

ANALISA DAN PERBANDINGAN AKURASI MODEL PREDIKSI RENTET WAKTU ARUS LALU LINTAS JANGKA PENDEK

Bambang Lareno

Teknik Informatika, STMIK Indonesia

Jl. P. Hidayatullah (Samping Jembatan Banua Anyar) Banjarmasin

Telp.(0511) 4315530

e-mail: blareno@gmail.com

Abstract

There are many algorithm that can be used to predict traffic flow but it is not known which algorithm that has a more accurate performance. So that each algorithm needs to be tested to find out. The proposed method is an accuracy comparison method of algorithm-based neural network that can be used for predictive a time-series data. Algorithms to be tested is the back Propagation Neural Network (BP-NN), Adaptive Neuro Fuzzy Inference System (ANFIS), Wavelet Neural Network (WNN), dan Evolving Neural Network (ENN), which is used to predict short-term traffic flow. Each algorithm will be implemented using MatLab 2009b. Performance measurement is done by calculating the average amount of error that occurred through the Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE) and Mean Absolute Deviation (MAD). The smaller value of each performance parameter will indicate that the predictive value was closer to the true value. Thus a more accurate algorithm can be determined. The test results determine that ENN is more accurate prediction algorithms for short-term traffic flow.

Keywords : Traffic Flow Prediction, Time-Series Forecasting.

Abstrak

Terdapat banyak algoritma yang dapat dipakai untuk memprediksi arus lalu lintas, namun belum diketahui algoritma manakah yang memiliki kinerja lebih akurat untuk lalu lintas di Indonesia. Algoritma-algoritma tersebut perlu diuji untuk mengetahui algoritma manakah yang memiliki kinerja lebih akurat. Metode yang diusulkan adalah metode perbandingan tingkat akurasi dari algoritma berbasis neural network yang bisa digunakan untuk prediksi data rentet waktu. Algoritma yang akan diuji adalah back Propagation Neural Network (BP-NN), Adaptive Neuro Fuzzy Inference System (ANFIS), Wavelet Neural Network (WNN), dan Evolving Neural Network (ENN), yang digunakan untuk memprediksi arus lalulintas. Masing-masing algoritma akan implementasikan dengan menggunakan MatLab 2009b. Pengukuran kinerja dilakukan dengan menghitung rata-rata error yang terjadi melalui besaran Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE) dan Mean Absolute Deviation (MAD). Semakin kecil nilai dari masing-masing parameter kinerja ini menyatakan semakin dekat nilai prediksi dengan nilai sebenarnya. Dalam penelitian ini diketahui bahwa Algoritma ENN memprediksi arus lalu lintas dengan lebih akurat.

Kata kunci : Prediksi Arus Lalu Lintas, Peramalan Rentet Waktu.

1. PENDAHULUAN

Dasar dan kunci manajemen sistem transportasi cerdas adalah kemampuan memprediksi arus lalu lintas secara akurat dan efisien, karena prediksi yang tidak akurat menyebabkan perencanaan yang tidak tepat[1].

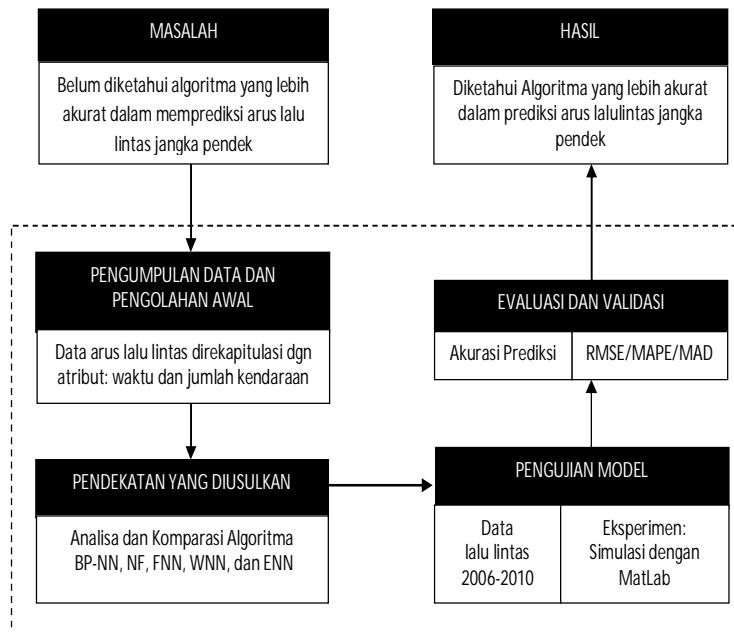
Karena itu, prediksi arus lalu lintas telah menarik minat banyak peneliti. Manoel Castro-Neto menggunakan metode Online-SVR[2]. Young Jung Yu menggunakan pendekatan Bayesian Network[3]. Haowei Su menggunakan Incremental Support Vector Regression[4]. Wang Xinying

menggunakan uji Grid-based[5]. Tao Ji menerapkan pendekatan Genetic Neural Network[6]. Yafei Huang mencoba pendekatan lain, yaitu Wavelet Neural Network (WNN) yang dioptimasi dengan Partikel Swam Optimizer[7]. Huang Hongqiong mencoba dengan metode Multi Regression Analysis[8]. Lin Yung-Chin memakai algoritma Evolving Neural Network (ENN)[9]. Jin Wang memakai pendekatan ‘Theory of Chaos’[1]. Nicolae Morariu menggunakan pengenalan pola dan neural network multilayer perceptron untuk diagnosa dan prediksi[10]. Gang Tong menyajikan strategi lain, yaitu Fuzzy Neural Network (FNN) sebagai metode prediksi arus lalu lintas untuk sistem kontrol lalu lintas di persimpangan[11]. Sementara itu Gao Guorong dan Liu Yanping menerapkan kombinasi PCA dan WNN sebagai algoritma untuk memprediksi. Mereka menyatakan bahwa WNN lebih baik dibandingkan jika dengan Back Propagation Nerural Network (BP-NN)[12].

