

Aplikasi Pengukur Tingkat Kepuasan Alumni Berdasarkan Data Tracer Study Berbasis Metode Machine Learning

I Wayan Supriana¹, Cokorda Pramatha², Luh Arida Ayu Rahning Putri³

^{1,2,3}Program Studi Informatika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Udayana
Jl. Raya Kampus Unud Bukit Jimbaran, Badung, Indonesia

e-mail: wayan.supriana@unud.ac.id¹, cokorda@unud.ac.id², rahningputri@unud.ac.id³

Received : Februari, 2024

Accepted : April, 2024

Published : April, 2024

Abstract

Tracking graduates or better known as tracer study is one of the feedback from alumni towards higher education. Tracer study is one of the mandatory activities for universities to explore various aspects needed from alumni such as personal data when they were students, services during college, length of time looking for work and suitability for the job. Every year hundreds of students are graduated by universities, so the number of alumni continues to increase from year to year, it is necessary to carry out in-depth analysis using data science techniques to get insight into tracer study data as an evaluation by the study program. Analysis of tracer study data is needed to improve the learning process by measuring graduate satisfaction levels. The aim of the research is to create a predictive model analysis of alumni satisfaction levels based on tracer study data classification using machine learning methods, namely the K-Means algorithm as data clusterization, the Support Vector Machine algorithm as data classification. The assessment model uses 87 tracer study data features, where the Support Vector Machine algorithm describes the classification of tracer study data with an accuracy level of 90%. Based on factors that can classify the level of alumni satisfaction, it can be determined that the quality of graduates will be better.

Keywords: K-Means, Measuring Graduate Satisfaction Levels, Support Vector Machine, Tracer Study

Abstrak

Pelacakan lulusan atau yang lebih dikenal dengan tracer study adalah salah satu feedback dari alumni terhadap perguruan tinggi. Tracer study merupakan salah satu kegiatan wajib bagi perguruan tinggi dalam menggali berbagai macam aspek yang dibutuhkan dari alumni seperti data diri ketika menjadi mahasiswa, pelayanan selama kuliah, lamanya mencari kerja serta kesesuaian dengan pekerjaan. Setiap tahun ratusan mahasiswa sudah diluluskan oleh perguruan tinggi, dengan begitu jumlah alumni dari tahun ke tahun terus bertambah, perlu dilakukan analisis yang mendalam dengan teknik data science untuk mendapatkan insight data tracer study sebagai evaluasi oleh program studi. Analisis data tracer study diperlukan untuk perbaikan proses pembelajaran melalui pengukuran tingkat kepuasan lulusan. Adapun tujuan penelitian, yaitu membuat analisis model prediksi tingkat kepuasan alumni berdasarkan klasifikasi data tracer study menggunakan metode machine learning yaitu algoritma K-Means sebagai klusterisasi data, algoritma Support Vektor Machine sebagai klasifikasi data. Model penilaian menggunakan 87 fitur data tracer study, dimana algoritma Support Vektor Machine menggambarkan klasifikasi data tracer study dengan tingkat akurasi sebesar 90%. Berdasarkan faktor yang dapat mengklasifikasikan tingkat kepuasan alumni, maka dapat menentukan kualitas lulusan akan semakin baik.

Kata Kunci: K-Means, Pengukuran Tingkat Kepuasan Lulusan, Support Vektor Machine, Tracer Study

1. PENDAHULUAN

Tracer study adalah survei terhadap alumni yang dilaksanakan oleh perguruan tinggi dengan tujuan untuk memperoleh informasi lulusan, dari saat menyelesaikan pendidikan sampai waktu pengisian data survei [1]. Informasi dari tracer study digunakan untuk meninjau pelayanan dan sistem pendidikan serta transisi antara dunia pendidikan dan industri. Tracer study merupakan salah satu kegiatan wajib bagi perguruan tinggi guna memperoleh berbagai macam aspek yang dibutuhkan dari alumni seperti data diri ketika menjadi mahasiswa, pelayanan selama kuliah, lamanya mencari kerja, kesesuaian antara pekerjaan dengan program studi, hingga status pekerjaan dan gaji dibutuhkan datanya [2].

