



UJM 3 (1) (2014)

UNNES Journal of Mathematics

<http://journal.unnes.ac.id/sju/index.php/ujm>



APLIKASI JARINGAN SYARAF TIRUAN BACKPROPAGATION DALAM PERAMALAN BEBAN PUNCAK DISTRIBUSI LISTRIK DI WILAYAH PEMALANG

Siwi Marsiana ✉, Dwijanto, Alamsyah

Jurusan Matematika, FMIPA, Universitas Negeri Semarang, Indonesia
Gedung D7 Lt. 1, Kampus Sekaran Gunungpati, Semarang 50229

Info Artikel

Sejarah Artikel:
Diterima September 2013
Disetujui Oktober 2013
Dipublikasikan Mei 2014

Artificial Neural Network,
ANN,
Forecast,
Backpropagation,
Peak Load

Abstrak

Tujuan dari penelitian ini adalah mengetahui bagaimana rancangan arsitektur jaringan syaraf tiruan (JST) backpropagation pada data beban puncak distribusi listrik di Wilayah Pemalang menggunakan program Matlab. Metode penelitian yang digunakan adalah menemukan masalah, merumuskan masalah, metode pengumpulan data, analisis dan pemecahan masalah, dan penarikan simpulan. Pengumpulan data dilakukan dengan mengambil atau melihat langsung data dari arsip di PT PLN (Persero) APD Semarang. Dari hasil analisis diperoleh arsitektur jaringan syaraf tiruan yang optimum untuk peramalan puncak distribusi listrik di Wilayah Pemalang yaitu jaringan dengan struktur 7 unit input, 32 unit tersembunyi, dan 1 unit output untuk beban puncak siang, dan jaringan dengan 7 unit input, 42 unit tersembunyi, dan 1 unit output untuk beban puncak malam.

Abstract

The purpose of this research was to build the architecture design of Artificial Neural Network (ANN) Backpropagation method to the electric peak load distribution's data at Pemalang region using Matlab's program. The method that used in the research are find the problem, form the problem, data collection method, analysis and solve the problem, and take the conclusions. The data collection were done by took or observed from PT PLN (Persero) APD Semarang's archives. The analysis results show that the optimum artificial neural network's architecture to predict the electric peak load distribution at Pemalang region was network with 7 input unit, 32 hidden unit, and 1 output unit for the daylight peak load, and network with 7 input unit, 32 hidden unit, and 1 output unit for the night peak load.

© 2014 Universitas Negeri Semarang

✉ Alamat korespondensi:
E-mail: marsianasiwi@yahoo.com

ISSN 2252-6943

Pendahuluan

Menurut Subiyanto (2000) tenaga Listrik tidak dapat disimpan dalam skala besar, karenanya tenaga ini harus disediakan pada saat dibutuhkan. Akibatnya timbul persoalan dalam menghadapi kebutuhan daya listrik yang tidak tetap dari waktu ke waktu, bagaimana mengoperasikan suatu sistem tenaga listrik yang selalu dapat memenuhi permintaan daya pada setiap saat, dengan kualitas baik dan harga yang murah. Apabila daya yang dikirim dari bus-bus pembangkit jauh lebih besar daripada permintaan daya pada bus-bus beban, maka akan mengakibatkan terjadinya kerugian daya listrik. Sedangkan apabila daya yang dibangkitkan dan dikirimkan lebih rendah atau tidak memenuhi kebutuhan beban konsumen maka akan terjadi pemadaman lokal pada bus-bus beban, yang akibatnya merugikan pihak konsumen.

Pemisahan data beban puncak distribusi listrik menurut pembagian waktu yaitu beban puncak distribusi listrik siang hari dan beban puncak distribusi listrik malam hari mempunyai banyak kegunaan dalam merencanakan beban pembangkitan. Dalam hal ini, beban puncak distribusi listrik siang hari ditetapkan pada pukul 08.00 WIB sampai dengan pukul 15.30 WIB, dan beban puncak distribusi listrik malam hari pada pukul 17.00 WIB sampai dengan 22.00 WIB. Besarnya beban puncak distribusi listrik siang hari, berbeda dengan beban puncak distribusi listrik malam hari.

