

KOMPARASI KINERJA MODEL *NEURAL NETWORK* DAN *RANDOM FOREST* PADA DETEKSI PENYAKIT DIABETES

Anti Aisyah^{*,1)}, Ferly Ardhy²⁾, Panji Bintoro³⁾, Tahta Herdian Andhika⁴⁾

¹⁾Program Studi Teknik Informatika, Fakultas Teknologi dan Informatika, Universitas Aisyah Pringsewu
Jl. A Yani No. 1 A Tambak Rejo, Wonodadi, Kec. Pringsewu, Kabupaten Pringsewu, Lampung 35372

²⁾Program Studi Teknik Informatika, Fakultas Teknologi dan Informatika, Universitas Aisyah Pringsewu
Jl. A Yani No. 1 A Tambak Rejo, Wonodadi, Kec. Pringsewu, Kabupaten Pringsewu, Lampung 35372

³⁾Program Studi Rekayasa Perangkat Lunak, Fakultas Teknologi dan Informatika, Universitas Aisyah Pringsewu
Jl. A Yani No. 1 A Tambak Rejo, Wonodadi, Kec. Pringsewu, Kabupaten Pringsewu, Lampung 35372

⁴⁾Program Studi Teknik Informatika, Fakultas Teknologi dan Informatika, Universitas Aisyah Pringsewu
Jl. A Yani No. 1 A Tambak Rejo, Wonodadi, Kec. Pringsewu, Kabupaten Pringsewu, Lampung 35372
Email: ¹antiaisyahzenderica@gmail.com*

Abstract

In order to better understand how neural networks and random forest algorithms detect diabetes, this study will assess their performance. The necessity for trustworthy prediction methodologies, especially in the healthcare industry, is the driving force behind this study's foundation. Accuracy, precision, recall, F1-score, and AUC-ROC are important metrics, and the Pima Indian Diabetes dataset from Kaggle is used for this purpose.

Collecting and preparing data, normalizing it, and dividing it into training and testing subsets are all part of the study methodology. In order to rectify the data's class imbalance, the Synthetic Minority Oversampling Technique (SMOTE) was utilized to equalize the distribution of diabetes cases, both positive and negative. In contrast to the Random Forest model's use of an ensemble of decision trees to produce predictions, the Neural Network model was built with numerous hidden layers.

Applying SMOTE improved the performance of both models, according to the data. In comparison to the Neural Network's accuracy 82% and 61% F1-score, Random Forest's improvement reached 83%, recall and F1-score 72%. According to these results, data balancing greatly enhances the models' capacity to correctly detect positive and negative instances.

Keywords: *Diabetes, Smote, Early Detection, Neural Network, Random Forest*

Abstrak

Untuk lebih memahami bagaimana jaringan saraf dan algoritma Random Forest mendeteksi diabetes, studi ini akan menilai kinerjanya. Khususnya, industri perawatan kesehatan sangat membutuhkan metodologi prediksi yang tepercaya, yang menjadi dasar penelitian ini. Kaggle menyediakan dataset Pima Indian Diabetes yang digunakan untuk mengukur akurasi, presisi, recall, skor F1, dan AUC-ROC.

Metode penelitian mencakup pengumpulan dan prapemrosesan data, normalisasi, serta pembagian data menjadi data latih dan uji. Karena data menunjukkan ketidakseimbangan antar kelas, digunakan teknik SMOTE untuk menyeimbangkan distribusi antara pasien positif dan negatif diabetes. Model Neural Network dibangun dengan beberapa lapisan tersembunyi, sedangkan Random Forest menggunakan banyak pohon keputusan untuk menghasilkan prediksi.

Hasil menunjukkan bahwa penerapan SMOTE berhasil meningkatkan performa kedua model. Random Forest mencatat peningkatan Akurasi sebesar 83%, Recall dan F1-score hingga 72%, sementara Neural Network mencapai akurasi hingga 82%, F1-score sebesar 61%. Dengan demikian, penyeimbangan data terbukti meningkatkan kemampuan model dalam mengenali kasus positif dan negatif secara lebih akurat

Kata Kunci: *Diabetes, Smote, Deteksi Dini, Neural Network, Random Forest*



“Jurnal Teknologi dan Sistem Tertanam is licensed under a [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).”

