

Pemodelan Klasifikasi Lama Waktu Pencapaian Jabatan Fungsional Lektor Kepala menggunakan Optimizer Parameter *Support Vector Machine*

ANDY SUPRIYADI, MUHAMMAD ASRI SAFI'IE

Sekolah Vokasi, Universitas Sebelas Maret, Surakarta
Email: andy.supriyadi@staff.uns.ac.id

Received 16 Juni 2023 | *Revised* 25 Juli 2023 | *Accepted* 20 Agustus 2023

ABSTRAK

Pemenuhan dosen dengan jabatan fungsional lektor kepala dan guru besar menjadi sangat penting dalam memperoleh akreditasi unggul bagi perguruan tinggi. Salah satu upaya pemenuhan dengan melakukan klasifikasi dosen dari sisi lama waktu pencapaian jabatan fungsional lektor kepala dari lektor pada Universitas Sebelas Maret dibagi menjadi tiga, yaitu cepat, sedang, dan lambat. Variabel yang digunakan dalam klasifikasi antara lain usia, tempat studi, lama studi, international research, sertifikasi dosen, jabatan structural dan bidang ilmu dari staf pengajar. Penelitian ini melakukan klasifikasi menggunakan algoritma Support Vector Machine dengan dataset sejumlah 520 data. K-fold Cross Validation digunakan untuk membagi dataset menjadi data latih dan data uji, dengan $k=5$. Hasil pengujian model diperoleh rata-rata akurasi terbaik menggunakan Support Vector Machine sebesar 86.39% dengan Optimizer Parameter sedangkan rata-rata akurasi Support Vector Machine tanpa parameter sebesar 80.92%.

Kata kunci: *klasifikasi, jabatan fungsional, Support Vector Machine, K-fold Cross Validation*

ABSTRACT

The fulfillment of lectures on achieving associate professor and professor position holds tremendous significance for gaining excellent institution Accreditation Predicate. Sebelas Maret Univesity took measures to achieve this objective by carrying out thorough the classification on the length of achieving associate professor from instructor position and split into 3 grades namely fast, medium and slow. The features used for conducting the classification are age, place of study, the length of the study, the amount of international publication, lecturer certification, lecturer's structural position and field of study. In this study, the Support Vector Machine algorithm was utilized to classify a dataset consisting of 520 data. To ensure reliable results, K-fold Cross Validation was applied to divide the dataset into training and test data, with $k=5$. The evaluation of the model's performance revealed that the Support Vector Machine achieved an impressive average accuracy of 86.39%. In contrast, the average accuracy of the Support Vector Machine to 80.92% without parameters.

Keywords: *classification, associate lectures position, support vector machine, K-fold Cross Validation*

1. PENDAHULUAN

Jabatan fungsional dosen merupakan kedudukan yang menunjukkan tugas dan tanggungjawab seorang dosen dalam melaksanakan tridharma perguruan tinggi. Jabatan fungsional dosen terdiri Asisten Ahli, Lektor, Lektor Kepala dan Guru Besar (**Permenpan No 17 Tahun 2013, 2013**). Salah satu instrument dalam meningkatkan atau meraih akreditasi unggul pada perguruan tinggi adalah pemenuhan jumlah dosen dengan jabatan fungsional lektor kepala dan guru besar (**Universitas Sebelas Maret, 2018**). Dalam proses kenaikan pangkat dan jabatan fungsional paradigmanya kurang terpantau dengan baik, karena dilakukan menurut keaktifan dari dosen tersebut. Akibatnya pimpinan perguruan tinggi kurang mengetahui permasalahan yang dihadapi oleh seorang dosen, mengapa tidak segera memproses usul jabatan fungsional. Mengetahui permasalahan tersebut informasi detail profil dosen menjadi sangat dibutuhkan pimpinan dalam melakukan klasifikasi lama waktu pencapaian jabatan fungsional lektor kepala. Penelitian ini bertujuan untuk memberikan alternatif pengambilan keputusan pimpinan untuk memberikan pembinaan kepada dosen yang mengalami kendala dalam kenaikan jabatan fungsional.

Beberapa penelitian yang berkaitan tentang klasifikasi dan kenaikan jabatan telah diusulkan. Seperti (**Rumpun, dkk, 2022**) melakukan penelitian tentang klasifikasi rumpun jabatan ASN berdasarkan riwayat pelatihan menggunakan *Multiclass Support Vector Machine* dengan 12 kategori jabatan dengan *kernel RBF* dihasilkan akurasi 98,5%. (**Samudra, dkk, 2022**) mengusulkan metode klasifikasi untuk memprediksi komparasi 3 metode algoritma klasifikasi data mining yaitu *naïve bayes*, *k-nearest neighbor* dan *neural network* pada prediksi kenaikan jabatan. Metode evaluasi yang digunakan menggunakan *cross validation* dalam klasifikasi promosi jabatan diperoleh akurasi tertinggi 76,6%, nilai presisi 65,9% dan *recall* sebesar 76,6%. Selanjutnya penelitian tentang pendekatan algoritma SVM untuk menentukan kenaikan gaji diusulkan oleh (**Widi Winjani & Muhamad Fatchan, 2022**) dengan menggunakan dua kelas yaitu kelas layak dan tidak layak untuk mendapatkan kenaikan gaji. Hasil percoba diperoleh akurasi klasifikasi sebesar 97,2%.