Untuk menyediakan tenaga listrik yang sesuai kebutuhan tersebut, harus ada rencana penyediaan listrik yang dilakukan dengan cara membuat prediksi atau prakiraan beban listrik. Karenanya, persoalan metode peramalan beban listrik ini menjadi sangat penting dalam penyediaan tenaga listrik yang efisien.

Salah satu metode peramalan beban listrik adalah jaringan syaraf tiruan. Menurut Siang (2005: 2) jaringan syaraf tiruan merupakan sistem pemrosesan informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi. Menurut Subiyanto (2000) jaringan syaraf tiruan membuat model sistem komputasi yang dapat menirukan cara kerja jaringan syaraf biologis.

Menurut Puspitaningrum (2006: 4) jaringan syaraf tiruan banyak dimanfaatkan untuk berbagai aplikasi, seperti pengenalan pola, peramalan, klasifikasi, signal processing, dan lain-lain. Bidang keilmuan yang sering menggunakan proses neural network tersebut

diantaranya bidang kedokteran, bisnis, dan teknologi informasi.

Penulis mencoba meneliti bagaimana perancangan arsitektur jaringan syaraf tiruan backpropagation pada data beban puncak distribusi listrik di wilayah pemalang. Berdasarkan latar belakang maka rumusan masalah yang diangkat dalam penelitian ini adalah bagaimana rancangan arsitektur jaringan syaraf tiruan backpropagation pada data beban puncak distribusi listrik di wilayah Pemalang.

Penelitian ini bertujuan untuk mengetahui rancangan arsitektur jaringan syaraf tiruan backpropagation pada data beban puncak distribusi listrik di Wilayah Pemalang.

Metode Penelitian

Penelitian ini dimulai dari menemukan masalah. Dalam tahap ini dicari sumber pustaka dan dipilih bagian dari sumber pustaka sebagai suatu masalah. Setelah itu dilanjutkan dengan merumuskan masalah yang ada seperti telah dirumuskan sebelumnya.

Adapun Metode Pengambilan Data pada penelitian ini yaitu melalui studi pustaka dan dokumentasi. Pada studi pustaka dilakukan kajian sumber-sumber pustaka dengan cara mengumpulkan data atau informasi yang berkaitan dengan masalah, sehingga didapatkan suatu ide mengenai bahan dasar pengembangan upaya pemecahan masalah. Selanjutnya, metode pengumpulan data dengan cara dokumentasi dilakukan penulis dengan mengambil atau melihat langsung data-data dari arsip yang ada di PT PLN (Persero) APD Semarang yaitu berupa besar beban puncak siang dan malam hari yang terjadi pada bulan Januari 2012 sampai Desember 2012

Selanjutnya dilakukan analisis data dan pemecahan masalah. Dari berbagai sumber pustaka yang sudah menjadi bahan kajian, diperoleh suatu pemecahan masalah diatas. Selanjutnya dilakukan langkah-langkah pemecahan masalah yaitu

- (1) Pembagian data, data harian beban puncak listrik siang dan malam dari bulan januari 2012 sampai dengan desember 2012 masing-masing dibagi menjadi data pelatihan (training) dan pengujian (testing). Presentase data pelatihan adalah 70% dari data dan 30% data untuk data pengujian.
- (2) Preprocessing / normalisasi, dalam penelitian ini yang digunakan sebagai tool peramalan beban puncak distribusi listrik adalah fungsi prestd.

- (3) Menentukan jumlah lapisan tersembunyi yang menghasilkan kinerja terbaik selama proses pelatihan, yaitu dengan MSE dan epoch yang terkecil.
- (4) Mencari laju belajar (learning rate) dan konstanta momentum terbaik.
- (5) Mencari variasi jaringan yang optimum, yaitu dengan mencari algoritma pembelajaran yang sesuai dengan sistem.
- (6) Postprocessing / denormalisasi, setelah proses pelatihan selesai, harga-harga ternormalisasi output jaringan harus dikembalikan (denormalisasi) ke harga aslinya untuk mendapatkan nilai output pada range yang sebenarnya.
- (7) Pemilihan jaringan yang optimum dan penggunaannya pada peramalan.

Metode terakhir dalam penelitian ini dilakukan penarikan simpulan berdasarkan penelitian.

Hasil dan Pembahasan

Hasil dari pelatihan pertama dengan satu lapisan tersembunyi untuk beban puncak siang dapat dilihat pada Tabel 1.

