

# Identifikasi Parameter Koefisien Gesek Memakai Metode Jaringan Saraf Tiruan Untuk Kontrol Dinamika Kendaraan

Midriem Mirdanies

P2 Tenaga Listrik dan Mekatronik – LIPI,  
midr001@lipi.go.id

Estiko Rijanto

P2 Tenaga Listrik dan Mekatronik – LIPI,  
estiko.rijanto@lipi.go.id

## Abstract

*Dynamical control of vehicle in order to stabilize its maneuver depends on the friction force between tire and road surface. In this paper it will be described a parameter identification method of a non-linear model using backpropagation, which is one method in an artificial neural network (ANN). The non-linear model used in this paper is friction coefficient between tire and road surface, in which it has two parameters that should be defined. The ANN architecture used in this paper has one input, one hidden layer and one output. Computer simulation has been done using GNU Octave software for three road conditions: slippery road, wet road and dry road. From the simulation results the two parameter values have been obtained so that the equation of friction coefficient on the slip road is  $\mu = 0.4 \sin(1,5761 \cdot \tan^{-1}(10,901.s))$ , on the wet road is  $\mu = 0.6 \sin(1,6443 \cdot \tan^{-1}(9,5941.s))$  and on the dry road is  $\mu = 0.9 \sin(-1,6354 \cdot \tan^{-1}(-10,279.s))$ .*

**Keywords:** *parameter identification, friction coefficient, artificial neural network (ANN), dynamical control, vehicle, backpropagation, gnu octave*

## Abstrak

*Pengendalian dinamika kendaraan agar lebih stabil saat bermanuver tergantung pada gaya gesek antara roda kendaraan dan permukaan jalan. Pada tulisan ini disajikan sebuah aplikasi metode identifikasi parameter model non-linear menggunakan metode backpropagation yang merupakan salah satu metode pada jaringan saraf tiruan (JST). Model pada tulisan ini adalah model koefisien gaya gesek antara roda kendaraan dan permukaan jalan yang memiliki dua buah parameter yang nilainya perlu ditentukan. Pendekatan metode jaringan saraf tiruan yang digunakan pada tulisan ini memiliki satu masukan, satu lapisan tersembunyi (hidden layer), dan satu keluaran. Simulasi komputer telah dilakukan menggunakan perangkat lunak GNU Octave terhadap tiga kondisi jalan yaitu kondisi jalan licin, kondisi jalan aspal basah, dan kondisi jalan aspal kering. Dari hasil simulasi telah diperoleh nilai dua parameter tersebut sehingga persamaan koefisien gesekan pada jalan licin menjadi:  $\mu = 0.4 \sin(1,5761 \cdot \tan^{-1}(10,901.s))$ , pada jalan aspal basah:  $\mu = 0.6 \sin(1,6443 \cdot \tan^{-1}(9,5941.s))$  dan pada jalan aspal kering:  $\mu = 0.9 \sin(-1,6354 \cdot \tan^{-1}(-10,279.s))$ .*

**Kata kunci:** *identifikasi parameter, koefisien gesek, jaringan saraf tiruan (JST), kontrol dinamika, kendaraan, backpropagation, gnu octave*

## 1. Pendahuluan

Analisis dinamika kendaraan dan perancangan kontroler dinamika kendaraan memerlukan sebuah model kendaraan. Model kendaraan ini biasanya sangat kompleks karena meliputi model penggerak

mula, transmisi, gaya traksi longitudinal, gaya normal dan gaya yaw. Model ini terbentuk dari model dinamika yang didalamnya mengandung model statik. Salah satu komponen model statik yang berperan sangat penting adalah gaya gesek antara roda

kendaraan dengan permukaan jalan. Berdasarkan hasil penelitian H.J. Hong dan H.Y Jo telah diketahui persamaan koefisien gesekan beberapa kondisi jalan [1], namun masih belum diketahui nilai kedua parameter yang digunakan sehingga diperlukan identifikasi parameter untuk menentukan kedua parameter pada persamaan tersebut.

