

# Comparison of Support Vector Machines and Multilayer Perceptrons in the Classification Process: A Case Study of Heart Disease Analysis

**Krisnawanti<sup>1\*</sup>**

<sup>1</sup>Program Studi Manajemen Rekayasa, Fakultas Logistik Teknologi dan Bisnis, Universitas Logistik dan Bisnis Internasional

Jl. Sariasih No. 54, Sarijadi, Sukasari, Kota Bandung, Jawa Barat, 40151, Indonesia

\*Penulis koresponden, *e-mail* : [krisnawanti@ulbi.ac.id](mailto:krisnawanti@ulbi.ac.id)

---

**Abstract:** Pattern Recognition is an important area in computer science that maps data to predefined concepts. Support Vector Machines (SVM) are particularly effective due to their ability to identify the optimal hyperplane that separates two classes in the feature space. Unlike neural networks, which look for a separating hyperplane, SVM determines the best hyperplane in the input space. SVM primarily serves as a linear classifier but can also address non-linear problems through the kernel trick, enabling high-dimensional operations. This paper delves into the foundational principles of SVM and its applications, specifically in classifying heart disease symptoms in individuals. The research includes the implementation of Gaussian Radial Basis Function (RBF) and Polynomial (POLY) kernel functions, along with various parameters affecting SVM performance. Additionally, a comparative analysis with Multilayer Perceptron (MLP) for data classification is presented to evaluate the effectiveness of the proposed kernel functions.

**Keywords:** Kernel; multilayer perceptron (MLP); pattern recognition; support vector machine

**Abstrak:** Pattern Recognition merupakan salah satu bidang dalam komputer sains, yang memetakan suatu data ke dalam konsep tertentu yang telah didefinisikan sebelumnya. Kelebihan SVM dibandingkan metode yang lain terletak pada kemampuannya untuk menemukan hyperplane terbaik yang memisahkan dua buah class pada feature space. Berbeda dengan strategi neural network yang berusaha mencari hyperplane pemisah antar class, SVM berusaha menemukan hyperplane yang terbaik pada input space. Prinsip dasar SVM adalah linear classifier, dan selanjutnya dikembangkan agar dapat bekerja pada problem non-linear. dengan memasukkan konsep kernel trick pada ruang kerja berdimensi tinggi. Tulisan ini membahas mengenai teori dasar SVM dan aplikasinya, yaitu pada klasifikasi ada tidaknya gejala penyakit jantung pada tubuh seseorang. Tulisan ini juga mengimplementasikan fungsi kernel Gaussian Radial Basis Function (RBF) dan Polynomial (POLY) yang diusulkan dengan sejumlah parameter yang terkait dengan penggunaan algoritma SVM yang dapat mempengaruhi hasil. Perbandingan analisis komparatif SVM Multilayer Perception (MLP) untuk klasifikasi data juga disajikan untuk memverifikasi keefektifan fungsi kernel yang diusulkan.

**Kata kunci:** Kernel; multilayer perceptron (MLP); pattern recognition; support vector machine

---

## PENDAHULUAN

Support Vector Machine (SVM) pertama kali diperkenalkan oleh Vapnik pada tahun 1992 sebagai rangkaian hasil sinergi antara konsep-konsep unggulan dalam bidang pattern recognition. Pattern recognition merupakan salah satu bidang komputer sains yang memetakan suatu data ke dalam konsep tertentu yang disebut class atau category (Chen, Fan, & Lin, 2006; Kusuma, Hayadi, Wanayumini, & Rosnelly, 2022; Lee, Nguyen, Karamanli, Lee, & Vo, 2023; Mirshekari, Moradi, Jafari, Jafari, & Ensaf, 2024; Satriyo Nugroho et al., 2005; Tukino & Fifi, 2024; Widodo, Firdaus

Mahmudy, & Muhamad Arifin, 2023). Sebagai salah satu metode pattern recognition, usia SVM terbilang masih relatif muda. Walaupun demikian, evaluasi kemampuannya dalam berbagai aplikasinya menempatkannya sebagai state of the art dalam pattern recognition, dan dewasa ini merupakan salah satu tema yang berkembang dengan pesat.

