

ALGORITMA KOMPUTASI CERDAS UNTUK PREDIKSI JUMLAH PENGGUNA KENDARAAN SEBAGAI INDIKATOR RAWAN MACET

Diana Purwitasari, Gregorius Edward, Tsabbit Aqdami Mukhtar, Joko Lianto Buliali

Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember (ITS)

Jl. Teknik Kimia, Ged. Teknik Informatika, Kampus ITS Sukolilo, Surabaya 60111, Indonesia

Telp: +6231 – 5939214, Fax: +6231 – 5913804

e-mail: diana@if.its.ac.id, joko@cs.its.ac.id

ABSTRAK

Pertumbuhan jumlah kendaraan bermotor yang tinggi menimbulkan permasalahan kemacetan sehingga memerlukan suatu solusi untuk menanganinya. Jalan rawan macet diketahui berdasarkan banyak kendaraan yang lewat dalam rentang waktu tertentu. Bahasan makalah ini adalah penggunaan algoritma komputasi cerdas, multi layer perceptron, k-means dan particle swarm optimization (PSO), untuk melakukan peramalan jalan rawan macet berdasarkan jumlah pengguna jalan. Sumber data diambil dari pengamatan lapangan yang digunakan dalam pembangkitan bilangan acak untuk distribusi uniform, eksponensial dan normal. Prediksi tingkat kepadatan jalan di suatu rentang waktu dengan jaringan saraf menunjukkan hasil lebih baik apabila data pembelajaran juga diambil dari waktu yang sama dengan sejumlah hari sebelumnya (seminggu sampai sebulan). Sedangkan penggunaan k-means+PSO untuk optimasi pengelompokkan jalan berdasarkan kepadatannya membutuhkan data belajar dengan rentang waktu lebih pendek (10 menit di hari kerja untuk mobil dan motor).

Kata Kunci: peramalan jumlah kendaraan, pembangkitan data, multi layer perceptron, regresi linier, k-means, particle swarm optimization.

ABSTRACT

The predicted rapid increase of vehicle numbers leads to a traffic congestion problem that demands a solution. Determining the congestion black spots requires the number of passed road vehicles in certain time periods. This paper will discuss the usage of intelligent computing algorithms like multi layer perceptron and a combination of k-means and particle swarm optimization to predict traffic flow based on vehicle numbers. Collected data from field observations is used to generate more data training that is consistent with some data distributions. We used normal, uniform, and exponential distributions for data distributions. Traffic flow prediction in a certain time period with multi layer perceptron showed better results with data training taken from some days, like a week or a month, before but in the same time period. Mean while optimization in clustering roads that are in the same congested traffic flow needed data training taken from short period of time which was 10 minutes of working days.

Keywords: traffic flow prediction, data generator, multi layer perceptron, linier regression, k-means, particle swarm optimization.

I. PENDAHULUAN

DATA Korps Lalu Lintas Kepolisian Negara Republik Indonesia mencatat kenaikan jumlah kendaraan yang beroperasi sebesar 11 persen pada dua tahun terakhir dengan total kisaran lebih dari 100 juta unit. Rata-rata penjualan mobil di Indonesia sekitar 1 juta unit per tahun sehingga perkiraan pertumbuhan jumlah kendaraan bermotor akan terjadi sekitar 10 persen setiap tahun. Diperlukan suatu solusi untuk menangani permasalahan kemacetan antara lain dengan pengaturan kendaraan pada jalan yang rawan terhadap kemacetan. Solusi yang dapat diambil adalah pengaturan lama lampu lalu lintas agar bekerja dengan optimal atau dengan menempatkan petugas-petugas lalu lintas di waktu dan jalan yang tepat. Agar dapat menentukan jalan rawan macet, banyak kendaraan yang lewat pada suatu jalan dalam rentang waktu tertentu harus diketahui terlebih dahulu.

Pemanfaatan algoritma komputasi cerdas telah banyak digunakan untuk menyelesaikan permasalahan termasuk peramalan jumlah kendaraan [1] [2] [3]. Hasil penelitian-penelitian yang telah dilakukan menunjukkan banyaknya variasi rute alternatif dapat mengurangi terjadinya kemacetan. Bahasan makalah ini adalah penggunaan algoritma komputasi cerdas seperti jaringan saraf tiruan multi layer perceptron, k-means dan particle swarm optimization untuk melakukan peramalan jumlah kendaraan karena memiliki karakteristik jumlah pengguna jalan yang sama berdasarkan data-data sebelumnya [4] [5].

