel 2.

Tabel 2. Ringkasan Metrik Evaluasi Model SVM

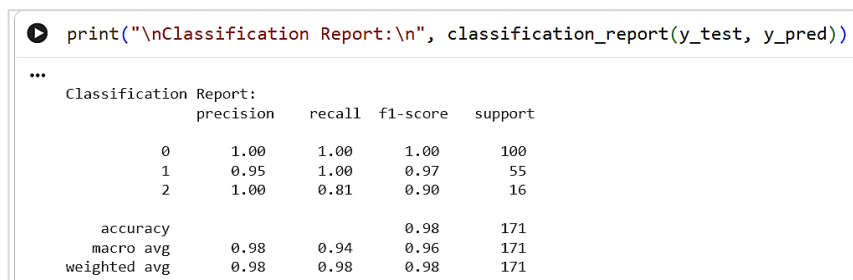
Metrik	Kelas 0	Kelas 1	Kelas 2	Rata-rata
Presisi	1,00	1,00	1,00	1,00
Recall	1,00	1,00	0,81	0,94
F1-Score	1,00	1,00	0,90	0,97
Akurasi	—	—	—	98,25%
Log Loss	—	—	—	0,0200

Evaluasi menggunakan matriks konfusi sebagaimana ditampilkan pada Gambar 5 memberikan gambaran paling detail mengenai distribusi prediksi benar dan salah pada setiap kelas target secara individual. Hasil analisis matriks menunjukkan bahwa kelas 0 dan kelas 1 berhasil diprediksi dengan tingkat akurasi sempurna, yang ditunjukkan oleh nilai presisi, *recall*, dan *F1-score* yang seluruhnya mencapai 1,00. Sementara itu, kelas 2 menunjukkan karakteristik yang sedikit berbeda dengan nilai presisi yang tetap sempurna sebesar 1,00, namun *recall* hanya mencapai 0,81 dengan *F1-score* sebesar 0,90. Kondisi ini mengindikasikan bahwa ketika model memutuskan untuk mengklasifikasikan suatu data ke dalam kelas 2, prediksi tersebut selalu benar tanpa satupun kesalahan, namun terdapat sejumlah kecil data yang sesungguhnya termasuk kelas 2 namun gagal diidentifikasi dengan benar oleh model.



Gambar 6. Visualisasi Matriks Konfusi Model SVM

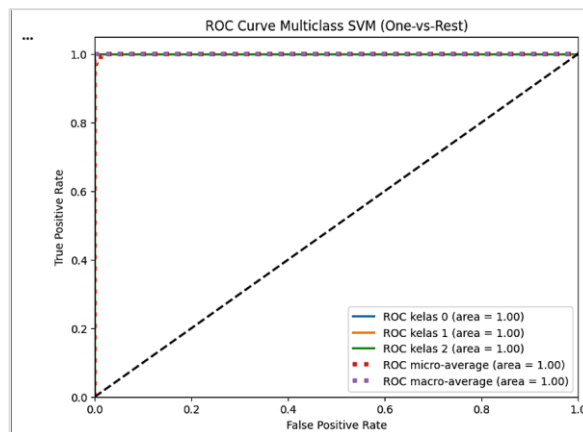
Analisis lebih mendalam terhadap performa model per kelas dilakukan menggunakan laporan klasifikasi sebagaimana ditampilkan pada Gambar 6. Laporan klasifikasi menyajikan nilai presisi, *recall*, dan *F1-score* untuk setiap kelas secara terpisah dan terperinci, sehingga memungkinkan identifikasi kelas mana yang paling sulit untuk diklasifikasikan oleh model. Hasil laporan klasifikasi mengonfirmasi bahwa kelas 0 dan kelas 1 memiliki performa sempurna pada semua metrik, sementara kelas 2 memerlukan perhatian khusus karena nilai *recall*-nya yang lebih rendah dibandingkan dua kelas lainnya. Perbedaan performa pada kelas 2 kemungkinan disebabkan oleh jumlah sampel kelas 2 dalam dataset yang lebih sedikit dibandingkan kelas 0 dan kelas 1, sehingga model memiliki lebih sedikit contoh untuk mempelajari pola kelas tersebut secara optimal.



