

SKRIPSI

**PERBANDINGAN FUNGSI AKTIVASI TERHADAP KINERJA
ALGORITMA *NEURAL NETWORK* PADA KLASIFIKASI DATA
DIABETES**

*COMPARISON OF ACTIVATION FUNCTIONS ON THE
PERFORMANCE OF NEURAL NETWORK ALGORITHM IN
DIABETES DATA CLASSIFICATION*



CINDI

D0220403

PROGRAM STUDI INFORMATIKA

FAKULTAS TEKNIK

UNIVERSITAS SULAWESI BARAT

2024

ABSTRAK

Penelitian ini menggunakan metode *Neural Network* dengan algoritma *backpropagation* yang membandingkan tiga fungsi aktivasi *Sigmoid biner*, *Sigmoid bipolar*, dan *Tanh* dalam mengklasifikasikan Data Diabetes. Dataset terdiri dari 70.692 data dengan 18 atribut, dimana 17 atribut dijadikan sebagai input dan 1 atribut (Diabetes) sebagai target klasifikasi. Dalam hal ini penulis menyimpulkan bahwa algoritma ini mampu melakukan klasifikasi untuk kasus diabetes berdasarkan pengujian kinerja yang dilakukan maka Hasil perbandingan akurasi dengan rasio terbaik pada 90:10 dengan tiga jenis fungsi aktivasi. *sigmoid biner* dengan arsitektur 18-5-1 didapatkan akurasi sebesar 76,22% dengan *precision* sebesar 83,07% untuk kelas 0 dan 71,63% untuk kelas 1, *recall* didapatkan hasil sebesar 66, 23% untuk kelas 0, untuk fungsi aktivasi *sigmoid bipolar* dengan arsitektur 18-15-1 didapatkan hasil akurasi sebesar 76,02% dengan *precision* kelas 0 dan 1 sebesar 80,97% dan 72,42% dan *recall* untuk kelas 0 dan 1 berturut-turut sebesar 68,08% dan 83,97%, sedangkan untuk akurasi dengan fungsi aktivasi *TanH* dengan arsitektur 18-15-1 didapatkan hasil sebesar 76,02% dengan presisi sebesar 80,97% untuk kelas 0 dan 72,42% untuk kelas 1 dengan nilai *recall* sebesar 68,08% untuk kelas 0 dan 83,97%. Berdasarkan hasil akurasi tersebut maka disimpulkan fungsi aktivasi *sigmoid biner* memberikan nilai akurasi terbaik pada dataset diabetes.

Kata Kunci: Diabetes, *Neural Network Backpropagation*, Aktivasi *Sigmoid biner*, Aktivasi *sigmoid biner*, *hyperbolic tangent function*, *Confusion Matrix*.

BAB I

PENDAHULUAN

A. Latar Belakang

Data adalah sumber informasi yang awalnya dalam bentuk mentah, mencakup karakter, huruf, angka, gambar, suara, dan lainnya. Agar dapat dimanfaatkan, data harus melalui proses pengolahan lebih lanjut agar menjadi informasi yang dapat dimengerti. Dalam konteks pengolahan data yang lebih lanjut, diperlukan teknik atau metode tertentu, salah satunya adalah *data mining*. *Data mining* adalah proses ekstraksi pola atau informasi yang berguna dari data mentah. Dengan *data mining*, data diolah menjadi informasi yang lebih bermanfaat dan dapat dipahami (Ahmad et al., 2022). *Data mining* adalah rangkaian proses yang digunakan untuk mengeksplorasi dan menemukan nilai informasi serta hubungan kompleks yang tersimpan dalam suatu basis data. Proses ini melibatkan ekstraksi pola informasi dari data yang berguna untuk mengubahnya menjadi informasi baru yang lebih bermanfaat (Utomo & Purba, 2019). Teknik *data mining* menggunakan pengetahuan seperti statistik, matematika, dan pengenalan pola untuk menganalisis dan mengidentifikasi data besar guna mendapatkan informasi yang berguna. Teknik ini dapat diterapkan untuk mengklasifikasikan, memprediksi, dan memperkirakan data guna mendapatkan informasi yang bermanfaat (Damuri et al., 2021).

Klasifikasi merupakan salah satu tahap penting dalam *data mining*. Klasifikasi adalah pengelompokan data atau objek baru ke dalam kelas atau label berdasarkan atribut-atribut tertentu. Teknik dari klasifikasi adalah dengan melihat variabel dari kelompok data yang sudah ada. Klasifikasi bertujuan untuk memprediksi kelas dari suatu objek yang tidak diketahui sebelumnya (D. A. Nasution et al., 2019). Salah satu metode klasifikasi yang paling sering digunakan adalah Metode klasifikasi *Neural network*. *Neural network* merupakan metode yang sering digunakan untuk

menyelesaikan masalah masalah yang rumit dan berkaitan dengan identifikasi, input, prediksi, pengenalan pola dan sebagainya (Hadianto et al., 2019).

Jaringan syaraf tiruan (*Artificial Neural network*) adalah sebuah sistem yang terdiri atas sekelompok unit pemroses yang dimodelkan untuk pemrosesan informasi yang meniru cara kerja sistem syaraf biologis seperti jaringan syaraf manusia. Pemodelan ini didasari oleh kemampuan otak manusia dalam mengorganisir *neuron* sehingga mampu mengenali pola secara efektif. *Back-propagation* merupakan salah satu algoritma pembelajaran dalam *Artificial Neural network*. Salah satu komponen penting dalam membangun model *Artificial Neural network* dengan menggunakan algoritma *backpropagation* adalah fungsi aktivasi. Fungsi aktivasi ini memiliki peranan sangat penting dalam suatu jaringan syaraf tiruan dimana penggunaannya tergantung sesuai kebutuhan dan target yang diinginkan serta fungsi aktivasi ini yang akan menentukan besarnya bobot. Fungsi aktivasi berperan sebagai sinyal untuk menentukan output ke beberapa neuron lainnya (Malla Avila, 2022) Ada beberapa fungsi aktivasi yang sering digunakan yaitu *sigmoid biner*, *sigmoid bipolar*, logistik dan juga *Hyperbolic Tangent Function (Tanh)* (Ervina et al., 2018).

Dalam penelitian ini, dilakukan klasifikasi data diabetes yang diperoleh dari dataset Kaggle. Dataset ini dipilih karena memiliki target yang sudah ditetapkan, sehingga cocok untuk melakukan klasifikasi. Penelitian ini memfokuskan pada perbandingan fungsi aktivasi terhadap kinerja *algoritma backpropagation neural network* (BPNN) dalam konteks klasifikasi data diabetes. Tujuannya adalah untuk memberikan pemahaman yang lebih baik mengenai fungsi aktivasi yang paling efektif terhadap kinerja algoritma BPNN. Evaluasi hasil dilakukan menggunakan *Confusion Matrix* untuk mendapatkan pemahaman yang lebih mendalam mengenai kinerja model.

B. Rumusan Masalah

Berdasarkan latar belakang yang dibahas sebelumnya, maka rumusan masalah pada penelitian ini yaitu bagaimana perbandingan hasil akurasi fungsi aktivasi *sigmoid biner*, *sigmoid bipolar* dan *Hyperbolic Tangent Function (Tanh)* terhadap kinerja algoritma BPNN (*back-propagation neural network*) pada klasifikasi data diabetes ?

C. Tujuan Penelitian

Tujuan penelitian ini adalah mengidentifikasi hasil perbandingan akurasi dari tiga fungsi aktivasi yang digunakan yaitu *sigmoid biner*, *sigmoid bipolar* dan juga *Hyperbolic Tangent Function (Tanh)* terhadap kinerja algoritma BPNN (*back-propagation neural network*) dalam melakukan klasifikasi data diabetes.

D. Manfaat Penelitian

Manfaat penelitian ini yaitu membantu memberikan informasi bidang penelitian Data Mining terkait pengaruh Fungsi aktivasi pada klasifikasi data Diabetes menggunakan algoritma BPNN (*back-propagation neural network*).

E. Batasan Masalah

1. Data yang digunakan pada penelitian ini di peroleh dari *open dataset kaggle* dengan nama file *diabetes_data.csv*
2. Algoritma yang digunakan pada penelitian ini adalah *backpropagation neural network* dengan fokus pada perbandingan fungsi aktivasi *sigmoid biner*, *sigmoid bipolar*, dan *Tanh* dalam klasifikasi data diabetes
3. Evaluasi model algoritma menggunakan *Confusion matrix*

BAB II

TINJAUAN PUSTAKA

A. Landasan Teori

1. Diabetes

Diabetes merupakan penyakit yang disebabkan oleh gangguan metabolik yang terjadi ketika pankreas tidak dapat menghasilkan atau memproduksi cukup insulin, hormon yang mengatur glukosa. Hal ini mengakibatkan tubuh tidak dapat efektif menggunakan insulin yang diproduksi, sehingga menyebabkan peningkatan kadar gula darah atau hiperglikemia (M. K. Nasution et al., 2021). Terdapat banyak faktor yang menjadi penyebab terjadinya diabetes, faktor - faktor tersebut diantaranya seperti faktor keturunan, gula darah yang tinggi, berat badan, usia, dan faktor lainnya (Fadhillah et al., 2022).

2. *Data Mining*

Data mining adalah suatu kegiatan yang melibatkan proses seperti mengumpulkan data, menggunakan dan mengeksploitasi data, mengekstraksi data, mencari pengetahuan untuk menemukan data baru, dan menggunakan data yang sudah ada pada akhirnya mengarah pada ekstraksi pengetahuan, informasi dan pola dapat digunakan (Saputro et al., 2022). Tujuan utama dari proses penambangan data adalah untuk mengekstrak informasi dari berbagai kumpulan data secara massal dan mengubahnya menjadi struktur yang dapat dipahami dan cocok untuk penggunaan akhir dan menghasilkan struktur data yang lebih mudah dimengerti (Shafarindu et al., 2021). Menurut (Daqiqil ID, n.d.) beberapa proses yang terdapat dalam penambangan data adalah sebagai berikut:

a) *Data Cleaning*

Data cleaning merupakan tindakan membersihkan data dengan tujuan mengurangi *noise* dan menghilangkan data yang tidak sesuai atau tidak relevan. Proses pembersihan ini melibatkan beberapa langkah, seperti menghapus data yang duplikat, mengecek ketidaksesuaian data, dan memperbaiki kesalahan yang mungkin ada pada data (Shafarindu et al., 2021).

b) *Data Reduction*

Proses seleksi data melibatkan pengurangan dimensi atau atribut pada *dataset* untuk mengoptimalkan atribut yang memiliki dampak signifikan pada akurasi algoritma saat melakukan penggalian data pada *dataset* atau biasa disebut juga pengurangan dimensi atau seleksi atribut (Muslim et al., n.d.).

c) *Data Transformation*

Data dalam data mining perlu mengalami proses transformasi atau penggabungan ke dalam format yang sesuai. Sebagai contoh, metode standar seperti analisis *clustering* dan asosiasi hanya dapat menerima data yang bersifat kategorikal. Untuk analisis *clustering* dan asosiasi, data numerik yang bersifat kontinyu perlu diubah menjadi interval, proses ini dikenal sebagai transformasi data (Muslim et al., n.d.).

d) *Data Integrasion (Integrasi Data)*

Integrasi data adalah proses penggabungan data dari *multiple database* menjadi satu *database* baru. Integrasi data yang efektif akan menghasilkan *Dataset* yang bersatu tanpa redundansi atau

inkonsistensi yang signifikan, meningkatkan akurasi dan kecepatan dalam proses data mining (Muslim et al., n.d.).

e) Data Normalisasi

Normalisasi menempatkan data pada skala 0 sampai 1 sehingga memudahkan dalam pengolahan data. Selanjutnya normalisasi dilakukan untuk mengelompokkan data dalam suatu skala atau suatu jangkauan tertentu sehingga memberikan kemudahan pada proses selanjutnya (Saputra et al., 2020).

