

# Sistem Peringatan Dini Keterlambatan Masa Studi Mahasiswa Menggunakan Metode Support Vector Machine

Muhammad Alkaff<sup>a,\*</sup>, Eka Setya Wijaya<sup>b</sup>, Akhmad Rojali<sup>c</sup>

<sup>a,b,c</sup>Program Studi Teknologi Informasi, Fakultas Teknik, Universitas Lambung Mangkurat, Jl. Brigjen H. Hasan Basri, Banjarmasin, 70123, Indonesia

\*correspondence e-mail : [m.alkaff@ulm.ac.id](mailto:m.alkaff@ulm.ac.id)

*Abstract*—Students graduating late from college are a common problem in universities. The period of study of students at universities is generally designed to be completed in 3.5 to 4 years. If a student has not graduated past that time, he is considered late in completing his education. Lambung Mangkurat University, as the oldest university in Kalimantan, also experienced these problems. Therefore, an early warning system was built to predict students' possibility of being late in completing their studies. This study uses a sample of students from the Faculty of Engineering, the University of Lambung Mangkurat, to predict students who will be late graduating from Lambung Mangkurat University since semester 5. This system was developed using a model built using the Support Vector Machine (SVM) method. Model training conducted using 755 data from Lambung Mangkurat University Faculty of Engineering students from 2010 to 2014. Then, the performance of the model tested using 234 student data from 2015 and 2016. The parameters used were the number of credits, gender, GPA on semester 1 to 4, and study programs. The test results show that the model has good performance to predict students who will be late in completing their studies with 88.2% accuracy.

*Index Terms*— early warning, lambung mangkurat university, prediction, study period, support vector machine

*Abstrak*—Keterlambatan masa studi mahasiswa merupakan suatu permasalahan yang umum terjadi di dalam perguruan tinggi. Masa studi mahasiswa di universitas umumnya dirancang untuk diselesaikan dalam waktu 3.5 hingga 4 tahun. Apabila mahasiswa belum lulus hingga melewati waktu tersebut maka mahasiswa tersebut dianggap terlambat dalam menyelesaikan pendidikannya. Universitas Lambung Mangkurat sebagai universitas tertua di Kalimantan pun mengalami permasalahan tersebut. Oleh karena itu, dibangunlah sistem peringatan dini yang dapat memprediksi kemungkinan keterlambatan mahasiswa dalam menyelesaikan masa studinya. Penelitian ini menggunakan sampel mahasiswa Fakultas Teknik Universitas Lambung Mangkurat dengan tujuan untuk memprediksi mahasiswa yang akan terlambat lulus dari Universitas Lambung Mangkurat sejak dari semester 5. Sistem ini dikembangkan menggunakan model yang dibangun dengan metode Support Vector Machine (SVM). Training model dilakukan dengan menggunakan 755 data mahasiswa Fakultas Teknik Universitas Lambung Mangkurat dari angkatan 2010 hingga 2014. Kemudian, performa model diuji dengan menggunakan 234 data mahasiswa dari angkatan 2015 dan 2016. Parameter yang digunakan adalah jumlah sks, jenis kelamin, ipk semester 1 sampai 4 dan program studi. Hasil pengujian menunjukkan bahwa model memiliki performa yang bagus sehingga dapat memprediksi mahasiswa yang akan terlambat menyelesaikan masa studinya dengan akurasi 88.2%.

*Kata Kunci*—masa studi, peringatan dini, prediksi, support vector machine, universitas lambung mangkurat

## I. PENDAHULUAN

Universitas Lambung Mangkurat memiliki tujuan menghasilkan mahasiswa yang terkemuka dalam mutu dan IPTEKS, berdaya saing dengan perguruan tinggi lain, dan unggul di lingkungan lahan basah. Fakultas Teknik setiap tahunnya meluluskan ratusan mahasiswa dari berbagai jurusan dari Teknik Sipil, Teknik Arsitektur, Teknik Pertambangan, Teknik Kimia, Teknik Lingkungan, Teknik Mesin, dan Teknologi Informasi, yang mana tingkat kelulusan mahasiswa merupakan salah satu faktor penilaian dalam menentukan nilai akreditasi bagi program studi dan perguruan tinggi oleh BAN-PT (Badan Akreditasi Nasional Perguruan Tinggi).

