

Perbandingan Inisialisasi Bobot Random dan Nguyen-Widrow Pada Backpropagation Dalam Klasifikasi Penyakit Diabetes

Widya Guswanti¹, Iis Afrianty², Elvia Budianita³, Fadhilah Syafria⁴
^{1,2,3,4}Teknik Informatika, Sains dan Teknologi, Universitas Islam Negeri Sultan Syarif Kasim Riau
Jl. HR. Soebrantas, Simpang Baru, Kota Pekanbaru, Riau, Indonesia

Info Artikel

Riwayat Artikel :

Received 2025-03-27

Revised 2025-04-25

Accepted 2025-04-29

Abstract - Diabetes is a metabolic disorder that occurs when the pancreas is unable to produce adequate amounts of insulin or the body has difficulty in utilizing it optimally, leading to potentially serious complications. Early diagnosis is very important to reduce the mortality rate due to these complications. This study uses the Backpropagation Neural Network (BPNN) method for diabetes classification, but to overcome the problem of slow convergence and the risk of getting stuck at a local minimum caused by random weight initialization, the Nguyen-Widrow weight initialization method is applied. The research data was obtained from the Kaggle dataset consisting of 768 data with 8 parameters. Model testing was conducted using 10-fold cross-validation, as well as exploring various numbers of neurons in the hidden layer and learning rate (lr). The results showed that weight initialization using the Nguyen-Widrow method was able to increase the accuracy of BPNN to 92.11% with a learning rate of 0.001 and 9 neurons in the hidden layer, compared to random weight initialization which only reached 89.91%. Overall, this research can contribute to the field of informatics by strengthening the development of artificial intelligence-based medical classification systems, especially in improving the accuracy and reliability of neural network models to support more effective and efficient disease diagnosis systems.

Keywords: Backpropagation Neural Network, Diabetes, Nguyen-Widrow, Artificial Neural Networks, Weight Optimization.

Corresponding Author:

Iis Afrianty

Email: iis.afrianty@uin-suska.ac.id



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstrak - Diabetes merupakan gangguan metabolik yang terjadi ketika pankreas tidak mampu menghasilkan insulin dalam jumlah yang memadai atau tubuh mengalami kesulitan dalam memanfaatkannya secara optimal, sehingga berpotensi menimbulkan komplikasi serius. Diagnosis dini sangat penting untuk menekan angka kematian akibat komplikasi tersebut. Penelitian ini menggunakan metode Backpropagation Neural Network (BPNN) untuk klasifikasi diabetes, namun untuk mengatasi masalah konvergensi lambat dan risiko terjebak pada minimum lokal yang disebabkan oleh inisialisasi bobot secara acak, diterapkan metode inisialisasi bobot Nguyen-Widrow. Data penelitian diperoleh dari dataset Kaggle yang terdiri dari 768 data dengan 8 parameter. Pengujian model dilakukan menggunakan 10-fold cross-validation, serta mengeksplorasi berbagai jumlah neuron dalam hidden layer dan learning rate (lr). Hasil penelitian menunjukkan bahwa inisialisasi bobot menggunakan metode Nguyen-Widrow mampu meningkatkan akurasi BPNN menjadi 92,11% dengan learning rate 0,001 dan 9 neuron pada hidden layer, dibandingkan dengan inisialisasi bobot acak yang hanya mencapai 89,91%. Secara keseluruhan, penelitian ini dapat berkontribusi dalam bidang informatika dengan memperkuat pengembangan sistem klasifikasi medis berbasis kecerdasan buatan, khususnya dalam meningkatkan akurasi dan keandalan model neural network untuk mendukung sistem diagnosis penyakit yang lebih efektif dan efisien.

Kata Kunci: Backpropagation Neural Network, Diabetes, Nguyen-Widrow, Jaringan Syaraf Tiruan.

I. PENDAHULUAN

Kemajuan teknologi komputer yang berkembang dengan cepat telah membawa pengaruh besar dalam berbagai bidang kehidupan [1]. Salah satu bidang teknologi yang mengalami kemajuan yang sangat pesat adalah kecerdasan buatan, yang lebih dikenal dengan istilah AI. AI memungkinkan sistem digital untuk menganalisis serta mengambil keputusan secara cerdas layaknya manusia [2]. Jaringan Syaraf Tiruan (JST) adalah suatu pendekatan paling umum diterapkan dalam AI. JST dirancang guna meniru mekanisme kerja otak manusia dalam mengolah informasi dan mengatasi berbagai persoalan yang kompleks [2], [3]. JST telah menjadi teknik komputasi yang populer dalam berbagai penerapan kasus, seperti peramalan, pengenalan pola, klasifikasi, dan optimasi [4], [5], [6]. Salah satu penerapan kasus yang banyak diteliti adalah klasifikasi penyakit, seperti klasifikasi diabetes yang dilakukan oleh [7].

Diabetes adalah penyakit metabolik serius yang terjadi ketika pankreas tidak mampu menghasilkan cukup insulin atau ketika tubuh tidak mampu menggunakan insulin yang diproduksi secara optimal [8], [9]. Gejala umum diabetes diantaranya yaitu *polidipsia*, *poliuria*, penurunan berat badan secara mendadak, kelelahan, kesemutan, rasa gatal, disfungsi ereksi pada pria, dan pandangan kabur [10], [11], [12]. Penyakit diabetes dapat menimbulkan berbagai komplikasi diantaranya kerusakan pada saraf, penyakit kardiovaskular, serta masalah

