

Predicting Students' On-Time Graduation using Support Vector Machine (SVM) Algorithm

Siswadi^{1*}, Elvi Khairunnisa², Novi Permata Indah³

¹Universitas Singaperbangsa Karawang

Corresponding author: siswadi@ft.unsika.ac.id^{1}, elvi.khairunnisa@ft.unsika.ac.id²,
novi.permata@fe.unsika.ac.id³

ABSTRACT

On-time graduation (OTG) is a primary key performance indicator (KPI) for higher education institutions. Delays in graduation adversely affect institutional academic efficiency and increase student costs. This study aims to implement the Support Vector Machine (SVM) algorithm, a machine learning technique, to develop a predictive model for students' on-time graduation. This study employed a quantitative approach using a historical dataset of 20 students as a case study. Five predictor variables were utilized: Semester 4 GPA, total completed credits, attendance percentage, working status, and organizational activity. The dataset was partitioned into 80% for training and 20% for testing. Model performance was evaluated using a Confusion Matrix, along with Accuracy, Precision, Recall, and F1-Score metrics. The evaluation on the test set demonstrated that the SVM model achieved an overall Accuracy of 75%. Specifically, for the 'On-Time' class, the model yielded a Precision of 66.7%, a Recall of 100%, and an F1-Score of 80%. These findings suggest that SVM is a viable method and holds potential as an early detection tool to identify students at risk of delayed graduation, thereby enabling timely intervention.

Keywords:

On-Time Graduation
Prediction, Support Vector
Machine Algorithm, Machine
Learning.

Memprediksi Kelulusan Tepat Waktu Mahasiswa menggunakan Algoritma Support Vector Machine

ABSTRAK

Kelulusan tepat waktu (KTW) merupakan indikator kinerja utama (IKU) bagi institusi pendidikan tinggi. Keterlambatan kelulusan berdampak buruk pada efisiensi akademik institusi dan meningkatkan biaya bagi mahasiswa. Penelitian ini bertujuan untuk mengimplementasikan algoritma *Support Vector Machine* (SVM), sebuah teknik pembelajaran mesin, untuk mengembangkan model prediksi kelulusan tepat waktu mahasiswa. Penelitian ini menggunakan pendekatan kuantitatif dengan studi kasus dataset historis dari 20 mahasiswa. Lima variabel prediktor digunakan, yaitu: IPK Semester 4, total SKS yang ditempuh, persentase kehadiran, status bekerja, dan keaktifan organisasi. Dataset dipartisi menjadi 80% untuk pelatihan dan 20% untuk pengujian. Performa model dievaluasi menggunakan *Confusion Matrix*, serta metrik Akurasi, Presisi, *Recall*, dan *F1-Score*. Evaluasi pada set data uji menunjukkan bahwa model SVM mencapai akurasi keseluruhan sebesar 75%. Secara khusus untuk kelas 'Tepat Waktu', model menghasilkan Presisi sebesar 66,7%, *Recall* sebesar 100%, dan *F1-Score* sebesar 80%. Temuan ini menunjukkan bahwa SVM merupakan metode yang layak dan memiliki potensi sebagai alat

Kata Kunci:

Prediksi Kelulusan Tepat
Waktu, Algoritma Support
Vector Machine, Pembelajaran
Mesin.

deteksi dini untuk mengidentifikasi mahasiswa yang berisiko mengalami keterlambatan kelulusan, sehingga memungkinkan adanya intervensi yang tepat waktu.