1. Pendahuluan

Kadar gula darah tinggi yang disebabkan oleh penurunan produksi dan fungsi insulin merupakan ciri khas diabetes melitus, suatu kondisi kronis. Menurut Organisasi Kesehatan Dunia (WHO) dan Federasi Diabetes Internasional (IDF), prevalensi diabetes di seluruh dunia diproyeksikan akan meningkat, dari 8,4% pada tahun 2017 menjadi lebih dari 10% pada tahun 2045. Diperkirakan 28 juta kasus diabetes akan tercatat di Indonesia pada tahun 2045, sebuah angka yang terus meningkat dengan laju yang mengkhawatirkan. Mengingat diabetes dapat menyebabkan masalah kardiovaskular, gagal ginjal, dan gangguan penglihatan, penyakit ini menimbulkan ancaman yang signifikan bagi kesehatan masyarakat [1].

Komplikasi diabetes dapat dikurangi dan kualitas hidup pasien dapat ditingkatkan dengan identifikasi dini. Namun, metode tradisional berbasis uji laboratorium memerlukan biaya dan waktu yang tidak sedikit. Perkembangan teknologi komputasi membuka peluang pemanfaatan *machine learning* (ML) untuk mendukung proses diagnosis lebih cepat, akurat, dan efisien.

Berbagai penelitian sebelumnya menunjukkan efektivitas model ML dalam memprediksi penyakit kronis. Kasturi (2021) membuktikan bahwa *Multi-Layer Feedforward Neural Network* (MLFNN) mampu mencapai akurasi 92% dalam mendeteksi diabetes menggunakan dataset Pima Indian Diabetes. Zulkifli et al. (2020) melakukan evaluasi beberapa algoritma seperti *Neural Network*, *Random Forest*, dan SVM, dengan hasil bahwa SVM memberikan akurasi lebih tinggi dibanding metode lainnya[2]. Sementara itu, Khan et al. (2023) menekankan kekuatan kekuatan *Random Forest* dalam menghasilkan prediksi stabil dan transparan, terutama ketika dipadukan dengan *Explainable AI*[3].

Meskipun demikian, sebagian besar penelitian masih membandingkan banyak algoritma secara umum tanpa memberikan analisis mendalam pada dua algoritma populer, yaitu *Neural Network* (NN) dan *Random Forest* (RF). Padahal, keduanya memiliki karakteristik berbeda: NN unggul dalam mempelajari pola non-linear yang kompleks, sementara RF lebih mudah diinterpretasikan dan relatif tahan terhadap *overfitting*. Hal ini menimbulkan pertanyaan, algoritma mana yang lebih optimal dalam mendukung deteksi dini diabetes.

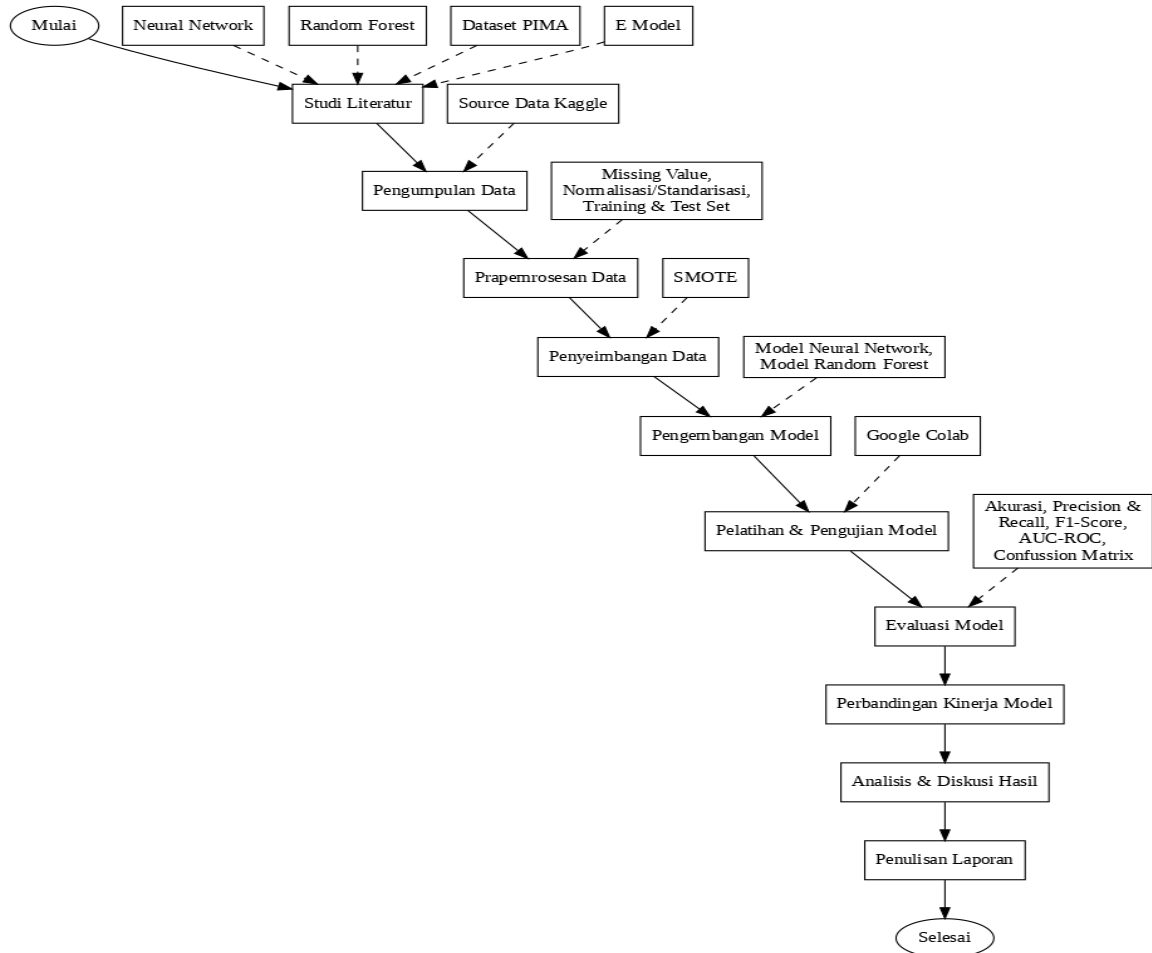
Selain itu, tantangan utama pada dataset medis adalah ketidakseimbangan kelas (*imbalanced dataset*). Jumlah pasien dengan diabetes jauh lebih sedikit dibanding pasien tanpa diabetes. Jika tidak ditangani, model cenderung bias pada kelas mayoritas, sehingga kasus positif diabetes sering tidak terdeteksi. Oleh karena itu, penelitian ini menerapkan *Synthetic Minority Oversampling Technique* (SMOTE) untuk menyeimbangkan distribusi data, dengan harapan dapat meningkatkan kinerja model dalam mendeteksi kasus positif[4].