Gambar 7. Laporan Klasifikasi Model SVM

Evaluasi menggunakan kurva ROC dilakukan untuk menilai kemampuan diskriminasi model dalam skenario klasifikasi multikelas secara menyeluruh. Pendekatan satu-lawan-selebihnya diterapkan di mana setiap kelas secara

bergantian dibandingkan dengan gabungan seluruh kelas lainnya untuk menghasilkan kurva ROC yang independen per kelas. Hasil visualisasi kurva ROC sebagaimana ditampilkan pada Gambar 7 menunjukkan bahwa kurva untuk kelas 0, kelas 1, dan kelas 2 seluruhnya berada jauh di atas garis diagonal acuan dengan nilai *Area Under Curve* (AUC) mencapai 1,00 untuk semua kelas tanpa pengecualian. Nilai *micro-average* dan *macro-average* AUC juga sama-sama mencapai 1,00, yang membuktikan konsistensi performa model yang luar biasa baik secara keseluruhan maupun pada level antar kelas individual. Nilai AUC sempurna ini menegaskan bahwa model memiliki kemampuan diskriminasi yang sangat tinggi dan mampu memisahkan kelas-kelas target secara sempurna dalam ruang probabilitas prediksi (Ramadhan & Triyudi, 2022).



Gambar 8. Kurva ROC Multikelas Model SVM

3.6 Penyebaran Model

Tahap penyebaran model merupakan tahap final yang memastikan bahwa model yang telah dilatih dan dievaluasi dapat digunakan kembali secara praktis tanpa perlu mengulang seluruh proses pelatihan dari awal. Model SVM yang telah dibangun disimpan dalam format berkas biner menggunakan pustaka serialisasi objek *Python*, sehingga seluruh parameter dan konfigurasi model tersimpan secara permanen dan dapat dipanggil kembali kapan saja sesuai kebutuhan. Selain model utama, objek standardisasi yang digunakan untuk normalisasi data juga disimpan secara terpisah dalam berkas tersendiri. Penyimpanan objek standardisasi ini sangat penting untuk memastikan bahwa setiap data baru yang masuk ke sistem dapat diproses dengan skala dan parameter normalisasi yang identik dengan data pelatihan, sehingga konsistensi dan keandalan hasil prediksi tetap terjaga sepenuhnya dalam penggunaan jangka panjang (Nasrum et al., 2022).

Langkah penyimpanan model dan objek standardisasi ini secara eksplisit memastikan bahwa penelitian tidak berhenti hanya sebatas pada tahap evaluasi akademis, melainkan benar-benar siap untuk diintegrasikan ke dalam sistem operasional nyata. Model yang tersimpan dapat langsung diintegrasikan ke dalam sistem *helpdesk* PT. Telkom Indonesia Witel Sumsel sebagai modul klasifikasi otomatis yang membantu tim teknis dalam mengidentifikasi dan memprioritaskan penanganan gangguan layanan pelanggan korporat secara lebih cepat dan tepat sasaran. Integrasi model ke dalam sistem operasional juga membuka peluang untuk pengembangan lebih lanjut di masa mendatang, seperti pembaruan model secara berkala menggunakan data terbaru agar performa model tetap relevan dan optimal seiring berjalannya waktu (Saputra et al., 2024).

3.7 Pembahasan

Secara keseluruhan, hasil penelitian ini membuktikan bahwa model SVM dengan fungsi inti linier yang diterapkan melalui kerangka kerja CRISP-DM mampu mengklasifikasikan tingkat pengerjaan gangguan layanan pelanggan korporat dengan performa yang sangat unggul. Hal ini dibuktikan secara kuantitatif melalui akurasi 98,25%, *log loss* 0,0200, nilai *F1-score* rata-rata 0,97, serta nilai AUC 1,00 pada seluruh kelas target. Kombinasi nilai metrik evaluasi yang sangat tinggi pada keempat instrumen pengukuran yang berbeda secara bersama-sama memberikan keyakinan yang kuat bahwa model yang dihasilkan memiliki kualitas dan keandalan yang sangat baik untuk diimplementasikan dalam lingkungan operasional nyata (Michael, 2022).

