

# EVALUASI KINERJA ALGORITMA *MACHINE LEARNING* (ML) MENGGUNAKAN SELEKSI FITUR PADA KLASIFIKASI DIABETES

Agus Wantoro<sup>1\*</sup>, Zulkifli<sup>2</sup>, Aviv Fitria Yulia<sup>3</sup>, Dwi Yana Ayu<sup>4</sup>, Syazili Mustofa<sup>5</sup>

<sup>1,2,3,4</sup>Jurusan Teknik Informatika, Fakultas Teknologi dan Informatika, Universitas Aisyah Pringsewu, Indonesia

<sup>5</sup>Jurusan Pendidikan Dokter, Fakultas Kedokteran, Universitas Lampung, Indonesia

\*<sup>1</sup>aguswantoro@aisyahuniversity.ac.id, <sup>2</sup>zulkifli@aisyahuniversity.ac.id, <sup>3</sup>avivfitriayulia@gmail.com,

<sup>4</sup>dwiyana@aisyahuniversity.ac.id, <sup>5</sup>syazilimustofa.dr@gmail.com

## Abstrak

*Diabetes Mellitus* (DM) merupakan salah satu penyakit kronis yang prevalensinya terus meningkat secara global, termasuk di Indonesia. Deteksi dini dan diagnosis yang akurat sangat penting untuk mencegah komplikasi serius. Dalam beberapa tahun terakhir, pendekatan berbasis *Machine Learning* (ML) telah banyak digunakan untuk meningkatkan akurasi prediksi diabetes. Salah satu dataset yang sering digunakan dalam penelitian ini adalah Pima Indians Diabetes Dataset (PIDD). Dataset ini memiliki delapan fitur dan satu kelas. Tantangan utama dalam pemodelan ML untuk prediksi adalah adanya fitur yang tidak relevan dalam *dataset*, yang dapat menurunkan kinerja model. Kami menggunakan pendekatan seleksi fitur teknik *Information Gain* (IG) dan *Gain Ratio* (GR). Hasil eksperimen seleksi fitur menggunakan IG didapatkan empat fitur yang memiliki bobot >0.05 yaitu Glucose Plassma (0.190), BMI (0.074), Age (0.072), dan Insulin (0.059). Namun hasil yang berbeda ketika menggunakan teknik GR yaitu Glucose Plassma (0.986), BMI (0.086), Age (0.078), Pregnancies (0.051). Hasil seleksi fitur dan semua fitur digunakan untuk menguji algoritma ML seperti Naive Bayes, J48, AdaBoost, Random Tree, Random Forest, dan Super Vector Machine (SVM). Hasil evaluasi kinerja algoritma ML menunjukkan algoritma SVM memiliki kinerja terbaik menggunakan semua fitur PIDD. Temuan ini berbeda dengan penelitian lain yang menggunakan seleksi fitur justru meningkatkan kinerja algoritma ML. Selain itu, kami melakukan evaluasi terhadap waktu eksekusi model. Kami menemukan bahwa algoritma Naïve Bayes dan Random Tree memiliki waktu komputasi terbaik. Temuan ini memberikan gambaran umum tentang kemampuan ML untuk memprediksi diabetes menggunakan seleksi fitur yang dihasilkan oleh teknik IG dan GR maupun tanpa seleksi fitur.

**Kata kunci** : Algoritma Machine Learning, Klasifikasi, Seleksi Fitur, Diabetes.

## 1 Pendahuluan

*Diabetes Mellitus* (DB) merupakan salah satu penyakit kronis yang prevalensinya terus meningkat secara global, termasuk di Indonesia. Deteksi dini dan diagnosis yang akurat sangat penting untuk mencegah komplikasi serius yang dapat ditimbulkan oleh penyakit ini (Ibrahim & Shiba, 2019). Dalam beberapa tahun terakhir, pendekatan berbasis *Machine Learning* (ML) telah banyak digunakan untuk meningkatkan akurasi prediksi diabetes (Guan et al., 2024). Dataset yang sering digunakan dalam penelitian ini adalah *Pima Indians Diabetes Dataset* (PIDD), yang berisi data medis dari wanita keturunan Pima Indian berusia di atas 21 tahun.

