

---

---

## **Penerapan *Multi Layer Perceptron* dan Diskrit pada Prediksi Cacat Software**

Dede Wintana<sup>1\*</sup>, Gunawan<sup>2</sup>, Hamdun Sulaeman<sup>3</sup>, Saeful Bahri<sup>4</sup>

<sup>1,2,3,4</sup> Informatika, Universitas Bina Sarana Informatika, Jl. Ringroad Barat, Gamping Kidul, Ambarketawang, Kec. Gamping, Kabupaten Sleman, Daerah Istimewa Yogyakarta, 55184, Indonesia

**\*Email Korespondensi:**

Dede.dwe@bsi.ac.id

### **Abstrak**

Cacat perangkat lunak merupakan salah satu penyebab utama limbah teknologi informasi hal ini menjadi tantangan utama dalam pengembangan perangkat lunak karena dapat menurunkan kualitas perangkat lunak itu sendiri. Untuk mengurangi biaya dan usaha dalam pengembangan serta perbaikan perangkat lunak, memprediksi cacat perangkat lunak adalah langkah terbaik. *Multi-Layer Perceptron (MLP)* merupakan jenis jaringan saraf tiruan yang dapat digunakan untuk mempelajari pola-pola yang kompleks dan non-linear pada data input, unggul dalam memodelkan hubungan kompleks dan non-linear dalam data, serta mampu mengekstraksi fitur secara otomatis dan menangani masalah yang tidak bisa diselesaikan oleh model linear. Salah satu tahapan pra-processing untuk mengoptimalkan MLP adalah diskritisasi data, yaitu membagi rentang atribut ke interval untuk mengurangi jumlah atribut numerikal menjadi data kategorikal. Hasil pengujian dengan lima jenis data dari NASA MDP (CM1, JM1, KC1, KC2, dan PC1) menunjukkan peningkatan akurasi signifikan. Pada dataset CM1, akurasi meningkat menjadi 96,1% dibandingkan dengan penggunaan MLP saja yang mencapai 91,1%. Pada dataset JM1, akurasi meningkat menjadi 79,1% dibandingkan MLP saja yang mencapai 78,3%. Pada data KC1, akurasi meningkat menjadi 88,5% dibandingkan MLP saja yang mencapai 85,9%. Pada dataset KC2, akurasi MLP dengan diskritisasi mencapai 89,8% lebih baik dibandingkan MLP saja sebesar 84,8%. Pada data PC1, akurasi tertinggi diperoleh sebesar 95,5% dibandingkan dengan MLP saja yang mencapai 94,3%.

**Kata Kunci :** Cacat; Diskritisasi; MLP; Software.

### **Abstract**

Software defects are one of the main causes of information technology waste, posing a major challenge in software development as they can degrade the quality of the software itself. To reduce costs and efforts in software development and maintenance, predicting software defects is the best approach. *Multi-Layer Perceptron (MLP)* is a type of artificial neural network that can be used to learn complex and non-linear patterns in input data. It excels in modeling complex and non-linear relationships in data, as well as automatically extracting features and handling problems that cannot be solved by linear models. One of the preprocessing steps to optimize MLP is data discretization, which involves dividing the range of attributes into intervals to reduce the number of numerical attributes to categorical data. Testing results with five types of data from NASA MDP (CM1, JM1, KC1, KC2, and PC1) showed significant accuracy improvements. In the CM1 dataset, accuracy increased to 96.1% compared to using MLP alone, which achieved 91.1%. In the JM1 dataset, accuracy increased to 79.1% compared to MLP alone, which achieved 78.3%. In the KC1 data, accuracy increased to 88.5% compared to MLP alone, which achieved 85.9%. In the KC2 dataset, MLP with discretization achieved an accuracy of 89.8%, better than MLP alone at 84.8%. In the PC1 data, the highest accuracy obtained was 95.5% compared to MLP alone, which achieved 94.3%.