Dengan demikian, dapat dikatakan bahwa terdapat banyak algoritma berbasis neural network yang dapat dipakai untuk memprediksi arus lalu lintas, dan belum diketahui algoritma mana yang memiliki kinerja lebih akurat untuk analisis lalu lintas di Indonesia. Sehingga fokus penelitian ini adalah pada bagaimana mengevaluasi akurasi algoritma BP-NN, NF, WNN, dan ENN dalam memprediksi arus lalu lintas jangka pendek dan menentukan algoritma berbasis neural network mana di antara BP-NN, NF, WNN, dan ENN, yang memiliki kinerja lebih akurat memprediksi arus lalu lintas jangka pendek.

2. METODE PENELITIAN

Penelitian ini memakai data metode penelitian eksperimen komparasi, yang terdiri : (1) Pengumpulan data dan pengolahan data awal, (2) Pendekatan yang diusulkan, (3) Pengujian model, dan (4) Evaluasi dan validasi hasil.



2.1 Metode Pengumpulan data dan pengolahan data awal

Penelitian ini memakai data arus lalu lintas yang didapatkan dari Satker P2JN (Satuan Kerja Perencanaan dan Pengawasan Jalan Nasional) Provinsi Kalimantan Selatan[13] dan Dinas Perhubungan Kota Banjarmasin. Data yang didapatkan dari instansi terkait masih berupa data dasar, yang terdiri dari jumlah masing-masing jenis kendaraan, sehingga harus direkapitulasi sehingga memiliki satuan yang sama. Rekapitulasi tersebut dilakukan dengan memperhatikan faktor konversi masing-masing jenis kendaraan[14], sebagaimana ditampilkan dalam tabel 1.

Tabel 1. Faktor Konversi

Kelas Kendaraan	kota	desa
Mobil pribadi, taksi, kombinasi sepeda motor, kendaraan muatan ringan	1,00	1,00
Sepeda motor, skuter, moped	0,75	1,00
Kendaraan barang sedang atau berat	2,00	3,00
Bis sedang dan besar, bis gandeng, trem	3,00	3,00
Sepeda	0,33	0,50

2.2 Pendekatan Yang Diusulkan

Pendekatan yang diusulkan adalah perbandingan tingkat akurasi dari algoritma berbasis neural network yang bisa digunakan untuk prediksi data rentet waktu. Algoritma yang akan diuji adalah BP-NN, NF, WNN, dan ENN, yang digunakan untuk memprediksi data arus lalu lintas jangka pendek. Masing-masing algoritma akan dimodelkan dan diimplementasi menggunakan MatLab 2009b.

2.3 Pengujian Model/Metode

Setiap algoritma akan diuji dengan beberapa perubahan parameter. Dalam setiap perubahan parameter, pengujian akan dilakukan beberapa kali. Setiap kali hasil akan dicatat dan dihitung nilai rata-ratanya. Berdasarkan nilai rata-rata ini hasil terbaik dari tiap algoritma akan ditentukan.

2.3.1 Desain Eksperimen Taguchi

Taguchi [15] menginisiasi metode perancangan yang berprinsip pada perbaikan mutu dengan memperkecil akibat dari variasi tanpa menghilangkan penyebabnya. Hal ini dapat diperoleh melalui optimasi produk/objek dan perancangan proses untuk membuat unjuk kerja/performance kebal terhadap berbagai penyebab variasi suatu proses yang disebut perancangan parameter.

2.3.2 Parameter Evaluasi

Menurut Carlo Vercellis, ada dua alasan utama untuk mengukur akurasi prediksi model time series [16]. Pertama, pada tahap pengembangan dan identifikasi model, ukuran akurasi diperlukan untuk membandingkan model-model alternatif satu sama lain dan untuk menentukan nilai parameter yang muncul dalam ekspresi untuk fungsi prediksi F. Untuk mengidentifikasi model prediksi yang paling akurat, masing-masing model dianggap diterapkan pada data masa lalu, dan model dengan total error minimum dipilih. Kedua, perlu untuk secara berkala menilai keakuratan, untuk mendeteksi kelainan dan kekurangan dalam model yang mungkin timbul di lain waktu. Untuk mengevaluasi akurasi dan peramalan kinerja model berbeda, penelitian ini mengadopsi tiga indeks evaluasi: *Percentage Error* (MAPE), *Root Mean Square Error* (RMSE) dan *Mean Absolute Deviation* (MAD).