Berdasarkan latar belakang tersebut, rumusan masalah dalam penelitian ini mencakup bagaimana kinerja algoritma *Neural Network* (NN) dan *Random Forest* (RF) dalam mendeteksi diabetes melitus menggunakan data medis, algoritma mana yang menunjukkan performa terbaik berdasarkan metrik evaluasi seperti akurasi, precision, recall, dan F1-score, serta sejauh mana penerapan *Synthetic Minority Oversampling Technique* (SMOTE) mampu meningkatkan kinerja kedua algoritma dalam mengatasi permasalahan ketidakseimbangan kelas pada dataset diabetes[5].

Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja algoritma *Neural Network* (NN) dan *Random Forest* (RF) dalam mendeteksi diabetes melitus, mengevaluasi algoritma yang memberikan performa terbaik berdasarkan metrik evaluasi yang digunakan, serta mengkaji pengaruh penerapan *Synthetic Minority Oversampling Technique* (SMOTE) terhadap peningkatan kinerja model dalam menghadapi permasalahan ketidakseimbangan kelas pada dataset medis[6].

2. Metode Pengumpulan Data

Metode pengkolektifan data yang dipakai yaitu data sekunder publik dari *Pima Indian Diabetes Dataset* yang didapatkan melalui platform *Kaggle* melalui repositori <https://www.Kaggle.com/datasets/uciml/pima-indians-diabetes-database>. Dataset ini dikembangkan oleh *National Institute of Diabetes and Digestive and Kidney Diseases* dan terdiri dari 768 data pasien, yang memuat delapan variabel medis sebagai fitur input serta satu variabel target yang menunjukkan status diabetes.



Gambar 1. Tahapan Penelitian

3. Metode Penelitian

Penelitian ini dilaksanakan dengan pendekatan kuantitatif eksperimental yang berfokus pada penerapan algoritma *machine learning* untuk deteksi penyakit diabetes. Alur penelitian meliputi beberapa tahapan, yaitu pengumpulan dataset, prapemrosesan data, pembagian dataset, implementasi model, serta evaluasi hasil.

A. Pengumpulan Data

Studi ini menggunakan Pima Indian Diabetes Dataset, yang awalnya dibuat oleh National Institute of Diabetes and Digestive and Kidney Diseases (NIDDK) dan kini tersedia di platform Kaggle. Struktur data yang konsisten dan faktor medis yang relevan dalam dataset ini menjadikannya ideal untuk studi yang bertujuan memprediksi diabetes.

Rekam medis pasien individu yang berkaitan dengan faktor risiko diabetes terwakili dalam dataset ini, yang terdiri dari 768 sampel pasien perempuan berusia minimal 21 tahun. Kami menargetkan variabel status diabetes, yang dapat bernilai 0 (tidak menderita diabetes) atau 1 (diabetes). Sebanyak 268 pasien (34,9%) ditemukan menderita diabetes, sementara 500 pasien (65,1%) ditemukan tidak menderita diabetes sama sekali. Proses pemodelan sangat terhambat oleh ketidakseimbangan ini.