Berdasarkan surat Edaran Direktur Jenderal Pembelajaran dan Kemahasiswaan Nomor: 471/B/SE/VII/2017 tanggal 26 Juli 2017 tentang pentingnya pelaksanaan Tracer Study di Perguruan Tinggi, dalam upaya meningkatkan relevansi pendidikan tinggi dan kebutuhan dunia kerja, Hasil tracer study diharapkan dapat disosialisasikan kepada berbagai pihak terkait untuk evaluasi kinerja perguruan tinggi, dan secara khusus untuk mendorong perbaikan proses pembelajaran di perguruan tinggi melalui pengembangan kurikulum yang relevan dengan kebutuhan dunia kerja. Selain itu, hasil tracer study diperlukan untuk pengambilan kebijakan nasional terkait pendidikan tinggi.

Perguruan tinggi dalam mengelola hasil tracer study belum maksimal untuk menggali serapan lulusan pada industri sehingga belum dapat mempersiapkan lulusan sesuai dengan kompetensi pada dunia industri, Setiap tahun ratusan mahasiswa sudah diluluskan oleh perguruan tinggi, dengan begitu jumlah alumni dari tahun ke tahun terus bertambah, melalui data tracer study perlu dilakukan analisis yang mendalam dengan teknik data science untuk mendapatkan insight dari data tersebut [3]. Tujuan sebagai bahan evaluasi oleh program studi untuk terus meningkatkan pelayanan kepada mahasiswa yang memiliki alumni yang tersebar dan banyak diserap oleh industri [4].

Penelitian tentang tracer study menggunakan pendekatan metode machine learning telah dilakukan oleh [5]. Pada penelitian ini menekankan analisa kelompok waktu tunggu


kerja, tujuannya untuk mengevaluasi kelancaran alumni memperoleh pekerjaan. Metode yang digunakan adalah SVM dan Backpropagation yang masing-masing memiliki akurasi sebesar 83,33% dan 83%. Pengetahuan tentang faktor-faktor yang menentukan kelancaran dalam memperoleh pekerjaan diharapkan dapat membantu pihak perguruan tinggi dalam merancang kebijakan yang relevan untuk meningkatkan kualitas lulusan. Pada penelitian ini hanya membahas dari sisi klasifikasi seperti waktu tunggu kerja untuk mengetahui tingkat kelancaran alumni dalam mendapatkan pekerjaan. Sementara pada penelitian yang dilakukan pengukuran tingkat kepuasan lulusan melalui data tracer study program studi.

Penelitian yang dilakukan bertujuan membuat analisis model prediksi tingkat kepuasan alumni berdasarkan klasifikasi data tracer study untuk pemantauan, penilaian pengembangan pendidikan, termasuk peningkatan metode belajar-mengajar, dan implementasi peningkatan proses pembelajaran melalui pengukuran tingkat kepuasan lulusan. Penelitian ini mengembangkan aplikasi menggunakan metode-metode machine learning yaitu algoritma K-Means sebagai klusterisasi data dan algoritma Support Vektor Machine sebagai klasifikasi data, kedua model adalah hasil dari *tuning* model terbaik berdasarkan data tracer study. Data penelitian menggunakan data tracer study program studi dari tahun 2018 sampai tahun 2020 dengan 87 fitur data. Permasalahan penelitian adalah pelaksanaan tracer studi dilakukan untuk memperoleh pemahaman yang objektif mengenai pencapaian lulusan dalam karier, status, dan pendapatan alumni. Namun, studi tersebut belum ada penelitian yang cukup untuk mengukur tingkat kepuasan berdasarkan sejauh mana pengetahuan dan keterampilan yang dimiliki sesuai dengan pekerjaan saat ini. Penelitian ini membuat sebuah pengukuran tingkat kepuasan alumni dari data tracer study. Penelitian ini sangat penting untuk dilakukan sebagai dasar salah satu upaya dalam penjaminan mutu Program Studi.

2. METODE PENELITIAN

Penelitian ini melalui beberapa tahapan yang dilakukan dengan menggunakan konsep pengembangan proyek data sains yaitu Cross Industry Standard Process for Data Mining

(CRISP-DM), seperti disajikan pada Gambar 1. Tahap business understanding, tahap data understanding, tahap data preparation, tahap modelling, tahap evaluation dan tahap deployment [6].



Gambar 1. Tahap Metodologi Cross Industry Standard Process for Data Mining (CRISP-DM)

2.1 Tahap Business Understanding

Tahap ini dilakukan pemahaman terhadap permasalahan yang ingin diselesaikan pada data tracer study. Pelaksanaan tracer study masih mengalami hambatan terkait kebutuhan, ketersediaan sumber daya, dan pendekatan metodologi analisis. Seringkali, tracer study yang dilaksanakan program studi hanya bertujuan untuk memenuhi persyaratan akreditasi., analisis mendalam terkait data tracer study belum dilakukan untuk mengetahui tingkat kepuasan alumni. Selain itu, analisis data tracer study dianggap kurang memadai, dan sering kali disertai dengan hambatan dan tantangan dalam menerapkan metode yang sesuai.