MAPE adalah nilai *absolute* dari persentase error data terhadap *mean*, atau dapat dirumuskan sebagai berikut[17]:

$$MAPE = \frac{\sum_{n=1}^N \left| \frac{(\text{Prediksi}-\text{Aktual})}{\text{Aktual}} \right| \times 100}{n} \quad (1)$$

RMSE adalah penjumlahan kuadrat error atau selisih antara nilai sebenarnya (aktual) dan nilai prediksi, kemudian membagi jumlah tersebut dengan banyaknya waktu data peramalan dan kemudian menarik akarnya, atau dapat dirumuskan sebagai berikut[18]:

$$RMSE = \sqrt{\frac{\sum_{n=1}^N (\text{Aktual}-\text{Prediksi})^2}{n}} \quad (2)$$

MAD adalah nilai absolut dari penyimpangan data terhadap *mean*, atau dapat dirumuskan sebagai berikut[19]:

$$MAD = \frac{\sum_{n=1}^N |\text{Aktual}-\text{Prediksi}|}{n} \quad (3)$$

3. HASIL DAN PEMBAHASAN

3.1 Hasil Eksperimen

3.1.1 Model Back Propagation Neural Network (BPNN)

Dalam model BPNN, tingkat akurasi didukung oleh arsitektur jaringan yang terbaik, model learning yang digunakan dan learning rate yang optimal. Untuk mendapatkan arsitektur neural network yang paling adaptif terhadap data training, maka dilakukan pemilihan berdasarkan error terkecil dari beberapa arsitektur pilihan. Proses pengujian dilakukan dengan nilai learning rate =0,05 dan model learning: Levenberg Marquardt (lm), conjugate gradient Fletcher-Reeves (cgf), dan Broyden, Fletcher, Goldfarb, and Shanno (bfg)[20]. Hasil seluruhnya ditampilkan dalam Tabel 2 berikut:

Tabel 2. Pengujian Struktur BPNN

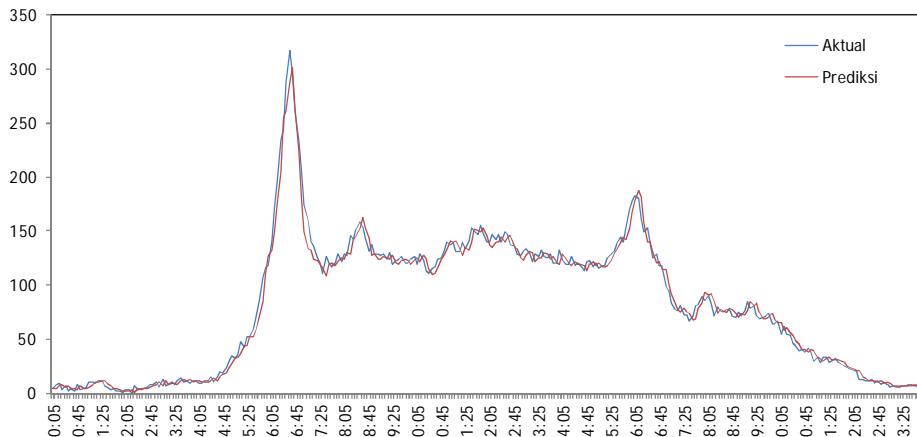
Arsitektur NN			(rata-rata MSE)		
Inp ut	Hide d n-1	Outp ut	BP-lm	BP-cgf	BP-bfg
4	2	1	367,79	293,82	224,70
4	4	1	302,74	446,32	385,37
4	6	1	332,77	331,57	369,28
4	8	1	249,50	154,61	220,23
5	2	1	7,29.10-3	1,18	2,80
5	5	1	9,11.10-3	2,56	13,51
6	2	1	386,62	391,23	443,21
6	4	1	396,21	456,21	402,48
6	6	1	353,30	373,68	389,64
6	9	1	259,83	274,22	240,73
6	12	1	360,35	286,55	265,33

Arsitektur 5-2-1 dengan model learning Levenberg Marquardt (lm) menghasilkan error terkecil. Jadi arsitektur 5-2-1 adalah struktur terbaik untuk mendapatkan hasil yang akurat. Untuk mendapatkan nilai learning rate terbaik, struktur ini diuji dengan nilai Lr yang berbeda, dengan Max Epoch = 2000. Dari Tabel 3, Learning rate yang terpilih adalah 0,05.

Tabel 3. Hasil Pengujian Learning Rate untuk Struktur 5-2-1

Arsitektur NN 5-2-1	
Lr	MSE (Rata-rata)
0.05	0,0003
0.10	0,0012
0.15	0,0400
0.20	0,0270
0.25	0,0018

Arsitektur 5-2-1, dilatih dengan model learning Levenberg Marquardt (lm), dan nilai learning rate = 0,05 menggunakan data training (2006-2010). Data uji (2011) yang dilewatkan pada struktur yang telah tersebut menghasilkan titik-titik prediksi (gambar 1). Data hasil beberapa kali uji ditampilkan pada tabel 9. Hasil prediksi didapatkan dengan rata-rata kesalahan: RMSE = 7,992; MAD = 5,2992; dan MAPE = 0,14984 (14,98%).