pada ginjal, mata, kaki, kulit dan bahkan memicu depresi [13]. Menurut informasi Organisasi Kesehatan Dunia (WHO), jumlah pengidap diabetes mengalami peningkatan yang signifikan serta diprediksi akan terus bertambah di era mendatang [14]. Sebagian besar kasus diabetes terjadi di negara-negara berpenghasilan rendah dan menengah, dengan penyakit ini menyebabkan sekitar 1,6 juta kematian setiap tahun [15]. Lebih lanjut, berdasarkan berdasarkan studi global yang dilakukan oleh NCD Risk Factor Collaboration menyatakan jumlah penderita diabetes pada tahun 2021 mencapai 529 juta orang dengan prevalensi global sebesar 6,1%. Studi tersebut juga memprediksi bahwa angka ini akan terus melonjak pada tahun 2050 hingga 1,3 miliar dengan prevalensi mencapai 9,8% secara global [16]. Diabetes kini termasuk dalam sepuluh penyebab utama kematian dan disabilitas di dunia [16]. Selain itu, diabetes juga memberikan beban ekonomi yang signifikan. *International Diabetes Federation* (IDF) mencatat bahwa total pengeluaran kesehatan global akibat diabetes mencapai 966 miliar dolar AS dan diperkirakan akan melampaui 1 triliun dolar AS pada tahun 2045 [17]. Mengingat tingginya angka prevalensi, risiko komplikasi serius, serta beban ekonomi yang ditimbulkan, maka diagnosis dini menjadi langkah penting dalam upaya menekan angka kejadian dan kematian akibat diabetes.

Salah satu pendekatan untuk meningkatkan diagnosis penyakit ini adalah dengan memanfaatkan perkembangan teknologi informasi, seperti JST. JST memiliki potensi besar untuk memperbaiki proses klasifikasi medis. *Backpropagation Neural Network* (BPNN) merupakan metode yang banyak diterapkan dalam JST dan dikenal efektif dalam menangani klasifikasi [6], [18], [19]. BPNN adalah algoritma pembelajaran terawasi yang mengubah bobot pada neuron lapisan tersembunyi dalam perceptron berlapis [20]. BPNN memiliki arsitektur yang terdiri dari lapisan input (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan output (*output layer*) [21]. Algoritma BPNN didasarkan pada tiga tahap, yaitu propagasi umpan maju (*feedforward*), propagasi mundur (*backward*) serta modifikasi bobot dan bias. Tahap *feedforward*, data input diproses dengan lapisan-lapisan jaringan untuk menghasilkan output berdasarkan bobot dan bias yang ada. Pada tahap *backward*, error dihitung dengan membandingkan output dengan target, lalu error ini digunakan untuk memperbarui bobot dan bias. Proses ini bertujuan untuk meminimalkan error sehingga jaringan dapat mempelajari pola dengan lebih akurat [22]. BPNN memiliki kemampuan dalam menangani masalah non-linear dan fleksibilitas dalam berbagai bidang, seperti klasifikasi data [19], [23].

Penelitian yang dilakukan oleh [24] dalam mengklasifikasikan citra daun herbal menggunakan BPNN menghasilkan akurasi 88,75%, menunjukkan bahwa metode ini efektif dalam mengenali pola pada citra daun herbal. Selanjutnya, penelitian dilakukan oleh [25] dalam mengklasifikasikan kerusakan mesin sepeda motor menggunakan metode BPNN memperoleh akurasi 81,61%. Selain itu, pada penelitian [26] mengenai klasifikasi status gizi remaja menggunakan metode BPNN menghasilkan akurasi sebesar 85,45%, menunjukkan potensi penerapannya dalam analisis data kesehatan masyarakat. Dan pada penelitian yang dilakukan oleh [7] dalam mengklasifikasikan penyakit diabetes menggunakan metode BPNN menghasilkan akurasi sebesar 80,75 %.


Berdasarkan penjabaran penelitian sebelumnya, telah membuktikan efektivitas metode BPNN dalam klasifikasi data dalam berbagai bidang. Namun, terdapat beberapa kelemahan utama BPNN yaitu konvergensi yang lambat dan risiko terjebak pada *local minimum*, sehingga dapat mengurangi efektivitas pelatihan. Kedua kelemahan tersebut dipengaruhi oleh pemilihan bobot awal yang dilakukan secara random [27]. Sebagai solusi terhadap permasalahan tersebut, penelitian ini akan mengimplementasikan metode inisialisasi bobot *Nguyen-Widrow* dalam diagnosis diabetes. Metode *Nguyen-Widrow* dirancang untuk mempercepat proses konvergensi dalam jaringan saraf tiruan dengan cara mengatur distribusi awal bobot agar lebih optimal sebelum proses pelatihan dimulai [18]. Pada penelitian [28] menunjukkan bahwa algoritma *Nguyen-Widrow* mampu meningkatkan kinerja *backpropagation* dalam mendiagnosis penyakit ginjal. Selain itu, penelitian yang dilakukan oleh [29] meneliti penggunaan metode *Nguyen-Widrow* dalam memprediksi kasus tuberkulosis menghasilkan akurasi sebesar 81,82% yang menunjukkan bahwa metode ini efektif digunakan. Selanjutnya, pada penelitian [30] juga menunjukkan metode *Nguyen-Widrow* dapat diterapkan secara efektif dalam memprediksi hasil produksi kedelai yang menghasilkan akurasi pelatihan sebesar 96,6% dan pengujian 96,5%. Dan pada penelitian [2] menunjukkan bahwa pengujian dengan nilai $(\alpha) = 20\%$ menghasilkan nilai MSE yang lebih kecil dengan metode *Nguyen-Widrow* dibanding metode random.

Penelitian ini berbeda dari penelitian sebelumnya, karena akan mengimplementasikan metode inisialisasi bobot *Nguyen-Widrow* pada BPNN dalam klasifikasi penyakit diabetes. Metode ini ditujukan untuk mengatasi kelemahan utama BPNN, yaitu konvergensi yang lambat dan risiko terjebak pada lokal minimum akibat pemilihan bobot awal secara acak sehingga diharapkan dapat meningkatkan akurasi klasifikasi.