Susunan topik bahasan dalam makalah adalah sebagai berikut dengan awalan mengenai persiapan data belajar. Kemudian diuraikan penggunaan algoritma komputasi cerdas yang digunakan. Bahasan selanjutnya adalah analisa uji coba berdasarkan hasil eksperimen yang telah dilakukan. Berbeda dengan penelitian-penelitian

sebelumnya, pada makalah ini prediksi dilakukan berdasarkan data-data jumlah kendaraan setiap periode jam tertentu.

II. METODE PENELITIAN

A. Persiapan Data Jumlah Kendaraan Rentang Waktu Tertentu untuk Pembelajaran

Sumber data diambil berdasarkan pengamatan lapangan jumlah pengguna jalan di sejumlah jalan Kota Surabaya yang kemudian digunakan dalam pembangkitan bilangan acak sesuai dengan penyebaran distribusi data (nama jalan ditunjukkan Tabel 9 Uji Coba). Sebelum pembangkitan dilakukan perhitungan untuk membuktikan hipotesa distribusi data lapangan terkumpul. Pembangkitkan data ke- i x_i berdasarkan distribusi normal pada Persamaan (1) memerlukan data pengamatan untuk menghitung nilai rata-rata μ dan simpangan σ . Variasi nilai konstanta r_1 dan r_2 antara 0 sampai 1 akan membedakan nilai data pada suatu rentang waktu. Untuk pembangkitkan data distribusi eksponensial menggunakan Persamaan (2) yang membutuhkan satu variasi konstanta r selain nilai rata-rata μ dan Persamaan (3) untuk distribusi uniform yang membutuhkan contoh nilai minimum a dan nilai maksimum b dari data pengamatan.

$$x_{i_normal} = \mu + (\sigma \times \sqrt{-2 \times \log r_1} \times \sin(2 \times \pi \times r_2)) \tag{1}$$

$$x_{i_eksponensial} = -\log(1 - r) \times \mu \tag{2}$$

$$x_{i_uniform} = a + (b - a) \times r \tag{3}$$

Pembangkitan data dilakukan untuk jumlah kendaraan setiap satu menit. Kemudian berdasarkan data yang telah diperoleh dikelompokkan setiap 15 menit sebagai data masukan proses berikut. Pencatatan data lapangan dilakukan di 40 jalan kota Surabaya selama beberapa hari pada jam-jam yang diperkirakan sibuk sehingga menimbulkan kemacetan serta jam saat kondisi jalan lancar sebagai pembanding (sebagai contoh antara jam 08.00-09.00, 10.00-11.00, 14.00-15.00, 18.00-19.00). Tabel 1 menunjukkan model distribusi yang digunakan untuk pembangkitan data di hari libur seperti Sabtu, Minggu atau hari besar. Sebagai contoh, peningkatan jumlah kendaraan secara eksponensial diasumsikan akan sering terjadi pada rentang waktu 06.00-07.00 (pagi), 09.00-10.00 dan 11.00-12.00 (siang).


B. Prediksi Jumlah Kendaraan dengan Multi Layer Perceptron, K-Means dan Particle Swarm Optimization

Algoritma komputasi cerdas pada permasalahan prediksi yang dibahas dalam makalah ini adalah sebagai berikut.

1. Jaringan saraf *Multi Layer Perceptron* untuk klasifikasi jalan menurut tingkat kepadatan [4]
2. Jaringan saraf Regresi Linier untuk prediksi jumlah kendaraan pada rentang waktu tertentu [4]
3. Kombinasi *K-Means* dan *Particle Swarm Optimization* untuk pengelompokkan jalan [5]

TABEL 1
CONTOH PENYEBARAN JUMLAH KENDARAAN DI HARI LIBUR

JAM MULAI	JAM AKHIR	JENIS DISTRIBUSI
03.00	03.59	Uniform
04.00	04.59	Uniform
05.00	05.59	Uniform
06.00	06.59	Eksponensial
07.00	07.59	Normal
08.00	08.59	Uniform
09.00	09.59	Eksponensial
10.00	10.59	Normal
11.00	11.59	Eksponensial



