

OPTIMASI CONJUGATE GRADIENT PADA BACKPROPAGATION NEURAL NETWORK UNTUK PREDIKSI HASIL TANGKAP IKAN

A. Aviv Mahmudi

Program Studi Manajemen-S1 STIE YPPI Rembang

Jl. Raya Rembang-Pamotan KM. 4 Rembang

Email: viva_77@yahoo.co.id

| Info Artikel : | ABSTRACT |
|---|--|
| Sejarah Artikel : Menerima : 28 Juli 2020 Revisi : 04 Agust 2020 Diterima : 07 Agust 2020 Online : 12 Agust 2020 Keyword : <i>Back Propagation, Neural Network, Conjugate Gradient Backpropagation, Epoch.</i> | <p><i>The need for fish catch by a company or fisherman in Rembang Regency affects market process and also welfare. The catch made by the fishermen is not on target, due to the weather and type of fishing gear. An accurate method is needed in making predictions and a correlation between catch and weather so that fisherman can get maximum predictions results, so that price adjustment can be made. The research was conducted using an experimental method, to determine the accuracy of the effect of the Conjugate Gradient on the Back Propagation Neural Network in obtaining the best value. Based on the results of the Cycle training test with the Conjugate Gradient Backpropagation Neural Network method, the smallest average value is obtained at the 400th Epoch compared to the Epoch Gradient Descent With Momentum method at Epoch 800. Thus it is proven that using the Conjugate Gradient Backpropagation Neural Network method is better with an average value of- MSE average 0.2223 in three stages of testing Training Cycle, Learning Rate and Hidden Layer.</i></p> |
| | INTISARI |
| Kata Kunci: <i>Back Propagation, Neural Network, Conjugate Gradient Backpropagation, Epoch.</i> | <p>Kebutuhan akan hasil tangkapan ikan oleh suatu perusahaan maupun nelayan di Kabupaten Rembang mempengaruhi harga dipasaran dan juga kesejahteraan. Hasil tangkapan yang dilakukan oleh nelayan tidak sesuai target, disebabkan oleh cuaca dan jenis alat tangkap. Dibutuhkan metode yang akurat dalam melakukan prediksi dan korelasi antara hasil tangkap dengan cuaca agar nelayan bisa mendapatkan hasil prediksi yang maksimal, sehingga dapat dilakukan penyesuaian harga. Penelitian yang dilakukan menggunakan metode eksperimen, yaitu untuk mengetahui akurasi pengaruh pada <i>Conjugate Gradient</i> pada <i>Back Propagation Neural Network</i> dalam mendapatkan nilai yang terbaik. Berdasarkan hasil pengujian <i>training Clycle metode Conjugate Gradient Backpropagation Neural Network</i> didapatkan nilai rata-rata terkecil pada Epoch ke 400 dibandingkan dengan Epoch metode <i>Gradient Descent With Mommmentum</i> berada di Epoch 800. Dengan begitu terbukti menggunakan metode <i>Conjugate Gradient Backpropagation Neural Network</i> lebih baik dengan nilai rata-rata MSE 0.2223 dalam tiga tahap pengujian <i>Training Clycle, Learning Rate</i> dan <i>Hidden Layer</i>.</p> |

1. PENDAHULUAN

Rembang merupakan salah satu kabupaten di pesisir pantai utara pulau Jawa yang memiliki panjang garis pantai 63,5 km dengan luas wilayah pesisir 355,95 km. Rembang merupakan kabupaten dengan garis pantai terpanjang di Jawa Tengah. Sumber daya alam ini menjadikan Rembang memiliki hasil perikanan yang tinggi. Kontribusi sektor perikanan dari daerah ini untuk Provinsi Jateng juga cukup besar, karena 30 persen berasal dari Rembang. Kebutuhan akan hasil tangkapan ikan oleh suatu perusahaan maupun nelayan di Kabupaten Rembang Jawa Tengah sangatlah mempengaruhi harga dipasaran dan juga kesejahteraan. Maka dari itu alat bantu yang digunakan dalam proses penangkapan ikan diperlukan kontrol yang baik, mulai dari pelepasan cantrang (*Trawls*) hingga sampai penarikan cantrang (*Trawls*) keatas kapal agar alat bantu tersebut tidak mengalami masalah dalam penggunaannya.

Conjugate Gradient merupakan teknik algoritmik fundamental untuk memecahkan sistem persamaan linear positif simetris dan pasti serta meminimalkan fungsi-fungsi nonlinear yang tidak dibatasi (Nazareth, 2009). Metode gradien konjugasi banyak digunakan untuk menyelesaikan masalah optimasi berskala besar karena tidak memerlukan penyimpanan matriks (Narushima, 2011). BackPropagation merupakan metode yang sangat baik dalam proses klasifikasi mengingat kemampuannya dalam mengadaptasikan kondisi jaringan dengan data yang diberikan dengan proses pembelajaran (Khairani, 2014). Jaringan syaraf tiruan memiliki kemampuan yang kuat antar polarisasi non linier. Itu dapat memperoleh pemetaan matematis yang mencerminkan hukum internal dari data eksperimen. Oleh karena itu, telah banyak digunakan dalam aplikasi teknik untuk prediksi dan optimisasi (Yin, et al, 2011). BPNN terkenal dengan algoritma belajar propagasi balik, yang merupakan algoritma pembelajaran mentor dari penurunan gradien, atau perubahannya (Wang, et al, 2014).