II. METODE

Penelitian ini menerapkan metode *backpropagation* dengan inisialisasi bobot random dan *Nguyen-Widrow*. Serangkaian proses sistematis dilakukan untuk mengolah data, mulai dari pengumpulan data hingga memperoleh tingkat akurasi terbaik pada pengklasifikasian penyakit diabetes dengan *backpropagation*.

Pengimplementasian dilakukan dengan menggunakan *tools Google Colab* dan bahasa pemrograman *Python*. Tahapan penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

A. Pengumpulan Data

Penelitian ini menggunakan data sekunder yang diperoleh dari platform Kaggle melalui situs <https://www.kaggle.com/datasets/jamaltariqcheema/pima-indians-diabetes-dataset>. Dataset ini terdiri 768 data dan 8 parameter, dengan 500 data kategori non-diabetes dan 268 kategori diabetes. Dari distribusi ini diketahui bahwa data bersifat tidak seimbang. Pada tabel 1 dijelaskan dataset penyakit diabetes.

TABEL 1
DATASET DIABETES

Pregnancies	Glucose	Blood Pressure	Skin Thickness	Insulin	BMI	Diabetes Pedigree Function	Age	Outcome
6	148	72	35	0	33,6	0,627	50	1
1	85	66	29	0	26,6	0,351	31	0
8	183	64	0	0	23,3	0,672	32	1
1	89	66	23	94	28,1	0,167	21	0
0	137	40	35	168	43,1	2,288	33	1
5	116	74	0	0	25,6	0,201	30	0
3	78	50	32	88	31	0,248	26	1
...
1	126	60	32	169,5	30,1	0,349	47	1
1	93	70	31	102,5	30,4	0,315	23	0

B. Data Preprocessing

Data preprocessing adalah tahap dimana data mentah diolah menjadi format yang lebih terstruktur dan siap digunakan. Tujuan utama dari proses ini untuk meningkatkan kualitas data agar lebih mudah dipahami serta dapat dimanfaatkan secara optimal dalam analisis lanjutan. Tahapan ini mencakup:

1. Data cleaning

Data cleaning adalah tahapan perbaikan kesalahan dalam data untuk memastikan kualitasnya sebelum digunakan dalam analisis. Dalam proses *data cleaning*, dilakukan pengecekan terhadap *missing values* serta data duplikat guna menghindari bias dalam model.

2. Scalling

Pada proses *scalling* ini dilakukan pengukuran nilai fitur dari kumpulan data tertentu dalam rentang nilai yang ditentukan. Metode *scalling* yang diterapkan adalah *min-max normalization* yang mengubah data atribut menjadi skala 0 hingga 1. Persamaan (1) merupakan rumus yang digunakan untuk menghitung *min-max normalization*.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Keterangan:

X : Nilai asli data.

X' : Nilai data setelah normalisasi.

X_{min} : Nilai minimum dalam data.

X_{max} : Nilai maksimum dalam data.

C. Backpropagation Neural Network (BPNN)

BPNN adalah metode pembelajaran terawasi yang mengubah bobot pada neuron lapisan tersembunyi dalam perceptron berlapis [20]. Metode BPNN memiliki sebuah arsitektur yang terdiri atas tiga bagian utama yaitu *input layer*, *hidden layer*, dan *output layer* [21]. Algoritma BPNN didasarkan pada tiga tahap, yaitu propagasi umpan maju (*feedforward*), propagasi mundur (*backward*) serta modifikasi bobot dan bias [22]. Dalam menerapkan algoritma *backpropagation* terdapat beberapa langkah-langkah sebagai berikut:

1. Menentukan arsitektur jaringan *backpropagation*. Jumlah neuron di lapisan masukan disesuaikan dengan jumlah fitur yang terdapat dalam dataset. Sementara jumlah neuron di *output layer* tergantung pada jumlah kelas yang ingin diprediksi. Pada *hidden layer*, dilakukan eksperimen dengan jumlah neuron sebanyak 9, 12, dan 15 neuron, di mana pemilihan jumlah ini didasarkan pada Persamaan (2) [31]. Pemilihan 9, 12, dan 15 neuron bertujuan untuk mengobservasi kinerja model dengan kompleksitas jaringan yang bertingkat (rendah, menengah, tinggi).

$$i < m < 2i \quad (2)$$

Keterangan:

i = neuron *input*

m = neuron *hidden layer*

2. Menentukan parameter yang akan digunakan, seperti fungsi aktivasi, minimum eror, maksimum epoch serta *learning rate* (lr).
3. Menginisialisasi bobot random dan metode *Nguyen-Widrow*. Untuk inisialisasi dengan *Nguyen-Widrow* dilakukan dengan langkah sebagai berikut [32]:
 - a. Menentukan bilangan pada jarak antara (-0.1) hingga 1.0
 - b. Hitung nilai bobot mutlak menggunakan Persamaan (3).

$$\|V_{ij}\| = \sqrt{V_1^2 j + V_2^2 j + \dots + V_n^2 j} \quad (3)$$

- c. Menghitung faktor skala menggunakan Persamaan (4).

$$\beta = 0.7 \sqrt[p]{p} = 0.7 (p)_n^1 \quad (4)$$

Keterangan:

β = faktor skala

π = unit masukan

p = jumlah unit tersembunyi

- d. Menghitung nilai V_{ij} menggunakan Persamaan (5).

$$\|V_{ij}\| = \frac{\beta V_{ij}(lama)}{\|V_{ij}\|} \quad (5)$$

Keterangan:

i = jumlah neuron ke- i (1,2,3,...,n)

j = jumlah hidden ke- j

$V_{ij}(lama)$ = bobot lama

$\|V_{ij}\|$ = bobot yang diperbarui

β = faktor skala

- e. Menentukan bobot bias dengan menggunakan bilangan acak yang berada pada interval antara $-\beta$ dan β .
4. Setiap unit pada lapisan input X_i ($i = 1,2,3, \dots, n$) menerima sinyal input X_i dan meneruskannya ke semua unit yang ada di lapisan tersembunyi.
5. Setiap unit pada lapisan tersembunyi Z_j ($j = 1,2,3, \dots, p$) menjumlahkan sinyal input yang telah dibobotkan.

