

Implementasi *Feed Forward Neural Network* (FFNN) dalam Memprediksi Penyakit Diabetes

Septian Wulandari (*), Dian Novita

Teknik Informatika, Universitas Indraprasta PGRI,

Jl Raya Tengah No. 80, Gedong, Pasar Rebo, Jakarta Timur, DKI Jakarta, Indonesia

Abstract

Diabetes is a non-communicable disease that has the seventh-highest mortality rate in the world. Diabetes causes a high frequency of thirst, frequent urination, and decreased body weight and endurance, resulting in the body becoming easily weak and sick. Not infrequently, patients suffering from diabetes die at a relatively young age. This research aims to identify or predict diabetes using the Artificial Neural Network Training (ANN) method, namely the Feed Forward Neural Network (FFNN). The variables used in the input values are personal data and medical records, totaling 8 independent variables and 1 dependent variable used as training and testing data. The data was processed using R software and the resulting error value was 0.002857, meaning less than 1%, proving that the resulting model was accurate enough as shown by the proximity of the target to the output results and the steps or number of iterations required by the system during the calculation process and 265 iterations were obtained. Cohen's Kappa value or Kappa value in this study is 1 or 100%, meaning that there is perfect agreement between the prediction model and its accuracy value.

Keywords: Artificial Neural Network Training, Diabetes, Feed Forward Neural Network

(* Corresponding Author: septian.pmb09@rocketmail.com

How to Cite: Wulandari, S., & Novita, D. (2024). *SainsMath: Jurnal MIPA Sains Terapan*, 3(1): 12-24.

PENDAHULUAN

Secara umum pada manusia, penyakit dapat diartikan lebih luas untuk merujuk pada sebuah kondisi apa pun yang dapat menimbulkan rasa sakit bagi penderitanya, atau masalah pada tubuhnya. Penyakit dapat digolongkan menjadi penyakit menular dan penyakit tidak menular. Penyakit menular adalah penyakit yang dapat ditularkan atau berpindah dari satu orang ke orang yang lain, penularan dapat terjadi secara langsung ataupun melalui perantara (Novianti et al., 2022). Di Indonesia sendiri penyakit tidak menular menjadi penyebab angka kematian tertinggi yaitu sebesar 64%. Pada tahun 2016, diabetes menduduki peringkat ketujuh untuk penyebab kematian yang ada di seluruh dunia (Santoso et al., 2020). Berdasarkan data yang diperoleh dari Reskesdas pada tahun 2018, jumlah prevalensi diabetes di Indonesia mencapai lebih dari satu juta pasien yang didiagnosa oleh dokter di semua Provinsi di Indonesia (Mustofa et al., 2022).

Prevalensi penyakit tidak menular mengalami angka peningkatan seperti kanker mencapai 1,8%, stroke 10,9%, penyakit ginjal kronik sebesar 3,8%, diabetes melitus 8,5%, dan hipertensi 34,1% (Nuraisyah et al., 2022). Peningkatannya disebabkan oleh pola hidup dari masyarakat Indonesia dan kurangnya edukasi dalam penanganan penyakit tersebut. Diabetes adalah gangguan pada metabolisme manusia yang kronis dengan multi-etologi, ditandai dengan tingginya kadar gula darah dan dibarengi dengan gangguan metabolisme karbohidrat, lipid, dan protein sebagai akibat dari insufisiensi fungsi insulin (Maliki et al.,

2021). Kondisi seperti ini dapat menyebabkan frekuensi rasa haus yang tinggi, sering buang air kecil, serta menurunnya berat badan, menurunnya daya ketahanan tubuh sehingga mengakibatkan tubuh yang terjangkit penyakit ini akan mudah lemah dan sakit. Tak jarang, pasien yang menderita penyakit diabetes mengalami kematian pada usia yang relatif muda (Setiadi, 2012). Penyakit diabetes dapat menyerang siapa saja mulai dari usia dewasa, remaja, bahkan anak-anak pun dapat terserang penyakit ini. Pada saat ini penyakit diabetes menjadi menyumbang yang cukup besar pada penderita penyakit tidak menular. Oleh karena itu, perlu adanya pengecekan secara rutin kondisi kesehatan pada setiap individu.

Pengecekan kesehatan yang dilakukan secara medis memerlukan biaya yang dapat terbilang cukup mahal, sehingga tidak menutup kemungkinan banyak masyarakat yang enggan untuk melakukan pengecekan kesehatan secara medis. Oleh karena itu, perlu dilakukan pencegahan dini untuk menangani penyakit diabetes pada pasien atau seseorang yang memiliki faktor resiko diabetes yaitu dengan menerapkan gaya hidup sehat. Pencegahan dini yang dilakukan untuk menangani penyakit diabetes dapat dilakukan dengan program *self-management* yaitu dengan mengoptimalkan sumber daya yang ada pada penderita maupun keluarga dalam mengendalikan penyakit yang dialami terutama yang terjadi pada pasien yang terjangkit penyakit kronis (Noradina et al., 2022). Pencegahan dini juga dapat dilakukan dengan mengetahui diagnosis medis dengan menerapkan teknologi dalam mengetahui keadaan kesehatan pada pasien atau seseorang. Oleh karena itu, perlu dilakukan penelitian untuk mendeteksi penyakit diabetes agar dapat menurunkan angka kematian.

