

## Metode Rough Set dan SVM untuk Penilaian Kinerja Kepegawaian serta Rekomendasi Jabatan

Rafika Sani<sup>✉</sup>, Sarjon Defit, Gunadi W. Nurcahyo

Fakultas Ilmu Komputer, Universitas Putra Indonesia YPTK Padang, 25221, Indonesia

[rafikasani2509@gmail.com](mailto:rafikasani2509@gmail.com)

### Abstract

Data Mining is a crucial technique for processing large and complex datasets to find hidden patterns that support strategic decisions. This study aims to apply Data Mining techniques with a focus on the Rough Set and Support Vector Machine (SVM) methods to improve employee performance assessments and provide job promotion recommendations. The Rough Set method is used to select attributes from employee performance evaluation data, covering seven main attributes such as work experience, education, age, type of position, class group, work results, and work behavior. The dataset used comes from the performance evaluation report of 8,457 employees at the Padang City Human Resources Development and Personnel Agency (BKPSDM). The results of the study showed that the Rough Set and Support Vector Machine (SVM) methods managed to achieve an accuracy level of 99.62%. Testing based on the results of the confusion matrix showed that the "very good" class with a precision value of 1,000, recall 0.952, and F-Measure 0.975; the "good" class precision 0.996, recall 1,000, and F-Measure 0.998; and the "very poor" class showed precision 0.990, recall 0.987, and F-Measure 0.988. Based on these results, this assessment can help management in making better promotion decisions. This research will also contribute to improving the performance assessment process and job recommendations in the organization.

Keywords: Data Mining, Rough Set, Support Vector Machine, Performance Appraisal, Position Recommendation

### Abstrak

Data Mining adalah teknik krusial untuk mengolah dataset besar dan kompleks guna menemukan pola tersembunyi yang mendukung keputusan strategis. Penelitian ini bertujuan untuk penerapan teknik Data Mining dengan fokus pada metode Rough Set dan Support Vector Machine (SVM) untuk meningkatkan penilaian kinerja pegawai dan memberikan rekomendasi promosi jabatan. Metode Rough Set digunakan untuk melakukan seleksi atribut dari data evaluasi kinerja pegawai, mencakup tujuh atribut utama seperti pengalaman kerja, pendidikan, usia, jenis jabatan, golongan ruang, hasil kerja, dan perilaku kerja. Dataset yang digunakan berasal dari laporan evaluasi kinerja 8.457 pegawai di Badan Kepegawaian dan Pengembangan Sumber Daya Manusia (BKPSDM) Kota Padang. Hasil penelitian menunjukkan bahwa metode Rough Set dan Support Vector Machine (SVM) berhasil mencapai tingkat akurasi sebesar 99,62%. Pengujian berdasarkan hasil confusion matrix menunjukkan, kelas "sangat baik" dengan nilai precision 1,000, recall 0,952, dan F-Measure 0,975; kelas "baik" precision 0,996, recall 1,000, dan F-Measure 0,998; serta kelas "sangat kurang" menunjukkan precision 0,990, recall 0,987, dan F-Measure 0,988. Berdasarkan hasil tersebut maka penilaian ini dapat membantu manajemen dalam membuat keputusan promosi yang lebih baik. Penelitian ini nantinya juga memberikan kontribusi dalam memperbaiki proses penilaian kinerja dan rekomendasi jabatan dalam organisasi.

Keywords: Data Mining, Rough Set, Support Vector Machine, Penilaian Kinerja, Rekomendasi Jabatan.

*KomtekInfo is licensed under a Creative Commons Attribution-Share Alike 4.0 International License.*



### 1. Pendahuluan

Knowledge Discovery in Database adalah keseluruhan proses non-trivial untuk mencari dan mengidentifikasi pola (Pattern) dalam data, di mana polayang ditemukan bersifat sah, baru dapat bermanfaat dan dapat dimengerti. Knowledge discovery in Database (KKD) didefinisikan sebagai ekstraksi informasi potensial, implisit, dan tidak dikenal dari sekumpulan data. Proses Knowledge discovery melibatkan hasil dari proses Data Mining (proses mengekstrak kecenderungan pola suatu data), kemudian mengubah hasilnya secara akurat menjadi informasi yang mudah dipahami. Data Mining merupakan bagian dari proses KKD (Knowledge Discovery in Databases)

yang terdiri dari beberapa tahapan seperti pemilihan data, pra pengolahan, transformasi, Data Mining, dan evaluasi hasil [1],[2].

Dalam era perkembangan teknologi yang pesat, penerapan metode kecerdasan buatan (Artificial Intelligence) semakin meluas dalam berbagai aspek, termasuk dalam domain bisnis dan manajemen sumber daya manusia. Pemanfaatan teknologi ini bukan hanya untuk mempercepat proses, tetapi juga untuk meningkatkan akurasi dan efisiensi pengambilan keputusan. Terutama dalam evaluasi kinerja tenaga kerja, kecerdasan buatan memiliki potensi besar untuk meningkatkan strategi pengembangan dan investasi sumber daya manusia di lingkungan perusahaan [3]. Pada suatu instansi, dibutuhkan pegawai yang mampu

melaksanakan pekerjaan sesuai dengan tujuan dalam mencapai suatu target [4]. Keseimbangan ini adalah kunci perusahaan untuk mampu berkembang menjadi perusahaan yang profitabel. Kemajuan usaha dan organisasi perusahaan sangatlah bergantung pada produktivitas pekerja yang ada di perusahaan [5].

Proses evaluasi prestasi kerja menjadi titik kritis yang memerlukan perubahan dan peningkatan efisiensi guna memastikan pengembangan optimal dari sumber daya manusia. Penilaian yang tidak efisien dan kurang objektif dapat menyebabkan ketidakpuasan karyawan, ketidaksetaraan peluang promosi, dan akhirnya berdampak pada kualitas kinerja perusahaan. Rekomendasi posisi bagi karyawan bukan hanya langkah formalitas, melainkan memiliki dampak signifikan terhadap motivasi dan dedikasi karyawan. Peluang untuk promosi sesuai dengan prestasi kerja bukan hanya menjadi motivasi bagi karyawan untuk berkembang, tetapi juga menciptakan lingkungan kerja yang dinamis dan berfokus pada prestasi [6].

Kebutuhan akan sistem yang mampu memberikan rekomendasi posisi yang akurat dan adil menjadi semakin mendesak. Ketidakpastian dan kompleksitas data prestasi kerja menjadi hambatan utama dalam pengembangan sistem evaluasi yang efektif. Metode tradisional seringkali kesulitan mengatasi variasi dalam penilaian kualitatif dan kuantitatif. Oleh karena itu, diperlukan pendekatan yang adaptif dan canggih untuk mengelola data tersebut, menjadikan teknologi kecerdasan buatan sebagai solusi yang menjanjikan [7].

Penelitian sebelumnya dilakukan oleh Das et al, menggunakan Rough Set Theory (RST) dan SVM untuk menganalisis data iklim terkait gelombang panas di India. RST mengidentifikasi gelombang panas sebagai faktor utama risiko lingkungan, sementara SVM digunakan untuk memprediksi kejadian gelombang panas di masa depan. Hasil penelitian menunjukkan bahwa model SVM memiliki akurasi 87% dalam memprediksi kejadian gelombang panas. Selain itu, analisis menunjukkan bahwa kurangnya ruang hijau berkontribusi secara signifikan sebesar 78% terhadap peningkatan risiko gelombang panas. Temuan ini memberikan wawasan berharga untuk strategi mitigasi risiko lingkungan dan perencanaan urban yang lebih baik [8].