Namun, tantangan utama dalam pemodelan ML untuk prediksi diabetes adalah adanya fitur yang tidak relevan atau *redundan* dalam *dataset*, yang dapat menurunkan kinerja model (Miao et al., 2025). Oleh karena itu, teknik seleksi fitur menjadi krusial untuk meningkatkan akurasi dan efisiensi model. Berbagai metode seleksi fitur telah dikembangkan, termasuk metode filter seperti *Chi-Squared*, metode wrapper seperti *Recursive Feature Elimination* (RFE), dan metode *embedded* seperti *Lasso Regression*. Sebuah studi menunjukkan bahwa

penerapan RFE pada PIDD dapat meningkatkan akurasi model hingga 78,2%, dibandingkan dengan 75% tanpa seleksi fitur (Setiawan et al., 2024).

Selain itu, kombinasi antara seleksi fitur dan algoritma klasifikasi tertentu dapat menghasilkan kinerja yang lebih baik. Misalnya, model *RFE-Gated Recurrent Unit* (RFE-GRU) menunjukkan akurasi hingga 90,7% dalam klasifikasi diabetes menggunakan PIDD. Pendekatan lain menggunakan teknik *ensemble* seperti *XGBoost* dan *Gradient Boosting*, yang dikombinasikan dengan seleksi fitur, telah mencapai akurasi hingga 100% dalam beberapa studi (Shams et al., 2025)

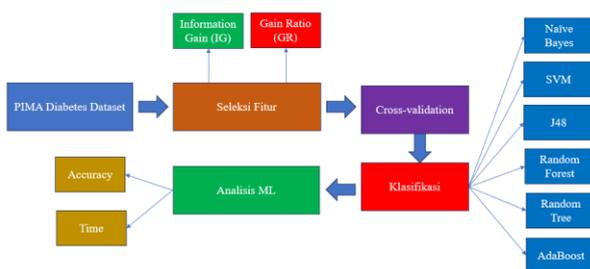
Meskipun berbagai penelitian telah dilakukan, masih terdapat kebutuhan untuk studi komprehensif yang membandingkan berbagai algoritma klasifikasi dengan pendekatan seleksi fitur yang berbeda pada PIDD. Penelitian semacam ini penting untuk mengidentifikasi kombinasi metode yang paling efektif dalam meningkatkan akurasi prediksi diabetes, serta untuk memahami pengaruh masing-masing teknik terhadap kinerja model

Dalam penelitian ini, kami ingin membandingkan kinerja algoritma ML seperti *Naive Bayes*, *J48*, *AdaBoost*, *Random Tree*, *Random Forest*, dan *Support Vector Machine* (SVM) dengan teknik

seleksi fitur. Pada ML, metode klasifikasi dapat membantu pakar dalam mengidentifikasi penyakit lebih akurat, efektif dan cepat untuk memberikan (Ratna Septia Devi et al., 2024). Metode ML akan dikombinasi dengan metode seleksi fitur seperti IG dan GR. Dalam studi ini, fitur dipilih ketika nilai bobot ( $w > 0,05$ ). Nilai ini sering kali diperlukan dan digunakan dalam studi yang memerlukan akurasi yang baik pada tingkat yang lebih rendah (Yang et al., 2020). Temuan penelitian akan memberikan gambaran umum tentang kemampuan pendekatan ML untuk memprediksi diabetes menggunakan fitur yang dihasilkan oleh teknik seleksi fitur maupun tanpa seleksi fitur pada dataset PIDD

## 2 Metode

Bagian ini menguraikan prosedur yang diikuti saat melakukan penelitian. Tahap penelitian diawali dengan pengumpulan data. Sebelum data dimasukkan ke dalam model, perlu dilakukan *pra*-pemrosesan data. Pada tahap ini, data dibersihkan dan disesuaikan untuk diproses ke langkah berikutnya menggunakan pemilihan fitur IG dan GR. Tahap berikutnya adalah fitur yang dipilih akan diproses menjadi metode ML seperti Naive Bayes, J48, Random Tree, Random Forest, dan Support Vector Machine (SVM). Desain kerangka penelitian diilustrasikan pada Gambar 1.