Tabel 1. Dataset

Variabel	Deskripsi	Satuan/ Skala
<i>Pregnancies</i>	Jumlah kehamilan yang pernah dialami	Integer
<i>Glucose</i>	Konsentrasi glukosa plasma (2 jam dalam tes toleransi glukosa oral)	mg/dL
<i>Blood Pressure</i>	Tekanan darah diastolik	mmHg
<i>Skin Thickness</i>	Ketebalan lipatan kulit triceps	mm
<i>Insulin</i>	Konsentrasi insulin serum 2 jam	μ U/mL
<i>BMI</i>	Indeks Massa Tubuh (berat badan/tinggi ²)	kg/m ²
<i>Diabetes Pedigree Function</i>	Indikator probabilitas diabetes berdasarkan riwayat keluarga	Skala numerik
<i>Age</i>	Usia pasien	Tahun
<i>Outcome</i>	Status diabetes (0 = negatif, 1 = positif)	Biner

Tabel 1 menyajikan deskripsi dataset yang digunakan dalam penelitian ini, yaitu Pima Indian Diabetes Dataset. Dataset tersebut terdiri dari 768 data pasien perempuan berusia minimal 21 tahun, dengan delapan variabel medis sebagai fitur input dan satu variabel target sebagai label kelas. Variabel input meliputi *Pregnancies* (jumlah kehamilan), *Glucose* (kadar glukosa plasma), *Blood Pressure* (tekanan darah diastolik), *Skin Thickness* (ketebalan lipatan kulit), *Insulin* (kadar insulin serum), *Body Mass Index (BMI)*, *Diabetes Pedigree Function* (riwayat genetik diabetes), dan *Age* (usia). Variabel target menunjukkan status diabetes pasien, dengan nilai 0 merepresentasikan pasien non-diabetes dan nilai 1 merepresentasikan pasien diabetes. Informasi pada tabel ini menjadi dasar dalam proses prapemrosesan, pemodelan, dan evaluasi kinerja algoritma Neural Network dan Random Forest[7].

B. Prapemrosesan Data

Tahap prapemrosesan dilakukan agar dataset siap digunakan dalam pemodelan. Langkah pertama adalah pembersihan data, yaitu mengganti nilai nol yang tidak realistis pada variabel seperti *Glucose*, *Blood Pressure*, *Skin Thickness*, dan *Insulin* dengan nilai median masing-masing variabel. Selanjutnya dilakukan normalisasi memakai metode *Min-Max Scaling* ke rentang [0,1] agar seluruh variabel berada pada skala yang sama dan dapat diproses optimal oleh model[8].

Menghadapi masalah ketidakseimbangan kelas, penelitian ini memakai metode *SMOTE* untuk menambah data sintesis pada kelas minoritas. Dengan demikian, distribusi data antara pasien diabetes dan non-diabetes menjadi lebih seimbang sehingga model dapat menghasilkan prediksi yang lebih adil dan akurat.

C. Pembagian Dataset

Set data dibagi menjadi set pelatihan dan set uji setelah prapemrosesan. Set pelatihan menerima 80% data dan set uji 20%. Pemecahan acak dilakukan untuk memastikan data tetap representatif. Data pelatihan digunakan untuk membangun model, sementara data uji digunakan untuk menilai kemampuan model dalam menggeneralisasi data baru yang belum pernah dilihat sebelumnya.

Tabel 2. Pembagian Dataset

Jenis Dataset	Jumlah Data	Persentase
Data Latih	614	80%
Data Uji	154	20%

D. Penyeimbang Data (*SMOTE*)

Dalam penelitian ini, pendekatan yang digunakan untuk menyeimbangkan distribusi kelas adalah *SMOTE*. Teknik ini menghasilkan data sintetis tambahan pada kelas minoritas dengan memanfaatkan kesamaan karakteristik fitur terhadap sejumlah tetangga terdekatnya. Dengan cara ini, jumlah data pada kelas minoritas dapat ditingkatkan tanpa harus mengurangi data dari kelas mayoritas[9].

Sebelum dilakukan penyeimbangan menggunakan *SMOTE*, model menunjukkan ketidakseimbangan performa, terutama pada metrik *Recall* dan *F1-score*, yang mencerminkan ketidakmampuan model dalam mendeteksi kelas minoritas (positif diabetes). Meskipun akurasi tergolong cukup tinggi, model cenderung bias terhadap kelas mayoritas, sehingga banyak kasus positif yang tidak terdeteksi.