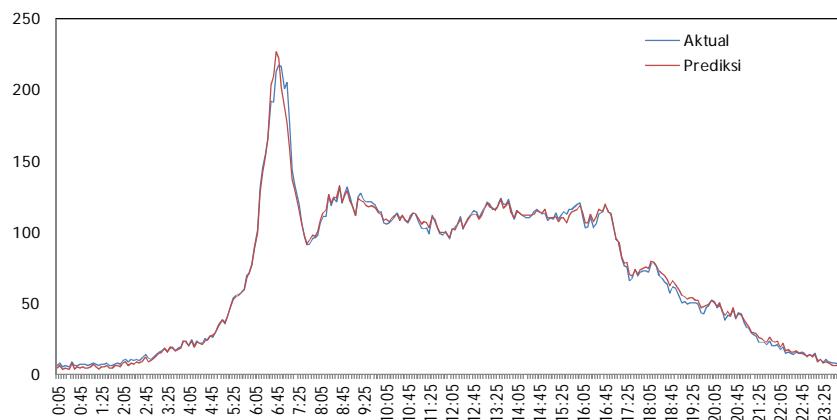


Gambar 1. Grafik hasil pengujian BPNN

3.1.2 Model Neuro Fuzzy (ANFIS)

Salah satu model Neuro Fuzzy adalah Adaptive Neuro Fuzzy Inference System (ANFIS). Validasi model adalah proses dimana vektor input dari input / output data set yang FIS tidak dilatih, disajikan dengan model FIS terlatih, untuk melihat seberapa baik model FIS memprediksi nilai set sesuai data output[21]. Proses Anfis dapat dilakukan dengan menggunakan Fuzzylogic Tool Matlab (menggunakan anfisedit)[22].

Hasil yang didapatkan sebagaimana tabel 9 dan grafik hasil pengujian pada gambar 2. Hasil ini konstan untuk paramater yang sama, sehingga kalaupun diulang akan tetap memberikan hasil sama. Data uji (2011) yang dilewatkan pada struktur tersebut menghasilkan titik-titik prediksi (gambar 2) dengan rata-rata kesalahan: RMSE = 7,608; MAD = 5,171; dan MAPE = 0,0896 (8,86%).



Gambar 2. Grafik hasil pengujian ANFIS

Parameter evaluasi menunjukkan bahwa sejauh ini, rata-rata kesalahan yang didapatkan ANFIS masih lebih kecil dari BPNN. Berdasarkan pengamatan visual, grafik garis prediksi BPNN lebih dapat dibedakan dari garis aktual. Makin identik grafik garis prediksi dengan aktual, semakin akurat prediksi tersebut. Selain itu hasil ANFIS konstan apabila diulang, sehingga deviasi menjadi nol (lihat tabel 9). Dengan demikian, ANFIS lebih akurat dari BPNN.

3.1.3 Model Wavelet Neural Network (WNN)

Data lalu lintas (data training) yang sudah di dekomposisi akan menjadi data input bagi neural network, dengan struktur yang optimal sebagaimana hasil dari uji model sebelumnya. Pembobotan dalam neural network dilakukan oleh wavelet. Kemudian data checking akan

didekomposisi dan dilewatkan dalam struktur neural network yang telah mengalami pembobotan wavelet, menghasilkan data checking yang terdekomposisi. Hasil keluaran neural network ini akan direkonstruksi sehingga menjadi data prediksi arus lalu lintas. Data prediksi seperti ini akan dibandingkan dengan data sebenarnya, untuk mendapatkan nilai RMSE, MAPE dan MAD. Pengujian dilakukan untuk mendapatkan struktur dan type wavelet yang terbaik. Hasil pengujian untuk Haar, db2, db3, dan db4 ditunjukkan oleh tabel 4, berikut:

Tabel 4. Hasil Pengujian Struktur NN

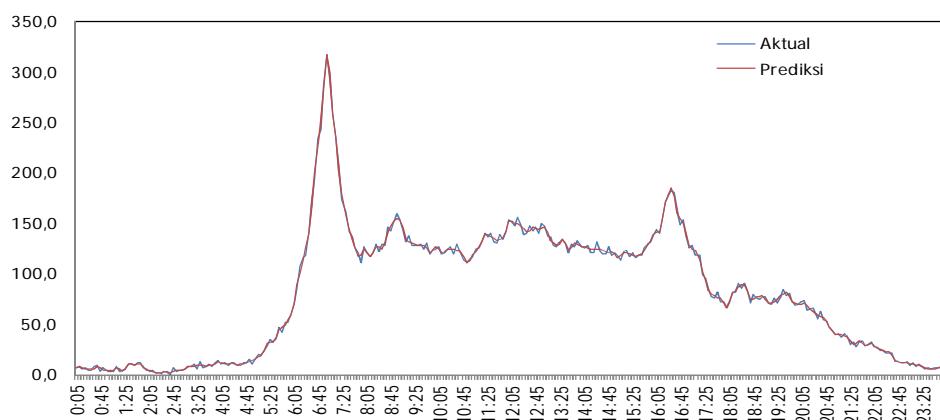
Arsitektur NN			WNN (MSE rata-rata)			
Input	Hidden	Output	Haar	Db2	Db3	Db4
4	8	1	3,540	3,2478	2,7184	8,4622
5	2	1	0,003	0,0015	0,0011	0,0027
5	5	1	0,082	0,0042	0,0021	0,0961
6	9	1	0,010	0,3714	0,0153	0,4283

Dari hasil uji ini, terlihat bahwa secara rata-rata, transformasi dengan wavelet Db3 menghasilkan nilai MSE terendah. Dari tabel yang sama dapat dilihat bahwa struktur 5 - 2 - 1 menghasilkan nilai MSE terendah.