Beragam metode dan penelitian telah diusulkan dalam melakukan klasifikasi dengan metode *Support Vector Machine*, antara lain oleh (**Monika & Furqon, 2018**) melakukan penelitian menggunakan metode SVM untuk melakukan klasifikasi penyimpangan pertumbuhan anak-anak dengan 3 kelas antara lain *autism*, *down syndrome* dan *attention deficit* menghasilkan akurasi sebesar 63.11%. (**Sri Wahyuni, 2019**) melakukan klasifikasi dalam memprediksi status perpanjangan kontrak kerja karyawan, sehingga pemberhentian karyawan sudah tersaji secara peringatan dini. Penelitian selanjutnya tentang klasifikasi wajah menggunakan SVM dilakukan oleh (**Rizal, dkk, 2019**) memperoleh akurasi 90%. Penelitian berikutnya membahas tentang klasifikasi kinerja layanan PDAM berdasarkan 3 atribut kelas yaitu jam operasi, rasio operasi dan jumlah karyawan, hasil klasifikasi diperoleh akurasi sebesar 80% (**Sihombing, 2020**). Selanjutnya penelitian yang dilakukan oleh (**Pratama, dkk, 2020**) melakukan penelitian tentang klasifikasi menghitung stok awal dengan stok akhir tahun dalam rangka meminimal penyimpangan data, dengan harapan manajemen stok barang dapat tersaji secara efektif dan efisien. Penelitian menggunakan metode SVM dan KNN dilakukan dalam klasifikasi untuk memprediksi penyakit stroke telah oleh (**Azhar, dkk, 2022**) menghasilkan akurasi klasifikasi sebesar 76.52% SVM dan 72.61% KNN.

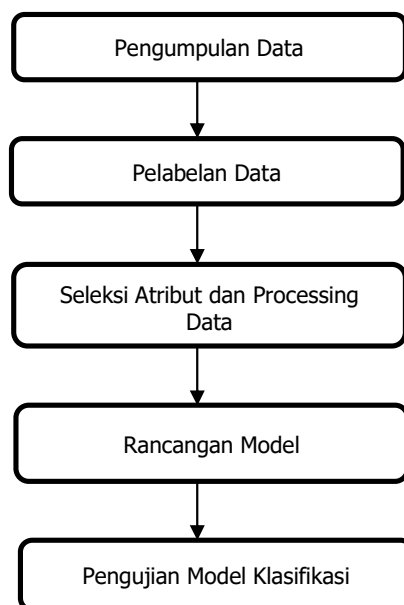
Menurut penelitian yang telah dilakukan, metode SVM digunakan karena mampu memproses klasifikasi dengan baik meskipun hanya memiliki data pelatihan kecil dan dapat menggunakan *kernel* untuk mengatasi data nonlinier. Untuk meningkatkan dan mencari hasil akurasi terbaik pada metode SVM, dilakukan *optimization parameter* dalam melakukan lama waktu

pencapaian jabatan fungsional dengan memanfaatkan data profil dosen antara lain usia, tempat studi, *international research*, sertifikasi dosen, jabatan *structural* dan bidang ilmu dengan melakukan pelabelan kelas dosen menjadi tugas dalam pencapaian jabatan fungsional yaitu kelas cepat, kelas sedang dan kelas lambat.

2. METODE PENELITIAN

2.1 Alur Metodologi Penelitian

Penelitian yang dilakukan merupakan pengembangan dari tugas akhir yang sebelumnya menggunakan metode naïve bayes dan menggunakan dataset dosen pada periode 2018 sampai dengan 2021 (**Supriyadi, 2021**). Pada penelitian ini mengusulkan metode *Support Vector Machine* dalam melakukan klasifikasi lama waktu pencapaian jabatan fungsional lektor kepala seorang dosen dari Jabatan fungsional lektor dengan menggunakan dataset profil dosen yang diperoleh dari bagian Sumber Daya Manusia Universitas Sebelas Maret pada periode 2019 sampai dengan 2022. Atribut atau *variable* yang dipergunakan antara lain usia, tempat studi, *international research*, sertifikasi dosen, jabatan *structural* dan bidang ilmu. Tahap awal dilakukan pengumpulan data yang bersumber dari *databases* sistem informasi kepegawaian Universitas Sebelas Maret dalam format *excel*, selanjutnya dilakukan proses pembersihan atau praprocessing data dan pemberian label pada dataset dilanjutkan *optimizer parameter* dan implementasi metode SVM serta pengujian metode. Adapun alur proses penelitian ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

2.2 Pengumpulan Data

Pada penelitian ini dilakukan proses pengumpulan data profil dosen yang bersumber dari bagian sumber daya manusia Universitas Sebelas Maret yang dipergunakan sebagai dataset. Dataset yang diperoleh berkisar tahun 2018 sampai dengan Desember 2021 diperoleh data sebanyak 520 data.

2.3 Pelabelan Data

Pelabelan data adalah proses pemberian label kelas dataset pada atribut lama pencapaian jabatan fungsional lektor kepala yaitu kelas cepat, kelas sedang dan kelas lambat. Adapun kelas cepat yaitu pencapaian jabatan fungsional lektor kepala kurang atau sama dengan 2 tahun, kemudian pencapaian jabatan lektor kepala pada rentang 4 sampai 9 tahun dimasukkan pada kelas sedang, dan yang terakhir pencapaian jabatan lektor kepala melebihi 9 tahun masuk pada kelas lambat.