Inovasi-inovasi dalam penanggulangan atau pencegahan dalam pengobatan diabetes telah banyak dilakukan di Indonesia. Terdapat penelitian dalam prediksi diagnosa pasien berdasarkan riwayat kesehatan atau diagnosa penyakit sebelumnya menggunakan *machine learning* salah satunya menggunakan *Artificial Neural Network Training* (ANN) (Santoso et al., 2020). Pada penelitian sebelumnya telah dilakukan penelitian oleh Ahmad Setiadi pada tahun 2012 dengan menerapkan algoritma *multilayer perception* untuk deteksi dini penyakit diabetes dan terbukti memiliki tingkat akurasi yang baik yaitu sebesar 77,7% (Setiadi, 2012). Penelitian lainnya yang menggunakan *machine learning* adalah penelitian yang dilakukan oleh Marsiska Ariesta dan Iwan Setiawan pada tahun 2022 yaitu menerapkan *neural network* menggunakan model *particle swarm optimization* untuk mendeteksi penyakit kanker payudara dimana pada penelitiannya menggunakan *neural network* dalam penelitiannya menghasilkan nilai akurasi yang tinggi yaitu sebesar 99,52% dalam memprediksi kanker payudara (Setiawan, 2022). Serta penelitian yang dilakukan oleh Jovi Antares pada tahun 2020 yaitu melakukan penetapan *neural network* dalam mengidentifikasi penyakit stroke menggunakan metode *backpropagation* pada kasus di klinik apotik madya Padang menghasilkan model prediksi dengan nilai akurasi sebesar 97% artinya metode *backpropagation* dapat mengidentifikasi penyakit *stroke* dengan baik (Antares, 2020).

Artificial Neural Network Training (ANN) adalah sebuah model penalaran yang didasarkan pada otak manusia (Pradana et al., 2022). ANN sudah banyak di gunakan karena memiliki kemampuan untuk mendeteksi interaksi yang mungkin terjadi antara variabel prediksi (Bhakti, 2019). Keunggulan dari metode ANN pada kasus prediksi diagnosa penyakit yaitu tidak selalu memerlukan proses *training* pada ilmu statistika, namun kemampuannya dalam secara implisit mengetahui hubungan *non linier* yang rumit diantara variabel *independent* dengan variabel *dependent* dalam mengetahui semua hubungan yang mungkin terjadi diantara variabel prediktor, serta dapat juga dikembangkan dengan berbagai macam algoritma pada proses training (Santoso et al., 2020). Dengan begitu ANN dapat memprediksi penyakit diabetes sejak dini.

Terdapat tiga metode dalam *Artificial Neural Network Training* (ANN) yaitu *Feed Forward Network* (FFNN), *Kohonen Network* (KN), dan *Radian Basis Function* (RBF).

Diantara ketiga jenis jaringan saraf tiruan tersebut FFNN adalah metode yang paling sering digunakan karena terkenal memiliki kemampuan pendekatan yang baik dan dapat digunakan pada dataset universal (Muhajir, 2023a). Jaringan yang digunakan pada metode FFNN adalah algoritma *backpropagation*. Selain itu, metode FFNN memiliki kualitas yaitu memiliki nilai prediksi yang mendekati nilai sebenarnya, sehingga dapat menghasilkan tingkat kesalahan (*error*) yang rendah, serta mempunyai kemampuan dalam memprediksi atau menganalisis setiap permasalahan yang sangat kompleks (Muhajir, 2023b). Oleh karena itu, pada penelitian ini akan dilakukan prediksi penyakit diabetes menggunakan metode *Feed Forward Network* (FFNN). Hasil prediksi yang diperoleh diharapkan dapat mendiagnosis penyakit diabetes sebagai langkah pencegahan dini untuk menangani penyakit diabetes pada pasien atau seseorang yang memiliki faktor resiko diabetes.

METODE

Metode yang digunakan dalam memprediksi penyakit diabetes adalah menggunakan metode FFNN. Namun, sebelum dilakukan prediksi penyakit diabetes tahap pertama yang dilakukan pada penelitian ini adalah menggumpulkan dataset dari www.kaggle.com yang merupakan situs pengumpulan data ilmu pengetahuan terbesar di dunia. Dataset ini diambil dari rumah sakit Frankfurt di Jerman dengan jumlah 2000 dataset. Data yang ditemukan di situs kaggle pada penyakit diabetes terdapat 8 hasil pemeriksaan untuk setiap pasien. Sehingga pada penelitian ini digunakan 8 hasil pemeriksaan yang dijadikan sebagai indikator *independent* dan 1 indikator *dependent*, indikator-indikator yang digunakan adalah sebagai berikut:

x_1 : *Pregnancies* (kehamilan)

x_2 : *Glucose* (kadar gula dalam darah)

x_3 : *Blood Pressure* (tekanan darah)

x_4 : *Skin Thickness* (ketebalan kulit)

x_5 : *Insulin*

x_6 : *BMI* (Indeks Masa Tubuh)

x_7 : *Diabetes Pedigree Function* (Fungsi Silsilah Diabetes/Silsilah)

x_8 : *Age* (umur)

y : *Outcome* (Hasil)