Pada buku pedoman peraturan akademik Universitas Lambung Mangkurat tahun 2018 [1] dijelaskan tentang penyelesaian kegiatan pendidikan di Universitas Lambung Mangkurat di Bab XI pasal 35. Mahasiswa yang mengikuti kegiatan pendidikan akademik untuk program sarjana dengan beban belajar

minimal adalah 144 sks dengan batas maksimal 160 sks termasuk dengan tugas akhir. Dalam kurikulum akademik yang sudah dirancang mahasiswa diharapkan agar dapat menyelesaikan masa studinya selama 3,5 sampai dengan 4 tahun. Namun, cukup banyak mahasiswa yang lulus kuliah dalam waktu lebih dari 4 tahun bahkan sampai dengan 7 tahun yang berarti mahasiswa tersebut terlambat dalam menyelesaikan masa studi yang telah direncanakan oleh universitas.

Dengan adanya permasalahan ini akan memberikan pengaruh yang dapat merugikan pihak universitas dan para mahasiswa. Dengan semakin menurunnya tingkat kelulusan mahasiswa yang lulus tepat waktu dapat mengakibatkan menurunnya mutu dan kualitas dari universitas. Selain itu bagi mahasiswa yang sudah terlalu lama menyelesaikan masa studinya memiliki kecenderungan menerima peringatan drop out dari akademik. Mahasiswa dengan kecenderungan yang demikian umumnya adalah mahasiswa berkebutuhan khusus yang memerlukan bimbingan lebih, untuk dibina agar dapat lulus tepat waktu. Oleh karena itu, pentingnya untuk memberikan perhatian lebih kepada mahasiswa-mahasiswa yang memiliki potensi lulus tidak tepat waktu.

Bagi universitas penting sekali untuk mengetahui mahasiswa-mahasiswa yang akan terlambat dalam menyelesaikan masa studinya sehingga dapat menjadi bahan evaluasi bagi pihak universitas dalam penyusunan dan evaluasi kurikulumnya. Selain itu, universitas juga dapat memberikan solusi kepada mahasiswa yang mengalami keterlambatan sehingga mahasiswa tersebut dapat menyelesaikan masa studinya dengan tepat waktu. Penerapan metode-metode *Big Data* maupun *Machine Learning* telah banyak digunakan dalam berbagai penelitian mengenai prediksi keterlambatan masa studi maupun performa akademik mahasiswa [2]–[4].

Terdapat beberapa penelitian terkait yang juga mencoba untuk menyelesaikan permasalahan prediksi keterlambatan mahasiswa pada universitas di Indonesia dalam menyelesaikan masa studinya dengan menggunakan metode yang berbeda-beda. Ade Ricky Rozzaqi [5] melakukan studi untuk memprediksi ketepatan kelulusan mahasiswa dengan *dataset* berjumlah 1920 data mahasiswa. Atribut yang digunakan pada penelitian tersebut yaitu jenis kelamin, Program Studi, SKS semester 1–semester 6, IP (indeks prestasi) semester 1–semester 6. Hasil pengujian menunjukkan bahwa metode *Naive Bayes* dengan kombinasi *filtering feature selection information gain* memperoleh hasil terbaik dengan perbandingan nilai akurasi tertinggi 89,79 %, dan nilai AUC tertinggi 0.875.

Selanjutnya terdapat penelitian memprediksi kelulusan mahasiswa dengan menggunakan metode *Learning Vector Quantization*. Atribut yang digunakan pada penelitian tersebut adalah IP (indeks prestasi) semester 1–semester 4 dan lama studi mahasiswa dari angkatan 2006–2012 yang sudah lulus berjumlah 237 mahasiswa. Hasil dari penelitian ini untuk menghindari mahasiswa yang akan mengalami *drop out* (DO) dan sebagai acuan bagi akademik. Hasil yang diperoleh dari *Learning Vector Quantization* menghasilkan nilai akurasi sebesar 70% untuk data pengujian yang sesuai dengan jaringan target dan nilai akurasi sebesar 30 % yang tidak sesuai dengan target [6].

