

Klasifikasi Kegagalan pada Sistem Injeksi Bahan Bakar Marine Diesel dengan Menggunakan Neural Network

Aulia Windyandari ¹⁾

¹⁾ Staf Pengajar Diploma Teknik Perkapalan

Abstrak

Pada artikel ini penulis mempresentasikan diagnosa kemungkinan kegagalan system injeksi bahan bakar marine diesel engine. Metode yang dipakai berdasarkan indicator diagram analisis. Algoritma dari deteksi kegagalan dikonstruksikan dengan menggunakan neural network. Data dikumpulkan selama tes pada engine merk Sulzr 3 Al 25/30 berdasarkan pengalaman. Indikasi algoritma dicatat oleh indicator eletronik Unitest 201. Tahap-tahap diagnosa riset juga dijabarkan pada artikel ini, yang meliputi data aktual selama eksperimen, diagnosa model konstruksi, kostruksi klasifikator secara otomatis dan verifikasi.

Tujuan metode diagnosa ini bisa dipakai untuk menunjukkan sebuah contoh evaluasi otomatis tahap-tahap teknis sebuah engine, terutama bagian yang mengalami kegagalan. Kegagalan dari sebuah engine tidak selalu membuat kerja engine berhenti.

Kata kunci : Neural Networks, Sistem Injeksi Bahan Bakar, Algoritma Deteksi Kegagalan

I. PENDAHULUAN

Teknik diagnosa memegang aturan penting dalam eksploitasi perlengkapan permesinnsn kelautan, khususnya diesel engine[1][2]. Metode kegagalan ototmatic sangat berguna dan membantu untuk pengawasan teknis yang bertanggung jawab pada unit persiapan pengoperasian[3]. Pengetahuan praktis tentang konstruksi dan dan prinsip kerja sebaian besar metode diagnosa menjadi komponen penting pada proses pendidikan seorang marine engineer. Aplikasi marine diesel engine dikhususkan untuk kegagalan yang sering terjadi pada system injeksi bahan bakar. Tahap teknis pada system ini, pada putaran yang berpengaruh pada tahap pembakaran. Engine performan, durability dan reliabilitynya tergantung pada persiapan kursus pada proses pembakarannya [4]. Selain itu kondisi sistem injeksi dikhususkan pada emisi gas buang yang beracun dan konsumsi bahan bakar.

Sistem injeksi bahan bakar salah satu bagian yang paing sering bermasalah pada sebuah engine. Pada dasarnya, kegagalan pada sistem ini tidak selalu menyebabkan engine berhenti beroperasi. Dimana sebuah engine dalam keadaan teknis yang buruk, ditandai dengan :

- Konsumsi bahan bakar tinggi;
- Emisi gas besar dan partikel beracun;

- Masalah start up dan penggunaan system tribologic utama enginr lebih cepat[5].

Meskipun metode analisa system bahan bakar diketahui paling banyak adalah tahap tekanan bahan bakar dalam pipa antara pompa dan injektor bahan bakar[6][7]. Hal ini tidak menimbulkan suatu batasan seperti tekanan dalam pipa injeksi yang selalu diakses dalam sebuah kamar mesin (engine perlu dilengkapi dengan sensor dan alat pengukuran untuk mencatat kurva tekanan). Untuk alasan ini maka diperlukan suatu algoritma yang digunakan sebagai aturan diagnosa. Perlu diingat bahwa metode diagnosa diharapkan menjadi alternatif murah dibanding sistem diagnosa kompleks lain, dan harus mempunyai parameter yang mudah diakses untuk pengukuran pada waktu yang sama memberikan informasi tentang kondisi sistem injeksi bahan bakar [8]. Karena itu tekanan dalam silinder menggunakan indikator sinyal. Algoritma untuk deteksi kegagalan dikonstruksikan oleh neural networks. Selain itu diagnosa model dibuat untuk mengklasifikasikan tahap-tahap dari injeksi bahan bakar..