3. *Machine Learning*

Pembelajaran mesin (*Machine Learning*) adalah bidang penelitian yang berfokus pada desain dan analisis algoritma yang memungkinkan komputer untuk belajar. *Machine Learning* mencakup algoritma tujuan umum yang dapat menghasilkan sesuatu yang menarik atau berguna dari sejumlah data tertentu tanpa harus menulis kode tertentu. *Machine Learning* juga dapat diartikan sebuah komputer yang memiliki kemampuan belajar tanpa deprogram secara eksplisit. Program tersebut memanfaatkan data untuk membangun model dan mengambil Keputusan berdasarkan model yang telah dibangun (Daqiqil ID, n.d.).

Ada dua jenis pembelajaran mesin, pembelajaran mesin yang diawasi dan pembelajaran mesin tanpa pengawasan. Data berlabel digunakan dalam pembelajaran mesin yang diawasi untuk melatih algoritma yang dapat mengidentifikasi data atau mengklasifikasi hasil dengan benar. Jika tidak, pembelajaran mesin tanpa pengawasan menggunakan teknik pembelajaran mesin untuk menganalisis dan mengklasifikasikan kumpulan data yang tidak berlabel (Aileen Chun Yueng Hong et al., 2023).

4. Klasifikasi

Data mining merupakan ilmu yang digunakan untuk menganalisis data untuk mengkategorikan, mengelompokkan, dan menyimpulkannya. Proses tersebut terdapat teknik atau cara dalam mengelompokkan data pada *data mining* disebut sebagai klasifikasi (Hizham et al., 2018). Klasifikasi adalah suatu metode yang digunakan dalam menentukan suatu *record* data baru ke salah satu dari beberapa kategori yang telah di definisikan sebelumnya (Muslehatin et al., 2017). Klasifikasi merupakan salah satu metode pembelajaran *data mining* yang sering digunakan untuk menyelesaikan permasalahan penelitian. Klasifikasi digunakan untuk menetapkan objek ke kelas, kelompok, atau kategori. Tujuan klasifikasi adalah untuk menentukan atau menetapkan suatu objek ke dalam salah satu kategori atau kelas. Cara kerja klasifikasi adalah dengan mencari model pembelajaran menggunakan data latihan yang label kelasnya sudah diketahui (Prayogo et al., 2023).

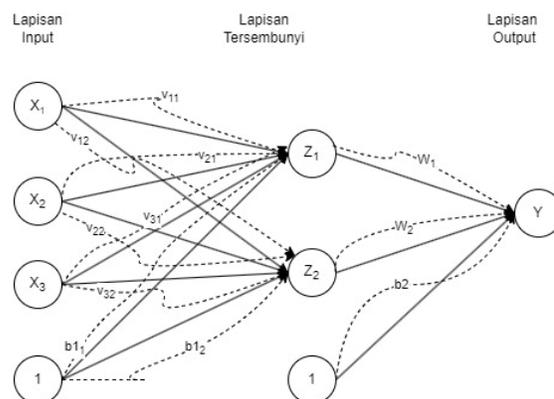
5. *Neural network*

Neural network umumnya disebut Jaringan Syaraf Tiruan (JST) yang mencoba meniru jaringan syaraf manusia yang desainnya berasal dari Jaringan jaringan syaraf tiruan terinspirasi dari struktur otak manusia (Mahendra et al., 2023). *Artificial Neural Network* terdiri dari beberapa lapisan *neuron* yang saling berhubungan yang dapat belajar dari data untuk melakukan tugas seperti klasifikasi, regresi, pengenalan pola, dan prediksi (Maulidia, 2023). Jaringan Syaraf Tiruan tersusun dari beberapa *neuron* yang saling berhubungan. *Neuron* tersebut akan mentransmisikan informasi yang diterima, menuju *neuron-neuron* yang lain. *Neuron* yang terdapat pada jaringan syaraf tiruan akan dikumpulkan pada suatu layer dan layer tersebut akan dihubungkan dengan layer-layer sebelum dan sesudahnya. Umumnya, layer pada Jaringan Syaraf Tiruan tersusun dari *Input Layer*, *Hidden layer*, dan *Output Layer* (Santoso & Hansun, 2021).

Seperti halnya model jaringan syaraf tiruan lainnya, algoritma *Backpropagation* melatih jaringan untuk mendapatkan keseimbangan antara kemampuan jaringan dengan tujuan mengenali pola yang digunakan selama pelatihan serta memberikan respons yang benar terhadap pola masukan yang serupa dengan pola yang dipakai selama pelatihan (Istiqomatul Fajriyah Yulianti et al., 2020).

a. *Backpropagation Neural network*

Backpropagation adalah sebuah metode sistematis jaringan syaraf tiruan yang menggunakan metode pembelajaran terawasi (*supervised learning*) dan banyak lapisan untuk mengubah bobot-bobot yang ada pada lapisan tersembunyi. *Backpropagation* merupakan metode pelatihan di mana sebagian dari *dataset* latihan digunakan sebagai *input* untuk jaringan, dan kemudian jaringan menghitung *output*nya. Saat ada perbedaan antara hasil yang diinginkan dan nilai *output* yang dihasilkan, nilai kesalahan diperhitungkan. Dalam situasi ini, bobot dalam jaringan diperbarui untuk mengurangi kesalahan tersebut (Dina, 2019). Metode pelatihan merupakan proses latihan mengenali data dan menyimpan pengetahuan atau informasi yang didapat ke dalam bobot-bobot (Hizham et al., 2018).



Gambar 2. 1 *Arsitektur Neural Network Backpropagation*

(Sumber gambar: (Dar, 2017))

Gambar 2.1 menunjukkan arsitektur *Backpropagation* dengan 3 buah unit masukan (x_1, x_2 dan x_3) dan 1 lapisan tersembunyi dengan 2 neuron (z_1 dan z_2) serta 1 unit lapisan keluaran (Y). Bobot yang menghubungkan (x_1, x_2 dan x_3) dengan neuron pertama pada lapisan tersembunyi adalah (v_{11}, v_{21}, v_{31}). Sedangkan bobot yang menghubungkan (x_1, x_2 dan x_3) dengan neuron kedua pada lapisan tersembunyi adalah (v_{12}, v_{22}, v_{32}). Untuk b_{11} dan b_{12} adalah bobot bias yang menuju ke neuron pertama dan kedua pada lapisan tersembunyi. Bobot yang menghubungkan Z_1 dan Z_2 dengan neuron pada lapisan keluaran adalah W_1 dan W_2 . Bobot bias b_2 menghubungkan lapisan tersembunyi dengan lapisan keluaran.

Ada beberapa *hyperparameter* yang umumnya digunakan dalam *backpropagation neural network* yaitu:

1) Fungsi aktivasi

Fungsi aktivasi dalam algoritma *backpropagation* berperan sebagai sinyal untuk menentukan keluaran ke beberapa neuron lainnya. Fungsi aktivasi memiliki peranan sangat penting dalam algoritma *backpropagation*, karena penggunaannya tergantung sesuai kebutuhan dan target yang diinginkan. Fungsi aktivasi ini akan menentukan besarnya bobot. Fungsi aktivasi adalah fungsi yang menggambarkan hubungan antara tingkat aktivasi internal (*summation function*) yang mungkin berbentuk linear atau non-linear. Fungsi aktivasi akan menentukan apakah sinyal dari input neuron akan diteruskan atau tidak, sehingga fungsi aktivasi berfungsi untuk menentukan apakah neuron tersebut harus “aktif” atau tidak berdasarkan dari *weighted sum* dari input. Inputan ini akan diproses melalui suatu fungsi perambatan. Fungsi aktivasi pada algoritma *backpropagation* harus mempunyai beberapa karakteristik penting, yaitu kontinu, dapat dibedakan, dan tidak meningkat secara

monoton. Adapun beberapa fungsi aktivasi yang akan digunakan sebagai berikut:

a) *Sigmoid biner*

Salah satu fungsi yang memenuhi ketiga kriteria tersebut dan sering digunakan adalah fungsi *sigmoid biner*, yang memiliki rentang nilai antara 0 dan 1 (Rifa'i, 2021), seperti pada persamaan (2.1) Berikut:

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.1)$$

dengan turunan:

$$f'(x) = f(x)(1 - f(x)) \quad (2.2)$$

Fungsi *sigmoid* memiliki nilai maksimum = 1. Maka untuk pola yang targetnya lebih dari 1, pola masukan serta keluaran harus ditransformasi sebagai akibatnya seluruh polanya memiliki *range* yang sama seperti fungsi *Sigmoid* yang digunakan.

b) *Sigmoid bipolar*

Fungsi *sigmoid bipolar* hampir sama dengan fungsi *sigmoid biner*, yang membedakannya adalah nilai *output* jaringan dari fungsi ini terletak pada interval -1 sampai 1. Fungsi *sigmoid bipolar* dirumuskan sebagai berikut (Prabowo et al., 2020).

$$f(x) = \frac{1-e^{-x}}{1+e^{-x}} \quad (2.3)$$

dengan turunan:

$$f'(x) = \frac{1}{2} (1 + f(x))(1 - f(x)) \quad (2.4)$$

c) *Hyperbolic Tangent Function (Tanh)*

Hyperbolic tangent function atau yang sering disebut *tanh* pada umumnya lebih cepat mencapai konvergensi dibandingkan fungsi aktivasi *sigmoid* (Wibawa, 2017). *Tanh* memiliki nilai *output* yang terletak pada interval -1 sampai 1. Rentang nilai dari fungsi aktivasi *tanh* lebih luas dari fungsi aktivasi *sigmoid biner*. Fungsi aktivasi *tanh* dirumuskan sebagai berikut (Rachmadina, 2024) :

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.5)$$

dengan turunan:

$$f'(x) = \frac{1}{2}(1 + f(x))(1 - f(x)) \quad (2.6)$$

2) *Learning rate (a)*

Learning rate adalah sebuah pengaturan dalam pelatihan jaringan syaraf yang membantu menentukan seberapa besar penyesuaian yang dilakukan pada bobot selama proses belajar. Nilai *learning rate* ini berada pada range nol 0 sampai 1. Jika nilai ini rendah, proses pelatihan jaringan akan berlangsung lebih pelan dan membutuhkan waktu lebih lama untuk menghasilkan hasil yang optimal. Di sisi lain, nilai *Learning rate* yang tinggi bisa mempercepat pelatihan, tapi ada kemungkinan mengurangi keakuratan hasil yang didapat. (Guntoro et al., 2019).

3) *Number of epoch*

Jumlah *epoch* adalah *hyperparameter* yang menentukan seberapa banyak kali algoritma pembelajaran akan bekerja pada keseluruhan dataset pelatihan. Dalam algoritma *Backpropagation*

neural network saat satu epoch berlangsung, algoritma akan membaca setiap baris data pelatihan untuk melakukan proses dan *backpropagation*. Ini berarti bahwa selama satu epoch, model akan menggunakan seluruh dataset pelatihan untuk mengoptimalkan parameter-parameternya dengan memperhitungkan kesalahan yang terjadi selama proses pelatihan (Julianto et al., 2023).

b. Tahapan Algoritma *Backpropagation Neural network*

1) Algoritma Pelatihan *Backpropagation*

Backpropagation adalah algoritma yang digunakan untuk mengajar jaringan syaraf dengan banyak lapisan. Cara kerjanya adalah dengan menyesuaikan bobot antara *neuron* berdasarkan perbedaan antara hasil yang dihasilkan dan hasil yang diharapkan (target). Kesalahan yang dihasilkan dari perbedaan ini digunakan untuk membuat perubahan pada bobot, dengan tujuan untuk mengurangi kesalahan pada iterasi selanjutnya (Dina, 2019). Untuk mendapatkan nilai kesalahan ini, pertama-tama perlu dilakukan proses yang disebut perambatan maju (*forward propagation*). Dalam proses ini, semua *neuron* diaktifkan menggunakan fungsi aktivasi yang bisa diturunkan (Ridla, 2018).