Adapun penelitian lain yang dilakukan oleh Zhao et al, dalam penelitian ini memperkenalkan metode prediksi emisi karbon dari pembakaran batu bara dengan mengintegrasikan Rough Set Theory, Grey GM model, dan SVM. Metode ini menunjukkan kesalahan prediksi maksimum hanya 0,08% dan waktu prediksi yang lebih cepat dibandingkan metode lain saat mengelola data besar, memperlihatkan efisiensi dan akurasi dalam prediksi emisi karbon [9]. Penelitian yang dilakukan oleh Mohammed Akif et al, dalam penelitian ini membahas penggunaan Machine Learning dalam Sistem Deteksi Intrusi (IDS) di Cloud Computing.

Penelitian ini menggabungkan berbagai algoritma Machine Learning seperti SVM dengan teknik clustering tak terbimbing. Hasilnya menunjukkan bahwa metode ini dapat meningkatkan akurasi deteksi intrusi dan mengurangi false positif, terutama dalam mendeteksi serangan DoS dan R2L [10].

Penelitian berikutnya yang dilakukan oleh Yu et al, penelitian ini mengoptimalkan diagnosis embolisme paru (PE) pada pasien dengan penyakit paru obstruktif kronis (AECOPD) menggunakan model gabungan Fuzzy Rough Sets (FRS) dan SVM. Model ini menunjukkan akurasi rata-rata 94,67% dan area di bawah kurva (AUC) 0,944, melebihi model regresi logistik, sehingga meningkatkan probabilitas prediksi PE dan mendukung pengambilan keputusan klinis [11]. Penelitian mengenai Rough set dan SVM juga dilakukan oleh Bhagat et al, dalam penelitian ini mengusulkan metode menggunakan teori Rough Set untuk memprediksi nilai hilang dalam dataset dan menerapkan SVM untuk klasifikasi. Algoritma Iteratif digunakan untuk mengidentifikasi kelas ekuivalen dan membangkitkan aturan keputusan. Validasi pada dataset medis ginjal kronis menunjukkan akurasi 82,1% dan skor F1 82,6%, mengungguli metode SVM langsung pada data hilang [12].

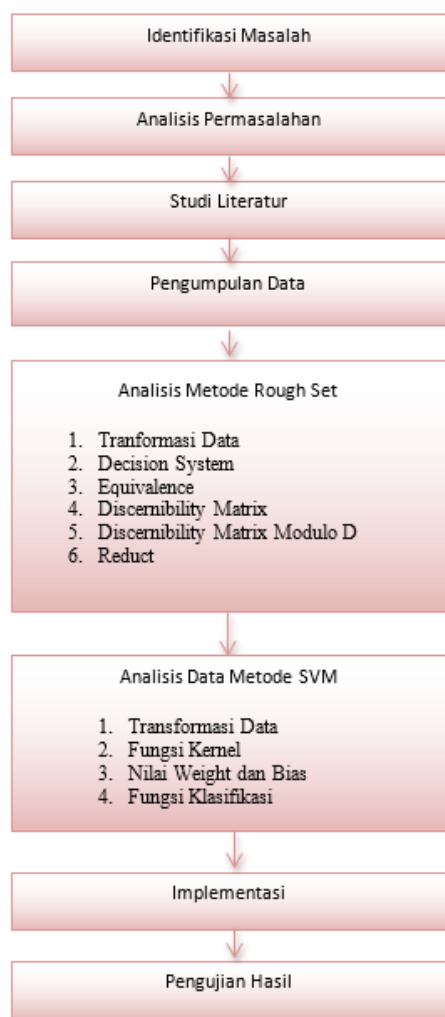
Memanfaatkan keunggulan masing-masing metode, penelitian ini bertujuan memberikan kontribusi dalam pengembangan sistem evaluasi prestasi kerja yang lebih efisien dan objektif di lingkungan perusahaan. Integrasi Rough Set dan SVM diharapkan dapat membuka peluang baru dalam meningkatkan efektivitas proses evaluasi prestasi kerja, menciptakan dasar yang kokoh untuk pengembangan kebijakan sumber daya manusia yang lebih tepat dan berkelanjutan. Penelitian ini berbeda dengan penelitian sebelumnya yang umumnya fokus pada aplikasi metode tersebut dalam bidang diagnosis medis, deteksi gangguan teknis, atau analisis lingkungan. Pembaruan dalam penelitian ini terletak pada penerapannya dalam konteks evaluasi kinerja pegawai dan rekomendasi kenaikan jabatan, yang belum banyak dieksplorasi sebelumnya. Selain itu, penelitian ini juga menawarkan pendekatan yang lebih komprehensif dengan mengombinasikan kedua metode untuk mengatasi kompleksitas data kinerja, memberikan solusi yang lebih adaptif dan akurat dalam penilaian prestasi kerja di sektor kepegawaian.

Berdasarkan latar belakang yang telah diuraikan, penulis merumuskan beberapa permasalahan utama untuk penelitian ini: pertama, bagaimana metode Rough Set dapat diterapkan untuk menyeleksi atribut yang relevan dalam penilaian prestasi kerja tenaga kepegawaian; kedua, bagaimana metode SVM dapat digunakan untuk memberikan rekomendasi kenaikan jabatan berdasarkan atribut-atribut yang telah diseleksi oleh metode Rough Set; dan ketiga, bagaimana penggabungan metode Rough Set dan SVM dapat meningkatkan akurasi serta efektivitas dalam penilaian prestasi kerja tenaga kepegawaian. Tujuan dari

penelitian ini adalah untuk menerapkan metode Rough Set dalam menyeleksi atribut yang relevan, menggunakan metode SVM untuk memberikan rekomendasi kenaikan jabatan, menganalisis efektivitas penggabungan kedua metode tersebut, serta menguji kehandalan dan keakuratan model yang dihasilkan dalam konteks penilaian prestasi kerja tenaga kepegawaian.

## 2. Metodologi Penelitian

Metode penelitian berfungsi sebagai panduan yang sistematis dalam melaksanakan setiap tahapan penelitian agar tujuan yang diinginkan tercapai dengan baik. Dalam penelitian ini, kerangka kerja yang digunakan dirancang untuk mengevaluasi kinerja tenaga kepegawaian dengan tujuan memberikan rekomendasi jabatan yang tepat. Tahapan-tahapan yang dilalui dalam penelitian ini dapat dilihat pada Gambar 1, yang menggambarkan proses penilaian hingga pemberian rekomendasi berdasarkan kinerja pegawai.



Gambar 1. Bagan Alir Penelitian

### 1.1 Identifikasi Masalah

Langkah awal dalam penelitian ini dimulai dengan mengidentifikasi berbagai permasalahan yang dihadapi

dalam penilaian prestasi kerja pegawai. Permasalahan seperti ketidakcocokan antara hasil penilaian dan rekomendasi jabatan sering kali muncul, yang dapat berdampak pada keputusan yang tidak tepat dalam promosi jabatan. Selain itu, ketidakobjektifan dalam proses penilaian serta kurangnya akurasi dalam evaluasi kinerja juga menjadi tantangan utama yang perlu diatasi, dan hal ini diidentifikasi melalui observasi langsung, wawancara dengan pihak terkait, serta analisis dokumen yang relevan.