Tabel 1. Hasil pelatihan pertama dengan 1 lapisan tersembunyi untuk beban puncak siang

Arsitektur	Epoch	LR	Momentum	MSE
7-7-1	10000	0,1	0,1	0,09848269
7-8-1	10000	0,1	0,1	0,0575245
7-9-1	10000	0,1	0,1	0,0926067
7-10-1	3015	0,1	0,1	0,009999485
7-11-1	4200	0,1	0,1	0,009999469
7-12-1	3778	0,1	0,1	0,009999165
7-13-1	2463	0,1	0,1	0,009999905
7-14-1	1195	0,1	0,1	0,009998555
7-15-1	1245	0,1	0,1	0,009998691
7-16-1	1263	0,1	0,1	0,009996521
7-17-1	1905	0,1	0,1	0,009999802
7-18-1	2238	0,1	0,1	0,009997782
7-19-1	2262	0,1	0,1	0,009997702
7-20-1	1980	0,1	0,1	0,009998362
7-21-1	1037	0,1	0,1	0,009999441
7-22-1	885	0,1	0,1	0,009999569
7-23-1	1450	0,1	0,1	0,00999773
7-24-1	791	0,1	0,1	0,009998922
7-25-1	1604	0,1	0,1	0,009998545
7-26-1	860	0,1	0,1	0,00999804
7-27-1	1044	0,1	0,1	0,009996938
7-28-1	797	0,1	0,1	0,009996292
7-29-1	642	0,1	0,1	0,009997241
7-30-1	846	0,1	0,1	0,009997576
7-31-1	733	0,1	0,1	0,009995872
7-32-1	663	0,1	0,1	0,009996698
7-33-1	440	0,1	0,1	0,009989994
7-34-1	593	0,1	0,1	0,000992964
7-35-1	728	0,1	0,1	0,000997223

Hasil pelatihan kedua dengan dua lapisan tersembunyi untuk beban puncak siang dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pelatihan kedua dengan 2 lapisan tersembunyi untuk beban puncak siang

Arsitektur	Epoch	LR	Momentum	MSE
7-32-4-1	3758	0,1	0,1	0,009999251
7-32-5-1	4943	0,1	0,1	0,009999393
7-32-6-1	1575	0,1	0,1	0,009996526
7-32-7-1	1733	0,1	0,1	0,009995192
7-32-8-1	2229	0,1	0,1	0,009995908
7-32-9-1	2568	0,1	0,1	0,009998787
7-32-10-1	1587	0,1	0,1	0,009999392
7-32-11-1	1741	0,1	0,1	0,009997772
7-32-12-1	1587	0,1	0,1	0,009999392
7-32-13-1	1735	0,1	0,1	0,009997521
7-32-14-1	1453	0,1	0,1	0,009999835
7-32-15-1	1453	0,1	0,1	0,009999835
7-32-16-1	2169	0,1	0,1	0,0099972
7-32-17-1	1302	0,1	0,1	0,009999201
7-32-18-1	1884	0,1	0,1	0,00999730
7-32-19-1	10000	0,1	0,1	0,0516285
7-32-20-1	10000	0,1	0,1	0,606411
7-32-21-1	10000	0,1	0,1	0,666867
7-32-22-1	10000	0,1	0,1	0,259687
7-32-23-1	10000	0,1	0,1	0,259687

Hasil keduanya menunjukkan bahwa goal (kinerja tujuan) yang tidak semuanya mencapai hasil yang diinginkan, meskipun *epoch* yang diinginkan tercapai. Ini menunjukkan bahwa jaringan masih belum mampu mengenali pola masukan yang diberikan dengan benar. Sebenarnya ini bukan suatu masalah karena grafik yang dihasilkan selama pelatihan menunjukkan adanya penurunan MSE.

Ada beberapa masalah yang mengakibatkan goal tidak tercapai pada kedua pelatihan. Pertama, *epoch* yang disediakan 10000 *epoch*, kalau menginginkan kinerja tujuan tercapai maka perlu ditambah *epoch* lagi sampai tak berhingga hingga kinerja tujuan tercapai. Ini menjadi kendala sebab akan membutuhkan banyak waktu. Padahal waktu yang dibutuhkan relatif singkat. Kedua, kecilnya laju belajar. Laju belajar yang digunakan pada pelatihan pertama dan kedua adalah 0,1, ini membuat jaringan sulit mengenali pola. Akan lebih baik jika laju belajar ditambahkan. Ketiga, momentum yang kecil. Momentum yang kecil akan berakibat pada penurunan gradien. Idealnya momentum yang digunakan berkisar antara 0,4 sampai dengan 0,8.