SVM merupakan metode learning machine yang bekerja atas prinsip Structural Risk Minimization (SRM) dengan tujuan menemukan hyperplane terbaik yang memisahkan dua buah class pada input space. Berbeda dengan strategi neural network yang berusaha mencari hyperplane pemisah antar class, SVM berusaha menemukan hyperplane yang terbaik pada input space. Prinsip dasar SVM adalah linear classifier, dan selanjutnya dikembangkan agar dapat bekerja pada problem non-linear. Dengan memasukkan konsep kernel trick pada ruang kerja berdimensi tinggi (Usmani, Saboor, Haris, Khan, & Park, 2021). Perkembangan ini memberikan rangsangan minat penelitian di bidang pattern recognition untuk investigasi potensi kemampuan SVM secara teoritis maupun dari segi aplikasi. Dewasa ini SVM telah berhasil diaplikasikan dalam problema dunia nyata (*real-world problems*), dan secara umum memberikan solusi yang lebih baik dibandingkan metode konvensional seperti misalnya *artificial neural network*. Tulisan ini memperkenalkan konsep dasar SVM, dan membahas aplikasinya di bioinformatika, yang akhir-akhir ini merupakan salah satu bidang yang berkembang cukup pesat.

SVM dan Multilayer Perceptron (MLP) merupakan algoritma pembelajaran mesin yang sering digunakan untuk tugas-tugas klasifikasi. Namun, ada perbedaan yang signifikan di antara keduanya dalam hal prinsip kerja, arsitektur, dan kinerjanya. Dari segi prinsip, SVM didasarkan pada konsep menemukan hyperplane optimal yang memisahkan kelas-kelas yang berbeda dalam ruang fitur. Hal ini bertujuan untuk memaksimalkan margin, yaitu jarak antara hyperplane dan titik data terdekat dari setiap kelas. SVM menggunakan fungsi kernel untuk mengubah data input menjadi ruang berdimensi lebih tinggi, yang memungkinkan pemisahan kelas secara non-linear. MLP, di sisi lain, adalah jenis jaringan saraf tiruan yang terdiri dari beberapa lapisan node atau neuron yang saling berhubungan. Setiap neuron menerapkan fungsi aktivasi non-linear ke jumlah tertimbang dari inputnya. Output dari satu lapisan berfungsi sebagai input ke lapisan berikutnya, dan proses ini berlanjut hingga lapisan output akhir tercapai (Supian, Revaldo, Marhadi, Rahmaddeni, & Efrizoni, 2024).

Dari segi arsitektur, SVM adalah model non-probabilistik yang mengklasifikasikan data dengan memetakannya ke dalam ruang fitur berdimensi tinggi (Khosravi, Razoumny, Hatami Afkoeieh, & Alavipanah, 2021). Batas keputusan ditentukan oleh vektor pendukung, yang merupakan subset dari titik data pelatihan. SVM dapat menangani masalah klasifikasi linier dan non-linier dengan menggunakan berbagai fungsi kernel seperti linier, polinomial, radial basis function (RBF), dan lain sebagainya (Razaque, Ben Haj Frej, Almi'ani, Alotaibi, & Alotaibi, 2021).

MLP memiliki arsitektur berlapis yang terdiri dari lapisan input, satu atau lebih lapisan tersembunyi, dan lapisan output. Setiap lapisan terdiri dari beberapa neuron, dan koneksi antar neuron memiliki bobot yang terkait (Rafly Alwanda, Putra, Ramadhan, & Alamsyah, 2020). Lapisan tersembunyi memungkinkan jaringan untuk mempelajari representasi kompleks dari data input. Lapisan output biasanya menggunakan fungsi softmax untuk klasifikasi multi-kelas.