Ari Fadli [7] dalam penelitiannya melakukan perbandingan antara metode Jaringan Syaraf Tiruan (JST), *Support Vector Machine* (SVM), dan *Decision Tree*. Dalam penelitiannya, menggunakan *dataset* berupa data akademik mahasiswa di Fakultas Teknik Universitas Jendral Soedirman dari semester ganjil 2014/2015 sampai dengan semester ganjil 2017/2018 berjumlah 651 data mahasiswa. Atribut yang digunakan pada penelitian ini yaitu NIM, IPK semester 1-3, SKS semester 1-3, seminar, artikel ilmiah, ujian pendadaran, PKL, KKN, jumlah MK ulang, dan jumlah SKS MK ulang. Metode yang digunakan untuk analisis yaitu CRISP – DM. Dengan hasil perbandingan memperlihatkan bahwa *Decision Tree* memiliki nilai akurasi 87.64% dan AUC 0.886, lalu ANN dengan nilai akurasi 88,35% dan AUC 0,934, dan SVM menghasilkan kinerja terbaik, yaitu dengan nilai akurasi 90,55% dan AUC 0,959.

Selain itu, terdapat penelitian yang membahas perbandingan prediksi keterlambatan kelulusan mahasiswa berdasarkan performa mahasiswa dengan membandingkan model dari *Support Vector Machine* (SVM), *Gaussian Process* (GP) dan *Deep Boltzmann Machine* (DBM). Dalam penelitian tersebut, mereka menggunakan *dataset* dari University of New Mexico (UNM) dengan jumlah yang digunakan untuk eksperimen sebanyak 16174 mahasiswa. Menggunakan set fitur yang dibagi menjadi 3 *dataset*, yaitu : *dataset* 1 (IPK kumulatif SMA, skor ACT komposit, jenis kelamin, jika mahasiswa tersebut berasal dari etnis Indian Amerika, IPK semester pertama dan kedua di UNM, jumlah jam kredit yang diambil oleh mahasiswa hingga Semester kedua di UNM, dan jika mahasiswa berubah jurusan hingga semester kedua di UNM), *dataset* 2 (IPK semester ketiga dan keempat di UNM, dan jumlah jam kredit yang diambil oleh mahasiswa hingga semester keempat di UNM), *dataset* 3 (IPK semester kelima dan keenam di UNM, dan jumlah jam kredit yang diambil oleh mahasiswa hingga semester keenam di UNM), dan nilai target terdiri dari tiga kelas berikut: Kelas 1 (tidak ada penundaan dalam kelulusan, yaitu mahasiswa lulus dalam empat tahun), Kelas 2 (tertunda kelulusan dalam satu tahun), Kelas 3 (tertunda


kelulusan dalam dua tahun atau lebih). Hasil yang didapat dari ketiga model SVM, GP, dan DBM dalam memprediksi keterlambatan kelulusan menghasilkan nilai dengan tingkat akurasi keseluruhan di wilayah 68%, 72% dan 75% untuk masing-masing *dataset* 1, 2 dan 3. Namun, dalam hal akurasi secara keseluruhan, perbedaan kinerja antara ketiga model itu diabaikan. Maka, DBM memiliki nilai kinerja lebih baik dalam hal presisi, *recall*, skor-F1, dan tingkat kesalahan untuk masing-masing kelas, namun dari perbandingan ketiga model berdasarkan waktu perhitungan, mengingat sumber daya dan *dataset* komputasi yang sama, SVM memiliki performa terbaik dibandingkan dengan DBM sedangkan GP memiliki performa terburuk [8].