**Keywords:** Defect; Diskritisasi; MLP; Software.

## 1. Pendahuluan

Salah satu penyebab utama limbah teknologi informasi adalah cacat perangkat lunak, yang menyebabkan pengerjaan ulang yang memakan waktu dan biaya. (Hardoni et al., 2021) Cacat perangkat lunak adalah kesalahan sistem komputer yang dapat menyebabkan kesalahan lain yang tidak terduga dan menurunkan kualitas perangkat lunak. (Hari Agus Prastyo et al., 2024) Cara terbaik untuk mengurangi biaya dan usaha dalam proses pengembangan dan perbaikan *software* adalah dengan memprediksi cacat *software*. (Prasetyo et al., 2021) Prediksi awal modul cacat perangkat lunak dapat membantu pengembang perangkat lunak mengalokasikan sumber daya yang tersedia untuk membuat produk perangkat lunak berkualitas tinggi yang dapat membantu dalam setiap proses bisnis perusahaan. (Hardoni & Rini, 2020)

Memprediksi kesalahan pada kecacatan sebuah perangkat lunak sangat penting untuk meningkatkan kualitas perangkat lunak. (Sugiono et al., 2020) Untuk menanggulangi hal tersebut Langkah awal yang dilakukan yakni memprediksi cacat pada perangkat lunak, beberapa metode yang dapat di gunakan yakni metode dengan memanfaatkan *machine Learning*, Metode pembelajaran mesin adalah cabang kecerdasan buatan (AI) dan ilmu komputer yang berfokus pada penggunaan data dan algoritma untuk meniru cara manusia belajar dan secara bertahap meningkatkan akurasi. Semakin baik algoritma pembelajaran mesin yang digunakan, semakin baik keputusan yang dibuat. (Faiza et al., 2022)

Dengan berkembangnya teknologi kecerdasan buatan, muncul metode pembelajaran mesin. Mesin ini dapat belajar sendiri tanpa bantuan manusia dan dibangun berdasarkan disiplin ilmu lain seperti data mining, statistika, dan matematika. (Sihombing & Yuliati, 2021) Jaringan Saraf Tiruan adalah komponen kecerdasan buatan yang digunakan untuk membantu pekerjaan manusia yang dibuat dengan bahasa komputer. Jaringan syaraf tiruan terus berusaha mensimulasikan proses pembelajaran dalam otak manusia. Neuron adalah bagian dari jaringan saraf tiruan, dan koneksi keluar sel saraf ke neuron lain memungkinkan sel saraf untuk mengubah data yang mereka terima. (Christiawan et al., 2023)

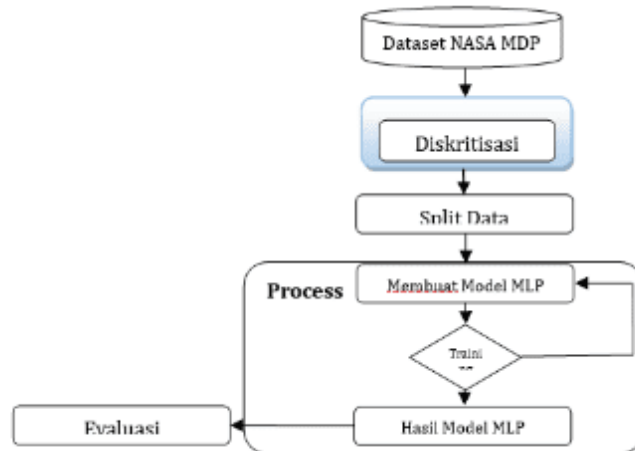
*Multi Layer Perceptron* (MLP) Merupakan jaringan syaraf tiruan (*artificial neural network*) *feedforward* dengan satu atau lebih lapisan tersembunyi. Secara umum, MLP terdiri dari lapisan input yang terdiri dari kumpulan neuron yang menangani input data, setidaknya satu lapisan tersembunyi yang berfungsi sebagai neuron komputasi, dan satu lapisan keluaran yang berfungsi sebagai neuron penyimpanan untuk hasil komputasi. Dua parameter utama MLP adalah fungsi aktivasi dan fungsi optimasi. Fungsi aktivasi menentukan output pada simpul elemen input, sedangkan fungsi optimasi menentukan bobot yang paling sesuai berdasarkan input dan output. (KUSUMA et al., 2022) Algoritma ini handal karena pembelajarannya terarah. Memperbaharui bobot balik, juga dikenal sebagai *backpropagation*, adalah metode pembelajaran yang digunakan untuk menghasilkan klasifikasi yang lebih baik. (Purnama, 2021) MLP memiliki keunggulan dalam memodelkan hubungan yang kompleks dan non-linier dalam data. serta dapat mengekstraksi fitur secara otomatis dan menangani masalah yang tidak dapat diselesaikan oleh model linear. (Gulo et al., 2024) Pre-processing data merupakan tahapan penting dalam data mining karena membantu mempersiapkan data, sehingga teknik data mining yang digunakan menghasilkan pola yang berkualitas tinggi dan akurat. (Puteri et al., 2021)