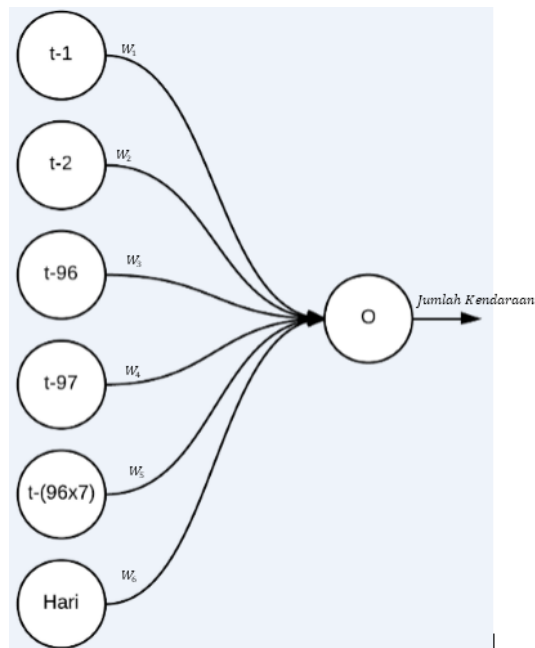
Gambar 1 Contoh model jaringan saraf Multi Layer Perceptron untuk klasifikasi jalan menurut tingkat kepadatan

TABEL 2
CONTOH REPRESENTASI DATA PADA LAPISAN MASUKAN JARINGAN SARAF MULTI LAYER PERCEPTRON

NO	NODE	KETERANGAN
1	Node t-1	Data jumlah kendaraan 1x15 menit sebelum waktu prediksi. Misal dilakukan prediksi jumlah kendaraan untuk Kamis, 15 Januari 2015, 06.30 WIB. Maka data node 1 adalah data jumlah kendaraan pada Kamis, 15 Januari 2015, 06.00-06.14 WIB.
2	Node t-2	Data jumlah kendaraan 2x15 menit sebelum waktu prediksi.
3	Node t-96	Data jumlah kendaraan 96x15 menit sebelum waktu prediksi atau 1 hari sebelum pada jam yang sama. Sesuai dengan contoh data node 1 maka node 3 berisi data jumlah kendaraan pada Rabu, 14 Januari 2015, 06.15-06.29 WIB.
4	Node t-97	Data jumlah kendaraan 96x15 menit sebelum waktu prediksi. Sesuai contoh, data node 4 adalah data jumlah kendaraan pada Rabu, 14 Januari 2015, 06.00-06.14 WIB.
5	Node t-(96x7)	Data jumlah kendaraan seminggu sebelumnya pada jam yang sama. Sesuai contoh, data node 5 berisi data jumlah kendaraan pada 8 Januari 2015, 06.15-06.29 WIB. Sebagai catatan: t-(96x14) dijam dan hari yang sama 2 minggu sebelumnya t-(96x21) dijam dan hari yang sama 3 minggu sebelumnya t-(96x28) dijam dan hari yang sama 4 minggu sebelumnya
6	Node Hari	Jika observasi dilakukan pada hari kerja (Senin, Selasa, Rabu, Kamis, Jumat) maka data node 6 = 0, dan jika dilakukan pada akhir pekan atau hari libur akan bernilai 1.

1) Pemodelan Jaringan saraf Multi Layer Perceptron dan Regresi Linier

Jaringan saraf tiruan *multi layer perceptron* yang digunakan mempunyai satu lapisan masukan (*input layer*), satu lapisan tersembunyi (*hidden layer*), dan satu lapisan keluaran (*output layer*). Jumlah neuron pada *Input Layer* yang digunakan bervariasi dengan maksimal 6 node input (Gambar 1). Penjelasan representasi data Gambar 1 ditunjukkan pada Tabel 2. Sebagai catatan, data yang digunakan adalah total jumlah kendaraan dalam rentang waktu 15 menit. Skenario representasi data pada node input dapat berbeda dengan Tabel 2 seperti contoh model data input sebagai berikut: t-4; t-(96x7); t-(96x14); t-(96x21); t-(96x28).