Dari proses pelatihannya, SVM bertujuan untuk menemukan hyperplane yang optimal dengan memecahkan masalah optimasi cembung (Joseph Teguh Santoso, 2024; Mirshekari et al., 2024). Proses pelatihan melibatkan meminimalkan fungsi biaya yang menggabungkan margin dan istilah regularisasi. Hal ini memastikan keseimbangan antara memaksimalkan margin dan meminimalkan kesalahan klasifikasi. Masalah optimasi biasanya diselesaikan dengan menggunakan pemrograman kuadratik atau teknik optimasi cembung. MLP dilatih menggunakan algoritma *backpropagation*, yang melibatkan perambatan maju data input melalui jaringan untuk menghasilkan prediksi dan kemudian memperbarui bobot berdasarkan kesalahan antara prediksi dan label yang sebenarnya. Bobot disesuaikan secara iteratif menggunakan gradient descent atau variannya, yang bertujuan untuk meminimalkan fungsi kerugian yang telah ditentukan sebelumnya seperti kesalahan kuadrat rata-rata atau kerugian entropi silang. Pada intepertasinya, SVM memberikan interpretasi yang baik karena *support vector* (titik data yang paling dekat dengan batas keputusan) berperan penting dalam menentukan klasifikasi. Hal ini memungkinkan pemahaman tentang fitur mana yang berkontribusi paling besar terhadap keputusan.

Tulisan ini membahas teori dasar SVM dan MLP serta aplikasinya, yaitu pada klasifikasi ada tidaknya gejala penyakit jantung pada tubuh seseorang. Aplikasi kedua metode memprediksi suatu kelas/variabel, misalnya apakah seorang pasien memiliki penyakit jantung atau tidak. Jika hal itu memungkinkan untuk dilakukan, maka dapat diprediksi tingkat akurasi yang akan dicapai.

Tulisan ini mengimplementasikan fungsi kernel Gaussian Radial Basis Function (RBF) dan Polynomial (POLY) yang diusulkan dengan sejumlah parameter yang terkait dengan penggunaan algoritma SVM yang dapat mempengaruhi hasil. Fungsi Basis Radial Gaussian dan Fungsi Kernel Polinomial secara signifikan memengaruhi kinerja SVM. RBF Gaussian memungkinkan SVM menangani data yang tidak dapat dipisahkan secara linier, memodelkan batasan keputusan yang kompleks, dan mencegah *overfitting*. Fungsi kernel polinomial memungkinkan SVM untuk menangani tugas klasifikasi non-linear, mempertahankan interpretabilitas, dan menawarkan efisiensi komputasi. Namun, pilihan parameter, seperti derajat gamma dan polinomial, memainkan peran penting dalam menentukan kinerja SVM. Penyetelan parameter yang cermat dan analisis metrik evaluasi diperlukan untuk menemukan kombinasi optimal untuk dataset yang diberikan. Dengan mempertimbangkan kelebihan dan keterbatasan fungsi kernel Gaussian RBF dan

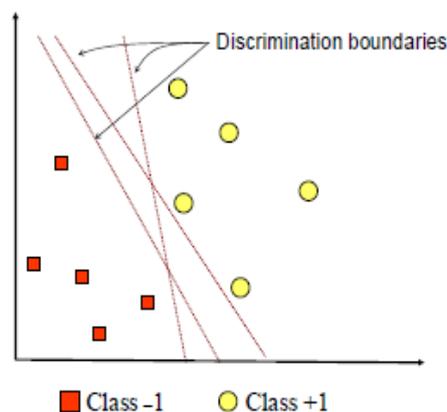
Polynomial, peneliti dapat membuat keputusan yang tepat tentang fungsi kernel mana yang akan digunakan berdasarkan persyaratan spesifik dari aplikasi SVM mereka.

Perbandingan analisis komparatif SVM Multilayer Persception (MLP) untuk klasifikasi data juga disajikan untuk memverifikasi keefektifan fungsi kernel yang diusulkan. Tujuan dari pembahasan yang dilakukan adalah mencari usulan fungsi kernel yang dapat mencapai klasifikasi akurasi yang lebih tinggi dibandingkan dengan jaringan multi-layer perceptron. Mesin vektor pendukung dievaluasi dalam perbandingan dengan fungsi kernel yang berbeda dan jaringan syaraf multi-layer oleh aplikasi ke berbagai kumpulan data yang tidak dapat dipisahkan dengan beberapa atribut (Risdi Aulia, Hidayat Lubis, & Sofinah Harahap, 2024). Hal ini diharapkan dapat menunjukkan bahwa kernel yang diusulkan memberikan akurasi klasifikasi yang baik di hampir semua set data, dibandingkan dengan klasifikasi yang dilakukan dengan MLP.