2.2 Tahap Data Understanding

Pada tahap ini, data penelitian dipahami secara mendalam, proses yang dilakukan adalah mengumpulkan data, jumlah data penelitian sebanyak 200 data dengan 87 atribut, data diambil dari data tracer study tahun 2018 sampai 2020. Proses kedua menelaah data, dilakukan dengan melakukan analisis data secara eksploratif (Exploratory Data Analysis), baik melalui pendekatan statistik maupun visualisasi, bertujuan untuk memperjelas

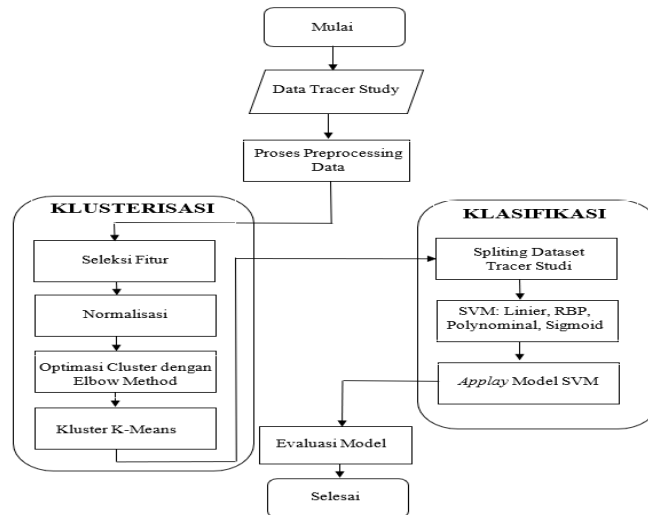
pemahaman tentang data. Data dianalisis berdasarkan ketidaklengkapan data dan kesalahan data. model visualisasi digunakan untuk menyederhanakan analisis data ,baik untuk visualisasi atribut maupun hubungan antara dua atribut [7]. Proses terakhir memvalidasi data, yaitu menilai kesesuaian data dengan permasalahan yang akan dipecahkan. Evaluasi analisis data yang telah dilakukan untuk memastikan apakah data yang terkumpul sesuai dengan harapan, termasuk jumlahnya, atributnya, dan kualitasnya. Salah satu aspek kualitas yang diperiksa adalah keseimbangan data.

2.3 Tahap Data Preparation

Data preparation mengacu pada penggunaan hasil analisis yang telah dilakukan untuk mengoptimalkan kualitas data dan meningkatkan hasil prediksi model. Tahap awal dalam data preparation adalah pemilihan dan penyaringan data, dimana tidak semua data dari tracer studi yang terkumpul akan digunakan. Pemilihan data didasarkan pada kualitas data dan kebutuhan analitik yang telah ditetapkan. Proses pemilihan data dilakukan dengan mempertimbangkan atribut, serta mereduksi atribut yang tidak relevan berdasarkan korelasi antar atribut [8]. Langkah berikutnya membersihkan data, dilakukan untuk memperbaiki kualitas data dari mengatasi missing value, outlier data dan inkonsistensi data. Langkah terakhir adalah merekonstruksi data, proses ini mengubah struktur data sehingga lebih mudah diproses oleh algoritma, teknik yang dilakukan adalah normalisasi, transformasi data dan feature engineering.