Perbedaan yang terjadi antara penggunaan satu lapisan tersembunyi dengan dua lapisan tersembunyi tersebut ada pada

MSE-nya. Memang MSE yang diinginkan tidak tercapai, tetapi dari hasil pelatihan MSE yang dihasilkan relatif kecil. Hasil-hasil pelatihan diatas tetap digunakan dengan melihat MSE yang paling kecil dari tabel. MSE terkecil pada pelatihan pertama adalah 0,009995872, sedangkan pada pelatihan kedua MSE terkecilnya adalah 0,00999730. Dari perbedaan MSE ini menjelaskan bahwa penggunaan lapisan tersembunyi dapat meningkatkan performa dari jaringan yang dibuat.

Dari hasil pelatihan pertama dan kedua maka dapat disimpulkan bahwa arsitektur jaringan yang optimal berdasarkan pertimbangan diatas adalah jaringan dengan satu lapisan tersembunyi sudah cukup yaitu 7-32-1, karena dengan 2 lapisan tersembunyi perbedaan MSE yang didapat masih lebih dari MSE yang didapat dengan 1 lapisan tersembunyi. Jadi untuk mempercepat proses iterasi digunakan satu lapisan tersembunyi.

Selanjutnya pelatihan ketiga dilakukan. Pelatihan ketiga bertujuan untuk memperoleh nilai momentum dan laju belajar yang optimum, dengan memakai arsitektur jaringan terbaik pada pelatihan pertama dan kedua. Arsitektur jaringan yang digunakan adalah 7-32-1, dengan *epoch* maksimum 10000, target kinerja (*goal*) 0,001 serta algoritma pelatihan *gradient descent* (traingd). Hasil pelatihan ketiga diperlihatkan pada Tabel 3.

Dari hasil pengamatan dapat dilihat bahwa untuk nilai laju belajar yang cukup kecil menjamin penurunan gradien terlaksana dengan baik, namun ini berakibat bertambahnya jumlah iterasi sehingga untuk mencapai konvergensi berlangsung lebih lama. Jika konstanta laju belajar bertambah besar terlihat tidak terjadi penurunan gradien secara signifikan.

Kemudian penggunaan konstanta momentum berfungsi untuk mempercepat konvergensi dan juga untuk mencegah terjebaknya pelatihan kedalam minimum lokal, jika momentum semakin besar maka konvergensi akan cepat tercapai. Akan tetapi penggunaan konstanta momentum jangan terlalu tinggi, sebab kemungkinan gelombang yang dihasilkan akan terjadi *noise*. Hasil terbaik terjadi pada laju belajar 0,1 dan konstanta momentum 0,1 menghasilkan MSE sebesar 0,009995872.

Selanjutnya adalah mencari variasi jaringan yang optimum. Tujuan dari pelatihan ini adalah mencari variasi jaringan yang mampu

menghasilkan kesalahan terkecil dengan waktu komputasi yang cepat. Pelatihan dilakukan dengan hasil pelatihan terbaik 0,1; momentum 0,1; target *error* (MSE) 0,001 dan maksimum *epoch*-nya 10000.

