

METODE HYBRID PARTICLE SWARM OPTIMIZATION - NEURAL NETWORK BACKPROPAGATION UNTUK PREDIKSI HASIL PERTANDINGAN SEPAK BOLA

Muhammad Ridwan Lubis

Program Studi Manajemen Informatika, AMIK Tunas Bangsa Pematangsiantar
Jln. Jenderal Sudirman Blok A No. 1,2,3 Pematangsiantar
ridwanlubis@amiktunasbangsa.ac.id

Abstract

Hybrid is using two methods to a problem with the aim to improve their approach towards the specified target data. Hybrid PSO-ANN one optimal algorithm to solve such predictions in football matches. The process begins with determining the outcome of test dataset with the neural network architecture, specify the input parameters, the value of weight up to the value of hidden layer and output layer. Then the optimization of the results of the first test on a training dataset optimized by Particle Swarm Optimization. Testing will continue over using back propagation neural network until the maximum iteration and the results of the initial approach the target value. Furthermore, from the output obtained to search the value of the average error.

Keywords: Artificial Neural Network, Particle Swarm Optimization, Football Prediction

Abstrak

Hybrid adalah menggunakan 2 metode pada sebuah permasalahan dengan tujuan untuk meningkatkan pendekatan terhadap data target yang ditentukan. Hybrid PSO-JST salah satu algoritma yang optimal untuk menyelesaikan seperti prediksi hasil pertandingan sepakbola. Proses menentukan hasil diawali dengan menguji dataset dengan arsitektur neural network, menentukan parameter input, nilai weight hingga nilai hidden layer dan output layer. Kemudian optimasi terhadap hasil pengujian pertama pada dataset training dioptimasi dengan Particle Swarm Optimization. Pengujian akan terus berulang dengan menggunakan neural network backpropagation sampai iterasi maksimal dan hasil mendekati nilai target awal. Selanjutnya dari output yang diperoleh akan dicari nilai error rata-rata.

Kata Kunci: Jaringan Saraf Tiruan, Particle Swarm Optimization, Prediksi Sepakbola

1. PENDAHULUAN

Penelitian dibidang Komputasi selalu mengalami perkembangan yang nyata dalam pengimplementasiannya. Hal tersebut dinilai sangat wajar karena banyak aspek yang mendukung dan harus disiapkan untuk penyelesaian sebuah penelitian diantaranya banyaknya data yang digunakan, dukungan terhadap RAM yang ada pada sebuah Central Processing Unit (CPU) dan Aplikasi yang

digunakan. Permasalahan yang sering terjadi pada proses komputasi adalah adanya keterbatasan di sebuah Unit komputer. Masalah tersebut bisa disebabkan oleh banyaknya data yang diproses sehingga tahapan finishing sering mengalami keterlambatan penyelesaiannya. Hal ini bisa saja terjadi disebabkan setiap unit CPU memiliki kapasitas yang berbeda baik RAM, Processor dan Harddisk yang dimiliki.

Menurut saya Optimasi adalah sebuah metode untuk mencapai nilai atau hasil yang efektif. Menggunakan metode optimasi pada salah satu dari dua algoritma pembelajaran bertujuan untuk memberikan perbedaan hasil yang diperoleh. Salah satu permasalahan yang mendasar dalam penelitian ini adalah menggunakan sebuah metode untuk memprediksi sebuah kasus dengan algoritma pembelajaran neural network backpropagation. Kesimpulan dari beberapa penelitian yang penulis temukan pada jurnal nasional atau internasional bahwa hasil yang dicapai dengan target yang ditentukan sudah tercapai dan akurat. Pada kasus lain, jika pencapaian nilai belum akurat sangat penting untuk menambahkan sebuah metode optimasi untuk memenuhi pencapaian nilai akurasi yang optimal.

Alasan diatas adalah alasan Penulis untuk menerapkan dua metode yaitu neural network dan optimasi dengan Particle Swarm Optimization (PSO) untuk menyelesaikan masalah penelitian yang penulis kembangkan. Dasar penulis menggunakan PSO adalah berdasarkan beberapa penelitian sebelumnya mengenai model Artificial Neural Network Berbasis Particle Swarm Optimization Untuk Prediksi laju Inflasi (Juni 2013), Peningkatan Kinerja Algoritma Neural Network Berbasis Particle Swarm Optimization Untuk Memprediksi Kelahiran Prematur (2015) dan Peningkatan Akurasi Algoritma Backpropagation dengan Seleksi fitur Particle Swarm Optimization dalam Prediksi Pelanggan Telekomunikasi yang Hilang (Februari 2014) menyimpulkan bahwa terjadi peningkatan akurasi dari hasil sebelumnya. Hasil penelitian dengan menggunakan metode neural network berbasis particle swarm optimization rata-rata mengalami peningkatan akurasi sebesar 0.5%.