2.4 Seleksi Atribut

Tahap selanjutnya pada penelitian melakukan seleksi atribut dengan mencari nilai *information gain* dari atribut pada dataset. Setelah memperoleh nilai *information gain* dilakukan pengurutan *table* atau atribut dari nilai *gain* yang lebih besar ke nilai yang lebih kecil (**Naufal, dkk, 2015**). Tahap ini dilakukan untuk meningkatkan ketepatan akurasi. Adapun atribut yang digunakan dalam penelitian ini ditunjukkan pada Tabel 1:

Tabel 1. Atribut dataset klasifikasi

| No | Atribut | Variabel | Value |
|----|-------------------------------|----------------|-----------|
| 1 | kelas_LK | cepat | 2 s.d 3 |
| | | sedang | 4 s.d 9 |
| | | lambat | >9 |
| 2 | usia | dewasa | 25 s.d 60 |
| | | tua | 61 s.d 79 |
| 3 | tempat studi | DN | 1 |
| | | LN | 2 |
| 4 | lama studi | cepat | 2 s.d 3 |
| | | sedang | 4 s.d 5 |
| | | lambat | >6 |
| 5 | <i>international research</i> | ada | 1 |
| | | tidak_ada | 2 |
| 6 | lolos serdos | cepat | <3 |
| | | sedang | 4 s.d 5 |
| | | lambat | >6 |
| 7 | jabatan_struktural | menjabat | 1 |
| | | tidak_menjabat | 2 |
| 8 | bidang_ilmu | saintek | 1 |
| | | soshum | 2 |
| 9 | jenis kelamin | laki-laki | 1 |
| | | perempuan | 2 |
| 10 | jenjang pendidikan | S2 | 1 |
| | | S3 | 2 |

2.5 Preprocessing Data

Tahapan *preprocessing* data adalah proses pengolahan data yang melalui *cleaning* data sehingga siap dijadikan model penelitian. Tahap ini dimulai membersihkan data-data *missing value* atau tidak lengkap. Selanjutnya dilakukan *integration* data untuk menyesuaikan format yang berbeda, semisal bidang ilmu saintek kita sesuai *value* menjadi 1 dan bidang ilmu soshum kita berikan *value* 2 (**Géron, 2019**).

2.6 Rancangan Model

Pada tahap perancangan model penelitian lama waktu pencapaian jabatan fungsional lektor kepala menggunakan metode *machine learning* yaitu *Support Vector Machine* dengan penambahan *Optimize Parameters*. Metode *Support Vector Machine* berjalan dengan mencari nilai *hyperplane* terbaik atau dengan mengoptimalkan *margin* antara kelas pada dataset (Ahmad, dkk, 2018). Secara matematika fungsi notasi dari *Support Vector Machine* sebagai berikut:

$$f(x) = w^T x + b \quad (1)$$

$$f(x) = \sum_{i=1}^m \alpha_i y_i K(x, x_i) + b \quad (2)$$

Nilai w adalah parameter bobot dari model, nilai x adalah nilai *vector* input dan nilai b adalah nilai bias dari model, kemudian nilai m adalah jumlah *support vector*, variabel α_i merupakan nilai bobot dari titik data, nilai K adalah nilai fungsi *kernel*. Proses awal metode *Support Vector Machine* adalah mencari nilai *support vector* dari setiap kelas yang ada. Penelitian ini menghitung nilai *support vector* dari kelas pencapaian jabatan fungsional lektor kepala secara cepat, sedang dan lambat. Tahap selanjutnya hitung *margin* antara kelas.

Penelitian ini menggunakan model *Support Vector Machine* mempergunakan *kernel linear* dan *Gaussian RBF* dalam menghasilkan nilai *hyperplane* terbaik.

2.7 Pengujian Model dengan *K-fold Cross Validation*

Tahapan evaluasi model dilakukan untuk memperoleh nilai performa atau akurasi terbaik dari model yang diujikan. Pada tahap pengujian menggunakan *k-fold cross validation* dilakukan dengan menggunakan aplikasi *rapidminer 9.1*. Pengujian model dengan menggunakan *k-fold cross validation* pada implementasi setiap data berkesempatan menjadi data latih atau data evaluasi atau validasi sesuai jumlah *fold* atau iterasi (FUADAH, dkk, 2022). Hasil evaluasi yang diperoleh berupa nilai *confusion* matrik akurasi, presisi dan *recall* (Park, 2021). Adapun Persamaan untuk menghitung nilai *confusion* matrik *multiclass* meliputi akurasi, presisi dan *recall* seperti Persamaan (3) - Persamaan(5)

$$\text{Akurasi klasifikasi} = \frac{\sum_{i=1}^l \frac{(TP_i + TN_i)}{(TP_i + FN_i + FP_i + TN_i)}}{l} \quad (3)$$

$$\text{Presisi klasifikasi} = \frac{\sum_{i=1}^l TP_i}{\sum_{i=1}^l (TP_i + FP_i)} \quad (4)$$

$$\text{Recall klasifikasi} = \frac{\sum_{i=1}^l TP_i}{\sum_{i=1}^l (TP_i + FN_i)} \quad (5)$$

Dari tiga Persamaan (3), (4), dan (5) diatas dapat disampaikan bahwa kondisi *False Positif (FP_i)* adalah kondisi ketika model tidak berhasil melakukan klasifikasi kelas *negative* ke- i sebagai kelas positif, sedangkan kondisi *True Negatif (TN_i)* adalah model berhasil melakukan klasifikasi kelas *negative* ke- i secara benar sebagai kelas *negative*. Selanjutnya, kondisi *False Negatif (FN_i)* adalah model tidak berhasil melakukan klasifikasi kelas *negative* ke- i sebagai kelas *negative*. *True Positif (TP_i)* adalah suatu keadaan ketika model berhasil melakukan klasifikasi kelas positif ke- i secara benar (Park, 2021). Dalam menghitung akurasi, presisi, dan *recall* menggunakan komponen sebagaimana tersaji pada Tabel 2.