2. NEURAL NETWORKS

Neural networks adalah sebuah algoritma yang mempunyai arsitektur yang dimodelkan seperti otak manusia. Neural networks terdiri dari banyak bahkan ratusan unit proses yang sederhana yang dirangkaikan dalam

sebuah jaringan kerja komunikasi kompleks. Tiap-tiap unit atau node adalah sebuah model yang disederhanakan dari neuron yang sebenarnya, yang dihitung berdasarkan sebuah sinyal yang menjadi input dari node lain yang dihubungkan.

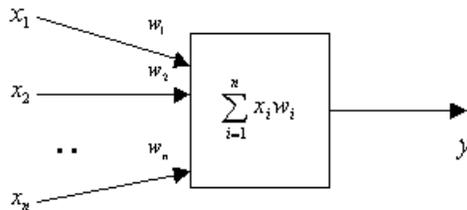
Kekuatan dari hubungan ini bisa bervariasi berdasarkan jaringan dengan tujuan yang berbeda-beda. Neural networks adalah sebuah metode baru untuk program komputer. Secara konsep performa rumusan yang baik dapat dikenali dan tujuan lain yang sangat sulit untuk diprogram menggunakan konvensional teknik. Program yang terdiri dari jaringan neural juga dapat mempelajari dirinya sendiri dan menyesuaikan dengan perubahan kondisi yang terjadi.

A Simple Artificial Neuron

Neural networks terdiri dari banyak unit proses sederhana (artificial neurons). Sebuah neurons sering disebut node atau unit, yang didapat dari inputan beberapa unit lain atau sumber dari luar. Tiap input x mempunyai suatu berat w , yang mana dapat dimodifikasi selama proses belajar. Unit tersebut menghitung beberapa fungsi f dari jumlah berat berdasarkan inputannya, sesuai formula berikut :

$$y = f\left(\sum_j w_j x_j\right)$$

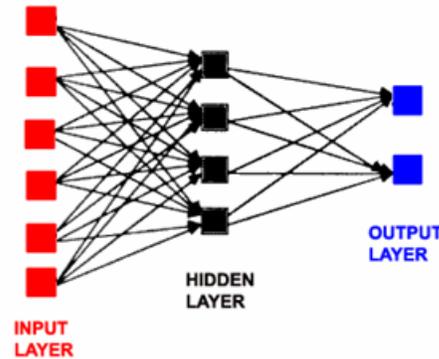
Output y , pada putarannya, dapat memberikan input pada unit yang lain , seperti pada gambar 1. Berat yang dijumlahkan, $\sum w_i x_i$, disebut net input pada :



Gambar 1 : Sebuah artificial neuron

Unit I sering ditulis sebagai neti. Fungsi f adalah unit fungsi aktivasi. Pada kasus sederhana, F adalah fungsi identifikasi dan unit output hanya net input. Ini disebut sebagai sebuah unit linier. Neuron sederhana bisa disusun dalam topologi neural networks yang berbeda. Dari sudut pandang aliran aktivasi antara prosesing unit, ada tiga arsitektur neural networks, yaitu :

- Single-layer feed-forward: satu input layer dan satu output layer dari processing unit; tidak ada hubungan feed back;
- Multi-layer feed-forward: satu input layer, satu output layer, dan satu atau lebih layer tersembunyi dari processing unit; disini tidak ada hubungan feedback dan layer tersembunyi terletak di dalam antara input dan out put layer (contohnya sebuah multi-layer perceptron);
- Recurrent: beberapa network paling sedikit hubungan satu feed back; bisa atau tidak mempunyai unit tersembunyi [9][10].



Gambar 2 : Sebuah perceptron neural networks

Perceptron Neural Network

A perceptron adalah arsitektur networks yang terkenal yang digunakan akhir-akhir ini khususnya dalam teknik pengetahuan. Dalam model ini artificial network disusun dalam layer. Sinyal mempresentasikan sebuah rumusan input yang dimasukkan pada layer pertama.. Node dalam layer ini dihubungkan ke layer lain (kadang-kadang dinamakan layer tersembunyi). Langkah dari node pada input layer di hubungkan melalui sebuah hubungan menuju layer tersembunyi. Akhirnya, kerja pada node dalam layer ini dimasukkan pada layer output terakhir,dimana rumusan dari langkah node output didefinisikan sebagai respon dari network yang diberikan pada rumusan inputan. Sinyal hanya dialirkan ke depan dari satu layer ke sebuah layer terakhir. Dalam sebuah perceptron, tidak ada feed back dari output layer.