1. INTRODUCTION

Tingkat kelulusan mahasiswa seringkali dianggap sebagai salah satu indikator penting keberhasilan sebuah perguruan tinggi. Hal ini tidak hanya berdampak pada akreditasi, tetapi juga pada reputasi institusi dan kemampuan perguruan tinggi dalam mengoptimalkan potensi mahasiswa secara maksimal [1], [2], [3]. Selain itu, ketepatan waktu kelulusan juga berhubungan erat dengan efisiensi proses akademik serta pengelolaan biaya operasional institusi [4], [5]. Namun, dalam praktiknya, kecepatan kelulusan mahasiswa seringkali tidak merata. Terdapat ketidakseimbangan antara mereka yang lulus tepat waktu dengan yang mengalami keterlambatan [5]. Keterlambatan kelulusan ini tidak hanya berisiko meningkatkan beban finansial bagi mahasiswa dan keluarganya, tetapi juga dapat menghambat peluang karier mereka di masa depan [6]. Dari sisi perguruan tinggi, masalah ini menimbulkan inefisiensi dalam alokasi sumber daya dan berpotensi merusak reputasi institusi secara keseluruhan [7].

Salah satu masalah utama yang dihadapi adalah bagaimana cara mengidentifikasi mahasiswa yang berisiko mengalami keterlambatan kelulusan sedini mungkin. Tanpa adanya mekanisme deteksi dini yang akurat, intervensi akademik sering kali terlambat, sehingga tidak cukup efektif dalam mencegah keterlambatan studi atau risiko *dropout* [8], [9]. Pendekatan pemantauan akademik yang ada saat ini masih banyak yang bersifat deskriptif atau reaktif, seperti yang sering dilakukan berdasarkan evaluasi semester berjalan. Hal ini membuat pendekatan tersebut belum optimal untuk melakukan prediksi dini serta intervensi yang lebih proaktif [8], [10]. Di samping itu, metode statistik tradisional pun seringkali kesulitan dalam menangkap pola yang lebih kompleks pada data akademik yang bersifat multidimensi [11], [12].

Bukti empiris menunjukkan adanya ketidakseimbangan antara proporsi mahasiswa yang lulus tepat waktu dan terlambat, yang pada gilirannya mempengaruhi berbagai aspek institusional seperti akreditasi dan efisiensi akademik [13], [14]. Oleh karena itu, dibutuhkan sistem prediktif atau sistem peringatan dini yang dapat memetakan potensi risiko keterlambatan sejak awal masa studi.

Pada saat yang sama, dalam konteks pemodelan prediktif berbasis Machine Learning, terdapat tantangan besar untuk membuat model yang tetap andal meski ukuran sampelnya terbatas (dataset kecil) dan target klasifikasi bersifat biner atau multikelas (tepat waktu vs terlambat). Pemilihan algoritma yang tepat menjadi sangat krusial dalam kondisi seperti ini, karena model perlu mampu melakukan generalisasi yang baik serta meminimalkan error dalam klasifikasi [15], [16]. *Machine Learning*, khususnya *Support Vector Machine* (SVM), menawarkan potensi besar dalam memanfaatkan data historis akademik untuk membangun model prediktif yang otomatis dapat mengidentifikasi mahasiswa berisiko, jauh sebelum masa studi mereka berakhir [16], [17]. SVM sangat relevan untuk digunakan dalam dataset dengan dimensi terbatas karena fokusnya dalam menemukan hyperplane pemisah yang optimal untuk memaksimalkan margin antar kelas, yang memungkinkan model untuk memberikan generalisasi yang baik pada data uji [18], [19]. Oleh karena itu, SVM diperkirakan dapat secara efektif meminimalkan tingkat kesalahan dalam klasifikasi status kelulusan, khususnya ketika data yang digunakan relatif kecil.

Penelitian ini bertujuan untuk mengembangkan model prediktif berbasis SVM yang dapat membantu memetakan risiko keterlambatan kelulusan mahasiswa sejak awal masa studi. Fokus utama penelitian adalah pada Program Studi S1 Teknik Mesin Universitas Singaperbangsa Karawang, yang memiliki data akademik historis namun belum dimanfaatkan secara optimal sebagai sistem peringatan dini. Karakteristik data yang terbatas, dengan variasi performa akademik yang tinggi dan ketidakseimbangan kelas, memerlukan penerapan pendekatan prediktif yang stabil, mudah diimplementasikan, serta dapat mendukung pengambilan keputusan akademik yang lebih tepat dan efektif dalam mengidentifikasi mahasiswa yang berisiko sejak dini. Dengan demikian, intervensi dapat dilakukan lebih cepat dan lebih tepat sasaran.