Gambar 1. Desain kerangka penelitian

Penelitian ini menggunakan *dataset* PIMA Indians yang diambil dari [www.kaggle.com/uciml/pima-indians-diabetes-database](http://www.kaggle.com/uciml/pima-indians-diabetes-database). Dataset ini memiliki 768 record (500 *non-diabetic* dan 268 *diabetes*). Fitur-fitur yang digunakan dalam dataset PIMA Indians disajikan dalam Tabel 1.

### 2.1 Seleksi Fitur

Salah satu hal terpenting pada klasifikasi adalah menentukan fitur untuk mendapatkan hasil akurasi terbaik (Sulistiani et al., 2024). Kumpulan data yang digunakan dalam proses ML biasanya berisi fitur yang berlebihan dan tidak relevan, dan tidak meningkatkan akurasi (Wang et al., 2014), tidak memiliki efek pada model pembelajaran, dan bahkan dapat menurunkan kinerja model pembelajaran (Bashir et al., 2019), oleh karena itu fitur yang relevan harus dipilih. Sebelum dilakukan pemilihan fitur dan *pra*-proses, data telah dibersihkan dan direduksi menjadi atribut yang paling penting. Beberapa tahap menyusun metode tersebut yaitu pemilihan fitur, *pra*-proses, dan penerapan ML pada proses prediksi

Tabel 1. Fitur dan attribute dataset

Kode	Fitur	Tipe	Keterangan
f1	Pregnancies	Numeric	Jumlah pregnancies
f2	Glucose Plasma	Numeric	Kadar glukosa plasma dua jam setelah mengonsumsi glukosa
f3	Blood Pressure	Numeric	Diastolic blood pressure (mm Hg)
f4	Skin	Numeric	Ketebalan lipatan kulit pada trisep lengan atas (mm)
f5	Insulin	Numeric	Kadar serum insulin dalam darah dua jam setelah tes glukosa (Ih/ml)
f6	BMI	Numeric	Body mass index kg/(Height in m) <sup>2</sup> , indeks yang digunakan untuk mengevaluasi berat relatif seseorang
f7	Pedigree	Numeric	Fungsi silsilah diabetes adalah nilai yang mengukur faktor risiko genetik berdasarkan riwayat keluarga diabetes.
f8	Age	Numeric	Usia pasien
f9	Class	Boolean	Kelas (Benar/Salah)

#### 2.1.1 Information-Gain (IG)

IG adalah perubahan entropi kelas dari keadaan sebelumnya ke keadaan saat nilai atribut muncul. Hal ini diterapkan untuk menunjukkan fitur-fitur yang relevan. *Decision Trees* adalah dasar dari metode ini. IG digunakan untuk seleksi atribut secara mendalam. Metode ini memiliki waktu yang lebih cepat dalam proses pemilihan fitur dibandingkan metode lainnya (Bhat & Dutta, 2022). Fitur dengan informasi terbanyak akan diberi peringkat tinggi. Langkah-langkah seleksi fitur menggunakan teknik IG sebagai berikut:

- Langkah 1: Melibatkan penghitungan entropi ( $H$ ) sebelum mengamati atribut  $A$  dan kelas  $C$ .
- Langkah 2: setelah atribut  $A$  diamati, lalu hitung entropi. Setelah. Fase pertama sangat penting karena menyediakan entropi yang dibutuhkan dalam fase berikutnya untuk memperoleh perolehan informasi.
- Langkah 3: penghitungan perolehan informasi. Selisih antara *entropi* sebelum mengamati karakteristik  $A$  dan perolehan informasi dari atribut  $A$ .
- Set fitur akhir yang akan digunakan untuk klasifikasi setelah menghitung perolehan dari setiap fitur dan menetapkan bobot