Metode optimasi konvensional yang sering digunakan untuk identifikasi parameter pada sebuah model adalah *Least Mean Square* (LMS) [2]. Metode LMS ini telah banyak digunakan di industri, misalnya dipakai untuk menentukan parameter model dinamika proses perpindahan panas pada proses kimia [3]. LMS juga telah digunakan untuk menentukan koefisien gesek roda kendaraan dengan permukaan jalan, namun hanya pada zona linier [4].

Metode LMS memiliki keterbatasan yaitu hanya dapat diaplikasikan setelah ditentukan struktur model terlebih dahulu, dan nilai parameter yang diperoleh mengandung bias, kecuali jika dua kondisi berikut dipenuhi yaitu matriks kovarian dari vektor regresi memiliki matriks inverse, dan derau pengukuran berupa *zero mean white noise*. Metode pemodelan yang relatif lebih baru adalah aplikasi metode Jaringan Saraf Tiruan (JST). Aplikasi JST pada saat ini telah merambah banyak bidang. Misalnya, pada bidang pertahanan, elektronika, keuangan, manufaktur dan lain-lain [5]. Proses optimasi *backpropagation* pada JST juga memakai *mean square error* (MSE) sebagai indeks kinerja [6]. Keunggulan JST jika dibandingkan dengan LMS adalah bahwa JST juga dapat diaplikasikan tanpa harus menentukan struktur model terlebih dahulu.

Dalam penelitian ini dibuat sebuah algoritma yang mengaplikasikan metode JST menggunakan struktur algoritma *backpropagation* untuk identifikasi 2 buah parameter yang belum diketahui pada suatu model non-linear yaitu koefisien gesekan antara roda kendaraan dan permukaan jalan, serta dibuat simulasi komputer dari algoritma tersebut pada bahasa pemrograman GNU Octave.

## 2. Metodologi Penelitian

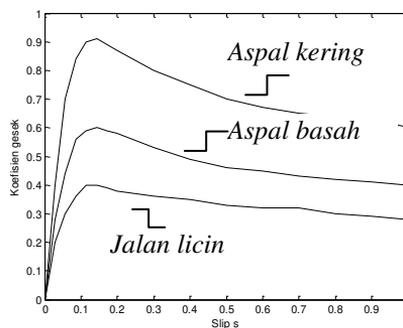
Nilai parameter yang diidentifikasi dalam penelitian ini yaitu parameter B dan C pada persamaan (1) dengan menggunakan algoritma *backpropagation*.

Pada penelitian ini dilakukan juga simulasi dan analisis data, serta perbandingan kinerja hasil identifikasi parameter dilakukan menggunakan algoritma *backpropagation* dengan metode LMS.

Tahapan yang dilakukan dalam penelitian ini yaitu studi model koefisien gesekan antara roda kendaraan dan permukaan jalan yang telah diperoleh dari hasil penelitian sebelumnya [1], memetakan model tersebut ke dalam struktur algoritma *backpropagation* sehingga dapat diidentifikasi nilai parameter B dan C yang belum diketahui, simulasi dan analisis data, serta membandingkan hasil yang diperoleh menggunakan algoritma *backpropagation* dengan hasil yang diperoleh menggunakan metode LMS.

### 2.1 Model koefisien gesek roda Kendaraan

Gambar 1 menunjukkan hasil yang diperoleh dari penelitian sebelumnya [1], Garis pada gambar 1 secara berurutan menunjukkan koefisien gesekan pada jalan licin, jalan aspal basah, dan jalan aspal kering. Sumbu horizontal menunjukkan Slip  $s$  dan sumbu vertikal menunjukkan koefisien gesekan  $\mu$  serta titik puncak/nilai maksimal koefisien gesekan dilambangkan dengan  $\mu_0$ .