Tahapan *pra-processing* yang dilakukan yakni dengan melakukan Diskritisasi data, Dengan membagi rentang atribut ke interval, diskritisasi digunakan untuk mengurangi jumlah atribut tertentu dari data numerikal ke data kategorikal. (Wintana, 2020) mendiskretisasi atribut numerik dan mengelompokkan nilai atribut nominal. algoritma ini sangat cocok untuk mengerjakan klasifikasi/prediksi pada data mining. (Berka & Bruha, 1998) Dengan menerapkan Metode *Pra-Procesing* Diskrit data dan penerapan *Multi Layer Perceptron* (MLP) Diharapkan dapat meningkatkan nilai akurasi dalam memprediksi Kecacatan pada perangkat lunak /*Software*.

## 2. Metode Penelitian

Pada penelitian ini dilakukan menggunakan 5 dataset nasa yakni dataset **CM1** yang mana merupakan instrumen pengumpulan dan pemrosesan data pesawat ruang angkasa NASA yang ditulis dalam "C". Peneliti telah mencapai kesepakatan tentang akses ke kode sumber CM, jadi agak lebih banyak dipelajari daripada set data nasa lainnya. Misalnya, model UML untuk CM1 direkayasa kembali dari artefak yang disediakan untuk Universitas West Virginia. Lalu **JM1** yang merupakan set data Promese yang dikembangkan untuk mendorong model rekayasa perangkat lunak yang dapat diulang, diverifikasi, disangkal, dan/atau diprediksi.

**KC1 & KC2** yang merupakan set data yang menjelaskan metrik nasa. data yang diperoleh dari perangkat lunak penerbangan yang digunakan oleh satelit yang mengorbit di sekitar Bumi. Sumber data adalah ekstraktor kode sumber yang digunakan oleh McCabe dan Halstead. Pada tahun 1970-an, fitur-fitur ini dibuat dalam upaya untuk menandai fitur kode yang secara objektif terkait dengan kualitas perangkat lunak. Serta **PC1** merupakan Data yang menjelaskan kecacatan metrik NASA berasal dari perangkat lunak penerbangan satelit yang mengorbit di Bumi. Sumber data adalah ekstraktor kode sumber yang digunakan oleh McCabe dan Halstead. Pada tahun 1970-an, fitur-fitur ini dibuat dalam upaya untuk menandai fitur kode yang secara objektif terkait dengan kualitas perangkat lunak. Dengan 21 atribut yang digunakan, Pengujian menggunakan Integrasi metode *Praprocessing Equal Frequency Binning*, Metode *Multi Layer Perceptron*



Gambar 1. Langkah-Langkah Penelitian  
Sumber: (Afikah et al., 2022)

Metode diskritisasi digunakan untuk mereduksi jumlah atribut tertentu berupa data numerik menjadi data kategorikal dengan cara membagi range atribut menjadi interval (Wintana, 2020) Range tag dapat digunakan untuk mengganti nilai data aktual untuk mempercepat dan mempermudah pemrosesan data (Muhamad et al., 2018).

*Machine learning* adalah serangkaian algoritma komputer yang digunakan untuk mengoptimalkan kinerja sistem atau komputer berdasarkan data sampel. Kemampuan utama *machine learning* adalah mengubah dan mengadaptasi keputusan untuk merespon perubahan. (Pambudi et al., 2020) Komputer dapat digunakan untuk melakukan hal-hal seperti berikut. Klasifikasi adalah teknik pembelajaran mesin. Untuk memprediksi nilai atau kelas seseorang dalam sebuah populasi, Similarity, juga dikenal sebagai pencocokan kemiripan, adalah teknik pembelajaran mesin yang digunakan untuk menemukan kemiripan antar individu berdasarkan data yang ada. Clustering, atau pengklasteran, adalah metode pengajaran mesin yang digunakan untuk mengelompokkan orang dalam grup yang sama berdasarkan kesamaan yang mereka miliki. Pada penelitian ini, kegunaan metode pengajaran mesin adalah yang pertama, yaitu untuk memprediksi nilai atau kelas seseorang.