Setelah penerapan *SMOTE*, distribusi data antar kelas menjadi seimbang dan menghasilkan peningkatan yang signifikan pada performa model. *Recall* dan *F1-score* pada kedua model meningkat, khususnya pada *Random Forest* yang mencapai *Recall* dan *F1-score* sebesar 72%, dibandingkan sebelumnya yang lebih rendah. *Neural Network* juga menunjukkan perbaikan dengan *F1-score* naik menjadi 61%. Hasil ini membuktikan bahwa *balancing* data berdampak langsung pada kemampuan model dalam mengenali kasus-kasus positif secara lebih akurat dan adil.

E. Implementasi Model Machine Learning

Pada tahap ini, dua algoritma *machine learning* digunakan untuk membangun model prediksi, yaitu *Neural Network* (NN) dan *Random Forest* (RF)

Model *Neural Network* dibangun menggunakan arsitektur sederhana dengan 8 neuron pada input layer sesuai jumlah atribut, satu *hidden layer* dengan 64 neuron berfungsi aktivasi ReLU, serta dropout sebesar 0,4 untuk mencegah *overfitting*. Pada output layer digunakan “1 neuron dengan fungsi aktivasi sigmoid untuk menghasilkan klasifikasi biner. Model dilatih menggunakan *optimizer Adam* dengan *binary crossentropy* sebagai fungsi *loss*.”

Model *Random Forest* dibangun dengan 100 pohon keputusan (*n_estimators* = 100) menggunakan teknik *bagging*. Setiap pohon dilatih pada subset data yang berbeda, kemudian hasilnya digabungkan dengan metode voting untuk menghasilkan prediksi akhir. Algoritma ini dipakai dikarenakan bisa menangani variabel numerik secara baik serta relatif tahan terhadap *overfitting*[2].

Pada proses pelatihan model, *Neural Network* dilatih menggunakan parameter epoch sebanyak 100 iterasi dengan batch size sebesar 32, yang dipilih untuk mencapai keseimbangan antara stabilitas pembelajaran dan efisiensi komputasi. Penggunaan jumlah epoch yang cukup memungkinkan model mempelajari pola data secara optimal tanpa mengalami *overfitting*, sementara batch size yang moderat membantu mempercepat proses konvergensi. Sementara itu, model *Random Forest* dikonfigurasi dengan jumlah pohon (*n_estimators*) sebanyak 100 dan kedalaman maksimum pohon (*max_depth*) dibatasi hingga 10, guna mengontrol kompleksitas model dan menghindari *overfitting*. Penentuan parameter ini dilakukan untuk memastikan bahwa kedua model dilatih secara optimal dan adil, sehingga hasil perbandingan kinerja yang diperoleh bersifat objektif dan dapat dipertanggungjawabkan secara ilmiah.

F. Analisis Model

Untuk mengetahui seberapa baik *Neural Network* (NN) dan *Random Forest* (RF) dapat mengidentifikasi diabetes, analisis model dilakukan. Data uji yang telah dipisahkan sebelumnya digunakan untuk melakukan evaluasi.

Untuk mengevaluasi efikasi model, berbagai pengukuran digunakan, termasuk presisi, akurasi, recall, skor F1, dan AUC-ROC. Recall mengevaluasi kapasitas model untuk mendeteksi semua kasus diabetes secara akurat, akurasi mengukur proporsi total prediksi yang benar, dan presisi mencerminkan akurasi model dalam memprediksi pasien diabetes. Gambaran umum kapasitas model untuk membedakan antara kelas positif dan negatif diberikan oleh AUC-ROC, dan skor F1 digunakan untuk memeriksa keseimbangan antara recall dan presisi[10].

Selain itu, distribusi prediksi yang benar dan salah di kedua kelas diperiksa menggunakan matriks konfusi. Sebelum dan sesudah SMOTE diterapkan, hasil evaluasi kedua model dibandingkan untuk mengetahui algoritma mana yang lebih baik. Keuntungan dan kerugian masing-masing model untuk deteksi dini diabetes disorot dalam analisis ini.

Dataset Diabetes Pima Indian sangat kekurangan individu diabetes dibandingkan dengan pasien non-diabetes, yang menjadi kendala substansial bagi penelitian kami. Kapasitas model untuk mengidentifikasi kasus diabetes (kelas minoritas) berkurang akibat kondisi ini, yang menyebabkannya cenderung lebih condong ke kelas mayoritas[11].