## II. METODE

### 1. Support Vector Machine (SVM)

*Support Vector Machine* (SVM) merupakan metode *machine learning* yang berbasis pembelajaran terawasi (*supervised learning*) yang dikembangkan oleh Vapnik dkk [9], [10]. SVM dikembangkan berdasarkan teori pembelajaran statistik dan *structural risk minimization* (SRM). Dalam berbagai pengaplikasiannya SVM memiliki tingkat akurasi yang tinggi dalam memprediksi, dimana tingkat akurasi klasifikasi sangat tergantung pada pengaturan parameter serta seleksi fitur [11]. Pada umumnya, metode SVM digunakan untuk menyelesaikan permasalahan klasifikasi dan regresi dengan jumlah data yang besar [12]. SVM digunakan untuk mengklasifikasi berbagai kategori data dari berbagai disiplin ilmu. Metode ini telah digunakan untuk dua kelas masalah klasifikasi linear dan non-linier. SVM menciptakan *hyperplane* atau *multiple hyperplanes* dalam ruang berdimensi tinggi, dan *hyperplane* terbaik di dalamnya adalah *hyperplane* yang secara optimal membagi data ke dalam kelas yang berbeda dengan pemisahan terbesar di antara kelas-kelas tersebut. Klasifikasi non-linear menggunakan berbagai fungsi kernel untuk memperkirakan margin. Tujuan utama dari fungsi-fungsi kernel ini (linier, polinomial, basis radial, dan sigmoid) adalah untuk memaksimalkan margin antara *hyperplane* [13].

Gambar 1 menunjukkan data yang terdiri dari dua kelas. Dimana kelas yang terdiri dari +1 sebagai kelas positif dan kelas yang terdiri dari -1 sebagai kelas negatif. Data yang terdapat di dalam kelas negatif disimbolkan dengan bentuk kotak warna merah dan kelas positif disimbolkan dengan bentuk lingkaran warna kuning. Masing-masing titik tersebut digunakan sebagai pemisah antara data positif dan negatif.



Gambar 1. Menemukan Hyperplane Terbaik pada SVM [14]

Data yang berada dalam bidang pembatas ini disebut *support vector*. Dua kelas yang ada pada gambar tersebut dapat dipisahkan oleh sepasang bidang pembatas yang paralel. Bidang pembatas pertama adalah sebagai pembatas kelas pertama sedangkan bidang pembatas kedua membatasi kelas kedua, sehingga menghasilkan persamaan (1) dimana kelas pertama terdiri dari *class +1* dan persamaan (2) dengan *class -1* yang dipisahkan oleh *hyperplane*.

$$w \cdot x_i + b \geq 1 \text{ untuk } y_i = 1 \quad (1)$$

$$w \cdot x_i + b \leq -1 \text{ untuk } y_i = -1 \quad (2)$$

Nilai *w* (*weight*) nilai bobot dari bidang dan nilai *b* (*bias*) merupakan posisi bidang relatif pada titik pusat koordinat. Persamaan (3) untuk mencari nilai *b*, dan persamaan (4) untuk menghitung nilai *w*.

$$b = -\frac{1}{2}(x_i^+ \cdot w + x_i^- \cdot w) \quad (3)$$

$$w = \sum_{i=1}^1 \alpha_i y_i x_i \quad (4)$$

Jarak antara kedua *hyperplanes* kanonik,  $H_1$  dan  $H_2$  adalah kuantitas yang kita sebut sebagai margin dan diberikan oleh persamaan (5).

$$\text{Jarak} = |dH_1 - dH_2| = \frac{2}{\|w\|} \quad (5)$$

Untuk memilih salah satu yang memiliki kemampuan generalisasi terbaik dengan memaksimalkan margin antara *hyperplanes* kanonik, digunakan persamaan (6) dan (7) untuk mengatasi masalah optimasi :

$$\text{Minimalkan } J_1[w] = \frac{1}{2} \|w\|^2 \quad (6)$$

$$\text{Bergantung pada } y_i(x_i \cdot w + b) - 1 \geq 0, i=1, \dots, l \quad (7)$$

Metode sekuensial SVM yang dikembangkan oleh Vijayakumar dan Wu [15] menyediakan *pseudocode* untuk algoritma pembelajaran sekuensial. Algoritma pada konvergensi menyediakan set optimal *Multiple Lagrange* untuk masalah klasifikasi dalam ruang fitur berdimensi tinggi yang sesuai dengan maksimum *cost function*.