$$Z_{inj} = v_{jo} + \sum_{i=1}^n x_i v_{ji} \quad (6)$$

Keterangan:

Z_{inj} = jumlah sinyal yang diterima oleh unit tersembunyi

x_i = data masukan untuk unit

v_{ji} = bobot antara *input* dan unit tersembunyi

Kemudian dihitung nilai keluaran menggunakan fungsi aktivasi berikut.

$$Z_j = f = Z_{netj} \quad (7)$$

$$= \frac{1}{1 + e^{-Z_{netj}}}$$

Keterangan:

Z_j = Keluaran dari nilai Z_{inj}

6. Tiap-tiap unit pada lapisan keluaran $Y_k (k = 1, 2, 3, \dots, m)$ menerima sinyal keluaran dari unit tersembunyi dan menjumlahkan sinyal keluaran yang terbobot dan biasnya.

$$Y_{ink} = W_{ko} + \sum_{j=1}^p Z_j W_{kj} \quad (8)$$

Keterangan:

Y_{ink} = Keluaran untuk output Y_k

Z_j = nilai masukan pada unit tersembunyi

W_{kj} = bobot antara unit tersembunyi dan keluaran

Kemudian hitung sinyal keluaran menggunakan fungsi aktivasi berikut.

$$Y_{out} = f = Y_{ink} \quad (9)$$

$$= \frac{1}{\alpha + e^{-y_{ink}}}$$

Keterangan:

Y_k = nilai keluaran dari unit ke-k pada *output layer*

7. Unit keluaran $Y_k (k = 1, 2, 3, \dots, m)$ menerima target berdasarkan data input pelatihan untuk mengukur error pada unit tersebut.

$$\delta_k = (t_k - Y_k) Y_k (1 - Y_k) \quad (10)$$

Keterangan:

δ_k = *error* pada *neuron output*

Y_k = keluaran dari unit ke-k

Kemudian perbarui bobot antara unit tersembunyi dan keluaran (ΔW_{kj}), yang kemudian akan digunakan untuk memperbarui bobot W_{kj} .

$$\Delta W_{kj} = \alpha \delta_k Z_j \quad (11)$$

Keterangan:

ΔW_{kj} = perubahan bobot dari *neuron hidden* ke *output*

α = tingkat pembelajaran

Kemudian faktor koreksi error δ_k dikirimkan ke layer unit yang ada di atasnya.

8. Selanjutnya hitung nilai error pada lapisan tersembunyi menggunakan Persamaan (12).

$$\delta_{inj} = \sum_{k=1}^m \delta_k W_{kj} \quad (12)$$

Keterangan:

δ_{inj} = delta masukan

Kemudian hasil yang diperoleh diterapkan pada fungsi aktivasi pada Persamaan (13).

$$\delta_j = \delta_{inj} Z_j Z_j (1 - Z_j) \quad (13)$$

Keterangan:

δ_j = delta keluaran

Selanjutnya, hitung error (ΔV_{ji}) yang nantinya akan digunakan untuk memperbarui V_{ji} .

$$\Delta V_{ji} = \alpha \delta_j x_i \quad (14)$$

Keterangan:

ΔV_{ji} = perubahan bobot dari *neuron input* ke *neuron hidden*

9. Setiap unit keluaran $Y_k (k = 1, 2, 3, \dots, m)$ memperbarui bobot dan biasnya.

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{kj} \quad (15)$$

Setiap unit tersembunyi $Z_j (j = 1, 2, 3, \dots, p)$ juga dilakukan pembaruan bobot beserta biasnya.

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (16)$$

10. Periksa kondisi berhenti, pelatihan dihentikan jika telah mencapai minimum eror atau jumlah maksimum epoch yang ditetapkan.

D. Evaluasi

Evaluasi bertujuan untuk mengukur sejauh mana suatu model dapat dengan tepat mengklasifikasikan data diabetes. Evaluasi akan menggunakan akurasi sebagai metrik utama untuk menilai kinerja model. Dalam penelitian ini, model diuji dengan *k-fold cross validation* ($k=10$). Dalam setiap iterasi, dataset terbagi menjadi 10 bagian, di mana 9 bagian digunakan untuk pelatihan dan 1 bagian untuk pengujian. Metode ini bertujuan untuk meningkatkan keandalan model serta menghindari *overfitting*. Untuk akurasi dihitung menggunakan Persamaan berikut.

$$Akurasi = \frac{TN + TP}{TP + TN + FP + FN} \quad (17)$$

Keterangan:

- TP(*True Positive*) : Jumlah data dengan kelas positif yang di klasifikasikan positif.
 TN(*True Negative*) : Jumlah data dengan kelas negatif yang di klasifikasikan negatif.
 FP(*False Positive*) : Jumlah data dengan kelas positif yang di klasifikasikan negatif.
 FN(*False Negative*) : Jumlah data dengan kelas negatif yang di klasifikasikan positif.

III. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan membandingkan inisialisasi bobot random dan *Nguyen-Widrow* pada *backpropagation* dalam klasifikasi penyakit diabetes. Penelitian ini meliputi tahap pengumpulan data, *data preprocessing*, pelatihan model menggunakan BPNN, serta evaluasi performa model.

A. Pengumpulan Data

Penelitian ini menggunakan 768 data, terdiri dari 500 data terkategori non-diabetes dan 268 data terkategori diabetes. Kondisi ini menunjukkan adanya ketidakseimbangan data, dengan jumlah data non-diabetes lebih banyak dibandingkan data diabetes. Data ini mencakup 8 parameter yaitu jumlah kehamilan (*pregnancies*), kadar glukosa (*glucose*), tekanan darah (*blood pressure*), ketebalan kulit (*skin thickness*), kadar insulin (*insulin*), indeks massa tubuh (BMI), fungsi silsilah diabetes (*diabetes pedigree function*), dan usia (*age*). Data diabetes dapat dilihat pada Tabel 1.