Metode SMOTE, singkatan dari Synthetic Minority Oversampling, digunakan untuk mengatasi masalah ini. Tujuan SMOTE adalah menciptakan distribusi kelas yang lebih merata dengan memanfaatkan kesamaan antara data yang ada untuk menghasilkan data sintesis baru untuk kelas minoritas. Model pembelajaran mesin, terutama yang dilatih pada kelas positif (mereka yang menderita diabetes), mendapatkan manfaat dari data yang lebih proporsional dalam hal pembelajaran pola, ingatan, dan skor F1[12].

Hasil penelitian ini membuktikan bahwa penerapan *SMOTE* mampu meningkatkan performa model, khususnya dalam mengurangi kasus *false negative* yang berisiko tinggi pada deteksi dini penyakit diabetes.

4. Hasil dan Pembahasan

Dataset Pima Indian Diabetes dibagi menjadi 614 set data latih (80%) dan 154 set data uji (20%), seperti yang ditunjukkan pada Tabel 2. Baik model Random Forest maupun Neural Network dilatih pada data latih, kemudian efikasinya pada data baru diuji pada data uji. Kategorisasi ini memudahkan perbandingan generalisasi masing-masing metode.

Penyeimbangan data menggunakan SMOTE dilakukan pada dataset Pima Indian Diabetes sebelum dan sesudah. Hasil eksperimen penerapan algoritma Neural Network (NN) dan Random Forest (RF) disajikan di bagian ini. Berdasarkan data uji, evaluasi dilakukan dengan menggunakan metrik termasuk skor F1, akurasi, presisi, recall, dan AUC-ROC.

Penerapan SMOTE secara signifikan meningkatkan kinerja model, sebagaimana ditunjukkan oleh temuan, terutama pada pengukuran recall dan skor F1. Hal ini karena model tersebut lebih mampu mengidentifikasi kasus diabetes karena distribusi data terbagi lebih merata antara kelas positif (diabetes) dan negatif (non-diabetes).

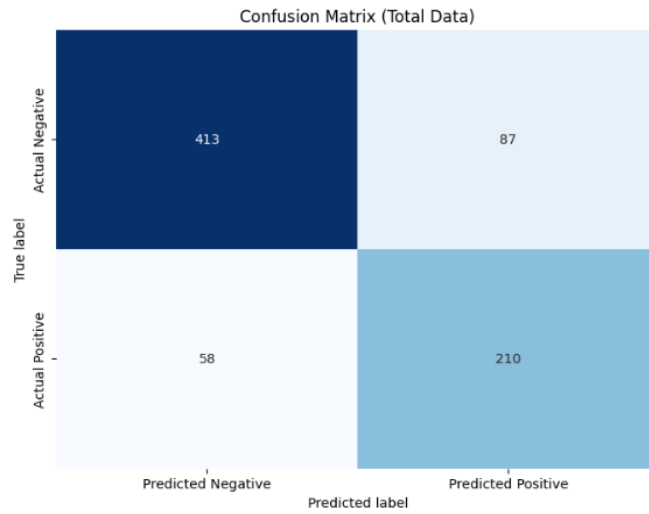
Tabel 3. Pembagian Dataset

Algoritma	Akurasi	Presisi	Recall	F1-score	AUC
<i>Neural Network</i>	82%	65%	57%	61%	86%
<i>Random Forest</i>	83%	72%	72%	72%	80%

Secara keseluruhan, model Random Forest mengungguli model Neural Network dalam hasil evaluasi. Dibandingkan dengan metode lain, Random Forest lebih berhasil dalam mendeteksi pasien diabetes, terbukti dari nilai skor F1, recall, akurasi, dan presisinya yang lebih baik. Selain itu, hasil analisis *Confusion Matrix* menunjukkan bahwa *Random Forest* menghasilkan jumlah kesalahan prediksi yang lebih sedikit dibandingkan dengan *Neural Network*, yang menandakan bahwa *Random Forest* lebih tepat dalam mengklasifikasikan pasien yang positif maupun negatif diabetes.

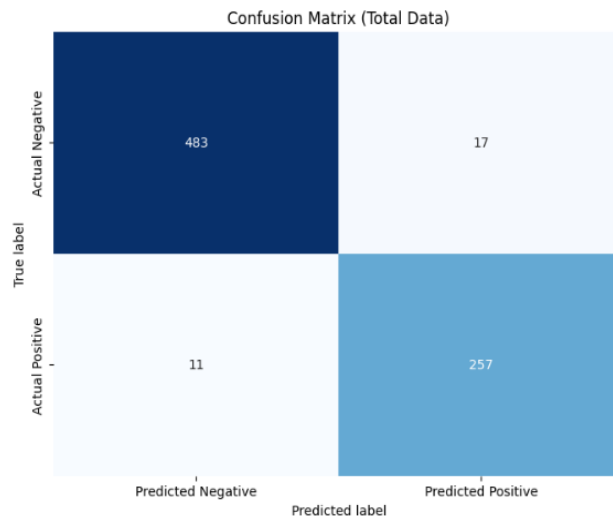
Selanjutnya, hasil evaluasi ditampilkan dalam bentuk tabel serta divisualisasikan melalui confusion matrix dan kurva ROC. Anda dapat menemukan ikhtisar tentang seberapa baik kinerja setiap model dalam tabel, dan representasi visual tentang keakuratan model dalam membedakan antara kelas positif dan negatif serta distribusi prediksinya dalam gambar.

