

ALGORITMA NEURAL NETWORK MENGUNAKAN MODEL PARTICLE SWARM OPTIMIZATION UNTUK PREDIKSI PENYAKIT KANKER PAYUDARA

Marsiska Ariesta P¹, Iwan Setiawan W²

Sistem Teknologi Informasi, ITBS Semarang

Jl. Jenderal Sudirman No.346, Gisikdrono, Kec. Semarang Barat, Kota Semarang, Jawa Tengah 50149

Email: siskaloyal99@gmail.com,

ABSTRACT

Breast cancer is one of the causes of cancer deaths in women worldwide. One technique to diagnose breast cancer: mammography. In this study developed a system to classify the "Breast Cancer" using Backpropagation neural network optimized with Particle Swarm Optimization for classifying tumors of the symptoms that cause breast cancer. The main objective of this study was to develop a more cost effective and easy to use system to support doctors. For the problem of diagnosis of breast cancer tumor symptoms, the experimental results show that the neural network based model of particle swarm optimization achieved a high degree of accuracy. Dataset used in this study were breast cancer database from the University of Wisconsin Machine Learning (UCI) Repository.

Keywords: *Breast Cancer, Backpropagation, Particle Swarm Optimization, Accuracy*

I. PENDAHULUAN

A. LatarBelakang

Kanker payudara merupakan salah satu kanker yang pada umumnya menimpa sebagian besar wanita. Kanker payudara adalah tumor ganas yang menyerang jaringan payudara (Purwoastuti, 2008 : p13). Sebuah tumor ganas terdiri dari sel-sel yang menyerang atau menyebar ke bagian lain dari tubuh. Wanita di seluruh dunia sering terganggu oleh pikiran didiagnosa menderita kanker payudara. Pada tahun 2008, terdapat 1.383.000 kasus kanker payudara dilaporkan dengan 458.000 kematian akibat kanker payudara di seluruh dunia (IRCA, 2008 : p8). Menurut data yang dipublikasikan pada 2011 kematian kanker payudara di Indonesia mencapai 20.052 atau 1,41% dari total kematian (WHO, 2011 : p5). Tingkat kematian yang disebabkan oleh kanker payudara berdasarkan usia adalah 20,25 per 100.000 penduduk Indonesia menempati urutan ke 45 di dunia. Salah satu cara untuk mendeteksi penyakit kanker payudara adalah dengan menggunakan mammography akan tetapi tingkat akurasi masih belum optimal. Sehingga perlu dilakukan penelitian lebih lanjut untuk meningkatkan akurasi deteksi kanker payudara.

B. Tujuan Penelitian

Menerapkan Particle Swarm Optimazation (PSO) pada optimasi bobot BP neural network, dengan menguji coba dataset yang ada untuk meningkatkan akurasi prediksi penyakit kanker payudara

C. Manfaat Penelitian

Manfaat yang diharapkan dari penelitian ini adalah:

- Hasil dari penelitian ini diharapkan dapat membantu para dokter di rumah sakit untuk mendeteksi penyakit kanker payudara dengan biaya yang lebih hemat.
- Penelitian ini dapat menghasilkan prediksi yang lebih akurat dalam penelitian sebelumnya.
- Menambah wawasan serta pengetahuan khususnya dalam penerapan neural network dan particle swarm optimization dalam prediksi kanker payudara.

II. TINJAUAN PUSTAKA

A. Neural Network

Neural network pertama kali diperkenalkan oleh McCulloch dan Pitts pada tahun 1943. McCulloch dan Pitts menyimpulkan bahwa kombinasi beberapa neuron sederhana menjadi sebuah sistem neural akan meningkatkan kemampuan komputasinya. Bobot

dalam jaringan yang diusulkan oleh McCulloch dan Pitts diatur untuk melakukan fungsi logika sederhana. Fungsi aktivasi yang dipakai adalah fungsi threshold (Siang, 2009 : p31).

Neural Network mencoba untuk meniru perilaku sel – sel otak manusia (Heaton, 2008 : p10). Sel neuron menerima sinyal dari dendrit. Ketika neuron menerima sinyal, neuron dapat menyala. Ketika neuron menyala, sinyal ditransmisikan melalui akson. Pada akhirnya, sinyal akan meninggalkan neuron karena perjalanan ke akson terminal. Sinyal ditransmisikan ke neuron lain atau saraf. Sinyal yang ditransmisikan oleh neuron adalah sebuah sinyal analog. Sedangkan pada komputer modern adalah mesin digital yang memerlukan sinyal digital dalam memproses informasi. Sehingga digunakan digit digital 0 (mati) dan 1 (hidup).