### 1.2 Analisis Permasalahan

Setelah masalah-masalah dalam penilaian prestasi kerja teridentifikasi, langkah selanjutnya adalah melakukan analisis mendalam untuk memahami penyebab utamanya. Alat seperti analisis SWOT digunakan untuk mengevaluasi kekuatan, kelemahan, peluang, dan ancaman yang terkait dengan sistem penilaian yang ada. Selain itu, metode root cause analysis diterapkan untuk menemukan akar penyebab dari kelemahan-kelemahan dalam sistem, sehingga solusi yang diambil dapat lebih efektif dan tepat sasaran.

### 1.3 Studi Literatur

Penelitian ini juga melibatkan tinjauan literatur yang mendalam terkait dengan penilaian prestasi kerja untuk memahami konsep dan pendekatan yang telah digunakan sebelumnya. Selain itu, peninjauan literatur tentang penggunaan metode Rough Set dan SVM dilakukan untuk memperoleh landasan teoritis yang kuat serta memahami bagaimana metode-metode tersebut telah diterapkan dalam penelitian-penelitian terdahulu. Dengan demikian, kerangka penelitian ini didasarkan pada pemahaman yang komprehensif terhadap teori dan praktik yang relevan.

### 1.4 Pengumpulan Data

Tahap berikutnya melibatkan pengumpulan data kinerja pegawai beserta atribut-atribut terkait yang diperoleh dari sumber internal organisasi. Proses ini dilakukan dengan cermat untuk memastikan bahwa data yang dikumpulkan akurat dan dapat diandalkan, sehingga analisis yang dilakukan nantinya menghasilkan rekomendasi yang valid. Selain itu, metode pengumpulan data didokumentasikan dengan baik untuk menjamin transparansi dan memungkinkan replikasi dalam penelitian lebih lanjut.

### 1.5 Analisis Data

Data yang telah dikumpulkan kemudian dianalisis menggunakan metode Rough Set untuk menyeleksi fitur-fitur yang paling relevan dalam penilaian kinerja pegawai. Fitur-fitur yang terpilih ini selanjutnya digunakan sebagai input untuk metode SVM, yang bertujuan membangun model rekomendasi jabatan yang akurat. Kombinasi kedua metode ini memungkinkan pengambilan keputusan yang lebih tepat berdasarkan data kinerja pegawai yang ada.

### 2.2 Metode Rough Set

Tahapan dalam metode Rough Set meliputi transformasi data, pembentukan decision system, dan pengelompokan data ke dalam equivalence class berdasarkan kesamaan atribut kondisi. Selanjutnya, dilakukan analisis dengan menggunakan discernibility matrix dan discernibility matrix modulo D untuk mengidentifikasi perbedaan antara objek-objek dalam kelas yang berbeda. Akhirnya, reduct ditentukan sebagai subset minimal dari atribut yang tetap mempertahankan kemampuan diskriminatif untuk membuat model atau aturan keputusan.

a. Transformasi Data

Transformasi data dilakukan untuk memudahkan pengolahan dengan mengonversi nilai-nilai data ke dalam rentang skala 1-6. Langkah ini memastikan bahwa data menjadi lebih seragam dan konsisten, sehingga dapat mendukung analisis lebih lanjut dengan hasil yang lebih akurat. Transformasi ini membantu dalam menyederhanakan kompleksitas data asli, membuatnya lebih mudah dianalisis menggunakan metode yang telah direncanakan.

b. Decision System

Decision System adalah suatu sistem informasi yang dilengkapi dengan atribut tambahan yang disebut sebagai Decision Attribute, yang berfungsi untuk menentukan hasil keputusan. Dalam konteks Data Mining, Decision Attribute ini sering dikenal dengan istilah kelas atau target, yang menjadi fokus utama dalam proses klasifikasi atau prediksi. Atribut ini menghubungkan data input dengan output yang diinginkan, sehingga memungkinkan pembentukan model yang dapat digunakan untuk pengambilan keputusan berbasis data.

c. Equivalence

Equivalence Class adalah konsep penting dalam analisis Rough Set yang digunakan untuk mengelompokkan objek-objek dalam dataset berdasarkan kesamaan nilai atribut tertentu. Dengan mengelompokkan objek-objek yang memiliki nilai atribut yang sama ke dalam kelas yang sama, proses ini memudahkan dalam identifikasi pola dan hubungan antara data. Kelas ekuivalen ini menjadi dasar untuk analisis lebih lanjut dalam menentukan perbedaan dan hubungan antara objek dalam dataset.

d. Discernibility Matrix

Setelah melakukan klasifikasi menggunakan Equivalence Class, langkah berikutnya dalam menganalisis data penilaian pegawai di Kantor BKPSDM Kota Padang, Sumatera Barat adalah proses pembuatan Discernibility Matrix. Untuk menghitung Discernibility Matrix, perlu mengacu pada equivalence class yang telah ditentukan, dan proses ini melibatkan klasifikasi atribut yang berbeda untuk mengidentifikasi perbedaan antara objek-objek dalam kelas yang berbeda. Discernibility Matrix ini membantu dalam

menentukan atribut mana yang paling signifikan dalam membedakan kelas-kelas keputusan, sehingga memungkinkan penyederhanaan dan pembuatan aturan yang lebih efektif.

e. Discernibility Matrix Modulo D

Discernibility Matrix Modulo D dapat didefinisikan sebagai sekumpulan atribut yang berbeda, termasuk atribut keputusan (D), yang digunakan untuk mengidentifikasi dan membedakan antara objek-objek dalam dataset. Matrix ini berfungsi untuk memisahkan objek-objek berdasarkan atribut yang relevan, serta membantu dalam penyaringan informasi penting yang mempengaruhi keputusan dalam analisis data. Dengan cara ini, Discernibility Matrix Modulo D memungkinkan penekanan pada atribut yang paling signifikan untuk membuat keputusan yang lebih akurat.

f. Reduct

Setelah menyelesaikan proses Discernibility Matrix Modulo D, langkah berikutnya adalah menghasilkan proses Reduct menggunakan aljabar Boolean. Proses Reduct bertujuan untuk menemukan subset minimal dari atribut yang masih dapat membedakan antara kelas-kelas keputusan dalam dataset. Dengan menggunakan aljabar Boolean, atribut-atribut yang dianggap tidak relevan dapat disaring, sehingga hanya atribut-atribut yang paling signifikan untuk klasifikasi dan pengambilan keputusan yang tersisa dalam model.

2.3 Metode SVM

Pada Support Vector Machine (SVM), langkah-langkah utama meliputi transformasi data, pencarian fungsi kernel, dan pencarian nilai weight serta bias. Pertama, data mentah ditransformasi untuk memastikan keseragaman fitur, kemudian fungsi kernel dipilih untuk mengubah data ke dalam ruang dimensi yang lebih tinggi untuk pemisahan yang lebih baik. Terakhir, nilai weight dan bias dioptimalkan untuk memaksimalkan margin antar kelas, dan fungsi klasifikasi dibangun untuk mengklasifikasikan data baru berdasarkan model yang telah dilatih.

a. Transformasi Data

Transformasi data dilakukan untuk memudahkan pengolahan dengan mengubah data ke dalam rentang nilai tertentu, sehingga data menjadi lebih seragam dan konsisten. Langkah ini memastikan bahwa semua fitur berada dalam skala yang sama, yang membantu dalam proses analisis lebih lanjut dan meningkatkan akurasi model. Dengan transformasi yang tepat, data dapat lebih mudah dikelola dan diolah dalam berbagai metode analisis, termasuk SVM.

$$X_n = (0,8*(\chi-a))/(b-a) + 0,1 \quad (1)$$

Dimana:

- $X_n$  : Nilai ke-n
- a : Nilai angka terendah
- b : Nilai angka tertinggi

0,8 dan 0,1 : Ketetapan

Data yang diberikan berupa pasangan  $(\chi_1, y_1), \dots, (\chi_m, y_m) \in \chi \times \{+1, -1\}$ . Kumpulan pasangan tersebut merupakan data pembelajaran Support Vector Machine. Berbekal pengalaman pembelajaran menggunakan data pembelajaran tersebut, Support Vector Machine harus mampu menentukan pola (generalisasi) dari  $\chi \in \mathbb{Z}^n$  [13].