B. Data Preprocessing

Tahap pertama pada *data preprocessing* adalah *data cleaning*, yang melibatkan pengecekan terhadap nilai yang hilang (*missing values*) dan data duplikat. Hasil pengecekan menunjukkan tidak terdapat data yang *missing values* dan data duplikat dalam data diabetes. Selanjutnya, dilakukan *scaling* menggunakan metode *min-max normalization* yang mengubah nilai fitur menjadi skala 0 hingga 1. Data diabetes yang telah di normalisasi menggunakan Persamaan (1) tercantum di Tabel 2.


TABEL 2
HASIL NORMALISASI DATA

Pregnancies	Glucose	Blood Pressure	Skin Thickness	Insulin	BMI	Diabetes Pedigree Function	Age
0,352941	0,670968	0,489796	0,304348	0,186899	0,314928	0,234415	0,483333
0,058824	0,264516	0,428571	0,239130	0,106370	0,171779	0,116567	0,166667
0,470588	0,896774	0,408163	0,271739	0,186899	0,104294	0,253629	0,183333
0,058824	0,290323	0,428571	0,173913	0,096154	0,202454	0,038002	0,000000
0,000000	0,600000	0,163265	0,304348	0,185096	0,509202	0,943638	0,200000
0,294118	0,464516	0,510204	0,217391	0,106370	0,151329	0,052519	0,150000
0,176471	0,219355	0,265306	0,271739	0,088942	0,261759	0,072588	0,083333
...
0,058824	0,529032	0,367347	0,271739	0,186899	0,243354	0,115713	0,433333
0,058824	0,316129	0,469388	0,260870	0,106370	0,249489	0,101196	0,033333

C. Backpropagation Neural Network

Setelah melalui tahapan *data preprocessing*, dilakukan pemodelan algoritma *Backpropagation Neural Network* dengan optimasi bobot menggunakan metode *Nguyen-Widrow*. Berikut adalah beberapa tahapan yang dilakukan dalam penerapannya:

1. Menentukan arsitektur jaringan *backpropagation*. Jumlah *input layer* sesuai dengan jumlah atribut yang terdapat dalam data diabetes yaitu 8. Untuk neuron pada *hidden layer* yang digunakan yaitu 9, 12, dan 15 yang ditentukan berdasarkan Persamaan (2) dan pada *output layer* terdiri dari 1 neuron. Arsitektur *backpropagation* ditampilkan pada Gambar (2).



Gambar 2. Arsitektur Jaringan Backpropagation

2. Menentukan parameter yang akan digunakan. Fungsi aktivasi yang digunakan yaitu sigmoid. Minimum eror yang diterapkan yaitu 0,01 dan maksimum epoch yang digunakan adalah 1000 epoch dengan *learning rate* (lr) terdiri dari 0,1, 0,01, dan 0,001.
3. Menginisialisasi bobot dengan metode random dan metode *Nguyen-Widrow*. Hasil inisialisasi bobot *Nguyen-Widrow* menggunakan Persamaan (3) hingga Persamaan (5) tercantum pada Tabel 3.

TABEL 3
BOBOT DENGAN NGUYEN-WIDROW

No	V1	V2	V3	V4	V...	V15
1	7,48261750e-01	2,57919896e-02	-8,84016305e-02	-3,29945058e-01	...	-8,83435458e-02
2	1,19137311e+00	4,83701043e-02	-4,44947273e-01	-8,13217461e-02	...	-2,37905398e-01
3	1,97459713e-01	1,04367115e-01	7,49365866e-01	-1,99192464e-01	...	1,34729281e-01
4	7,91960061e-01	-1,7522570e-01	3,51371109e-01	4,79444593e-01	...	4,17221636e-01
5	-9,8102831e-01	-3,048156e+00	-3,2745387e+00	-6,67756274e-02	...	-2,78201056e+00
6	1,71093196e-01	-2,5915172e-02	2,37001970e-01	-3,92167926e-01	...	-3,29850882e-01
7	-2,2688020e-01	-6,3272461e-02	-1,4505952e+00	-7,20471889e-02	...	-4,13139731e-01
8	-4,4031988e-04	-4,3975073e-02	3,41357648e-01	-3,13195914e-01	...	1,27787977e-01

4. Melakukan tahapan *feedforward* yaitu data masukan diteruskan dari *input layer* melalui *hidden layer* hingga *output layer* dengan menggunakan Persamaan (6) hingga Persamaan (9).
5. Selanjutnya, dilakukan tahapan *backward* yaitu error dari *output layer* dihitung menggunakan fungsi error. Untuk melakukan tahapan *backward* dengan menggunakan Persamaan (10) hingga Persamaan (14).
6. Kemudian lakukan modifikasi bobot dan bias yaitu bobot diperbarui untuk meminimalkan error berdasarkan perhitungan sebelumnya dengan menggunakan Persamaan (15) hingga Persamaan (16).
7. Mengecek kondisi penghentian telah tercapai. Jika belum, ulangi langkah 4 - 6 hingga kondisi penghentian tercapai.
8. Melakukan pengujian pada data uji melalui tahapan *feedforward* dengan menggunakan Persamaan (6) hingga Persamaan (9).

D. Evaluasi

Model akan diuji menggunakan *k-fold cross validation* dengan berbagai skenario parameter menggunakan inisialisasi bobot random dan dengan inisialisasi bobot *Nguyen-Widrow*. Dengan batas minimum error sebesar 0,01 dan jumlah epoch maksimum sebanyak 1000, dilakukan variasi *learning rate* (lr) sebesar 0,1, 0,01, dan 0,001. Setiap nilai *learning rate* dikombinasikan dengan jumlah neuron yang berbeda pada *hidden layer* yaitu 9, 12, dan 15 neuron. Hasil pengujian dengan inisialisasi bobot random disajikan dalam Tabel 4.