Confusion matrix untuk keseluruhan data:
[[413 87]
[58 210]]




Gambar 1. *Confusion Matrix Neural Network*

Confusion matrix untuk keseluruhan data:
[[483 17]
[11 257]]




Gambar 2. *Confusion Matrix Random Forest*

Gambar 1 dan 2 menampilkan confusion matrix dari model *Neural Network* (NN) dan *Random Forest* (RF). Dari hasil tersebut terlihat bahwa penerapan *SMOTE* bisa menaikkan jumlah prediksi benar pada kelas positif (pasien diabetes). Sebelum *SMOTE*, kedua model cenderung bias terhadap kelas negatif, sehingga banyak kasus diabetes yang tidak terdeteksi (*false negative*). Setelah *SMOTE*, distribusi prediksi menjadi lebih seimbang, dengan peningkatan nilai *True Positive* (TP) yang signifikan. Hal ini menunjukkan bahwa penyeimbangan data berhasil membantu model dalam mengenali pasien diabetes dengan lebih akurat.



Gambar 3. ROC *Neural Network*



Gambar 4. ROC *Random Forest*

Pada Gambar 2, Anda dapat melihat kurva ROC Neural Network dan Random Forest. Akurasi model dalam mengklasifikasikan data sebagai positif atau negatif ditunjukkan oleh kurva ROC. Performa model meningkat seiring mendekati sudut kiri atas. Sebelum dan sesudah SMOTE, data menunjukkan bahwa Random Forest mengungguli Neural Network dalam hal area di bawah kurva (AUC). Hal ini semakin membuktikan bahwa Random Forest secara konsisten mengungguli Neural Network dalam membedakan antara individu diabetes dan non-diabetes, meskipun terdapat keterbatasan inheren yang disebabkan oleh arsitekturnya yang sederhana.

Hasil penelitian menunjukkan bahwa kedua algoritma mampu mendeteksi diabetes dengan lebih baik setelah menggunakan SMOTE, terutama dalam hal metrik recall dan skor F1. Hal ini menyoroti pentingnya penyeimbangan data ketika menangani kasus medis yang memiliki distribusi kelas yang tidak merata.

Performa Neural Network yang lebih rendah dibandingkan Random Forest dalam penelitian ini dapat disebabkan oleh beberapa faktor. Pertama, jumlah data yang relatif terbatas, yaitu hanya 768 sampel, kurang ideal untuk melatih model Neural Network secara optimal. Neural Network umumnya membutuhkan dataset yang besar agar mampu mempelajari pola kompleks secara stabil dan menghindari overfitting.

Kedua, arsitektur Neural Network yang digunakan dalam penelitian ini masih bersifat shallow network, yaitu hanya terdiri dari satu hidden layer. Arsitektur yang sederhana ini membatasi kemampuan model dalam menangkap hubungan non-linear yang lebih kompleks antar fitur medis. Akibatnya, kemampuan generalisasi model menjadi kurang optimal dibandingkan Random Forest.

Sebaliknya, Random Forest lebih cocok diterapkan pada dataset berukuran kecil hingga menengah karena mekanisme ensemble learning yang menggabungkan banyak pohon keputusan. Pendekatan ini membuat Random Forest lebih stabil, tahan terhadap overfitting, serta mampu menangani variasi data dengan lebih baik. Hal ini tercermin dari nilai recall dan F1-score Random Forest yang lebih tinggi, yang menunjukkan kemampuannya dalam mendeteksi kasus positif diabetes secara lebih akurat.

Dengan demikian, hasil penelitian ini mengindikasikan bahwa meskipun Neural Network memiliki potensi besar dalam memodelkan pola non-linear, pada kondisi dataset terbatas dan arsitektur jaringan yang sederhana, Random Forest menjadi pilihan yang lebih optimal untuk deteksi dini penyakit diabetes.