#### b. Fungsi Kernel

Fungsi kernel bertujuan untuk mengubah data ke ruang dimensi lebih tinggi untuk memungkinkan pemisahan linear, dengan tipe kernel seperti Polinomial. Fungsi  $K(X, X_1)$  menghitung kesamaan antara dua titik data, dan untuk mendapatkan nilai kernel penuh  $(N \times N)$ , diperlukan penentuan variabel klasifikasi. perhitungan nilai matrik K dapat dilakukan dengan menggunakan Persamaan 2.

$$K(\chi, \chi_i) = \phi(\chi_i) \quad (2)$$

Hyperlane tersebut dapat dibuat secara tunggal sesuai dengan  $w$  dan  $b$  yang akan diperoleh. Selanjutnya  $\chi_i$  yang berupa sub himpunan data pembelajaran yang terletak pada margin disebut dengan Support Vector. Untuk mencari nilai matrik K menggunakan persamaan 2 [14].

#### c. Nilai Weight

Nilai weight dalam SVM digunakan untuk menentukan arah dan kekuatan margin pemisah, yang memandu posisi hyperplane dalam ruang fitur. Pencarian nilai weight dilakukan dengan memecahkan persamaan optimisasi yang ditentukan dalam Persamaan 3, yang bertujuan untuk memaksimalkan margin antara kelas-kelas yang berbeda. Dengan nilai weight yang optimal, hyperplane dapat diposisikan sedemikian rupa sehingga memisahkan kelas-kelas data dengan margin maksimum.

$$w = \sum_{i=1}^n \alpha_i y_i K(\chi, \chi_i) \quad (3)$$

#### d. Bias

Nilai bias merupakan nilai konstanta yang menggeser hyperplane untuk menyesuaikan posisi pemisah sesuai dengan distribusi data. Untuk mencari nilai bias menggunakan Persamaan 4.

$$b = -\frac{1}{2} (w \cdot \chi_- + w \cdot \chi_+) \quad (4)$$

Persamaan hyperplane  $\langle w, x \rangle + b = 0$ , terlebih dahulu harus diketahui nilai  $w$  dan  $b$ . Nilai  $w$  ini berkaitan langsung dengan margin yang memisahkan kelas-kelas data dalam SVM. Dengan mengetahui nilai  $w$  dan  $b$ , kita dapat menentukan posisi hyperplane yang optimal untuk memisahkan data secara akurat. (He, *et al.*, 2022).

#### e. Fungsi Klasifikasi

Fungsi klasifikasi dilakukan dengan menggunakan model SVM untuk mengidentifikasi kelas atau kategori data berdasarkan posisi data dalam ruang fitur yang

dipisahkan oleh hyperplane. Fungsi ini memanfaatkan weight dan bias untuk menentukan prediksi kelas dari data baru. Proses penentuan kelas dapat dilakukan dengan menggunakan Persamaan 5

$$F(\phi(\chi)) = \text{sign}(w \cdot \phi(\chi) + b) \\ = \text{sign}(\sum_{i=1}^n \alpha_i y_i \phi(\chi_i)^T \cdot \phi(\chi) + b) \quad (5)$$

Dimana:

$w$  : nilai weight  
 $x$  : nilai variabel input  
 $b$  : nilai bias

Masalah dasar Support Vector Machine adalah menentukan suatu hyperlane ke masing-masing kelas data. Selanjutnya, hyperlane ini akan menjadi fungsi keputusan  $f(x)$  untuk masalah klasifikasi diatas. Berikut persamaan untuk mencari nilai fungsi keputusan  $f(x)$  [15].

#### 1.6 Implementasi

Hasil dari analisis kemudian diimplementasikan ke dalam sistem atau model yang telah dirancang, memastikan bahwa temuan analisis diterapkan secara efektif untuk mencapai tujuan yang diinginkan. Proses ini melibatkan integrasi hasil analisis dengan sistem operasional untuk memastikan bahwa keputusan dan rekomendasi yang dihasilkan dapat diterapkan secara praktis. Dengan implementasi yang tepat, sistem atau model dapat memberikan manfaat yang optimal sesuai dengan tujuan penelitian atau proyek.


#### 1.7 Pengujian Hasil

Melakukan pengujian model menggunakan data uji melibatkan beberapa tahapan kunci. Pertama, data disiapkan dan diproses untuk memastikan kualitas dan konsistensi. Selanjutnya, seleksi fitur dilakukan menggunakan metode ROSETTA untuk menentukan fitur-fitur yang relevan. Proses dilanjutkan dengan penerapan model SVM untuk memberikan rekomendasi jabatan. Hasil prediksi kemudian dievaluasi untuk mengukur kinerja model, diikuti dengan analisis kekuatan dan kelemahan model. Berdasarkan hasil evaluasi ini, model dapat disempurnakan untuk meningkatkan akurasi dan efektivitasnya.

### 3. Hasil dan Pembahasan

#### 3.1 Tahap Analisa Dan Perancangan

Pada tahap analisa dan perancangan, metode Rough Set dan SVM diterapkan untuk memberikan rekomendasi jabatan dalam penilaian prestasi kerja pegawai. Proses dimulai dengan pemahaman data, pemilihan fitur relevan menggunakan Rough Set, dan dilanjutkan dengan implementasi SVM untuk menghasilkan rekomendasi jabatan dengan menggunakan bagan alir yang disajikan pada Gambar 2.



Gambar 2. Bagan Alir Analisa Dan Perancangan

Dalam penelitian ini, penting untuk memahami alur sistematis yang akan digunakan untuk menganalisis dan merancang model penilaian kinerja pegawai. Proses ini melibatkan beberapa tahapan krusial yang dimaksudkan untuk memastikan data diolah secara efektif dan hasil yang diperoleh relevan serta akurat. Penjelasan bagan alir tahapan analisis dan perancangan berikut memberikan gambaran jelas mengenai langkah-langkah yang akan diambil untuk mencapai tujuan penelitian secara optimal.

- a. Data sampel sebanyak 26 pegawai akan diolah menggunakan metode Rough Set untuk menseleksi fitur-fitur relevan seperti pendidikan, pengalaman kerja, jenis jabatan, usia, golongan ruang (golru),

hasil kerja, perilaku kerja, dan hasil akhir penilaian SKP. Proses ini melibatkan pengkodean, normalisasi, dan pembersihan data.

- b. Setelah seleksi fitur, data yang telah diproses akan dianalisis menggunakan SVM untuk mengevaluasi kinerja pegawai dan memberikan rekomendasi jabatan yang sesuai, dengan tujuan untuk menghasilkan penilaian kinerja yang akurat dan objektif.

### 3.2 Mempersiapkan Data

Penelitian ini menggunakan data laporan penilaian sasaran kinerja pegawai (SKP) tahun 2023 dari instansi pemerintahan Kota Padang, Sumatera Barat. Data ini mencakup 8.457 pegawai dengan 30 kolom variabel. Sebanyak 26 data pegawai akan dipilih sebagai sampel untuk proses analisis. Data akan diproses melalui pengkodean, normalisasi, dan pembersihan untuk memastikan kualitas data sebelum diterapkan metode Rough Set dan SVM. Data lengkap dapat dilihat pada Tabel 1.