Tahap kedua adalah melakukan normalisasi data. Pada penelitian ini, data yang digunakan memiliki rentang data yang berbeda-beda. Sehingga perlu adanya normalisasi data untuk menghindari dimensi data yang terlalu besar dan terlalu kecil. Normalisasi data dapat menggunakan rumus min-max normalization dengan rumus (Wulandari, 2020):

$$\text{normalized}(x) = \frac{\text{min Range} + (x - \text{min Value})(\text{max Value} - \text{min Range})}{\text{max Value} - \text{min Value}} \quad (1)$$

Tahap ketiga adalah melakukan prediksi dengan menggunakan metode FFNN. Metode FFNN adalah metode yang paling sering digunakan karena terkenal memiliki kemampuan pendekatan yang baik dan dapat digunakan pada dataset universal (Muhajir, 2023a). Selain itu, metode FFNN memiliki kualitas yaitu memiliki nilai prediksi yang mendekati nilai sebenarnya, sehingga dapat menghasilkan tingkat kesalahan (*error*) yang rendah, serta mempunyai kemampuan dalam memprediksi atau menganalisis setiap permasalahan yang sangat kompleks (Muhajir, 2023b). Pada algoritma *backpropagation* terdapat tiga tahapan yaitu umpan maju (*feedforward*) pada pola input dataset, perhitungan serta propagasi balik (*backforward*) pada *error*, dan penyesuaian bobot. Tahap pertama yaitu *feedforward*, setiap dataset input menangkap sinyal input (x_i). Tahap kedua adalah

mendistribusikan dataset input ke unit yang tersembunyi yaitu z_1, z_2, \dots, z_p . Kemudian tahap terakhir adalah menghitung aktivasi dari semua unit yang tersembunyi kemudian outputnya adalah memprediksi atau memperkirakan nilai dari variabel respons. Pada tahap ini meminimalisir nilai error yang diperoleh pada tahap penginputan awal (Wahjono et al., 2020).


Pada metode FFNN, terdapat fungsi aktivasi yang dapat mengaktifkan neuron-neuron yang dapat dideferensiasikan seperti sigmoid. Fungsi sigmoid digunakan karena nilai pada fungsinya yang terletak diantara 0 dan 1 sehingga dapat diturunkan dengan mudah (Ariesta, 2022). Fungsi sigmoid didefinisikan sebagai berikut ini:

$$f(x) = \frac{1}{1+e^{-\sigma x}} \quad (2)$$

Sedangkan, fungsi identitas yang digunakan jika ingin hasil output jaringan adalah bilangan riil, tidak hanya pada range $[0,1]$ atau $[-1,1]$ adalah sebagai berikut (Ariesta, 2022):

$$f'(x) = f(x)[1 - f(x)] \quad (3)$$

Metode FFNN memiliki tiga lapisan yaitu: lapisan masukan (*input layer*) yaitu lapisan yang terdiri atas input dataset mulai dari input dataset 1 sampai dengan input dataset n , lapisan tersembunyi (*hidden layer*) yaitu unit-unit yang tersembunyi mulai dari unit tersembunyi 1 sampai tersembunyi p , dan lapisan keluaran (*output layer*) yaitu unit-unit keluaran mulai dari unit keluaran ke 1 sampai dengan unit keluaran m, n, p . Berikut adalah gambaran arsitektur untuk metode FFNN dengan unit dataset input x_1, x_2, \dots, x_n , satu *hidden layer* yaitu neuron z_1, z_2, \dots, z_p , dan satu unit output yang digambarkan pada Gambar 1 (Putra et al., 2022).



Gambar 1. Arsitektur Metode FFNN

Sedangkan, untuk langkah-langkah pada metode *backpropagation* adalah sebagai berikut (Ariesta, 2022):

Fase I: Umpan Maju (*feedforward*)

1. Untuk setiap neuron input yaitu x_i dengan $i = 1, 2, \dots, n$ menangkap sinyal x_i dan meneruskannya ke semua unit yang ditunjukkan pada *hidden layer*
2. Setiap neuron yang tersembunyi yaitu z_j dengan $j = 1, 2, \dots, p$ serta menjumlahkan bobot pada sinyal input dengan menggunakan persamaan:

$$z_{in_j} = v_{oj} + \sum_{i=1}^n x_i v_{ij} \quad (4)$$

Digunakan untuk menetapkan jumlah *neuron* yang ada pada *hidden layer* dengan persamaan:

$$\ell < m < 2\ell \quad (5)$$

dengan ℓ adalah jumlah *neuron* yang ada pada input layer serta m merupakan jumlah *neuron* yang ada pada *hidden layer*. Sedangkan, untuk menghitung nilai sinyal keluaran menggunakan persamaan:

$$z_j = f(z_{in_j}) \quad (6)$$

Fungsi aktivasi yang digunakan adalah sigmoid (persamaan (2)) dan setelah itu, mengirimkan sinyal ke semua *neuron output*.