Gambar 1 Koefisien Gesekan [1]

Diagram pada Gambar 1 dapat diekspresikan dengan fungsi berikut [1].

$$\mu = \mu_0 \sin(C.\tan^{-1}(Bs)) \quad (1)$$

dimana  $\mu$  adalah koefisien gesek;  $\mu_0$  adalah nilai maksimum koefisien gesek;  $s$  adalah slip; dan  $B$  dan  $C$  adalah parameter yang nilainya dicari.

Pada Gambar 1 diketahui bahwa koefisien gesek  $\mu$  terus bertambah sebagaimana kenaikan slip 10-20 % hingga mencapai nilai maksimum  $\mu_0$ , selanjutnya akan menurun sesuai dengan penambahan slip. Nilai maksimum koefisien gesekan  $\mu_0$  dapat dihitung jika nilai  $\mu$  dan  $s$ , serta koefisien  $C$  dan  $B$  diketahui, seperti persamaan berikut [1].

$$\mu_0 = \frac{\mu}{\sin(C.\tan^{-1}(Bs))} \quad (2)$$

Koefisien gesek  $\mu$  merupakan perbandingan dari gaya longitudinal ban  $F_{LG}$  dengan gaya normal ban  $F_N$  seperti berikut [1].

$$\mu = \frac{F_{LG}}{F_N} \quad (3)$$

Sedangkan longitudinal slip  $s$  didefinisikan oleh kecepatan longitudinal mobil  $v$  dan kecepatan rotasi roda  $\omega_w$  yaitu sebagai berikut [1].

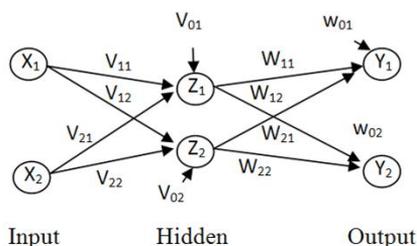
$$s = \frac{v - r\omega_w}{\max(v, r\omega_w)} \quad (4)$$

Dimana  $r$  adalah jari-jari ban.

## 2.2 Tahapan Identifikasi Parameter B dan C Menggunakan Algoritma Backpropagation

Arsitektur jaringan *backpropagation* yang terdiri dari 2 unit *input*, 1 lapisan tersembunyi yang terdiri dari 2 unit, dan 2 unit *output* ditunjukkan pada Gambar 2. Algoritmanya adalah sebagai berikut.

- Inisialisasi bobot (ambil bobot awal dengan nilai random yang cukup kecil)
- Kerjakan langkah-langkah berikut selama kondisi berhenti bernilai FALSE



Gambar 2 Arsitektur jaringan *backpropagation*

### Feedforward:

$$\begin{aligned} (x_i, i = 1, 2, 3, \dots, n) \\ (z_j, j = 1, 2, 3, \dots, p) \\ (y_k, k = 1, 2, 3, \dots, m) \end{aligned}$$

$$z\_in_j = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (5)$$

$$z_j = f(z\_in_j)$$

$$y\_in_k = w_{0k} + \sum_{j=1}^p z_j w_{jk}$$

$$y_k = f(y\_in_k)$$

### Backpropagation:

$$\delta_k = (t_k - y_k) f'(y\_in_k)$$

$$\Delta w_{jk} = \alpha \delta_k z_j$$

$$\Delta w_{0k} = \alpha \delta_k$$

$$\delta\_in_j = \sum_{k=1}^m \delta_k w_{jk}$$

$$\delta_j = \delta\_in_j f'(z\_in_j)$$

$$\Delta v_{ij} = \alpha \delta_j x_i$$

$$\Delta v_{0j} = \alpha \delta_j$$

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk}$$

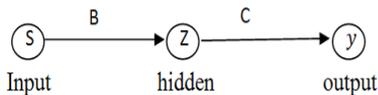
$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (6)$$