Capaian performa penelitian ini secara konsisten melampaui hasil penelitian-penelitian terdahulu yang menggunakan algoritma SVM pada domain yang berbeda. Hasanah et al. (2021) yang menerapkan SVM pada domain pendidikan memperoleh akurasi 96,15%, sedangkan Hasanah et al. (2021) yang menggunakan SVM pada klasifikasi data pendonor darah mencatat akurasi 96,34%. Penelitian ini berhasil melampaui kedua capaian tersebut dengan margin yang signifikan sebesar lebih dari dua poin persentase. Keunggulan ini tidak terlepas dari karakteristik data yang digunakan, di mana korelasi yang sangat kuat antara variabel durasi pengerjaan dan tingkat pengerjaan dengan nilai 0,91 memberikan sinyal diskriminatif yang sangat jelas dan konsisten bagi algoritma SVM dalam membangun *hyperplane* pemisah yang optimal (Abdusyukur, 2023).

Temuan ini juga berbeda secara substansial dengan hasil penelitian Hasanah et al. (2021) yang menerapkan SVM



pada data teks tidak terstruktur berupa berita *hoax* dan hanya memperoleh akurasi 86,11%. Perbedaan yang mencapai lebih dari dua belas poin persentase ini mengonfirmasi bahwa karakteristik data numerik terstruktur seperti yang digunakan dalam penelitian ini memberikan kondisi yang jauh lebih kondusif bagi algoritma SVM dibandingkan data teks tidak terstruktur. Data numerik yang memiliki korelasi kuat antar variabel memungkinkan SVM untuk menemukan *hyperplane* pemisah yang lebih tegas dan akurat, sehingga menghasilkan performa klasifikasi yang lebih tinggi secara konsisten. Sementara itu, penelitian Hasanah et al. (2021) yang menerapkan SVM pada klasifikasi teks media sosial hanya memperoleh akurasi 77%, yang semakin memperkuat argumen bahwa domain data operasional terstruktur seperti data laporan gangguan layanan merupakan medan yang paling ideal bagi algoritma SVM untuk menunjukkan kemampuan terbaiknya.


Penelitian ini juga membuktikan bahwa penerapan kerangka kerja CRISP-DM secara konsisten dan menyeluruh memberikan kontribusi signifikan terhadap kualitas model yang dihasilkan. Setiap tahapan CRISP-DM yang dilaksanakan dengan seksama, mulai dari pemahaman bisnis yang tepat sasaran, pemahaman dan validasi data yang komprehensif, persiapan data yang cermat, hingga pemodelan dan evaluasi yang sistematis, secara kolektif membangun fondasi yang kokoh bagi model klasifikasi yang berkualitas tinggi (Singgalen, 2023). Penelitian ini berkontribusi dalam mengisi kesenjangan pengetahuan mengenai efektivitas SVM pada data operasional industri telekomunikasi, sekaligus menawarkan model yang siap diimplementasikan untuk mendukung pengambilan keputusan berbasis data di PT. Telkom Indonesia Witel Sumsel secara berkelanjutan (Palisoa et al., 2023).