Algoritma pelatihan jaringan *backpropagation* pada dasarnya terdiri dari tiga tahapan (Santoso & Hansun, 2021), yaitu:

1. *Input* nilai data pelatihan sehingga diperoleh nilai *output* (tahap *Feedforward*).
2. Propagasi balik dari nilai *error* yang diperoleh (tahap *Backpropagation*).
3. Penyesuaian bobot koneksi untuk meminimalkan nilai *error*.

Ketiga tahapan tersebut diulangi terus-menerus sampai mendapatkan nilai *error* yang diinginkan. Setelah *training* selesai dilakukan, hanya tahap pertama yang diperlukan untuk memanfaatkan Jaringan Syaraf Tiruan tersebut.

Artificial Neural network (ANN) merupakan metode klasifikasi dan prediksi dengan metode kerja yang terinspirasi dari struktur dan fungsi sistem syaraf manusia (Maulidia, 2023). *Neural network* mencari pola dan hubungan dalam data yang sangat besar yang terlau rumit dan sulit untuk dianalisis manusia (Muttakin & Hanadwiputra, 2022). Langkah-langkah dalam algoritma *Backpropagation* oleh Fausent (1994):

Langkah 0: Inisialisasi bobot (set bobot pada nilai *random* yang kecil).

Langkah 1: Ketika pada kondisi salah berhenti, Lakukan Langkah 2- 9.

Langkah 2: Untuk setiap pasangan *training*, Lakukan Langkah 3 – 8.

Tahap 1 *Feedforward*

Langkah 3: Tiap-tiap *input* ($x_i, i = 1,2,3, \dots, n$) menerima sinyal x_i dan meneruskan sinyal tersebut ke semua unit pada lapisan yang ada di atasnya (*Hidden layer*).

Langkah 4: Tiap-tiap unit tersembunyi ($z_j, j = 1,2,3, \dots, p$) menjumlahkan sinyal-sinyal *input* terbobot.

$$z_{in_j} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (2.7)$$

Gunakan fungsi aktivasi untuk menghitung sinyal *output*-nya.

$$z_j = f(z_in_j) \quad (2.8)$$

dan kirimkan sinyal tersebut ke semua unit di lapisan atasnya (unit-unit *hidden*).

Langkah 5: Tiap-tiap *hidden unit* ($y_k, k = 1, 2, 3, \dots, m$) menjumlahkan bobot sinyal *input*.

$$y_in_k = w_{0k} + \sum_{i=1}^p z_i w_{jk} \quad (2.9)$$

Gunakan fungsi aktivasi untuk menghitung sinyal *output*-nya.

$$y_k = f(y_in_k) \quad (2.10)$$

dan kirimkan sinyal tersebut ke semua unit di lapisan atasnya (unit-unit *output*).

Tahap 2: *Backpropagation*

Langkah 6: Tiap-tiap unit *output* ($y_k, k = 1, 2, 3, \dots, m$) menerima target pola yang berhubungan dengan pola *input* pembelajarannya, hitung informasi *error*-nya:

$$\delta_k = (t_k - y_k) f'(y_k) \quad (2.11)$$

Kemudian hitung koreksi bobot (yang nantinya akan digunakan untuk memperbaiki nilai w_{jk}):

$$\Delta w_{jk} = \alpha \delta_k z_j \quad (2.12)$$

Hitung juga koreksi bias (yang nantinya akan digunakan untuk memperbaiki nilai w_{0k}):

$$\Delta w_{0k} = \alpha \delta_k \quad (2.13)$$

Kirimkan δ_k ini ke unit-unit yang ada di lapisan bawahnya.

Langkah 7: Tiap-tiap *hidden unit* ($z_j, j = 1, 2, 3, \dots, p$) menjumlahkan *input*-nya (dari unit-unit yang berada pada lapisan di atasnya):

$$\delta_in_j = \sum_{k=1}^m \delta_k w_{jk} \quad (2.14)$$

Kalikan nilai ini dengan turunan dari fungsi aktivasinya untuk menghitung informasi *error*:

$$\delta_j = \delta_{in_j} f'(z_j) \quad (2.15)$$

Kemudian hitung koreksi bobot (digunakan untuk memperbaharui v_{ij})

$$\Delta v_{ij} = \alpha \delta_j x_i \quad (2.16)$$

Hitung juga koreksi bias (digunakan untuk memperbaharui v_{0j})

$$\Delta v_{0j} = \alpha \delta_j \quad (2.17)$$

Tahap 3: Update bobot dan bias

Langkah 8: Tiap-tiap unit *output* ($y_k, k = 1, 2, 3, \dots, m$) memperbaharui bias dan bobotnya ($j = 0, 1, 2, 3, \dots, p$):

$$(w_{jk}(\text{baru})) = (w_{jk}(\text{lama})) + \Delta w_{jk} \quad (2.18)$$

Tiap-tiap *hidden unit* ($z_j, j = 1, 2, 3, \dots, p$) memperbaiki bias dan bobotnya ($i = 0, 1, 2, 3, \dots, n$):

$$(v_{ij}(\text{baru})) = (v_{ij}(\text{lama})) + \Delta v_{ij} \quad (2.19)$$

Langkah 9: Tes kondisi berhenti ketika sudah memenuhi jumlah *epoch*.

2) Algoritma pengujian *Backpropagation*

Setelah nilai *output* yang didapatkan dari proses pelatihan yang paling mendekati target, maka bobot dan bias dari pelatihan akan disimpan dan dilakukan proses pengujian. Adapun tahapan dari Algoritma *Backpropagation* (Dina, 2019), yaitu:

1. Langkah 0: inialisasi bobot dan bias sesuai dengan bobot yang dihasilkan pada proses pelatihan.

2. Langkah 1: setiap unit ($x_i, i = 1, 2, 3, \dots, n$) menyebarkan sinyal *input* pada seluruh *hidden unit*.
3. Langkah 2: setiap unit ($z_j, j = 1, 2, 3, \dots, p$) akan menghitung sinyal-sinyal *input* dengan bobot dan biasnya.

$$z_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (2.20)$$

4. Setiap unit *output* ($y_k, k = 1, 2, 3, \dots, m$) akan menghitung sinyal-sinyal dan *hidden unit* dengan bobot dan biasnya menggunakan rumus pada persamaan (2.14).
5. Langkah 3: menggunakan fungsi aktivasi yang telah ditentukan memperoleh sinyal *output* dari unit *output* tersebut menggunakan rumus persamaan (2.15).

Keterangan rumus:

z_in_j : total sinyal masukan pada linjtasan j

v_{0j} : nilai bobot bias *input layer* ke *Hidden layer*

x_i : nilai *input* pada unit i

v_{ij} : bobot tantara *input* unit i dan lapisan unit j

y_in_k : total sinyal masukan pada lapisan unit i

w_{0k} : nilai bias pada *Hidden layer*

z_j : nilai masukan pada lapisan j

δ_k : faktor kesalahan pada unit keluaran k

w_{jk} : bobot tantara lapisan unit j dan keluaran unit k

t_k : target data

y_k : keluaran pada keluaran unit k

α : *Learning rate*

6. Confusion Matrix

Confusion matrix merupakan salah satu metode yang dapat digunakan untuk mengukur kinerja suatu metode klasifikasi. Pada dasarnya *confusion matrix* mengandung informasi yang membandingkan hasil klasifikasi yang dilakukan oleh sistem dengan hasil klasifikasi yang seharusnya (Hadianto et al., 2019). Dalam klasifikasi *biner*, *confusion matrix* menggambarkan performa model dengan membagi hasil klasifikasi menjadi empat kategori seperti pada tabel (2.1) berikut:

Tabel 2. 1 *Confusion Matrix*

<i>Confusion matrix</i>		Kelas Aktual	
		1	0
Kelas Prediksi	1	<i>TP (True Positive)</i>	<i>FP (False Positive)</i>
	0	<i>FN (False Negative)</i>	<i>TN (True Negative)</i>

1. *True Positive* (TP) adalah jumlah objek dari kelas positif yang diklasifikasikan dengan benar
2. *False Negative* (FN), FN adalah jumlah objek dari kelas positif yang salah diklasifikasikan sebagai kelas negatif
3. *False Positive* (FP), FP adalah jumlah objek dari kelas negatif yang salah diklasifikasikan sebagai kelas positif
4. *True Negative* (TN). TN adalah jumlah objek dari kelas negatif yang diklasifikasikan dengan benar (Istiqomatul Fajriyah Yuliati et al., 2020).

Beberapa ukuran evaluasi kinerja klasifikasi dapat dihitung berdasarkan *confusion matrix*, antara lain *accuracy*, *precision* dan *recall*. Nilai akurasi menggambarkan seberapa akurat dan efektifitas sistem secara keseluruhan

dalam mengklasifikasikan data secara benar. Perhitungan akurasi dinyatakan dalam persamaan berikut :

$$accuracy = \frac{TP+TN}{TP+FP+FN+TN} \times 100\% \quad (2.20)$$

Precision adalah parameter ketepatan dari proses klasifikasi atau proporsi klasifikasi *Positive* dari hasil prediksi yang benar terhadap keseluruhan hasil prediksi yang bernilai *Positive*. Persamaan dari nilai *precision* adalah sebagai berikut:

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2.21)$$

Sementara *recall* merupakan ukuran pada *completeness* pada proses klasifikasi *positive* dari hasil prediksi yang benar (*true*) terhadap keseluruhan kelas aktual bernilai *positive* (M. K. Nasution et al., 2021) . Persamaan dari nilai *recall* adalah sebagai berikut :

$$recall = \frac{TP}{TP+FN} \times 100\% \quad (2.22)$$

7. *K-Fold Cross Validation*

Cross Validation adalah sebuah metode dari teknik *data mining* yang bertujuan untuk memperoleh hasil akurasi maksimum ketika data dibagi menjadi dua subset (data *training* dan data *testing*). Salah satu dari jenis pengujian *Cross Validation* adalah *K-Fold Cross Validation* yang berfungsi untuk menilai kinerja proses sebuah metode algoritma dengan membagi sampel data secara acak dan mengelompokkan data tersebut sebanyak nilai *K* pada *K-Fold*. Pada pendekatan metode *K-Fold Cross Validation*, dataset dibagi menjadi sejumlah buah partisi secara acak. Data partisi tersebut

diolah sejumlah K kali eksperimen dengan masing-masing eksperimen menggunakan data partisi ke- K sebagai data *testing* dan menggunakan sisa partisi lainnya sebagai data *training*.

B. Penelitian Terkait

Dalam persiapan penelitian ini, penulis merasa penting untuk merujuk pada beberapa penelitian sebelumnya sebagai landasan dan wawasan. Untuk itu, penulis telah menghimpun sejumlah referensi dari penelitian-penelitian terdahulu yang relevan dengan permasalahan yang dibahas dalam penelitian ini dapat dilihat pada Tabel 2.2.

Tabel 2. 2 Penelitian Terkait

No.	Judul	Hasil Penelitian	Keterkaitan
1.	Perbandingan <i>K-Nearest Neighbor</i> Dan <i>Backpropagation Neural network</i> Dalam Prediksi Resiko Diabetes Tahap Awal (Permadi et al., 2021)	Pada penelitian yang dilakukan oleh (Jaka Permadi dkk, tahun 2021) yaitu membandingkan dua Metode klasifikasi <i>K-Nearest Neighbor</i> (KNN) dan <i>Backpropagation Neural network</i> (BPNN). Berdasarkan hasil penelitian, BPNN merupakan metode klasifikasi yang lebih baik dibandingkan dengan KNN dalam memprediksi resiko diabetes tahap awal. BPNN dengan <i>learning rate</i> $\alpha = 0.3, 0.4, 0.5$ dan jumlah <i>node</i>	Menggunakan algoritma yang sama, yaitu <i>Backpropagation Neural Network</i> (BPNN). Namun, perbedaannya terletak pada penelitian sebelumnya yang tidak menjelaskan fungsi aktivasi yang digunakan, serta adanya perbedaan pada dataset yang digunakan.