2.4 Tahap Data Modelling

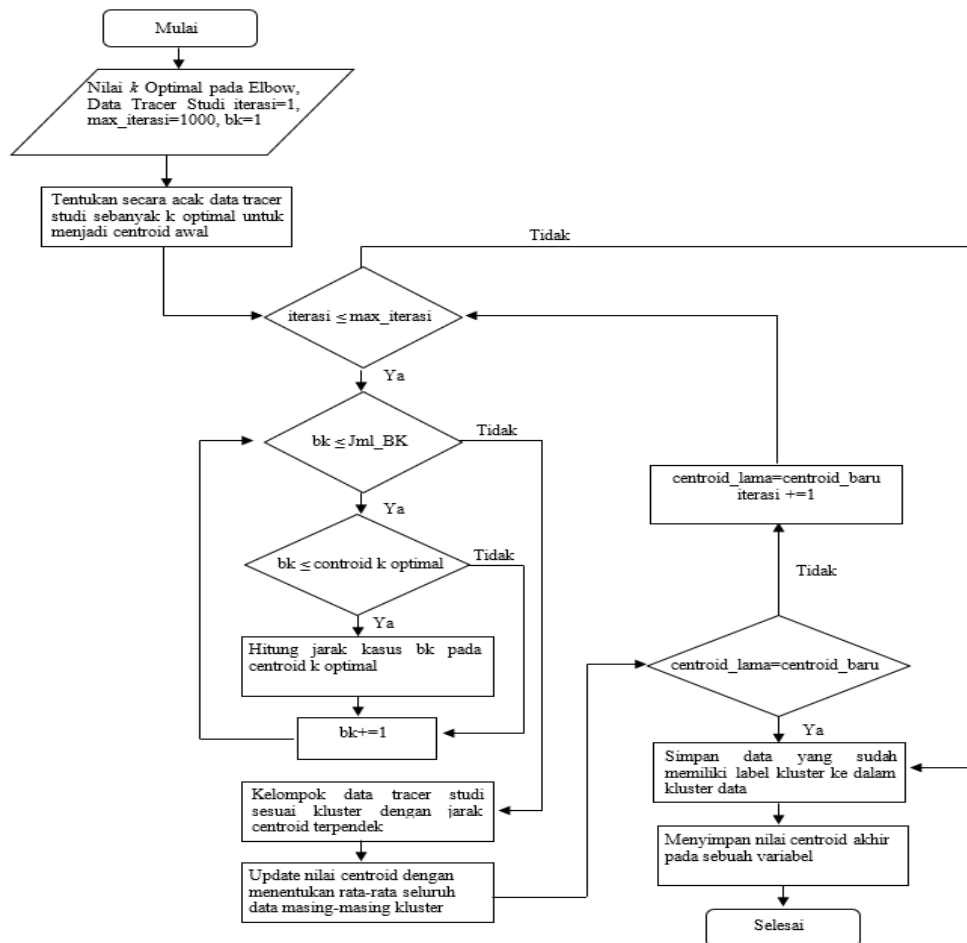
Pada tahap ini menggunakan algoritma Machine Learning untuk mengembangkan model dari data preparation tracer study yang telah disiapkan sebelumnya. Tahap pemodelan ini mengubah persyaratan kebutuhan menjadi desain perangkat lunak yang sesuai dan pembuatan model machine learning sebelum dilakukan proses deployment dalam sistem aplikasi [9]. Gambar 2. Adalah alur sistem aplikasi yang dibangun.



Gambar 2. Alur Aplikasi Penilaian Tingkat Kepuasan Alumni

Proses pelatihan ini didahului dengan preprocessing data, seleksi fitur dan splitting dataset untuk training data dan testing data. Data latih akan digunakan untuk melatih model K-Means dan SVM. Proses pelatihan model akan selesai apabila sudah memenuhi kriteria

evaluasi model, selanjutnya sistem akan melakukan pengukuran tingkat kepuasan alumni dari data uji. Pemodelan pada tahap kluster data dengan algoritma k-means, ditunjukkan pada Gambar 3.



Gambar 3. Flowchart Klusterisasi dengan Algoritma K-Means

Pemilihan jumlah kluster optimal dilakukan untuk mendapatkan nilai k terbaik dalam proses klusterisasi tracer studi. Teknik untuk menentukan jumlah kluster optimal menggunakan Elbow method. Metode ini menentukan jumlah kluster optimal dengan mencari perbedaan terbesar dalam penurunan Sum of Square Error (SSE) dan membentuk siku pada grafik [10]. SSE merupakan total kesalahan Pada penelitian ini model kernel yang digunakan adalah kernel linier, merupakan pengklasifikasian data yang memisahkan data menggunakan garis linear. Misalnya diketahui $x_i = \{x_1, \dots, x_n\}$ merupakan titik pada dataset, dan $y_i = y \in \{+1, -1\}$ merupakan class pada data x_i . Bidang pemisah optimal, mampu memisahkan semua data yang sesuai dengan kelasnya dan memiliki margin terbesar. Bidang pemisah pertama mengelompokkan kelas pertama, sementara bidang pemisah kedua mengelompokkan kelas kedua, dengan persamaan 2 dan 3.