4. KESIMPULAN

Berdasarkan seluruh rangkaian proses penelitian yang telah dilaksanakan secara sistematis melalui enam tahapan kerangka kerja CRISP-DM, dapat ditarik kesimpulan bahwa model klasifikasi berbasis *Support Vector Machine* (SVM) dengan fungsi inti linier terbukti sangat efektif dan dapat diandalkan dalam mengklasifikasikan tingkat pengerjaan gangguan layanan pelanggan korporat PT. Telkom Indonesia Witel Sumsel. Menjawab rumusan masalah pertama, model berhasil dibangun dengan memanfaatkan tiga variabel fitur utama yaitu jenis layanan, jenis perbaikan, dan durasi pengerjaan, dengan tingkat pengerjaan sebagai variabel target yang diklasifikasikan ke dalam tiga kelas berbeda. Menjawab rumusan masalah kedua, model menghasilkan tingkat akurasi sebesar 98,25% pada data pengujian, didukung nilai *log loss* yang sangat rendah sebesar 0,0200, nilai *F1-score* rata-rata 0,97, serta nilai *Area Under Curve* sempurna mencapai 1,00 pada seluruh kelas, yang secara kolektif membuktikan keandalan prediksi model secara konsisten. Menjawab rumusan masalah ketiga, uji prediksi pada data sampel baru menunjukkan bahwa model mampu menghasilkan prediksi yang tepat dengan tingkat keyakinan tinggi, menjadikannya layak untuk diintegrasikan ke dalam sistem operasional. Adapun keterbatasan penelitian ini terletak pada cakupan data yang terbatas hanya pada satu wilayah telekomunikasi dalam rentang empat bulan, serta penggunaan satu algoritma tanpa perbandingan dengan metode lain. Untuk penelitian selanjutnya, disarankan agar dilakukan eksplorasi menggunakan algoritma lain seperti *Random Forest* atau *Gradient Boosting* sebagai pembanding, penambahan fitur yang lebih beragam seperti jenis gangguan dan lokasi layanan, serta perluasan cakupan data ke wilayah telekomunikasi lain agar model yang dihasilkan lebih general dan komprehensif.

REFERENCES

- Abdusyukur, F. (2023). Penerapan Algoritma Support Vector Machine (Svm) Untuk Klasifikasi Pencemaran Nama Baik Di Media Sosial Twitter. *Komputa: Jurnal Ilmiah Komputer Dan Informatika*, 12(1), 73–82. <https://doi.org/10.34010/komputa.v12i1.9418>
- Ahmad, I., Samsugi, S., & Irawan, Y. (2022). Implementasi Data Mining Sebagai Pengolahan Data. *Jurnal Teknoinfo*, 16(1), 46. <http://portaldata.org/index.php/portaldata/article/view/107>
- Alfarizi, M. R. S., Al-farish, M. Z., Taufiqurrahman, M., Ardiansah, G., & Elgar, M. (2023). Penggunaan Python Sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning. *Karya Ilmiah Mahasiswa Bertauhid (Karimah Tauhid)*, 2(1), 1–6.
- Arif, M., & Faisal, M. (2023). Penerapan Model Regresi Linear Untuk Estimasi Mobil Bekas Menggunakan Bahasa Python. *Euler: Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11(2), 182–191. <https://doi.org/10.37905/euler.v11i2.20698>
- Dhewayani, F. N., Amelia, D., Alifah, D. N., Sari, B. N., & Jajuli, M. (2022). Implementasi K-Means Clustering untuk Pengelompokan Daerah Rawan Bencana Kebakaran Menggunakan Model CRISP-DM. *Jurnal Teknologi Dan Informasi*, 12(1), 64–77. <https://doi.org/10.34010/jati.v12i1.6674>
- Haryatmi, E., & Pramita Hervianti, S. (2021). Penerapan Algoritma Support Vector Machine Untuk Model Prediksi Kelulusan Mahasiswa Tepat Waktu. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(2), 386–392. <https://doi.org/10.29207/resti.v5i2.3007>
- Hasanah, M. A., Soim, S., & Handayani, A. S. (2021). Implementasi CRISP-DM Model Menggunakan Metode Decision Tree dengan Algoritma CART untuk Prediksi Curah Hujan Berpotensi Banjir. *Journal of Applied Informatics and Computing*, 5(2), 103–108. <https://doi.org/10.30871/jaic.v5i2.3200>
- Irmanda, H. N., & Astriratma, R. (2021). Klasifikasi Jenis Pantun dengan Metode Support Vector Machines (SVM). *JURNAL RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 1(10), 915–922.