No.	Judul	Hasil Penelitian	Keterkaitan
		hidden = 5 unit, memiliki tingkat akurasi, presisi dan <i>recall</i> sebesar 90%. Sementara KNN dengan K = 5, 7 dan 9 memiliki tingkat akurasi sebesar 83.75%, presisi sebesar 85.5497% dan <i>recall</i> sebesar 83.75%.	
2.	Klasifikasi Usaha Mikro Kecil Menengah Menggunakan Jaringan Syaraf Tiruan <i>Backpropagation</i> (Hardoyo & Eko, 2022)	Pada penelitian yang dilakukan oleh (Hardoyo dkk, 2022), yaitu mengklasifikasikan usaha mikro kecil menengah (UMKM) d menggunakan metode <i>Backpropagation Neural Network</i> (BPNN) dengan menggunakan tiga fungsi aktivasi Logsig (<i>sigmoid biner</i>), tansig (<i>sigmoid bipolar</i>), dan <i>purelin</i> (output), dengan validasi data menggunakan metode <i>3-fold cross validation</i> , yang menghasilkan akurasi terbaik sebesar 98,4294%	Menggunakan algoritma yang sama, yaitu <i>Backpropagation Neural Network</i> , Namun, perbedaannya terletak pada tidak adanya perbandingan fungsi aktivasi dalam penelitian sebelumnya, dan menggunakan dataset yang berbeda
3.	Klasifikasi Kalimat Pada Berita Olahraga	Pada penelitian ini melakukan klasifikasi kalimat berita	Menggunakan algoritma yang sama

No.	Judul	Hasil Penelitian	Keterkaitan
	<p>Secara Otomatis Menggunakan Metode <i>Artificial Neural network</i> (Ridwan et al., 2021)</p>	<p>olahraga yang terdiri dari sepuluh kelas. Sistem dibangun menggunakan ANN dengan metode pembelajaran <i>Backpropagation</i>. Berdasarkan hasil pengujian, parameter yang paling optimal yaitu <i>hidden layer</i> berjumlah 6 buah <i>neuron</i> dengan menghasilkan akurasi 99% pada data latih dan 57% pada data uji. Hasil pengujian penambahan <i>neuron</i> pada <i>hidden layer</i> pada percobaan keempat tidak mampu meningkatkan akurasi karena semakin banyak jumlah <i>neuron</i> yang ditambahkan pada <i>hidden layer</i>, akurasi yang dihasilkan malah mengalami penurunan. <i>Dataset</i> yang <i>balance</i> sangat berpengaruh pada akurasi</p>	<p>yaitu algoritma <i>backpropagation</i> dan fungsi aktivasi yang digunakan juga sama. Perbedaannya adalah tidak membandingkan fungsi aktivasi serta meneliti kasus yang berbeda dengan penelitian yang akan dilakukan, dataset yang digunakan juga berbeda.</p>
4.	<p>Klasifikasi Pasien Pengidap Diabetes Menggunakan <i>Neural network</i></p>	<p>Pada penelitian ini melakukan klasifikasi pasien pengidap diabetes <i>Neural network Backpropagation</i>, fungsi</p>	<p>menggunakan algoritma yang sama yaitu <i>Backpropagation Neural network</i></p>

No.	Judul	Hasil Penelitian	Keterkaitan
	<p><i>Backpropagation</i> Untuk Prediksi Kesembuhan (Ali et al., 2020)</p>	<p>aktivasi yang digunakan pada penelitian ini yaitu sigmoid. evaluasi pengujian pada penelitian ini menggunakan akurasi, <i>presisi</i>, <i>recall</i> dan MAE (<i>Mean Absolute Error</i>) dan didapatkan hasil akurasi 92,48% nilai <i>precision</i> 94,36% nilai <i>recall</i> 94,88 dan MAE terkecil dengan nilai 0,000142 pada jumlah 250 <i>dataset</i></p>	<p>dengan fungsi aktivasi yang sama, dimana fungsi aktivasi yang digunakan dalam penelitian sebelumnya akan dibandingkan dengan fungsi aktiavsi lain. Perbedaannya terletak pada masalah yang akan diselesaikan yaitu antara prediksi dan klasifikasi</p>
5.	<p>Peramalan Data Deret Waktu Menggunakan Algoritma <i>Backpropagation Neural Network</i> (BPNN) (Novita Veronika, 2022)</p>	<p>Dari hasil analisis yang telah dilakukan pada penelitian ini menggunakan algoritma BNN menghasilkan model terbaik yaitu MSE 0.0002452 dan MAPE 5.1165471 pada fungsi aktivasi <i>tanh</i> di hidden layer ke-2 dengan pembagian data pelatihan 70%</p>	<p>Menggunakan algoritma yang sama, serta penggunaan fungsi aktivasi yang sama. Namun, perbedaannya tidak membandingkan dengan fungsi aktivasi yang akan digunakan dalam penelitian ini, penggunaan dataset yang berbeda, serta permasalahan yang berbeda, yaitu</p>

No.	Judul	Hasil Penelitian	Keterkaitan
			klasifikasi dan peramalan (prediksi)
6.	Penerapan Jaringan Syaraf Tiruan <i>Backpropagation</i> untuk Klasifikasi Akreditasi Sekolah Menengah Pertama (Utama & Parmadi, 2024)	Arsitektur optimal dari Jaringan Syaraf Tiruan ini menghasilkan akurasi sebesar 93,4925%. dengan jumlah <i>hidden layer</i> yang digunakan adalah dua. Adapun <i>neuron</i> yang digunakan dalam <i>hidden layer</i> pertama berjumlah 10 dan <i>hidden layer</i> dua berjumlah 20 dengan fungsi aktivasi <i>tansig</i> pada <i>hidden layer</i> pertama dan <i>logsig</i> pada <i>hidden layer</i> kedua.	Persamaannya terletak pada penggunaan algoritma <i>backpropagation neural network</i> dengan membandingkan fungsi aktivasi yang nantinya akan digunakan dalam penelitian ini. Perbedaannya terletak kasus / <i>dataset</i> yang berbeda.
7.	Klasifikasi Status Gizi Balita Menggunakan Jaringan Syaraf Tiruan <i>Backpropagation</i> (Pratama & Darmawan, 2021)	Penelitian ini mengklasifikasikan Status Gizi Balita Menggunakan Jaringan Syaraf Tiruan <i>Backpropagation</i> serta menguji variasi fungsi aktivasi, yaitu ReLU dan <i>tanh</i> , dan ditemukan bahwa hasil tertinggi diperoleh menggunakan fungsi aktivasi <i>tanh</i> dengan akurasi sebesar 98.471%.	Menggunakan algoritma yang sama serta salah satu fungsi aktivasi yang akan digunakan pada penelitian ini, perbedaannya terletak pada membandingkan fungsi aktivasi yang berbeda serta dataset yang digunakan berbeda.

No.	Judul	Hasil Penelitian	Keterkaitan
8.	<p>Analisis Fungsi Aktivasi pada Algoritma <i>Backpropagation</i> dalam Pengenalan Aksara Batak Toba (Esrayanti Simanjuntak et al., 2023)</p>	<p>Pada Penelitian menganalisis Algoritma <i>Backpropagation</i> dalam pengenalan aksara Batak Toba dengan variasi fungsi aktivasi. Dari hasil pengujian yang dilakukan, diperoleh hasil akurasi tertinggi pada dua jenis fungsi aktivasi, Akurasi pada fungsi aktivasi <i>Sigmoid bipolar</i> mencapai 80,53% dan pada fungsi aktivasi <i>Sigmoid biner</i> mencapai 78,95%.</p>	<p>menggunakan algoritma yang sama yaitu <i>Backpropagation Neural network</i> dengan fungsi aktivasi yang sama, dimana fungsi aktivasi yang digunakan dalam artikel ini akan dibandingkan dengan fungsi aktiavsi lain. Perbedaannya terletak pada penggunaan dataset yang berbeda, yaitu Aksara Batak Toba dan diabetes.</p>
9.	<p><i>Activation functions selection for BP neural network model of ground surface roughness.</i> (Pan et al., 2020)</p>	<p>Penelitian ini mengusulkan pendekatan pemilihan fungsi aktivasi di mana data virtual yang dihasilkan dari perkiraan model fisik digunakan untuk mengevaluasi kinerja BPNN dalam aplikasi praktik. Hasil penelitian menunjukkan bahwa dengan tansig sebagai fungsi aktivasi hidden layer dan purelin sebagai fungsi</p>	<p>Artikel ini dan penelitian yang akan dilakukan memiliki kesamaan dalam melakukan klasifikasi menggunakan <i>backpropagation</i> serta menggunakan fungsi aktivasi yang sama. Namun, perbedaannya terletak pada dataset</p>

No.	Judul	Hasil Penelitian	Keterkaitan
		<p>aktivasi output layer, model BPNN dapat memperoleh efisiensi pembelajaran yang paling tinggi. Selain itu, ketika fungsi aktivasi lapisan tersembunyi adalah sigmoid dan fungsi aktivasi lapisan keluaran adalah purelin, model dapat memprediksi dengan lebih tepat.</p>	<p>atau kasus yang akan digunakan serta rancangan arsitektur yang direncanakan.</p>
10.	<p><i>Experimental Analysis of Training Parameters Combination of ANN Backpropagation for Climate Classification</i> (Serrat & Djebbar, 2022)</p>	<p>Pada penelitian ini yaitu melakukan Eksperimental Kombinasi Parameter Pelatihan <i>Backpropagation</i> JST untuk Klasifikasi Iklim. Menunjukkan bahwa variasi fungsi aktivasi <i>logsig-logsig-purelin</i> dan fungsi <i>trainlm</i> menunjukkan hasil yang paling baik dengan <i>epoch</i> 7, MSE 0.00090, dan RMSE 0.03011</p>	<p>Persamaan artikel ini dengan penelitian yang akan dilakukan adalah sama-sama melakukan klasifikasi menggunakan <i>backpropagation</i> dan juga menggunakan fungsi aktivasi yang sama. Sedangkan perbedaannya terletak pada dataset/kasus yang akan digunakan serta rencana arsitektur yang akan digunakan.</p>
11	<p>Prediksi IHSG dengan</p>	<p>Pada penelitian ini memprediksi indeks harga</p>	<p>persamaanya dengan penelitian ini yaitu</p>

No.	Judul	Hasil Penelitian	Keterkaitan
	Backpropagataion neural network(Santoso & Hansun, 2019)	saham gabungan (IHSG) menggunakan metode backpropagataion, dengan menggunakan tiga <i>learning rate</i> yang bebrbeda yaitu 0.3, 0.5, 0.7 dan juga jumlah epoch 100 samapai 3000 dengan kelipatan 100.	menggunakan hyperparameter yang hamper sama yaitu jumlah epoch yang digunakan dan perbedaanya terletak pada kasus yang diteliti
12	IMPLEMENTASI JARINGAN SYARAF TIRUAN BACKPROPAGATION UNTUK PREDIKSI HARGA CRUDE PALM OIL (CPO) (Gusti & Cholidhazia, 2018)	Pada penelitian ini memprediksi harga (CPO) dengan metode <i>backpropagation</i> menggunakan 3 pola pembagian data latih dan data uji yakni 70%:30%, 80%:20%, serta 90%:10% dari 72 data. Rentang epoch dari 1000 hingga 5000, rentang α dari 0.1 hingga 0.9 dan neuron hidden 6 hingga 8.	Perbedaanya yaitu dataset yang digunakan berbeda dan juga kasus yang sedang diteliti, persamaanya yaitu menggunakan jumlah nilai <i>learning rate</i> yang sama yaitu 0.1 sampai 0.9 dan juga pembagian rasio data.