Tabel 5. Nilai MSE NN 5-2-1 dalam beberapa level dekomposisi wavelet

Level	WNN (MSE rata-rata) 5-2-1			
	Haar	Db2	Db3	Db4
1	0,0322	0,0322	0,0271	0,0426
2	0,0033	0,0015	0,0011	0,0027
3	0,0018	0,0011	0,0009	0,0014
4	0,0022	0,0013	0,0003	0,0016
5	0,0023	0,0015	0,0005	0,0011

Tabel 5 memperlihatkan bahwa MSE terendah neural network hasil training wavelet dihasilkan oleh wavelet Db3 pada level 4. Dengan demikian struktur ini dipakai untuk simulasi data uji. Data uji (2011) didekomposisi dan dilewatkan ke struktur 5-2-1 menghasilkan besar, yang dikembalikan ke bentuk asal, menghasilkan RMSE = 2,6445; MAD=2,0893; dan MAPE = 0,0673 (6,73%). Grafik hasil pengujian diperlihatkan gambar 3.



Gambar 3. Grafik hasil pengujian WNN

Membandingkan hasil ini dengan hasil sebelumnya, didapatkan rata-rata kesalahan hasil WNN lebih kecil dari ANFIS. Berdasarkan pengamatan visual, grafik garis prediksi WNN lebih bila dibanding dengan hasil ANFIS. Dengan demikian, WNN lebih akurat dari ANFIS dan BPNN.

3.1.4 Model Evolving Neural Network (ENN)

Lima parameter penting algoritma genetika menurut Suyanto[23], yaitu: tipe crossover dan nilainya, tipe mutasi dan nilainya serta tipe seleksi, diatur menggunakan desain eksperimen Taguchi. Desain eksperimen Taguchi [15][19] digunakan untuk pengaturan parameter parameter itu. Pendekatan dilakukan dengan perhitungan Signal-to-Noise (S/N). Kode dan level untuk masing-masing parameter tersebut ditampilkan dalam tabel 6, sebagai berikut:

Tabel 6. Kode dan level parameter GA

Parameter/kode	Level 1	Level 2	Level 3	Level 4
Cross over (A)	1-Point	1-Point	2-Point	2-Point
Mutasi (B)	1-Point	1-Point	Shift	Shift
Seleksi (C)	Total	Total	Elite	Elite
Nilai Cross over (D)	0,2	0,4	0,6	0,8
Nilai Mutasi (E)	0,1	0,3	0,5	0,7

Berdasarkan uji optimasi, profil konvergensi untuk data time-series semi musiman menunjukkan bahwa sistem dapat mendekati nilai tertinggi setelah lebih 20.000 generasi bahkan untuk ukuran populasi yang kecil misalnya 10. Pada Tabel 7, terlihat bahwa nilai fitness tertinggi dicapai oleh populasi awal 100 dengan generasi yang lebih sedikit. Oleh karena itu, dalam pengujian akan digunakan ukuran populasi 100 sebagai populasi awal untuk percobaan.

Tabel 7. Hasil fitness untuk optimasi parameter

Ukuran Populasi	Prob. mutation	Rata-rata Fitness	Rata-rata Jumlah individu
10	0.1	6.3226	41608
10	0.3	9.7154	44745
10	0.5	6.443	50000
10	0.7	7.0115	50000
20	0.1	6.7849	36660
20	0.3	9.2607	50000
20	0.5	6.3597	50000
20	0.7	7.7605	50000
30	0.1	9.049	23247
30	0.3	9.7905	43596
30	0.5	7.9803	45735
30	0.7	7.4558	45108
40	0.1	8.1327	35096
40	0.3	9.5833	47812
40	0.5	8.3176	47608
40	0.7	6.9825	48360
50	0.1	9.0757	31050
50	0.3	9.4636	47500
50	0.5	7.2806	50000
50	0.7	6.2719	50000
100	0.1	9.9573	30220
100	0.3	8.5623	50000
100	0.5	7.5089	45700
100	0.7	7.6876	45690

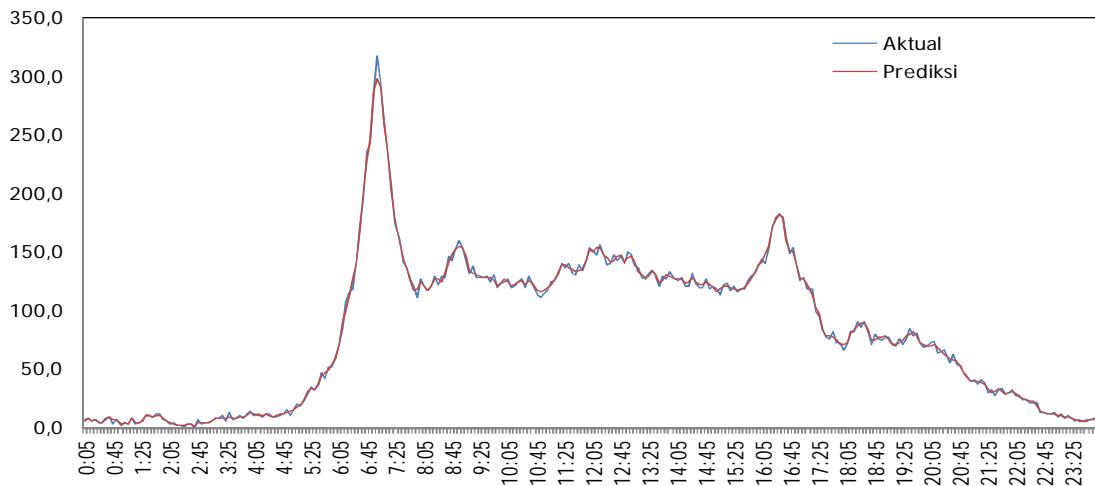
Dengan data lalulintas sebagai input dan target, dilakukan tiga kali percobaan algoritma genetika (tanpa neural network) dengan populasi 100 dan parameter masing-masing operator di-setting sesuai level rencana, kemudian menghitung rata-rata S/N rasio dari setiap tingkat faktor, hasilnya ditunjukkan pada Tabel 8.