## KAJIAN PUSTAKA

### 1.1 Support Vector Machine (SVM) Classification

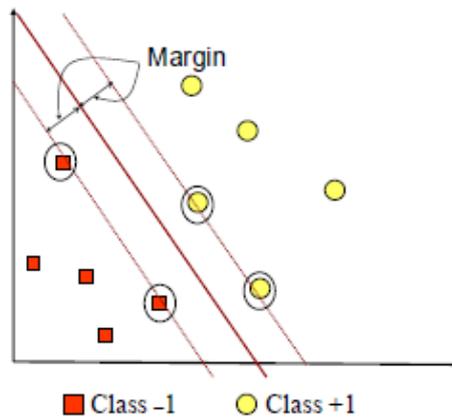
Secara sederhana, konsep SVM dijelaskan sebagai usaha mencari hyperplane yang terbaik untuk memisahkan dua buah class pada input space. Gambar 1 memperlihatkan beberapa pattern yang merupakan anggota dari dua buah class : +1 dan -1. “Pattern yang tergabung pada class -1 disimbolkan dengan warna merah (kotak), sedangkan pattern pada class +1, disimbolkan dengan warna kuning (lingkaran)” (Satriyo Nugroho et al., 2005; Tukino & Fifi, 2024).



**Gambar 1. Discrimination Bounderies**

Problem klasifikasi dapat diterjemahkan dengan usaha menemukan garis (hyperplane) yang memisahkan antara kedua kelompok tersebut. Berbagai alternatif garis pemisah (discrimination boundaries) ditunjukkan pada Gambar. 1. Hyperplane pemisah terbaik antara kedua class dapat ditemukan dengan mengukur margin. Gambar 1– SVM berusaha menemukan hyperplane terbaik yang memisahkan kedua class -1 dan +1 hyperplane tersebut dan mencari titik maksimalnya.

Margin adalah jarak antara hyperplane tersebut dengan pattern terdekat dari masing-masing class. Pattern yang paling dekat ini disebut sebagai support vector.



**Gambar 2. Hyperlane Super Vector**

Garis solid pada Gambar. 2 menunjukkan hyperplane yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua class, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah support vector. Usaha untuk mencari lokasi hyperplane ini merupakan inti dari proses pembelajaran pada SVM.

### **Multilayer Perceptron (MLP)**

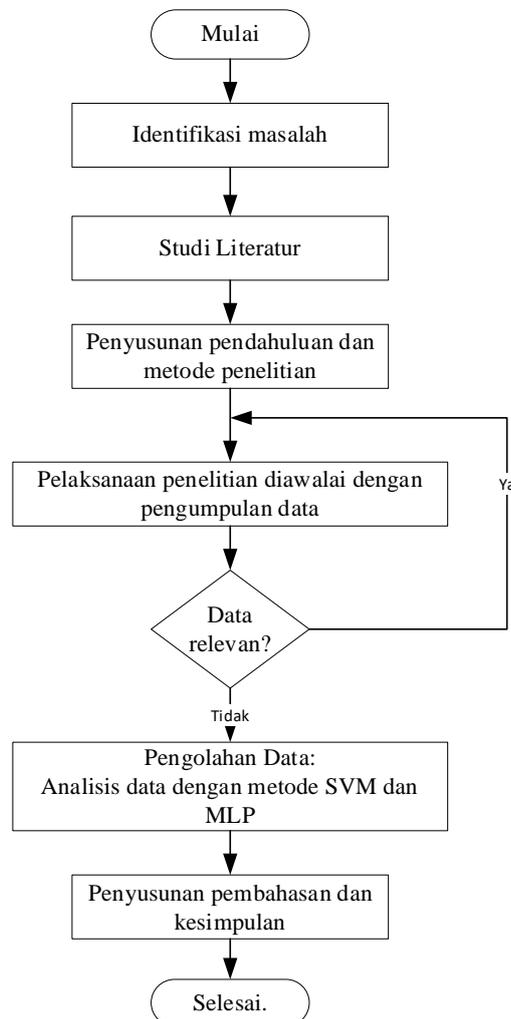
Dewasa ini, Multilayer Perceptron (MLP) menjadi arsitektur jaringan yang paling banyak digunakan untuk klasifikasi dan regresi (Hidayatulloh, 2014; Suradiradja, 2022). MLP merupakan feed forward neural network (NN) dengan melakukan penggabungan beberapa layer dari nodes pada jaringan yang tidak berhubungan langsung, training menggunakan back propagation.