Gambar 2 Contoh model jaringan saraf Regresi Linier untuk prediksi jumlah kendaraan

gubeng 23	kenjeran 44	ahmadyani 37	basuki rahmat 20	mayjen sungkono 22	dharmahusada 33
----------------------------	------------------------------	-------------------------------	-----------------------------------	-------------------------------------	----------------------------------

Gambar 3 Kelompok jalan sebagai representasi partikel Particle Swarm Optimization

Hidden Layer yang digunakan dalam model prediksi hanya berisi satu layer dengan jumlah node $\#nd_{hidden}$ sesuai dengan Persamaan (4) [6]. Sebagai contoh apabila *Input Layer* memiliki node $\#nd_{in} = 6$ dan node *Output Layer* $\#nd_{out} = 5$ maka jumlah neuron *Hidden Layer* adalah $\#nd_{hidden} = 8$. Hasil luaran adalah lima buah kelas yang menandakan tingkat kepadatan kendaraan (Gambar 1). Kelas 1 berarti kelas jumlah kendaraan yang sangat tidak padat sampai Kelas 5 berarti kelas jumlah kendaraan yang sangat padat.

$$\#nd_{hidden} = \left(\sqrt{\#nd_{in} \times (\#nd_{out} + 2)} \right) + \left(2 \times \sqrt{\frac{\#nd_{in}}{\#nd_{out} + 2}} \right) \tag{4}$$

Terdapat dua jenis bobot pada jaringan saraf multi layer perceptron yaitu w_{ij} yang menghubungkan antara *Input Layer* dan *Hidden Layer* serta w_{jk} yang menghubungkan *Hidden Layer* dan *Output Layer*. Tidak ada *Hidden Layer* pada jaringan saraf tiruan regresi linier dengan satu jenis bobot w_i yang menghubungkan *Input Layer* dan *Output Layer* (Gambar 2). Penjelasan tentang representasi data input model Gambar 2 sama dengan keterangan pada Tabel 2. Inisialisasi bobot antara *Input Layer* menggunakan nilai korelasi antara setiap input dengan output data latihan dibagi dengan total seluruh nilai korelasi.

2) *Pemodelan K-Means dan Particle Swarm Optimization*

Particle Swarm Optimization (PSO) merupakan teknik optimasi pencarian berbasis populasi terinspirasi dari perilaku sosial kelompok kawanan burung atau ikan (sebagai partikel) yang sedang mencari makan (sebagai ruang solusi). Partikel bergerak mengelilingi ruang solusi dan menyesuaikan posisi berdasarkan pengalaman sebelumnya secara bersama-sama sebagai kelompok kawanan (*swarm*). Pada makalah ini representasi partikel adalah jalan yang dikelompokkan menurut kemiripan jumlah pengguna kendaraan (Gambar 3 dengan tiga klaster yaitu *gubeng-basuki rahmat-mayjen sungkono*, *kenjeran-ahmadyani*, dan *dharmahusada*). Terlihat bahwa klaster *gubeng-basuki rahmat-mayjen sungkono* memiliki jumlah pengguna kendaraan yang hampir sama jika dibanding dengan klaster *kenjeran-ahmadyani*. Untuk mendapatkan model partikel tersebut dibutuhkan data jalan dan jumlah penggunaanya. Pencatatan data lapangan dan pembangkitan data dilakukan dengan cara yang sama seperti model jaringan saraf tiruan multi layer perceptron di bahasan sebelumnya.

Algoritma PSO+K-Means [1] yang digunakan dalam permasalahan pengelompokkan jalan adalah sebagai berikut.

1. - Inisialisasi parameter PSO: partikel p_i dalam *swarm* (contoh ditunjukkan pada Gambar 3), nilai posisi $y_i^{t=0}$ dan kecepatan $v_i^{t=0}$ setiap partikel secara random.
 - Inisialisasi parameter K-Means: jumlah kluster k_i setiap partikel p_i secara random antara 5-10 (contoh Gambar 3 memiliki jumlah kluster $k_i = 3$ jadi $cl_{i1}, cl_{i2}, cl_{i3}$);
 Apabila contoh partikel pada Gambar 3 disebut dengan p_1 maka
 $p_{1j\text{jalan}} = [\text{gubeng, kenjeran, ..., dharmahusada}]_{1 \times 6}^T$; nilai $p_{1j\text{pengguna}} = [23, 44, ..., 33]_{1 \times 6}^T$
 Data anggota kluster $\{\text{gubeng} - \text{basuki rahmat} - \text{mayjen sungkono}\} \in cl_{i1}$
 Terdapat 40 jalan data pengamatan sehingga ukuran vektor jalan partikel p_i adalah 40×1
 - Tentukan jalan sebagai anggota kluster tertentu secara random pada setiap partikel p_i