BAB III

METODE PENELITIAN

A. Jenis Penelitian

Penelitian ini menggunakan metode eksperimen sebagai pendekatan utama untuk mencapai tujuan penelitian. Metode eksperimen dipilih untuk memberikan wawasan yang mendalam tentang dampak variabel independen terhadap variabel dependen dalam konteks klasifikasi data diabetes.

B. Tempat Dan Waktu Penelitian

Penelitian ini akan dilakukan di Laboratorium Progam Studi Informatika Fakultas Teknik, Universitas Sulawesi barat. Penelitian akan berlangsung selama 3 bulan dimulai sejak usulan proposal diterima pada ujian proposal.

Tabel 3. 1 Jadwal penelitian

No	Kegiatan	Waktu penelitian (2024)																
		April				Mei				Juni				Juli				
		1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	
1	Observasi																	
2	Rancangan Program																	
3	Implementasi																	
4	Pengujian																	
5	Pembuatan laporan hasil																	

C. Alat Dan Bahan

Berikut perangkat keras dan perangkat lunak yang digunakan untuk melakukan penelitian : Spesifikasi perangkat lunak

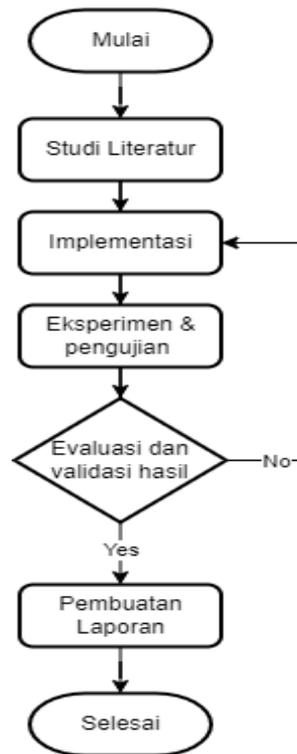
- Sistem operasi (*Windows 10 pro 64 bit*)
- Bahasa Pemrograman java
- JDK (*Java Development Kit*)
- Apache NetBeans IDE 2019
- Microsoft word 2016
- Microsoft Excel 2016

a. Spesifikasi perangkat keras

- Laptop / computer
- *Processor AMD Ryzen 3 3250u with Radeon Graphics*
- 4096MB RAM

D. Tahap Penelitian

Pengumpulan data berupa studi literatur dari jurnal dan artikel ilmiah dilakukan sehingga di tentukan ruang lingkup masalah pada penelitian yang dilakukan. Pada bagian ini disajikan tahapan penelitian seperti yang tertera pada gambar 3.1 :



Gambar 3. 1 Alur Penelitian

1. Pengumpulan data

Tahapan awal yaitu melakukan pengumpulan data, termasuk mengumpulkan referensi atau landasan teori dari penelitian sebelumnya yang berkaitan dengan topik yang sedang diteliti. *Dataset* yang digunakan berasal dari website *open dataset kaggle* dengan nama *diabetes_data* yang terdiri dari 18 atribut dan 70.692 *record* yang dapat dilihat pada tabel 3.2 dari atribut - atribut tersebut 17 atribut akan dijadikan *input*, sementara 1 atribut (Diabetes) akan dijadikan target dalam proses klasifikasi.

Tabel 3. 2 Atribut dalam dataset

No	Atribut	Keterangan
1	<i>Age</i>	Atribut ini menunjukkan usia seseorang
2	<i>Sex</i>	Atribut ini merupakan Jenis kelamin seseorang, dengan nilai 1 untuk laki-laki dan 0 untuk perempuan
3	<i>HighChol</i>	Atribut ini menunjukkan apakah seseorang memiliki kadar kolesterol tinggi (0 untuk tidak, 1 untuk ya).
4	<i>CholCheck</i>	Atribut ini menunjukkan apakah seseorang telah melakukan pemeriksaan kolesterol dalam 5 tahun terakhir (0 untuk tidak, 1 untuk ya).
5	<i>BMI</i>	Indeks Masa Tubuh, mengukur proporsi berat badan terhadap tinggi badan
6	<i>Smoker</i>	Atribut ini menunjukkan apakah seseorang telah merokok setidaknya 100 batang rokok dalam hidupnya (0 untuk tidak, 1 untuk ya)
7	<i>HeartDiseaseor Attack</i>	Atribut ini menunjukkan apakah seseorang memiliki penyakit jantung koroner atau serangan jantung (0 untuk tidak, 1 untuk ya).
8	<i>PhysActivity</i>	Atribut Tingkat aktivitas fisik dalam 30 hari terakhir, tidak termasuk pekerjaan (0 untuk tidak, 1 untuk ya).
9	<i>Fruits</i>	Atribut ini menunjukkan apakah seseorang mengonsumsi buah setidaknya satu kali atau lebih per hari (0 untuk tidak, 1 untuk ya)

No	Atribut	Keterangan
10	<i>Veggies</i>	Atribut ini menunjukkan apakah seseorang mengonsumsi sayuran setidaknya satu kali atau lebih per hari (0 untuk tidak, 1 untuk ya).
11	<i>HvyAlcoholConsump</i>	Atribut ini menunjukkan apakah seseorang mengonsumsi alkohol secara berat (0 untuk tidak, 1 untuk ya)
12	<i>GenHlth</i>	Atribut ini mengukur persepsi umum seseorang tentang kesehatannya, dengan skala dari 1 hingga 5, di mana 1 adalah sangat baik dan 5 adalah buruk.
13	<i>MentHlth</i>	Atribut ini mengukur jumlah hari dalam sebulan di mana seseorang mengalami masalah kesehatan mental, dengan skala dari 1 hingga 30 hari.
14	<i>PhysHlth</i>	Atribut ini mengukur jumlah hari dalam sebulan di mana seseorang mengalami penyakit fisik atau cedera, dengan skala dari 1 hingga 30 hari.
15	<i>DiffWalk</i>	Atribut ini Menunjukkan apakah seseorang memiliki kesulitan serius dalam berjalan atau naik tangga (0 untuk tidak, 1 untuk ya).
16	<i>Stroke</i>	atribut ini menunjukkan menunjukkan apakah seseorang pernah mengalami stroke (0 untuk tidak, 1 untuk ya).
17	<i>HighBP</i>	Atribut ini menunjukkan apakah seseorang memiliki tekanan darah tinggi (0 untuk tidak, 1 untuk ya).
18	<i>Diabetes</i>	Atribut ini menunjukkan apakah seseorang memiliki diabetes (0 untuk tidak, 1 untuk ya).

2. Implementasi

Pada tahapan ini, melakukan implementasi algoritma yang akan digunakan yaitu *backpropogation neural network* untuk melakukan klasifikasi data diabetes dengan membandingkan tiga fungsi aktivasi yang berbeda dengan menggunakan parameter parameter sebagai berikut :

- a. Pembagian rasio data : (70 :30, 80:20, 90:10)
- b. *Learning rate* :0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9
- c. Fungsi aktivasi : *Sigmoid biner*; *Sigmoid bipolar*; *Hyperbolic Tangent Function (Tanh)*
- d. *Input layer* : 17
- e. Jumlah *neuron* pada *Hidden layer* : 5,10, 15, 20
- f. *Output layer* : 1
- g. *Max epoch* : 500, 1000, 1500, 2000
- h. *Target error* : 0.001
- i. *Dataset* : *diabetes_data.csv* (70.692 data)

3. Pengujian dan analisis

Pada tahap Eksperimen dan Pengujian, peneliti menjalankan program dengan *Dataset* yang telah ditentukan. Berikut tahapan eksperimen dalam penelitian ini :

- a) Menyiapkan *dataset* yang akan digunakan (*dataset diabetes*)
- b) Menginput *dataset* ke program.
- c) Melakukan pengolahan data dimulai dari mencari *missing value* pada data dan normalisasi data
- d) Melakukan *training* dan *testing* menggunakan rasio data (70:30, 80:20, 90:10). Kemudian Merancang alur algoritma *Backpropagation Neural network* dengan beberapa arsitektur yang berbeda-beda dengan

mengubah jumlah *neuron* pada *Hidden layer* (lapisan tersembunyi) sebanyak 5, 10, 15, dan 20. Dengan percobaan *Learning rate* dari range 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, dan 0.9 dan Kemudian menguji beberapa *Max_epoch*/iterasi pembelajaran sebanyak 500, 1000, 1500, dan 2000,2500,3000.

e) Mencatat hasil perhitungan akurasi berdasarkan *confusion matrix*.

4. Validasi sistem

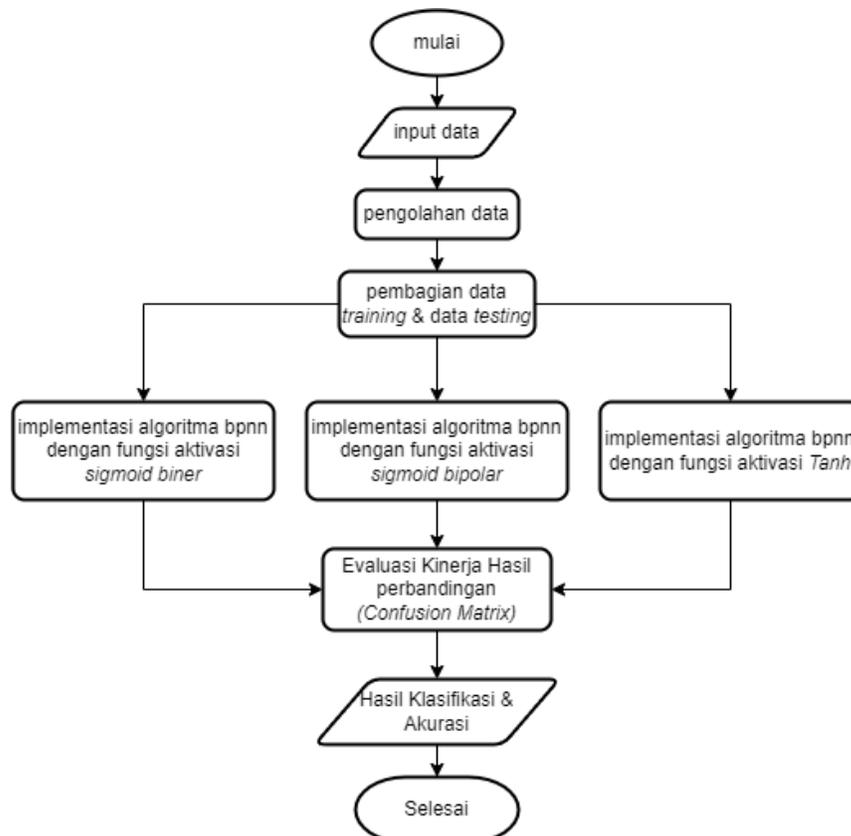
Pada tahap evaluasi hasil analisis dalam penelitian ini, dilakukan pengecekan untuk memastikan apakah model algoritma yang telah dibuat berhasil menghasilkan output klasifikasi yang sesuai. Jika ditemukan ketidaksesuaian antara output dan target meskipun sudah dilakukan perbaikan, proses penelitian akan tetap dilanjutkan dengan penulisan laporan. Di sisi lain, jika output yang dihasilkan setelah perbaikan sesuai dengan target yang ditentukan, maka dapat disimpulkan bahwa model telah mencapai tujuan yang diinginkan. Evaluasi hasil dilakukan dengan mencari arsitektur yang dapat memberikan akurasi tinggi dalam melakukan klasifikasi terhadap atribut kelas atau target.