2. METHOD

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimental-komputasional untuk membangun dan mengevaluasi model klasifikasi yang memprediksi status kelulusan mahasiswa (tepat waktu atau terlambat) sebagai dasar sistem peringatan dini. Objek penelitian adalah mahasiswa Program Studi S1 Teknik Mesin Universitas Singaperbangsa Karawang dengan cohort tahun 2023. Unit analisis berupa rekaman data akademik per mahasiswa selama masa studi yang tersedia, dengan kriteria inklusi mencakup mahasiswa yang memiliki riwayat akademik memadai dan informasi yang memungkinkan penentuan label, sedangkan data yang tidak lengkap secara krusial atau label tidak dapat ditentukan dikecualikan dari proses pemodelan.

Data penelitian bersumber dari Sistem Informasi Akademik institusi melalui proses ekstraksi dalam format terstruktur, kemudian dilakukan validasi konsistensi (misalnya urutan semester dan kelengkapan atribut) serta anonimisasi untuk menghapus informasi identitas personal. Variabel target didefinisikan sebagai status kelulusan, yaitu “tepat waktu” apabila lulus dalam ≤ 8 semester dan “terlambat” apabila lulus dalam > 8 semester. Variabel prediktor mencakup indikator performa dan progres studi, seperti IP semester, IPK kumulatif, jumlah SKS diambil/lulus per semester, total SKS kumulatif, jumlah mata kuliah mengulang, jumlah mata kuliah tidak lulus, serta indikator kelulusan/nilai pada mata kuliah inti (jika tersedia), dan dapat ditambah variabel administratif seperti status aktif/cuti apabila terdapat pada data.

Tahap pra-pemrosesan dilakukan untuk meningkatkan kualitas data dan kesesuaian input model, meliputi pembersihan data (duplikasi dan inkonsistensi), penanganan nilai hilang dengan imputasi atau eksklusi sesuai proporsi ketidaklengkapan, transformasi variabel kategorik menggunakan encoding, serta standarisasi fitur numerik (z-score) karena SVM sensitif terhadap perbedaan skala. Apabila terjadi ketidakseimbangan kelas, digunakan penyesuaian bobot kelas (*class_weight=balanced*) dan/atau resampling pada data latih. Seleksi fitur dapat diterapkan secara opsional untuk mengurangi noise pada dataset terbatas.

Pemodelan utama menggunakan *Support Vector Machine* (SVM) untuk klasifikasi biner dengan evaluasi beberapa konfigurasi kernel, terutama linear dan RBF. Hyperparameter penting yang dituning mencakup nilai C (regularisasi) serta gamma untuk kernel RBF. Data dibagi menjadi data latih dan uji menggunakan stratified split agar distribusi kelas tetap terjaga, dan pada data latih diterapkan k-fold cross-validation untuk memperoleh estimasi performa yang stabil. Tuning hyperparameter dilakukan menggunakan Grid Search/Random Search dalam pipeline (scaling $\rightarrow$ (opsional) resampling $\rightarrow$ SVM) untuk mencegah kebocoran data.

Evaluasi model dilakukan menggunakan *accuracy*, *precision*, *recall*, dan F1-score, dengan penekanan pada metrik kelas “terlambat” karena berkaitan langsung dengan tujuan deteksi dini dan intervensi akademik. *Confusion matrix* digunakan untuk menganalisis jenis kesalahan, khususnya meminimalkan *false negative* pada kelas terlambat, serta ROC-AUC dapat digunakan sebagai evaluasi tambahan. Implementasi dilakukan menggunakan Python (*pandas/numpy* dan *scikit-learn*) dengan random seed tetap untuk menjaga replikasi hasil, serta seluruh pemrosesan data dilakukan secara anonim dan sesuai prinsip privasi serta kebijakan institusi.