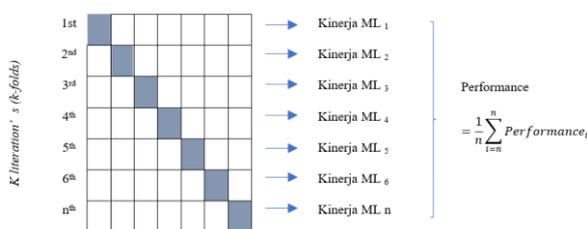
#### 2.1.2 Gain-Ratio (GR)

Setelah data dibagi, nilai entropi dari *subset* distribusi probabilitas dihitung menggunakan GR, yang menormalkan perolehan informasi (Sulistiani et al., 2024). Saat memilih fitur, GR mempertimbangkan jumlah dan ukuran dataset (Trabelsi et al., 2017). GR memodifikasi perolehan

informasi, yang mengurangi bias. GR memilih atribut berdasarkan jumlah dan ukuran cabang dengan memperhitungkan informasi inheren dari pemisahan

2.2 Cross-validation Classification

Klasifikasi merupakan salah satu bentuk teknik penambangan data yang sedang populer saat ini. Strategi ini menggunakan berbagai metode untuk menilai data yang tersedia guna menghasilkan prediksi diabetes (Sulistiani et al., 2024). Model klasifikasi akan divalidasi menggunakan k-fold cross-validation. Metode cross-validation umumnya digunakan untuk training set (Yan et al., 2022). Gambar 2 menampilkan jumlah k-fold cross-validation



Gambar 2. Prosedur k-fold validation

2.3 Performance Measurement

Hal ini digunakan untuk mengukur kinerja algoritma ML menggunakan perhitungan jumlah prediksi tepat yang dibagi seluruh jumlah data (Ohsaki et al., 2017). Perhitungan akurasi kinerja algoritma ML menggunakan persamaan (1)

$$Accuracy = \frac{\text{Semua perediksi benar}}{\text{Semua data}} \quad (1)$$

3 Hasil dan Pembahasan

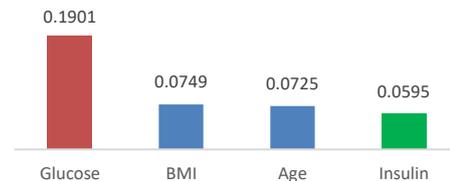
Kami menggunakan software WEKA (versi 3.9.2). Platform ini menyederhanakan konstruksi beberapa data teknik analisis. WEKA memiliki kemampuan mengategorikan, melakukan regresi, pengelompokan, menghilangkan fitur, membuat aturan asosiasi, dan menampilkan kumpulan data (Ibrahim & Shiba, 2019).

Pemilihan fitur menggunakan teknik IG dan GR untuk seleksi fitur yang berpengaruh terhadap klasifikasi berdasarkan nilai bobot. Langkah pertama metode pemilihan fitur adalah menghitung bobot setiap fitur. Selanjutnya, fitur akan diperingkat berdasarkan nilai bobot. Fitur yang memiliki bobot ( $w > 0.05$ ) akan dipilih untuk melakukan pengujian algoritma ML. Hasil pemilihan fitur ditampilkan pada Tabel 2.