Tabel 2. Hasil Performa Klasifikasi

| Kelas Prediksi | Kelas Aktual Klasifikasi | | |
|----------------|-----------------------------|-----------------------------|-----------------------------|
| | <i>Kelas Positif</i> | <i>Kelas Negatif</i> | <i>Netral</i> |
| <i>Positif</i> | <i>True Positif</i> | <i>False Negatif</i> | <i>False Netral Positif</i> |
| <i>Negatif</i> | <i>False Positif</i> | <i>True Negatif</i> | <i>False Negatif Netral</i> |
| <i>Netral</i> | <i>False Positif Netral</i> | <i>False Negatif Netral</i> | <i>True Netral</i> |

3. HASIL DAN PEMBAHASAN

Penelitian ini melakukan klasifikasi lama waktu pencapaian jabatan fungsional lektor kepala dari jabatan fungsional lektor dengan membagi menjadi tiga kelas yaitu kelas cepat, kelas sedang dan kelas lambat dengan menggunakan metode *Support Vector Machine*. Langkah-langkah klasifikasi antara lain:

3.1 Pelabelan Dataset

Tahapan pertama dalam klasifikasi adalah membaca dataset dan melakukan pelabelan data yang bersumber dari database bagian sumber daya manusia Universitas Sebelas Maret pada rentang tahun 2018 sampai dengan 2021 sejumlah 520 data. Pelabelan yang dilakukan secara manual pada dataset dengan memberikan label pencapaian jabatan fungsional lektor kepala dengan kelas cepat, sedang dan lambat.

Tabel 3. Kutipan Dataset

| idpeg | Lama studi | tempat studi | <i>internation research</i> | lolos serdos | usia | bidang ilmu | jab_struktural | jenis kelamin | jenjang pendidikan | kelas_LK |
|--------|------------|--------------|-----------------------------|--------------|------|-------------|----------------|---------------|--------------------|----------|
| peg1 | 4 | 1 | 2 | 3 | 63 | 1 | 2 | 1 | 1 | 9,3 |
| peg10 | 5 | 1 | 2 | 3 | 64 | 1 | 1 | 1 | 2 | 9 |
| peg100 | 2 | 1 | 2 | 5 | 55 | 1 | 2 | 2 | 1 | 7,6 |
| peg101 | 3 | 1 | 1 | 8 | 55 | 1 | 1 | 1 | 2 | 8 |
| peg102 | 3 | 1 | 1 | 6 | 54 | 1 | 2 | 1 | 2 | 9,2 |
| peg103 | 4 | 1 | 2 | 5 | 54 | 1 | 1 | 1 | 2 | 6 |
| peg114 | 3 | 1 | 2 | 3 | 60 | 2 | 1 | 2 | 2 | 3 |
| peg104 | 8 | 1 | 1 | 6 | 54 | 1 | 1 | 1 | 2 | 9,6 |
| peg105 | 3 | 1 | 2 | 4 | 52 | 1 | 1 | 1 | 1 | 6,6 |
| peg106 | 3 | 1 | 2 | 2 | 52 | 1 | 2 | 2 | 2 | 7 |
| peg107 | 3 | 1 | 2 | 4 | 52 | 1 | 1 | 2 | 2 | 4 |

Tabel 4. Kutipan Hasil Pelabelan Dataset

| idpeg | usia | temp at studi | lama studi | <i>internati on research</i> | lolos serdos | jab_str uktural | bidang ilmu | jenis kelamin | jenjang pendidik an | kelas LK |
|--------|------|---------------------|---------------|--------------------------------------|-----------------|--------------------|----------------|------------------|---------------------------|-------------|
| peg1 | 63 | 1 | 4 | 2 | 3 | 2 | 1 | 1 | 1 | lambat |
| peg10 | 64 | 1 | 5 | 2 | 3 | 1 | 1 | 1 | 2 | lambat |
| peg100 | 55 | 1 | 2 | 2 | 5 | 2 | 1 | 2 | 1 | sedang |
| peg101 | 55 | 1 | 3 | 1 | 8 | 1 | 1 | 1 | 2 | sedang |
| peg102 | 54 | 1 | 3 | 1 | 6 | 2 | 1 | 1 | 2 | lambat |
| peg103 | 54 | 1 | 4 | 2 | 5 | 1 | 1 | 1 | 2 | sedang |
| peg114 | 60 | 1 | 3 | 2 | 3 | 1 | 2 | 2 | 2 | cepat |
| peg104 | 54 | 1 | 8 | 1 | 6 | 1 | 1 | 1 | 2 | lambat |
| peg105 | 52 | 1 | 3 | 2 | 4 | 1 | 1 | 1 | 1 | sedang |
| peg106 | 52 | 1 | 3 | 2 | 2 | 2 | 1 | 2 | 2 | sedang |
| peg107 | 52 | 1 | 3 | 2 | 4 | 1 | 1 | 2 | 2 | sedang |

3.2 Pemilihan Atribut menggunakan *Information Gain*

Proses pemilihan atribut pada klasifikasi pencapaian jabatan fungsional lektor kepala yang dianggap relevan menggunakan perhitungan *gain* dari setiap atribut. Setelah memperoleh nilai *gain* dilakukan pengurutan atribut dari yang memiliki nilai *gain* tertinggi hingga paling rendah (Naufal, dkk, 2015). Nilai *information gain* yang diperoleh ditunjukkan pada Gambar 2.

```

Attribute selection output
Evaluation mode:    evaluate on all training data

=== Attribute Selection on all input data ===

Search Method:
    Attribute ranking.

Attribute Evaluator (supervised, Class (nominal): 8 kelas):
    Information Gain Ranking Filter

Ranked attributes:
    0.27      5 x5
    0.2309    2 x2
    0.1772    1 x1
    0.1501    3 x3
    0.129     4 x4
    0.0342    7 x7
    0.0243    6 x6

Selected attributes: 5,2,1,3,4,7,6 : 7
    
```