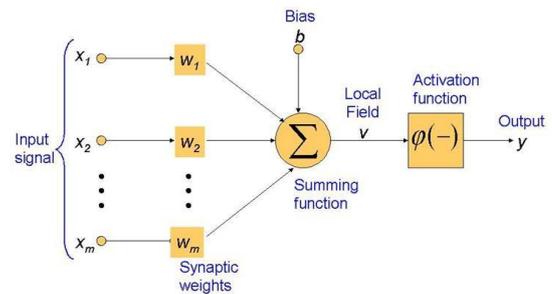
Neural network biasanya diimplementasikan dengan menggunakan komponen elektronika atau disimulasikan dalam sebuah perangkat lunak pada komputer digital. Untuk mencapai tampilan yang baik, neural network memakai interkoneksi yang sangat besar antara sel-sel komputasi yang disebut "neuron" atau "unit pemroses". Sebagai mesin yang adaptif, sebuah neural network adalah sebuah processor besar terdistribusi yang paralel yang tersusun dari unit pemroses sederhana yang mempunyai kecenderungan untuk menyimpan pengalaman dan pengetahuan dan membuatnya siap untuk digunakan. Hal itu menyerupai otak dalam dua aspek:

- a. Pengetahuan dibutuhkan oleh jaringan dari lingkungannya melalui proses pembelajaran.
- b. Kekuatan koneksi interneuron, dikenal sebagai bobot sinapsis, digunakan untuk menyimpan pengetahuan yang dibutuhkan.

Neural network adalah system pemroses informasi yang memiliki karakteristik mirip dengan jaringan saraf biologi (Siang, 2009 : p2). Neural network telah dikembangkan sebagai generalisasi model matematika dari jaringan saraf biologi, berdasarkan asumsi:

- a. Pemrosesan informasi terjadi pada neuron.
- b. Sinyal dikirimkan antarneuron melalui penghubung dendrit dan akson.
- c. Penghubung antarelemen memiliki bobot yang akan menambah dan mengurangi sinyal.
- d. Untuk menentukan output, setiap neuron memiliki fungsi aktivasi yang dikenakan pada jumlah semua inputnya. Besar output akan dibandingkan dengan nilai threshold tertentu.

Secara matematis, proses ini dijelaskan dalam gambar 2.1



Gambar 2.1 Model matematis dari neural network

Berdasarkan model matematis tersebut, baik tidaknya neural network ditentukan oleh hal-hal berikut: arsitektur jaringan, metode pembelajaran dan fungsi aktivasi (Siang, 2009: p3).

B. Arsitektur Jaringan

Baik tidaknya suatu model neural network salah satunya ditentukan oleh hubungan antarneuron atau yang biasa disebut sebagai arsitektur jaringan (Siang, 2009 : p24). Neuron- neuron tersebut berkumpul dalam lapisan-lapisan yang disebut neuron layer. Lapisan-lapisan penyusun neural network dibagi menjadi tiga yaitu:

- a. Input Layer adalah unit-unit dalam lapisan input disebut unit-unit input yang bertugas menerima pola inputan dari luar yang menggambarkan suatu permasalahan.
- b. Hidden Layer adalah unit-unit dalam lapisan tersembunyi disebut unit-unit tersembunyi, yang mana nilai output-nya tidak dapat diamati secara langsung.
- c. Output Layer adalah unit-unit dalam lapisan output disebut unit-unit output, yang merupakan solusi neural network terhadap suatu permasalahan.

Dalam menentukan jumlah layer, input tidak terhitung sebagai layer karena layer tersebut tidak melakukan proses komputasi. Atau bisa dikatakan bahwa jumlah layer pada jaringan ditentukan berdasarkan lapisan yang berisikan bobot antar koneksi dari kumpulan neuron-neuron. Hal inilah yang mendasari bahwa bobot pada neural network berisikan informasi yang sangat penting.

Adapun jenis arsitektur yang sering digunakan dalam neural network antara lain:

1. Jaringan lapisan tunggal

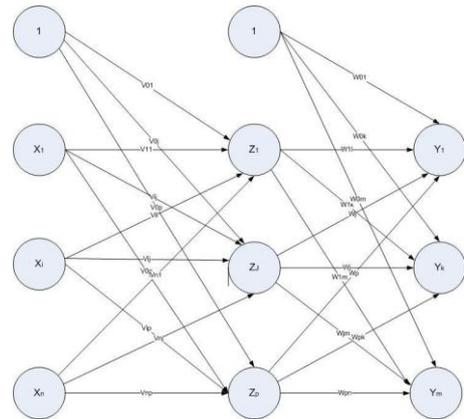
Jaringan lapisan tunggal mempunyai satu lapisan bobot terkoneksi. Pada lapisan ini, unit input dapat dibedakan dengan unit output. Dimana unit input merupakan unit yang menerima sinyal dari dunia luar sedangkan unit output adalah unit dimana respon dari jaringan dapat terlihat.

2. Jaringan lapisan banyak

Jaringan lapisan banyak adalah jaringan dengan satu atau lebih lapisan diantara lapisan input dan lapisan output yang biasa disebut lapisan tersembunyi (hidden layer).