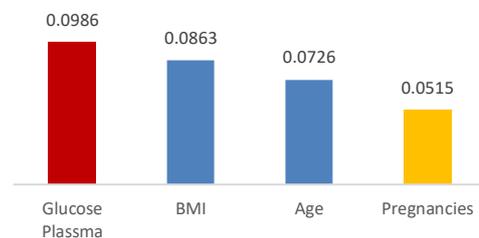
Tabel 2. Hasil seleksi fitur menggunakan IG dan GR

Information Gain (IG)		Gain Rasio (GR)	
Fitur	Bobot	Fitur	Bobot
Glucose Plassma (f2)	0.1901	Glucose Plassma (f2)	0.0986
BMI (f6)	0.0749	BMI (f6)	0.0863
Age (f8)	0.0725	Age (f8)	0.0726
Insulin (f5)	0.0595	Pregnancies (f1)	0.0515

Dari Tabel 2 terlihat bahwa teknik IG menghasilkan empat fitur terpilih dengan urutan bobot tertinggi yaitu Glucose Plassma (f2), BMI (f6), Age (f8), Insulin (f5). Sedangkan teknik GR menghasilkan fitur yang berbeda. Urutan fitur yang dihasilkan teknik GR yaitu Glucose Plassma (f2), BMI (f6), Age (f8), Pregnancies (f1). Gambar 3 dan 4 menampilkan urutan pembobotan fitur menggunakan IG dan GR.



Gambar 3. Hasil peringkat bobot fitur teknik IG



Gambar 4. Hasil peringkat bobot fitur teknik GR

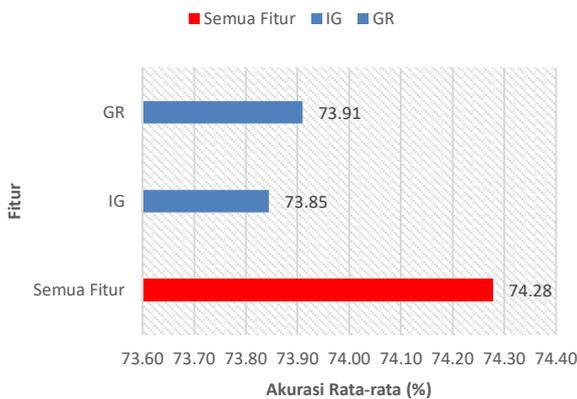
Dari teknik IG terdapat lima fitur yang memiliki nilai bobot kurang dari ( $w < 0.05$ ) yaitu f1, f3, f4, dan f7. Sedangkan dari teknik GR fitur yang akan dihilangkan yaitu f3, f4, f5, dan f7. Fitur-fitur tersebut akan dihilangkan dan tidak digunakan dalam proses klasifikasi. Hail ini untuk mendapatkan temuan berupa gambaran umum tentang kemampuan pendekatan ML untuk memprediksi diabetes menggunakan seleksi fitur

Pengujian kinerja klasifikasi, kami menerapkan validasi silang k-fold=10 karena hasil temuan kami menghasilkan nilai terbaik untuk setiap pengujian algoritma ML. Kami membandingkan algoritma klasifikasi Naive Bayes, J48, AdaBoost, Random Tree, Random Forest, dan Support Vector Machine (SVM). Hasil perbandingan kinerja akurasi berdasarkan semua fitur, pemilihan fitur menggunakan IG dan GR ditampilkan pada Tabel 3.

Tabel 3. Perbandingan akurasi algoritma ML

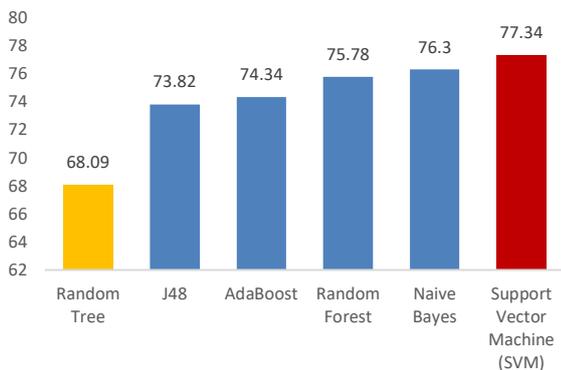
No	Algoritma	Semua Fitur (%)	IG (%)	GR (%)	Gap (Semua Fitur - IG)	Gap (Semua Fitur - GR)
1	Naive Bayes	76.3	75.39	75.52	0.91	0.78
2	SVM	77.34	76.04	76.04	1.3	1.3
3	AdaBoost	74.34	74.08	73.95	0.26	0.39
4	J48	73.82	74.34	74.86	-0.52	-1.04
5	Random Forest	75.78	73.17	74.08	2.61	1.7
6	Random Tree	68.09	70.05	69.01	-1.96	-0.92
<b>Rata-rata</b>		<b>74.28</b>	<b>73.85</b>	<b>73.91</b>	<b>0.43</b>	<b>0.37</b>