5. Laporan hasil

Laporan hasil penelitian ini, merupakan proses penulisan laporan dari seluruh tahapan yang dilakukan didokumentasikan secara tertulis dan merupakan bukti dari penelitian.

E. Perancangan Alur Sistem

Berikut tahapan dalam implementasi algoritma *Backpropagation Neural Network* dalam penelitian ini :



Gambar 3. 2 Alur Sistem

1. *Input data*

Pada tahapan ini yaitu menginputkan data berupa file csv yang akan digunakan dalam program. *Dataset* yang digunakan dalam penelitian ini berupa data diabetes yang diperoleh dari *open dataset Kaggle*. Program kemudian memproses setiap baris data, mengekstrak nilai yang diperlukan, dan menyimpannya ke dalam variabel atau struktur data yang sesuai. *Input* dari sistem ini adalah 17 variabel/atribut yang digunakan dapat dilihat pada tabel 3.2.

2. Pengolahan data

2.1 Pemahaman Data (*Data Understanding*)

Pada tahap ini yaitu memahami data yang akan digunakan dalam hal ini menganalisis data untuk mengenali lebih lanjut data yang akan digunakan.

Tabel 3. 3 Deskripsi data

No	Nama	Min	Max
1	<i>Age</i>	1	13
2	<i>Sex</i>	0	1
3	<i>HighChol</i>	0	1
4	<i>CholCheck</i>	0	1
5	<i>BMI</i>	12	98
6	<i>Smoker</i>	0	1
7	<i>HeartDiseaseorAttack</i>	0	1
8	<i>PhysActivity</i>	0	1
9	<i>Fruits</i>	0	1
10	<i>Veggies</i>	0	1
11	<i>HvyAlcoholConsump</i>	0	1
12	<i>GenHlth</i>	1	5
13	<i>MentHlth</i>	0	30
14	<i>PhysHlth</i>	0	30
15	<i>DiffWalk</i>	0	1
16	<i>Stroke</i>	0	1
17	<i>HighBP</i>	0	1

2.2 Proses *Exploratory Data Analysis* (EDA)

Pada proses analisis data, penelitian ini dilakukan untuk menemukan kesalahan dalam dataset, seperti keberadaan *missing value* atau data yang tidak lengkap. Namun, berdasarkan gambar 3.3, dapat dilihat bahwa dataset yang digunakan tidak mengandung *missing value*. Jika terjadi *missing value*, ada beberapa cara untuk mengatasi masalah tersebut. Salah satunya adalah dengan menghapus baris yang mengandung *missing value*, atau mengisi nilai yang hilang dengan nilai tertentu, seperti rata-rata, nilai maksimum, nilai minimum, atau nilai konstan.

```

Diabetes          0
Age              0
Sex              0
HighChol         0
CholCheck        0
BMI              0
Smoker           0
HeartDiseaseorAttack 0
PhysActivity     0
Fruits           0
Veggies          0
HvyAlcoholConsump 0
GenHlth          0
MentHlth         0
PhysHlth         0
DiffWalk         0
Stroke           0
HighBP           0
dtype: int64

```

Gambar 3.3 pengecekan *missing value*

2.3 Transformasi data

Transformasi data adalah proses mentransformasi atau mengubah data ke dalam bentuk yang sesuai (kategori menjadi numerik), agar dapat di proses dengan perhitungan algoritma yang digunakan.

2.4 Normalisasi Data

Normalisasi data digunakan untuk menormalkan rentang antar setiap data. Salah satu metode normalisasi data yang umum digunakan adalah *MinMax Normalization*. Fungsi aktivasi *sigmoid biner* memiliki rentang 0-1, sementara fungsi aktivasi *sigmoid bipolar* dan *Tanh* memiliki rentang -1 hingga 1. Salah satu metode yang cocok untuk normalisasi data dari rentang -1 hingga 1 adalah metode MinMax. Metode MinMax adalah metode yang mudah dan fleksibel karena hasilnya dapat disesuaikan dengan rentang yang ditentukan (Khoirudin et al., 2019). Persamaan untuk menghitung MinMax Normalization dapat dilihat pada persamaan 3.1.

$$v' = \frac{v_i - \min(x)}{\max(x) - \min(x)} (new_{\max(x)} - new_{\min(x)}) + new_{\min(x)} \quad (3.1)$$

Keterangan :

V' : Hasil Normalisasi

V_i : nilai yang akan dinormalisasi

Min (x) : hasil minimal dari sebuah atribut

Max(x) : nilai maksimal dari sebuah atribut

New max(x) : maksimum data baru

New min (x) : minimum data baru

Pada penelitian ini atribut yang akan dinormalisasi yaitu semua atribut dalam *dataset*, sehingga data yang dihasilkan tidak dalam jumlah yang terlalu besar. Perhitungan normalisasi dapat dilakukan dengan menggunakan persamaan (3.1).

$$x' = \frac{4 - 1}{13 - 1} (1 - (-1)) + (-1)$$

V_i : nilai yang akan dinormalisasi = 4

Min (x) : nilai minimal pada age = 1

Max(x) : nilai maksimum pada age = 13

New max(x) : maksimum data baru = 1

New min (x) : minimum data baru = (-1)

3. Pembagian *data training* dan *data testing*

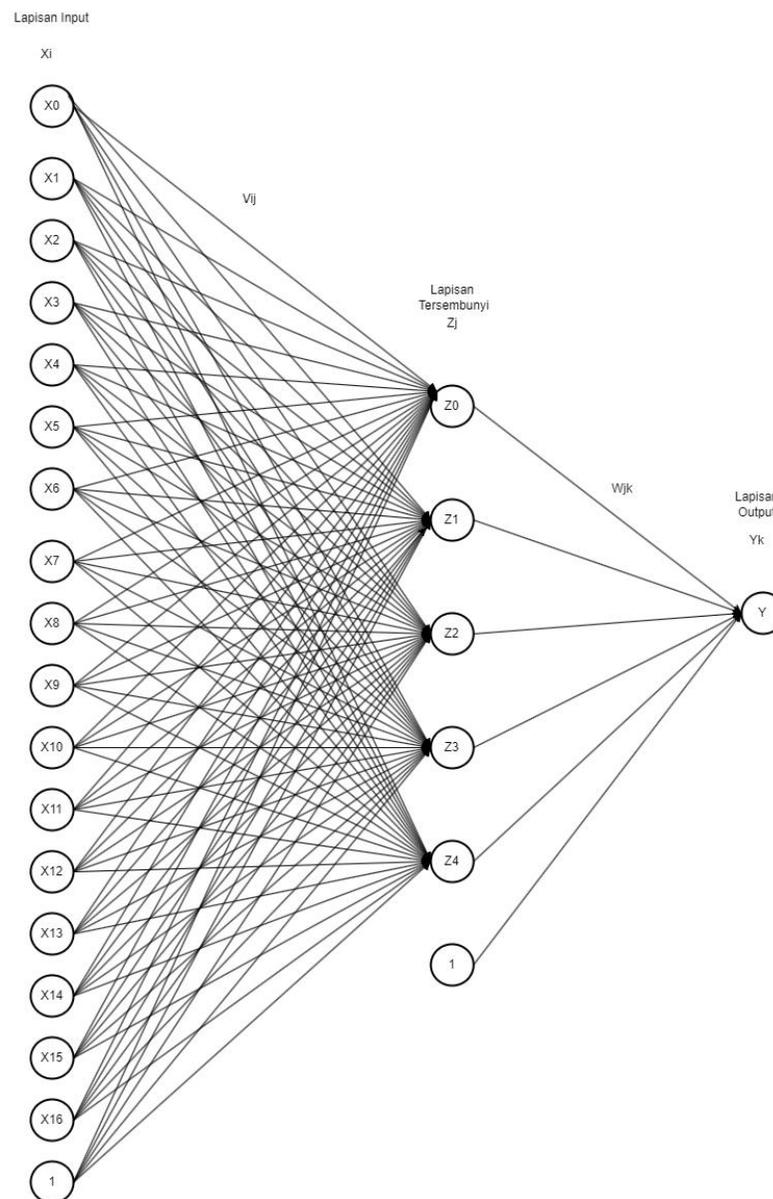
Pada tahap ini, akan dilakukan pembagian data dengan tiga rasio yang berbeda, yaitu 70:30, 80:20, dan 90:10, untuk mengamati pengaruhnya terhadap kinerja model. Langkah ini bertujuan untuk mendapatkan pemahaman yang lebih baik tentang bagaimana pembagian data mempengaruhi hasil klasifikasi.

Tabel 3. 4 pembagian data *training* dan *testing*

Rasio data	Jumlah data	
	70 :30	<i>Training</i>
<i>Testing</i>		21.208
80:20	<i>Training</i>	56.553
	<i>Testing</i>	14.139
90:10	<i>Training</i>	63.622
	<i>Testing</i>	7.070

4. Penerapan algoritma *Backpropagation neural network*

Setelah membagi data menjadi dua bagian, yaitu data latih (*training*) dan data pengujian (*testing*), kemudian membuat model dari algoritma Jaringan Syaraf Tiruan menggunakan data latih untuk melatih model tersebut. Data pengujian digunakan untuk melihat seberapa baik model bekerja dalam klasifikasi. Pada algoritma *backpropagation* terdapat 3 tahapan dasar yaitu (*feedforward*, *backward* dan *update* bobot) seperti yang tertera pada gambar 3.4.



Gambar 3. 4 Arsitektur *Backpropagation neural network* klasifikasi data diabetes

Keterangan :

$X_i, i \in \{0, 1, 2, 3, \dots, m\}$ = berperan sebagai neuron pada *input* layer. X_0 = neuron input (nilainya konstan = 1) yang berpasangan dengan bias.

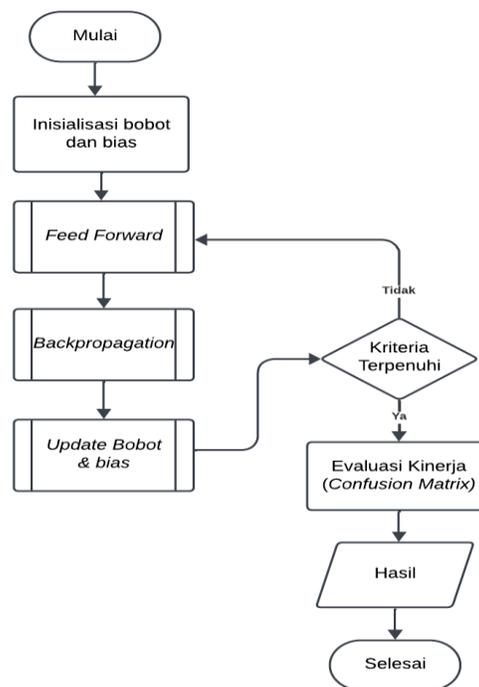
$Z_j, j \in \{0, 1, 2, 3, \dots, n\}$ = berperan sebagai *neuron hidden layer*.

$V_{ij}, i \in \{0, 1, 2, 3, \dots, m\}, j \in \{0, 1, 2, 3, 4, \dots, n\}$. V_{ij} = bobot yang berada di *input* dan *hidden*.

$W_{jk}, j \in \{0, 1, 2, 3, \dots, n\} k \in \{0, 1, 2, \dots, o\}$.

$Y_k(y)$ = berperan sebagai output layer.