3. Jaringan dengan lapisan kompetitif

Bentuk lapisan kompetitif merupakan neural network yang sangat besar. Interkoneksi antarneuron pada lapisan ini tidak ditunjukkan pada arsitektur seperti jaringan yang lain.



Gambar 2.2 Arsitektur BP network network

C. Fungsi Aktivasi

Fungsi aktivasi merupakan bagian penting dalam tahapan perhitungan output dari suatu algoritma (Hermawan, 2006 : p11). Beberapa fungsi aktivasi yang sering digunakan adalah sebagai berikut:

- a. Fungsi threshold (batas ambang)

$$F(x) = \int_0^1 \text{jika } x \geq 0, \text{jika } x < 0 f(x)$$

Untuk beberapa kasus, fungsi threshold yang dibuat tidak nilai 0 atau 1, tapi bernilai -1 atau 1 (sering disebut threshold bipoar). Jadi

$$F(x) = \int_{-1}^1 \text{jika } x \geq 0, \text{jika } x < 0 f(x)$$

- b. Fungsi sigmoid

$$F(x) = \frac{1}{1 + \delta^{-x}}$$

Fungsi sigmoid sering dipakai karena nilai fungsinya yang terletak antara 0 dan 1 dan dapat diturunkan dengan mudah.

- c. Fungsi identitas

$$f'(x) = f(x)(1 - f(x))$$

$$f(x) = x$$

sering dipakai apabila menginginkan output jaringan berupa sembarang bilangan riil (bukan hanya pada range [0,1] atau [-1,1]).

D. Backpropagation neural network (BP neural network)

Backpropagation adalah salah satu model neural network. BP neural network merupakan algoritma error backpropagation untuk forward propagation multilayer yang diusulkan oleh D. Ruvmelhar dan McClelland tahun 1985. Arsitektur BP neural network terdiri dari input layer dan output layer seperti pada Gambar 2.2

Pelatihan dengan metode backpropagation terdiri dari 3 fase yaitu :

- a. Fase pertama adalah fase propagasi maju (forward propagation). Pola masukan dihitung maju mulai dari layer masukan hingga layer keluaran menggunakan fungsi aktivasi yang ditentukan.
- b. Fase kedua adalah fase propagasi mundur (backpropagation). Selisih antara keluaran jaringan dengan target yang diinginkan merupakan kesalahan yang terjadi. Kesalahan tersebut dipropagasikan mundur, dimulai dari garis yang berhubungan langsung dengan unit –unit di layar keluaran.
- c. Fase ketiga adalah modifikasi bobot dan bias untuk menurunkan kesalahan yang terjadi

Algoritma backpropagation

- a. Inisialisasi bobot (ambil nilai acak yang cukup kecil)
- b. Selama kondisi berhenti bernilai salah, kerjakan:

Fase I : Propagasi Maju(forward propagation)

- 1. Setiap unit input ($x_i, i = 1,2,3, \dots, n$) menerima sinyal x_i dan meneruskan sinyal tersebut ke semua unit pada hidden layer.
- 2. Setiap unit tersembunyi ($z_j, j = 1,2,3, \dots, p$), menjumlahkan bobot sinyal input dengan persamaan berikut,

$$z_inj = v0j + \sum_n x_i v_{ij} \quad (2.1)$$

Dan menerapkan fungsi aktivasi untuk menghitung sinyal output-nya;

$$z_j = f(z_inj) \quad (2.2)$$

Biasanya fungsi aktivasi yang digunakan adalah sigmoid, kemudian mengirimkan sinyal tersebut ke semua output

- 3. Setiap unit output ($y_k, k = 1,2,3, \dots, m$) menjumlahkan bobot sinyal input

$$y_ink = w0k + \sum_p z_j w_{jk} \quad (2.3)$$

Dan menerapkan fungsi aktivasi untuk menghitung sinyal output-nya;

$$yk = f(y_{ink}) \quad (2.4)$$

Fase II : Propagasi mundur (Backpropagation)

1. Setiap unit output ($yk, k = 1,2,3, \dots, m$) menerima pola target yang sesuai dengan pola input pelatihan, kemudian hitung error dengan persamaan berikut;

$$(\delta k = tk - yk)f'(y_{ink}) \quad (2.5)$$

f' adalah turunan dari fungsi aktivasi kemudian hitung koreksi bobot dengan persamaan sebagai berikut:

$$\Delta w_{0k} = \alpha * \delta k * z_j \quad (2.6)$$

Dan menghitung koreksi bias dengan persamaan berikut,

$$\Delta w_{0k} = \alpha * \delta k \quad (2.7)$$

Sekaligus mengirimkan δk ke unit-unit yang ada di layer paling kanan

2. Setiap unit tersembunyi ($z_j, j = 1,2,3, \dots, p$) menjumlahkan delta inputnya (dari unit-unit yang berada pada lapisan di kanannya):

$$\delta_{inj} = \sum_m \delta k w_{jk} \quad (2.8)$$

Untuk menghitung informasi error, kalikan nilai ini dengan turunan dari fungsi aktivasinya:

$$\delta_j = \delta_{inj} f'(z_{inj}) \quad (2.9)$$

kemudian hitung koreksi bobot dengan persamaan sebagai berikut:

$$\Delta v_{jk} = \alpha * \delta_j * x_i \quad (2.10)$$

Dan menghitung koreksi bias dengan persamaan berikut,

$$\Delta v_{0j} = \alpha * \delta_j \quad (2.11)$$

Fase III : Perubahan bobot dan bias

1. Setelah unit output ($yk, k = 1,2,3, \dots, m$) dilakukan perubahan bobot dan bias ($z_j, j = 1,2,3, \dots, p$) dengan persamaan berikut.