3. RESULTS AND DISCUSSION

A. Evaluasi Model

Pada bagian ini, kami akan menyajikan hasil evaluasi model prediksi kelulusan tepat waktu mahasiswa yang menggunakan algoritma Support Vector Machine (SVM). Evaluasi dilakukan pada 20% data pengujian yang terdiri dari 4 mahasiswa. Sebelum membahas metrik evaluasi secara rinci, mari kita lihat tabel Confusion Matrix yang menggambarkan hasil prediksi dari model ini.

Tabel 1: Confusion Matrix

	Prediksi Tepat Waktu	Prediksi Terlambat
Aktual Tepat Waktu	3	0
Aktual Terlambat	1	0

Berdasarkan tabel *Confusion Matrix* di atas, kita dapat melihat bahwa dari 4 data pengujian:

- **3 mahasiswa yang sebenarnya lulus tepat waktu** berhasil diprediksi dengan benar sebagai "Tepat Waktu".
- **1 mahasiswa yang sebenarnya terlambat lulus** diprediksi salah sebagai "Tepat Waktu".
- Tidak ada mahasiswa yang terlambat yang diprediksi sebagai "Terlambat".

Dengan ini, model menunjukkan akurasi yang cukup baik dengan angka **Akurasi 75%**. Mari kita lihat metrik evaluasi lainnya:

Tabel 2: Metrik Evaluasi Model

Metrik	Nilai
Akurasi	75%
Presisi	66,7%
Recall	100%
F1-Score	80%

1) Akurasi

Akurasi adalah metrik yang menunjukkan seberapa sering model membuat prediksi yang benar secara keseluruhan. Pada model ini, akurasi keseluruhan mencapai **75%**, yang berarti bahwa model berhasil memprediksi dengan benar 3 dari 4 data pengujian.

Akurasi dihitung dengan rumus:

$$\text{Akurasi} = \frac{TP + TN}{TP + FP + TN + FN} = \frac{3 + 0}{3 + 1 + 0 + 0} = 75\%$$

di mana TP adalah True Positive (Tepat Waktu yang diprediksi benar), TN adalah True Negative (Terlambat yang diprediksi benar), FP adalah False Positive (Terlambat yang diprediksi Tepat Waktu), dan FN adalah False Negative (Tepat Waktu yang diprediksi Terlambat).

2) Presisi

Presisi mengukur proporsi prediksi kelas "Tepat Waktu" yang benar dari semua yang diprediksi sebagai "Tepat Waktu". Dalam kasus ini, model memiliki **Presisi 66,7%**, yang berarti bahwa hanya 2 dari 3 mahasiswa yang diprediksi lulus tepat waktu yang benar-benar lulus tepat waktu. Presisi dihitung dengan rumus:

$$\text{Presisi} = \frac{TP}{TP + FP} = \frac{3}{3 + 1} = 66,7\%$$

3) Recall

Recall adalah metrik yang mengukur seberapa baik model dalam mengidentifikasi semua mahasiswa yang lulus tepat waktu. Model ini memiliki **Recall 100%**, yang berarti bahwa model tidak melewatkan satupun mahasiswa yang lulus tepat waktu. Recall dihitung dengan rumus:

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{3}{3 + 0} = 100\%$$

Pencapaian Recall 100% ini sangat penting, karena berarti bahwa model ini sangat efektif dalam mengidentifikasi mahasiswa yang lulus tepat waktu, tanpa ada yang terlewat. Ini menjadikannya alat yang sangat berguna untuk peringatan dini, sehingga pihak universitas dapat segera mengambil tindakan apabila seorang mahasiswa berisiko terlambat lulus.

4) F1-Score

F1-Score adalah rata-rata harmonis antara Presisi dan Recall. F1-Score memberikan gambaran umum tentang keseimbangan antara Presisi dan Recall. Dalam hal ini, model memiliki **F1-Score 80%**, yang menunjukkan keseimbangan yang baik antara keduanya. F1-Score dihitung dengan rumus:

$$F1\text{-Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} = 2 \times \frac{66,7 \times 100}{66,7 + 100} = 80\%$$

Dengan demikian, model ini secara keseluruhan memiliki performa yang baik dalam hal Recall dan F1-Score, meskipun presisi untuk kelas "Tepat Waktu" sedikit lebih rendah.