c. Tes kondisi berhenti

Dimana  $x_i$  adalah data masukan,  $z_j$  adalah data pada unit tersembunyi,  $y_k$  adalah data pada unit *output*,  $z\_in_j$  adalah data yang masuk ke unit tersembunyi,  $y\_in_k$  adalah data yang masuk ke unit *output*,  $\delta_k$  adalah informasi error pada lapisan *output*,  $\Delta w_{jk}$  adalah koreksi bobot yang akan digunakan untuk memperbaiki nilai  $w$ ,  $\Delta w_{0k}$  adalah koreksi bias yang akan digunakan untuk memperbaiki nilai  $w_0$ ,  $\delta\_in_j$  adalah

informasi error yang masuk ke unit tersembunyi,  $\delta_j$  adalah informasi error pada lapisan tersembunyi,  $\Delta v_{ij}$  adalah koreksi bobot yang akan digunakan untuk memperbaiki nilai  $v$ ,  $\Delta v_{oj}$  adalah koreksi bias yang akan digunakan untuk memperbaiki nilai  $v_0$

Persamaan (1) selanjutnya dipetakan sehingga sesuai dengan struktur algoritma *backpropagation*. Karena nilai parameter yang dicari berjumlah 2 buah, maka arsitektur jaringan diubah sehingga terdiri dari 1 unit *input*, 1 lapisan tersembunyi (1 unit) dan 1 unit *output*, seperti pada Gambar 3.



**Gambar 3. Arsitektur jaringan *backpropagation* hasil pemetaan dari persamaan (1)**

Fungsi aktivasi yang digunakan terdiri dari:

5 Fungsi aktivasi pada *hidden layer*:

$$f(z\_in) = \tan^{-1}(z\_in)$$

6 Fungsi aktivasi pada *output layer*:

$$f(y\_in) = \mu_0 \sin(y\_in)$$

Arsitektur *backpropagation* sesuai dengan Gambar 3, selanjutnya dibuat algoritmanya dan disimulasikan menggunakan bahasa pemrograman GNU Octave. *Source code*-nya adalah sebagai berikut.

```

z_in = B*S(i);
z = atan(z_in);
y_in = C*z;
y = miu0*sin(y_in);
err = t(i) - y;
jmlErr = jmlErr + err^2;
slshError = (t(i)-y)*(miu0*cos(y_in));
deltaC = lr *slshError*z;
slshErrorIn = slshError * C;
slshError2 = slshErrorIn*(1/(1+z_in^2));
deltaB = lr*slshError2*x(i);
B = B + deltaB;
C = C + deltaC;
  
```

Dimana S adalah data masukan (slip s), Z adalah data pada unit tersembunyi, Y adalah data pada unit *output* (koefisien gesek  $\mu$ ),  $\mu_0$  adalah nilai maksimum ( $\mu_0$ ),  $z\_in$  adalah data yang masuk ke unit tersembunyi,  $y\_in$  adalah data yang masuk ke unit *output*,  $slshError$  adalah informasi error pada lapisan *output*,  $\delta C$  adalah koreksi bobot yang akan digunakan untuk memperbaiki nilai C,  $slshErrorIn$  adalah informasi error yang masuk ke unit tersembunyi,  $slshError2$  adalah informasi error pada lapisan tersembunyi,  $\delta B$  adalah koreksi bobot yang akan digunakan untuk memperbaiki nilai B,  $jmlErr$  adalah nilai jumlah kuadrat errornya