Tabel 8. Hasil perhitungan S/N rasio

Faktor	A	B	C	D	E
Level 1	12,24	32,41	14,32	12,22	12,56
Level 2	12,68	21,22	15,98	12,54	16,21
Level 3	11,60	7,14	12,45	12,98	14,67
Level 4	10,46	7,14	17,42	15,62	16,11

Dari rasio S/N sebagaimana Tabel 9, kombinasi terbaik dari pengaturan parameter dapat ditemukan sebagai (A) 2 - (B) 1 - (C) 4 - (D) 4 - (E) 2 (sebagaimana disorot dalam huruf tebal). Kode-kode ini mewakili crossover satu titik, mutasi satu titik, seleksi elitis, Crossover rate = 0,8, dan tingkat mutasi = 0,3.

Struktur NN yang dipergunakan adalah 5-2-1. Operator GA: crossover satu titik, mutasi satu titik, seleksi elitis, crossover rate = 0.8, dan tingkat mutasi = 0.3. Pengujian menghasilkan RMSE = 2,7920; MAD=1,5780; dan MAPE = 0,0580 (5,80%). Grafik hasil pengujian diperlihatkan gambar 4.

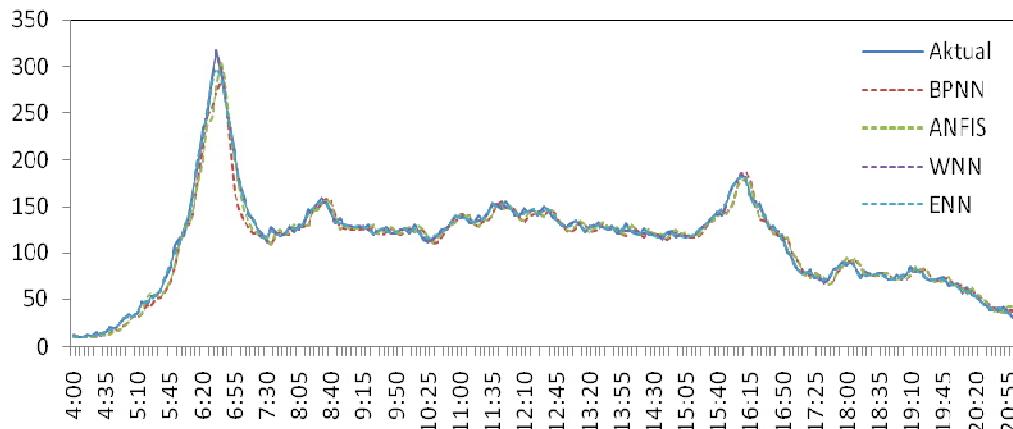


Gambar 4. Grafik hasil pengujian ENN

Nilai RMSE yang dihasilkan oleh algoritma WNN lebih kecil dibandingkan yang lain. Nilai MAPE yang dihasilkan algoritma ENN adalah yang terkecil. Nilai MAD terkecil juga dihasilkan oleh algoritma ENN. Dengan demikian, WNN dan ENN lebih baik dari ANFIS dan BPNN. ENN lebih baik dalam dua parameter dibandingkan WNN.

3.2 Evaluasi dan validasi hasil

Nilai prediksi yang dihasilkan oleh masing-masing algoritma dibandingkan, kemudian masing nilai parameter evaluasi juga dibandingkan. Hasilnya ditunjukkan gambar 5, tabel 9 dan tabel 10.



Gambar 5. Perbandingan hasil prediksi algoritma (4.00-20.55)