1. Inisialisasi  $h_i = 0$ . Menghitung matriks metode sekuensial (8).

$$D_{ij} = y_i y_j (K(x_i, x_j) + \lambda) \quad (8)$$

$$\text{for } i, j = 1, \dots, l.$$

2. Setelah selesai tahap 1 menghitung matriks lalu dilanjutkan ke langkah berikutnya, untuk setiap pola dimana  $i = 1$  ke  $l$ .

$$E_i = \sum_{j=1}^l h_j D_{ij} \quad (9)$$

$$\delta h_i = \min\{\max[y(1 - E_i) - h_i], C - h_i\} \quad (10)$$

$$h_i = h_i + \delta h_i \quad (11)$$

2. Nilai ACC (*Accuracy*) dan AUC (*Area Under Curva*)

Ukuran atau metrik dapat digunakan untuk menilai atau mengevaluasi model klasifikasi, seperti: akurasi (ACC) atau tingkat pengakuan, area di bawah kurva (AUC), tingkat kesalahan tingkat disklasifikasi, tingkat sensitivitas pengingat atau tingkat positif (TPR), kekhususan atau tingkat negatif (TNR), presisi, rata-rata *F-Measure* F1 atau *F-score* or harmonik dari presisi dan recall [16]. Dalam klasifikasi dua kelas (biner), hasil yang diprediksi akan dilabeli sebagai kelas positif (p) atau negatif (n). Ada empat hasil yang mungkin dari klasifikasi biner.

1. Jika hasil prediksi adalah p dan nilai benar juga p disebut *true positive* (TP).
2. Selanjutnya, jika hasil prediksi adalah p dan nilai benar adalah n disebut *false positive* (FP).
3. Sebaliknya, jika hasil prediksi dan nilai true adalah n maka *true negative* (TN).
4. Dan jika hasil prediksi adalah n tetapi nilai sebenarnya adalah p maka *false negative* (FN).

Tabel 1. *Confusion Matrix* 2 Kelas (Tupel Positif dan Negatif)

Actual Class	Predicted Class	
	Positive	Negative
Positive	True Positive	False Negative
Negative	False Positive	True Negative

Rumus ukuran evaluasi adalah:

1. *Accuracy* (ACC) adalah nilai akurasi dari suatu model:

$$\frac{TN + TP}{TN + TP + FN + FP} \quad (12)$$

2. *Error Rate* atau tingkat kesalahan klasifikasi:

$$\frac{FN + FP}{TN + TP + FN + FP} \quad (13)$$

3. *Recall* atau tingkat positif sejati (TPR) dalah persentasekasus positif yang diidentifikasi benar

$$\frac{TP}{TP + FN} \quad (14)$$

4. *Specificity* (SPC) atau true negative rate (TNR):

$$\frac{TN}{TN + FP} \quad (15)$$

5. *Precision* atau presisi, yang merupakan hasil persentase dari pelabelan yang benar dari kasus positif:

$$\frac{TP}{TP + FP} \quad (16)$$

6. *F-Measure* atau F1 atau F-skor atau rata-rata harmonis dari presisi dan *recall*:

$$\frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (17)$$

3. *Early Warning System*


*Early Warning System* (EWS) atau disebut juga sebagai sistem peringatan dini merupakan kumpulan kapasitas yang diperlukan untuk menghasilkan dan menyebarluaskan informasi peringatan yang tepat waktu dan akurat guna memungkinkan orang, masyarakat, dan organisasi yang ada kemungkinan terancam bahaya agar dapat merencanakan dan merespons sesuai dan dalam waktu yang memadai untuk meminimalkan risiko bahaya tersebut [17].

4. *Data Penelitian*


Penelitian ini menggunakan data yang diambil dari SIMARI (Sistem Informasi Universitas Lambung Mangkurat Terintegrasi) yaitu berupa data mahasiswa dari angkatan 2010 sampai dengan angkatan 2016 dengan rentang data selama enam tahun. Untuk menyederhanakan proses pengambilan dan pemrosesan data, data mahasiswa yang digunakan hanya diambil dari mahasiswa Fakultas Teknik Universitas Lambung Mangkurat. Data mahasiswa angkatan 2010 sampai dengan 2014 digunakan sebagai data *training* yaitu sejumlah 755 mahasiswa. Selanjutnya, data mahasiswa dari tahun angkatan 2015–2016 sejumlah 234 mahasiswa digunakan sebagai data *testing*.