$$(w \cdot x_i + b) \geq +1 \text{ untuk } y_i = +1 \text{ (1).....(2)}$$

$$(w \cdot x_i + b) \geq -1 \text{ untuk } y_i = -1 \text{.....(3)}$$

kuadrat antara semua titik data dalam sebuah kluster (C_j) dengan pusat kluster (centroid) P_j .

$$SSE = \sum_{j=1}^K \sum_{x_i \in C_j} \|x_i - p_j\|^2 \text{(1)}$$

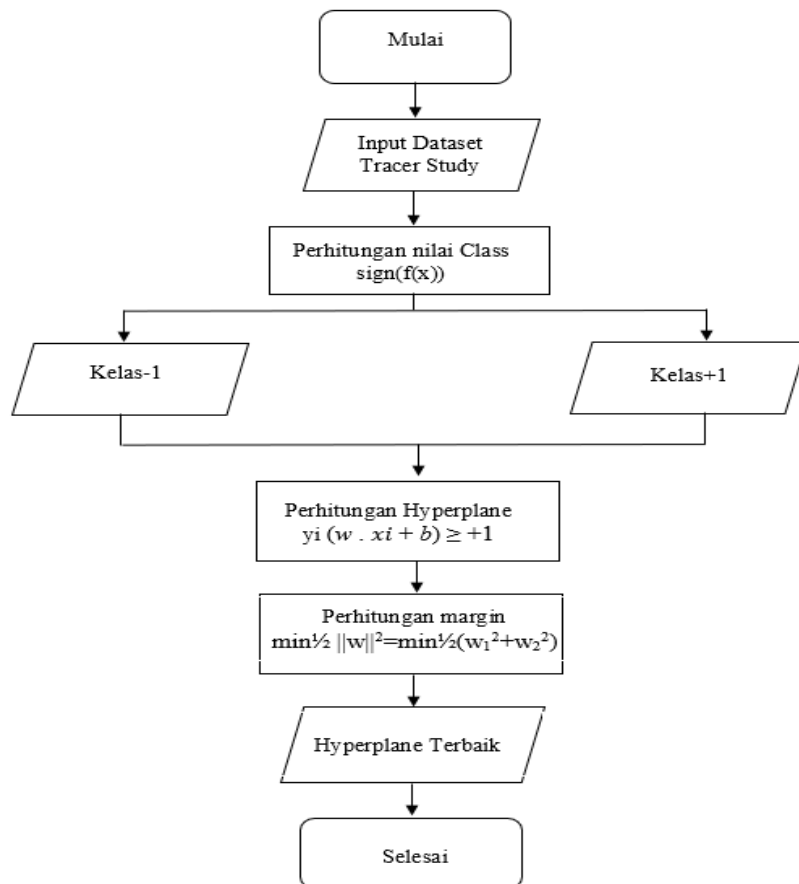
Pemodelan klasifikasi dengan SVM, Proses ini mengubah dataset menjadi prediksi akhir dalam bentuk klasifikasi ke dalam kelas-kelas tertentu. Proses ini dimulai dengan perhitungan kernel.

Variabel w adalah bidang normal yang terletak di antara bidang pemisah dan pusat koordinat, sedangkan variabel b menentukan posisi relatif bidang terhadap pusat koordinat. Untuk menemukan margin terbesar, jarak antara hiperplane dan titik terdekat diperbesar dengan memaksimalkan fungsi $1/\|w\|$ atau dengan meminimumkan $\|w\|^2$. Sementara untuk hyperplane kedua kelas dengan persamaan 4.

$$y_i (w \cdot x_i + b) \geq 1, i = 1, 2, \dots, n \text{(4)}$$

Persamaan 4 dapat diformulasikan sebagai Quadratic Programming yang mencari titik minimum. Hyperplane optimal dengan margin terbesar direpresentasikan sebagai masalah optimisasi dengan persamaan 5 [1].

$$Min = 1/2 \|w\|^2 \text{(5)}$$



Gambar 4. Flowchart Algoritma SVM Penilaian Tingkat Kepuasan Alumni

Implementasi antarmuka menggunakan bahasa Python dengan front end berbasis website. Antar muka aplikasi penilaian tingkat kepuasan alumni menggunakan metode *Support Vector Machine* terdapat komponen kriteria penilaian

tingkat kepuasan alumni yang terdiri dari satu halaman inputan sistem. Tahap awal membuat variabel cluster yang akan mengelompokkan tingkat kepuasan lulusan yang mencakup tren dari riwayat pekerjaan dan kompetensi lulusan.