Berikut adalah langkah-langkah penerapan *algoritma Backpropagation Neural Network*:



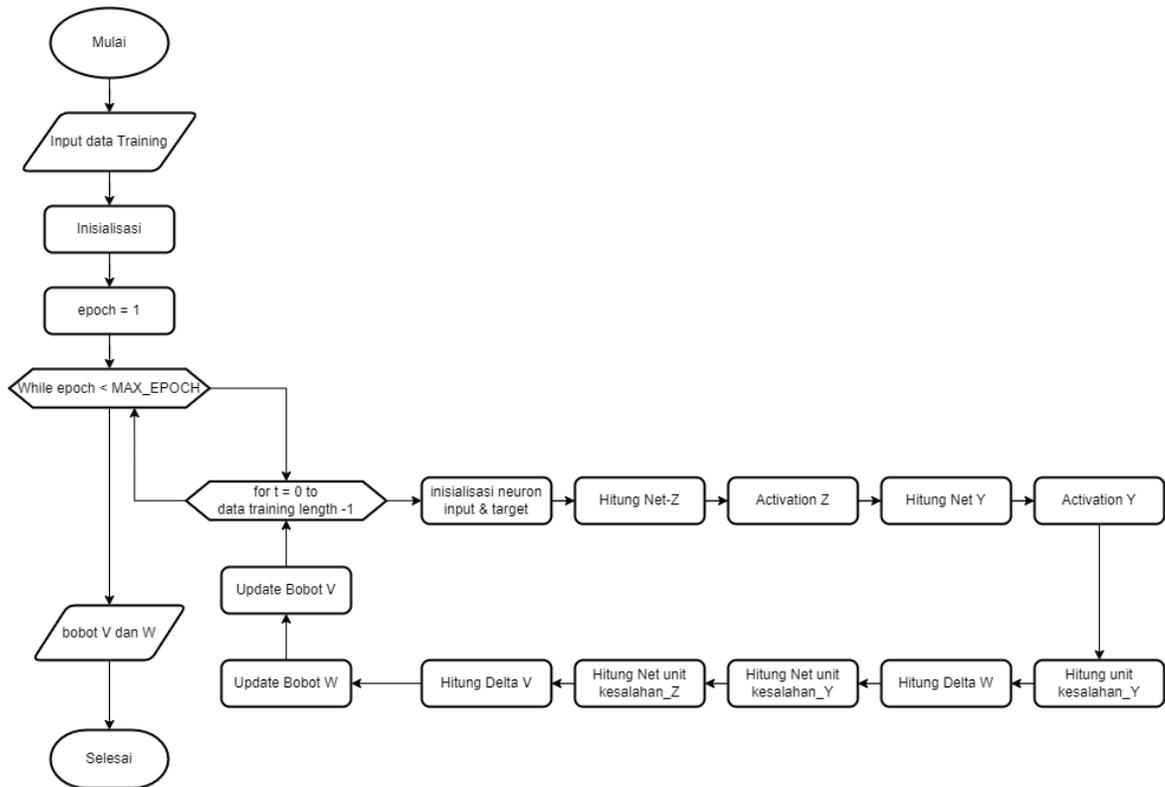
Gambar 3.5 Tahapan *Backpropagation neural network*

Berikut ini adalah langkah-langkah dalam diagram alir algoritma *Backpropagation*:

- a) Memulai dengan menginisialisasi bobot dan bias secara random, nilai bobot random biasanya berada pada *range* 0 - 1. menginputkan nilai bobot dan bias yang telah ditentukan sebelumnya.

- b) Pada proses *feed forward* ini dilakukan perhitungan untuk menghitung nilai keluaran *hidden* layernya dimana didapat dari perkalian antara *input* dan bobot kemudian *neuron* diaktifkan menggunakan fungsi aktivasi *Sigmoid biner*, *sigmoid bipolar*, dan *tanh* yang nantinya akan dibandingkan hasilnya.
- c) Tahap selanjutnya adalah memperbarui bobot (*update bobot*), prosesnya adalah memperbarui bobot yang sebelumnya dirandom yang akan digunakan pada iterasi selanjutnya.
- d) Selanjutnya mengecek jumlah *epoch* yang sudah ditentukan diawal. Jika jumlah epoch sudah terpenuhi maka akan dilanjutkan ke tahap selanjutnya. Namun, apabila jumlah epoch belum mencapai max epoch yang telah ditentukan maka akan di lanjutkan Kembali pada tahap *feedforward* sampai pada tahap *update* bobot dan bias.
- e) Pada tahap selanjutnya jika sudah mencapai max epoch maka dilakukan evaluasi kinerja algoritma menggunakan metode yang sudah di tentukan yaitu confusion matrix.
- f) Tahap terakhir yaitu menampilkan hasil dari algoritma Dimana menghasilkan output berupa hasil klasifikasi data diabetes serta Tingkat akurasinya dan proses akan berhenti.

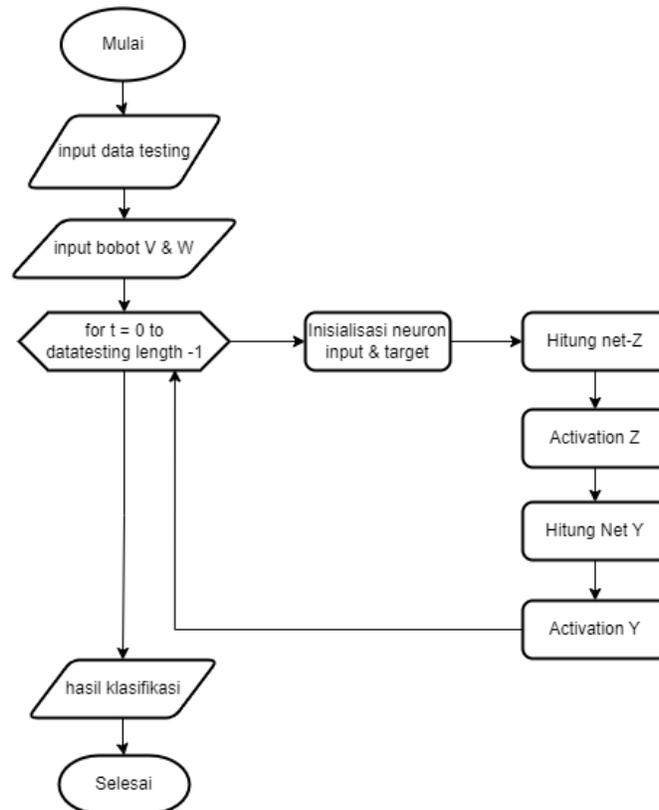
Sistem terdiri dari dua proses utama yaitu pelatihan dan pengujian. Proses pelatihan dapat dilihat pada gambar 3.6



Gambar 3. 6 Proses pelatihan *backpropagation neural network*

- a) Langkah awal dalam proses pelatihan adalah menginputkan data *training* dalam untuk klasifikasi diabetes yang mencakup 18 parameter dengan nilai X0 sampai X17 yaitu atribut dalam data diabetes yang dibagi dalam 3 rasio serta bias yang digunakan. Dimana jumlah masing-masing data *training* dapat dilihat pada table 3.4.
- b) Selanjutnya masuk pada tahap inisialisasi bobot awal yang dirandom, nilai bobot awal biasanya berada pada rentang nilai 0-1, menginisialisasi *learning rate* yang digunakan serta *max epoch*. yang pada awalnya nilai *epoch* kita beri nilai 1,
- c) kemudian dilakukan looping *Max_epoch* sebanyak data *training*. Dimana *looping epoch* akan terus dilakukan selama nilai *epoch* masih lebih kecil dari *MAX_EPOCH*.

- d) Tahapan selanjutnya yaitu masuk pada *looping for* untuk pembacaan setiap baris yang menjadi *input* pada *training*.
- e) inisialisasi *input* dimana atribut dari data akan jadi *inputnya* dan target dijadikan variabel (*t*).
- f) Selanjutnya menghitung Net-Z yaitu hasil penjumlahan dari hasil perkalian antara *input* dan bobot *V*.
- g) Tahap selanjutnya dilakukan aktivasi dengan menggunakan fungsi aktivasi. Pada penelitian ini menggunakan tiga jenis fungsi aktivasi yaitu *sigmoid bipolar*, *sigmoid biner*, dan TanH.
- h) Tahap selanjutnya menghitung Net-Y yaitu hasil penjumlahan dari hasil perkalian antara *Hidden* dan bobot *W*.
- i) Tahap selanjutnya dilakukan aktivasi dengan menggunakan fungsi aktivasi. Pada penelitian ini menggunakan tiga jenis fungsi aktivasi yaitu *sigmoid bipolar*, *sigmoid biner*, dan TanH.
- j) Selanjutnya dilakukan proses hitung *error*, kemudian masuk pada perhitungan delta bobot, hitung error pada Net-Y, hitung error *Z*, hitung delta *V* kemudian dilakukan *update* bobot *V* dan *W*. Proses ini berulang hingga seluruh data *training*.
- k) Proses seluruh data *training* telah melewati arsitektur *backpropagation* akan terhitung sebagai 1 *epoch*.
- l) Ketika banyaknya data sudah terpenuhi maka akan dilanjutkan ke *Max Epoch* berikutnya dan ketika sudah terpenuhi maka proses *training* selesai. Dimana akan menghasilkan model berupa bobot (*v* dan *w*) yang akan diujikan pada data *testing*.



Gambar 3. 7 Proses pengujian *backpropagation*

Berikut adalah proses *testing* berdasarkan hasil model yang didapatkan pada proses *training*. proses pengujian *backpropagation* dapat dilihat pada gambar 3.7.

- a) proses ini akan menggunakan model yang terbaik yang diperoleh dari proses pelatihan untuk digunakan dalam mengklasifikasikan data diabetes yang dijadikan data *testing* dengan pola atau bobot dari proses pelatihan dengan tingkat akurasi tertinggi,
- b) inisialisasi bobot berdasarkan bobot atau model dari proses *training*.
- c) Kemudian dilakukan *looping* sebanyak data *testing* didalamnya dilakukan inisialisasi *input* dan target dilanjutkan ke tahap *feed forward* yang dimulai dari penghitungan Net-Z dilanjutkan menggunakan fungsi

aktivasi, dan perhitungan Net_Y untuk dimasukkan ke dalam fungsi aktivasi.

5. Evaluasi kinerja hasil perbandingan fungsi aktivasi

Evaluasi kinerja adalah proses penting untuk mengukur seberapa baik suatu sistem bekerja. Pada tahap ini peneliti menggunakan *confusion matrix* untuk mengevaluasi hasil perbandingan tiga fungsi aktivasi yang berbeda dalam algoritma *backpropagation neural network* (BPNN) untuk klasifikasi data diabetes.

6. Hasil klasifikasi dan akurasi

Pada tahapan akhir bagian implementasi dari algoritma *Backpropagation Neural network* tersebut memberikan *output* berupa hasil klasifikasi dan akurasi .