$$W_{jk}(\text{baru}) = W_{jk}(\text{lama}) + \Delta W_{jk} \quad (2.12)$$

Setiap unit tersembunyi ($z_j, j = 1,2,3, \dots, p$) dilakukan perubahan bobot dan bias ($z_i, i = 1,2,3, \dots, m$) dengan persamaan berikut.

$$V_{ij}(\text{baru}) = V_{ij}(\text{lama}) + \Delta V_{ij} \quad (2.13)$$

2. Tes kondisi berhenti

BP neural network ini banyak digunakan dalam feed forward multilayer neural network dengan beberapa output, yang dapat digunakan dalam klasifikasi nonlinier. BP neural network saat ini merupakan neural network yang paling banyak digunakan dalam bidang pengolahan informasi dan pengenalan pola. Tapi kelemahan BP neural network ini, teletak pada lamanya waktu pelatihan dan mudah masuk ke lokal minimum. Sehingga perlunya melakukan optimasi pada beberapa parameter BP neural network untuk mendapatkan hasil akurasi yang lebih baik.

E. Particle Swarm Optimization

PSO merupakan salah satu algoritma kecerdasan swarm yang pada awalnya dikembangkan oleh Kennedy dan Eberhart pada tahun 1995. Ini didorong oleh perilaku sosial dari kawanan burung atau kawanan ikan yang sejenis (Sun, Lai, & Vu, 2012 : p304). Teori ini dikembangkan berdasarkan proses adaptasi alamiah dengan tiga prinsip dasar yaitu: evaluasi, membandingkan, dan meniru. Algoritma PSO adalah salah satu algoritma evolusioner yang mirip dengan algoritma genetika dan menggunakan fungsi fitness untuk mengevaluasi kualitas dari solusi. PSO memiliki keunggulan seperti: sederhana, sedikit parameter, kecepatan konvergensi yang cepat dan mudah terealisasi, sehingga PSO lebih banyak diterapkan dalam bidang optimasi fungsi, pelatihan neural network, klasifikasi pola dan algoritma optimasi tradisional.

Dalam PSO, setiap solusi potensial yang ada pada suatu masalah dioptimalkan menjadi individu dalam ruang pencarian, yang disebut "partikel". Artinya bahwa posisi setiap partikel adalah solusi potensial. Pertama PSO menginisialisasi sekelompok partikel secara acak, dan setiap partikel bergerak dalam ruang solusi. Sebuah vektor memutuskan kemana arah dan perpindahan partikel, serta fitness yang sesuai dihitung dengan fungsi untuk menilai apakah target tercapai atau tidak. Dan solusi optimal dapat diperoleh dengan iterasi. Partikel memperbarui diri dengan menelusuri dua nilai ekstrim dalam setiap iterasi.

F. Kanker Payudara

Kanker payudara adalah tumor ganas dari salah satu kelenjar kulit di sebelah luar rongga dada (Jong, 2004 : p317). Kanker payudara merupakan penyakit yang paling ditakuti oleh kaum wanita. Dari hasil penelitian para ahli bahwa satu dari delapan wanita terkena kanker payudara. Kanker payudara umumnya menyerang wanita yang telah berumur 40 tahun lebih, tapi wanita muda pun tidak menutup kemungkinan terkena kanker ini.

Kanker payudara di banyak negara merupakan kanker yang paling sering terjadi dan penyebab kematian terpenting (karena kanker) pada wanita. Pada pria, penyakit ini sangat jarang terjadi; rata-rata tidak sampai setengah persen dari insidens pada wanita. Insidens ini meningkat dengan usia. Di bawah tiga puluh tahun, kanker payudara sangat jarang muncul. Berdasarkan data yang didapat dari PERABOI (Perhimpunan Ahli Bedah Orkologi Indonesia, 2003 : p106), didapatkan prognosis daya tahan hidup penderita kanker payudara (survival rate) per stadium sebagai berikut:

- a. Stadium 0 : 10 years survival ratenya 98% (nonpalpable breast cancer yang terdeteksi oleh mammografi/USG)

- b. Stadium 1 : 5 years survival ratenya 85%
- c. Stadium 2 : 5 years survival ratenya 60-70%
- d. Stadium 3 : 5 years survival ratenya 30-50%

Sampai saat ini patofisiologi kanker payudara masih belum diketahui secara pasti, sehingga upaya deteksi dini yang dilakukan hanya sebatas tujuan untuk mendeteksi penderita kanker payudara yang masih stadium sangat rendah dan kemungkinan untuk bertahan hidup tinggi.