Gambar 2. Nilai *Information Gain*

3.3 Hasil *Preprocessing Data*

Pada tahapan *preprocessing* data dilakukan pembersihan data, kemudian melakukan kombinasi atau *integration* data dan menghilangkan *missing value* dan data *redunden* (Géron, 2019). Variable yang mengalami *reduction* adalah jenis kelamin dan jenjang

pendidikan dan untuk proses diskretisasi dilakukan untuk variable tempat studi, lama studi, *internation research*, sertifikasi, *structural* dan bidang ilmu.

Tabel 5. Kutipan Hasil Preprocessing

| idpeg | usia | tempat studi | lama_s tudi | <i>internation research</i> | lolos serdos | jab_stru ktural | bidang ilmu | Kelas LK |
|--------|------|--------------|-------------|-----------------------------|--------------|-----------------|-------------|----------|
| peg1 | 63 | 1 | 4 | 2 | 3 | 2 | 1 | lambat |
| peg10 | 64 | 1 | 5 | 2 | 3 | 1 | 1 | lambat |
| peg100 | 55 | 1 | 2 | 2 | 5 | 2 | 1 | sedang |
| peg101 | 55 | 1 | 3 | 1 | 8 | 1 | 1 | sedang |
| peg102 | 54 | 1 | 3 | 1 | 6 | 2 | 1 | lambat |
| peg103 | 54 | 1 | 4 | 2 | 5 | 1 | 1 | sedang |
| peg114 | 60 | 1 | 3 | 2 | 3 | 1 | 2 | cepat |
| peg104 | 54 | 1 | 8 | 1 | 6 | 1 | 1 | lambat |
| peg105 | 52 | 1 | 3 | 2 | 4 | 1 | 1 | sedang |
| peg106 | 52 | 1 | 3 | 2 | 2 | 2 | 1 | sedang |
| peg107 | 52 | 1 | 3 | 2 | 4 | 1 | 1 | sedang |
| peg135 | 54 | 2 | 3 | 1 | 2 | 1 | 1 | cepat |
| peg108 | 51 | 1 | 4 | 2 | 8 | 1 | 1 | sedang |

3.4 Proses Pemodelan

Pemodelan dalam klasifikasi lama waktu pencapaian jabatan fungsional lektor kepala dilakukan dengan algoritma *Support Vector Machine* dengan menggunakan dataset sebanyak 520 data dengan pembagian rasio dataset 70% data dari keseluruhan data sebagai *training* kemudian 30% sisa data sebagai data uji atau *testing*. Selanjutnya dilakukan penambahan *Optimizer Parameter* untuk mengoptimalkan model dengan menggunakan berbagai *kernel* (**Amalia & Yustanti, 2021**) (**Lombu, dkk, 2022**). Adapun *optimizer parameter* yang digunakan yaitu *Linear* dan *Radial Basis Function (RBF)*. *Parameter LibSVM* yang digunakan dalam proses pemodelan tersaji pada Tabel 6.

Tabel 6. Parameter LibSVM

| Kernel Model | Parameter |
|-----------------------|---|
| <i>Linear dan RBF</i> | C: Min=0.1, Max=100 Gamma: Min=0.125, Max=8 Degree: Min=2, Max=3 |

3.5 Hasil Pengujian Model

Tahap penelitian selanjutnya adalah melakukan pengujian model untuk mengetahui performa terbaik yang diperoleh dengan melihat nilai akurasi, presisi dan *recall* pada metode *Support Vector Machine*. Pada penelitian ini menggunakan metode *k-fold cross validation* untuk melakukan evaluasi model. (**Lombu, dkk, 2022**) *k-fold cross validation* yang digunakan dengan nilai k sebanyak 5 dengan menggunakan dua *scenario* yaitu (i) *scenario* pengujian

akurasi model, (ii) *scenario* pengujian akurasi model dengan *Optimizer Parameter linear* dan *RBF* dengan menghitung nilai akurasi *precision* dan *recall* kelas pencapaian jabatan fungsional dosen lektor kepala dosen ditunjukkan pada Tabel 7 dan Tabel 8.

Tabel 7. Hasil Akurasi K-Fold Cross Validation Skenario 1

| <i>k-fold</i> | Presisi | | | Recall | | | Akurasi |
|---------------|---------------------------|----------------------------|----------------------------|---------------------------|----------------------------|----------------------------|---------------|
| | Dosen Lektor Kepala Cepat | Dosen Lektor Kepala Sedang | Dosen Lektor Kepala Lambat | Dosen Lektor Kepala Cepat | Dosen Lektor Kepala Sedang | Dosen Lektor Kepala Lambat | |
| k=2 | 78.85% | 84.01% | 76.44% | 75.93% | 82.61% | 79.64% | 80.96% |
| k=3 | 77.78% | 83.16% | 76.33% | 77.78% | 82.61% | 77.25% | 80.39% |
| k=4 | 83.33% | 83.01% | 77.71% | 74.07% | 84.95% | 77.25% | 81.35% |
| k=5 | 84.00% | 82.47% | 77.16% | 77.78% | 84.95% | 74.85% | 80.96% |
| Rerata | 80.99% | 83.16% | 76.91% | 76.39% | 83.78% | 77.25% | 80.92% |