Tabel 9. Nilai RMSE, MAPE dan MAD masing masing algoritma

	RMSE			MAD			MAPE					
	BPNN	ANFIS	WNN	BPNN	ANFIS	WNN	BPNN	ANFIS	WNN	ENN		
8,1081	7,6084	3,7207	1,2444	5,2493	5,2095	2,5871	2,0931	15,3893	14,9083	6,5977	4,5495	
8,3353	7,6084	2,2591	3,2864	5,2267	5,2095	2,9394	0,5620	16,1983	14,9083	5,1557	6,6704	
7,8808	7,6084	2,3938	3,8338	5,3394	5,2095	2,1335	1,2933	16,5869	14,9083	5,2426	4,3484	
8,5622	7,6084	2,7375	1,5930	5,5065	5,2095	2,3748	1,7266	15,9977	14,9083	7,7549	5,9717	
7,1793	7,6084	3,3177	3,3998	5,1646	5,2095	1,2212	1,7804	13,5421	14,9083	6,0933	4,7583	
8,0694	7,6084	3,9518	3,9256	5,1986	5,2095	2,6820	1,5873	13,8445	14,9083	7,7853	6,9986	
7,7386	7,6084	3,3343	2,4460	5,3106	5,2095	1,8159	2,7838	15,1769	14,9083	8,7541	7,6862	
9,9519	7,6084	1,4892	1,3167	5,8491	5,2095	2,8208	0,3261	14,0559	14,9083	7,9578	5,4707	
9,0273	7,6084	2,0332	2,4985	5,6230	5,2095	2,8117	0,8940	9,9668	14,9083	6,5053	6,6531	
7,4672	7,6084	2,0967	2,4459	5,0260	5,2095	1,6248	2,9890	14,6300	14,9083	6,1535	4,6230	
7,2111	7,6084	1,8059	2,2259	5,0757	5,2095	1,0047	1,9007	17,9877	14,9083	6,3192	6,2101	
7,8227	7,6084	1,5381	2,9562	5,4770	5,2095	2,0058	2,1547	17,4019	14,9083	8,6596	5,3267	
8,6127	7,6084	2,4218	2,6459	5,3781	5,2095	2,6294	0,4921	17,8599	14,9083	8,1169	7,3217	
7,7152	7,6084	2,9762	1,5306	5,2136	5,2095	1,1616	1,0721	12,4381	14,9083	6,3879	6,5883	
7,3017	7,6084	1,9075	3,8086	5,1726	5,2095	1,1233	2,6440	14,6847	14,9083	8,3175	7,0490	
6,9150	7,6084	3,4710	3,3558	4,9748	5,2095	2,9184	1,8619	12,2132	14,9083	6,3839	7,2498	
7,6747	7,6084	1,7743	3,7851	5,2732	5,2095	1,4640	0,4764	17,4458	14,9083	4,8201	4,4629	
8,1924	7,6084	3,5724	3,5414	5,2745	5,2095	2,6070	0,8217	12,9243	14,9083	4,6090	4,0563	
8,0867	7,6084	3,4444	3,2091	5,3512	5,2095	1,7713	2,5232	16,3651	14,9083	6,2420	4,2407	
Rata-rata	7,9922	7,6084	2,6445	2,7920	5,2992	5,2095	2,0893	1,5780	14,9847	14,9083	6,7293	5,8019
Deviasi Stand.	0,7178	0,0000	0,8026	0,8929	0,2085	0,0000	0,6759	0,8396	2,1655	0,0000	1,2958	1,2250
Maximum	9,9519	7,6084	3,9518	3,9256	5,8491	5,2095	2,9394	2,9890	17,9877	14,9083	8,7541	7,6862
Minimum	6,9150	7,6084	1,4892	1,2444	4,9748	5,2095	1,0047	0,3261	9,9668	14,9083	4,6090	4,0563

Tabel 10. Rekap Nilai RMSE, MAPE dan MAD masing masing algoritma

(rata-rata)	Algoritma			
	BPNN	ANFIS	WNN	ENN
RMSE	7,992	7,6084	2,645	2,792
MAPE	14,98%	8,96%	6,73%	5,80%
MAD	5,299	5,171	2,089	1,578

Pada tabel 10, terlihat bahwa ENN lebih akurat dalam parameter MAPE dan MAD, yaitu 5,80% dan 1,578. Namun WNN memiliki akurasi lebih baik pada parameter RMSE, yaitu 2,645 dan ini lebih kecil dari ENN yang menghasilkan 2,792. Deviasi RMSE WNN juga masih lebih kecil dari ENN. Sementara ANFIS masih memberikan nilai parameter yang masih lebih baik daripada yang dihasilkan BPNN.

4. KESIMPULAN

Berdasarkan hasil penelitian dan pengukuran, dapat disimpulkan:

1. Algoritma ENN adalah algoritma yang memprediksi arus lalu lintas jangka pendek dengan lebih akurat dalam parameter MAPE dan MAD, yaitu 5,80% dan 1,578.
2. Algoritma WNN memberikan akurasi tertinggi dalam parameter RMSE, yaitu 2,645 dan ini lebih kecil dari ENN yang menghasilkan 2,792.
3. Algoritma ANFIS, walaupun bukan yang paling akurat, namun masih lebih baik dari BPNN.

Dengan demikian, algoritma ENN sebagai algoritma berbasis neural network yang memprediksi lebih akurat diharapkan mampu memberikan solusi bagi petugas mengelola arus lalu lintas maupun instansi terkait, serta menjadi metode prediksi arus lalu lintas jangka pendek dalam manajemen arus lalu lintas.

5. SARAN

Analisis dan perbandingan dalam penelitian mengenai arus lalu lintas ini hanya menempatkan akurasi (berdasar nilai error) sebagai faktor uji. Berkaitan dengan itu, beberapa hal perlu disampaikan untuk perbandingan dan pengujian yang lebih baik:

1. Akurasi data sebagai sumber masukan bagi sistem dapat bervariasi (beberapa titik pengamatan) dan dengan jumlah lebih banyak (beberapa hari atau minggu).
2. Perlu pengujian untuk variasi horison prediksi, yaitu lebih dari satu langkah ke depan. Karena sangat memungkinkan bahwa satu metode lebih akurat dalam prediksi satu langkah ke depan, sementara yang lain lebih unggul tiga langkah ke depan.