III. METODOLOGI PENELITIAN

A. Analisa Kebutuhan

Untuk menunjang eksperimen dalam penelitian ini dibutuhkan satu unit PC (Personal Computer) atau notebook untuk melakukan simulasi menggunakan software Rapid miner 5.2

B. Perancangan Penelitian

Dalam penelitian ini metode yang digunakan untuk model neural network berbasis particle swarm optimization untuk prediksi penyakit kanker payudara adalah metode eksperimen, dimana data yang diambil merupakan dataset kanker payudara Wincosin yang telah dikumpulkan oleh Dr. William H. Wolberg di Universitas Rumah sakit Madison Wincosin. Ada 699 baris pada database ini. Setiap baris pada database memiliki Sembilan atribut.

Tabel 3.1 Deskripsi atribut data kanker payudara pada dataset Wisconsin

No	Atribut	Keterangan
1	Sample code number	No-id
2	Clump Thickness	1-10
3	Uniformity of cell size	1-10
4	Uniformity of cell shape	1-10
5	Marginal Adhesion	1-10
6	Single epithelial cell size	1-10
7	Bare nuclei	1-10
8	Bland Chromatin	1-10
9	Normal Nucleoli	1-10
10	Mitoses	1-10
11	Class	2 untuk tumor jinak 4 untuk tumor ganas

Nilai atribut yang hilang ada 16.

- a. Ada 16 baris di grup 1 sampai 6 yang mengandung satu hilang yaitu, tidak tersedia nilai atributnya, dilambangkan dengan "?".
- b. Distribusi kelas: tumor jinak terdiri dari 458 (65,5%) dan tumor ganas terdiri dari 241 (34,5%).

C. Metode yang diusulkan

Dalam penelitian ini metode yang diusulkan berdasarkan state of the art tentang Model Neural Network berbasis Particle Swarm Optimazation untuk prediksi penyakit kanker payudara untuk meningkatkan nilai akurasi dengan menyesuaikan parameter – parameter yang ada pada neural network sehingga didapat model arsitektur neural network yang terbaik. Selanjutnya arsitektur neural network tersebut di optimasi bobotnya dengan menggunakan PSO sehingga menghasilkan output berupa root mean square error (RMSE) yang terkecil dan accuracy yang besar. Metode yang diusulkan dapat dilihat pada gambar 3.1.



Gambar 3.1 Metode yang diusulkan

Pada metode yang diusulkan algoritma BP neural network digabungkan dengan algoritma PSO untuk mengoptimalkan bobot dan fungsi aktivasi. Adapun fungsi fitness pada PSO diperoleh dari RMSE arsitektur BP neural network. Berikut adalah langkah – langkah optimasi bobot BP neural network dengan PSO:

- a. Langkah 1: Menentukan struktur neural network, termasuk pengaturan jumlah training cycles, learning rate, momentum, size dan jumlah hidden layer.
- b. Langkah 2: Menentukan particle swarms, termasuk populasi size, kecepatan, berat inersia dan sebagainya. Menentukan fungsi fitness dengan menggunakan RSME struktur neural network menjadi fitness untuk memandu pencarian populasi.
- c. Langkah 3: Menghitung fitness, menggunakan sampel training dihitung dengan propagasi maju (forward propagation), untuk menghitung fitness gunakan rumus 5.
- d. Langkah 4: Memperbaharui individu dan optimasi global.
- e. Langkah 5: Memperbaharui posisi dan kecepatan

dari masing-masing partikel dengan rumus (2.14) dan (2.15) serta memperbaharui berat inersia.

- f. Langkah 6: Jika Jika salah satu jaringan telah mencapai error minimum yang diharapkan atau jumlah iterasi maksimum, simpan bobotnya dan solusi optimal akan dihasilkan. Jika tidak, kembali ke langkah 3.

IV. HASIL DAN PEMBAHASAN

1. Parameter Neural Network dan Particle Swarm Optimazation

- a. Menentukan Nilai training cycles, Learning Rate dan Momentum

Nilai training cycles dalam penelitian ini ditentukan dengan cara melakukan uji coba memasukkan nilai dengan range 100 sampai dengan 1500 untuk training cycles, serta nilai 0.3 untuk learning rate dan 0.2 untuk momentum. Berikut ini adalah hasil dari percobaan yang telah dilakukan untuk penentuan nilai training cycles:

Tabel 4.1 Percobaan Penentuan Nilai Training Cycles

Training Cycles	Learnng Rate	Momen tum	RMSE	Accuracy
100	0.3	0.2	0.150	96.71%
200	0.3	0.2	0.150	96.71%
300	0.3	0.2	0.150	96.71%
400	0.3	0.2	0.149	96.71%
500	0.3	0.2	0.149	96.57%
600	0.3	0.2	0.149	96.42%
700	0.3	0.2	0.149	96.42%
800	0.3	0.2	0.149	96.42%
900	0.3	0.2	0.149	96.42%
1000	0.3	0.2	0.149	96.42%
1100	0.3	0.2	0.149	96.42%
1200	0.3	0.2	0.149	96.42%
1300	0.3	0.2	0.149	96.42%
1400	0.3	0.2	0.149	96.42%
1500	0.3	0.2	0.149	96.42%

Nilai training cycles dipilih berdasarkan nilai (RMSE) terkecil dan nilai accuracy yang terbesar. Berdasarkan hasil percobaan di atas, dipilih nilai training cycles sebesar 400 karena terletak pada root mean square error (RMSE) terkecil yaitu 0.149 dan nilai accuracy terbesar yaitu 96.71%. Nilai 400 ini selanjutnya dipakai untuk percobaan dalam menentukan nilai learning rate. Nilai learning rate ditentukan dengan cara melakukan dengan uji coba memasukkan nilai dengan range 0.1 sampai dengan 1. Nilai training cycles dipilih dari percobaan sebelumnya

yaitu 400, sedangkan 0.2 digunakan untuk nilai momentum. Berikut ini adalah hasil dari percobaan yang telah dilakukan untuk penentuan nilai learning rate:

Tabel 4.2 Percobaan Penentuan Nilai Learning Rate

Training Cycles	Learnng Rate	Moment um	RMSE	Accuracy
400	0.1	0.2	0.160	96.57%
400	0.2	0.2	0.151	96.57%
400	0.3	0.2	0.149	96.71%
400	0.4	0.2	0.149	96.42%
400	0.5	0.2	0.149	96.42%
400	0.6	0.2	0.150	96.57%
400	0.7	0.2	0.150	96.57%
400	0.8	0.2	0.151	96.57%
400	0.9	0.2	0.151	96.57%
400	1	0.2	0.152	96.57%

Nilai learning rate dipilih berdasarkan nilai rmse terkecil yang dihasilkan yaitu 0.149 dan nilai accuracy terbesar yaitu 96.71%. Berdasarkan hasil percobaan di atas, dipilih nilai learning rate sebesar 0.3. Nilai 0.3 ini selanjutnya dipakai untuk percobaan dalam menentukan nilai momentum. Nilai momentum ditentukan dengan cara melakukan dengan uji coba memasukkan nilai dengan range 0 sampai dengan 0.9. Nilai training cycles 400 dan learning rate 0.3 dipilih berdasarkan percobaan sebelumnya. Berikut ini adalah hasil dari percobaan yang telah dilakukan untuk penentuan nilai momentum:

Tabel 4.3 Percobaan Penentuan Nilai Momentum

Training Cycles	Lear ning Rate	Mome ntum	RMSE	Accuracy
400	0.3	0.0	0.150	96.71%
400	0.3	0.1	0.150	96.71%
400	0.3	0.2	0.149	96.71%
400	0.3	0.3	0.149	96.42%
400	0.3	0.4	0.149	96.42%
400	0.3	0.5	0.149	96.42%
400	0.3	0.6	0.150	96.57%
400	0.3	0.7	0.150	96.57%
400	0.3	0.8	0.153	96.57%
400	0.3	0.9	0.155	96.42%

Berdasarkan hasil percobaan di atas, maka untuk parameter neural network dipilih nilai 400 untuk training cycles 0.3 untuk learning rate dan 0.2 untuk momentum

b. Penentuan Jumlah dan Size Hidden Layer

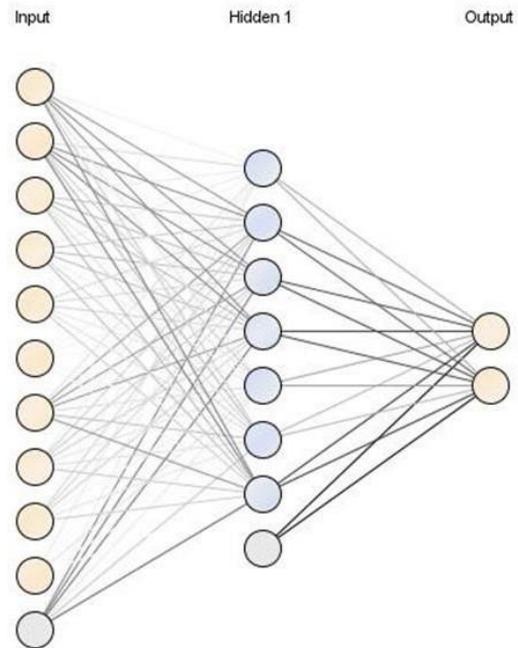
Untuk 1 hidden layer, dilakukan percobaan size dengan range 1 sampai dengan 30. Berikut ini adalah hasil dari percobaan yang telah dilakukan:

Tabel 4.4 Percobaan dengan Satu Hidden Layer

Hidden Layer	Neuron Size	Training Cycle	Learning Rate	Momentum	RMS E	Accuracy
1	1	400	0.3	0.2	0.154	96.28%
1	2	400	0.3	0.2	0.150	96.28%
1	3	400	0.3	0.2	0.149	96.28%
1	4	400	0.3	0.2	0.149	96.28%
1	5	400	0.3	0.2	0.149	96.28%
1	6	400	0.3	0.2	0.149	96.28%
1	7	400	0.3	0.2	0.149	96.71%
1	8	400	0.3	0.2	0.149	96.57%
1	9	400	0.3	0.2	0.150	96.42%
1	10	400	0.3	0.2	0.149	96.57%
1	11	400	0.3	0.2	0.150	96.57%
1	12	400	0.3	0.2	0.149	96.71%
1	13	400	0.3	0.2	0.150	96.57%
1	14	400	0.3	0.2	0.150	96.57%
1	15	400	0.3	0.2	0.150	96.71%
1	16	400	0.3	0.2	0.149	96.57%
1	17	400	0.3	0.2	0.150	96.57%
1	18	400	0.3	0.2	0.150	96.71%
1	19	400	0.3	0.2	0.149	96.71%
1	20	400	0.3	0.2	0.149	96.71%
1	21	400	0.3	0.2	0.150	96.71%
1	22	400	0.3	0.2	0.150	96.71%
1	23	400	0.3	0.2	0.150	96.71%
1	24	400	0.3	0.2	0.149	96.85%
1	25	400	0.3	0.2	0.150	96.71%
1	26	400	0.3	0.2	0.149	96.71%
1	27	400	0.3	0.2	0.150	96.71%
1	28	400	0.3	0.2	0.149	96.71%
1	29	400	0.3	0.2	0.149	96.57%
1	30	400	0.3	0.2	0.149	96.71%

Hasil terbaik pada percobaan dengan satu hidden layer yaitu hidden layer dengan size 7 dan rmse yang dihasilkan sebesar 0.149.

Arsitektur neural network terbaik yang didapatkan dari percobaan, dapat dilihat pada gambar 4.1 ini:



Gambar 4.1 Arsitektur neural network

c. Optimasi BP neural network berbasis PSO

Pada tahap ini, struktur BP neural network yang dihasilkan pada percobaan dimasukkan ke dalam rapidminer (tools) dioptimasi dengan optimize weight (PSO) dengan system default. Dimana pada optimize weight (PSO) memiliki nilai untuk population size: 5, generation max: 30, inertia weight: 1.0, local best weight: 1.0 dan global best weight: 1.0

Selanjutnya dilakukan penambahan jumlah populasi (population size) untuk mencari model yang ideal atau yang terbaik dengan membuat model sebagai berikut:

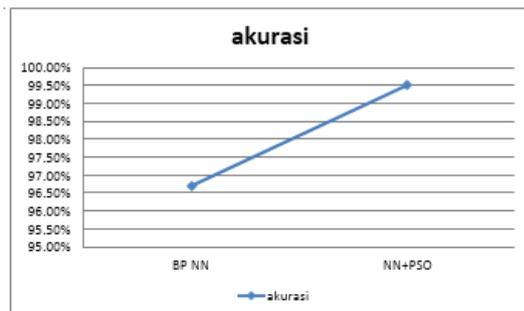
Tabel 4.5 Model optimasi BP neural network dengan PSO

Model	Population	Generation	Inertia weight	RMSE	Accuracy
1	5	30	1	0.113	99.52%
2	6	30	1	0.123	98.57%
3	7	30	1	0.120	98.57%
4	8	30	1	0.135	98.57%
5	9	30	1	0.121	99.05%

6	10	30	1	0.114	99.52%
7	11	30	1	0.112	99.05%
8	12	30	1	0.098	99.52%
9	13	30	1	0.084	99.52%
10	14	30	1	0.129	98.57%

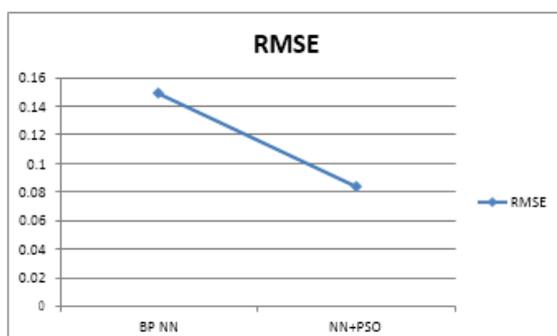
2. Evaluasi dan Validasi hasil

Pada percobaan ini dilakukan dengan membandingkan hasil akurasi dengan metode BP neural network dengan NN+PSO dengan menguji dataset kanker payudara. Hasil menunjukkan untuk BP neural network mendapatkan hasil akurasi 96.71% sedangkan NN dengan PSO mendapatkan nilai akurasi 99.52% seperti terlihat pada gambar berikut:



Gambar 4.2 Hasil akurasi

Sedangkan root mean square error (RMSE) yang dihasilkan dengan BP neural network dengan dataset yang sama di dapat nilai RMSE sebesar 0.149 dan untuk RMSE dengan NN+PSO mendapat nilai 0.084 dengan selisih 0.065 dapat dilihat pada gambar di bawah ini:



Gambar 4.3 Hasil RMSE

3. Implikasi Penelitian

Berdasarkan model neural network berbasis particle swarm optimization untuk prediksi penyakit kanker payudara yang telah dilakukan di atas,

menunjukkan bahwa prediksi penyakit kanker payudara dengan metode tersebut dapat dijadikan referensi untuk membantu dokter dalam mengambil keputusan.

Pengujian Model Neural Network berbasis Particle Swarm Optimization pada penelitian ini mendapatkan hasil akurasi yang baik yaitu 99.52% dengan menggunakan dataset yang sama pada penelitian sebelumnya.

Kendala pada penelitian ini adalah dibutuhkan waktu komputasi yang lebih lama sehingga diperlukan metode lain yang mengarah kepada efisiensi waktu komputasi yang lebih sedikit.

V. KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan eksperimen yang dilakukan dalam penelitian ini dapat ditarik kesimpulan bahwa:

- Pengujian model neural network yang dioptimasi dengan particle swarm optimization mencapai nilai akurasi sebesar 99.52% dengan root mean square error (RMSE) sebesar 0.083.
- PSO (Particle Swarm Optimization) dalam optimasi bobot dapat membantu menghasilkan nilai akurasi yang tinggi dalam prediksi kanker payudara.
- Penyesuaian jumlah populasi dapat memberikan optimasi yang lebih baik, tetapi diikuti dengan penambahan waktu komputasi

Saran

Saran-saran yang dapat digunakan untuk penelitian berikutnya untuk mencapai hasil yang lebih baik diantaranya:

- Untuk menghasilkan prediksi yang lebih akurat dan pengurangan waktu komputasi diperlukan penelitian lebih lanjut, yaitu dengan mengoptimasi neural network dengan pendekatan komputasi cerdas lainnya, Contohnya dengan Feature selection dan optimize parameters.
- Untuk menghasilkan prediksi yang lebih akurat dari penelitian ini, diperlukan pembersihan data dari data yang missing pada pengolahan data awal

DAFTAR PUSTAKA

- Chunekar, V. N., & Ambulgekar, H. P. (2009). Approach of Neural Network to Diagnose Breast Cancer on Three Different Data Set. International Conference on Advances in Recent Technologies in Communication and Computing.

- Heaton, J. (2008). Introduction to Neural Networks with Java. United States of America: Heaton Research.Inc.
- Hermawan, A. (2006). Jaringan Saraf Tiruan, Teori dan Aplikasi. Yogyakarta: Andi Offset.
- International Research Cancer Agency. (2008). Globacon 2008 International Agency for Research on Cancer. World Health Organization, IRCA.
- Jong, W. d. (2004). Kanker,Apakah itu?pengobatan, harapan hidup dan dukungan keluarga. Jakarta: Arcan.
- Jung, & Wang, Y. (2003). Data Mining Analysis (breast-cancer data). AI term project.
- Liu, L., & Deng, M. (2010). An Evolutionary Artificial Neural Network Approach for Breast Cancer Diagnosis. 2010 Third International Conference on Knowledge Discovery and Data Mining (pp. 593 - 596). IEEE Computer Society.
- Purwoastuti, E. (2008). Kanker Payudara. Yogyakarta: Kanisius.
- Siang, J. J. (2009). Jaringan Syaraf Tiruan dan Pemogramannya Menggunakan MATLAB. Yogyakarta: C.V Andi Offset.
- Sufyian, M., & Cob, Z. C. (2010). Breast Cancer Prediction Based On Backpropagation Algorithm. Proceedings of 2010 IEEE Student Conference on Research and Development (SCOReD 2010). malaysia: IEEE.
- Sun, J., Lai, C. H., & Vu, X. J. (2012). Particle Swarm Optimazation: Classical and Quantum Perspectives. United States of America : Taylor & FrancisGroup. LLC.
- Trelea, C. I. (2003). The Particle swarm Optimazation Algorithm: Convergence Analysis and Parameter Selection. Information Processing Letters.
- Vazirani, H., Shukla, A., Kala, R., & Tiwari, R. (2010). Diagnosis of Breast Cancer by Modular Neural Network. Computer Sciene and Information Tecnology (ICCSIT).
- World Health Organization. (2011). World Health Rangkings. United Nations,World Health Organization.Tarjo, 2019. *Metode Penelitian*. 1nd ed. Yogyakarta: DEEPUBLISH.
- Widodo, 2017. *Metodologi Penelitian Populer dan Praktis*. 1st ed. Depok: PT RajaGrafindo Persada.