2. Tentukan partikel p_i sebagai partikel terbaik lokal p_{best} dan partikel terbaik global g_{best} menggunakan fungsi objektif Davies-Bouldin Index (DB Index) yang memperhitungkan kualitas hasil pengklasteran dilihat dari kuantitas dan kedekatan antar data hasil (Persamaan (5) dan Persamaan (6)).

$$f(p_i) = DB_{index} = \frac{1}{k_i} \sum_{a=1}^{k_i} \max_{a \neq b} d_{ab}$$
 adalah fungsi objektif partikel p_i (5)

$$d_{ab} = \frac{\bar{d}_a + \bar{d}_b}{dist_{ab}}$$
 dengan \bar{d}_a = rerata selisih nilai pengguna jalan j anggota kluster a (6)
 dengan titik pusatnya; $dist_{ab}$ = selisih nilai titik tengah kluster a dengan titik tengah kluster b
 Pada saat $iter_0$, partikel dengan nilai $f(p_i)$ terkecil dari semua partikel p_i menjadi p_{best} dan juga nilai g_{best} .
 Pada saat $iter_1$, akan dihitung ulang $f(p_i)$ karena posisi dan kecepatan partikel p_i berubah. Partikel dengan nilai $f(p_i)$ terkecil menjadi p_{best} dan apabila nilai tersebut lebih kecil daripada $f(g_{best})$ maka terjadi perubahan partikel yang menjadi g_{best} .

3. Lakukan perulangan sampai iterasi $iter_t$
 - a. Hitung kecepatan partikel p_i untuk iterasi berikut $iter_{t+1}$ dengan Persamaan (7)

$$v_i^{t+1} = w \times v_i^t + c_1 \times rand() \times (-1 - y_i^t) + c_2 \times rand() \times (1 - y_i^t)$$
 (7)
 - b. Hitung posisi partikel p_i untuk iterasi berikut $iter_{t+1}$ dengan Persamaan (8)

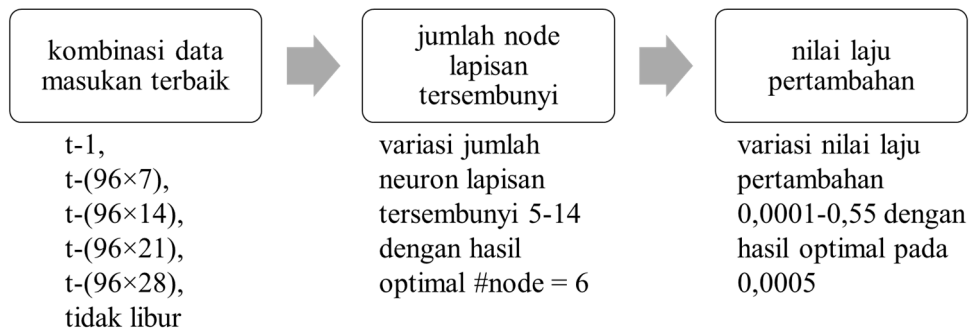
$$y_i^{t+1} = y_i^t + v_i^{t+1}$$
 (8)
 - c. Tentukan partikel p_i sebagai partikel terbaik lokal p_{best} dan partikel terbaik global g_{best} (hitung sesuai dengan Langkah 2)
 - d. Klasterisasi jalan di partikel p_{best} sesuai dengan nilai k_i ; ukuran kedekatan untuk mengelompokkan adalah jumlah pengguna jalan

$$\sqrt{\sum_{j=1}^n (x_{aj} - x_{bj})^2}$$
 dengan x_{aj} = nilai pengguna jalan j anggota kluster a
 Simpan partikel p_{best} sebagai solusi terbaik sementara sampai ditemukan solusi lain selama kondisi $iter_t$ masih terjadi.