TABEL 4
PENGUJIAN DENGAN INISIALISASI BOBOT RANDOM

Learning Rate (lr)	Neuron pada Hidden Layer	Hasil Rata-Rata Akurasi
0.1	9	89,91%
	12	87,28%
	15	88,60%
0.01	9	88,60%
	12	89,47%
	15	85,53%
0.001	9	89,47%
	12	88,60%
	15	89,47%


Tabel 3 menunjukkan bahwa hasil pengujian inisialisasi bobot random pada *backpropagation* dengan kombinasi lr 0,1 dengan 9 neuron *hidden layer* memberikan akurasi tertinggi, yaitu 89,91%. Untuk melihat pengaruh penggunaan metode inisialisasi bobot terhadap performa model, pengujian dilanjutkan dengan menggunakan inisialisasi *Nguyen-Widrow*. Hasil pengujian dengan inisialisasi *Nguyen-Widrow* disajikan dalam Tabel 5.

TABEL 5
 PENGUJIAN DENGAN INISILIASASI *NGUYEN-WIDROW*

Learning Rate (lr)	Neuron pada Hidden Layer	Hasil Rata-Rata Akurasi
0.1	9	90,35%
	12	87,72%
	15	89,04%
0.01	9	89,47%
	12	89,91%
	15	90,35%
0.001	9	92,11%
	12	90,79%
	15	91,23%

Berdasarkan Tabel 5 menunjukkan bahwa pengujian dengan inisialisasi *Nguyen-Widrow* dengan kombinasi lr 0,001 dengan 9 neuron pada *hidden layer* memberikan akurasi tertinggi, yaitu 92,11%. Rata-rata akurasi tertinggi yang diperoleh pada inisialisasi bobot acak adalah 89,91%, sedangkan pada inisialisasi *Nguyen-Widrow* meningkat menjadi 92,11%. Penggunaan metode dalam inisialisasi bobot yaitu *Nguyen-Widrow* menghasilkan peningkatan akurasi model, karena distribusi awal bobot lebih optimal sebelum proses pelatihan dimulai. Jumlah neuron pada *hidden layer* memiliki pengaruh terhadap performa model BPNN. Peningkatan jumlah neuron dari 9 ke 12 atau 15 neuron tidak selalu meningkatkan akurasi secara signifikan. Oleh karena itu, pemilihan jumlah neuron yang tepat sangat penting untuk menghindari *overfitting* guna mendapatkan model yang optimal dalam klasifikasi penyakit diabetes. Perbandingan akurasi antara BPNN dengan inisialisasi bobot random dan BPNN dengan inisialisasi bobot *Nguyen-Widrow* ditampilkan pada Gambar 3.

Perbandingan Akurasi Inisialisasi Bobot Random dan Nguyen - Widrow



Gambar 3. Perbandingan Akurasi Pengujian BPNN

Gambar 3 menyajikan perbandingan akurasi pengujian klasifikasi penyakit diabetes dengan skenario BPNN dengan inisialisasi bobot random dan inisialisasi *Nguyen-Widrow*. Setiap skenario diuji dengan kombinasi *learning rate* yaitu 0,1, 0,01 dan 0,001 serta variasi neuron *hidden layer* yaitu 9, 12, dan 15. Hasil pengujian menunjukkan bahwa BPNN dengan inisialisasi *Nguyen-Widrow* cenderung menghasilkan akurasi lebih tinggi dibandingkan dengan BPNN dengan inisialisasi bobot random. Model ini dapat diadaptasi digunakan dalam sistem pendukung keputusan medis, khususnya untuk diagnosis dini penyakit diabetes. Pengintegrasian model ini dalam aplikasi berbasis kecerdasan buatan (AI) di bidang medis dapat mempercepat proses diagnosis serta meningkatkan akurasi.

IV. SIMPULAN

Penelitian ini bertujuan membandingkan inisialisasi bobot random dan *Nguyen-Widrow* pada *backpropagation* dalam klasifikasi diabetes. Hasil penelitian menunjukkan bahwa metode inisialisasi *Nguyen-Widrow* mampu meningkatkan akurasi klasifikasi dibandingkan dengan inisialisasi bobot random. Model BPNN dengan inisialisasi *Nguyen-Widrow* mencapai akurasi tertinggi sebesar 92,11% pada konfigurasi *learning rate* 0,001 dan 9 neuron di *hidden layer*, sedangkan model dengan inisialisasi bobot random hanya mencapai akurasi

89,91%. *Learning rate* yang lebih kecil (0,001) cenderung menghasilkan akurasi lebih tinggi dan konvergensi lebih stabil dibandingkan nilai yang lebih besar (0,1 dan 0,01). Jumlah neuron pada *hidden layer* juga memengaruhi akurasi, tetapi peningkatan jumlah neuron tidak selalu memberikan hasil yang lebih baik, karena berisiko menyebabkan *overfitting*. Secara keseluruhan, inisialisasi *Nguyen-Widrow* terbukti lebih efektif dalam meningkatkan performa BPNN untuk klasifikasi diabetes. Penelitian ini menunjukkan bahwa kombinasi algoritma BPNN dengan inisialisasi bobot *Nguyen-Widrow* memiliki potensi besar untuk diadaptasi dalam sistem pendukung keputusan medis, khususnya untuk diagnosis dini penyakit diabetes. Pengintegrasian model ini dalam aplikasi berbasis kecerdasan buatan (AI) di bidang medis dapat mempercepat proses diagnosis serta meningkatkan akurasi.