Gambar 2 menunjukkan sebuah perceptron neural network.

Sebuah perceptron mampu mengenali dan mengklasifikasikan pola yang ada, termasuk beberapa node yang tidak ditampilkan secara langsung, juga memungkinkan untuk mengklasifikasi pola kedalan satu atau lebih dari

dua set. Perceptron neural networks adalah sebuah alat sempurna untuk model non-linier objek, beberapa gambarn tentang pemilihan, konstan hubungan non-linier dan kemampuan mempelajari dan menyesuaikan diri. Neural networks juga digunakan sebagian besar untuk diagnosa [11][12].

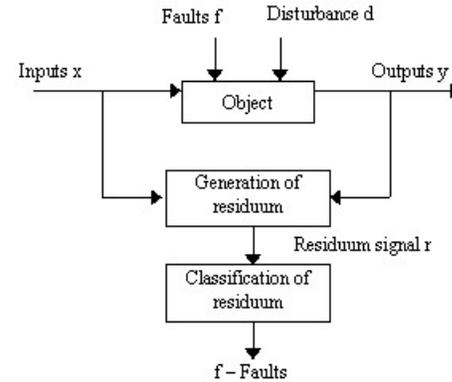
3. OUTLINE METODE DIAGNOSA

Ide metode ini didasarkan atas kegunaan dari model perubahan tekanan dalam silinder pada tahap teknis system diagnosa. Model ini digunakan untuk menghitung standart pressure level untuk engine tanpa kegagalan. Setelah itu sisa dari sinyal dihitung dengan kegunaan kurva standart tekanan dan pengukuran tekanan. Sinyal ini memperlihatkan ketidak-stabilan antara nilai nominal (tanpa kegagalan) dan kegagalan kondisi system fuel injeksi. Sisa sinyal dianalisa dari sudut pandang technical state system injeksi bahan bakar. Struktur umum algoritma diagnosa digambarkan pada gambar 3. Algoritma ditunjukkan pada gambar 3 terdiri dari dua blok utama, yaitu susunan dan klasifikasi dari residuum valve. Susunan blokmengidentifikasi residuum sinyal dengan membandingkan sinyal dari model tekanan dengan nilai pengukuran. Residuum sinyal sama dengan 0 sementara system bekerja dibawah kondisi nominal.

Pada kasus ini jika terjadi sebuah kegagalan, maka nilainya berbeda dari 0. Klasifikasi blok membedakan kerusakan dalam sistem injeksi bahan baker berdasarkan residuum sinyal terbaru. Karena kesalahan dalam analisa modeling dari objek yang kompleks dan prosesnya, neural modeling dapat digunakan. Perceptron neural networks yang dipakai adalah perceptron neural networks dengan satu layer tersembunyi. Ini juga digunakan untuk memodelkan tekanan sebuah silinder dan mengklasifikasi sinyal residuum. Kesalahan algoritma kembali pada propagasi yang digunakan untuk mengajar pelajar tentang networks.

Pada awal penelitian ini, sebuah model neural tekanan dalam silinder diaktifkan. Model memperlihatkan kurva standart pressure di belakang valve yang terindikasi fungsi load engine. Load engine diestimasi dari kurva tekanan. Hubungan antara tekanan kompresi dan load engine adalah digunakan untuk turbocharge engine [13]. Tekanan kompresi berkisar 55 - 50 crank angle sebelum top dead centre (TDC) yang digunakan sebagai input. Modelm dan analisa

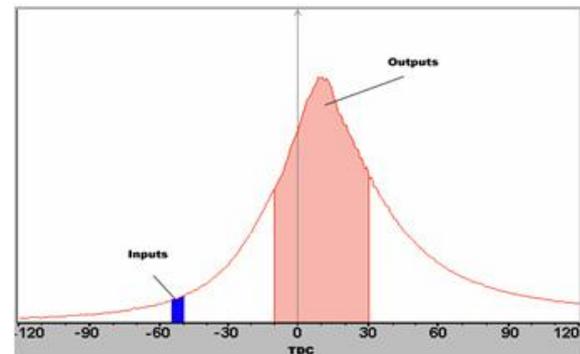
dibatasi dari 40 crank angle (10 sebelum TDC dan 30 setelah TDC) (lihat gambar 4).