III. UJI COBA DAN ANALISA

A. Uji coba klasifikasi jalan menurut tingkat kepadatan dan prediksi jumlah kendaraan

Gambar 4 menunjukkan skenario penentuan parameter yang dapat mempengaruhi akurasi klasifikasi tingkat kepadatan jalan. Pengujian diawali dengan mencoba kombinasi data masukan, kemudian mendapatkan jumlah neuron paling optimal pada *Hidden Layer* dan nilai laju pembelajaran terbaik (Tabel 3). Model kombinasi data masukan dengan % kesalahan terkecil adalah skenario 2 yang berarti prediksi tingkat kepadatan sebaiknya dilakukan dengan sebanyak mungkin data pembelajaran diambil pada jam sama hari berbeda (seminggu yaitu data t-(96×7) sampai satu bulan sebelum yaitu data t-(96×28)) (Tabel 4). Variasi uji coba pada node ke-6 *Input Layer* untuk mengetahui pengaruh hari libur tidak menunjukkan perbedaan yang signifikan dengan selisih nilai < 0,4%. Uji coba selanjutnya menggunakan *Input Layer* skenario 2 untuk mendapatkan jumlah node *Hidden Layer*. Hasil uji coba menunjukkan bahwa model jaringan optimal dengan % kesalahan terkecil memiliki enam buah node pada *Hidden Layer*. Kemudian model skenario 2 dan 6 node pada *Hidden Layer* digunakan untuk mendapatkan nilai laju pertambahan optimal yaitu 0,0005.



Gambar 4 Rekomendasi model jaringan saraf multi layer perceptron

TABEL 3
KOMBINASI DATA MASUKAN

KOMBINASI	NODE KE-1	NODE KE-2	NODE KE-3	NODE KE-4	NODE KE-5
1	t-1	t-2	t-3	t-4	t-5
2	t-1	t-(96×7)	t-(96×14)	t-(96×21)	t-(96×28)
3	t-1	t-2	t-3	t-96	t-97
4	t-96	t-(96×7)	t-(96×14)	t-(96×21)	t-(96×28)
5	t-1	t-2	t-96	t-97	t-(96×7)
6	t-1	t-2	t-3	t-(96×7)	t-(96×14)
7	t-1	t-2	t-96	t-(96×7)	t-(96×14)
8	t-1	t-2	t-3	t-4	t-96
9	t-2	t-(96×7)	t-(96×14)	t-(96×21)	t-(96×28)
10	t-4	t-(96×7)	t-(96×14)	t-(96×21)	t-(96×28)

TABEL 4
HASIL PENGUJIAN KOMBINASI DATA MASUKAN PADA MODEL JARINGAN SARAF

KOMBINASI	% PREDIKSI SALAH (PENGARUH HARI LIBUR)			
	MULTI LAYER PERCEPTRON		REGRESI LINIER	
	YA	TIDAK	YA	TIDAK
1	20,47	20,46	13,99	13,90
2	11,65	11,65	7,03	7,05
3	17,14	16,88	11,68	11,50
4	11,87	11,87	7,03	6,99
5	13,12	13,04	8,89	8,84
6	12,51	12,47	7,75	7,73
7	12,51	12,49	7,88	7,84
8	19,39	19,01	11,35	11,16
9	11,80	11,76	7,03	7,05
10	12,55	12,56	6,93	6,93

Pengujian pada jaringan saraf regresi linier menghasilkan model kombinasi data masukan dengan % kesalahan terkecil adalah skenario 10 (Tabel 4), Skenario tersebut juga dilakukan dengan sebanyak mungkin data pembelajaran diambil pada jam sama hari berbeda (seminggu sampai satu bulan sebelum), Kesalahan klasifikasi dihitung dengan membandingkan kesesuaian label kelas kepadatan, Namun untuk regresi linier, kesalahan luaran hasil dihitung dengan *Mean Absolute Percentage Error* (MAPE) Persamaan (9) berdasarkan nilai hasil *pengamatan* A_t dan *luaran* F_t jaringan saraf tiruan regresi linier, Untuk model jaringan saraf tiruan regresi linier, uji coba laju pembelajaran 0,0001-0,15 menunjukkan hasil yang tidak signifikan sehingga laju pembelajaran terpilih adalah 0,5,

$$Error = \frac{100 \%}{n \text{ data}} \sum_{t=1}^{n \text{ data}} \frac{|pengamatan A_t - luaran F_t|}{pengamatan A_t} \tag{9}$$

Pada Tabel 5 ditunjukkan prediksi kesalahan hasil luaran model jaringan saraf yang optimal untuk data berbeda, Data pembelajaran adalah data yang digunakan untuk membangun model tersebut sedangkan data pengujian adalah data yang berbeda, Terlihat model jaringan sudah stabil sehingga tidak menunjukkan selisih prediksi salah, Untuk kedua jaringan saraf tiruan, secara umum semakin kecil nilai laju pembelajaran memberikan hasil yang semakin baik namun dengan batasan tertentu,