Dalam penelitian selanjutnya, disarankan untuk mengimplementasikan teknik penyeimbangan data seperti *Synthetic Minority Over-sampling Technique* (SMOTE) guna mengatasi ketidakseimbangan data yang mungkin memengaruhi performa model dalam klasifikasi penyakit diabetes. Selain itu, direkomendasikan untuk mengeksplorasi teknik lainnya, seperti *Hybrid Neural Networks* (misalnya BPNN dikombinasikan dengan *Long Short-Term Memory/LSTM*), yang dapat diintegrasikan dengan metode inisialisasi bobot *Nguyen-Widrow* untuk meningkatkan akurasi dan kemampuan generalisasi model klasifikasi dalam bidang medis.

UCAPAN TERIMA KASIH

Penulis mengucapkan rasa terima kasih kepada Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sultan Syarif Kasim Riau atas kesempatan yang diberikan dalam penelitian ini. Penulis juga berterima kasih kepada Ibu Iis Afrianty, S.T., M.Sc., selaku pembimbing, atas arahan, dukungan, serta masukan berharga yang sangat membantu dalam penyusunan jurnal ini. Selain itu rasa terima kasih disampaikan kepada keluarga serta teman-teman atas dukungan moral, semangat, dan motivasi yang diberikan selama proses penelitian dan penulisan jurnal ini.

DAFTAR PUSTAKA

- [1] J. Saindikom *et al.*, "Implementasi Jaringan Syaraf Tiruan Dalam Klasifikasi Citra Medis," vol. 24, pp. 64–72, 2025.
- [2] H. Mustafidah and S. N. Rohman, "Mean Square Error pada Metode Random dan Nguyen Widrow dalam Jaringan Syaraf Tiruan Mean Square Error on Random and Nguyen Widrow Method on Artificial Neural Networks," *Sainteks*, vol. 20, no. 2, pp. 133–142, 2023, doi: 10.30595/sainteks.v20i2.19516.
- [3] I. M. D. U. Putra, G. K. Gandhiadi, and L. P. I. Harini, "Implementasi Backpropagation Neural Network Dalam Prakiraan Cuaca Di Daerah Bali Selatan.," *E-Jurnal Mat.*, vol. 5, no. 4, p. 126, 2020, doi: 10.24843/mtk.2016.v05.i04.p131.
- [4] R. Maiyuriska, "Penerapan Jaringan Syaraf Tiruan dengan Algoritma Backpropagation dalam Memprediksi Hasil Panen Gabah Padi," *J. Inform. Ekon. Bisnis*, vol. 4, pp. 28–33, 2022, doi: 10.37034/infeb.v4i1.115.
- [5] M. F. Mubarak, M. Nasir, and D. Komalasari, "Jaringan Syaraf Tiruan Untuk Memprediksi Penjualan Pakaian Menggunakan Algoritma Backpropagation," *J. Comput. Inf. Syst. Ampera*, vol. 1, no. 1, pp. 29–43, 2020, doi: 10.51519/journalcisa.v1i1.3.
- [6] T. H. Saragih and N. Huda, "Jaringan Syaraf Tiruan Backpropagation Dengan Adaptive Moment Estimation Untuk Klasifikasi Penyakit Covid-19 Di Kalimantan Selatan," *Epsilon. J. Mat. Murni Dan Terap.*, vol. 16, no. 2, p. 162, 2022, doi: 10.20527/epsilon.v16i2.6792.
- [7] F. Marwati and R. Fauzi, "Prediksi Penyakit Diabetes Melitus Menggunakan Jaringan Syaraf Tiruan Dengan Metode Backpropagation," *Jitu J. Inform. Utama Hal*, vol. 2, no. 1, pp. 26–34, 2024.
- [8] T. H. Sembodo, "Evaluasi Pelaksanaan Program Pengendalian Diabetes Melitus oleh Puskesmas di Indonesia : Literature Review Evaluation of Diabetes Mellitus Control Program in Indonesia Public Health Center : Literature Review," *Researchgate.Net*, no. December, 2021, doi: 10.13140/RG.2.2.11431.88488.
- [9] S. Sutrisno and Jupron, "Analisa Klasifikasi Penyakit Diabetes Dengan Algoritma Neural Network," *bit-Tech*, vol. 6, no. 3, pp. 303–310, 2024, doi: 10.32877/bt.v6i3.1161.
- [10] Noradina, M. Herlina, E. S. Mastari, and C. M. Tampubolon, "Edukasi Kesehatan Tentang Faktor Risiko Dan Pencegahan Diabetes Di Kelurahan Labuhan Deli, Medan Marelant Tahun 2022," *J. Pengabd. Ilmu Kesehat.*, vol. 2, no. 2, pp. 22–27, 2022.
- [11] N. M. S. H. Putri and D. Hisni, "Analisis Asuhan Keperawatan melalui Intervensi Edukasi Kepatuhan Diet DM dan Kadar Glukosa Darah Pada Pasien Ny. I dan Tn. U dengan Diagnosa Medis Diabetes Mellitus Tipe 2 di Rumah Sehat Wilayah Jakarta Timur," *J. Kreat. Pengabd. Kpd. Masy.*, vol. 7, no. 4, pp. 1573–1588, 2024, doi: 10.33024/jkpm.v7i4.13699.
- [12] A. Ridwan, "Penerapan Algoritma Naïve Bayes Untuk Klasifikasi Penyakit Diabetes Mellitus," *J. SISKOM-KB (Sistem Komput. dan Kecerdasan Buatan)*, vol. 4, no. 1, pp. 15–21, 2020, doi: 10.47970/siskom-kb.v4i1.169.
- [13] A. W. Mucholladin, F. A. Bachtiar, and M. T. Furqon, "Klasifikasi Penyakit Diabetes menggunakan Metode Support Vector Machine," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 5, no. 2, pp. 622–633, 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [14] N. Arminarahmah and G. Mahalisa, "Implementasi Model Machine Learning pada Klasifikasi Status Penyakit Diabetes Berbasis Streamlit," *Smart Comp Jurnalnya Orang Pint. Komput.*, vol. 13, no. 3, pp. 470–475, 2024, doi: 10.30591/smartcomp.v13i3.5866.
- [15] Z. Mutaqin, C. Rozikin, and Y. A. Tomo, "Jurnal Sistem dan Teknologi Informasi (JSTI) Klasifikasi Penyakit Diabetes Menggunakan Algoritma Logistic Regression," vol. 06, no. 3, pp. 320–329, 2024, [Online]. Available: <https://journalpedia.com/1/index.php/jsti>
- [16] K. L. Ong *et al.*, "Global, regional, and national burden of diabetes from 1990 to 2021, with projections of prevalence to 2050: a systematic analysis for the Global Burden of Disease Study 2021," *Lancet*, vol. 402, no. 10397, pp. 203–234, 2023, doi: 10.1016/S0140-6736(23)01301-6.
- [17] GBD 2021 Diabetes Collaborators, *IDF Diabetes Atlas*. The Lancet, 2025.
- [18] H. F. Mahfuzh, D. Widiyanto, and N. Chamidah, "Pengaruh Algoritma Inisialisasi Nguyen-Widrow Terhadap Algoritma Backpropagation Dalam Prediksi Indeks Harga Konsumen (IHK)," *J. Semin. Nas. Mhs. Bid. Ilmu Komput. dan Apl.*, pp. 707–720, 2020.