Prediksi (peramalan) merupakan hal yang sangat penting dalam kehidupan manusia, karena dengan melakukan prediksi, maka suatu masalah akan dapat diperkecil dampak yang akan terjadi kedepannya (Wanto, 2017). Penelitian ini dilakukan karena nelayan di Kabupaten Rembang Jawa Tengah menggunakan alat bantu cantrang (*Trawls*) sebagai alat bantu tangkap utama. Penelitian ini juga dapat dijadikan tolak ukur harga ikan dipasaran sehingga pemerintah dapat mengontrol harga pada saat ikan melimpah maupun ikan kurang dari target yang diharapkan saat pembongkaran di Tempat Pelelangan Ikan (TPI) agar kesejahteraan nelayan terpenuhi.

Dalam penelitian ini digunakan metode *Back Propagation Neural Network Conjugate Gradient* (BPNN-CG) dikarenakan dalam memecahkan permasalahan yang terkait dengan efisiensi pada pembahasan dalam skala yang besar. BPNN-CG ini digunakan untuk mendapatkan akurasi yang tinggi dari hasil analisis. Akurasi yang tinggi dapat diperoleh dengan menggunakan algoritma resilient BNN (Fa'rifah dan Busrah, 2017). *Neural Network* atau Jaringan Saraf Tiruan merupakan salah satu sistem tiruan yang memproses informasi yang dilakukan dengan cara mendesain dengan menirukan cara kerja manusia dalam proses belajarnya sehingga menyelesaikan suatu permasalahan melalui proses belajar pada perubahan bobot sinapsisnya (Fitri, 2019).

Sedangkan data yang digunakan dalam penelitian ini adalah data *time series* yaitu jenis data yang terdiri dari satu objek akan tetapi meliputi beberapa periode waktu, seperti harian, mingguan, bulanan, tahunan dan lain-lain (Hutabarat, dkk, 2018). Data *time series* diyakini sangat berguna bagi masa depan karena tidak menutup kemungkinan data yang sebelumnya pernah terjadi akan terulang lagi dimasa depan (Purba dan Wanto, 2018). Optimasi Algoritma *Backpropagation* dengan *Conjugate Gradient Beale-powell Restarts* terbukti dapat diimplementasikan untuk memprediksi data *times series* (Wanto, 2017). Peneliti mengunggulkan peramalan hasil tangkapan ikan di Kabupaten Rembang Jawa Tengah ini digunakan metode *Back Propagation Neural Network Conjugate Gradient* (BPNN CG) diharapkan metode ini dapat melengkapi dan mendapatkan hasil rata-rata akurasi yang maksimal. Algoritma Back propagation memungkinkan multilayer meneruskan jaringan saraf untuk mempelajari pemetaan *input/output* dari sampel pelatihan. *Back propagation networks* mengadaptasi sendiri untuk mempelajari hubungan antara himpunan pola contoh, dan bisa dapat menerapkan hubungan yang sama ke pola input baru (Sibi, et al, 2013).

Penelitian ini bertujuan untuk menganalisis *Back Propagation Neural Network Conjugate Gradient* (BPNN CG) dan memprediksi hasil tangkap nelayan berdasarkan alat tangkap dan cuaca. sehingga dapat diketahui tingkat efisien nelayan dalam menggunakan alat tangkap dibandingkan

dengan tangkapan aslinya. Algoritma *Back Propagation Neural Network Conjugate Gradient* diharapkan menjadi penyempurna hasil prediksi, sehingga dapat memberikan nilai rata-rata kecil dan hasil korelasi terhadap cuaca yang kemudian digunakan sebagai acuan perolehan hasil tangkap ikan.

2. METODE PENELITIAN

Jenis penelitian yang dilakukan menggunakan metode experiment, yaitu untuk mengetahui akurasi pengaruh pada *Conjugate Gradient* pada *Back Propagation Neural Network* dalam mendapatkan nilai yang terbaik. Kemudian akan diimplementasikan menggunakan MATLAB untuk mendapatkan hasil yang akurat.

2.1 Metode Pengumpulan Data

Data penelitian dibagi menjadi 2 jenis, yaitu data primer dan sekunder. Data primer merupakan data yang diperoleh berdasarkan pencarian di internet maupun dari media informasi lainnya juga dari hasil wawancara maupun observasi. Sedangkan sekunder berdasarkan website resmi dari pemerintahan maupun data yang diperoleh dari perusahaan. Berikut data yang diperoleh dari Pos TPI (Tempat Pelelangan Ikan) Kabupaten Rembang Jawa Tengah, dapat dilihat pada Tabel 1.