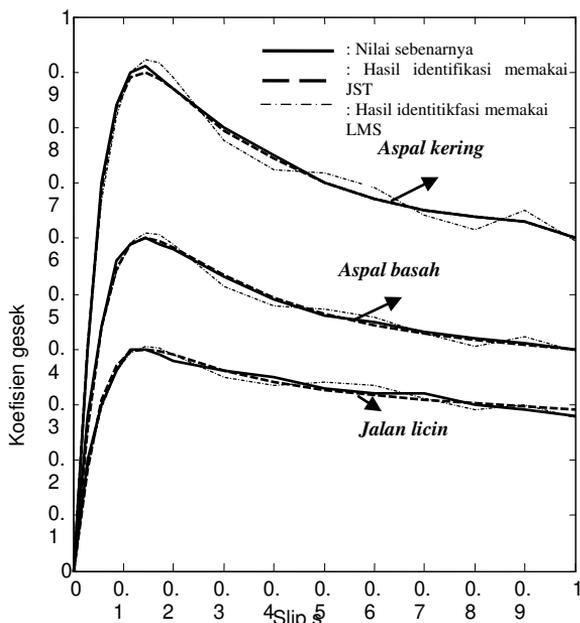
Data  $\mu$ ,  $\mu_0$ , dan s yang digunakan pada penelitian ini diambil dari data hasil penelitian H.J. Hong dan H.Y Jo [1] seperti pada Gambar 1. Data yang diperoleh selanjutnya disimulasikan menggunakan komputer dengan spesifikasi, Processor AMD Turion (tm) 64 Mobile Technology MK-38, MMX, 3DNow, ~2,2GHz. Memory 958MB RAM. VGA Card ATI Radeon Xpress 1100, 256MB (Share).

### 3 Hasil dan Pembahasan

Simulasi telah dilakukan dengan  $\alpha = 1$  toleransi error = 0,0011 untuk jalan licin (bersalju), jalan aspal basah dan aspal kering, sehingga diperoleh hasil seperti pada Gambar 4. Sebagai perbandingan telah dilakukan juga identifikasi parameter menggunakan metode LMS konvensional dengan mengasumsikan model berupa polinomial non-linier orde 6.

Pada Gambar 4, diagram dengan garis solid adalah nilai sebenarnya, diagram dengan garis putus-putus adalah hasil identifikasi menggunakan metode *backpropagation*, sedangkan diagram dengan garis terputus ber-titik yang tipis adalah hasil menggunakan metode LMS konvensional. Dari Gambar 4 dapat dilihat secara visual bahwa hasil dengan metode *backpropagation* lebih mendekati nilai sebenarnya dibandingkan hasil identifikasi menggunakan metode LMS. Dari hasil

identifikasi menggunakan metode backpropagation dapat diketahui nilai-nilai parameternya seperti yang ditunjukkan pada Tabel 1.



Gambar 4. Hasil Simulasi pada kondisi jalan licin, aspal basah dan aspal kering

Tabel 1 Nilai parameter hasil identifikasi

Kondisi Jalan	B	C
Licin	10,901	1,5761
Aspal basah	9,5941	1,6443
Aspal kering	-10,279	-1,6354

Sedangkan jumlah iterasi dan waktu proses yang diperlukan (satuan: detik) dengan Toleransi *Error (Integrated Absolute Error (IAE))* = 0,0011 adalah seperti ditunjukkan pada Tabel 2.

Tabel 2 Perbandingan hasil simulasi

Kondisi Jalan	Jumlah Iterasi	Waktu (detik)
Licin	9376	32,8186
Aspal basah	1116	3,9006
Aspal kering	1160	4,0715

Berdasarkan Tabel 2 dapat diketahui bahwa pada jalan licin (bersalju), jumlah iterasi dan waktu proses yang dilakukan lebih besar dibanding pada kondisi jalan lainnya, hal tersebut karena koordinat data *input* dan *output* kurang halus.

Untuk memperoleh tingkat akurasi yang lebih tinggi, maka JST ini dapat dilatih dengan jumlah contoh data (*input* dan *output*) yang lebih banyak.