5. Kesimpulan

Dengan menggunakan dataset Pima Indian Diabetes, penelitian ini membandingkan akurasi algoritma NN dan RF dalam deteksi diabetes. Hasil penelitian menunjukkan bahwa kinerja kedua model meningkat pesat setelah menggunakan SMOTE, terutama dalam hal recall dan F1-score, yang menunjukkan bahwa model tersebut lebih baik dalam mengidentifikasi pasien diabetes.

Dibandingkan dengan Neural Network, Random Forest mengunggulinya dalam hal akurasi, recall, F1-score, dan area di bawah kurva (AUC). Hal ini menunjukkan bahwa NN masih memiliki keterbatasan dengan arsitektur minimal yang digunakan dalam penelitian ini, berbeda dengan RF, yang lebih robust dan andal dalam memberikan prediksi.

Dengan demikian, dapat disimpulkan bahwa penggunaan teknik penyeimbangan data seperti *SMOTE* serta pemilihan algoritma yang tepat sangat berpengaruh terhadap keberhasilan model *machine learning* dalam deteksi dini penyakit diabetes. Untuk penelitian selanjutnya, disarankan pengembangan *Neural Network* dengan arsitektur lebih kompleks (*deep learning*) serta penggunaan dataset yang lebih besar agar hasil yang diperoleh semakin optimal.

Daftar Pustaka

Journal Article

- [1] R. Mallik, P. Kar, H. Mulder, and A. Krook, "The future is here: an overview of technology in diabetes," *Diabetologia*, vol. 67, no. 10, pp. 2019–2026, Oct. 2024, doi: 10.1007/s00125-024-06235-z.
- [2] Z. Zulkifli, "Multi-Algorithm to Measure the Accuracy Level of Diabetes Status Prediction," *J. Appl. Data Sci.*, vol. 5, no. 2, pp. 736–746, May 2024, doi: 10.47738/jads.v5i2.250.
- [3] Dr. K. Kasturi, "Comparison of Machine Learning Models for Diabetes Prediction," *Int. J. Adv. Res. Sci. Commun. Technol.*, pp. 531–536, June 2024, doi: 10.48175/IJARSCT-19072.
- [4] S. Y. Rhee, J. M. Sung, S. Kim, I.-J. Cho, S.-E. Lee, and H.-J. Chang, "Development and Validation of a Deep Learning Based Diabetes Prediction System Using a Nationwide Population-Based Cohort," *Diabetes Metab. J.*, vol. 45, no. 4, pp. 515–525, July 2021, doi: 10.4093/dmj.2020.0081.
- [5] D. C. P. Buani, "Deteksi Dini Penyakit Diabetes dengan Menggunakan Algoritma Random Forest," *EVOLUSI J. Sains Dan Manaj.*, vol. 12, no. 1, June 2024, doi: 10.31294/evolusi.v12i1.21005.
- [6] L. Kopitar, P. Kocbek, L. Cilar, A. Sheikh, and G. Stiglic, "Early detection of type 2 diabetes mellitus using machine learning-based prediction models," *Sci. Rep.*, vol. 10, no. 1, p. 11981, July 2020, doi: 10.1038/s41598-020-68771-z.
- [7] M. S. Alzboon, M. Al-Batah, M. Alqaraleh, A. Abuashour, and A. F. Bader, "A Comparative Study of Machine Learning Techniques for Early Prediction of Diabetes," in *2023 IEEE Tenth International Conference on Communications and Networking (ComNet)*, Hammamet, Tunisia: IEEE, Nov. 2023, pp. 1–12. doi: 10.1109/ComNet60156.2023.10366688.
- [8] G. Anwar and N. N. Abdullah, "The impact of Human resource management practice on Organizational performance," *Int. J. Eng. Bus. Manag.*, vol. 5, no. 1, pp. 35–47, 2021, doi: 10.22161/ijebm.5.1.4.
- [9] H. Harwani, M. O. Khan, and A. Arora, "Prognostication of Diabetes using Random Forest," *Int. J. Comput. Appl.*, vol. 175, no. 29, pp. 40–43, Nov. 2020, doi: 10.5120/ijca2020920833.
- [10] I. Tasin, T. U. Nabil, S. Islam, and R. Khan, "Diabetes prediction using machine learning and explainable AI techniques," *Healthc. Technol. Lett.*, vol. 10, no. 1–2, pp. 1–10, Feb. 2023, doi: 10.1049/htl2.12039.
- [11] L. Alzubaidi *et al.*, "Review of deep learning: concepts, CNN architectures, challenges, applications, future directions," *J. Big Data*, vol. 8, no. 1, p. 53, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [12] Z. Mirikharaji *et al.*, "A survey on deep learning for skin lesion segmentation," *Med. Image Anal.*, vol. 88, p. 102863, Aug. 2023, doi: 10.1016/j.media.2023.102863.