Tabel 1
Data Harian Hasil Timbangan Tangkapan Ikan

| Kabupaten | Tanggal Kedatangan | Jumlah Hasil Tangkapan (Kg) | Lintang (°) | Bujur (°) | Ketinggian (mdpl) | Time Zone |
|--------------|--------------------|-----------------------------|-------------|-----------|-------------------|-----------|
| Kab. Rembang | 1-Jul-19 | 64060 | -6.70188 | 111.33484 | 0 | Cerah |
| Kab. Rembang | 2-Jul-19 | 60895 | -6.76228 | 111.47702 | 0 | Cerah |
| Kab. Rembang | 3-Jul-19 | 59850 | -6.7966 | 111.2589 | 0 | Cerah |
| Kab. Rembang | 4-Jul-19 | 143840 | -6.85922 | 111.4042 | 165 | Hujan |
| Kab. Rembang | 5-Jul-19 | 88150 | -6.86123 | 111.4121 | 176 | Hujan |
| Kab. Rembang | 6-Jul-19 | 59400 | -6.858 | 111.41 | 0 | Cerah |
| Kab. Rembang | 7-Jul-19 | 87200 | -6.85974 | 111.4058 | 0 | Cerah |
| Kab. Rembang | 8-Jul-19 | 90165 | -6.81552 | 111.4461 | 0 | Cerah |
| Kab. Rembang | 9-Jul-19 | 35250 | -6.82052 | 111.4339 | 75 | Mendung |
| Kab. Rembang | 10-Jul-19 | 88420 | -6.87405 | 111.5862 | 0 | Cerah |
| Kab. Rembang | 11-Jul-19 | 115825 | -6.73709 | 111.6695 | 0 | Cerah |
| Kab. Rembang | 12-Jul-19 | 90690 | -6.79206 | 111.6522 | 49 | Berawan |
| Kab. Rembang | 13-Jul-19 | 90900 | -6.77193 | 111.5792 | 0 | Cerah |
| Kab. Rembang | 14-Jul-19 | 38650 | -6.7674 | 111.4968 | 0 | Cerah |
| Kab. Rembang | 15-Jul-19 | 38450 | -6.77748 | 111.4703 | 35 | Berawan |
| Kab. Rembang | 16-Jul-19 | 65040 | -6.80639 | 111.3799 | 0 | Cerah |
| Kab. Rembang | 17-Jul-19 | 88495 | -6.70388 | 111.2453 | 27 | Berawan |
| Kab. Rembang | 18-Jul-19 | 88275 | -6.75505 | 111.2567 | 0 | Cerah |
| Kab. Rembang | 19-Jul-19 | 90740 | -6.74968 | 111.2565 | 0 | Cerah |
| Kab. Rembang | 20-Jul-19 | 114695 | -6.72066 | 111.3476 | 0 | Cerah |
| Kab. Rembang | 21-Jul-19 | 113225 | -6.70318 | 111.3334 | 0 | Cerah |
| Kab. Rembang | 22-Jul-19 | 116915 | -6.7206 | 111.3476 | 34 | Berawan |
| Kab. Rembang | 23-Jul-19 | 35200 | -6.71669 | 111.472 | 30 | Berawan |
| Kab. Rembang | 24-Jul-19 | 66300 | -6.72174 | 111.4697 | 59 | Berawan |
| Kab. Rembang | 25-Jul-19 | 93120 | -6.70804 | 111.4651 | 0 | Cerah |
| Kab. Rembang | 26-Jul-19 | 61900 | -6.69887 | 111.6177 | 0 | Cerah |
| Kab. Rembang | 27-Jul-19 | 88850 | -6.63664 | 111.4997 | 0 | Cerah |
| Kab. Rembang | 28-Jul-19 | 86625 | -6.63342 | 111.4982 | 35 | Berawan |
| Kab. Rembang | 29-Jul-19 | 89225 | -6.69195 | 111.4518 | 32 | Berawan |
| Kab. Rembang | 30-Jul-19 | 63800 | -6.70577 | 111.4425 | 35 | Berawan |
| Kab. Rembang | 31-Jul-19 | 65700 | -6.69147 | 111.4477 | 0 | Cerah |

2.2 Metode Penyelesaian Yang Digunakan

Untuk mendapatkan prediksi akurasi yang akurat dalam menentukan hasil pendapatan pengusaha ikan maupun nelayan diperlukan metode yang kemudian diusulkan selanjutnya

digunakan dalam mendapatkan nilai prediksi yang akurat. Metode yang digunakan dalam penelitian ini menggunakan algoritma *Back Propagation Neural Network Conjugate Gradient* (BPNN CG).