MLP merupakan model non-linear dan secara luas digunakan untuk menguji hubungan kompleks antara variabel input dan variabel output (Risdi Aulia et al., 2024; Yuichi & Susetyo, 2025). Karena kemampuan belajar mereka yang efektif, MLP telah berhasil diterapkan dalam berbagai bidang, menggunakan berbagai algoritma pembelajaran. MLP merupakan pembelajaran yang efektif dan supervised learning algorithm yang paling populer. Back-Propagation merupakan algoritma pelatihan atau pembelajaran dari jaringan itu sendiri. Jaringan yang digunakan umumnya tipe sederhana dan dalam contoh-contoh hingga sekarang (Risdi Aulia et al., 2024). Ini disebut Feed-Forward Networks atau terkadang Multi-Layer Perceptrons (MLPs).

### **METODE PENELITIAN**

Studi kasus dilakukan terhadap analisis absence atau precence penyakit jantung pada objek. Data base memiliki 270 instance dan 13 attribute. Langkah penelitian disajikan pada Gambar. 4.

Pengolahan data dilakukan menggunakan software Weka 3.8 untuk melihat tingkat akurasi pada metode yang dibandingkan yaitu SVM dan MLP dengan tahapan berikut:



**Gambar 3. Metode Penelitian**

Pendahuluan menjelaskan mengenai keterkaitan antara metode SVM dan MLP berikut dengan pengetahuan terbaru berkenaan dengan kedua metode tersebut serta permasalahan yang bisa diselesaikan.

1. Penulisan metode penelitian, untuk menentukan langkah penelitian secara terperinci.
2. Pelaksanaan dan hasil penelitian dengan langkah sebagai berikut:
  - a. Data yang relevan dijadikan input pada analisis dengan software Weka, proses unsupervised dilakukan dengan menggunakan *NumericToNominal*.
  - b. Dilakukan analisis dengan metode SMO
  - c. Dilakukan implementasi dengan fungsi kernel Gaussian Radial Basis Function (RBF) dan Polynomial (POLY) yang diusulkan dengan sejumlah parameter yang terkait dengan penggunaan algoritma SVM yang dapat mempengaruhi hasil.

- d. Dilakukan analisa dengan MLP dengan sejumlah parameter yang terkait dengan penggunaan algoritma MLP yang dapat mempengaruhi hasil.
  - e. Perbandingan analisis komparatif SVM Multilayer Perspection (MLP) untuk klasifikasi data juga disajikan untuk memverifikasi keefektifan fungsi kernel yang diusulkan.
3. Pembahasan penelitian yang membahas hasil analisa dari software Weka.
  4. Tahap yang terakhir adalah pemaparan kesimpulan dari hasil pembahasan yang telah dilakukan.

## HASIL DAN PEMBAHASAN

Seperti yang telah disampaikan sebelumnya, implementasi menggunakan *software* Weka 3.8 dengan data ekspektasi gejala penyakit jantung pada responden sebanyak 270 *instance* data tanpa *missing value*. *Instance* memiliki 13 atribut dari ekstraksi 75 atribut sebelumnya. Informasi terkait 13 atribut yang digunakan adalah sebagai berikut:

1. Age,
2. Sex,
3. Chest pain type (4 values),
4. Resting blood pressure,
5. Serum cholestorol in mg/dl,
6. Fasting blood sugar > 120 mg/dl,
7. Resting electrocardiographic results (values 0,1,2),
8. Maximum heart rate achieved,
9. Exercise induced angina,
10. Oldpeak = ST depression induced by exercise relative to rest,
11. The slope of the peak exercise ST segment,
12. Number of major vessels (0-3) colored by flourosopy,
13. Thal: 3 = normal; 6 = fixed defect; 7 = reversable defect,

Dengan tipe data sebagai berikut:

- Real: 1,4,5,8,10,12
- Ordered: 11,
- Binary: 2,6,9
- Nominal: 7,3,13

**Tabel 1. Hasil SMV dan MLP**

	Accuracy %	RMSE
<b>POLY</b>	77,4074	0,4753
<b>RBFKERNEL</b>	84,4444	0,3944
<b>MLP</b>	78,5185	0,4439
<b>POLY</b>	a	B