5. *Perancangan Sistem*

Gambar 2 adalah bagan alur sistem *Support Vector Machine*. Prosesnya dimulai menyiapkan *dataset* yang kemudian data tersebut akan dilatih dan diuji dengan menggunakan metode *Support Vector Machine*, lalu setelah data diproses dilakukan proses pengujian ACC dan AUC untuk melihat tingkat akurasi, selanjutnya keluar hasil dan evaluasi.



Gambar 2. Diagram alur metode SVM



Gambar 3. Diagram alur sistem yang akan dibuat

Gambar 3 merupakan alur perancangan sistem yang akan dibuat untuk melakukan prediksi pada mahasiswa. Dimulai dari pengguna melakukan login lalu sistem akan menampilkan halaman menu prediksi, kemudian pengguna menginputkan data mahasiswa yang selanjutnya akan diproses oleh sistem dengan menggunakan *Support Vector Machine*. Kemudian setelah selesai melalui pemrosesan data mahasiswa, maka proses selanjutnya ditampilkan hasil dari prediksinya

III. HASIL DAN PEMBAHASAN

a) *Implementasi Metode SVM*

Penelitian ini menggunakan data mahasiswa Fakultas Teknik Universitas Lambung Mangkurat. Data yang digunakan berupa informasi detail dari mahasiswa tersebut diantaranya NIM, prodi, jenis kelamin, SKS 4 semester, IP 4 semester, IPK, dan tanggal yudisium. Dengan jumlah data sebanyak 989 data mahasiswa, yang mana dari data mahasiswa tersebut dibagi menjadi dua data dimana 755 data *training* dan 234 data *testing* guna memprediksi mahasiswa yang akan mengalami keterlambatan dengan menggunakan model *Support Vector Machine*.

Dari data tersebut maka diolah dengan mengimpor data tersebut ke dalam sistem, yang kemudian akan dilakukan proses selanjutnya yaitu *preprocessing* data dengan menghapus data yang tidak lengkap atau mempunyai *missing value* serta menyesuaikan data numerik menjadi data kategorikal. Nantinya data tersebut digunakan dalam proses perhitungan *Support Vector Machine* untuk menentukan hasil yang sesuai dengan nilai yang menjadi acuan untuk data tersebut.

Tabel 2. Variabel dan Kategori

Variabel	Kategori
Jumlah SKS	0 = $\leq 82$
	1 = $\geq 82$
Jenis Kelamin	0 = Perempuan
	1 = Laki-laki
IPK	0 = $< 2,75$
	1 = 2,75-3,5
	2 = $> 3,5$
Prodi	0 = Sipil
	1 = Pertambangan
	2 = Mesin
	3 = Arsitektur
	4 = Kimia
	5 = Lingkungan

1. Gambar 4 merupakan halaman yang digunakan oleh pengguna untuk menguji data mahasiswa yang telah melalui masa perkuliahan selama 4 semester, untuk mengetahui apakah mahasiswa tersebut akan mengalami keterlambatan atau tidak dalam menyelesaikan masa studi yang nantinya dapat dilihat hasilnya di halaman hasil prediksi.

Gambar 4. Halaman Prediksi

2. Gambar 5 merupakan halaman menu hasil prediksi yang berfungsi untuk melihat hasil dari prediksi keterlambatan mahasiswa.

#### b) Hasil Pengujian

Pada proses pengujian data ini dilakukan dengan menggunakan bantuan dari aplikasi *Orange 3 Python*. Dari hasil pengujian metode SVM dengan menggunakan data mahasiswa dengan jumlah 755 data *training* dan 234 data *testing*, didapatkan hasil pengujian pada sistem (tabel 4). Diketahui bahwa mahasiswa yang terlambat sebanyak 26 mahasiswa dan tidak terlambat sebanyak 208 mahasiswa pada gambar 6 dapat dilihat performa model yang dibangun pada gambar 8.