2.3 Eksperimen Dan Pengujian Metode

Sebelum melakukan pengujian data, semua data yang diperoleh harus dilakukan normalisasi atau sebagai langkah *pre processing* data. Normalisasi data dilakukan sebagai pengelompokan data ke dalam skala maupun Julgkauan tertentu agar memudahkan dalam pengolahan data. Dalam melakukan normalisasi data dengan menggunakan perhitungan manual ke dalam jangkauan (0,1) dan hasil perhitungan yang telah dilakukan. Setelah dilakukan normalisasi maka data tersebut akan ditambahkan parameter cuaca berdasarkan prediksi dari perkiraan cuaca BMKG dan kemudian dihitung menggunakan metode BPNN CG dengan alat bantu MATLAB.

$$X_i = \frac{0.8}{d_{Max} - d_{Min}} (d_i - d_{Min}) + 0.1$$

Tabel 2
Hasil Normalisasi Data

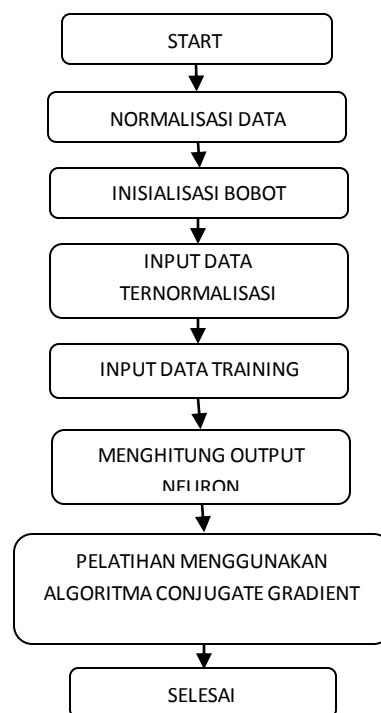
| Jumlah Hasil Tangkapan /Kg | Time Zone |
|----------------------------|-----------|
| 0.426317 | 0.1 |
| 0.407526 | 0.1 |
| 0.401321 | 0.1 |
| 0.9 | 0.9 |
| 0.569348 | 0.9 |
| 0.398649 | 0.1 |
| 0.563708 | 0.1 |
| 0.581312 | 0.1 |
| 0.255262 | 0.633333 |
| 0.570951 | 0.1 |
| 0.733665 | 0.1 |
| 0.584429 | 0.366667 |
| 0.585676 | 0.1 |
| 0.275449 | 0.1 |
| 0.274262 | 0.366667 |
| 0.432136 | 0.1 |
| 0.571397 | 0.366667 |
| 0.570091 | 0.1 |
| 0.584726 | 0.1 |
| 0.726956 | 0.1 |
| 0.718228 | 0.1 |
| 0.740137 | 0.366667 |
| 0.254965 | 0.366667 |
| 0.267434 | 0.366667 |

Dari hasil normalisasi data di atas berikutnya data tersebut akan diolah menggunakan alat bantu *software* Matlab dalam pengimplementasian *algoritma Back Propagation Neural Network Conjugate Gradient*.

Langkah-langkah pengujian BPNN sebagai berikut:

1. Normalisasi / scaling (perubahan rentang dari nilai atribut) atribut bernilai bilangan real umumnya juga diperlukan agar proses perhitungan lebih mudah dan memberi jaminan bahwa atribut yang rentang nilainya lebih kecil. Normalisasi umumnya memberikan hasil yang lebih baik. Rentang nilai atribut yang dianjurkan untuk digunakan adalah [0,1] atau [-1,+1] (Hsu, C, W, 2004).
2. Inisiasi bobot dengan mengambil bobot awal menggunakan nilai random yang terkecil.
3. Input Data training, data pelatihan ini merupakan data yang digunakan untuk membangun dan melatih sistem yang telah dibuat, dimana pada data pelatihan ini telah ditetapkan nilai target yang ingin dihasilkan, sehingga jika hasil yang diperoleh pada pelatihan tidak sesuai dengan target, maka akan dilakukan perbaikan pada sistem tersebut.
4. Dengan menggunakan bobot-bobot yang telah ditetapkan pada inisialisasi awal dapat menghitung nilai keluaran pada hidden layer.

Untuk *flowchart* pengujian sebagaimana Gambar 1.



Gambar 1. Flowchart Langkah-Langkah Pengujian BPNN

3. HASIL DAN ANALISA

3.1 Processing

Processing merupakan langkah awal sebelum dilakukan *training* data dengan melakukan normalisasi data. Dengan Persamaan Normalisasi BPNN).

$$X_i = \frac{0.8}{d_{Max} - d_{Min}}(d_i - d_{Min}) + 0.1$$

Selanjutnya menggunakan persamaan normalisasi BPNN di atas maka akan diimplementasikan ke dalam data, dengan hasil normalisasi berikut

Tabel 3. Hasil Normalisasi Sebagai Input Data Pelatihan

| Jumlah Tangkapan /Kg | Hasil | Time Zone | Hasil Normalisasi |
|----------------------|-------|-----------|-------------------|
| 64060 | 1 | 0.426317 | 0.1 |
| 60895 | 1 | 0.407526 | 0.1 |
| 59850 | 1 | 0.401321 | 0.1 |
| 143840 | 4 | 0.9 | 0.9 |