Tabel 1. laporan penilaian sasaran kinerja pegawai (SKP) tahunan tahun 2023

No	Jenis	Id	NIP	.....	Hasil Akhir
1	22	A8ACA7C4C8243912E040	19660122XXXX11100	...	sangat baik
2	31	A8ACA7C9E1D83912	1978 XXXX 011007	...	sangat baik
3	31	A8ACA770FEB03912	19880 XXXX 011002	...	sangat baik
4	31	A8ACA7EACC3D391	197812 XXXX 011003	...	sangat baik
5	41	A8ACA7CCE4CE39	197708 XXXX 012002	...	sangat baik
6	41	7E2C0FACADF6B6DDE	19891 XXXX 021001	...	sangat baik
7	41	A8ACA7CF399F39	19790 XXXX 07011006	...	sangat baik
8	41	A8ACA7A371903912E0	1983 XXXX 010011008	...	sangat baik
...	...	.....	...	...	...
8465	99	A8ACA7D9A1DF391	198909 XXXX 0122006	...	sangat baik

Laporan penilaian SKP (Sasaran Kinerja Pegawai) adalah dokumen yang mencatat dan mengevaluasi pencapaian kinerja seorang pegawai berdasarkan target yang telah ditetapkan dalam periode tertentu, biasanya satu tahun. Laporan ini mencakup berbagai aspek seperti hasil kerja, perilaku, serta kontribusi pegawai terhadap organisasi, yang kemudian digunakan untuk menilai kinerja secara keseluruhan dan memberikan rekomendasi terkait pengembangan karier atau jabatan. SKP bertujuan untuk memastikan bahwa kinerja pegawai selaras dengan tujuan dan kebutuhan organisasi.

proses pengolahan data terdiri dari empat tahap utama: transformasi data untuk memastikan keseragaman, pembentukan decision system untuk menghubungkan atribut kondisi dengan keputusan, pengelompokan data ke dalam equivalence class, dan perhitungan discernibility matrix serta reduct untuk menentukan atribut yang relevan. Tahap-tahap ini memastikan bahwa data dianalisis secara menyeluruh dan efisien untuk menghasilkan hasil yang akurat dan berguna.

### 3.3 Analisa Data Metode Rough Set

Tabel 1, atribut yang dapat ditransformasikan meliputi pendidikan, pengalaman kerja, jenis jabatan, usia, golongan ruang (golru), hasil kerja, perilaku kerja, dan hasil akhir penilaian SKP. Dalam metode Rough Set,

- a. Transformasi Data

Transformasi data dilakukan dengan mengubah nilai menjadi rentang skala dari 1-6 untuk memudahkan sistem dalam mengolah data. Dengan skala yang konsisten, data menjadi lebih seragam dan siap untuk analisis lebih lanjut. Data yang telah ditransformasi dapat dilihat pada Tabel 2.

Tabel 2. Data Transformasi

Pengalaman_Kerja	Pendidikan	Usia	Jenis_Jabatan	.....	Perilaku_Kerja
5	4	5	2	.....	2
4	3	4	2	.....	2
3	3	3	2	.....	2
3	4	4	2	.....	2
3	0	4	2	.....	2
1	2	2	2	.....	2
4	3	3	2	.....	2
3	2	3	2	.....	2
6	3	4	1	.....	2
6	4	5	2	.....	2
2	3	4	2	.....	2
3	4	3	2	.....	2
3	3	3	2	.....	2
4	3	3	2	.....	2
6	4	4	1	.....	2
3	3	3	2	.....	2
3	3	4	2	.....	1
2	3	5	2	.....	1
1	3	2	2	.....	1
3	3	3	2	.....	1
2	3	5	2	.....	1
1	3	2	2	.....	1
4	3	5	1	.....	1
3	3	3	2	.....	1
1	3	3	2	.....	1
3	3	2	2	.....	1

Data tersebut ditransformasikan melalui proses pengkodean, normalisasi, dan pembersihan sehingga siap untuk analisis lebih lanjut. Setelah data ditransformasikan, metode Rough Set akan digunakan untuk menseleksi fitur yang paling relevan. Atribut yang dapat ditransformasikan terdiri dari: Pengalaman kerja, pendidikan, usia, golru, jenis jabatan, hasil kerja, hasil perilaku, dan hasil akhir.

b. Decision System

Decision System adalah suatu sistem informasi yang dilengkapi dengan atribut tambahan yang disebut Decision Attribute, yang dalam Data Mining dikenal sebagai kelas atau target. Decision Attribute ini berfungsi untuk menentukan hasil keputusan atau klasifikasi dalam analisis data. Tabel 3 merupakan tabel Decision System yang menunjukkan atribut-atribut terkait serta Decision Attribute yang digunakan dalam proses klasifikasi tersaji pada Tabel 3.

Tabel 3. Decision Sytem

Nama	Pengalaman_Kerja	Pendidikan	Golru	...	Hasil Akhir
Arnaldi	5	4	4	.....	sangat baik
Alfitri Hamda	4	3	3	.....	sangat baik
Andika	3	3	3	.....	sangat baik
Hafez Assaf	3	4	3	.....	sangat baik
Yurniati	3	0	2	.....	sangat baik
Febri Frishtianto	1	2	2	.....	sangat baik
Andi Irawan	4	3	2	.....	sangat baik
Anasrul Amir	3	2	3	.....	sangat baik
Eva Yanti	6	3	3	.....	sangat baik
Alfitri	6	4	4	.....	sangat baik
Marzuki	2	3	3	.....	sangat baik
Dian Fitri	3	4	3	.....	sangat baik
Andi Purmada Year	3	3	3	.....	sangat baik
Fachry Indra	4	3	3	.....	sangat baik
Elvira	6	4	4	.....	sangat baik
Misrayenti	3	3	3	.....	Sangat baik
Betti Miswati	3	3	3	.....	Baik

Rajablis	2	3	3	....	Baik
Rani Oktaviani	1	3	3	....	Baik
Wiwid Sagita	3	3	3	....	Baik
Nelti	2	3	3	....	Baik
Mayfaliona Mastuti	1	3	3	....	Baik
Agus Rindo	4	3	4	....	Baik

Pada decision system terdiri 1 atau lebih atribut kondisi dan 1 atribut keputusan. Dimana atribut kondisinya: terdiri dari 8 kolom atau atribut, dan 1 atribut keputusan. Dapat dilihat pada Tabel 3 di atas.

Equivalence Class adalah pengelompokan objek-objek yang memiliki nilai yang sama pada atribut tertentu. Berdasarkan Tabel 3, terdapat 26 data penilaian pegawai yang diproses, menghasilkan 16 Equivalence Class, yaitu Class 1 hingga Class 16. Masing-masing kelas ini memiliki atribut kondisi yang berbeda, seperti yang ditunjukkan dalam tabel.

c. Equivalence

Tabel 4. Equivalence

	A	B	C	D	E	F	G	H
Class1	4	3	3	2	3	2	2	2
Class2	3	3	4	2	3	2	2	2
Class3	4	3	4	2	3	2	2	2
Class4	3	3	3	2	3	2	2	2
Class5	1	3	2	2	3	1	1	1
Class6	3	3	3	2	3	1	1	1
Class7	1	3	2	2	3	2	2	2
Class8	6	4	4	1	4	2	2	2
Class9	3	3	5	2	3	2	2	2
Class10	6	3	5	2	4	2	2	2
Class11	3	4	3	2	3	2	2	2
Class12	4	3	5	2	4	2	2	2
Class13	1	3	4	2	3	2	2	2
Class14	3	3	2	2	3	1	1	1
Class15	4	3	5	1	4	1	1	1
Class16	3	3	2	2	3	1	1	1

Pada tahap Equivalence, kita mengelompokkan atribut kondisi dan keputusan yang memiliki nilai yang sama ke dalam satu kelas. Proses ini memungkinkan kita untuk menyederhanakan data dengan mengelompokkan objek-objek yang serupa menjadi kelas-kelas yang konsisten. Hal ini memudahkan analisis lebih lanjut dan pemodelan, dengan fokus pada perbedaan antar kelas daripada perbedaan antar objek individu.