Berdasarkan percobaan *scenario* kesatu diperoleh informasi bahwa nilai akurasi menggunakan *cross validation* untuk mencapai jabatan fungsional lektor kepala tertinggi diperoleh pada iterasi *kfold* = 4 dengan nilai akurasi sebesar 81.35%. Selanjutnya Rerata akurasi pada *scenario* kesatu di dapat sebesar 80.92% dalam memprediksi pencapaian jabatan fungsional secara cepat, sedang dan lambat. Adapun hasil prediksi tersaji pada Gambar 3.

| accuracy: 81.35% +/- 3.94% (micro average: 81.35%) | | | | |
|--|-------------|-------------|------------|-----------------|
| | true lambat | true sedang | true cepat | class precision |
| pred. lambat | 129 | 37 | 0 | 77.71% |
| pred. sedang | 38 | 254 | 14 | 83.01% |
| pred. cepat | 0 | 8 | 40 | 83.33% |
| class recall | 77.25% | 84.95% | 74.07% | |

Gambar 3. Hasil Prediksi Akurasi dengan k=4 Support Vector Machine tanpa Optimizer

Berdasarkan Gambar 3 dapat diketahui hasil akurasi klasifikasi tertinggi menggunakan metode SVM tanpa penambahan *Optimizer Parameter* pada *k-fold cross validation*, dengan *k*= 4 dengan dataset sebanyak 520 data diperoleh akurasi sebesar 81.35% dan dapat memprediksi secara tepat pencapaian jabatan fungsional lektor kepala secara cepat sebanyak 40 data, jabatan fungsional lektor kepala secara sedang sebanyak 254 data dan jabatan fungsional lektor kepala yang diperoleh secara lambat sebanyak 129 data.

Tahapan selanjutnya dilakukan pengujian akurasi metode SVM dengan penambahan *Optimizer Parameter Linear* pada *k-fold cross validation* dan diperoleh akurasi tertinggi pada *k*=2, sebesar 83,46% sebagaimana tersaji pada Gambar 4.

accuracy: 83.46% +/- 1.63% (micro average: 83.46%)

| | true lambat | true sedang | true cepat | class precision |
|--------------|-------------|-------------|------------|-----------------|
| pred. lambat | 134 | 33 | 0 | 80.24% |
| pred. sedang | 33 | 260 | 14 | 84.69% |
| pred. cepat | 0 | 6 | 40 | 86.96% |
| class recall | 80.24% | 86.96% | 74.07% | |

Gambar 4. Hasil Prediksi Optimizer Parameter Linear Support Vector Machine k=2

Berdasarkan Gambar 4 tersaji hasil akurasi klasifikasi tertinggi menggunakan metode SVM dengan penambahan *Optimizer Parameter Linear* pada *k-fold cross validation*, dengan $k=5$ pada dataset sebanyak 520 data diperoleh akurasi sebesar 83.46% dan dapat memprediksi secara tepat pencapaian jabatan fungsional lektor kepala secara cepat sebanyak 40 data, jabatan fungsional lektor kepala secara sedang sebanyak 260 data dan jabatan fungsional lektor kepala yang diperoleh secara lambat sebanyak 134 data.

Tabel 8. Hasil Akurasi K-Fold Cross Validation dengan Optimizer Parameter Linear

| <i>k-fold</i> | <i>Parameter Kernel Linier</i> | | | Presisi | | | Recall | | | Akurasi |
|---------------|--------------------------------|--------------|---------------|---------------------------|----------------------------|----------------------------|---------------------------|----------------------------|----------------------------|---------------|
| | <i>C</i> | <i>Gamma</i> | <i>Degree</i> | Dosen Lektor Kepala Cepat | Dosen Lektor Kepala Sedang | Dosen Lektor Kepala Lambat | Dosen Lektor Kepala Cepat | Dosen Lektor Kepala Sedang | Dosen Lektor Kepala Lambat | |
| k=2 | 62.7 | 0.125 | 3 | 86.96% | 84.69% | 80.24% | 74.07% | 86.96% | 80.24% | 83.46 % |
| k=3 | 9.14 | 1.519 | 2 | 87.50% | 84.64% | 79.52% | 77.78% | 86.62% | 79.04% | 83.26% |
| k=4 | 9.14 | 2.104 | 3 | 90.70% | 84.92% | 77.33% | 72.22% | 86.62% | 79.64% | 82.88% |
| k=5 | 5.63 | 4.86 | 3 | 87.50% | 83.82% | 79.14% | 77.78% | 86.62% | 77.25% | 82.69% |
| Rerata | 21.6 | 2.15 | 2.7 | 88.17% | 84.52% | 79.06% | 75.46% | 86.71% | 79.04% | 83.07% |

accuracy: 87.88% +/- 2.85% (micro average: 87.88%)

| | true lambat | true sedang | true cepat | class precision |
|--------------|-------------|-------------|------------|-----------------|
| pred. lambat | 147 | 18 | 0 | 89.09% |
| pred. sedang | 20 | 280 | 24 | 86.42% |
| pred. cepat | 0 | 1 | 30 | 96.77% |
| class recall | 88.02% | 93.65% | 55.56% | |