3. Setiap *neuron output* y_k dengan $k = 1, 2, \dots, m$, jumlahkanlah bobot dengan sinyal input dengan persamaan:

$$y_{in_k} = w_{ok} + \sum_{i=1}^p z_i w_{jk} \quad (7)$$

Terapkan fungsi aktivasi untuk menghitung nilai sinyal keluaran dengan persamaan:

$$y_k = f(y_{in_k}) \quad (8)$$

Fase II: Propagasi Balik (*backward*)

1. Setiap *neuron output* y_k dengan $k = 1, 2, \dots, m$ memperoleh pola pada target yang setara dengan pola input latih, kemudian menghitung nilai error dengan persamaan:

$$\delta_k = (t_k - y_k) f'(y_{in_k}) \quad (9)$$

dengan f' merupakan turunan pada fungsi aktivasi. Kemudian, hitunglah nilai koreksi pada bobot dengan persamaan:

$$\Delta w_{ok} = a * \delta_k * z_j \quad (10)$$

Menghitung koreksi bias dengan rumus:

$$\Delta w_{ok} = a * \delta_k \quad (11)$$

Kemudian mengirimkan δ_k ke unit-unit yang berada pada layer paling kanan

2. Setiap *neuron tersembunyi* z_j dengan $j = 1, 2, \dots, p$ jumlahkan delta inputnya (pada *neuron-neuron* yang berada di lapisan kanannya)

$$\delta_{in_j} = \sum m \delta_k w_{jk} \quad (12)$$

Kalikan persamaan tersebut dengan turunan dari fungsi aktivasi untuk memperoleh informasi error dengan persamaan:

$$\delta_j = \delta_{in_j} f'(z_{in_j}) \quad (13)$$

Lalu, hitung koreksi pada bobot dengan rumus:

$$\Delta v_{jk} = a * \delta_j * x_i \quad (14)$$

Kemudian, hitunglah koreksi bias dengan rumus:

$$\Delta v_{0j} = a * \delta_j \quad (15)$$

Fase III: Penyelesaian bobot dan bias

1. Penyelesaian bobot dan bias dilakukan dengan persamaan:

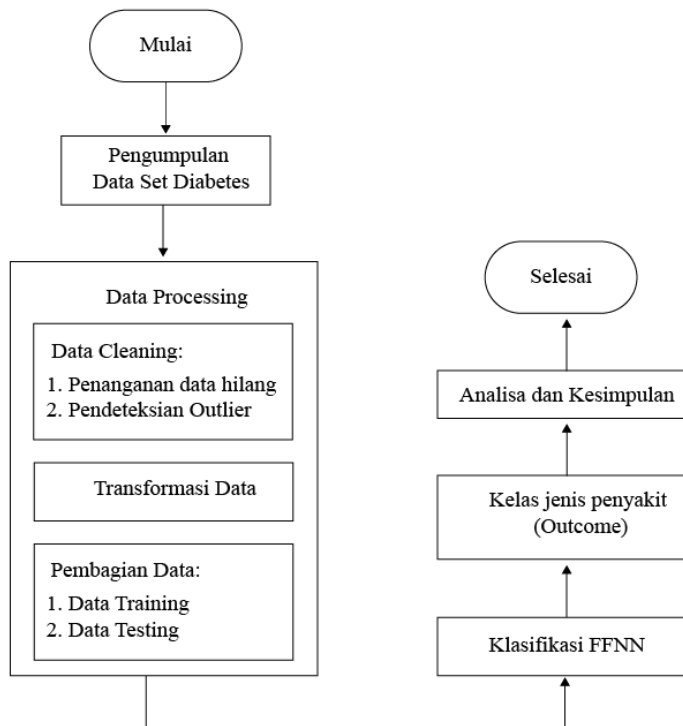
$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (16)$$

Setiap *neuron tersembunyi* z_j dengan $j = 1, 2, \dots, p$ dilakukan penyelesaian bobot dan bias z_i dengan $i = 1, 2, \dots, m$ dengan persamaan:

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (17)$$

2. Langkah terakhir adalah memeriksa iterasi berhenti.

Desain penelitian adalah gambaran kerja yang akan digunakan pada sebuah penelitian. Pada tahapan ini gambaran kerja dimulai dari awal penelitian hingga penelitian selesai (Santoso et al., 2020). Pada penelitian ini kerangka atau gambaran penelitian dapat dilihat pada Gambar 2.



Gambar 2. Kerangka Penelitian

HASIL & PEMBAHASAN

Hasil

Dataset yang digunakan pada penelitian ini adalah data pasien yang memiliki gejala diabetes yang dapat diunduh melalui laman www.kaggle.com. Terdapat 2000 dataset yang diambil dari rumah sakit Frankfurt di Jerman dengan 9 indikator yang digunakan yaitu 8 indikator *independent* dan 1 indikator *dependent*. 8 Indikator *independent* yaitu: *Pregnancies* (kehamilan), *Glucose* (kadar gula dalam darah), *Blood Pressure* (tekanan darah), *Skin Thickness* (ketebalan kulit), *Insulin*, *BMI* (Indeks Masa Tubuh), *Diabetes Pedigree Function* (Fungsi Silsilah Diabetes/Silsilah), dan *Age* (umur), sedangkan indikator *dependent* adalah *Outcome* (Hasil) yang merupakan diagnosa positif atau negatifnya pasien tersebut menderita penyakit diabetes. Berikut merupakan potongan dataset pasien yang digunakan pada penelitian ini dapat dilihat pada Tabel 1. Untuk *Outcome* (hasil) terdapat dua hasil yaitu positif mengidap penyakit diabetes ditunjukkan dengan angka 1 dan negatif mengidap penyakit diabetes ditunjukkan dengan angka 0.