Lanjutan Tabel 3. Hasil Normalisasi Sebagai Input Data Pelatihan

| | | | |
|--------|-------|----------|----------|
| 88150 | 4 | 0.569348 | 0.9 |
| 59400 | 1 | 0.398649 | 0.1 |
| 87200 | 1 | 0.563708 | 0.1 |
| 90165 | 1 | 0.581312 | 0.1 |
| 35250 | 3 | 0.255262 | 0.633333 |
| 88420 | 1 | 0.570951 | 0.1 |
| 115825 | 1 | 0.733665 | 0.1 |
| 90690 | 2 | 0.584429 | 0.366667 |
| 90900 | 1 | 0.585676 | 0.1 |
| 38650 | 1 | 0.275449 | 0.1 |
| 38450 | 2 | 0.274262 | 0.366667 |
| 65040 | 1 | 0.432136 | 0.1 |
| 88495 | 2 | 0.571397 | 0.366667 |
| 88275 | 1 | 0.570091 | 0.1 |
| 90740 | 1 | 0.584726 | 0.1 |
| 114695 | 1 | 0.726956 | 0.1 |
| 113225 | 1 | 0.718228 | 0.1 |
| 116915 | 2 | 0.740137 | 0.366667 |
| 64060 | 1 | 0.254965 | 0.366667 |
| | | | |
| 37300 | 2 | 0.267434 | 0.366667 |

Data *time zone* diatas merupakan pecahan angka jenis cuaca (1=Cerah, 2=Berawan, 3=Mendung, 4= Hujan). Setelah data selesai dihitung menjadi data yang sudah dinormalisasikan, kemudian proses selanjutnya adalah normalisasi data dalam bentuk data pelatihan yang mempunyai fungsi untuk memberikan nilai pada lapisan input.


3.2 Eksperimen Epoch atau *Training Cycle*

Untuk menentukan nilai Epoch atau *training cycle*, dilakukan suatu eksperimen atau percobaan dengan memasukan nilai dengan range 100 hingga 1000. Berikut hasil percobaan yang dilakukan untuk penentuan *training cycle*.


Tabel 4. Penentuan jumlah training clycle (Epoch) berdasarkan training Metode *Conjugate Gradient Backpropagation Neural Network*

| Epoch | Learning Rate | Jumlah Hidden | Loop 1 | Loop 2 | Loop 3 | Average |
|-------|---------------|---------------|-----------|-----------|-----------|-----------|
| 100 | 0.1 | 3 | 0.0223345 | 0.0281175 | 0.0277470 | 0.0260662 |
| 200 | 0.1 | 3 | 0.0273215 | 0.0281701 | 0.0219088 | 0.0258001 |
| 300 | 0.1 | 3 | 0.0229213 | 0.0254071 | 0.0283171 | 0.0255485 |
| 400 | 0.1 | 3 | 0.0227751 | 0.0225263 | 0.0223167 | 0.0225394 |
| 500 | 0.1 | 3 | 0.0242339 | 0.0230541 | 0.0296382 | 0.0256421 |
| 600 | 0.1 | 3 | 0.0276429 | 0.0227118 | 0.0257887 | 0.0253811 |
| 700 | 0.1 | 3 | 0.0219106 | 0.0287266 | 0.0217301 | 0.0241224 |
| 800 | 0.1 | 3 | 0.0232825 | 0.0218572 | 0.0242644 | 0.0231347 |
| 900 | 0.1 | 3 | 0.0272789 | 0.0223931 | 0.0271825 | 0.0256182 |
| 1000 | 0.1 | 3 | 0.0243576 | 0.0256929 | 0.0282165 | 0.0260890 |

Nilai hasil uji *cycle* yang dipilih berdasarkan nilai MSE terkecil. Pada hasil uji coba tabel diatas menunjukkan pada training clycle 400 mendapatkan nilai MSE terkecil.



Gambar 2. Hasil prediksi jumlah training cycle (Epoch).



Gambar 3. Validasi terbaik terdapat pada epoch 10

Untuk menentukan nilai Epoch atau *training cycle*, dilakukan suatu eksperimen atau percobaan dengan memasukkan nilai dengan range 100 hingga 1000.


3.3 Pengujian Data Hasil Tangkapan

Untuk menentukan nilai Epoch atau *training cycle*, dilakukan suatu eksperimen atau percobaan dengan memasukkan nilai dengan range 100 hingga 1000. Berikut hasil percobaan yang dilakukan untuk penentuan *training cycle*.


Tabel 5. Penentuan Jumlah Training Cycle (Epoch)

| Epoch | Learning Rate | Jumlah Hidden | Loop 1 | Loop 2 | Loop 3 | Average |
|-------|---------------|---------------|-----------|-----------|-----------|-----------|
| 100 | 0.1 | 3 | 0.0229636 | 0.0235012 | 0.0226896 | 0.0230515 |
| 200 | 0.1 | 3 | 0.0228788 | 0.0228588 | 0.0263043 | 0.0240140 |
| 300 | 0.1 | 3 | 0.0274038 | 0.0283581 | 0.0228013 | 0.0261877 |
| 400 | 0.1 | 3 | 0.0234608 | 0.0259389 | 0.0233106 | 0.0242368 |
| 500 | 0.1 | 3 | 0.0261986 | 0.0244201 | 0.0238604 | 0.0248264 |
| 600 | 0.1 | 3 | 0.0230127 | 0.0230850 | 0.0222763 | 0.0227913 |
| 700 | 0.1 | 3 | 0.0227049 | 0.0273989 | 0.0224554 | 0.0241864 |
| 800 | 0.1 | 3 | 0.0230872 | 0.0225264 | 0.0242769 | 0.0232968 |
| 900 | 0.1 | 3 | 0.0274617 | 0.0247109 | 0.0249395 | 0.0257040 |
| 1000 | 0.1 | 3 | 0.0229006 | 0.0243376 | 0.0283619 | 0.0252000 |

Nilai hasil uji cycle yang dipilih berdasarkan nilai MSE terkecil. Pada hasil uji coba tabel diatas menunjukkan pada training cycle 600 mendapatkan nilai MSE terkecil.