DAFTAR PUSTAKA

- [1] Jin Wang, Qixin Shi, and Huapu Lu, "The Study of Short-Term Traffic Flow Forecasting Based on Theory of Chaos," *IEEE*, pp. 869-874, December 2005.
- [2] Castro-Neto Manoel, Young-Seon Jeong, Myong-Kee Jeong, and Lee D. Han, "Online-SVR for short-term traffic flow prediction under typical and atypical traffic conditions," *Expert Systems with Applications: An International Journal, Volume 36 Issue 3*, pp. 345-346, 2009.
- [3] Young Jung Yu and Mi-Gyung Cho, "A Short-Term Prediction Model for Forecasting Traffic Information Using Bayesian Network," in *Third 2008 International Conference on Convergence and Hybrid Information Technology*, 2008, pp. 242-247.
- [4] Haowei Su, Ling Zhang, and Shu Yu, "Short-term Traffic Flow Prediction Based on Incremental Support Vector Regression," in *Third International Conference on Natural Computation (ICNC)*, 2007, p. Third International Conference on Natural Computation (ICNC).
- [5] Wang Xinying, Juan Zhicai, Liu Xin, and Mei Fang, "Research on Grid-based Short-term Traffic Flow Forecast Technology," in *2009 International Conference on Computer Engineering and Technology*, 2009, pp. 449-451.
- [6] Tao Ji, Qingle Pang, and Xinyun Liu, "Study of Traffic Flow Forecasting Based on Genetic Neural Network," in *Proceedings of the Sixth International Conference on Intelligent Systems Design and Applications (ISDA'06)*, 2006.
- [7] Yafei Huang, "Short-term Traffic Flow Forecasting Based on Wavelet Network Model Combined with PSO," in *2008 International Conference on Intelligent Computation Technology and Automation*, 2008, pp. 249-253.
- [8] Huang Hongqiong, George F. List, Tang Tianhao, Alixandra Demers, and Wang Tianzhen, "Hybrid Traffic Flow Forecasting Model Based on MRA," in *International Conference on Measuring Technology and Mechatronics Automation*, 2009, pp. 222-225.
- [9] Yung-Chin Lin, Yung-Chien Lin, and Kuo-Lan Su, "Evolutionary Neural Networks for Time Series Prediction," in *Fourth International Conference on Genetic and Evolutionary Computing*, 2010, pp. 219-223.
- [10] Morariu Nicolae, Iancu Eugenia, and Vlad Sorin, "A Neural Network Model For Time-Series Forecasting," *Romanian Journal of Economic Forecasting*, pp. 213-233, April 2009.
- [11] Gang Tong, Chunling Fan, Fengying Cui, and Xiangzhong Meng, "Fuzzy Neural Network Model Applied in the Traffic Flow Prediction," in *Proceedings of the 2006 IEEE International Conference on Information Acquisition*, Weihai, Shandong, China, 2006, pp. 1229 - 1233.
- [12] Guorong Gao and Yanping Liu, "Traffic Flow Forecasting based on PCA and Wavelet Neural Network," in *2010 International Conference of Information Science and Management Engineering*, 2010, pp. 158-161.
- [13] Satker P2JN, "Laporan Ruas Liang Anggang - Martapura," Balai Besar Peningkatan Jalan Nasional IV Kalimantan, Banjarmasin, Annual Report 2006-2011.

- [14] Suraji Aji, Halim Abdul, and Aditya Chandra, Rekayasa Lalu Lintas, 2008, Diktat Kuliah Fakultas Teknik Universitas WidyaGama.
- [15] Philip J. Ross, *Taguchi Techniques For Quality Engineering: Loss Function, Orthogonal Experiments, Parameters and Tolerance Design*, 2nd ed. New York: Mc Graw-Hill Companies, Inc., 1996.
- [16] Carlo Vercellis, *Business Intelligence: Data Mining and Optimization for Decision Making*. Milano, Italy: John Wiley & Sons Ltd, 2009.
- [17] P. V. V. K Theja and Vanajakshi Lelitha, "Short Term Prediction of Traffic Parameters Using Support Vector Machines Technique," in *Third International Conference on Emerging Trends in Engineering and Technology*, 2010, pp. 70-75.
- [18] Phang Ming-bao and Zhao Xin-ping, "Traffic Flow Prediction of Chaos Time Series by Using Subtractive Clustering for Fuzzy Neural Network Modeling," in *Second International Symposium on Intelligent Information Technology Application*, Beijing, 2008, pp. 23-27.
- [19] Pei-Chann Chang and Yen-Wen Wang, "Using Soft Computing Methods for Time Series Forecasting," in *Series on Computers and Operations Research (Vol.6) - Recent Advances in Data Mining of Enterprise Data: Algorithms and Applications*, P.M Pardalos, Ed. Singapore: World Scientific, 2007, ch. 4, pp. 189-246.
- [20] The MathWorks, *Neural Network Toolbox: User's Guide ver.7*, Mark Hudson Beale, Martin T. Hagan, and Howard B Demuth, Eds., 2010.
- [21] Kusumadewi Sri and Hartati Sri, *Neuro-Fuzzy: Integrasi Sistem Fuzzy Dan Jaringan Syaraf*, 2nd ed.: Graha Ilmu, 2010.
- [22] The MathWorks, *Fuzzy Logic Toolbox User's Guide*.: The MathWorks Inc., 2009.
- [23] Suyanto, *Evolutionary Computing: Komputasi Berbasis 'Evolusi' dan 'Genetika'*. Bandung: Informatika, 2008.