Tabel 1. Pratinjau Dataset Diabetes di Rumah Sakit Frankfurt Jerman

Data	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	y
1	2	138	62	35	0	33,6	0,127	47	1
2	0	84	82	31	125	38,2	0,233	23	0
3	0	145	0	0	0	44.2	0,630	31	1
4	0	135	68	42	250	42.3	0,365	24	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1997	8	179	72	42	130	32.7	0,719	36	1
1998	6	85	78	0	0	31.2	0,382	42	0
1999	0	129	110	46	130	67.1	0,319	26	1
2000	2	81	72	15	76	30.1	0,547	25	0

Sumber: Diolah dari Data Hasil Penelitian, 2024.

Data pada Tabel 1 selanjutnya memasuki tahap data *processing*. Tujuan dilakukan data *processing* adalah untuk mengoptimalkan data agar sesuai dengan kebutuhan model. Hasil data *processing* menunjukkan tidak ada data yang *outlier*. Pada Tabel 1 terlihat bahwa indikator *glucose* dan *diabetes predigree function* memiliki skala yang berbeda. Untuk itu, perlu dilakukan normalisasi data pada 8 indikator *independent* sehingga tidak terdapat data yang mendominasi data yang lainnya pada tahapan *training neural network*. Normalisasi data menggunakan *min-max normalization* untuk menghindari data yang terlalu besar atau terlalu kecil (Wulandari, 2020). Perhitungan normalisasi menggunakan software R yang dapat diunduh secara gratis. Dataset yang telah dilakukan normalisasi data dapat dilihat pada Tabel 2.

Tabel 2. Normalisasi Dataset Diabetes di Rumah Sakit Frankfurt Jerman

Data	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	y
1	0,003	0,185	0,083	0,047	0,000	0,045	0,000	0,063	1
2	0,000	0,113	0,110	0,042	0,168	0,051	0,000	0,031	0
3	0,000	0,195	0,000	0,000	0,000	0,059	0,001	0,042	1
4	0,000	0,181	0,091	0,056	0,336	0,057	0,000	0,032	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1997	0,011	0,241	0,097	0,056	0,175	0,044	0,001	0,048	1
1998	0,008	0,114	0,105	0,000	0,000	0,042	0,001	0,056	0
1999	0,000	0,173	0,148	0,062	0,175	0,090	0,000	0,035	1
2000	0,003	0,109	0,097	0,020	0,102	0,040	0,001	0,034	0

Sumber: Diolah dari Data Hasil Penelitian, 2024.

Langkah selanjutnya adalah membagi data menjadi dataset *training* dan dataset *testing*. Tujuan dari membagi data menjadi data *training* dan data *testing* adalah untuk menghindari *overfitting* serta untuk mempersiapkan data agar tidak bias. Dataset *training* dipergunakan untuk meningkatkan serta menyesuaikan performa dari model yang dihasilkan sedangkan, dataset *testing* dipergunakan untuk pemberhentian proses pada pelatihan sehingga kinerja pada model dataset *testing* berhenti dalam kondisi baik. Pada penelitian ini dataset *training* dan dataset *testing* dibagi menjadi 80% *training* dan 20% *testing*. Setelah dilakukan proses pembagian dataset maka terdapat 1600 dataset *training* dapat dilihat pada Tabel 3 dan 400 dataset *testing* dapat dilihat pada Tabel 4.

Tabel 3. Potongan Dataset *Training*

Data	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	y
450	0,000	0,161	0,099	0,024	0,085	0,041	0,000	0,035	0
346	0,011	0,169	0,118	0,048	0,145	0,052	0,000	0,066	0
336	0,000	0,222	0,102	0,058	0,343	0,064	0,000	0,035	0
1271	0,001	0,120	0,102	0,046	0,050	0,042	0,000	0,031	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1535	0,000	0,184	0,113	0,036	0,000	0,037	0,000	0,079	0
1331	0,003	0,117	0,000	0,031	0,000	0,039	0,001	0,034	0
1643	0,004	0,134	0,091	0,031	0,109	0,042	0,001	0,038	0
272	0,003	0,145	0,083	0,043	0,075	0,034	0,000	0,028	0

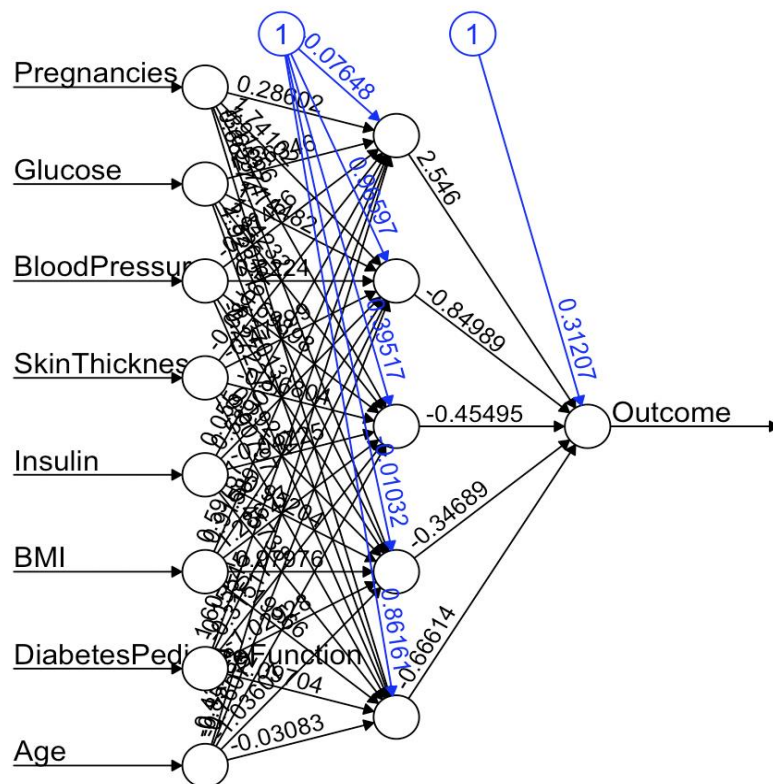
Sumber: Diolah dari Data Hasil Penelitian, 2024.