Gambar 4. Hasil prediksi jumlah training cycle (Epoch)



Gambar 5. Validasi terbaik berada pada epoch 31

Untuk menentukan nilai Epoch atau *training cycle*, dilakukan suatu eksperimen atau percobaan dengan memasukkan nilai dengan range 100 hingga 1000.


3.4 Learning Rate

Untuk memperoleh nilai dari learning rate dilakukan uji coba nilai dengan range 0.1 sampai dengan 1, dengan menggunakan hasil *training cycle* sebelumnya. Berikut hasil dari tabel penelitian yang dilakukan.


Tabel 6. Penentuan jumlah Learning Rate berdasarkan training Metode Conjugate Gradient Backpropagation Neural Network

| Epoch | Learning Rate | Jumlah Hidden | Loop 1 | Loop 2 | Loop 3 | Average |
|-------|---------------|---------------|-----------|-----------|-----------|---------------|
| 400 | 0.1 | 3 | 0.0260814 | 0.0277915 | 0.0228641 | 0.02557904946 |
| 400 | 0.2 | 3 | 0.0322692 | 0.0297952 | 0.0281226 | 0.03006238135 |
| 400 | 0.3 | 3 | 0.0221580 | 0.0282304 | 0.0228731 | 0.02442055599 |
| 400 | 0.4 | 3 | 0.0224215 | 0.0222632 | 0.0232651 | 0.02264998190 |
| 400 | 0.5 | 3 | 0.0258748 | 0.0236792 | 0.0216755 | 0.02374322114 |
| 400 | 0.6 | 3 | 0.0216252 | 0.0221291 | 0.0223062 | 0.02202020174 |
| 400 | 0.7 | 3 | 0.0234228 | 0.0290741 | 0.0246338 | 0.02571027443 |
| 400 | 0.8 | 3 | 0.0281609 | 0.0290759 | 0.0229072 | 0.02671471544 |
| 400 | 0.9 | 3 | 0.0227018 | 0.0279201 | 0.0229473 | 0.02452312007 |
| 400 | 1 | 3 | 0.0280429 | 0.0230160 | 0.0250499 | 0.02536963917 |

Nilai hasil uji cycle yang dipilih berdasarkan nilai MSE terkecil. Pada hasil uji coba tabel diatas menunjukkan pada Learning Rate 0.6 mendapatkan nilai MSE terkecil dengan nilai training cycle 400.



Gambar 6. Hasil prediksi jumlah Learning Rate sebesar 0.6



Gambar 7. Validasi terbaik berada pada epoch 39

Untuk memperoleh nilai dari learning rate dilakukan uji coba nilai dengan range 0.1 sampai dengan 1, dengan menggunakan hasil training cycle sebelumnya. Berikut hasil dari tabel penelitian yang dilakukan.

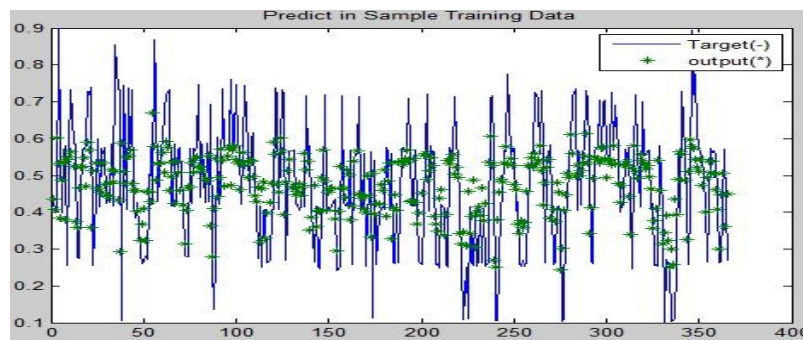
Intrepretasi Hasil Analisis Data dan Pembahasan

Untuk menentukan nilai Learning Rate, dilakukan suatu eksperimen atau percobaan dengan memasukan nilai dengan range 0.1 hingga 1. Berikut hasil percobaan yang dilakukan untuk penentuan Learning Rate.