	89	31
	30	120
<b>RBFKERNEL</b>	a	B
	95	25
	17	133
<b>MLP</b>	a	B
	90	30
	28	122

*classified as*

a = Presence

b = Absence

Variabel yang digunakan bertujuan untuk memprediksi absence atau precence penyakit jantung pada seseorang dengan cross validation folds 10 sehingga pembagian training set dan data set dilakukan oleh software. Analisa yang dilakukan berfokus pada tingka akurasi dan nilai RMSE terkecil dengan hasil pada Tabel 1. Bagian hasil berisi temuan penelitian yang didapatkan dari data penelitian dan berkaitan dengan hipotesis.

Dalam studi analisa pattern recognition, ada dua hal yang merupakan bahasan menarik dari sudut pattern recognition (Lee et al., 2023).

1. Mungkinkah dengan data pattern recognition dari microarray, diprediksi suatu class, misalnya apakah seorang pasien tersebut terkena penyakit jantung atau tidak.
2. Jika hal tersebut memungkinkan untuk dilaksanakan, kemudian diprediksi tingkat akurasi yang akan dicapai.

Fungsi kernel yang digunakan adalah:

- Normalized Poly Kernel pada gambar 2 menggunakan rumus:

$$K(x,y) = \frac{\langle x,y \rangle^2}{(\langle x,x \rangle^2 * \langle y,y \rangle^2)^{1/2}} \quad (1)$$

dengan akurasi yang diperoleh adalah 70,4074%

- RBF Kernel pada gambar 3:

$$K(x,y) = \exp(-0.01*(x-y)^2) \quad (2)$$

```

Time taken to build model: 0.12 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      228          84.4444 %
Incorrectly Classified Instances    42          15.5556 %
Kappa statistic                    0.6829
Mean absolute error                 0.1556
Root mean squared error             0.3944
Relative absolute error             31.4968 %
Root relative squared error         79.3725 %
Total Number of Instances          270

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
                0.792   0.113   0.848     0.792   0.819     0.684   0.839   0.764   Presence
                0.887   0.208   0.842     0.887   0.864     0.684   0.839   0.809   Absence
Weighted Avg.   0.844   0.166   0.845     0.844   0.844     0.684   0.839   0.789

=== Confusion Matrix ===

  a  b  <-- classified as
95 25 | a = Presence
17 133 | b = Absence

```

**Gambar 4. Analisa SMV Polykernel**

```

Time taken to build model: 0.12 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      228          84.4444 %
Incorrectly Classified Instances    42          15.5556 %
Kappa statistic                    0.6829
Mean absolute error                 0.1556
Root mean squared error             0.3944
Relative absolute error             31.4968 %
Root relative squared error         79.3725 %
Total Number of Instances          270

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
                0.792   0.113   0.848     0.792   0.819     0.684   0.839   0.764   Presence
                0.887   0.208   0.842     0.887   0.864     0.684   0.839   0.809   Absence
Weighted Avg.   0.844   0.166   0.845     0.844   0.844     0.684   0.839   0.789

=== Confusion Matrix ===

  a  b  <-- classified as
95 25 | a = Presence
17 133 | b = Absence

```

**Gambar 5. Analisa SMV RBFKernel**

```

Time taken to build model: 20.76 seconds

=== Stratified cross-validation ===
=== Summary ===

Correctly Classified Instances      212          78.5185 %
Incorrectly Classified Instances    58          21.4815 %
Kappa statistic                    0.5643
Mean absolute error                 0.2226
Root mean squared error             0.4439
Relative absolute error             45.0627 %
Root relative squared error         89.3346 %
Total Number of Instances          270

=== Detailed Accuracy By Class ===

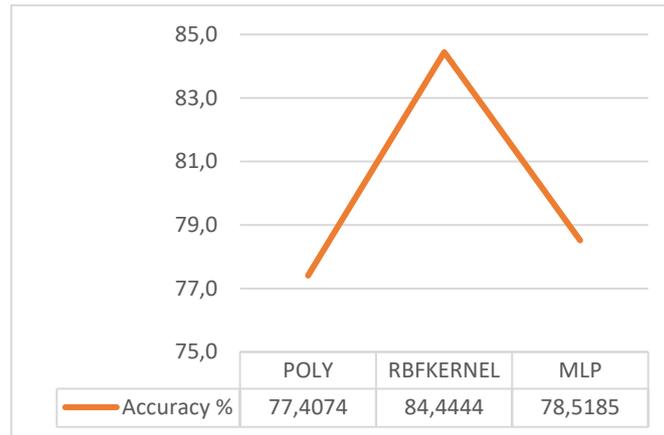
                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
                0.750   0.187   0.763     0.750   0.756     0.564   0.854   0.837   Presence
                0.813   0.250   0.803     0.813   0.808     0.564   0.854   0.856   Absence
Weighted Avg.   0.785   0.222   0.785     0.785   0.785     0.564   0.854   0.848

=== Confusion Matrix ===

  a  b  <-- classified as
90 30 | a = Presence
28 122 | b = Absence