Tabel 4. Potongan Dataset *Testing*

Data	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	y
2	0,000	0,113	0,110	0,042	0,168	0,051	0,000	0,031	0
5	0,001	0,187	0,083	0,055	0,645	0,055	0,001	0,028	0
9	0,003	0,112	0,087	0,038	0,089	0,049	0,001	0,032	0
13	0,004	0,108	0,000	0,000	0,000	0,000	0,000	0,030	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
1983	0,009	0,137	0,099	0,054	0,141	0,003	0,000	0,060	0
1984	0,000	0,153	0,108	0,046	0,383	0,059	0,000	0,036	0
1993	0,008	0,180	0,094	0,031	0,175	0,048	0,001	0,039	1
1998	0,008	0,114	0,105	0,000	0,000	0,042	0,001	0,056	0

Sumber: Diolah dari Data Hasil Penelitian, 2024.

Berdasarkan output plot pada Gambar 3 terlihat bahwa arsitektur atau jaringan metode FFNN yang dihasilkan memiliki 8 input yang masing-masing *node* atau *neuron* mewakili sebuah variable *independent*. Kemudian pada *hidden layer* terdapat 5 *neuron* dan *neuron* yang berwarna biru yang berada diatas adalah bias yang mempunyai bobot atau berat terhadap masing-masing *neuron*, serta 1 *neuron output* dengan parameter yang telah ditentukan sebelumnya. Sedangkan, garis-garis yang mengaitkan masing-masing *neuron* adalah *synapse* yang mempunyai bobot atau berat masing-masing. Nilai *error* yang dihasilkan yaitu sebesar 0,002857 dengan menggunakan persamaan (9) dan *steps* adalah jumlah iterasi atau perulangan selama proses perhitungan dan diperoleh sebanyak 265 iterasi. Jika dilihat perubahan *error* selama iterasi berlangsung sebesar 0,002857 artinya kurang dari 1% membuktikan bahwa tidak ada optimasi yang dilakukan lebih lanjut oleh model yang dihasilkan.

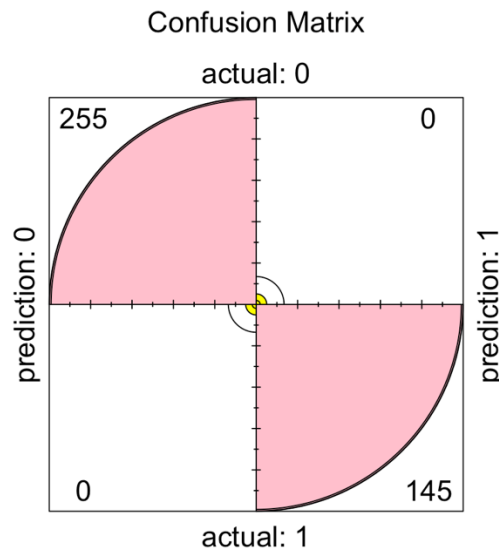


Error: 0.002857 Steps: 265

Gambar 3. Model Arsitektur Metode FFNN

Pembahasan

Berdasarkan paparan hasil penelitian di subbab hasil, pada subbab ini akan dipaparkan beberapa pembahasan. Hasil prediksi menggunakan data *testing* serta membandingkan hasil prediksi dengan data aktual dapat dilihat pada hasil *confussion matrix* dan *statisticsnya*. Pada penelitian ini, hasil *confussion matrix and statistics* menunjukkan bahwa jumlah positif dan negatif pasien yang mengalami penyakit diabetes. Berdasarkan Gambar 4 terlihat bahwa kemampuan metode FFNN memprediksi 255 negatif (0) mengindap penyakit diabetes dengan tepat (berwarna merah muda) dan 145 positif (1) mengindap penyakit diabetes dengan tepat (berwarna merah muda).

Gambar 4. *Confusion Matrix*Tabel 5. *Statistics Hasil Prediksi*

Statistics	Value
Accuracy	1
95% CI	0,9908
No Information Rate (NIR)	0,6375
p-value	$< 2,2 * 10^{-16}$
Kappa	1
Sensitivity	1,0000
Specifity	1,0000
Pos Pred Value	1,0000
Neg Pred Value	1,0000
Prevalence	0,6375
Detection Rate	0,6375
Detection Prevalence	0,6375
Balanced Accuracy	1,0000

Sumber: Diolah dari Data Hasil Penelitian, 2024.