MLP merupakan pengembangan dari perceptron sederhana di lapisan tersembunyi. Dalam proses ini lebih dari satu lapisan tersembunyi dapat digunakan. Jaringan topologi dibatasi *Multilayer Perceptron* adalah jaringan saraf yang melatih menggunakan pembelajaran propagasi (Rasna & Matdoan, 2022)

MLP terdiri dari lapisan input yang terdiri dari kumpulan neuron yang menangani input data, setidaknya satu lapisan tersembunyi yang berfungsi sebagai neuron komputasi, dan satu lapisan keluaran yang berfungsi sebagai neuron penyimpanan untuk hasil komputasi. Dua parameter utama MLP adalah fungsi aktivasi dan fungsi optimasi. Fungsi aktivasi menentukan output pada simpul elemen input, sedangkan fungsi optimasi menentukan bobot yang paling sesuai berdasarkan input dan output. (KUSUMA et al., 2022)

Algoritma *Multilayer Perceptron* digunakan dalam penelitian ini untuk melakukan pembelajaran dengan mengubah bobotnya berdasarkan perbedaan output dan target yang diinginkan. Fungsi standar Sigmoid digunakan dalam *Multilayer Perceptron* untuk menghasilkan output, di mana jumlah pembobotan dari sejumlah input dan bias dimasukkan ke level aktivasi melalui fungsi transfer, dan unit diatur dalam lapisan topologi. (Ainun et al., 2021)

Tahapan prosedur metode analisis untuk pelaksanaan *Multilayer Perceptron* adalah sebagai berikut. Pertama, inisialisasi bobot jaringan secara acak. Kedua, mencari nilai probabilitas dapat dirumuskan sebagai berikut :

$$P(A) = \frac{\text{Jumlah Data (Yang dimaksud)}}{\text{Banyak Data}} \quad (1)$$

P(A) = Peluang Kejadian

Ketiga, membangkitkan *output* untuk simpul menggunakan fungsi aktivasi *Sigmoid*, Dengan rumus *Sigmoid* biner yang digunakan sebagai berikut:

$$\text{output} = \frac{1}{1 + e^{-\text{input}}} \quad (2)$$

Keempat, menghitung nilai *error* antara nilai yang diprediksi dengan nilai yang sesungguhnya menggunakan rumus MSE (*Mean Square Error*) sebagai berikut:

$$MSE = \sum \frac{xt - ft^2}{n} \quad (3)$$

Ft = Nilai Prediksi pada periode

n = Jumlah Data

Xt= Data Label

Dataset cacat perangkat lunak yang digunakan dalam penelitian ini. Menggunakan dataset NASA MDP yang dapat diakses di situs PROMISE, Dataset yang digunakan pada penelitian ini berupa dataset yang berjumlah 5 dataset yaitu, CM1, JM1, KC1, KC2 dan PC1 berikut dataset yang digunakan pada penelitian ini:

Table 1. Dataset Software Defect Nasa MDP

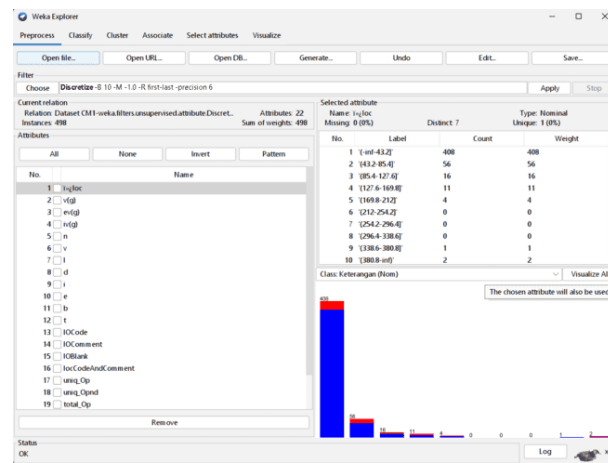
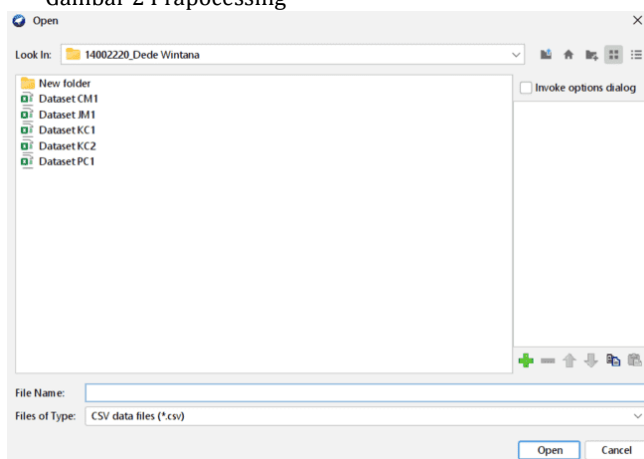
Fitur	CM1	JM1	KC1	KC2	PC1
Line Of Code (loc)	v	v	v	v	v
cyclomatic complexity (v(g))	v	v	v	v	v
essential complexity (ev(g))	v	v	v	v	v
Design Complexity (iv(g))	v	v	v	v	v
Unique Operators (uniq_Op)	v	v	v	v	v
Unique Operands (uniq_Opnd)	v	v	v	v	v
Total Operators (total_Op)	v	v	v	v	v