Berdasarkan Tabel 3, terlihat bahwa setelah melakukan pemilihan fitur menggunakan teknik IG dan GR justru kinerja algoritma ML mengalami penurunan sebesar 0.43% dan 0.37% kecuali algoritma J48 dan Random Tree menggunakan teknik IG mengalami peningkatan 0.52% dan 1.96%. Sedangkan menggunakan teknik GR mengalami peningkatan berbeda yaitu 1.04% dan 0.92%. Jika dibandingkan antara seleksi IG dan GR kami menemukan bahwa seleksi menggunakan GR memiliki akurasi yang lebih baik. Perbandingan rata-rata kinerja algoritma ML menggunakan semua fitur dan seleksi fitur ditampilkan pada Gambar 5.



Gambar 5. Perbandingan rata-rata akurasi algoritma ML menggunakan (a) semua fitur, (b) Information Gain (IG) dan (c) Gain Ratio (GR)

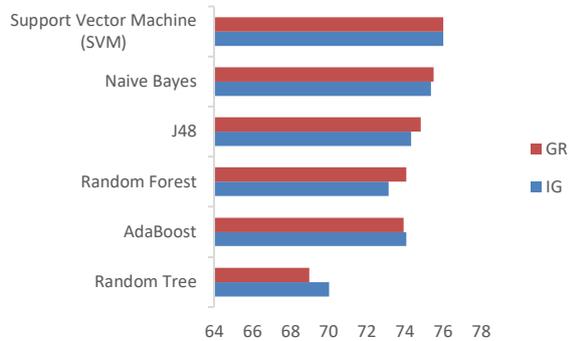
Berdasarkan Gambar 5 kami menemukan bahwa dalam kasus ini penggunaan teknik seleksi fitur justru menurunkan kinerja algoritma, hal ini menunjukkan penemuan yang berbeda dengan penelitian sebelumnya (Sulistiani et al., 2024). Hasil perbandingan akurasi algoritma ML menggunakan semua fitur ditampilkan pada Gambar 6.



Gambar 6. Perbandingan akurasi algoritma ML menggunakan semua fitur

Berdasarkan Gambar 6, terlihat bahwa algoritma ML SVM memiliki akurasi terbaik menggunakan semua fitur dan algoritma ML terburuk Random Tree. Temuan ini sejalan dengan penelitian sebelum (Trabelsi et al., 2017) bahwa SVM memiliki kinerja yang lebih unggul dalam hal klasifikasi dengan *class*

yang tidak seimbang dibandingkan dengan algoritma ML lain. Selanjutnya kami menampilkan perbandingan akurasi algoritma ML menggunakan seleksi fitur IG dan GR. Perbandingan algoritma ML, kami sajikan pada Gambar 7.



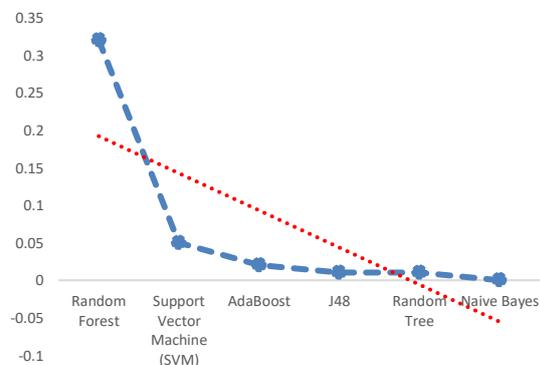
Gambar 7. Perbandingan akurasi ML menggunakan seleksi fitur IG dan GR