Tabel 4. Hasil prediksi


Data	Terlambat	Tidak terlambat	Total
Terlambat	26	0	26
Tidak terlambat	0	208	208
			234

Hasil Prediksi  
Accuracy 0.7965686274509803  
AUC : Fair


Show 10 entries Search:

No	NIM	Status	Hasil SVM	Angkatan	Program Studi	Jenis Kelamin
1	H1C110003	telat	telat	2010	S1 - TEKNIK PERTAMBANGAN	Laki-Laki
2	H1C110049	telat	telat	2010	S1 - TEKNIK PERTAMBANGAN	Laki-Laki
3	H1B110024	telat	tidak telat	2010	S1 - ARSITEKTUR	Laki-Laki
4	H1A110210	telat	telat	2010	S1 - TEKNIK SIPIL	Laki-Laki
5	H1A110220	telat	telat	2010	S1 - TEKNIK SIPIL	Laki-Laki

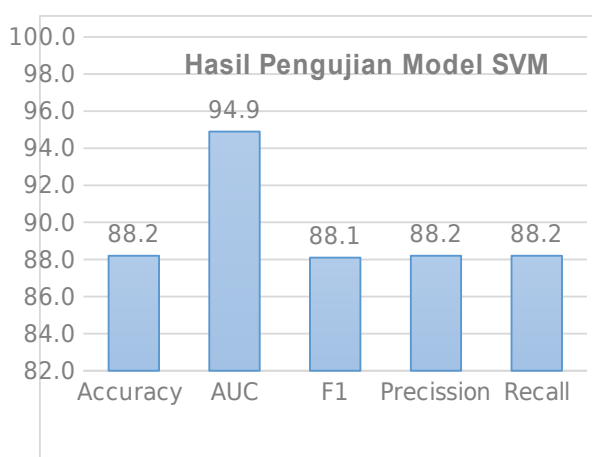
Gambar 5. Halaman Hasil Prediksi



Gambar 6. Proses Pembangunan Model SVM



Gambar 7. Proses Pengujian Model SVM



Gambar 8. Hasil Pengujian Model SVM

**IV. KESIMPULAN**

Dari hasil penelitian ini dapat diambil kesimpulan bahwa sistem peringatan dini yang telah dibangun dengan menggunakan metode *Support Vector Machine* memiliki performa yang baik yaitu dapat

*Sistem Peringatan Dini Keterlambatan Masa Studi Mahasiswa Menggunakan Metode Support Vector Machine (Muhammad Alkaff)*

memprediksi mahasiswa yang akan terlambat lulus nantinya dengan akurasi sebesar 88.2%. Atribut yang digunakan untuk memprediksi keterlambatan mahasiswa yaitu IP dari semester 1 sampai dengan semester 4, jenis kelamin dan program studi mahasiswa tersebut. Model prediksi ini dibangun dengan menggunakan 755 data mahasiswa Fakultas Teknik Universitas Lambung Mangkurat dari angkatan 2010 hingga 2014 selanjutnya, pengujian model dilakukan dengan menggunakan 234 data mahasiswa dari angkatan 2015 – 2016. Diharapkan dengan menggunakan sistem ini, dapat memberikan peringatan dini terhadap universitas mengenai daftar mahasiswa yang diperkirakan akan terlambat lulus sejak dari semester 5. Selanjutnya, diharapkan sistem peringatan dini keterlambatan mahasiswa ini dapat dikembangkan lagi sesuai dengan kebutuhan Universitas Lambung Mangkurat yakni menambah modul-modul yang dapat melengkapi fitur sistem serta dapat diintegrasikan dengan sistem informasi akademik universitas.