Proses perhitungan Discernibility Matrix dilakukan untuk klasifikasi menggunakan Equivalence Class, langkah selanjutnya dalam menganalisa data penilaian pegawai yang ada pada Kantor BKPSDM Kota Padang, Sumatera Barat salah satunya dengan proses Discernibility Matrix. Proses menghitung Discernibility Matrix, mengacu pada Tabel 4, untuk menghasilkan Discernibility Matrix-nya dapat dilakukan dengan cara mengklasifikasikan atribut yang berbeda. Hasil Discernibility Matrix dapat dilihat pada Tabel 5.

d. Discernibility Matrix

Tabel 5. Discernibility Matrix

	Class1	Class2	Class3	Class4	...	Class16
Class1	X	A,C	C	A	...	A,C,F,G
Class2	A,C	X	A	C	...	C,FG
Class3	C	A	X	A,C	...	A,C,F,G
Class4	A	C	A,C	X	...	F,G
Class5	A,C,F,G	A,C,F,G	A,C,F,G	A,C,F,G	...	A,F,G
Class6	A,F,G	C,F,G	A,C,F,G	F,G	...	C
Class7	A,C	A,C	A,C	A,C	...	A,F,G
Class8	A,B,C,D,E	A,B,C,D,E	A,B,C,D,E	A,B,C,D,E	...	A,B,C,E,F,G
Class9	A,C	C	A,C	C	...	C,F,G
Class10	A,C,E	A,C,E	A,C,E	A,C,E	...	A,C,E,F,G
Class11	A,B	B,C	A,B,C	B	...	B,C,F,G
Class12	A,C,E	A,C,E	A,C,E	A,C,E	...	A,C,E,F,G
Class13	A,E	A	A	A,C	...	A,C,F,G

Class14	A,C,F,G	C,F,G	A,C,F,G	C,F,G	...	C
Class15	C,D,E,F,G	A,C,D,E,F,G	C,D,E,F,G	A,B,C,D,E,F,G	...	A,C,D,E
Class16	A,C,F,G	C,F,G	A,C,F,G	F,G	...	X

Pada proses Equivalence Class, terdapat 16 kelas yang diidentifikasi, sementara pada Discernibility Matrix, kita juga memiliki 16 kolom kelas dan 16 kelas data. Pada tahap ini, atribut kondisi yang berbeda dipilih untuk digabungkan dalam satu kelas, memungkinkan identifikasi perbedaan antara kelas-kelas dan penyederhanaan proses analisis. Penggunaan Discernibility Matrix membantu dalam menentukan atribut mana yang relevan untuk membedakan antara kelas-kelas yang ada.

e. Discernibility Matrix Modulo D

Discernibility Matrix Modulo D dapat didefinisikan sebagai sekumpulan atribut yang berbeda termasuk juga atribut keputusan (D). Berdasarkan Tabel 4, maka Discernibility Matrix Modulo D yang dihasilkan dapat dilihat pada Tabel 6.

Tabel 6. Discernibility Matrix Modulo D

	Class1	Class2	Class3	Class4	...	Class16
Class1	X	X	X	X	...	A,C,F,G
Class2	X	X	X	X	...	C,F,G
Class3	X	X	X	X	...	A,C,F,G
Class4	X	X	X	X	...	C,F,G
Class5	A,C,F,G	A,C,F,G	A,C,F,G	A,C,F,G	...	X
Class6	A,F,G	C,F,G	A,F,G	F,G	...	X
Class7	X	X	X	X	...	A,F,G
Class8	X	X	X	X	...	A,B,C,D,E,F,G
Class9	X	X	X	X	...	C,F,G
Class10	X	X	X	X	...	A,C,E,F,G
Class11	X	X	X	X	...	B,C,F,G
Class12	X	X	X	X	...	A,C,E,F,G
Class13	X	X	X	X	...	A,C,F,G
Class14	A,C,F,G	C,F,G	A,C,F,G	F,G	...	X
Class15	C,D,E,F,G	A,C,D,E,F,G	C,D,E,F,G	A,C,D,E,F,G	...	X
Class16	A,C,F,G	C,F,G	A,C,F,G	C,F,G	...	X

Discernibility Matrix Modulo D digunakan untuk mengidentifikasi dan mengelompokkan atribut kondisi serta atribut keputusan yang berbeda ke dalam satu kelas. Proses ini membantu dalam menyaring atribut-atribut yang memiliki pengaruh signifikan terhadap keputusan, sehingga hanya atribut yang relevan yang dipertimbangkan dalam analisis lebih lanjut. Dengan mengelompokkan atribut yang berbeda dalam satu kelas, kita dapat fokus pada perbedaan yang benar-benar penting untuk meningkatkan akurasi model keputusan.

7.	[B]
8.	[D]
9.	[C, F, G]
10.	[A, C, E, F, G]
11.	[D, F, G]
12.	[A, C, F, G]
13.	[C, D, E, F, G]
14.	[A, B, C, D, E, F, G]
15.	[A, F, G]

f. Reduct

Setelah melakukan proses Discernibility Matrix Modulo D, langkah selanjutnya dengan menghasilkan proses Reduct dengan menggunakan Aljabar BOOLEan. Adapun Reduct yang dihasilkan dapat dilihat pada Tabel 7, berikut hasil penyelesaian Reduction:

No	Reduct
1.	[A]
2.	[F]
3.	[G]
4.	[C]
5.	[F, G]
6.	[A, F]

Didapat dari hasil pencarian menggunakan aljabar boolean 15 reduct. Atribut yang paling banyak ada di nomor 14. Atribut tersebut yang terpilih, terdiri dari atribut A hingga G yang akan digunakan untuk proses selanjutnya menggunakan metode SVM.

3.4 Analisa Hasil Metode Rough Set

Berdasarkan perhitungan menggunakan metode rough set, maka di dapat 7 atribut / kolom, di mana kolom yang terpilih yaitu: pengalaman\_kerja, pendidikan, usia, jenis\_jabatan, golru, hasil\_kerja, hasil\_perilaku, yang mana atribut yang di terpilih dapat digunakan pada metode svm untuk menghasilkan rekomendasi jabatan.

3.5 Analisa Data Metode SVM

Sebelum memasuki pembahasan mengenai penerapan metode Support Vector Machine (SVM), penting untuk memahami tahapan-tahapan yang harus dilalui dalam pengolahan data menggunakan metode ini. SVM merupakan salah satu teknik yang efektif dalam klasifikasi data, terutama ketika dihadapkan pada data yang kompleks dan berukuran besar. Oleh karena itu, penerapan SVM dalam penelitian ini dilakukan melalui empat langkah utama yang akan dijelaskan sebagai berikut:

- a. Menentukan variabel yang akan digunakan.
- b. Melakukan proses tranformasi data sesuai dengan format Support Vector Machine (SVM).
- c. Menentukan fungsi kernel yang ditentukan dalam hal ini tipe kernel yang dapat digunakan adalah tipe kernel plynomial.
- d. Mencari nilai weight dan bias sesuai format Support Vector Machine (SVM).