Total Operands (TotalOpnd)	V	V	V	V	V
Total Operators dan Operands (n)	V	V	V	V	V
volume (v)	V	V	V	V	V
program legth (l)	V	V	V	V	V
Divicuity (d)	V	V	V	V	V
intelegence (I)	V	V	V	V	V
Time to write program (t)	V	V	V	V	V
Effort to Write Program (e)	V	V	V	V	V
Errorr Estimate (b)	V	V	V	V	V
Count of Statement Lines (lOCCode)	V	V	V	V	V
Count of Code and Comments Lines (locCodeAndComment)	V	V	V	V	V
Count of Blank Lines (lOBlank)	V	V	V	V	V
Count of Lines of Comments (lOComment)	V	V	V	V	V
Metrik Branch Count (branchCount)	V	V	V	V	V

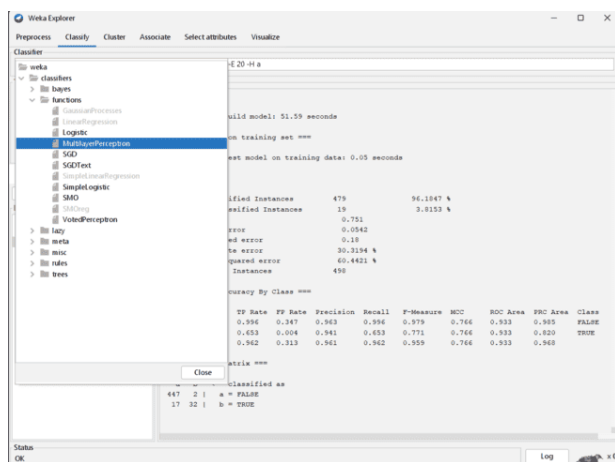
### 3. Hasil

Tahapan Penelitian yang dilakukan dalam prediksi cacat perangkat lunak dengan menggunakan *Multi layer perceptron* dan Diskrit dengan menggunakan aplikasi WEKA, pada tahap awal dilakukan dengan menginput dataset kedalam aplikasi weka, lalu mulai dilakukan praprocessing dengan melakukan diskrit daya pada menu filter terus memilih unsupervise, atribute, Discreteze, adapun tahapannya antarlain sebagai berikut:

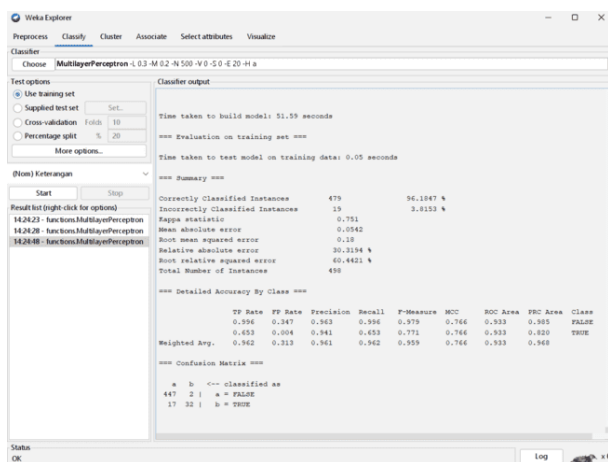
Gambar 2 Praprocessing



Gambar 3. Output



Gambar 4. Multi Layer Perceptron



Gambar 5. Hasil Penghitungan Layer Perceptron

Hasil Pengujian data menggunakan Aplikasi Weka didapatkan dengan hasil *confusion Matrix* sebagai Berikut:  
 Pengujian Data CM1 Hanya Menggunakan MLP:

Table 2. *Confusion Matrix*

		Kenyataan	
		TRUE	FALSE
Prediksi	TRUE	443	11
	FALSE	38	6

Berdasarkan hasil pengujian yang ditampilkan dalam confusion matrix, kita bisa menguraikan hasilnya sebagai berikut. True Positive (443) adalah jumlah kasus di mana model memprediksi positif dan hasil sebenarnya juga positif. Dengan kata lain, ada 443 data yang benar-benar cacat dan berhasil diidentifikasi sebagai cacat oleh model. True Negative (6) adalah jumlah kasus di mana model memprediksi negatif dan hasil sebenarnya juga negatif. Artinya, ada 6 data yang tidak cacat dan berhasil diidentifikasi sebagai tidak cacat oleh model. False Positive (11) adalah jumlah kasus di mana model memprediksi positif tetapi hasil sebenarnya negatif. Jadi, ada 11 data yang sebenarnya tidak cacat namun diidentifikasi sebagai cacat oleh model. False Negative (38) adalah jumlah kasus di mana model memprediksi negatif tetapi hasil sebenarnya positif. Dengan kata lain, ada 38 data yang benar-benar cacat tetapi tidak teridentifikasi sebagai cacat oleh model.