Dari penelitian diatas, penulis menyimpulkan perlu adanya efisiensi dan efektivitas dalam proses komputasi sehingga untuk mendapatkan akurasi yang lebih tinggi dibutuhkan sub-sub program untuk input, proses dan output. Untuk itu, penulis menerapkan Metode neural Network Berbasis Particle Swarm Optimization Untuk Memprediksi Hasil Pertandingan Sepak Bola sebagai judul penelitian saya.

2. METODOLOGI PENELITIAN.

2.1. Definisi Neural Network

Jaringan Saraf Tiruan (JST) adalah model komputasi, yang didasarkan pada Biological Neural Network. Jaringan Saraf Tiruan (JST) sering disebut sebagai Neural Network (NN)[1]. Istilah tiruan digunakan karena jaringan saraf ini meniru cara kerja jaringan saraf biologis pada manusia dan diimplementasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran [2][3].

2.1.1. Komponen Jaringan Saraf Tiruan

Ada beberapa tipe jaringan saraf tiruan, namun demikian hampir semuanya memiliki komponen-komponen yang sama. Jaringan saraf tiruan disusun dengan asumsi yang sama seperti jaringan saraf biologis yakni terdiri dari beberapa node dan adanya hubungan antara node. Sinyal informasi yang terdapat di antara 2 buah node diteruskan melalui sebuah hubungan dan setiap hubungan antara 2 buah node mempunyai nilai bobot lalu dengan menggunakan fungsi aktivasi nilai keluaran node ditentukan [4][5].

2.1.2. Algoritma Pelatihan *Neural Network Backpropagation*

Algoritma pelatihan Backpropagation Neural Network pertama kali dirumuskan oleh Werbos dan dipopulerkan oleh Rumelhart dan Mc.Clelland[6][7]. Pada supervised learning terdapat pasangan data input dan output yang dipakai untuk melatih JST hingga diperoleh bobot penimbang (weight) yang diinginkan. Pelatihan Backpropagation meliputi 3 fase[8][9][10][11]:

1. fase propaksi maju (feedforward) pola pelatihan masukan. Pola masukan dihitung maju mulai dari layer masukan hingga layer keluaran dengan fungsi aktivasi yang ditentukan;
2. fase propaksi mundur (Backpropagation) dari error yang terkait. Selisih antara keluaran dan target merupakan kesalahan yang terjadi. Kesalahan tersebut dipropagasi mundur, dimulai dari garis yang berhubungan langsung dengan unit-unit dilayar keluaran;
3. fase modifikasi bobot. 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. Kemudian, dilakukan pengujian terhadap jaringan yang telah dilatih. pembelajaran algoritma jaringan syaraf membutuhkan perambatan maju dan diikuti dengan perambatan mundur.

2.2. Definisi Particle Swarm Optimization

Particle Swarm Optimization (PSO) diperkenalkan oleh Dr. Eberhart dan Dr. Kennedy pada tahun 1995, merupakan algoritma optimasi yang meniru proses yang terjadi dalam kehidupan populasi burung (*flock of bird*) dan ikan (*school of fish*) dalam bertahan hidup. Sejak diperkenalkan pertama kali, algoritma PSO berkembang cukup pesat, baik dari sisi aplikasi maupun dari sisi pengembangan metode yang digunakan pada algoritma tersebut [12]. Oleh sebab hal tersebut, mereka mengategorikan algoritma sebagai bagian dari kehidupan rekayasa/buatan Artificial Life. Algoritma ini juga terhubung dengan komputasi evolusioner, algoritma genetik dan pemrograman. Dalam *Particle Swarm Optimization* (PSO), kawanan diasumsikan mempunyai ukuran tertentu dengan setiap partikel posisi awalnya terletak disuatu lokasi yang acak dalam ruang multidimensi[13]. Setiap partikel diasumsikan memiliki dua karakteristik yaitu posisi dan kecepatan. Setiap partikel bergerak dalam ruang atau *space* tertentu dan mengingat posisi terbaik yang pernah dilalui atau ditemukan terhadap sumber makanan atau nilai fungsi objektif. Setiap partikel menyampaikan

informasi atau posisi terbaiknya kepada partikel yang lain dan menyesuaikan posisi dan kecepatan masing masing berdasarkan informasi yang diterima mengenai posisi yang bagus tersebut[14][15].