```

**Gambar 6. Analisa MLP**



**Gambar 7. Perbandingan akurasi antar metode**

Gambar 6. menunjukkan tingkat akurasi dengan menggunakan fungsi kernel RBF memiliki akurasi tertinggi sudah lebih baik dari akurasi fungsi polykernel dan MLP berdasarkan hasil pada Gambar 4-6. Nilai RMSE menunjukkan maximum margin hyperplane dengan prinsip jika *error* lebih kecil dari  $1 \times 10^{-12}$  maka attribute diabaikan dan tidak diperhitungkan untuk menentukan support vektor.

## KESIMPULAN DAN SARAN

Tulisan ini memperkenalkan teori dasar Support Vector Machine (SVM), sebagai salah satu topik yang saat ini banyak mendapat perhatian dalam bidang pattern recognition. Kelebihan SVM dibandingkan metode yang lain terletak pada kemampuannya untuk menemukan hyperplane terbaik yang memisahkan dua buah class dengan parameter dan fungsi kernel yang digunakan yaitu polykernel dan RBFkernel.

Pada bagian kedua dari tulisan ini, dibahas aplikasi SVM pada bidang bioinformatika untuk memprediksi kelas ekspektasi diagnosa penyakit jantung dengan membandingkan metode SMV fungsi kernel polynomial dan RBF, serta metode multilayer perceptron (MLP). Berdasarkan hasil analisa dengan menggunakan software Weka 3.8 SVM dengan fungsi RBFkernel menunjukkan hasil akurasi dan nilai RMSE yang lebih baik daripada perceptron. Walaupun demikian, dikarenakan jumlah sampel yang relatif sedikit, hasil eksperimen itu belum dapat memberikan kesimpulan final bahwa SVM superior terhadap perceptron.

## DAFTAR PUSTAKA

- Chen, P. H., Fan, R. E., & Lin, C. J. (2006). A study on SMO-type decomposition methods for support vector machines. *IEEE Transactions on Neural Networks*, 17(4), 893–908. Retrieved from <https://doi.org/10.1109/TNN.2006.875973>
- Hidayatulloh, T. (2014). Kajian Komparasi Penerapan Algoritma Support Vector Machine (SVM) dan Multilayer Perceptron (MLP) dalam Prediksi Indeks Saham Sektor Perbankan: Studi Kasus Saham LQ45 IDX Bank BCA. *Seminar Nasional Inovasi Dan Tren (SNIT)*, 262–272. Retrieved from [www.finance.yahoo.com](http://www.finance.yahoo.com)