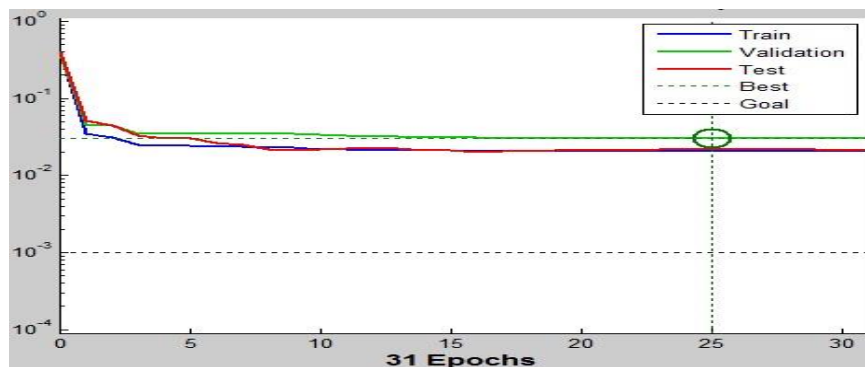
Tabel 7. Penentuan jumlah Learning Rate berdasarkan training Metode Conjugate Gradient Backpropagation Neural Network

| Epoch | Learning Rate | Hidden Layer | Loop 1 | Loop 2 | Loop 3 | Avarage |
|-------|---------------|--------------|-----------|-----------|-----------|-----------|
| 600 | 0.1 | 3 | 0.0247916 | 0.0227471 | 0.0267956 | 0.0247781 |
| 600 | 0.2 | 3 | 0.0244820 | 0.0227545 | 0.0242010 | 0.0238125 |
| 600 | 0.3 | 3 | 0.0241042 | 0.0226667 | 0.0274756 | 0.0247488 |
| 600 | 0.4 | 3 | 0.0229636 | 0.0235012 | 0.0226896 | 0.0230515 |
| 600 | 0.5 | 3 | 0.0228788 | 0.0228588 | 0.0263043 | 0.0240140 |
| 600 | 0.6 | 3 | 0.0252060 | 0.0235391 | 0.0265176 | 0.0250876 |
| 600 | 0.7 | 3 | 0.0234608 | 0.0259389 | 0.0233106 | 0.0242368 |
| 600 | 0.8 | 3 | 0.0274038 | 0.0283581 | 0.0228013 | 0.0261877 |
| 600 | 0.9 | 3 | 0.0261986 | 0.0244201 | 0.0238604 | 0.0248264 |
| 600 | 1 | 3 | 0.0230127 | 0.0230850 | 0.0222751 | 0.0227913 |

Nilai hasil uji cycle yang dipilih berdasarkan nilai MSE terkecil. Pada hasil uji coba tabel diatas menunjukkan pada Learning Rate 1 mendapatkan nilai MSE terkecil dengan nilai training cycle 600.



Gambar 8. Hasil prediksi jumlah Learning Rate sebesar 1 berdasarkan training Metode Conjugate Gradient Backpropagation Neural Network



Gambar 9. Validasi terbaik berada pada Epochke 31

3.5 Evaluasi

Dengan melihat hasil dari seluruh percobaan yang dilakukan untuk mendapatkan nolai terbaik dari neural network tersebut, dimana training cycle, learning rate dan hidden layer diuji pada metode yang berbeda. Maka didapat rata-rata error terbaik dari metode Conjugate Gradien Bacpropagation Neural Network Gradient Descent dan metode Gradient Descent With Mommentum dengan menggunakan seluruh data pengujian dan data hasil tangkapan sebagai berikut :

Tabel 8. RMSE terkecil dari seluruh pengujian

| Metode / Jenis Data | Average Conjugate Gradient Backpropagation | Average Gradient Descent with Mommentum | Average Gradient Descent |
|---------------------------|--|---|--------------------------|
| Hasil Tangkap | 0.022791387 | 0.023295588 | 0.023756661 |
| | 0.022791387 | 0.025220359 | 0.023705952 |
| | 0.022174668 | 0.023095315 | 0.025323225 |
| Hasil Tangkap & Time Zone | 0.022539428 | 0.025694843 | 0.025704640 |
| | 0.022020201 | 0.026594115 | 0.024148741 |
| | 0.022202524 | 0.022835175 | 0.024868708 |

Dari serangkaian pengujian ke empat metode diatas membuktikan metode Conjugate Gradient Backpropagation Neural Network memiliki nilai error yang lebih baik dibandingkan metode Gradient Descent With Mommentum dan Gradient Descent.

Dengan demikian dapat diprediksikan pada bulan januari 2015 diperoleh hasil analisa pengujian dengan menggunakan metode *Back Propagation Neural Network Conjugate Gradient* (BPNN CG) dengan nilai rata-rata *mean squered error* (RMSE) 0.0293.

3.6 Korelasi

Setelah didapat hasil metode terbaik yang digunakan dalam mendapatkan nilai RMSE terkecil. Kemudian dilakukan korelasi untuk mengetahui hubungan antar data. Berikut hasil pengujian korelasi Data Hasil Gabungan. Data hasil cuaca sebesar 0.145638.

**Gambar 10. Korelasi data hasil gabungan dan data hasil cuaca**

Grafik diatas merupakan hasil korelasi gabungan data hasil tangkapan dan cuaca dikorelasikan dengan data cuaca saja sehingga mendapatkan grafik seperti dalam gambar.