Particle Swarm Optimization (PSO) adalah salah satu dari teknik komputasi *evolusioner*, yang mana populasi pada PSO didasarkan pada penelusuran algoritma dan diawali dengan suatu populasi yang random yang disebut dengan *particle*. Berbeda dengan teknik komputasi *evolusioner lainnya*, setiap *particle* di dalam PSO juga berhubungan dengan suatu *velocity*. Partikel-partikel tersebut bergerak melalui penelusuran ruang dengan *velocity* yang dinamis yang disesuaikan menurut perilaku historisnya. Oleh karena itu, partikel-partikel mempunyai kecenderungan untuk 6 bergerak ke area penelusuran yang lebih baik setelah melewati proses penelusuran.

Particle Swarm Optimization (PSO) mempunyai kesamaan dengan *genetic algorithm* yang mana dimulai dengan suatu populasi yang random dalam bentuk matriks. Namun PSO tidak memiliki operator evolusi yaitu crossover dan mutasi seperti yang ada pada *genetic algorithm*. Baris pada matriks disebut *particle* atau dalam *genetic algorithm* sebagai kromosom yang terdiri dari nilai suatu *variable*. Setiap *particle* berpindah dari posisinya semula ke posisi yang lebih baik dengan suatu *velocity*. Pada algoritma PSO vektor *velocity* di *update* untuk masing-masing partikel kemudian menjumlahkan vektor *velocity* tersebut ke posisi *particle*. *Update velocity* dipengaruhi oleh kedua solusi yaitu *global best* yang berhubungan dengan biaya yang paling rendah yang pernah diperoleh dari suatu *particle* dan solusi *local best* yang berhubungan dengan biaya yang paling rendah pada populasi awal[15].

Jika solusi *local best* mempunyai suatu biaya yang kurang dari biaya solusi global yang ada, maka solusi *local best* menggantikan solusi *global best*. Kesederhanaan algoritma dan performansinya yang baik, menjadikan PSO telah menarik banyak perhatian di kalangan para peneliti dan telah diaplikasikan dalam berbagai persoalan optimisasi. PSO telah populer menjadi optimisasi global dengan sebagian besar permasalahan dapat diselesaikan dengan baik di mana variabel-variabelnya adalah bilangan riil. Menurut [8], beberapa istilah umum yang biasa digunakan dalam *Particle Swarm Optimization* dapat didefinisikan sebagai berikut:

1. *Swarm* : populasi dari suatu algoritma.
2. *Particle*: anggota (individu) pada suatu *swarm*. Setiap *particle* merepresentasikan suatu solusi yang potensial pada permasalahan yang diselesaikan. Posisi dari suatu *particle* adalah ditentukan oleh representasi solusi saat itu.
3. *Pbest (Personal best)*: posisi *Pbest* suatu *particle* yang menunjukkan posisi *particle* yang dipersiapkan untuk mendapatkan suatu solusi yang terbaik.
4. *Gbest (Global best)* : posisi terbaik *particle* pada *swarm* atau posisi terbaik diantara *Pbest* yang ada.
5. *Velocity (v)*: vektor yang menggerakkan proses optimisasi yang menentukan arah di mana suatu *particle* diperlukan untuk berpindah (*move*) untuk memperbaiki posisinya semula atau kecepatan yang menggerakkan proses optimasi yang menentukan arah dimana *particle* diperlukan untuk berpindah dan memperbaiki posisinya semula.

6. *Inertia weight* (θ): inertia weight di simbolkan w , parameter ini digunakan untuk mengontrol dampak dari adanya *velocity* yang diberikan oleh suatu *particle*.
7. *Learning Rates* ($c1$ dan $c2$) : suatu konstanta untuk menilai kemampuan *particle* ($c1$) dan kemampuan sosial *swarm* ($c2$) yang menunjukkan bobot dari *particle* terhadap memorinya.