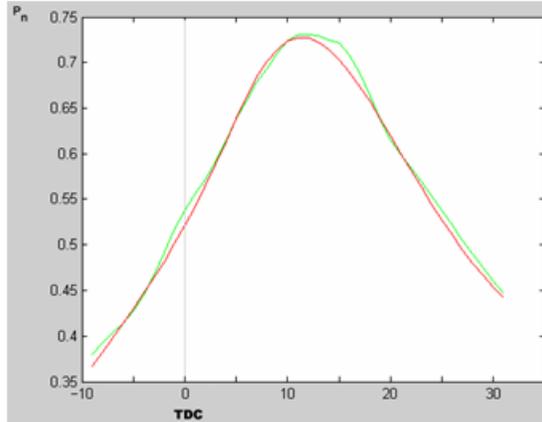
Gambar 3: Algoritma diagnosa struktur umum

4. HASIL PENELITIAN

Penelitian ini dilakukan pada sebuah marine supercharge diesel engine empat langkah type Sulzer 3A1 25/30. Indikator elektronik Unitest 201 digunakan untuk indikasi engne. Pada bagian pertama riset, dibuat model neural tekanan untuk nominal state. Model didasarkan pada grafik indikasi dari load 50 kW sampai 250 kW. Hal ini memungkinkan untuk perhitungan sebuah contoh kurva tekanan antara range 10 crank sebelum TDC sampai 30 crank setelah TDC. Sebuah perbandingan model neural dengan kurva tekanan ditunjukkan pada gambar 5.



Gambar 4: Batasan input dan output neural model dari combustion course



Grafik 5: Contoh tekanan : dash line menunjukkan perhitungan menggunakan model, dimana continous line menggambarkan yang diukur.

Kurva sebenarnya dipresentasikan pada gambar 5. Percobaan aktif dilakukan untuk mendapatkan metode diagnosa yang bervariasi. Kegagalan berikut pada system injeksi bahan bakar disimulasikan selama percobaan :

- Mengurangi tensi dalam fuel injector spring;
- Pemakaian pompa injeksi;
- Kalibrasi nozzle fuel injector;
- Pemasangan nozzle fuel injektor.

Selama percobaan, satu level dari kegagalan disimulasikan dan tekanan dalam silinder diukur, dengan range load engine dari 50 sampai 250 kW. Dari tiap simulasi engine state, 42 kurva tekanan diregisterkan. Tabel 1 merupakan list kegagalan simulasi dengan simbol respektif. Implementasi dari beberapa kegagalan pada waktu yang sama dan level yang bervariasi pada kegagalan sistem tidak difokuskan pada percobaan ini. Data percobaan digunakan untuk klasifikasi state sistem injeksi bahan bakar. Tujuan utama dari pengklasifikasian ini untuk menandai rumusan (states) menuju satu kelas yang mungkin. Dua images yang berbeda dari states ditandai oleh kelas yang sama hanya jika keduanya sama, dan dengan tanda yang berbeda jika benar-benar berbeda.

Kesamaan ini sangat tergantung pada tujuan dari klasifikasi. Dua cara diperkenalkan untuk mengelompokkan aktifitas neural network, dinamakan relatif error dan kesalahan penandaan.

Table 1: Kegagalan simulasi dengan simbol respektifnya

Symbol	State of the Engine
K1	Nominal state without faults
K2	Fall of tension of the fuel injector spring
K3	Injection pump wear
K4	Decalibration of the fuel injector nozzles
K5	Coked fuel injector nozzles

Relatif error didefinisikan seberapa banyak contoh dari beberapa klas yang diidentifikasi salah. Penandaan yang salah didefinisikan seberapa banyak contoh negative dari klas yang ditandai itu. Hasil dari kegagalan klasifikasi dipresentasikan dalam tabel 2. Hasil klasifikasi dengan error.