Untuk mendapatkan pemahaman yang mendalam tentang proses SVM, perhitungan manual berikut ini dapat memberikan gambaran yang lebih jelas. Langkah-langkah perhitungan ini akan membantu menjelaskan bagaimana SVM bekerja dalam mengklasifikasikan data secara akurat. Dengan mempelajari perhitungan manual ini, diharapkan pembaca dapat mengikuti dan mengaplikasikan metode SVM secara lebih efektif.

a. Transformasi Data

Untuk tranformasi data dari X1(pengalaman kerja), X2(pendidikan), X3(usia), X4(Jabatan), X5(golru), X6(hasil kerja), dan X7(hasil perilaku), dapat menggunakan rumus (3.1), berikut merupakan hasil transformasi yang sudah dilakukan dapat dilihat pada Tabel 8.

Tabel 8. Transformasi Nilai

X1	X2	X3	X4	X5	X6	X7
0.74	0.90	0.90	0.90	0.90	0.90	0.90
0.58	0.70	0.70	0.90	0.60	0.90	0.90
0.42	0.70	0.40	0.90	0.60	0.90	0.90
0.42	0.90	0.70	0.90	0.60	0.90	0.90
0.42	0.10	0.70	0.90	0.30	0.90	0.90
0.10	0.50	0.10	0.90	0.30	0.90	0.90
0.58	0.70	0.40	0.90	0.30	0.90	0.90
0.42	0.50	0.40	0.90	0.60	0.90	0.90
0.90	0.70	0.70	0.10	0.60	0.90	0.90
0.90	0.90	0.90	0.90	0.90	0.90	0.90
0.26	0.70	0.70	0.90	0.60	0.90	0.90
0.42	0.90	0.40	0.90	0.60	0.90	0.90
0.42	0.70	0.40	0.90	0.60	0.90	0.90
0.58	0.70	0.40	0.90	0.60	0.90	0.90
0.90	0.90	0.70	0.10	0.90	0.90	0.90
0.42	0.70	0.40	0.90	0.60	0.90	0.90
0.42	0.70	0.70	0.90	0.60	0.50	0.50
0.26	0.70	0.90	0.90	0.60	0.50	0.50
0.10	0.70	0.10	0.90	0.60	0.50	0.50
0.42	0.70	0.40	0.90	0.60	0.50	0.50
0.26	0.70	0.90	0.90	0.60	0.50	0.50
0.10	0.70	0.10	0.90	0.60	0.50	0.50
0.58	0.70	0.90	0.10	0.90	0.50	0.50
0.42	0.70	0.40	0.90	0.60	0.50	0.50
0.10	0.70	0.40	0.90	0.60	0.50	0.50
0.42	0.70	0.40	0.90	0.60	0.50	0.50

Berikut merupakan nilai yang sudah ditransformasikan menggunakan rumus persamaan nomor (1). Atribut yang digunakan ditransformasikan menjadi X1 hingga X7. Berada pada rentan nilai tertentu agar memudahkan dalam proses perhitungan.

b. Fungsi Kernel

Menghitung nilai kernel tujuannya untuk mentransformasikan data ke dalam ruang dimensi yang

lebih tinggi. Kernel digunakan untuk mengubah data yang dapat dipisahkan secara linear diruang dimensi yang lebih tinggi. Fungsi K (X, X1) menghitung kesamaan antara dua titik data diruang dimensi tinggi. Dalam hal ini tipe kernel yang dapat digunakan adalah tipe kernel Plynomial. Untuk mencari nilai kernel K di sini penuh (N\*N), terlebih dahulu kita haris menentukan variabel-variabel yang dibutuhkan dalam proses klasifikasi. Variabel yang dibutuhkan dapat dilihat pada Tabel 9 dan Tabel 10.

Tabel 9. Data Testing

X1	X2	X3	X4	X5	X6	X7	Label
----	----	----	----	----	----	----	-------

0.26	0.70	0.90	0.90	0.60	0.50	0.50	+1
0.10	0.70	0.10	0.90	0.60	0.50	0.50	-1
0.42	0.70	0.40	0.90	0.60	0.50	0.50	+1

Tabel 10. Data Training

X1	X2	X3	X4	X5	X6	X7	Label
0.74	0.90	0.90	0.90	0.90	0.90	0.90	+1
0.58	0.70	0.70	0.90	0.60	0.90	0.90	+1
0.42	0.70	0.40	0.90	0.60	0.90	0.90	+1
0.42	0.90	0.70	0.90	0.60	0.90	0.90	+1
0.42	0.10	0.70	0.90	0.30	0.90	0.90	+1
0.10	0.50	0.10	0.90	0.30	0.90	0.90	+1
0.58	0.70	0.40	0.90	0.30	0.90	0.90	+1
0.42	0.50	0.40	0.90	0.60	0.90	0.90	+1
0.90	0.70	0.70	0.10	0.60	0.90	0.90	+1
0.90	0.90	0.90	0.90	0.90	0.90	0.90	+1
0.26	0.70	0.70	0.90	0.60	0.90	0.90	+1
0.42	0.90	0.40	0.90	0.60	0.90	0.90	+1
0.42	0.70	0.40	0.90	0.60	0.90	0.90	+1
0.58	0.70	0.40	0.90	0.60	0.90	0.90	+1
0.90	0.90	0.70	0.10	0.90	0.90	0.90	+1
0.42	0.70	0.40	0.90	0.60	0.90	0.90	+1
0.42	0.70	0.70	0.90	0.60	0.50	0.50	+1
0.26	0.70	0.90	0.90	0.60	0.50	0.50	+1
0.10	0.70	0.10	0.90	0.60	0.50	0.50	-1
0.58	0.70	0.90	0.10	0.90	0.50	0.50	+1
0.42	0.70	0.40	0.90	0.60	0.50	0.50	+1
0.10	0.70	0.40	0.90	0.60	0.50	0.50	+1
0.42	0.70	0.40	0.90	0.60	0.50	0.50	+1

Berdasarkan data testing pada Tabel 9, langkah pertama adalah memasukkan variabel-variabel yang diperlukan, yaitu X1, X2, dan X3, ke dalam persamaan. Setelah itu, semua variabel tersebut dikalikan satu sama lain untuk membentuk matriks kernel K, sesuai dengan persamaan (2). Dari proses ini, didapatkan matriks kernel K seperti yang ditunjukkan berikut ini:

$$K = \begin{bmatrix} 16.30221 & 10.73218 & 13.17109 \\ 10.73218 & 10.1124 & 10.51056 \\ 13.17109 & 10.51056 & 1222481 \end{bmatrix}$$

c. Nilai Weight Dan Bias

Nilai weight dihitung menggunakan persamaan (3.3), dan beberapa nilai penting diperlukan untuk mendapatkan hasil yang akurat. Proses perhitungan ini melibatkan pengambilan data dari hasil klasifikasi sebelumnya untuk menentukan vektor weight (w) yang optimal. Berikut adalah nilai-nilai yang dibutuhkan untuk menghitung nilai w:

Nilai K = [16.30221, 10.73218, 13.17109, 10.73218, 10.1124, 10.51056, 13.17109, 10.51056, 1222481]