Posisi dari tiap partikel dapat dianggap sebagai calon solusi (*candidate solution*) bagi suatu masalah optimisasi. Tiap-tiap partikel diberi suatu fungsi *fitness* merancang sesuai dengan menunjuk masalah yang yang bersesuaian. Ketika masing-masing partikel bergerak ke suatu posisi baru didalam ruang pencarian, itu akan mengingat sebagai *personal best* [16]. Sebagai tambahan terhadap ingatan informasi sendiri, masing-masing partikel akan juga menukar informasi dengan partikel yang lain dan mengingat *global best* (*Gbest*). Kemudian masing-masing partikel akan meninjau kembali arah dan percepatannya sesuai dengan *Pbest* dan *Gbest* untuk bergerak ke arah yang optimal dan menemukan solusi yang optimal. Dengan keuntungan dari aplikasi yang mudah dan sederhana, lebih sedikit parameter yang diperlukan, dan hasil yang baik, PSO telah diadopsi didalam banyak bidang, seperti TSP, *flowshop*, VRP, *task-resource assignment*, penjadwalan khusus dan lain lain. Sebab itu PSO telah pula diterapkan dalam membentuk penjadwalan yang optimal untuk *university courses*. Seperti halnya dengan algoritma evolusioner yang lain, algoritma PSO adalah sebuah populasi yang didasarkan penelusuran inialisasi partikel secara *random* dan adanya interaksi diantara partikel dalam populasi. Di dalam PSO setiap partikel bergerak melalui ruang solusi dan mempunyai kemampuan untuk mengingat posisi terbaik sebelumnya dan dapat bertahan dari generasi ke generasi. Algoritma PSO dikembangkan dengan berdasarkan pada model berikut[17][18]:

1. Ketika seekor burung mendekati target atau makanan (atau bisa minimum atau maximum suatu fungsi tujuan) secara cepat mengirim informasi kepada burung-burung yang lain dalam kawanan tertentu.
2. Burung yang lain akan mengikuti arah menuju ke makanan tetapi tidak secara langsung.
3. Ada komponen yang tergantung pada pikiran setiap burung, yaitu memorinya tentang apa yang sudah dilewati pada waktu sebelumnya.

Menurut Bai (2010) keuntungan dari Algoritma PSO adalah[19]:

1. PSO berdasar pada kecerdasan (*intelligence*). Ini dapat diterapkan ke dalam kedua penggunaan dalam bidang teknik dan riset ilmiah.
2. PSO tidak punya overlap dan kalkulasi mutasi. Pencarian dapat dilakukan oleh kecepatan dari partikel. Selama pengembangan beberapa generasi, kebanyakan hanya partikel yang optimis yang dapat mengirim informasi kepartikel yang lain, dan kecepatan dari pencarian adalah sangat cepat.
3. Perhitungan didalam Algoritma PSO sangat sederhana, menggunakan kemampuan optimisasi yang lebih besar dan dapat diselesaikan dengan mudah.
4. PSO memakai kode/jumlah yang riil, dan itu diputuskan langsung dengan solusi, dan jumlah dimensi tetap sama dengan solusi yang ada.

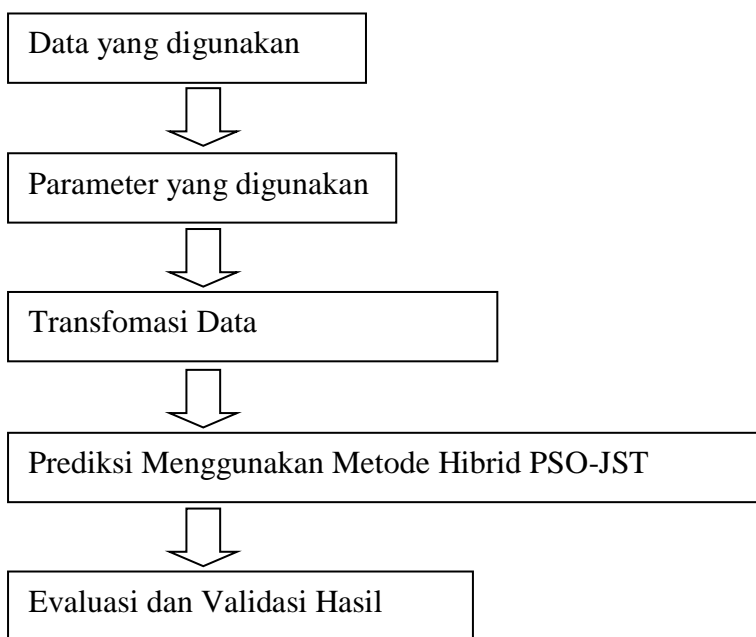
Beberapa kerugian dari Algoritma PSO adalah[19]:

1. Metode mudah mendapatkan optimal parsial (sebagian), yang mana menyebabkan semakin sedikit ketepatannya untuk peraturan tentang arah dan kecepatan.
2. Metode tidak bisa berkembang dari permasalahan sistem yang tidak terkoordinir, seperti solusi dalam bidang energi dan peraturan yang tidak menentu didalam bidang energy.