B. Analisis Fitur

Pada bagian ini, kami akan menganalisis kontribusi dari masing-masing fitur atau variabel dalam memprediksi kelulusan tepat waktu mahasiswa. Dalam penelitian ini, terdapat lima variabel prediktor yang digunakan untuk membangun model: IPK Semester 4, Total SKS yang Ditempuh, Persentase Kehadiran, Status Bekerja, dan Keaktifan Organisasi.

IPK semester 4 merupakan salah satu indikator utama dalam menggambarkan konsistensi akademik mahasiswa. Mahasiswa yang memiliki IPK yang lebih tinggi cenderung memiliki pemahaman yang lebih baik terhadap materi perkuliahan dan lebih mampu mengelola waktu mereka. Dengan demikian, mahasiswa dengan IPK tinggi lebih besar kemungkinannya untuk lulus tepat waktu. Dalam analisis ini, IPK semester 4 terbukti menjadi prediktor yang kuat, karena mahasiswa yang lulus tepat waktu memiliki IPK yang stabil.

Total SKS yang ditempuh menunjukkan beban studi yang dihadapi oleh mahasiswa. Mahasiswa dengan total SKS yang lebih tinggi, terutama yang dapat mengelola waktu dengan baik, lebih cenderung menyelesaikan studinya tepat waktu. Sebaliknya, mahasiswa dengan beban studi yang lebih ringan atau yang kurang mampu mengelola waktu cenderung menghadapi kesulitan dalam memenuhi target kelulusan tepat waktu. Variabel ini juga memiliki korelasi positif terhadap kelulusan tepat waktu, karena semakin banyak SKS yang ditempuh secara efisien, semakin besar kemungkinan lulus tepat waktu.

Kehadiran dalam perkuliahan merupakan indikator penting dalam mengukur keterlibatan mahasiswa dalam proses belajar. Mahasiswa yang sering hadir dalam perkuliahan cenderung lebih terlibat dan memiliki pemahaman yang lebih baik terhadap materi yang diajarkan. Oleh karena itu, mahasiswa dengan persentase kehadiran yang tinggi memiliki peluang lebih besar untuk lulus tepat waktu. Pada analisis ini, persentase kehadiran menunjukkan peran yang signifikan dalam prediksi kelulusan tepat waktu.

Status bekerja dapat mempengaruhi kelulusan tepat waktu karena pekerjaan dapat mengalihkan perhatian mahasiswa dari studi mereka. Mahasiswa yang bekerja penuh waktu atau paruh waktu sering kali kesulitan untuk menjaga fokus dan waktu mereka untuk studi. Dalam hal ini, mahasiswa yang bekerja cenderung lebih berisiko terlambat lulus. Variabel ini menunjukkan hubungan yang signifikan dengan kelulusan terlambat, dengan mahasiswa yang tidak bekerja lebih cenderung lulus tepat waktu.

Keaktifan dalam organisasi menunjukkan tingkat keterlibatan mahasiswa dalam kegiatan ekstrakurikuler yang dapat mempengaruhi manajemen waktu mereka. Mahasiswa yang aktif dalam organisasi cenderung memiliki keterampilan organisasi yang baik, namun jika keterlibatannya berlebihan, hal ini dapat mengganggu fokus akademik mereka dan meningkatkan risiko keterlambatan kelulusan. Namun, keaktifan organisasi juga bisa menjadi indikator positif jika mahasiswa mampu mengelola waktu dengan baik.

Meskipun hasil yang diperoleh menunjukkan performa model yang cukup baik, terdapat beberapa kelemahan yang perlu diakui. Salah satu kelemahan utama adalah ukuran dataset yang kecil. Hanya terdapat 20 mahasiswa dalam dataset ini, yang membatasi kemampuan model untuk generalisasi. Oleh karena itu, hasil penelitian ini lebih bersifat *proof of concept* atau studi awal.