Pada Tabel 5 terlihat bahwa hasil statistik tingkat akurasi yang diperoleh menggunakan metode FFNN ini adalah 99,08% artinya bahwa diagnosa penyakit yang terdapat pada data *testing* sangat baik dalam mengkorelasikan hasil atribut dalam dataset. Kemudian, nilai sensitifitas pada hasil output sebesar 1 atau 100% artinya proporsi pada jumlah observasi positif yang tepat diprediksi sebesar 100%. Nilai spesifitas pada hasil output sebesar 1 atau 100% artinya proporsi pada jumlah observasi negatif yang tepat diprediksi sebesar 100%. Untuk nilai akurasi keseimbangan dari hasil output adalah sebesar 1 atau 100% artinya akurasi proporsi jumlah observasi kela positif yang tepat diprediksi sebesar 100%. *Pos Pred Value* (PPV) adalah matriks tanpa syarat atau yang dikenal sebagai presisi. Pada hasil penelitian ini nilai *Pos Pred Value* (PPV) sebesar 1 atau 100% artinya contoh yang dipilih benar-benar termasuk dalam kelas tersebut. Sedangkan, untuk *Neg Pred Value* (NPV) adalah matriks tanpa syarat yang menandakan probabilitas yang dipilih tidak termasuk dalam kelas tersebut. Pada hasil penelitian ini nilai *Neg Pred Value* (NPV) sebesar 1 atau 100% artinya contoh yang dipilih menandakan probabilitas yang dipilih tidak

termasuk dalam kelas tersebut sebesar 1 atau 100%. Nilai *p-value* adalah pengukuran yang membandingkan keakuratan model dengan *No Information Rate* (NIR) sedangkan NIR menunjukkan keakuratan proyek jika model mengklasifikasikan setiap sample data “benar”. Jika nilai *p-value* semakin kecil maka menunjukkan performa model yang lebih baik. Pada penelitian ini nilai *p-value* sebesar $< 2,2 * 10^{-16}$ artinya performa model yang dihasilkan lebih baik. *Cohen's Kappa* atau Nilai *Kappa* merupakan matriks akurasi yang menunjukkan tingkat kesesuaian antara kebenaran dasar dan prediksi di luar perubahan dari tingkat hasil persetujuan. Nilai *kappa* diantara 0 sampai dengan 1, nilai 0 menunjukkan keakuratan pada model tidak lebih baik dari peluang acak, sedangkan nilai 1 menunjukkan adanya kesesuaian yang sempurna antara prediksi model dengan nilai akurasi yang tidak disebabkan oleh peluang (Minitab, 2024). Pada penelitian ini diperoleh nilai *kappa* yaitu 1 artinya terdapat kesesuaian yang sempurna antara model prediksi dengan nilai akurasinya. *Detection Rate* merupakan proporsi positif sebenarnya yang dihasilkan dengan benar oleh model. Berdasarkan hasil penelitian ini nilai *detection rate* adalah sebesar 0,6375 atau 63,75% artinya model yang dihasilkan pada penelitian ini sudah cukup benar yaitu sebesar 63,75%. Sedangkan *Detection Prevalence* adalah proporsi kasus positif yang diklasifikasikan oleh model dan pada penelitian ini hasil nilai *detection prevalence* adalah sebesar 0,6375 atau 63,75% artinya proporsi positif yang dihasilkan oleh model sudah cukup benar yaitu sebesar 63,75%. Untuk *Balanced Accuracy* adalah matriks yang digunakan untuk menilai performa model klasifikasi. Hasil pada penelitian ini menunjukkan nilai *balanced accuracy* adalah 1 atau 100%, artinya model yang dihasilkan 100% sesuai. Maka dapat disimpulkan bahwa hasil dari pengujian dengan memakai dataset pengujian pada Gambar 7 dapat diuji dengan baik sehingga model tersebut dapat digunakan dengan baik untuk memprediksi penyakit diabetes di rumah sakit Frankfurt Jerman.

KESIMPULAN

Kesimpulan yang dapat diambil dari hasil penelitian ini yaitu *Feed Forward Network* (FFNN) merupakan salah satu metode *neural network* yang dapat digunakan dengan baik dalam membuat model prediksi untuk kasus pasien yang menderita diabetes di rumah sakit Frankfurt di Jerman. Hal ini dibuktikan dengan nilai *error* yang dihasilkan yaitu sebesar 0,002857 dan *steps* atau jumlah iterasi yang dibutuhkan sistem selama proses perhitungan dan diperoleh sebanyak 265 iterasi. Jika dilihat perubahan *error* selama iterasi berlangsung sebesar 0,002857 artinya kurang dari 1% membuktikan bahwa model yang dihasilkan sudah cukup akurat dengan ditunjukkan pada kedekatan target dengan hasil *output*. Hal ini juga dibuktikan dengan nilai *Cohen's Kappa* atau Nilai *Kappa* pada penelitian ini adalah 1 atau 100% artinya terdapat kesesuaian yang sempurna antara model prediksi dengan nilai akurasinya.

REFERENSI

- Ahmad Setiadi. (2012). Penerapan Algoritma Multilayer Perception untuk Deteksi Dini Penyakit Diabetes. *Paradigma*, 14(1), 46–59. <http://archive.ics.uci.edu/ml/>.
- Antares, J. (2020). Artificial Neural Network Dalam Mengidentifikasi Penyakit Stroke Menggunakan Metode Backpropagation (Studi Kasus di Klinik Apotik Madya Padang). In *Djtechno : Journal of Information Technology Research* (Vol. 1, Issue 1).