DAFTAR PUSTAKA

- Ahmad, I., Samsugi, S., & Irawan, Y. (2022). Implementasi Data Mining Sebagai Pengolahan Data. *Jurnal Teknoinfo*, 16(1), 46. <http://portaldata.org/index.php/portaldata/article/view/107>
- Aileen Chun Yueng Hong, KHAW, K. W., XINYING CHEW, & WAI CHUNG YEONG. (2023). Prediction of US airline passenger satisfaction using machine learning algorithms. *Data Analytics and Applied Mathematics (DAAM)*, 4(1), 8–24. <https://doi.org/10.15282/daam.v4i1.9071>
- Ali, M., Wiriaatmadja, B. S., & Hartanto, A. D. (2020). Klasifikasi Pasien Pengidap Diabetes Menggunakan Neural Network Backpropagation Untuk Prediksi Kesembuhan. *Seminar Nasional Teknologi Komputer & Sains*, 135–141.
- Damuri, A., Riyanto, U., Rusdianto, H., & Aminudin, M. (2021). Implementasi Data Mining dengan Algoritma Naïve Bayes Untuk Klasifikasi Kelayakan Penerima Bantuan Sembako. *JURIKOM (Jurnal Riset Komputer)*, 8(6), 219. <https://doi.org/10.30865/jurikom.v8i6.3655>
- Daqiqil ID, I. (n.d.). *MACHINE LEARNING Teori, Studi Kasus dan Implementasi Menggunakan Python*.
- Dar, M. H. (2017). Penerapan Metode Backpropagation Neural Network Untuk Memprediksi Produksi Air. *Majalah Ilmiah INTI*, 12(2), 203–208.
- Dina, R. (2019). *Optimasi Backpropagation Neural Network Menggunakan Metode Algoritma Genetika Dalam Memprediksi Jumlah Pengangguran*.
- Ervina, M. E., Silvi, R., & Wisisono, I. R. N. (2018). Peramalan Jumlah Penumpang Kereta Api di Indonesia dengan Resilient Back-Propagation (Rprop) Neural Network. *Jurnal Matematika "MANTIK,"* 4(2), 90–99. <https://doi.org/10.15642/mantik.2018.4.2.90-99>

- Esrayanti Simanjuntak, Nurul Khairina, Zulfikar Sembiring, Rizki Muliono, & Muhathir Muhathir. (2023). Analisis Fungsi Aktivasi pada Algoritma Backpropagation dalam Pengenalan Aksara Batak Toba. *JUSTINDO (Jurnal Sistem Dan Teknologi Informasi Indonesia)*, 8(2), 99–107. <https://doi.org/10.32528/justindo.v8i2.331>
- Fadhillah, R. P., Rahma, R., Sephani, A., Mufidah, R., Sari, B. N., & Pangestu, A. (2022). Klasifikasi Penyakit Diabetes Mellitus Berdasarkan Faktor-Faktor Penyebab Diabetes menggunakan Algoritma C4.5. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 7(4), 1265–1270. <https://doi.org/10.29100/jipi.v7i4.3248>
- Guntoro, G., Costaner, L., & Lisnawita, L. (2019). Prediksi Jumlah Kendaraan di Provinsi Riau Menggunakan Metode Backpropagation. *Informatika Mulawarman : Jurnal Ilmiah Ilmu Komputer*, 14(1), 50. <https://doi.org/10.30872/jim.v14i1.1745>
- Gusti, S. K., & Cholidhazia, P. (2018). *Backpropagation Untuk Prediksi Harga Crude Palm Oil (Cpo) (Studi Kasus : Dinas Perkebunan Provinsi Riau)*. 155, 5000.
- Hadianto, N., Novitasari, H. B., & Rahmawati, A. (2019). Klasifikasi Peminjaman Nasabah Bank Menggunakan Metode Neural Network. *Jurnal Pilar Nusa Mandiri*, 15(2), 163–170. <https://doi.org/10.33480/pilar.v15i2.658>
- Hardoyo, T., & Eko, E. H. P. (2022). Klasifikasi Usaha Mikro Kecil Menengah Menggunakan Jaringan Syaraf Tiruan Backpropagation. *KONSTELASI: Konvergensi Teknologi Dan Sistem Informasi*, 2(1), 111–123. <https://doi.org/10.24002/konstelasi.v2i1.5625>
- Hizham, F. A., Nurdiansyah, Y., & Firmansyah, D. M. (2018). Implementasi Metode Backpropagation Neural Network (BNN) dalam Sistem Klasifikasi Ketepatan Waktu Kelulusan Mahasiswa (Studi Kasus: Program Studi Sistem Informasi

- Universitas Jember). *Berkala Sainstek*, 6(2), 97.
<https://doi.org/10.19184/bst.v6i2.9254>
- Istiqomatul Fajriyah Yuliati, Septie Wulandary, & Sihombing, P. (2020). Penerapan Metode SVM dan BPNN dalam Pengklasifikasian PUS di Jawa Barat. *Jurnal Statistika Dan Aplikasinya*, 4(1), 23–34. <https://doi.org/10.21009/jsa.04103>
- Julianto, B., Nugroho, K. T., Maharani, T., & Nur, D. F. (2023). Pengaruh Jumlah Epoch Dan Step Per Epoch Terhadap Performa Mask-Rcnn Pada Deteksi Objek Tanda Tangan. *Journal of Electrical, Electronic, Mechanical, Informatic, and Social Applied Science*, 2(1), 7–16. <https://viso.ai/deep-learning/image-segmentation-using-deep->
- Khoirudin, K., Nurdiah, D., & Wakhidah, N. (2019). Prediksi Penerimaan Mahasiswa Baru Dengan Multi Layer Perceptron. *Jurnal Pengembangan Rekayasa Dan Teknologi*, 14(1), 1. <https://doi.org/10.26623/jprt.v14i1.1212>
- Mahendra, B. H., Chaerani, L., & Gumay, G. (2023). Analisis Perbandingan Prediksi Harga Saham Menggunakan Algoritma Artificial Neural Network dan Linear Regression. 22, 303–312.
- Malla Avila, D. E. (2022). No Title הכי קשה לראות את מה שבאמת לנגד העיניים. *הארץ*, 8.5.2017, 2003–2005.
- Maulidia, N. K. (2023). Penerapan artificial neural network pada proses klasifikasi curah hujan di Jawa Tengah. <http://etheses.uin-malang.ac.id/id/eprint/58140>
- Muslehatin, W., Ibnu, M., & Mustakim. (2017). Penerapan Naïve Bayes Classification untuk Klasifikasi Tingkat Kemungkinan Obesitas Mahasiswa Sistem Informasi UIN Suska Riau. *Seminar Nasional Teknologi Informasi, Komunikasi Dan Industri (SNTIKI)*, 9, 250–256.
- Muslim, M. A., Prasetyo, B., Mawarni, E. L. H., Herowati, A. J., Mirqotussa'adah,

- Rukmana, S. H., & Nurzahputra, A. (n.d.). *Data Mining Algoritma C4.5*.
- Muttakin, M., & Hanadwiputra, S. (2022). *PENINGKATAN AKURASI PREDIKSI PENGADAAN BAHAN BAKU PRODUKSI DENGAN MENGGUNAKAN METODE NEURAL NETWORK. 1*.
- Nasution, D. A., Khotimah, H. H., & Chamidah, N. (2019). Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *Computer Engineering, Science and System Journal*, 4(1), 78. <https://doi.org/10.24114/cess.v4i1.11458>
- Nasution, M. K., Saedudin, R. R., & Widartha, V. P. (2021). Perbandingan Akurasi Algoritma Naïve Bayes Dan Algoritma Xgboost Pada Klasifikasi Penyakit Diabetes. *E-Proceeding of Engineering*, 8(5), 9765–9772. <https://journal.ubpkarawang.ac.id/mahasiswa/index.php/ssj/article/view/424/338> %0A<https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/15759>
- Novita Veronika. (2022). *Peramalan Data Deret Waktu Menggunakan Algoritma Backpropagation Neural Network (Bnn)*.
- Pan, Y., Wang, Y., Zhou, P., Yan, Y., & Guo, D. (2020). Activation functions selection for BP neural network model of ground surface roughness. *Journal of Intelligent Manufacturing*, 31(8), 1825–1836. <https://doi.org/10.1007/s10845-020-01538-5>
- Permadi, J., Rhomadhona, H., & Aprianti, W. (2021). Perbandingan K-Nearest Neighbor Dan Backpropagation Neural Network Dalam Prediksi Resiko Diabetes Tahap Awal. *Kumpulan Jurnal Ilmu Komputer (KLIK)*, 08(3), 352–365.
- Prabowo, J. R., Santoso, R., & Yasin, H. (2020). IMPLEMENTASI JARINGAN SYARAF TIRUAN BACKPROPAGATION DENGAN ALGORITMA CONJUGATE GRADIENT UNTUK KLASIFIKASI KONDISI RUMAH (Studi Kasus di Kabupaten Cilacap Tahun 2018). *Jurnal Gaussian*, 9(1), 41–49.

<https://doi.org/10.14710/j.gauss.v9i1.27522>

- Pratama, E. R., & Darmawan, J. B. B. (2021). Klasifikasi Status Gizi Balita Menggunakan Jaringan Syaraf. *Riset Dan Teknologi Terapan (RITEKTRA)*, 1–10. <https://journal.unpar.ac.id/index.php/ritektra/article/view/4899>
- Prayogo, E. E., Indriati, I., & Dewi, C. (2023). Klasifikasi Bidang Keunggulan Mahasiswa menggunakan Metode Backpropagation dan Seleksi Fitur Information Gain (Studi Kasus: Departemen Teknik Informatika *Jurnal Pengembangan Teknologi ...*, 7(1), 169–178. <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/12129>
- Rachmadina. (2024). *PENERAPAN METODE BACKPROPAGATION NEURAL NETWORK (BNN) UNTUK MEMPREDIKSI HARGA MINYAK DUNIA*. 1–23.
- Ridla, M. A. (2018). Particle Swarm Optimization Sebagai Penentu Nilai Bobot Pada Artificial Neural Network Berbasis Backpropagation Untuk Prediksi Tingkat Penjualan Minyak Pelumas Pertamina. *Jurnal Ilmiah Informatika*, 3(1), 183–192. <https://doi.org/10.35316/jimi.v3i1.473>
- Ridwan, A. S., Chrisnanto, Y. H., & Ilyas, R. (2021). Klasifikasi Kalimat Pada Berita Olahraga Secara Otomatis Menggunakan Metode Artificial Neural Network. *Jurnal Komputer Dan Informatika*, 9(1), 88–97. <https://doi.org/10.35508/jicon.v9i1.3708>
- Rifa'i, A. (2021). Prediksi Inflasi Indonesia Berdasarkan Fuzzy Ann Menggunakan Algoritma Genetika. *Jurnal ELTIKOM*, 5(1), 12–24. <https://doi.org/10.31961/eltikom.v5i1.215>
- Santoso, A., & Hansun, S. (2019). Prediksi IHSG dengan Backpropagation Neural Network. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 3(2), 313–318. <https://doi.org/10.29207/resti.v3i2.887>

- Santoso, A., & Hansun, S. (2021). *Prediksi IHSG dengan Backpropagation Neural Network*. *I*(10), 2–5.
- Saputra, D., Safii, M., Fauzan, M., & Tunas Bangsa, S. (2020). Implementasi Algoritma Backpropagation Dalam Memprediksi Harga Bahan Pangan. *Oktober, I*(4), 120–129.
- Saputro, J., Asruddin, Bani, A. U., & Mesran. (2022). *Penerapan Algoritma C4 . 5 Dalam Mengukur Tingkat Kepuasan Mahasiswa Terhadap Pelayanan Program Studi*. *4*(1), 196–202. <https://doi.org/10.47065/josyc.v4i1.2565>
- Serrat, A., & Djebbar, B. (2022). Experimental Analysis of Training Parameters Combination of ANN Backpropagation for Climate Classification. *Mathematical Modelling of Engineering Problems*, *9*(2), 507–514. <https://doi.org/10.18280/mmep.090229>
- Shafarindu, A. I., Ernawati, L., & Zaidiah, A. (2021). *Penerapan Algoritma Naive Bayes untuk Klasifikasi Tingkat Kebugaran Jasmani Berdasarkan Hasil Pengukuran pada Pegawai*. *September*, 278–287.
- Utama, R. E., & Parmadi, E. H. (2024). Penerapan Jaringan Syaraf Tiruan Backpropagation untuk Klasifikasi Akreditasi Sekolah Menengah Pertama. *Seminar Nasional Teknologi & Sains*, *3*(1), 45–52. <https://doi.org/10.29407/stains.v3i1.4133>
- Utomo, D. P., & Purba, B. (2019). Penerapan Datamining pada Data Gempa Bumi Terhadap Potensi Tsunami di Indonesia. *Prosiding Seminar Nasional Riset Information Science (SENARIS)*, *1*(September), 846. <https://doi.org/10.30645/senaris.v1i0.91>
- Wibawa, M. S. (2017). Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan. *Jurnal Sistem Dan Informatika (JSI)*, *11*(December), 167–174. <https://doi.org/10.13140/RG.2.2.21139.94241>