Selanjutnya telah ditentukan nilai standar deviasi dari data sebenarnya dengan data hasil identifikasi (16 data *input* dan *output*) dengan rumus berikut.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2} \quad (8)$$

Tabel 3 menunjukkan perbandingan kinerja identifikasi parameter menggunakan JST dan LMS, sehingga dari hasil tersebut diketahui bahwa secara kuantitatif metode JST memberikan hasil yang lebih baik dari pada metode LMS. Hal tersebut karena metode LMS menggunakan polinomial sehingga kurang optimal jika diimplementasikan pada tipe persamaan yang menggunakan sin dan tan seperti pada persamaan (1), sedangkan metode JST dapat dimodifikasi sehingga sesuai dengan persamaan (1).

Oleh karena data hasil simulasi yang diperoleh menggunakan metode JST lebih mendekati data sebenarnya pada model gaya gesek antara roda kendaraan dengan permukaan jalan, berarti kontroler dinamika kendaraan yang menggunakan metode JST bekerja berdasarkan model yang lebih akurat sehingga akan membuat manufer kendaraan semakin stabil.

Tabel 3. Perbandingan kinerja

Kondisi Jalan	Standar deviasi	
	JST	LMS
Licin	0,0081	0,0103
Aspal basah	0,0085	0,0114
Aspal kering	0,0084	0,0195

#### 4. Kesimpulan

Berdasarkan hasil simulasi dan analisis yang telah dilakukan dalam penelitian ini, dapat diambil kesimpulan sebagai berikut:

1. Hasil identifikasi parameter model gaya gesek antara roda kendaraan dan permukaan jalan menggunakan metode *backpropagation* pada JST mendekati data sebenarnya untuk tiga jenis kondisi jalan yaitu: jalan licin, aspal basah, dan aspal kering.
2. Hasil identifikasi parameter menggunakan *backpropagation* lebih baik dibandingkan hasil identifikasi parameter menggunakan metode LMS.
3. Dari hasil identifikasi parameter menggunakan metode *backpropagation* diperoleh persamaan koefisien gesekan pada jalan licin adalah  $\mu = 0.4 \sin(1,5761 \cdot \tan^{-1}(10,901.s))$ , pada jalan aspal basah adalah  $\mu = 0.6 \sin(1,6443 \cdot \tan^{-1}(9,5941.s))$  dan pada jalan aspal kering adalah  $\mu = 0.9 \sin(-1,6354 \cdot \tan^{-1}(-10,279.s))$ .

#### 5. Ucapan terimakasih

Penulis mengucapkan banyak terimakasih kepada seluruh dewan redaksi Jurnal INKOM, Prof. Dr. Ir Bambang Subiyanto, M.Agr yang telah memberikan bimbingan dalam hal penulisan makalah ilmiah, Puslit Telimek LIPI dan Pusat Pembinaan, Pendidikan dan Pelatihan Peneliti LIPI, serta semua pihak yang tidak dapat disebutkan satu persatu, yang telah membantu penulisan karya tulis ilmiah ini.

#### 6. Daftar pustaka

- [1] Hong, H.J. and Jo, H.Y. 1998. Prediction of Friction between Tire and Road Using Powertrain Model. *Proceedings of International Conference on Advanced Vehicle Control (AVEC)*:135-140.
- [2] Bosch, P.P.J.van den and Klauw, A.G.van der. 1994. *Modeling, Identification, and Simulation of Dynamical Systems*. CRC Press, Florida.
- [3] Rijanto, E. 2004. Modeling and On-line Process Identification of GMS Flake Shaping Process Using RDF. *PPI-KIM, ISSN.0852-002X* : 191-200.
- [4] Hwang, W. And Song, B. 2000. Road Condition Monitoring System Using Tire-Road Friction Estimation. *Proceedings of International Conference on Advanced Vehicle Control (AVEC)*: 437-442.
- [5] Sholahuddin, A.2002. Penerapan Neural Network Tentang Metode Backpropagation pada Pengenalan Pola Huruf. *KOMMIT 2002, ISSN.1411-6286*: A.82-A.89.
- [6] Kumar, S. 2004. *Neural Networks*. McGraw - Hill, Singapore.