## DAFTAR PUSTAKA

- [1] Universitas Lambung Mangkurat, *Pedoman Akademik*. Banjarmasin: Universitas Lambung Mangkurat, 2018.
- [2] V. Tampakas, I. E. Livieris, E. Pintelas, N. Karacapilidis, and P. Pintelas, "Prediction of students' graduation time using a two-level classification algorithm," in *International Conference on Technology and Innovation in Learning, Teaching and Education*, 2018, pp. 553–565.
- [3] M. S. Nuraffah, S. Abdul-Rahman, S. Mutalib, N. H. A. Hamid, and A. M. Ab Malik, "Review on predicting students' graduation time using machine learning algorithms," *Int. J. Mod. Educ. Comput. Sci.*, vol. 11, no. 7, p. 1, 2019.
- [4] Z. Wang *et al.*, "Design and Implementation of Early Warning System Based on Educational Big Data," in *2018 5th International Conference on Systems and Informatics, ICSAI 2018*, 2019, pp. 549–553.
- [5] A. R. Rozzaqi, "Naive Bayes dan Filtering Feature Selection Information Gain untuk Prediksi Ketepatan Kelulusan Mahasiswa," *J. Inform. UPGRIS*, vol. 1, no. 1 Juni, 2015.
- [6] D. Kartini, R. A. Nugroho, M. R. Faisal, and U. L. Mangkurat, "Klasifikasi Kelulusan Mahasiswa Menggunakan Algoritma Learning Vector Quantization," vol. 3, no. 2, pp. 93–98, 2017.
- [7] A. Fadli, M. I. Zulfa, and Y. Ramadhani, "Perbandingan Unjuk Kerja Algoritme Klasifikasi Data Mining dalam Sistem Peringatan Dini Ketepatan Waktu Studi Mahasiswa," *J. Teknol. dan Sist. Komput.*, vol. 6, no. 4, pp. 158–163, 2018.
- [8] T. Ojha, G. L. Heileman, M. Martinez-Ramon, and A. Slim, "Prediction of graduation delay based on student performance," in *2017 International Joint Conference on Neural Networks (IJCNN)*, 2017, pp. 3454–3460.
- [9] B. E. Boser, I. M. Guyon, and V. N. Vapnik, "A training algorithm for optimal margin classifiers," in *Proceedings of the fifth annual workshop on Computational learning theory - COLT '92*, 1992, pp. 144–152.
- [10] C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, 1995.
- [11] H. Faris, M. A. Hassonah, A.-Z. Ala'M, S. Mirjalili, and I. Aljarah, "A multi-verse optimizer approach for feature selection and optimizing SVM parameters based on a robust system architecture," *Neural Comput. Appl.*, vol. 30, no. 8, pp. 2355–2369, 2018.
- [12] S. Suthaharan, "Support vector machine," in *Machine learning models and algorithms for big data classification*, Springer, 2016, pp. 207–235.
- [13] I. Ahmad, M. Basher, M. J. Iqbal, and A. Rahim, "Performance comparison of support vector machine, random forest, and extreme learning machine for intrusion detection," *IEEE access*, vol. 6, pp. 33789–33795, 2018.
- [14] A. S. Nugroho, A. B. Witarto, and D. Handoko, "Support Vector Machine," *Power Syst.*, vol. 28, pp. 161–226, 2007.
- [15] S. Vijayakumar and S. Wu, "Sequential support vector classifiers and regression," *Margin*, vol. 1, no. h2, p. h2, 1999.
- [16] J. Han, J. Pei, and M. Kamber, *Data mining: concepts and techniques*. Elsevier, 2011.
- [17] I. Kelman and M. H. Glantz, "Early Warning Systems Defined BT - Reducing Disaster: Early Warning Systems For Climate Change," A. Singh and Z. Zommers, Eds. Dordrecht: Springer Netherlands, 2014, pp. 89–108.

**Muhammad Alkaff**, Meraih gelar sarjana komputer (S.Kom) dari Universitas Brawijaya pada tahun 2009. Kemudian meraih gelar Master (M.Kom) dari Institut Teknologi Sepuluh Nopember pada tahun 2013. Saat ini Penulis menjadi dosen program studi Teknologi Informasi di Universitas Lambung Mangkurat.

Eka Setya Wijaya, Meraih gelar sarjana teknik (S.T) dari Universitas Ahmad Dahlan pada tahun 2006. Kemudian meraih gelar Master (M.Kom) dari Universitas Dian Nuswantoro pada tahun 2012. Saat ini Penulis menjadi dosen program studi Teknologi Informasi di Universitas Lambung Mangkurat.