Tabel 3. Hasil pelatihan ketiga beban puncak siang

Architecture	Momentum	LR	Epoch	MSE
7-32-1		0,1	733	0,009995872
7-32-1		0,2	10000	~
7-32-1	0,1	0,3	10000	~
7-32-1		0,4	10000	~
7-32-1		0,5	10000	~
7-32-1		0,1	915	0,009998546
7-32-1		0,2	10000	~
7-32-1	0,2	0,3	10000	~
7-32-1		0,4	10000	~
7-32-1		0,5	10000	~
7-32-1		0,1	754	0,009996312
7-32-1		0,2	10000	~
7-32-1	0,3	0,3	10000	~
7-32-1		0,4	10000	~
7-32-1		0,5	10000	~
7-32-1		0,1	794	0,009999072
7-32-1		0,2	10000	~
7-32-1	0,4	0,3	10000	~
7-32-1		0,4	10000	~
7-32-1		0,5	10000	~
7-32-1		0,1	945	0,00999841
7-32-1		0,2	10000	~
7-32-1	0,5	0,3	10000	~
7-32-1		0,4	10000	~
7-32-1		0,5	10000	~
7-32-1		0,1	763	0,009998254
7-32-1		0,2	10000	~
7-32-1	0,6	0,3	10000	~
7-32-1		0,4	10000	~
7-32-1		0,5	10000	~
7-32-1		0,1	826	0,009998110
7-32-1		0,2	10000	~
7-32-1	0,7	0,3	10000	~
7-32-1		0,4	10000	~
7-32-1		0,5	10000	~
7-32-1		0,1	905	0,009997131
7-32-1		0,2	10000	~
7-32-1	0,8	0,3	10000	~
7-32-1		0,4	10000	~
7-32-1		0,5	10000	~
7-32-1		0,1	875	0,009996324
7-32-1		0,2	10000	~
7-32-1	0,9	0,3	10000	~
7-32-1		0,4	10000	~
7-32-1		0,5	10000	~

Ada beberapa variasi jaringan yang dapat digunakan dalam jaringan syaraf tiruan *backpropagation*. Setiap variasi yang dilatihkan memiliki karakteristik masing-masing. Untuk menentukan variasi yang digunakan perlu melihat MSE, jumlah *epoch* dan prosentase hasil

pengujian. Ada beberapa variasi yang MSE-nya tercapai namun prosentasenya tidak tercapai.

Tabel 4. Variasi Jaringan Beban Puncak Siang

Arsitektur	Epoch	LR	Momentum	Variasi	MSE	Epoch
7-32-1	10000	0,1	0,1	traingd	0,009995872	733
7-32-1	10000	0,1	0,1	traingda	0,00999730	1884
7-32-1	10000	0,1	0,1	traingdm	0,009988550	860
7-32-1	10000	0,1	0,1	traingdx	0,009990292	423

Dari berbagai pertimbangan di atas maka variasi yang paling baik pada tabel 4 adalah menggunakan traingdx. Selain menghasilkan waktu komputasi yang singkat, grafiknya juga baik. Selanjutnya proses pengujian dilakukan untuk mengetahui tingkat akurasi jaringan.

Ada dua proses pengujian yang dilakukan dalam penelitian ini yaitu pengujian dengan data pelatihan dan pengujian dengan data pengujian yaitu analisis pengujian dengan data pelatihan dan yaitu analisis pengujian dengan data pengujian. Pengujian dilakukan dengan menggunakan arsitektur dan algoritma terbaik pada proses pelatihan yaitu dengan satu lapisan tersembunyi dengan arsitektur 7-32-1 dengan konstanta momentum 0,1 dan laju belajar 0,1 dengan algoritma traingdx.

Selanjutnya untuk data beban puncak malam. Sama dengan proses pada beban puncak siang, pada beban puncak malam juga melalui tahapan yang sama. Hasil dari pelatihan pertama dengan satu lapisan tersembunyi dapat dilihat pada Tabel 5.

Berdasarkan Tabel 5, hasil terbaik diperoleh dengan bobot 42. Hasil dari pelatihan kedua dengan dua lapisan tersembunyi dapat dilihat pada tabel berikut.

Berdasarkan Tabel 6 MSE terkecil pada pelatihan pertama adalah 0,00998844, sedangkan pada pelatihan kedua MSE terkecilnya adalah 0,009998778. Dari hasil kedua pelatihan tersebut dapat disimpulkan bahwa arsitektur jaringan yang optimal adalah jaringan dengan satu lapisan tersembunyi sudah cukup yaitu 7-42-1,

Selanjutnya mencari laju belajar dan momentum. Arsitektur jaringan yang digunakan adalah 7-42-1, dengan epoch maksimum 10000, target kinerja (goal) 0,001 serta algoritma pelatihan gradient descent (traingd). Hasil pelatihan ketiga diperlihatkan pada Tabel 7.