Gambar 5. Hasil Prediksi Optimizer Parameter RBF Support Vector Machine k=5

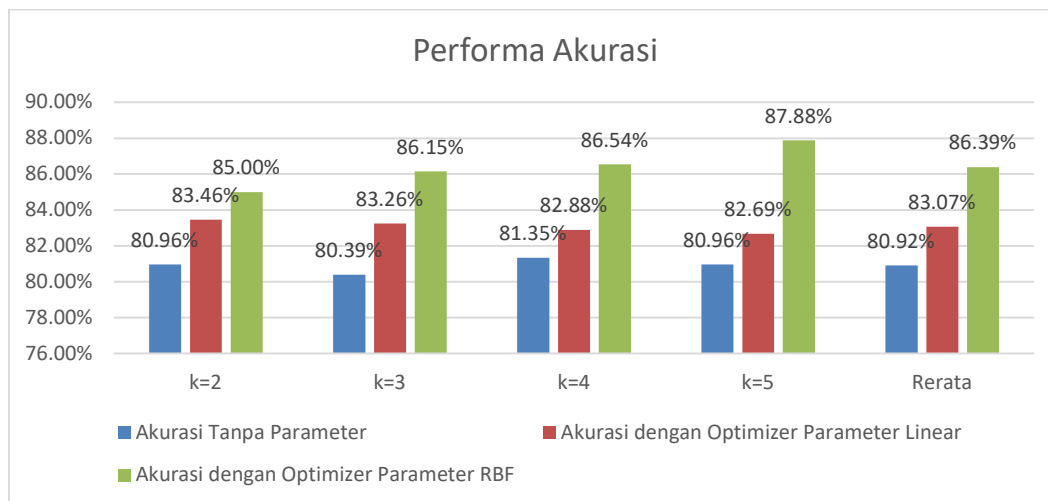
Berdasarkan Gambar 5 tersaji hasil akurasi klasifikasi tertinggi menggunakan metode SVM dengan penambahan *Optimizer Parameter RBF* pada *k-fold cross validation*, dengan $k=5$ pada dataset sebanyak 520 data diperoleh akurasi sebesar 87.88% dan dapat memprediksi secara tepat pencapaian jabatan fungsional lektor kepala secara cepat sebanyak 30 data, jabatan

fungsional lektor kepala secara sedang sebanyak 280 data dan jabatan fungsional lektor kepala yang diperoleh secara lambat sebanyak 147 data.

Hasil percobaan *scenario* kedua dengan *optimizer parameter RBF* diperoleh informasi bahwa nilai akurasi menggunakan *cross validation* untuk mencapai jabatan fungsional lektor kepala mengalami peningkatan disetiap iterasi dan rata-rata akurasi yang diperoleh dari hasil pengujian sebesar 86,39% dalam memprediksi pencapaian jabatan secara cepat, sedang dan lambat sebagaimana tersaji pada Tabel 9.

Tabel 9. Hasil Akurasi K-Fold Cross Validation dengan Optimizer Parameter RBF

| <i>k-fold</i> | <i>Parameter Kernel RBF</i> | | | <i>Presisi</i> | | | <i>Recall</i> | | | <i>Akurasi</i> |
|---------------|-----------------------------|--------------|---------------|----------------------------------|-----------------------------------|-----------------------------------|----------------------------------|-----------------------------------|-----------------------------------|----------------|
| | <i>C</i> | <i>Gamma</i> | <i>Degree</i> | <i>Dosen Lektor Kepala Cepat</i> | <i>Dosen Lektor Kepala Sedang</i> | <i>Dosen Lektor Kepala Lambat</i> | <i>Dosen Lektor Kepala Cepat</i> | <i>Dosen Lektor Kepala Sedang</i> | <i>Dosen Lektor Kepala Lambat</i> | |
| k=2 | 5.63 | 0.125 | 3 | 84.38% | 84.05% | 87.04% | 50.00% | 91.64% | 84.43% | 85.00% |
| k=3 | 2.59 | 0.125 | 3 | 86.21% | 85.62% | 87.13% | 46.30% | 91.64% | 89.22% | 86.15% |
| k=4 | 2.59 | 0.125 | 2 | 82.86 % | 85.94% | 88.48% | 53.70 % | 91.97% | 87.43% | 86.54% |
| k=5 | 2.59 | 0.125 | 2 | 96.77% | 86.42% | 89.09% | 55.56% | 93.65% | 88.02% | 87.88% |
| Rerata | 3.35 | 0.125 | 2.5 | 89.12% | 85.36% | 87.75% | 50.62% | 92.31% | 87.22% | 86.39% |



Gambar 6. Hasil Perbandingan Akurasi Metode Support Vector Machine dengan dan tanpa Parameter Optimizer

Selanjutnya untuk memudahkan memahami perbandingan hasil akurasi dengan dan tanpa menggunakan *Optimizer Parameter* dalam metode *Support Vector Machine* tersaji pada Gambar 6.

4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan dengan dua *scenario* diperoleh kesimpulan bahwa klasifikasi dengan menggunakan metode *Support Vector Machine* diperoleh rata-rata akurasi sebesar 80.92% pada *k-fold cross validation*, dengan iterasi $k=2$, $k=3$, $k=4$ dan $k=5$ untuk

scenario pertama, kemudian untuk *scenario* kedua ditambahkan model dengan *Optimizer Parameter* secara signifikan meningkatkan rata-rata akurasi sebesar 86.39% untuk *parameter RBF* dan 83.07% *Linear* pada *k-fold cross validation* dengan iterasi $k=2$, $k=3$, $k=4$ dan $k=5$ dalam melakukan klasifikasi lama waktu pencapaian jabatan fungsional lektor kepala dosen secara cepat, sedang dan lambat. Sehingga dapat disampaikan untuk metode yang diujikan telah dengan baik dapat melakukan klasifikasi. Harapan penulis melalui penelitian ini dapat membantu pimpinan perguruan tinggi dalam pengambilan keputusan di dalam meningkatkan akreditasi program studi dan institusi dengan meningkatnya jumlah dosen dengan jabatan fungsional lektor kepala, penelitian disarankan untuk dicobakan menggunakan metode klasifikasi yang berbeda dan dengan jumlah data yang lebih besar sehingga diperoleh hasil klasifikasi yang lebih baik.