Gambar 5. Aplikasi Penilaian Tingkat Kepuasan Alumni

2.4 Tahap Evaluation


Evaluasi memiliki fungsi untuk menguji validitas sistem. Sistem dianggap efektif dan valid apabila error yang dihasilkan kecil [11]. Oleh karena itu, penting untuk melakukan pengujian pada sistem. Beberapa skenario pengujian yang akan dilakukan pada sistem menggunakan teknik K-Fold Cross Validation. Pada skenario pengujian, k yang digunakan adalah 5 fold, di mana tiap fold terdiri dari 40 data. Dari 40 data tersebut, akan dibagi lagi menjadi data training (80%) dan data testing (20%). Tiap fold memiliki 33 data training dan 7 data testing. Evaluasi dilakukan menggunakan Confusion Matrix untuk mengukur akurasi, presisi, recall, dan f1-score

3. HASIL DAN PEMBAHASAN

3.1 Klusterisasi Data


Data sebelum di kluster, dilakukan scalling dengan teknik min-max normalisasi. Teknik penskalaan dengan nilai-nilai digeser dan diubah skalanya sehingga nilainya berkisar antara 0 dan 1 atau rentang [0,1]. Klusterisasi data digunakan untuk membuat variabel cluster yang akan mengelompokkan tingkat kepuasan lulusan. Pertama, membuat 'cluster tracer

studi yang akan mencakup tren dari riwayat pekerjaan dan kompetensi lulusan. Tahap awal adalah dengan menentukan jumlah kluster optimal dengan menggunakan algoritma elbow.



Gambar 6. Algoritma Elbow Penentu Kluster Optimal

Berdasarkan algoritma elbow diperoleh jumlah kluster optimal pada data tracer study adalah 5 dari nilai SSE pada perubahan nilai WCSS (Within Cluster Sum Square) secara signifikan. Tahap berikutnya klusterisasi, teknik kluster menggunakan K-Means, Nilai kluster optimal 5 digunakan untuk membagi data kedalam 5 kelompok data.



Gambar 7. Klusterisasi dengan K-Means

Data-data yang telah mendapat posisi clusternya masing-masing kemudian diberi label. Untuk data di cluster 5 diberi label sangat puas, cluster 4 puas, cluster 3 cukup puas, cluster 2 kurang puas dan cluster 1 sangat tidak puas. Pemberian label ini berdasarkan data yang diinput oleh para alumni. Setelah data memiliki labelnya masing-masing diterapkan proses klasifikasi. Metode klasifikasi yang digunakan adalah Support Vector Machine (SVM) kernel linear. Kernel linear memiliki tuning parameter terbaik dari pengujian tuning parameter pada kernel RBF dan Polynomial. Algoritma SVM menentukan hyperplane optimal dengan memilih bidang dengan margin terbaik, sehingga kemampuan generalisasi SVM dapat dijaga secara otomatis. Tingkat generalisasi SVM tidak bergantung pada jumlah data latih. Dengan menyesuaikan parameter soft margin, noise dapat dikendalikan, sehingga semakin besar parameter soft margin, semakin besar pula penalti yang dikenakan pada kesalahan klasifikasi, serta proses pelatihan menjadi lebih ketat. Contoh perhitungan SVM ini akan diambil 10 data secara acak dari 200 data dan 6 fitur dari 87 fitur data, berikut ini.

1. Data Training

Proses training SVM terdapat 5 level yang mewakili proses tiap kelas dengan jumlah data training yang berbeda. Setiap kelas yang akan dieksekusi pada tiap level akan disimbolkan dengan angka 1, yang menandakan kelas tersebut adalah kelas positif. Untuk kelas lainnya akan dilambangkan dengan -1 yang artinya kelas negatif. Data training dari setiap level akan dijelaskan lebih detail pada penjabaran berikut.

a) Pada perhitungan SVM level 1, data yang akan dieksekusi adalah data yang ada pada kelas 1 yaitu kelas sangat puas. Data yang

dieksekusi akan diberi nilai pada kelas sistem = 1 (kelas positif) dan data selain dari kelas sangat puas akan diberi nilai kelas sistem = -1 (kelas negatif).