Table 2: The results of the klasifikasi with the errors.

Classificatory network	The number assigned to the class					Relative error	Mean relative error	Wrong assign error	Mean wrong assign error
	K1	K2	K3	K4	K5				
K2	2	38	4	5	2	10%	12%	4%	3%
K3	0	0	39	4	1	7%		2%	
K4	1	3	8	30	2	28%		5%	
K5	1	0	2	0	41	2%		1%	

KESIMPULAN

Hasil studi penjabaran dalam artikel ini, dapat disimpulkan sebagai berikut:

Menggunakan metode tertentu memungkinkan untuk diagnosa (dengan kesalahan relative di bawah 15 %) seperti kegagalan, dengan mengurangi tekanan dalam spring fuel injector, menggunakan pompa injeksi dan nozzle fuel injector. Sementara, pada kasus nozzle fuel injector de-kalibrasi, relative error ditemukan sebesar 28%. Diagnosa dengan kualitas rendah dapat disebabkan factor berikut :

- Kesalahan pengukuran tekanan dalam silinder
- Kesalahan dalam representasi tekanan dalam silinder menggunakan sebuah model nominal neural;
- Sensitifitas yang rendah dari diagnosa sinyal pada beberapa kegagalan

Metode diagnosa ini dapat digunakan untuk klasifikasi secara otomatis, kegagalan system injeksi bahan bakar. Artikel ini mempresentasikan pengetahuan praktis, penemuan, dan prinsip kerja sebuah metode diagnosa yang mempertimbangkan komponen penting dalam pendidikan teknis kemaritiman.

REFERENCES

1. Hebda, M., Niziński, S. and Pelc, H., *Podstawy Diagnostyki Pojazdów Samochodowych*. Warsaw: WKŁ (1980).
2. Kluj, S., *Diagnostyka Urządzeń Okrętowych*, Wydawnictwo. Gdynia: WSM (1982).
3. Ambrozik, A. and Piasta, Z., Ocena pracy silnika spalinowego w oparciu o uogólnion¹ użytecznooæ jest wskaŹników. *Silniki Spalinowe*, **4** (1988).
4. Lee, Y.B., Lee, T.W., Kim, S.J. and Kim, C.H., A hybrid knowledge-based expert system for rotating machinery. *Proc. 14th Inter. Congresson Condition Monitoring and Diagnostic Engng. Management* (COMADEM), Manchester, England, UK (2001).
5. Jankowski, M., Ocena Wrazliwooci Diagnostycznej Sygna³u Pulsacji Cioenienia Aparatury Wtryskowej. Rozprawa doktorska, Akademia Techniczno Rolnicza w Bydgoszczy (1997).
6. Jankowski, M. and Kwidzyński, M., Zastosowanie sieci neuronowej do automatycznej klasyfikacji stanu aparatury wtryskowej. *Proc. Kongres Diagnostyki Technicznej*, Gdańsk, Poland (1996).
7. Lotko, W., Diagnostyka aparatury wtryskowej WSI Radom. *Mechanika*, **20** (1991).
8. Quinlan, J.R., *C4.5 Programs for Machine Learning*. San Mateo: Morgan Kaufman (1993).
9. Russel, S. and Norvig, P., *Artificial Intelligence: A Modern Approach*. Englewood Cliffs: Prentice Hall (1995).
10. McGarry, K. and MacIntyre, J., Hybrid Diagnostic System Based Upon Simulation and Artificial Intelligence. University of Sunderland, School of Computing, Engineering and Technology (2002).
11. Birmingham, J. and Klinker, G., Knowledge acquisition tools with explicit problem solving method. *The Knowledge Engng. Review*, **8**, **1** (1993).
12. Korbicz, J., Koocielny, J., Kowalczuk, Z. and Cholewa, W., *Diagnostyka Procesów*. arsaW: WNT (2002).
13. Henrion, M., Shacter, R., Kanal, L. and Lemmer, J. (Eds), *Uncertainty in artificial intelligence*, Vol.5. New York: North-Holland Publishing (1990).