Hasil dari penghitungan akurasi secara manual pada confusion matrix pada data diperoleh nilai akurasi sebesar : 0,9116465863A. Secara keseluruhan, hasil ini menunjukkan bahwa model memiliki tingkat akurasi yang cukup baik dalam mengidentifikasi cacat perangkat lunak dengan lebih banyak prediksi yang benar dibandingkan prediksi yang salah.

Pengujian Data CM1 dengan menggunakan Diskrit dan MLP:

Table 3. *confusion matrix MLP*

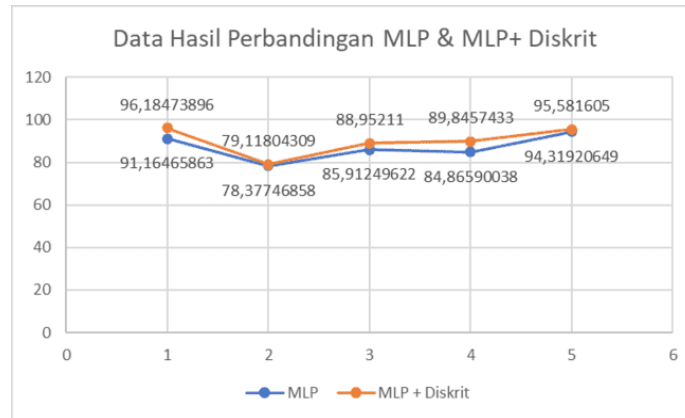
		Kenyataan	
		TRUE	FALSE
Prediksi	TRUE	447	32
	FALSE	17	2

Berdasarkan hasil pengujian menggunakan *Multi Layer Perceptron* dengan metode diskrit, berikut adalah uraian dari confusion matrix yang diperoleh. True Positive (447) adalah jumlah kasus di mana model berhasil memprediksi positif dengan benar. Artinya, ada 447 data yang benar-benar cacat dan berhasil diidentifikasi sebagai cacat oleh model. True Negative (2) adalah jumlah kasus di mana model memprediksi negatif dengan benar. Dengan kata lain, ada 2 data yang tidak cacat dan berhasil diidentifikasi sebagai tidak cacat oleh model. False Positive (32) adalah jumlah kasus di mana model memprediksi positif, tetapi sebenarnya negatif. Jadi, ada 32 data yang tidak cacat tetapi diidentifikasi sebagai cacat oleh model. False Negative (17) adalah jumlah kasus di mana model memprediksi negatif, tetapi sebenarnya positif. Artinya, ada 17 data yang cacat tetapi tidak diidentifikasi sebagai cacat oleh model.

Hasil dari penghitungan akurasi secara manual pada *confusion matrix* pada data diperoleh nilai akurasi sebesar **0.9618473896**. Analisis dari hasil ini menunjukkan bahwa model memiliki tingkat akurasi yang cukup baik dalam mengidentifikasi cacat perangkat lunak dibandingkan dengan pengujian tanpa menggunakan metode diskrit..

Tabel 4. Data Hasil Pengolahan dengan MLP dan MLP + Diskrit

Dataset	MLP	MLP + Diskrit
CM1	0,9116465863	0,9618473896
JM1	0,7837746858	0,7911804309
KC1	0,8591249622	0,889521100
KC2	0,8486590038	0,898457433
PC1	0,9431920649	0,955816050



Gambar 6. Data Hasil perbandingan MLP & MLP+Diskrit

#### 4. Pembahasan

Dari data diatas dapat disimpulkan bahwa penerapan model *multi layer Perceptron* dengan *multi layer perceptron* + diskrit, menunjukan bahwa *model multi layer perceptron* memiliki nilai akurasi lebih baik dibandingkan dengan model yang hanya menggunakan model *multi layer perceptron* saja. Dari hasil tersebut juga dapat disimpulkan bahwa penerapan pra-processing dengan memanfaatkan Diskrit data menunjukan hasil yang lebih baik. Dan mampu memprediksi dengan baik pada kecacatan sebuah *software* sehingga dapat mengurangi biaya dan waktu dalam pembuatan sebuah *software*.