Tabel 1: Data Training SVM Level 1

NIM	Label	F1	F2	F3	F4	F5	F6	Kelas Sistem
120612068	Puas	1	0	1	0	1	1	-1
120612040	Sangat Puas	1	1	1	1	0	0	1
100612039	Tidak Puas	0	1	1	1	0	1	-1
100612035	Puas	1	1	1	0	0	1	-1
120612021	Sangat Puas	1	1	1	1	0	1	1
100612090	Kurang Puas	0	0	1	1	0	0	-1
100612110	Kurang Puas	1	0	0	1	0	1	-1
120612275	Puas	1	1	0	0	1	1	-1
120612099	Puas	1	0	0	1	1	1	-1
110612160	Kurang Puas	1	1	1	0	0	1	-1

b) Pada saat masuk ke proses data training level 2, data dengan kelas sangat puas tidak akan diproses lagi. Pada kasus ini hanya akan memproses data selain dari kelas sangat puas. Sehingga untuk data training level 2, kelas sistem positif (1) akan dialihkan kepada kelas puas.

Tabel 2: Data Training SVM Level 2

NIM	Label	F1	F2	F3	F4	F5	F6	Kelas Sistem
120612068	Puas	1	0	1	0	1	1	1
100612039	Tidak Puas	0	1	1	1	0	1	-1
100612035	Puas	1	1	1	0	0	1	1
100612090	Kurang Puas	0	0	1	1	0	0	-1
100612110	Kurang Puas	1	0	0	1	0	1	-1
120612275	Puas	1	1	0	0	1	1	1
120612099	Puas	1	0	0	1	1	1	1
110612160	Kurang Puas	1	1	1	0	0	1	-1

c) Selanjutnya ketika telah memasuki proses training level 3, artinya data dengan kelas

sangat puas dan puas tidak akan diproses lagi sehingga hanya akan ada 4 data yang mewakili kurang puas dan kelas tidak puas yang akan diproses. Pada training SVM level 2, kelas sistem positif (1) adalah kelas puas yang artinya mengeksekusi nilai training pada kelas puas. Sehingga untuk data training level 3, kelas puas dihilangkan dan selanjutnya yang menjadi kelas sistem positif (1) adalah kelas kurang puas.

Tabel 3. Data Training SVM Level 3

NIM	Label	F1	F2	F3	F4	F5	F6	Kelas Sistem
100612039	Tidak Puas	0	1	1	1	0	1	-1
100612090	Kurang Puas	0	0	1	1	0	0	1
100612110	Kurang Puas	1	0	0	1	0	1	1
110612160	Kurang Puas	1	1	1	0	0	1	1

d) Pada training SVM level 3, kelas sistem positif (1) adalah kelas kurang puas yang artinya mengeksekusi nilai training pada kelas kurang puas. Sehingga untuk data training level 4, kelas kurang puas dihilangkan dan selanjutnya yang menjadi kelas sistem positif (1) adalah kelas tidak puas.

Tabel 4. Data Training SVM Level 4

NIM	Label	F1	F2	F3	F4	F5	F6	Kelas Sistem
100612039	Tidak Puas	0	1	1	1	0	1	1

2. Proses Perhitungan Kernel SVM Data Training

Proses perhitungan kernel SVM yang akan diterapkan pada kasus ini adalah kernel RBF, linier dan Polynomial. inisialisasi awal parameter SVM sebagai berikut:

λ	σ	α_{awal}	$complexity(c)$	cLR	ϵ	$Itermax$
0,5	1	0	1	0,01	0,0001	2

Berdasarkan analisis hasil perhitungan kernel RBF, kernel Linear dan kernel Polynomial, maka dapat diketahui bahwa:

- Nilai perhitungan kernel Linier adalah yang terbaik karena menghasilkan nilai numerik paling sedikit dibandingkan kernel lainnya.
- Pada proses perhitungan SVM selanjutnya akan digunakan hasil perhitungan dari kernel Linier.

Hasil pemodelan sistem berdasarkan evaluasi model dengan confusion matrix sebagai berikut:

- Accuracy menjelaskan ukuran yang mengindikasikan seberapa tepat model dalam melakukan klasifikasi secara benar. sebesar 90%

- Precision menjelaskan metrik yang menunjukkan seberapa tepat model dalam mengklasifikasikan data yang diminta sesuai dengan hasil prediksi yang diberikan sebesar 85%
- Recall menjelaskan ukuran yang menggambarkan seberapa berhasil model dalam mengidentifikasi kembali sebuah informasi yang relevan sebesar 83%
- F-1 Score merupakan metrik yang menggambarkan perbandingan rata-rata bobot antara precision dan recall sebesar 0,79%

Accuracy pilihan tepat untuk mengukur performa algoritma ketika jumlah data false negatif dan false positif pada dataset hampir sama (simetris). Namun, jika perbedaannya signifikan, lebih baik menggunakan F1 Score sebagai penanda performa yang lebih baik.