Model Algoritma PSO ini akan disimulasikan dalam ruang dengan dimensi tertentu dengan sejumlah iterasi sehingga di setiap iterasi, posisi partikel akan semakin mengarah ke target yang dituju (minimasi atau maksimasi fungsi). Ini dilakukan hingga maksimum iterasi dicapai atau bisa juga digunakan kriteria penghentian yang lain. Hal ini disebabkan, PSO merupakan algoritma optimasi yang mudah dipahami, cukup sederhana, dan memiliki unjuk kerja yang sudah terbukti handal. Algoritma PSO dapat digunakan pada berbagai masalah optimasi baik kontinyu maupun diskrit, linier maupun nonlinier. PSO memodelkan aktivitas pencarian solusi terbaik dalam suatu ruang solusi sebagai aktivitas terbangnya kelompok partikel dalam suatu ruang solusi tersebut. Dengan demikian, awal penelusuran pada algoritma PSO dilakukan dengan populasi yang *random* (acak) yang disebut dengan partikel dan jika suatu partikel atau seekor burung menemukan jalan yang tepat atau pendek menuju sumber makanan, maka sisa kelompok yang lain juga akan segera mengikuti jalan tersebut meskipun lokasi mereka jauh di kelompok tersebut. Posisi partikel dalam ruang solusi tersebut merupakan kandidat solusi yang berisi variabel-variabel optimasi. Setiap posisi tersebut akan dikaitkan dengan sebuah nilai yang disebut nilai objektif atau nilai *fitness* yang dihitung berdasarkan fungsi objektif dari masalah optimasi yang akan diselesaikan.

2.3. Tahapan Penelitian

Sesuai dengan ketentuan yang ada pada Bab Pendahuluan, penulis sudah menjelaskan tujuan menggunakan metode optimasi adalah untuk memprediksi hasil pertandingan sepak bola liga inggris. Tujuan menggunakan Metode Optimasi adalah untuk mengoptimalkan hasil prediksi pertandingan sepak bola dengan menggunakan metode neural network dan particle swarm optimization. Diharapkan dapat memberikan manfaat khususnya bagi penulis dan berguna bagi perkembangan penelitian selanjutnya. Berikut ini adalah Tahapan penelitian yang dilakukan.



Gambar 2.1. Tahapan Penelitian

Pada rancangan proses, ada beberapa tahapan yang penulis konsep untuk mendapatkan hasil prediksi. Berikut ini penjelasan dari beberapa tahapan pada rancangan proses :

1. Data yang digunakan

Data yang digunakan pada penelitian ini adalah hasil pertandingan liga inggris musim 2015. Dengan ketentuan Tim yang bertanding pada setiap musim berjumlah 20 tim, masing-masing tim menjalani masing-masing 19 pertandingan sebagai tim tuan rumah (home) dan menjadi tim tamu (Away). Jumlah data yang dikumpulkan sebanyak 380 record.

2. Parameter yang digunakan

Pada langkah ini, dimulai dengan mempersiapkan data yang digunakan untuk proses pelatihan dan pengujian. Penentuan parameter prediksi dijelaskan pada tabel 2.1 berikut :

Tabel 2.2. Parameter Prediksi yang digunakan

No	Parameter Prediksi	Simbol
1	Rata-rata Point 5 Pertandingan Tim Home	<i>I1</i>
2	Rata-rata Point 5 Pertandingan Tim Away	<i>I2</i>
3	Jumlah Point Tim Home	<i>I3</i>
4	Jumlah Point Tim Away	<i>I4</i>
5	Jumlah point pada 5 Laga Terakhir Tim Home	<i>I5</i>
6	Jumlah point pada 5 Laga Terakhir Tim Away	<i>I6</i>
7	Jumlah Pertandingan	<i>I7</i>
8	Jumlah Minggu	<i>I8</i>
9	Hasil	<i>O1, O2</i>

3. Transformasi Data

Pada tahap tranformasi data dilakukan proses komputasi data dengan menggunakan Persamaan 2.1

$$X^1 = \frac{(X-X_{min})(b-\alpha)}{(X_{max}-X_{min})} + \alpha \dots\dots\dots 2.1$$

Keterangan :

X^1 adalah Nilai Transformasi , X adalah nilai asli

X_{min} adalah nilai minimal pada satu kolom data, X_{Max} adalah nilai maksimal pada satu kolom data, b , α adalah nilai atas dan nilai bawah (antara 0,1..0,9).