B. Uji coba pengelompokkan jalan

Uji coba parameter PSO konstanta w , konstanta c_1 dan konstanta c_2 dilakukan untuk menentukan kombinasi nilai yang menghasilkan luaran optimal dalam menentukan posisi baru partikel (Persamaan (7)) dengan batasan nilai $c_1 + c_2 = 1,0$ (Tabel 6), Luaran optimal memiliki nilai fungsi objektif DB_{index} kecil, Satu kombinasi nilai akan diuji sebanyak 50x dikarenakan adanya unsur random saat menentukan posisi baru partikel, Hasil uji coba kombinasi konstanta c_1 dan konstanta c_2 ditunjukkan pada Tabel 6 dan konstanta w pada Tabel 7 sehingga Persamaan (7) menjadi Persamaan (10), Untuk uji coba berikut menentukan posisi baru partikel akan menggunakan Persamaan (10),

$$v_i^{t+1} = 0,53 \times v_i^t + 0,24 \times rand() \times (-1 - y_i^t) + 0,76 \times rand() \times (1 - y_i^t) \tag{10}$$

TABEL 5
PREDIKSI KESALAHAN HASIL MODEL JARINGAN SARAF

METODE	PENGARUH HARI LIBUR DATA PEMBELAJARAN		PENGARUH HARI LIBUR DATA PENGUJIAN	
	YA	TIDAK	YA	TIDAK
Multi Layer Perceptron t-1; t-(96×7); t-(96×14); t-(96×21); t-(96×28)	11,65%	11,65%	11,74%	11,73%
Regresi Linier t-4; t-(96×7); t-(96×14); t-(96×21); t-(96×28)	6,93%	6,93%	6,93%	6,93%

TABEL 6,
HASIL FUNGSI OBJEKTIF DENGAN KOMBINASI KONSTANTA c_1 DAN KONSTANTA c_2

NO	KONSTANTA c_1	KONSTANTA c_2	FUNGSI OBJEKTIF DB_{index}
1	0,08	0,92	0,116
2	0,18	0,82	0,124
3	0,24	0,76	0,105
4	0,25	0,75	0,132
5	0,33	0,67	0,123
6	0,56	0,44	0,137
7	0,62	0,38	0,124

TABEL 7,
HASIL FUNGSI OBJEKTIF DENGAN KOMBINASI KONSTANTA w

NO	KONSTANTA w	FUNGSI OBJEKTIF DB_{index}
1	0,12	0,076
2	0,24	0,069
3	0,42	0,062
4	0,53	0,061
5	0,65	0,072
6	0,74	0,070

7	0,91	0,084
---	------	-------

TABEL 8,
HASIL FUNGSI OBJEKTIF DENGAN PENGAMATAN HARI BERBEDA

SKENARIO	WAKTU (HARI LIBUR)	MOBIL #KLASTER, DB		MOTOR #KLASTER, DB		WAKTU (HARI EFEKTIF)		MOBIL #KLASTER, DB		MOTOR #KLASTER, DB	
Pagi	06.00-07.00	9	0,103	5	0,113	10.10-10.20	8	0,06	6	0,04	
Siang	12.00-13.00	7	0,133	5	0,091	13.10-13.20	5	0,07	9	0,05	
Sore	18.00-19.00	9	0,081	9	0,123	16.20-16.30	8	0,09	6	0,09	
Malam	22.30-23.30	7	0,083	8	0,103	20.10-20.20	6	0,08	6	0,11	

TABEL 9,
HASIL PENGELOMPOKKAN JALAN DARI LUARAN OPTIMAL (DATA HARI EFEKTIF, PAGI)

NO	DATA HARI EFEKTIF, PAGI, MOBIL	DATA HARI EFEKTIF, PAGI, MOTOR
1	<i>Ahmadyani, Basuki Rahmat</i>	Basuki Rahmat
2	Darmo	Darmo
3	Indrapura, Nginden	Indrapura
4	Arjuno, Deles, Jagir Wonokromo, Jemursari, Kedungcowek, Kertajaya, Kusuma Bangsa, Mayjen Sungkono, Menganti, Prof,Dr,Mestopo, Rajawali	Arjuno, Deles, Jagir Wonokromo, Jemursari, Kedungcowek, Kertajaya, Kusuma Bangsa, Manyar Kertoarjo, <i>Mastrip</i> , Menganti, <i>Nginden</i> , Rajawali
5	Ir,Soekarno, Kalimas Barat, Kembang Jepun, Ketintang, <i>Manyar Kertoarjo, Mastrip</i> , Mercon Jimerto, Mulyosari, Mulyorejo, Ngagel, Raya Menur, Rungkut Industri	Ahmadyani, Arief Rahman Hakim, Ir,Soekarno, Kalimas Barat, Kembang Jepun, Kenjeran, Ketintang, Mayjen Sungkono, <i>Menganti Lidah Kulon</i> , Mercon Jimerto, Mulyosari, Mulyorejo, Ngagel, Raya Menur, Rungkut Industri
6	Arief Rahman Hakim, <i>Kapasari</i> , Kenjeran, <i>Raya Dupak, Raya ITS</i>	
7	Ambengan, Kalianyar, Randu, Tambaksari	Ambengan, Bulak Banteng, Dharmahusada,
8	Bulak Banteng, Dharmahusada, <i>Menganti Lidah Kulon</i>	Kalianyar, Kapasari, Prof,Dr,Mestopo, Randu, Raya Dupak, Raya ITS, Tambaksari