Tabel 5. Hasil Pelatihan dengan 1 lapisan tersembunyi untuk beban puncak malam

Arsitektur	Epoch	LR	Momentum	MSE
7-7-1	10000	0,1	0,1	0,00319829
7-8-1	10000	0,1	0,1	0,0163833
7-9-1	10000	0,1	0,1	0,0131695
7-10-1	10000	0,1	0,1	0,00891917
7-11-1	8310	0,1	0,1	0,009999904
7-12-1	10000	0,1	0,1	0,00157169
7-13-1	5463	0,1	0,1	0,009999952
7-14-1	5712	0,1	0,1	0,009999839
7-15-1	5695	0,1	0,1	0,009999649
7-16-1	9619	0,1	0,1	0,009999702
7-17-1	3134	0,1	0,1	0,009999021
7-18-1	3645	0,1	0,1	0,009995745
7-19-1	3191	0,1	0,1	0,009997564
7-20-1	1744	0,1	0,1	0,009999132
7-21-1	2655	0,1	0,1	0,009999925
7-22-1	1980	0,1	0,1	0,009998613
7-23-1	2850	0,1	0,1	0,009999749
7-24-1	2388	0,1	0,1	0,009999791
7-25-1	1821	0,1	0,1	0,009998196
7-26-1	2336	0,1	0,1	0,009998761
7-27-1	2386	0,1	0,1	0,009999974
7-28-1	1783	0,1	0,1	0,009998332
7-29-1	2424	0,1	0,1	0,009999509
7-30-1	1421	0,1	0,1	0,00999833
7-31-1	1235	0,1	0,1	0,009997701
7-32-1	1726	0,1	0,1	0,009998249
7-33-1	1238	0,1	0,1	0,009999975
7-34-1	1254	0,1	0,1	0,009998499
7-35-1	965	0,1	0,1	0,009999956
7-36-1	526	0,1	0,1	0,009999392
7-37-1	1021	0,1	0,1	0,009996709
7-38-1	734	0,1	0,1	0,009995669
7-39-1	1110	0,1	0,1	0,009998708
7-40-1	979	0,1	0,1	0,009998999
7-41-1	1373	0,1	0,1	0,00999899
7-42-1	837	0,1	0,1	0,00998844
7-43-1	2745	0,1	0,1	0,009999892
7-44-1	2518	0,1	0,1	0,009998698
7-45-1	2267	0,1	0,1	0,009998399

Tabel 6 Hasil Pelatihan kedua untuk beban puncak malam

Arsitektur	Epoch	LR	Momentum	MSE
7-42-4-1	10000	0,1	0,1	0,00369229
7-42-5-1	6244	0,1	0,1	0,009999983
7-42-6-1	5745	0,1	0,1	0,009999717
7-42-7-1	10000	0,1	0,1	0,09125031
7-42-8-1	3454	0,1	0,1	0,009999198
7-42-9-1	2808	0,1	0,1	0,009998778
7-42-10-1	6006	0,1	0,1	0,00999856
7-42-11-1	5585	0,1	0,1	0,00999962
7-42-12-1	4144	0,1	0,1	0,009999273
7-42-13-1	10000	0,1	0,1	0,00245368
7-42-14-1	10000	0,1	0,1	0,105641
7-42-15-1	10000	0,1	0,1	0,0337163
7-42-16-1	10000	0,1	0,1	0,607461
7-42-17-1	10000	0,1	0,1	0,511206
7-42-18-1	10000	0,1	0,1	0,375475
7-42-19-1	10000	0,1	0,1	0,686041
7-42-20-1	10000	0,1	0,1	0,289311
7-42-21-1	10000	0,1	0,1	0,427789
7-42-21-1	10000	0,1	0,1	0,713778
7-42-22-1	10000	0,1	0,1	0,628961