Dari hasil pengujian data dengan menggunakan 5 jenis data dari Nasa MDP yakni, CM1, JM1, KC1, KC2, Dan PC1, dapat dilihat terdapat Peningkatan Akurasi yang signifikan sebesar 96,1% dibanding Hanya Menggunakan Model MLP yang hanya 91,1 % pada Dataset CM1, lalu pada pengujian Data JM1, terdapat peningkatan 79,1 dibanding metode MLP saja dengan 78,3, lalu pada pengujian data KC1 peningkatan akurasi 88,5% dibanding Model MLP dengan 85,9%, Pada dataset KC2 Akurasi MLP+Diskrit diperoleh akurasi 89,8 lebih baik dibanding hanya menggunakan Model MLP saja yakni sebesar 84,8% dan Pengujian terakhir dengan menggunakan data PC1 yakni dengan akurasi tertinggi diperoleh 95,5% lebih baik dibanding model MLP saja dengan akurasi 94,3%.

#### 5. Kesimpulan

Pengujian model menggunakan dataset dari NASA MDP dengan lima jenis data yaitu CM1, JM1, KC1, KC2, dan PC1. Pengujian data dilakukan dengan dua metode percobaan, yaitu menggunakan Model Multi Layer Perceptron (MLP) dan Model Multi Layer Perceptron + Diskrit. Dari hasil dua kali pengujian data pada lima dataset NASA MDP, yang melalui proses pra- preprocessing menggunakan diskrit data, kemudian displit menjadi data training dan testing, lalu dibuat model Multi Layer Perceptron dan dievaluasi hasilnya. Hasil pengujian menunjukkan peningkatan akurasi yang signifikan. Misalnya, pada dataset CM1, akurasi meningkat menjadi 96,1% dibandingkan hanya menggunakan model MLP yang mencapai 91,1%. Pada pengujian data JM1, terdapat peningkatan akurasi dari 78,3% (MLP) menjadi 79,1% (MLP + Diskrit). Pada data KC1, akurasi meningkat dari 85,9% (MLP) menjadi 88,5% (MLP + Diskrit). Untuk dataset KC2, akurasi dengan MLP + Diskrit mencapai 89,8%, lebih baik dibandingkan dengan hanya menggunakan MLP yang memperoleh 84,8%. Pada

pengujian terakhir dengan data PC1, akurasi tertinggi diperoleh dengan nilai 95,5% (MLP + Diskrit) dibandingkan dengan MLP saja yang memperoleh 94,3%.

Dari hasil pengujian tersebut, dapat disimpulkan bahwa model dengan memanfaatkan diskrit pada pengujian metode Multi Layer Perceptron menunjukkan hasil yang lebih baik dibandingkan dengan hanya menggunakan Multi Layer Perceptron tanpa pra-preprocessing diskritisasi data, karena hasil yang didapatkan menunjukkan perbedaan akurasi yang cukup signifikan. selanjutnya.