4. Pengujian dengan Metode PSO-JST

Pengujian dengan metode particle swarm optimization adalah:

- a. Inisialisasi posisi dan kecepatan awal partikel, jumlah partikel, batas atas dan batas bawah ruang pencarian dan jumlah iterasi yang digunakan. Posisi dan kecepatan awal partikel ditentukan secara *random* dengan *range* antara -1 sampai dengan 1. Posisi adalah nilai *weight* (seperti pada Tabel 3.5), sementara kecepatan (v) adalah nilai yang mempengaruhi perubahan posisi pada setiap iterasi (w_{baru}) pada hidden unit dan actual output dengan menggunakan persamaan 3.5

$$W_{ij} = w_{ij} + .Err_j . O_i \dots\dots\dots 2.2$$

dimana :

- l = *learning rate* dengan nilai antara 0 hingga 1; jika nilai l kecil, maka perubahan bobot akan sedikit dalam setiap iterasi; begitu pula sebaliknya. Nilai *learning rate* biasanya berkurang selama proses pembelajaran.
- b. Jumlah partikel untuk pengujian adalah 152 partikel.
- c. Jumlah iterasi yang digunakan pada pengujian PSO-JST adalah 10 iterasi.
- d. Melakukan *feedforward ANN* dengan optimasi PSO kemudian membandingkannya dengan data target untuk memperoleh fitness (fungsi pembangkit) dari fungsi objektifnya. Data target/fungsi tujuan (t_0) pada neural network ditentukan seperti pada tabel 2.3.

Tabel 2.3 Data Target

No	Skor/Nilai	Bobot
1	0	0 - 0.726
2	1	0.727 - 0.766
3	2	0.767 - 0.773
4	3	0.774 - 0.779
5	4	0.780 - 0.783
6	5	0.784 0 -786
7	6	0.787 - 1

Pada penelitian ini target ditentukan berdasarkan jumlah gol yang diperoleh pada hasil pertandingan liga inggris musim 2015-2016 dengan jumlah gol sebanyak 6.

Nilai fitness diperoleh dari MAPE-nya.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Aktual_i - Prediksi_i}{Prediksi_i} \right| \times 100 \dots\dots\dots 2.3$$

- e. Evaluasi nilai fitness pada setiap partikel dengan menentukan Pbest dan

Gbest pada awal iterasi (i). untuk posisi dan kecepatan partikel memiliki batas atas dan batas bawah antara -1 dan 1.

- f. Perbaharui posisi dan kecepatan partikel dengan tetap mempertimbangkan batas atas dan batas bawah nilai awal iterasi (i=0). Gunakan persamaan 2.3

$$v \text{ baru} = (w * v \text{ skrg}) + (c1 * r1 * (\text{posisi terbaik} - w)) + (c2 * r2 * (\text{posisi umum terbaik} - w)) \dots\dots\dots 2.4$$

dimana nilai v skarang bernilai 0, c1 adalah ketetapan yang ditentukan dengan nilai c1=c2, r1 dan r2 adalah nilai random (learning rate) yang bernilai antara 0 dan 1.

- g. Optimasi PSO hingga nilai Gbest tidak berubah pada iterasi yang ditentukan. Kemudian algoritma dialihkan ke *Back Propagation*. Setelah pendekatan optimasi dilakukan dengan menggunakan metode particle swarm optimization, akan diperoleh nilai kecepatan dengan menggunakan persamaan 2.3
- h. Lakukan langkah *g - h* hingga maksimum iterasi tercapai atau Gbest tidak berubah atau mendekati nilai target yang ditentukan pada tabel 2.3
- i. Inisialisasi parameter pada algoritma *Back Propagation* dengan menggunakan bobot dan bias yang diperoleh dari PSO. Parameter *learning rate* (α) adalah 0,9. Nilai maksimum epoch adalah 100. Hasil pengujian dengan menggunakan metode optimasi (PSO) selanjutnya diuji kembali dengan metode JST .
- j. Hitung nilai fungsi objektif pada setiap epoch hingga akhir iterasi untuk mengetahui error rata-rata. Untuk menghitung nilai rata-rata adalah menghitung nilai pada setiap partikel kemudian dibagi dengan jumlah partikel.
- k. Perbaiki nilai bobot dan bias, ulangi langkah *f - h* hingga nilai maksimum iterasi tercapai.
- l. Denormalisasi hasil keluaran
- m. Hitung MAPE dengan menggunakan persamaan 2.2 dari hasil keluaran yang telah didenormalisasi

2.5. Penelitian Terdahulu

Berikut beberapa penelitian terdahulu yang berkaitan sebagai bahan acuan penulis dapat dilihat pada tabel 2.4.