Selain itu, dataset yang digunakan dalam penelitian ini tidak mempertimbangkan berbagai faktor lain yang mungkin mempengaruhi kelulusan tepat waktu, seperti faktor pribadi, kesehatan, atau masalah eksternal yang dihadapi mahasiswa. Oleh karena itu, disarankan agar penelitian ini divalidasi lebih lanjut dengan dataset yang lebih besar dan lebih beragam.

4. CONCLUSION

Penelitian ini berhasil mengembangkan model prediksi kelulusan tepat waktu mahasiswa menggunakan algoritma Support Vector Machine (SVM). Berdasarkan hasil evaluasi, model ini menunjukkan performa yang cukup baik dengan akurasi 75%, recall 100% untuk kelas "Tepat Waktu", dan F1-Score 80%. Beberapa fitur, seperti IPK, total SKS, dan kehadiran, terbukti menjadi prediktor kuat dalam menentukan kelulusan tepat waktu. Namun, karena keterbatasan dataset yang digunakan, hasil ini memerlukan validasi lebih lanjut dengan data yang lebih besar untuk memastikan keandalannya.

REFERENCES

1. N. Purwati, R. Nurlistiani, and O. Devinsen, "DATA MINING DENGAN ALGORITMA NEURAL NETWORK DAN VISUALISASI DATA UNTUK PREDIKSI KELULUSAN MAHASISWA," *Jurnal Informatika*, vol. 20, no. 2, p. 156, Dec. 2020, doi: 10.30873/ji.v20i2.2273.
2. H. Hairani, "Peningkatan Kaneria Metode SVM Menggunakan Metode KNN Imputasi dan K-Means-Smote untuk Klasifikasi Kelulusan Mahasiswa Universitas Bumigora," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 4, p. 713, Jul. 2021, doi: 10.25126/jtiik.2021843428.
3. A. M. Susetyo, J. Junaidi, V. Wardani, S. Subyantoro, and W. Wagiran, "Evaluasi Pelaksanaan Perkuliahan Semester Antara Menggunakan Model Countenance Stake," *Jurnal Onoma Pendidikan Bahasa dan Sastra*, vol. 10, no. 2, p. 2130, May 2024, doi: 10.30605/onoma.v10i2.3680.
4. T. H. Hasibuan and D. Mahdiana, "PREDIKSI KELULUSAN MAHASISWA TEPAT WAKTU MENGGUNAKAN ALGORITMA C4.5 PADA UIN SYARIF HIDAYATULLAH JAKARTA," *SKANIKA Sistem Komputer dan Teknik Informatika*, vol. 6, no. 1, p. 61, Jan. 2023, doi: 10.36080/skanika.v6i1.2976.
5. M. A. S. Pawitra, H.-C. Hung, and H. Jati, "A Machine Learning Approach to Predicting On-Time Graduation in Indonesian Higher Education," *Elinvo (Electronics Informatics and Vocational Education)*, vol. 9, no. 2, p. 294, Dec. 2024, doi: 10.21831/elinvo.v9i2.77052.
6. A. Armansyah and R. Kurniawan, "Model Prediksi Kelulusan Mahasiswa Tepat Waktu dengan Metode Naïve Bayes," *EDUMATIC Jurnal Pendidikan Informatika*, vol. 6, no. 1, p. 1, Jun. 2022, doi: 10.29408/edumatic.v6i1.4789.
7. H. H. Sabtu, W. S. W. M. Noor, and M. F. M. Isa, "Student Attrition at Technical and Vocational Educational Training (TVET) Institutions: The Case of XCel Technical College in Malaysia," *Asian Social Science*, vol. 12, no. 12, p. 197, Oct. 2016, doi: 10.5539/ass.v12n12p197.
8. U. S. Aesyi, A. R. Lahitani, T. W. Diwangkara, and R. T. Kurniawan, "Deteksi Dini Mahasiswa Drop Out Menggunakan C5.0," *JISKA (Jurnal Informatika Sunan Kalijaga)*, vol. 6, no. 2, p. 113, May 2021, doi: 10.14421/jiska.2021.6.2.113-119.
9. H. Hamsiah and N. Adiyati, "Early Prediction of At Risk Students Using Minimal Data: A Machine Learning Framework for Higher Education," *Digitus Journal of Computer Science Applications*, vol. 3, no. 2, p. 105, Apr. 2025, doi: 10.61978/digitus.v3i2.953.
10. R. Syahrani, S. Suhartono, and S. Zaman, "Prediksi Kategori Kelulusan Mahasiswa Menggunakan Metode Regresi Logistik Multinomial," *JISKA (Jurnal Informatika Sunan Kalijaga)*, vol. 8, no. 2, p. 102, May 2023, doi: 10.14421/jiska.2023.8.2.102-111.
11. H. Herman and Y. Christian, "Analisis Perbandingan Algoritma Untuk Prediksi Performa Akademik Mahasiswa Pada Pembelajaran Daring," *Journal of Applied Informatics and Computing*, vol. 6, no. 2, p. 180, Dec. 2022, doi: 10.30871/jaic.v6i2.4854.