4. KESIMPULAN

Analisis dan pemodelan sistem dapat dilakukan pengembangan aplikasinya dengan metode machine learning pengukur tingkat kepuasan alumni berdasarkan data tracer study program studi. Hasil evaluasi yang dilakukan bahwa model SVM memberikan akurasi sebesar 0,90, recall sebesar 0,83, precision sebesar 0,85 dan F1-score sebesar 0,79 dalam mengukur tingkat kepuasan alumni terhadap proses akademik di perguruan tinggi dengan bidang pekerjaan di industri.

PERNYATAAN PENGHARGAAN

Penulis mengucapkan terimakasih kepada Lembaga Penelitian dan Pengabdian pada Masyarakat (LPPM) Universitas Udayana atas dana hibah penelitian yang diberikan serta Program Studi Informatika Fakultas MIPA Universitas Udayana atas kerjasama dan ijin melaksanakan penelitian.

DAFTAR PUSTAKA

- R. Akbar and M. Akbar, "E- Tracer Study Based on Expert Systems (A Case Study At Amik Indonesia)," *EPH - International Journal of Science And Engineering*, vol. 5, no. 2, pp. 13–18, Jun. 2019
- I. Sintiani, L. Fitriani, and R. Kurniawati, "Pengembangan Aplikasi Tracer Study STT-Garut," vol. 14. No. 1, pp. 118-124, 2017.
- V. B. Siahaan, D. Aqwam, and R. Kardian, "Penerapan Algoritma K-Means Untuk

- Analisis Tracer Alumni Universitas Gunadarma Jurusan Sistem Informasi dan Sistem Komputer Angkatan 2013,” *Jurnal Ilmiah KOMPUTASI.*, vol. 18 No. 3, pp. 215-228. 2019.
- [4] R. Chandra and S. Ruhama, “Pengembangan Sistem E-Tracer Study pada Perguruan Tinggi,” *Konferensi Nasional Sistem Informasi 2014, STMIK Dipanegara Makassar*, 27 Pebruari – 1 Maret 2014.
- [5] D. I. Purnama, R. L. Islami, L. Sari, and P. R. Sihombing, “Analisis Klasifikasi Data Tracer Study Dengan Support Vector Machine Dan Neural Network,” *Jurnal Sistem Komputer dan Kecerdasan Buatan*, vol. 4, No. 2, pp. 46–52, 2021.
- [6] W. Supriana, M. A. Raharja, I. Made, and S. Bimantara, “Pengembangan Sistem Prediksi Bantuan Program Keluarga Harapan (PKH) Berbasis Machine Learning,” vol. 6 No.1, pp. 1-11, 2023.
- [7] I. P. Dedy, W. Darmawan, G. Aditra Pradnyana, I. Bagus, and N. Pascima, “Optimasi Parameter Support Vector Machine Dengan Algoritma Genetika Untuk Analisis Sentimen Pada Media Sosial Instagram,” vol.6 No.1, pp. 58-67, 2023.
- [8] N. W. S. Saraswati, I. K. A. Bisena, I. D. M. K. Muku, G. G. E. Krisna, “Recognizing Hotel Visitors Preferences Based on Service Consumption Level Using K-Means Method”, vol. 6 No.3, pp. 173-181, 2023.
- [9] M. A. Sapaat, A. Mustapha, J. Ahmad, K. Chamili, and R. Muhamad, “A Classification-Based Graduates Employability Model for Tracer Study by MOHE,” *International Journal on New Computer Architectures and Their Applications (IJNCAA)*, vol.1 No.4, pp. 1086-1098, 2011.
- [10] A. H. Setianingrum, “Model Pemetaan Evaluasi Penilaian Kualifikasi Lulusan Berbasis Metode Fuzzy C Means Clustering,” *Jurnal Teknik Informatika*, vol.7 No. 2, pp. 8-15, 2014.
- [11] Y. Darmi, A. Setiawan, “Penerapan Metode Clustering K-Means Dalam Pengelompokan Penjualan Produk,” *Jurnal Media Infotama*, vol. 12 No. 2, pp. 148-157, 2016.