Berdasarkan Gambar 7, kami menemukan bahwa kombinasi algoritma ML dan seleksi fitur IG dan GR menampilkan hasil yang berbeda. Algoritma SVM dan seleksi IG atau GR menghasilkan akurasi terbaik dengan nilai akurasi sama. Sedangkan algoritma Naive Bayes dan seleksi fitur GR menjadi algoritma dengan kinerja terbaik ke-dua. Selanjutnya perbandingan akurasi rata-rata algoritma ML menggunakan semua fitur, seleksi IG dan GR yang ditampilkan pada Tabel 4.

Tabel 4. Perbandingan akurasi rata-rata algoritma ML

Algoritma	Akurasi rata-rata (%)
Support Vector Machine (SVM)	76.47
Naive Bayes	75.73
Random Forest	74.34
J48	74.34
AdaBoost	74.12
Random Tree	69.05

Berdasarkan Tabel 4, terlihat bahwa algoritma SVM memiliki akurasi terbaik dan algoritma terburuk Random Tree. Kami juga melakukan evaluasi waktu eksekusi model yang dibutuhkan algoritma ML yang kami tampilkan pada Gambar 7.



Gambar 8. Perbandingan waktu eksekusi model

Gambar 8 menampilkan kinerja algoritma ML dengan waktu komputasi tercepat yaitu Naive Bayes

dan terlama Random Forest. Temuan ini sejalan dengan penelitian sebelumnya (Sulistiani et al., 2024)

#### 4 Kesimpulan

Kami melakukan evaluasi kinerja teknik seleksi fitur Informasion Gain (IG) dan Gain Ratio (GR) pada Diabetes Dataset (PIDD). Hasil seleksi fitur menggunakan IG didapatkan empat fitur yang memiliki bobot tertinggi  $>0.05$  yaitu Glucose Plassma (0.190), BMI (0.074), Age (0.072), dan Insulin (0.059). Namun hasil ini berbeda teknik GR dengan hasil seleksi fitur yaitu Glucose Plassma (0.986), BMI (0.086), Age (0.078), Pregnancies (0.051).

Hasil seleksi fitur IG dan GR dan semua fitur digunakan untuk menguji algoritma ML. Hasil perbandingan kinerja algoritma ML ditemukan bahwa algoritma SVM memiliki kinerja terbaik dengan menggunakan semua fitur. Temuan ini berbeda dengan penelitian lain yang menggunakan seleksi fitur justru meningkatkan kinerja algoritma ML. Namun kombinasi algoritma ML dengan teknik seleksi fitur, kami menemukan bahwa teknik GR memiliki akurasi lebih baik

Selain itu kami melakukan evaluasi terhadap waktu eksekusi algoritma ML, kami menemukan bahwa algoritma Naïve Bayes dan Random Tree memiliki waktu komputasi terbaik. Temuan ini memberikan gambaran umum tentang kemampuan ML untuk memprediksi diabetes menggunakan seleksi fitur yang dihasilkan oleh teknik IG dan GR maupun tanpa seleksi fitur

Penelitian ini perlu dilanjutkan dengan melakukan evaluasi algoritma ML dengan mengukur variable lain seperti Precision, Recall, F1-Score untuk memahami pengaruh masing-masing teknik terhadap kinerja model