12. T. Gori, A. Sunyoto, and H. A. Fatta, "Preprocessing Data dan Klasifikasi untuk Prediksi Kinerja Akademik Siswa," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 1, p. 215, Feb. 2024, doi: 10.25126/jtiik.20241118074.
13. E. Etriyanti, D. Syamsuar, and Y. N. Kunang, "Implementasi Data Mining Menggunakan Algoritme Naive Bayes Classifier dan C4.5 untuk Memprediksi Kelulusan Mahasiswa," *Telematika*, vol. 13, no. 1, p. 56, Feb. 2020, doi: 10.35671/telematika.v13i1.881.
14. H. Setiadi, K. Sanjaya, A. Wijayanto, D. W. Wardhani, and H. D. Cahyono, "Comparative Analysis of Classification Algorithms Using Feature Selection Techniques to Predict On-Time Student Graduation," *Ingénierie des systèmes d information*, vol. 29, no. 4, p. 1365, Aug. 2024, doi: 10.18280/isi.290412.
15. Q. Meidianingsih, D. E. Wardani, E. Salsabila, L. Nafisah, and A. N. Mutia, "Perbandingan Performa Metode Berbasis Support Vector Machine untuk Penanganan Klasifikasi Multi Kelas Tidak Seimbang," *STATISTIKA Journal of Theoretical Statistics and Its Applications*, vol. 23, no. 1, p. 8, Jun. 2023, doi: 10.29313/statistika.v23i1.1660.
16. J. J. Purnama, H. M. Nawawi, S. Rosyida, R. Ridwansyah, and R. Risnandar, "Klasifikasi Mahasiswa HER Berbasis Algoritma SVM dan Decision Tree," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 7, no. 6, p. 1253, Dec. 2020, doi: 10.25126/jtiik.0813080.
17. W. Setyonugroho, S. Sesotya, I. Permana, T. Lestari, D. Mahendra, and H. Abda, "Enhancing Predictive Accuracy: Assessing the Effectiveness of SVM in Predicting Medical Student Performance," *E3S Web of Conferences*, vol. 465, p. 2028, Jan. 2023, doi: 10.1051/e3sconf/202346502028.
18. M. P. Utami, F. Suroso, F. L. H., F. P. J. Sibuea, and K. Chandra, "Integrasi Algoritma Support Vector Machine dengan Java untuk Memprediksi Kualitas Komponen Otomotif dalam Industri 4.0," *Techno Com*, vol. 24, no. 3, p. 790, Aug. 2025, doi: 10.62411/tc.v24i3.12719.
19. N. F. Mahing, A. L. Gunawan, A. F. A. Zen, F. A. Bachtiar, and S. A. Wicaksono, "Klasifikasi Tingkat Stress dari Data Berbentuk Teks dengan Menggunakan Algoritma Support Vector Machine (SVM) dan Random Forest," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 11, no. 5, p. 1067, Dec. 2023, doi: 10.25126/jtiik.1078010.