- Ariesta, M., & Setiawan, I. (2022). Algoritma Neural Network Menggunakan Model Particle Swarm Optimization Untuk Prediksi Penyakit Kanker Payudara. In *Jurnal Prodi Teknik Informatika UNW "Multimatrix"* (Issue 1).
- Bhakti, H. D. (2019). Aplikasi Artificial Neural Network (ANN) untuk Memprediksi Masa Studi Mahasiswa Program Studi Teknik Informatika Universitas Muhammadiyah Gresik. *Eksplora Informatika*, 9(1), 88–95. <https://doi.org/10.30864/eksplora.v9i1.234>
- Eka Mustofa, E., Purwono, J., & Keperawatan Dharma Wacana Metro, A. (2022). Penerapan Senam Kaki Terhadap Kadar Glukosa Darah Pada Pasien Diabetes Melitus Di Wilayah Kerja Puskesmas Purwosari Kec. Metro Utara Tahun 2021. Implementation Of Foot Exercise On Blood Glucose Levels In Diabetes Mellitus Patients In The Work Area Puskesmas Purwosari Kec. North Metro In 2021. *Jurnal Cendikia Muda*, 2(1).
- Leonardus Sandy Ade Putra, Eka Kusumawardhani, Putranty Widha Nugraheni, Lalak Tarbiyatun Nasyin Maleiva, & Vincentius Abdi Gunawan. (2022). Sistem Identifikasi Dini Penyakit Stroke Dengan Menggunakan Jaringan Syaraf Tiruan Perambatan Balik. *Jurnal Teknologi Informasi*, 16(2), 145–157.
- Maliki, M., Jember, U., Wardhana, A. Y., Jember, U., Austru, N., Putra, D., Jember, U., Hariyono, J., & Jember, U. (2021). Analisis Faktor Pemicu Penyakit Diabetes. *Analysis of Diabetes Trigger Factors*. December.
- Minitab. (2024). *Kappa statistics for Attribute Agreement Analysis*. Minitab.
- Muhajir, M. (2023a). Perbandingan Akurasi Peramalan Antara Model Neural Network Dan Regresi Berganda Comparison Of Accuracy Between Neural Network And Multiple Regression Models In Forecasting. *Mathematics and Applications Journal*, 61–69.
- Muhajir, M. (2023b). Perbandingan Akurasi Peramalan Antara Model Neural Network Dan Regresi Berganda Comparison Of Accuracy Between Neural Network And Multiple Regression Models In Forecasting. *Mathematics and Application Journal (MAP)*, 61–69.
- Noradina, Herlina, M., Suryani Mastari, E., & Magdalena Tampubolon, C. (2022). Edukasi Kesehatan Tentang Faktor Risiko Dan Pencegahan Diabetes Di Kelurahan Labuhan Deli, Medan Marelan Tahun 2022. *Jurnal Pengabdian Ilmu Kesehatan*, 2(2), 38–43.
- Novianti, F., Aisyah Yasmin, Y. R., & Novitasari, D. C. R. (2022). Penerapan Algoritma Fuzzy C-Means (FCM) dalam Pengelompokan Provinsi di Indonesia berdasarkan Indikator Penyakit Menular Manusia. *JUMANJI (Jurnal Masyarakat Informatika Unjani)*, 6(1), 23. <https://doi.org/10.26874/jumanji.v6i1.103>
- Nuraisyah, F., Srikandhia Purnama, J., Nuryanti, Y., Dika Agustin, R., Desriani, R., & Utami Putri, M. (2022). Edukasi Pengetahuan Penyakit Tidak Menular dan GERMAS Pada Usia Produktif di Dusun Karangbendo. *Jurnal Panrita Abdi*, Volume 6, Issue 1, 6(1), 1–7.
- Pradana, D., Luthfi Alghifari, M., Farhan Juna, M., & Palaguna, D. (2022). Klasifikasi Penyakit Jantung Menggunakan Metode Artificial Neural Network. *Indonesian Journal of Data and Science*, 3(2), 55–60. <https://doi.org/10.56705/ijodas.v3i2.35>
- Ramadhani Resky Santoso, Rani Megasari, & Hambali Yudi Ahmad. (2020). Implementasi Metode Machine Learning Menggunakan Algoritma Evolving Artificial Neural Network Pada Kasus Prediksi Diagnosis Diabetes. Implementation of Machine Learning Method Using Evolving Artificial Neural Network Algorithm in Prediction of Diabetes Diagnosis. *Jatikom (Jurnal Aplikasi Dan Teori Ilmu Komputer)*, 3(2), 8597. <https://ejournal.upi.edu/index.php/JATIKOM>



- Wahjono, E., Anggriawan, D. O., Satriawan, A. L., Firdaus, A. A., Prasetyono, E., Sudiharto, I., Tjahjono, A., & Budikarso, A. (2020). Pendeteksian Harmonisa Arus Berbasis Feed Forward Neural Network Secara Real Time. *Jurnal Rekayasa Elekrika*, 16(1). <https://doi.org/10.17529/jre.v16i1.15093>
- Wulandari, S. (2020). Clustering Kecamatan Di Kota Bandung Berdasarkan Indikator Jumlah Penduduk Dengan Menggunakan Algoritma K-Means. *Seminar Nasional Riset Dan Teknologi (Semnasristek)*, 128–132.