Uji coba berikutnya menggunakan data yang dibangkitkan dari data lapangan saat hari libur dan hari kerja yang dibedakan dari jenis kendaraan: mobil-motor, Variasi data juga ditentukan dari rentang waktu yang digunakan, Untuk data hari libur menggunakan rentang waktu 60 menit sedangkan hari kerja menggunakan 10 menit, Hasil uji coba dengan data-data tersebut ditunjukkan pada Tabel 8, Kelompok jalan yang dihasilkan dari data hari libur dengan pengguna mobil tidak sama dengan pengguna motor, Sedangkan data hari efektif pagi (10.10-10.20) lebih menunjukkan adanya kesamaan kelompok dari hasil PSO yang optimal (Tabel 9 dengan jalan yang berbeda kelompok ditulis miring), Hal tersebut disebabkan pengambilan data dengan rentang waktu pendek yaitu 10 menit,

IV. SIMPULAN

Makalah ini telah membahas tentang pemanfaatan algoritma komputasi cerdas untuk prediksi jalan berdasarkan tingkat kepadatannya yang diketahui dari banyaknya pengguna jalan dengan mobil dan motor pada rentang waktu tertentu, Selain itu dengan data yang sama telah dilakukan prediksi jumlah pengguna dan mengelompokkan jalan tersebut berdasarkan keramaiannya, Prediksi tingkat kepadatan jalan di suatu rentang waktu dengan jaringan saraf menunjukkan hasil lebih baik apabila data pembelajaran juga diambil dari waktu yang sama dengan sejumlah hari sebelumnya (seminggu sampai sebulan), Sedangkan penggunaan K-Means+PSO untuk optimasi pengelompokkan jalan berdasarkan kepadatannya membutuhkan data belajar dengan rentang waktu lebih pendek (10 menit di hari kerja untuk mobil dan motor),

DAFTAR PUSTAKA

- [1] Y. Kao and S.-Y. Lee, "Combining K-means and particle swarm optimization for dynamic data clustering problems," in *IEEE International Conference on Intelligent Computing and Intelligent Systems*, Shanghai, 2009.
- [2] V. Topuz, "Hourly Traffic Flow Prediction Using Different ANN Models," in *Urban Transport and Hybrid Vehicles*, InTech, 2010.
- [3] R. Luthfianto, I. Santoso and Y. Christyono, "Peramalan Jumlah Penumpang Kereta Api dDengan Jaringan Saraf Tiruan Metode Perambatan Balik (Back Propagation)," T. Elektro, Fak. Teknik, Universitas Diponegoro (Tugas Akhir), Semarang, 2011.
- [4] G. Edwadr, "Peramalan Jumlah Kendaraan di Jalan Raya Menggunakan Jaringan Saraf Tiruan Multi Layer Perceptron dengan dan tanpa Regresi Linier," Teknik Informatika, Institut Teknologi Sepuluh Nopember (skripsi tidak diterbitkan), Surabaya, 2014.
- [5] T. A. Mukhtar, "Implementasi Dynamic Cluster Menggunakan Metode K-Means Cluster dan Particle Swarm Optimization untuk Identifikasi Karakteristik Lalu Lintas Berdasarkan Jumlah dan Jenis Kendaraan," Teknik Informatika, Institut Teknologi Sepuluh Nopember (skripsi tidak diterbitkan), Surabaya, 2014.
- [6] D. Stathakis, "How many hidden layers and nodes?," *Int. J. Remote Sens.*, vol. 30, no. 8, pp. 2133-2147, 2009.