Tabel 2.4. Penelitian Terdahulu

No	Nama dan Tahun	Algoritma/Metode	Hasil Penelitian
1	Kusumawati 2015	Neural Network dan Particle Swarm Optimization	Prediksi Kelulusan Mahasiswa
2	Muzakkir 2015	Backpropagation, Particle Swarm Optimization	Prediksi Pelanggan Telekomunikasi

No	Nama dan Tahun	Algoritma/Metode	Hasil Penelitian
			yang hilang
3	Raharjo, 2013	Artificial Neural Network, Particle Swarm Optimization	Prediksi Laju inflasi
4	Ramanda, 2015	Artificial Neural Network, Particle Swarm Optimization	Prediksi kelahiran prematur
5	Septiana, 2016	Artificial Neural Network, Particle Swarm Optimization	Penentuan Mahasiswa Drop out
6	Taqiyuddin, 2013	Artificial Neural Network, Particle Swarm Optimization	Studi optimal power flow pada kelistrikan
7	Amadin, 2015	Artificial Neural Network Backpropagation	Prediksi Hasil Pertandingan Sepak bola
8	A.G Abdullah 2013	Artificial Neural Network, Particle Swarm Optimization	Peningkatan Akurasi Prediksi Beban Listrik

Tabel 2.4. merupakan referensi yang digunakan sebagai pendukung dalam bentuk jurnal nasional dalam kurun waktu 5 tahun terakhir.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Penelitian

Pada sub bab ini dijelaskan hasil dari proses pembelajaran dan pengujian dari dataset pertandingan liga inggris. Hasil ini menggunakan dua algoritma yaitu Backpropagation dengan particle swarm optimization. Pada tahapan ini dataset hasil pertandingan Liga Inggris dibagi menjadi dua bagian yaitu dataset untuk pembelajaran dan dataset untuk pengujian dengan persentase 60% untuk pembelajaran dan 40% untuk pengujian. Dataset ini berjumlah 380 dengan menggunakan persentase tersebut dataset untuk pembelajaran 228 dataset sedangkan untuk pengujian 152 dataset.

Tabel 3.1 merupakan hasil pengujian dengan menggunakan metode JST dan PSO+JST dengan menggunakan data pengujian 152 data dengan hasil antara metode JST dan PSO memiliki perbandingan sebesar 0.15% terhadap data target.

Tabel 3.1. Nilai Error Rata-rata Pengujian dengan JST dan JST+PSO

ERROR RATA-RATA			
JST		JST + PSO	
Y1	Y2	Y1	Y2
0.004789	-0.00167	0.001489	-0.00325

Pada tabel 3.1 menjelaskan mengenai rata-rata error yang didapat dari metode JST dan Optimasi PSO+JST. Pengujian yang dilakukan terhadap dataset sebanyak 125 data membuktikan bahwa dengan menggunakan metode optimasi (Particle Swarm Optimization) Rata-rata error sebesar 0.001, sedangkan pada metode sebelum dilakukan tahapan optimasi error yang didapat sebesar 0.004. Berdasarkan hasil pada tabel 3.1 bahwa dengan menggunakan metode Optimasi (Particle Swarm Optimization) hasil yang diperoleh akan lebih baik daripada metode sebelumnya.

4. SIMPULAN

Kesimpulan yang dapat diambil setelah melakukan pelatihan dan pengujian hasil prediksi pada jaringan syaraf tiruan dengan menggunakan algoritma hybrid PSO JST adalah memberikan hasil prediksi yang akurat dari pengujian yang dilakukan terhadap hasil pertandingan sepakbola. Melalui metode neural network dataset diuji dengan menggunakan metode optimasi diperoleh hasil yang lebih baik dengan persentasi 0.03% pada setiap pengujian.