#### Daftar Pustaka:

- Bashir, S., Khan, Z. S., Khan, F. H., Anjum, A., & Bashir, K. (2019). Improving Heart Disease Prediction Using Feature Selection Approaches. *2019 16th International Bhurban Conference on Applied Sciences and Technology (IBCAST)*, 619–623. <https://doi.org/10.1109/IBCAST.2019.8667106>
- Bhat, P., & Dutta, K. (2022). A multi-tiered feature selection model for android malware detection based on Feature discrimination and Information Gain. *Journal of King Saud University - Computer and Information Sciences*, 34(10, Part B), 9464–9477. <https://doi.org/https://doi.org/10.1016/j.jksuci.2021.11.004>
- Guan, H., Wang, Y., Niu, P., Zhang, Y., Zhang, Y., Miao, R., Fang, X., Yin, R., Zhao, S., Liu, J., & Tian, J. (2024). The role of machine learning in advancing diabetic foot: a review. *Frontiers in Endocrinology*, 15(April), 1–15. <https://doi.org/10.3389/fendo.2024.1325434>
- Ibrahim, F. A., & Shiba, O. A. (2019). Data Mining : WEKA Software ( an Overview ). *Journal of Pure & Applied Sciences*, 18(3), 54–58. [www.Suj.sebhau.edu.ly](http://www.Suj.sebhau.edu.ly)
- Miao, F., Wu, Y., Yan, G., & Si, X. (2025). Dynamic multi-swarm whale optimization algorithm based on elite tuning for high-dimensional feature selection classification problems. *Applied Soft Computing*, 169, 112634. <https://doi.org/https://doi.org/10.1016/j.asoc.2024.112634>
- Ohsaki, M., Wang, P., Matsuda, K., Katagiri, S., Watanabe, H., & Ralescu, A. (2017). Confusion-matrix-based kernel logistic regression for imbalanced data classification. *IEEE Transactions on Knowledge and Data Engineering*, 29(9), 1806–1819. <https://doi.org/10.1109/TKDE.2017.2682249>
- Ratna Septia Devi, Triando Hamonangan Saragih, & Mohammad Reza Faisal. (2024). Seleksi Fitur Hybrid Grey Wolf Optimization dan Particle Swarm Optimization pada Distance Biased Naive Bayes untuk Klasifikasi Kanker Payudara. *Jurnal Informatika Polinema*, 10(2), 307–314. <https://doi.org/10.33795/jip.v10i2.4737>
- Setiawan, D., Nugraha, A., & Luthfiarta, A. (2024). Komparasi Teknik Feature Selection Dalam Klasifikasi Serangan IoT Menggunakan Algoritma Decision Tree. *Jurnal Media Informatika Budidarma*, 8(1), 83. <https://doi.org/10.30865/mib.v8i1.6987>
- Shams, M. Y., Tarek, Z., & Elshewey, A. M. (2025). A novel RFE-GRU model for diabetes classification using PIMA Indian dataset. *Scientific Reports*, 15(1), 1–22. <https://doi.org/10.1038/s41598-024-82420-9>
- Sulistiani, H., Syarif, A., Muludi, K., & Warsito. (2024). Performance evaluation of feature selections on some ML approaches for diagnosing the narcissistic personality disorder. *Bulletin of Electrical Engineering and Informatics*, 13(2), 1383–1391. <https://doi.org/10.11591/eei.v13i2.6717>
- Trabelsi, M., Meddouri, N., & Maddouri, M. (2017). A New Feature Selection Method for Nominal Classifier based on Formal Concept Analysis. *Procedia Computer Science*, 112, 186–194. <https://doi.org/10.1016/j.procs.2017.08.227>
- Wang, J., Zhou, S., Yi, Y., & Kong, J. (2014). An improved feature selection based on effective range for classification. *The Scientific World Journal*, 2014. <https://doi.org/10.1155/2014/972125>
- Yan, T., Shen, S.-L., Zhou, A., & Chen, X. (2022). Prediction of geological characteristics from shield operational parameters by integrating grid search and K-fold cross validation into stacking classification algorithm. *Journal of*

*Rock Mechanics and Geotechnical Engineering*, 14(4), 1292–1303.  
<https://doi.org/https://doi.org/10.1016/j.jrmge.2022.03.002>

Yang, Z., Ye, Q., Chen, Q., Ma, X., Fu, L., Yang, G., Yan, H., & Liu, F. (2020). Robust discriminant

feature selection via joint L2,1-norm distance minimization and maximization. *Knowledge-Based Systems*, 207, 106090.  
<https://doi.org/https://doi.org/10.1016/j.knosys.2020.106090>