<https://doi.org/10.29207/resti.v4i5.2313>

- Kanaka, N. A. S., Heriansyah, R., & Puspasari, S. (2024). Perbandingan Algoritma Decision Tree dan Support Vector Machine Dalam Pemilihan Calon Mahasiswa Penerima KIP-K. *TIN: Terapan Informatika Nusantara*, 4(9), 613–619. <https://doi.org/10.47065/tin.v4i9.4902>
- Laili, E. F., Alawi, Z., Rohmah, R., Barata, M. A. (2025). Komparasi Algoritma Decision Tree Dan Support Vector Machine (Svm) Dalam Klasifikasi Serangan Jantung. *Jurnal Sistem Informasi Dan Informatika (Simika)*, 8(1), 67–76.
- Michael, A. (2022). Komparasi Kombinasi Pre-trained Model dengan SVM pada Klasifikasi Kematangan Kopi Berbasis Citra. *Journal Dynamic Saint*, 7(1), 42–48. <https://doi.org/10.47178/dynamicsaint.v7i1.1613>
- Nasrum, Zulkarnain, & Nurdiansah. (2022). Sistem Pelaporan Gangguan Jaringan Telkom Dengan Metode Apriori dan Generalized Rule Induction. *Jurnal Dipanegara Komputer Sistem Informasi*, 16(1), 66–70.
- Palisoa, N. F., Sinay, L. J., Matdoan, M. Y., Yudistira, Y., & Bakarbesy, L. (2023). Penerapan Support Vector Machine (Svm) Untuk Klasifikasi Kabupaten Tertinggal Di Provinsi Maluku. *PARAMETER: Jurnal Matematika, Statistika Dan Terapannya*, 2(02), 79–86. <https://doi.org/10.30598/parameterv2i02pp79-86>
- Qirani, S. D., & Sukarsih, I. (2024). Penerapan Metode K-Nearest Neighbor untuk Prediksi Harga Gas Alam Menggunakan Python. 57–64.
- Ramadhan, R., & Triyudi, A. (2022). Perbandingan Klasifikasi Data Calon Pendorong Darah Dengan Algoritma K-Nearest Neighbor Dan Support Vector Machine. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 9(2), 1250–1260. <https://doi.org/10.35957/jatisi.v9i2.2018>
- Sani, R. R., Pratiwi, Y. A., Winarno, S., Udayanti, D. E., & Zami, F. Al. (2022). Comparative Analysis of the Naive Bayes Classifier Algorithm and Support Vector Machine for Hoax Classification in Indonesian Online News. *Jurnal Masyarakat Informatika*, 13(2), 85–98.
- Saputra, D. B., Atina, V., & Nastiti, F. E. (2024). Penerapan Model Crisp-Dm Pada Prediksi Nasabah Kredit Menggunakan Algoritma Random Forest. *IDEALIS: InDonEsiA Journal Information System*, 7(2), 240–247. <https://doi.org/10.36080/idealis.v7i2.3244>
- Sari, R. A., Aswar, N. F., & Aslam, A. P. (2023). Pengaruh Kualitas Layanan Dan Kepercayaan Terhadap Kepuasan Nasabah Pada Pt. Bank Sulselbar. *Jurnal Manajemen*, 2(2), 119. <https://doi.org/10.26858/jm.v2i2.42329>
- Shedriko, & Firdaus, M. (2022). Penentuan Klasifikasi Dengan Crisp-Dm Dalam Memprediksi Kelulusan Mahasiswa Pada Suatu Mata Kuliah. *The Indonesian Journal of Computer Science*, 10(11), 826–831.
- Singgalen, Y. A. (2023). Penerapan Metode CRISP-DM dalam Klasifikasi Data Ulasan Pengunjung Destinasi Danau Toba Menggunakan Algoritma Naïve Bayes Classifier (NBC) dan Decision Tree (DT). *Jurnal Media Informatika Budidarma*, 7(3), 1551. <https://doi.org/10.30865/mib.v7i3.6461>
- Wurijanto, T., Setiawan, H. B., & Tjandrarini, A. B. (2022). Penerapan Model CRISP-DM pada Prediksi Nasabah Kredit yang Berisiko Menggunakan Algoritma Support Vector Machine. *Jurnal Ilmiah Scroll (Jendela Teknologi Informasi)*, 10(1), 1–6. <https://univ45sby.ac.id/ejournal/index.php/informatika/article/view/291>