- [19] M. Azhima, I. Afrianty, E. Budianita, and S. Kurnia Gusti, "KLIK: Kajian Ilmiah Informatika dan Komputer Penerapan Metode Backpropagation Neural Network untuk Klasifikasi Penyakit Stroke," *Media Online*, vol. 4, no. 6, pp. 3013–3021, 2024, doi: 10.30865/klik.v4i6.1956.
- [20] N. Rahayu and H. Mustafidah, "Perbandingan Ketepatan Pola Data pada Jaringan Backpropagation Berdasarkan Metode Pembobotan Random dan Nguyen Widrow," *Sainteks*, vol. 19, no. 1, p. 27, 2022, doi: 10.30595/sainteks.v19i1.12931.
- [21] D. Aprilia, ; Jajam, H. Jaman, ; Riza, and I. Adam, "Application Of Backpropagation Neural Network Algorithm For Ciherang Rice Image Identification," *Pilar Nusa Mandiri*, vol. 16, no. 02, p. 141, 2020, doi: 10.33480/pilar.v16i1.1500.
- [22] M. H. Dar, "Penerapan Metode Backpropagation Neural Network Untuk Memprediksi Produksi Air," *Maj. Ilm. INTI*, vol. 12, no. 2, pp. 203–208, 2020.
- [23] F. A. Hizham, Y. Nurdiansyah, and D. M. Firmansyah, "Implementasi Metode Backpropagation Neural Network (BNN) dalam Sistem Klasifikasi Ketepatan Waktu Kelulusan Mahasiswa (Studi Kasus: Program Studi Sistem Informasi Universitas Jember)," *Berk. Sainstek*, vol. 6, no. 2, p. 97, 2018, doi: 10.19184/bst.v6i2.9254.
- [24] A. Herdiansah, R. I. Borman, D. Nurnaningsih, A. A. J. Sinlae, and R. R. Al Hakim, "Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk," *JURIKOM (Jurnal Ris. Komputer)*, vol. 9, no. 2, p. 388, 2022, doi: 10.30865/jurikom.v9i2.4066.
- [25] T. Pipit Mulyah, Dyah Aminatun, Sukma Septian Nasution, Tommy Hastomo, Setiana Sri Wahyuni Sitepu, "Klasifikasi Kerusakan Mesin Sepeda Motor Menggunakan Metode Neural Network Backpropagation," *J. Geej*, vol. 7, no. 2, 2020.
- [26] lian, "Klasifikasi Status Gizi Lansia Menggunakan Metode Backpropagation Neural Network," vol. 5, pp. 1–14, 2023, [Online]. Available: <https://www.ncbi.nlm.nih.gov/books/NBK558907/>
- [27] M. Dasuki, "Optimasi Nilai Bobot Algoritma Backpropagation Neural Network Dengan Algoritma Genetika," *JUSTINDO (Jurnal Sist. dan Teknol. Inf. Indones.)*, vol. 6, no. 1, pp. 38–44, 2021, doi: 10.32528/justindo.v6i1.5280.
- [28] R. Damanik, M. Zarlis, and Z. Situmorang, "Analysis of The Use of Nguyen Widrow Algorithm in Backpropagation in Kidney Disease," *Sinkron*, vol. 8, no. 2, pp. 1001–1013, 2024, doi: 10.33395/sinkron.v8i2.13608.
- [29] V. Lestari, H. Mawengkang, and Z. Situmorang, "Artificial Neural Network Backpropagation Method to Predict Tuberculosis Cases," *Sinkron*, vol. 8, no. 1, pp. 35–47, 2023, doi: 10.33395/sinkron.v8i1.11998.
- [30] B. S. Laili, D. T. Utomo, and D. Wijanarko, "Implementasi Metode Backpropagation Neural Network Dalam Memprediksi Hasil Produksi Kedelai," *J. Teknol. Inf. dan Terap.*, vol. 10, no. 1, pp. 1–6, 2023, doi: 10.25047/jtit.v10i1.145.
- [31] M. Azhima, I. Afrianty, E. Budianita, and S. Kurnia Gusti, "KLIK: Kajian Ilmiah Informatika dan Komputer Penerapan Metode Backpropagation Neural Network untuk Klasifikasi Penyakit Stroke," *Media Online*, vol. 4, no. 6, pp. 3013–3021, 2024.
- [32] A. E. Goldenia, D. Widiyanto, and M. M. Santoni, "Perbandingan Particle Swarm Optimization dan Nguyen Widrow pada Implementasi Backpropagation untuk Prediksi Jumlah Kasus Demam Berdarah Dengue (Studi Kasus: DKI Jakarta)," *Angew. Chemie Int. Ed. 6(11)*, 951–952., pp. 5–48, 2022.