DAFTAR PUSTAKA

- [1] Agus Perdana Windarto, "Implementation of Neural Networks in Predicting the Understanding Level of Students Subject," *Int. J. Softw. Eng. Its Appl.*, vol. 10, no. 10, pp. 189–204, 2016.
- [2] M.f. Andrijasa, mistianingsih, " penerapan jaringan syaraf tiruan untuk memprediksi jumlah pengangguran di propinsi kalimantan timur dengan menggunakan algoritma pembelajaran backpropagation" viewed 1 februari 2010.
- [3] Arif jurmawanto, rudy hartono, dhidik prastiyanto, " aplikasi jaringan syaraf tiruan backpropagation untuk memprediksi penyakit tht di rumah sakit mardi rahayu kudas" viewed 2009.
- [4] Muhammad erwin ashari haryono, "model identifikasi peta secara otomatis menggunakan konsep jaringan syaraf tiruan backpropagation" viewed 1 juni 2004.
- [5] Nazla nurmalia, aris sugiharto, eko adi sarwoko, " algoritma back propagatiun neural network untuk pengenalan pola karakter huruf jawa ".
- [6] Sri kusumadewi.2003, "artificial intelligence (teknik aplikasinya)", graha ilmu, yogyakarta.
- [7] Tole Sutikno, Ardi Pujianto, Yuni Tri Supanti, "Prediksi Resiko Kredit Dengan Jaringan Syaraf Tiruan Backpropagation", viewed 2007.
- [8] [Wati, Dwi Ana Ratna, 2011. Sistem Kendali Cerdas: Bandung](#)

- [9] Sumijan, AgusPerdana Windarto, Abulwafa Muhammad and Budiharjo, 2016, "Implementation of Neural Networks in Predicting the Understanding Level of Students Subject", *International Journal of Software Engineering and Its Applications* Vol. 10, No. 10, pp. 189-204.
- [10] Yohanes Suhari, "Jaringan Syaraf Tiruan : Aplikasi Pemilihan Merk ", viewed 2 Juli 2010.
- [11] Erick paulus, yessica nataliani.2007, "gui matlab", penerbit andi , yogyakarta.
- [12] Jong jek siang.2009, " jaringan syaraf tiruan & pemrograman menggunakan matlab", penerbit andi, yogyakarta.
- [13] Hsieh, L.F., Huang, C.J. & Huang, C.L. 2007. Applying Particle Swarm Optimization To Schedule Order Picking Routes In A Distribution Center. *Asian Journal of Management and Humanity Sciences*. Vol. 1, No. 4. pp. 558-576.
- [14] Bernard renaldy suteja, "penerapan jaringan saraf tiruan propagasi balik studi kasus pengenalan jenis kopi", viewed juni 2007.
- [15] Asriningtias, s. R., dachlan, h. S., & yudaningtyas, e. (2015). Optimasi training neural network menggunakan hybrid adaptive mutation pso-bp. *Jurnal eccis*, 9(1), pp-79.
- [16] Chen, R.M. & Shih, H.F. 2013. Solving University Course Timetabling Problems Using Constriction Particle Swarm Optimization with Local Search. *Article Algorithms* 2013, 6, 227-244; doi:10.3390/a6020227. ISSN 1999-4893
- [17] Engelbrecht, A.P. 2006. *Fundamentals of Computational Swarm Intelligence*. Wiley.
- [18] Kusumawati, d., winarno, w. W., & arief, m. R. (2015). Prediksi kelulusan mahasiswa menggunakan metode neural network dan particle swarm optimization. *Semnasteknomedia online*, 3(1), 3-8.
- [19] Raharjo, j. S. D. (2013). Model artificial neural network berbasis particle swarm optimization untuk prediksi laju inflasi. *Jurnal sistem komputer*, 3(1), 10-21.
- [20] Bai, Qinghai. 2010. Analysis Of Particle Swarm Optimization Algorithm. *CCSE, Computer and Information Science*. www.ccsenet.org/cis College of Computer Science and Technology. Inner Mongolia University for Nationalities. Tongliao 028043: China

- [21] Ramanda, k. (2015). Penerapan particle swarm optimization sebagai seleksi fitur prediksi kelahiran prematur pada algoritma neural network. *Jurnal teknik komputer amik bsi*, 1(2), 178-183.
- [22] Septiana, l. (2016). Penerapan neural network berbasis particle swarm optimization untuk seleksi atribut penentuan mahasiswa drop out. *Pilar*, 9(2).
- [23] Taqiyuddin, t., & hadi, s. P. (2013). Studi optimal power flow pada sistem kelistrikan 500 kv jawa-bali dengan menggunakan particle swarm optimization (pso). *Jurnal nasional teknik elektro dan teknologi informasi (jnteti)*, 2(3).