4. KESIMPULAN

Berdasarkan penelitian dan percobaan diatas dapat disimpulkan, bahwa berdasarkan hasil pengujian dengan menggunakan tiga metode diatas mendapatkan hasil akurat sehingga jenis alat bantu yang digunakan nelayan (cantrang/trawls) sangat efisien untuk mendapatkan hasil tangkapan yang maksimal, sedangkan cuaca tidak berpengaruh besar pada hasil tangkapan yang diperoleh oleh nelayan. Pada pengujian training Clycle metode Conjugate Gradient Backpropagation Neural Network didapatkan nilai rata-rata terkecil pada Epoch ke 400 dibandingkan dengan Epoch metode Gradient Descent With Mommentum berada di Epoch 800. Dengan begitu terbukti menggunakan metode Conjugate Gradient Backpropagation Neural Network lebih baik dengan nilai rata-rata MSE 0.2223 dalam 3 tahap pengujian Training Cycle, Learning Rate dan Hidden Layer.

DAFTAR PUSTAKA

- Fa'rifah, Ry Dan Busra, Z, 2017, Backpropagation Neural Network Untuk Optimasi Akurasi Pada Prediksi Financial Distress Perusahaan, *Jurnal Instek*, Volume 2 Nomor 2.
- Fardhani, AA, Simanjuntak, DIN dan Wanto, A, 2018, Prediksi Harga Eceran Beras Di Pasar Tradisional di 33 Kota di Indonesia Menggunakan Algoritma Backpropagation, *Jurnal Infomedia*, Vol. 3 No. 1, P-ISSN: 2527-9858 E-ISSN: 2548-1180.
- Ginting, R, Tulus, dan Nababan, EB, 2014, Analisis Penggunaan Algoritma Kohonen Pada Jaringan Syaraf Tiruan Backpropagation Dalam Pengenalan Pola Penyakit Paru, *Jurnal Teknovasi*, Volume 01, Nomor 2, 2014, 27 – 47 ISSN : 2355-701X
- Fitri, Z, 2019, Simulasi Permodelan Neural Network dengan Backpropagation pada Pemograman C#, *J-SISKO TECH Jurnal Teknologi Sistem Informasi dan Sistem Komputer* P:ISSN : 2621-8976 E-ISSN : 2615-5133 58 Vol.2, No.2, Juli 2019, pp.58-70
- Hutabarat, Map, Julham, M Dan Wanto, A, 2018, Penerapan Algoritma Backpropagation Dalam Memprediksi Produksi Tanaman Padi Sawah Menurut Kabupaten/Kota Di Sumatera Utara, *Semantik*, Vol.4, No.1, Pp. 77-86 ISSN : 2502-8928 (Online)
- Lin Wang a, Yi Zeng a, Tao Chen, 2014, Back propagation neural network with adaptive differential evolution algorithm for time series forecasting, *Expert Systems with Applications*,
- Hsu, C, W., Lin, C, J., 2004, *A Comparison Of Methods For Multi-Class Support Vector Machines*, IEEE Transactions On Neural Networks, USA
- Purba, IS dan Anjar Wanto, A, 2018, Forecasting of Import Value Quantity in Sumatera Utara According Orriginating Country Using Backpropagation Algorithm, *Techno.COM*.
- Purba, A, 2015, Perancangan Aplikasi Peramalan Jumlah Calon Mahasiswa Baru Yang Mendaftar Menggunakan Metode Single Exponential Smothing (Studi Kasus : Fakultas Agama Islam UISU), *Jurnal Riset Komputer (JURIKOM)*, Vol. 2 No. 6, ISSN 2407-389X (Media Cetak) Hal : 8-12, 17, No. 3, 302-311 IJ
- Sari, Y, 2016, Optimasi Conjugate Gradient Pada Algoritma Backpropagation Neural Network Untuk Prediksi Kurs Time Series, *Jurnal GEMA AKTUALITA*, Vol. 5 No. 1.
- Sibi, P., Jones, Sa., Dan Siddarth, P, 2013, Analysis Of Different Activa tion Functions Using Back Propagation Neural Networks, *Journal Of Theoretical And Applied Information Technology*, Vol. 47 No.3
- Wanto, A, 2017, Optimasi Prediksi Dengan Algoritma Backpropagation Dan Conjugate Gradient Beale-Powell Restarts, *Jurnal Nasional Teknologi dan Sistem Informasi*, VOL. 03 NO. 03 (Print) 2460-3465 ISSN (Online) 2476-8812.
- Wanto, A dan Windarto, AP, 2017, Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation, *Jurnal & Penelitian Teknik Informatika*, Volume 2 Nomor 2
- Wanto, 2017, Penerapan Jaringan Saraf Tiruan Dalam Memprediksi Jumlah Kemiskinan Pada Kabupaten/Kota Di Provinsi Riau, *Kumpulan jurnal Ilmu Komputer (KLIK)*, Volume 05, No.01 Februari 2018 ISSN: 2406-7857
- Yin F., Mao H, Hua L., Guo W., dan Shu M, 2011, Back Propagation neural network modeling for warpage prediction and optimization of plastic products during injection molding, *Journal Materials and Design*, doi:10.1016/j.matdes.2010.12.022, PP. 1844–1850.