DAFTAR RUJUKAN

- Ahmad, I., Basher, M., Iqbal, M. J., & Rahim, A. (2018). Performance Comparison of Support Vector Machine, Random Forest, and Extreme Learning Machine for Intrusion Detection. *IEEE Access*, 6, 33789–33795. <https://doi.org/10.1109/ACCESS.2018.2841987>
- Amalia, D. H., & Yustanti, W. (2021). Klasifikasi Buku Menggunakan Metode Support Vector Machine pada Digital Library. *Journal of Informatics and Computer Science (JINACS)*, 3(01). <https://doi.org/10.26740/jinacs.v3n01.p55-61>
- Azhar, Y., Firdausy, A. K., & Amelia, P. J. (2022). Perbandingan Algoritma Klasifikasi Data Mining Untuk Prediksi Penyakit Stroke. *SINTECH (Science and Information Technology) Journal*, 5(2). <https://doi.org/10.31598/sintechjournal.v5i2.1222>
- Fuadah, Y. N., Ubaidullah, I. D., Ibrahim, N., Taliningsing, F. F., SY, N. K., & PRAMUDITHO, M. A. (2022). Optimasi Convolutional Neural Network dan K-Fold Cross Validation pada Sistem Klasifikasi Glaukoma. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(3). <https://doi.org/10.26760/elkomika.v10i3.728>
- Géron, A. (2019). Hands-on Machine Learning with Scikit-Learning, Keras and Tensorflow. In *O'Reilly Media, Inc.*
- Lombu, A. S., Hidayat, S., & Hidayatullah, A. F. (2022). Pemodelan Klasifikasi Gaji Menggunakan Support Vector Machine. *Journal of Computer System and Informatics (JoSYC)*, 3(4). <https://doi.org/10.47065/josyc.v3i4.2137>
- Monika, I. P., & Furqon, M. T. (2018). Penerapan Metode Support Vector Machine (SVM) Pada Klasifikasi Penyimpangan Tumbuh Kembang Anak. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 2(10).
- Naufal, A. R., Satria, R., & Syukur, A. (2015). Penerapan Bootstrapping untuk

- Ketidakseimbangan Kelas dan Weighted Information Gain untuk Feature Selection pada Algoritma Support Vector Machine untuk Prediksi Loyalitas Pelanggan. *Journal of Intelligent Systems*, 1(2).
- Park, K. J. (2021). Determining the tiers of a supply chain using machine learning algorithms. *Symmetry*, 13(10). <https://doi.org/10.3390/sym13101934>
- Permenpan No 17 Tahun 2013. (2013). *PERMENPAN NOMOR 17 TAHUN 2013*.
- Pratama, F., Nasir, M., & Sauda, S. (2020). Implementasi Metode Klasifikasi Dengan Algoritma Support Vector Machine Untuk Menentukan Stok Persediaan Barang Pada Koperasi Karyawan Pangan Utama. *Journal of Software Engineering Ampera*, 1(2). <https://doi.org/10.51519/journalsea.v1i2.46>
- Rizal, R. A., Girsang, I. S., & Prasetyo, S. A. (2019). Klasifikasi Wajah Menggunakan Support Vector Machine (SVM). *REMIK (Riset Dan E-Jurnal Manajemen Informatika Komputer)*, 3(2). <https://doi.org/10.33395/remik.v3i2.10080>
- Rumpun, K., Asn, J., Riwayat, B., Arifah, A. N., Suprijadi, J., Ginanjar, I., & Padjadjaran, U. (2022). Pelatihan Menggunakan Multiclass Support Vector Machine. *Jurnal BIAStatistics*, 1(1). <http://prosiding.statistics.unpad.ac.id>
- Samudra, J. T., Hayadi, B. H., & Ramadhan, P. S. (2022). Komparasi 3 Metode Algoritma Klasifikasi Data Mining Pada Prediksi Kenaikan Jabatan. *J-SISKO TECH (Jurnal Teknologi Sistem Informasi Dan Sistem Komputer TGD)*, 5(2). <https://doi.org/10.53513/jsk.v5i2.5642>
- Sihombing, P. R. (2020). Perbandingan Metode Artificial Neural Network (ANN) dan Support Vector Machine (SVM) untuk Klasifikasi Kinerja Perusahaan Daerah Air Minum (PDAM) di Indonesia. *Jurnal Ilmu Komputer*, 13(1). <https://doi.org/10.24843/jik.2020.v13.i01.p02>
- Sri wahyuni, N. W. (2019). Penerapan Metode Klasifikasi Support Vector Machine (Svm) Untuk Menentukan Karyawan Putus Kontrak Pada Pt. Tae Hang Indonesia. *Jurnal Informatika SIMANTIK*, 4(September).
- Supriyadi, A. (2021). *Model Klasifikasi Lama Waktu Pencapaian Jabatan Fungsional Lektor Kepala Menggunakan Metode Naive Bayes (Studi Kasus Universitas Sebelas Maret)*. Universitas Sebelas Maret. (2018). *Borang Akreditasi UNS*.
- Widi Winjani, & Muhamad Fatchan. (2022). Pendekatan Algorithma Svm Untuk Menentukan Kenaikan Gaji. *Jurnal Informatika Teknologi Dan Sains*, 4(2), 114–117. <https://doi.org/10.51401/jinteks.v4i2.2027>