## Referensi

- Afikah, P., Affandi, I. R., & Hasan, F. N. (2022). Implementasi Business Intelligence Untuk Menganalisis Data Kasus Virus Corona di Indonesia Menggunakan Platform Tableau. *Pseudocode*, 9(1), 25–32. <https://doi.org/10.33369/pseudocode.9.1.25-32>
- Ainun, N., Rismayanti, & Lestari, D. Y. (2021). Implementasi Model JST Dalam Menentukan Bantuan Langsung Tunai Menggunakan Algoritma Multilayer Perceptron Pada Desa Karang Anyar Kec. Aek Kuo. *ProsidingSNASTIKOM: Seminar Nasional Teknologi Informasi & Komunikasi*, 320–325.
- Berka, P., & Bruha, I. (1998). Discretization and grouping: Preprocessing steps for data mining. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1510, 239–245. <https://doi.org/10.1007/bfb0094825>
- Christiawan, G. Y., Putra, R. A., Sulaiman, A., Poerbaningtyas, E., & Putri Listio, S. W. (2023). Penerapan Metode Convolutional Neural Network (CNN) Dalam Mengklasifikasikan Penyakit Daun Tanaman Padi. *J-Intech*, 11(2), 294–306. <https://doi.org/10.32664/j-intech.v11i2.1006>
- Faiza, I. M., Gunawan, G., & Andriani, W. (2022). Tinjauan Pustaka Sistematis: Penerapan Metode Machine Learning untuk Deteksi Bencana Banjir. *Jurnal Minfo Polgan*, 11(2), 59–63. <https://doi.org/10.33395/jmp.v11i2.11657>
- Gulo, S. H., Lubis, A. H., Informatika, T., Teknik, F., & Area, U. M. (2024). Penerapan Multi-Layer Perceptron untuk Mengklasifikasi Penduduk Kurang Mampu. 4(2), 51–59.
- Hardoni, A., & Rini, D. P. (2020). Integrasi Pendekatan Level Data Pada Logistic Regression Untuk Prediksi Cacat Perangkat Lunak. *JIKO (Jurnal Informatika Dan Komputer)*, 3(2), 101–106. <https://doi.org/10.33387/jiko.v3i2.1734>
- Hardoni, A., Rini, D. P., & Sukemi, S. (2021). Integrasi SMOTE pada Naive Bayes dan Logistic Regression Berbasis Particle Swarm Optimization untuk Prediksi Cacat Perangkat Lunak. *Jurnal Media Informatika Budidarma*, 5(1), 233. <https://doi.org/10.30865/mib.v5i1.2616>
- Hari Agus Prastyo, E., Suhartono, S., Faisal, M., Yaqin, M. A., & Firdaus, R. A. J. (2024). Naive Bayes Classification Untuk Prediksi Cacat Perangkat Lunak. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 9(2), 782–791. <https://doi.org/10.29100/jupi.v9i2.5508>
- 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. <https://doi.org/10.26760/mindjournal.v7i1.51-60>
- Muhamad, F. P. B., Siahaan, D. O., & Faticah, C. (2018). Software Fault Prediction Using Filtering Feature Selection in Cluster-Based Classification. *IPTEK Journal of Proceedings Series*, 4(1), 59. <https://doi.org/10.12962/j23546026.y2018i1.3508>
- Pambudi, H. K., Kusuma, P. G. A., Yulianti, F., & Julian, K. A. (2020). Prediksi Status Pengiriman Barang Menggunakan Metode Machine Learning. *Jurnal Ilmiah Teknologi Infomasi Terapan*, 6(2), 100–109. <https://doi.org/10.33197/jitter.vol6.iss2.2020.396>
- Prasetyo, R., Nawawi, I., Fauzi, A., & Ginabila, G. (2021). Komparasi Algoritma Logistic Regression dan Random Forest pada Prediksi Cacat Software. *Jurnal Teknik Informatika UNIKA Santo Thomas*, 06(Siringoringo 2017), 275–281. <https://doi.org/10.54367/jtiust.v6i2.1522>
- Purnama, I. N. (2021). Perbandingan Klasifikasi Website Secara Otomatis Menggunakan Metode Multilayer Perceptron dan Naive Bayes. *Jurnal Sistem Komputer Dan Informatika (JSON)*, 2(2), 155–161. <https://doi.org/10.30865/json.v2i2.2703>



- Puteri, A. N., Arizal, A., & Achmad, A. D. (2021). Feature Selection Correlation-Based pada Prediksi Nasabah Bank Telemarketing untuk Deposito. *MATRIK: Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 20(2), 335–342. <https://doi.org/10.30812/matrik.v20i2.1183>
- Rasna, & Matdoan, Moh. R. I. (2022). Metode Bayesian dan Multilayer Perceptron dalam Mengklasifikasi Diabetes Mellitus. *Jurnal Sistim Informasi Dan Teknologi*, 4, 82–86. <https://doi.org/10.37034/jsisfotek.v4i2.132>
- Sihombing, P. R., & Yuliati, I. F. (2021). Penerapan Metode Machine Learning dalam Klasifikasi Risiko Kejadian Berat Badan Lahir Rendah di Indonesia. *MATRIK: Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 20(2), 417–426. <https://doi.org/10.30812/matrik.v20i2.1174>
- Sugiono, Taufik, A., & Faizal Amir, R. (2020). Penerapan Penerapan Teknik Pso Over Sampling Dan Adaboost J48 Untuk Memprediksi Cacat Software. *Jurnal Responsif: Riset Sains Dan Informatika*, 2(2), 198–203. <https://doi.org/10.51977/jti.v2i2.249>
- Wintana, D. (2020). Integrasi Metode Diskritisasi Dan Gain Ratio Pada Prediksi Cacat Perangkat Lunak Berbasis Naive Bayes. Tesis. *Repository Nusa Mandiri*, 1–48.