Tabel 7. Hasil Pelatihan kedua untuk beban puncak malam

Arsitektur	Momentum	LR	Epoch	MSE
7-42-1		0,1	837	0,00998844
7-42-1		0,2	10000	~
7-42-1	0,1	0,3	10000	~
7-42-1		0,4	10000	~
7-42-1		0,5	10000	~
7-42-1		0,1	837	0,00999754
7-42-1		0,2	10000	~
7-42-1	0,2	0,3	10000	~
7-42-1		0,4	10000	~
7-42-1		0,5	10000	~
7-42-1		0,1	837	0,0099965
7-42-1		0,2	10000	~
7-42-1	0,3	0,3	10000	~
7-42-1		0,4	10000	~
7-42-1		0,5	10000	~
7-42-1		0,1	837	0,00998980
7-42-1		0,2	10000	~
7-42-1	0,4	0,3	10000	~
7-42-1		0,4	10000	~
7-42-1		0,5	10000	~
7-42-1		0,1	837	0,00998812
7-42-1		0,2	10000	~
7-42-1	0,5	0,3	10000	~
7-42-1		0,4	10000	~
7-42-1		0,5	10000	~
7-42-1		0,1	837	0,0099947
7-42-1		0,2	10000	~
7-42-1	0,6	0,3	10000	~
7-42-1		0,4	10000	~
7-42-1		0,5	10000	~
7-42-1		0,1	837	0,00998943
7-42-1		0,2	10000	~
7-42-1	0,7	0,3	10000	~
7-42-1		0,4	10000	~
7-42-1		0,5	10000	~
7-42-1		0,1	837	0,00998734
7-42-1		0,2	10000	~
7-42-1	0,8	0,3	10000	~
7-42-1		0,4	10000	~
7-42-1		0,5	10000	~
7-42-1		0,1	837	0,0099965
7-42-1		0,2	10000	~
7-42-1	0,9	0,3	10000	~
7-42-1		0,4	10000	~
7-42-1		0,5	10000	~

Berdasarkan Tabel 7, hasil terbaik terjadi pada laju belajar 0,1 dan konstanta momentum 0,1 menghasilkan MSE sebesar 0,00998844. Hasil Analisis variasi jaringan pada beban puncak malam ditampilkan pada tabel 8.

Tabel 8. Variasi Jaringan Beban Puncak Malam

Arsitektur	Epoch	LR	Momentum	Variasi	MSE	Epoch
7-42-1	10000	0,1	0,1	traingd	0,00998844	837
7-42-1	10000	0,1	0,1	traingda	0,009991904	3545
7-42-1	10000	0,1	0,1	traingdm	0,00999582	485
7-42-1	10000	0,1	0,1	traingdx	0,009985689	2823

Dari Tabel 8 terlihat bahwa variasi yang paling baik adalah menggunakan traingd karena menghasilkan waktu komputasi yang singkat.

Langkah selanjutnya adalah jaringan

akan diuji dengan data pelatihan dan pengujian. Pengujian dilakukan dengan menggunakan arsitektur dan algoritma terbaik pada proses pelatihan yaitu dengan satu lapisan tersembunyi dengan arsitektur 7-42-1 dengan konstanta momentum 0,1 dan laju belajar 0,1 dengan algoritma traingd.

Penutup

Arsitektur jaringan syaraf tiruan yang optimum pada data beban puncak distribusi listrik di wilayah Pemalang adalah

1. Untuk beban puncak siang, arsitektur jaringan syaraf tiruan yang optimum untuk data beban puncak siang adalah jaringan yang terdiri dari sebuah lapisan input dengan 7 unit input, sebuah lapisan tersembunyi dengan 32 unit tersembunyi, dan sebuah lapisan output dengan 1 unit output. Arsitektur ini menggunakan konstanta momentum 0,1 dan laju belajar 0,1 dengan algoritma traingdx. MSE yang dihasilkan adalah sebesar 0.009990292 dengan 423 epoch.
2. Untuk beban puncak malam, arsitektur jaringan syaraf tiruan yang optimum untuk data beban puncak malam adalah jaringan yang terdiri dari sebuah lapisan input dengan 7 unit input, sebuah lapisan tersembunyi dengan 42 unit tersembunyi, dan sebuah lapisan output dengan 1 unit output. Arsitektur ini menggunakan konstanta momentum 0,1 dan laju belajar 0,1 dengan algoritma traingdx. MSE yang dihasilkan adalah sebesar 0,00998844 dengan 837 epoch.

Ucapan Terimakasih

Peneliti mengucapkan terima kasih kepada Direktur PT PLN (Persero) APD Semarang dan karyawan yang telah mengizinkan peneliti dalam memperoleh data-data yang dibutuhkan untuk menyelesaikan penelitian ini.

Daftar Pustaka

- Puspitaningrum, D. 2006. *Pengantar Jaringan Syaraf Tiruan*. Yogyakarta: ANDI.
- Siang, JJ. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Yogyakarta: ANDI.
- Subiyanto. 2000. Aplikasi Jaringan syaraf tiruan sebagai metode alternatif prakiraan beban jangka pendek. *Jurnal Elektro Indonesia Nomor 29 Tahun VI Januari 2000*. Tersedia di <http://www.elektroindonesia.com/elektro/ener29.html>.