- Joseph Teguh Santoso. (2024). *Cara Memanipulasi Pembelajaran Mesin (Machine Learning)*. Penerbit Yayasan Prima Agus Teknik (Vol. 10). Retrieved from <https://penerbit.stekom.ac.id/index.php/yayasanpat/article/view/488>
- Khosravi, I., Razoumny, Y., Hatami Afkouseieh, J., & Alavipanah, S. K. (2021). Fully polarimetric synthetic aperture radar data classification using probabilistic and non-probabilistic kernel methods. *European Journal of Remote Sensing*, 54(1), 310–317. Retrieved from <https://doi.org/10.1080/22797254.2021.1924081>
- Kusuma, J., Hayadi, B. H., Wanayumini, W., & Rosnelly, R. (2022). Komparasi Metode Multi Layer Perceptron (MLP) dan Support Vector Machine (SVM) untuk Klasifikasi Kanker Payudara. *MIND Journal*, 7(1), 51–60. Retrieved from <https://doi.org/10.26760/mindjournal.v7i1.51-60>
- Lee, S., Nguyen, N. H., Karamanli, A., Lee, J., & Vo, T. P. (2023). Super learner machine-learning algorithms for compressive strength prediction of high performance concrete. *Structural Concrete*, 24(2), 2208–2228. Retrieved from <https://doi.org/10.1002/suco.202200424>
- Mirshekari, S., Moradi, M., Jafari, H., Jafari, M., & Ensaf, M. (2024). Enhancing Predictive Accuracy in Pharmaceutical Sales Through An Ensemble Kernel Gaussian Process Regression Approach. *ArXiv:2404.19669*. Retrieved from <http://arxiv.org/abs/2404.19669>
- Rafly Alwanda, M., Putra, R., Ramadhan, K., & Alamsyah, D. (2020). Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle. *Jurnal Algoritme*, 1(1), 45.
- Razaque, A., Ben Haj Frej, M., Almi'ani, M., Alotaibi, M., & Alotaibi, B. (2021). Improved support vector machine enabled radial basis function and linear variants for remote sensing image classification. *Sensors*, 21(13). Retrieved from <https://doi.org/10.3390/s21134431>
- Risdi Aulia, R., Hidayat Lubis, F., & Sofinah Harahap, L. (2024). Penerapan Multi-Layer Perceptron untuk Prediksi Durasi Tidur Berdasarkan Faktor Kebiasaan Harian. *Journal of Multidisciplinary Inquiry in Science, Technology and Educational Research*, 2(1), 20–30. Retrieved from <https://doi.org/10.32672/mister.v2i1.2326>
- Satriyo Nugroho, A., Handoko, D., Arief Witarto, dan B., No, T., Rekayasa Protein, L., Penelitian Bioteknologi, P., & Raya Bogor Km, J. (2005). ANALISA INFORMASI DIMENSI TINGGI PADA BIOINFORMATIKA MEMAKAI SUPPORT VECTOR MACHINE. *Proc. of National Conference on Information & Communication Technology (ICT) for Indonesia*, 427–435.
- Supian, A., Revaldo, B. T., Marhadi, N., Rahmaddeni, & Efrizoni, L. (2024). Penerapan SVM dan Word2Vec untuk Analisis Sentimen Ulasan Pengguna Aplikasi DANA. *Jurnal Ilmiah Komputasi*, 23(3). Retrieved from <https://doi.org/10.32409/jikstik.23.3.3642>
- Suradiradja, K. H. (2022). Algoritme Machine Learning Multi-Layer Perceptron dan Recurrent Neural Network untuk Prediksi Harga Cabai Merah Besar di Kota Tangerang. *Faktor Exacta*, 14(4), 194. Retrieved from <https://doi.org/10.30998/faktorexacta.v14i4.10376>
- Tukino, & Fifi. (2024). Penerapan Support Vector Machine Untuk Analisis Sentimen Pada Layanan Ojek Online. *Jurnal Desain Dan Analisis Teknologi (JDDAT)*, 3(2), 104–113. Retrieved from <http://journal.aptikomkepri.org/index.php/JDDAT>
- Usmani, S., Saboor, A., Haris, M., Khan, M. A., & Park, H. (2021). Latest research trends in fall detection and prevention using machine learning: A systematic review. *Sensors*, 21(15), 1. Retrieved from <https://doi.org/10.3390/s21155134>
- Widodo, A., Firdaus Mahmudy, W., & Muhamad Arifin, M. (2023). Comparison of Multi-layer Perceptron and Support Vector Machine Methods on Rainfall Data with Optimal Parameter Tuning. *IJACSA) International Journal of Advanced Computer Science and Applications*, 14(7), 2023. Retrieved from [www.ijacsa.thesai.org](http://www.ijacsa.thesai.org)
- Yuichi, M., & Susetyo, Y. A. (2025). Klasifikasi Penyakit Migrain dengan Metode Naïve Bayes pada Dataset Kaggle. *Jurnal Indonesia : Manajemen Informatika Dan Komunikasi (JIMIK)*, 6(1), 139–151. Retrieved from <https://journal.stmiki.ac.id>