Nilai Alpha: [1 = 0.5, -1 = 0.3, 1 = 0.2]

kemudian lakukan untuk seluruh data sehingga didapatkan nilai weight (w), menggunakan persamaan (3). Berikut nilai (w) yang didapat:

$$w = \begin{pmatrix} 7.565669 \\ 4.434482 \\ 5.877339 \end{pmatrix}$$

Setelah didapatkan nilai w, selanjutnya pilih salah satu Support Vector dari kelas "+1" dan "-1" dari matrik yang mempunyai nilai (+) dan (-). Pada penelitian ini diambil dari kolom pertama dan kolom ke 2 pada tabel 9 untuk menghitung nilai b dengan menggunakan persamaan (4) sebagai berikut:

$$b = -\frac{1}{2} * [ \begin{matrix} \text{Nilai X1} + \text{X2} * w \\ 16.30221 & 10.73218 & 7.565669 \\ 10.73218 & 10.1124 & 4.434482 \\ 13.17109 & 10.51056 & 5.877339 \end{matrix} ]$$

d. Fungsi Klasifikasi

Hasil rekomendasi kelas yang di dapat menggunakan persamaan nomor (3.5), dari sign dari hasil fungsi klasifikasi apabila hasilnya lebih dari (>) 0 maka masuk kelas 1 dan apabila hasilnya kurang dari (<) 0 maka masuk kelas -1. Untuk data testing di atas masuk ke kelas -1 yang artinya masuk ke dalam kategori tidak cocok direkomendasikan. Untuk hasil data testing lainnya dapat dilihat pada Tabel 11.

Tabel 11. Hasil Rekomendasi

No.	X1	X2	X3	X4	X5	X6	X7	Label	Hasil Rekomendasi
1.	0.26	0.70	0.90	0.90	0.60	0.50	0.50	+1	-1
2.	0.10	0.70	0.10	0.90	0.60	0.50	0.50	-1	-1
3.	0.42	0.70	0.40	0.90	0.60	0.50	0.50	+1	-1

### 3.6 Analisa Hasil Metode SVM

Berdasarkan hasil pengolahan menggunakan metode svm dapat dianalisa pegawai nomor 1 dengan nilai terdiri dari kolom X1-X7 diberi label -1 lalu hasil tidak direkomendasikan, yang artinya pegawai dengan nomor 1, nomor 2 dan 3 tidak direkomendasikan untuk naik jabatan karena memerlukan perbaikan.

### 4. Kesimpulan

Berdasarkan analisa menggunakan metode Rough Set dan SVM terhadap data sampel 26 pegawai dari laporan SKP penilaian kinerja, didapatkan 7 atribut utama: pengalaman kerja, pendidikan, usia, jenis jabatan, golru, hasil kerja, dan hasil perilaku. Atribut-atribut ini kemudian digunakan dalam SVM untuk memberikan rekomendasi jabatan. Hasil pengolahan SVM menunjukkan bahwa pegawai dengan nomor 1, 2, dan 3, yang memiliki nilai atribut X1-X7, tidak direkomendasikan untuk naik jabatan, sebagaimana ditunjukkan oleh label dan hasil rekomendasi.

### Daftar Rujukan

- [1] A. Puri, D. Solihudin, S. Anwar, D. Pratama, and E. Wahyudin, "Analisis Klaster K-Medoid Untuk Pengelompokan Dan Pemetaan Provinsi Di Indonesia Berdasarkan Nilai Ujian Nasional," *JATI (Jurnal Mhs. Tek. Inform.,* vol. 8, no. 1, pp. 918–924, 2024, doi: 10.36040/jati.v8i1.8653.
- [2] S. Głowania, J. Kozak, and P. Juszczuk, "Knowledge Discovery in Databases for a Football Match Result," *Electron.,* vol. 12, no. 12, pp. 1–17, 2023, doi: 10.3390/electronics12122712.
- [3] S. Ashrafi, B. Majidi, E. Akhtarkavan, and S. H. R. Hajiagha, "Efficient Resume-Based Re-Education for Career Recommendation in Rapidly Evolving Job Markets," *IEEE Access,* vol. 11, no. April 2020, pp. 124350–124367, 2023, doi: 10.1109/ACCESS.2023.3329576.
- [4] F. El Khair, S. Defit, and Y. Yuhandri, "Sistem Keputusan dengan Metode Multi Attribute Utility Theory dalam Penilaian Kinerja Pegawai," *J. Inf. dan Teknol.,* vol. 3, pp. 215–220, 2021, doi: 10.37034/jidt.v3i4.155.
- [5] A. Alhidayatullah, A. Sudarma, and M. Khairul Amal, "Efektivitas Pelatihan Kerja Dalam Meningkatkan Prestasi Kerja Karyawan," *Coopetition J. Ilm. Manaj.,* vol. 14, no. 1, pp. 119–130, 2023, doi: 10.32670/coopetition.v14i1.2373.
- [6] L. Falat, T. Michalova, P. Madzik, and K. Marsikova, "Discovering Trends and Journeys in Knowledge-Based Human Resource Management: Big Data Smart Literature Review Based on Machine Learning Approach," *IEEE Access,* vol. 11, no. September, pp. 95567–95583, 2023, doi: 10.1109/ACCESS.2023.3296140.
- [7] E. Devia, "Penerapan Decision Tree Dengan Algoritma C4.5 Untuk Menentukan Rekomendasi Kenaikan Jabatan Karyawan," *J. Inf. Syst.,* vol. 3, no. 1, pp. 28–37, 2023, doi: 10.61488/jis.v3i1.257.
- [8] R. Das, J. Mishra, and P. K. Pattnaik, "Prediction of Heatwave Using Advanced Soft Computing Technique," pp. 1–11, 2023.
- [9] Y. Zhao, Y. Zhou, F. Meng, and H. Qiu, "Research on Carbon Emission Prediction of Coal Combustion in Power Generation Enterprises Based on Rough Set and Grey SVM," *Adv. Transdiscipl. Eng.,* vol. 47, pp. 174–181, 2024, doi: 10.3233/ATDE231187.
- [10] Mohammed Akif, Anuj Nakka, Solanki Prakash, Vijay N, and Dr Suresh Kallam, "Utilizing Machine Learning for Intrusion Detection Systems in the Context of Cloud Computing," *Int. J. Adv. Res. Sci. Commun. Technol.,* pp. 14–21, 2023, doi: 10.48175/ijarsct-11603.
- [11] R. Yu, X. Kong, and Y. Li, "Optimizing the Diagnostic Algorithm for Pulmonary Embolism in Acute COPD Exacerbation Using Fuzzy Rough Sets and Support Vector Machine," *COPD J. Chronic Obstr. Pulm. Dis.,* vol. 20, no. 1, pp. 1–8, 2023, doi: 10.1080/15412555.2022.2139671.
- [12] S. N. Bhagat, P. S. Rath, and A. Mitra, "Coupling of Rough Set Theory and Predictive Power of SVM Towards Mining of Missing Data," *Int. Res. J. Multidiscip. Scope,* vol. 5, no. 2, pp. 732–744, 2024, doi: 10.47857/irjms.2024.v05i02.0631.
- [13] H. He, G. Quan, H. Zhu, W. Li, R. Xing, and Y. Zhao, "Evaluation modeling of highway collapse hazard based on rough set and support vector machine," *Sci. Rep.,* pp. 1–10, 2022, doi: 10.1038/s41598-022-23567-1.
- [14] D. I. Pushpita Anna Octaviani, Yuciana Wilandari, "Penerapan Metode SVM Pada Data Akreditasi Sekolah Dasar Di Kabupaten Magelang," *J. Gaussian,* vol. 3, no. 8, pp. 811–820, 2018.
- [15] B. Santosa and S. Surabaya, "Ide Dasar Support Vector Machine," *Support Vector Mach.,* no. x, pp. 1–19, 1995.