

PREDIKSI PROSES PENDINGINAN BAHAN DI PLTN DENGAN JARINGAN SYARAF DAN ALGORITMA GENETIKA

Mike Susmikanti dan Ghofir

Pusat Pengembangan Informatika Nuklir-BATAN
Kawasan PUSPIPTEK, Tangerang Selatan
Email untuk korespondensi: mike@batan.go.id

ABSTRAK

PREDIKSI PROSES PENDINGINAN BAHAN DI PLTN DENGAN JARINGAN SYARAF DAN ALGORITMA GENETIK. *Prediksi proses pendinginan bahan merupakan faktor utama untuk mengetahui sifat mekanik pada bahan yang digunakan di PLTN. Hal ini untuk mencegah korosi dan keretakan. Proses pendinginan mempengaruhi sifat mekanik bahan seperti creep dan fatigue. Tujuan dari penelitian ini adalah membuat suatu pemodelan terhadap proses pendinginan bahan yang digunakan di PLTN menggunakan algoritma genetika dan jaringan syaraf. Pemodelan dengan neural network dalam hal ini dilakukan untuk memperoleh sifat bahan yang digunakan. Neural network merupakan sistem pembelajaran dan pelatihan untuk model non linier. Dalam hal optimasi untuk mengetahui sifat mekanik material digunakan algoritma genetika. Data hasil eksperimen digunakan untuk pembelajaran dan pelatihan. Diperoleh nilai tegangan sebenarnya yang optimal dan pemodelan untuk memprediksi proses pendinginan terhadap bahan yang digunakan di PLTN.*

Kata kunci: Bahan, proses pendinginan, korosi, neural network, algoritma genetika

ABSTRACT

PREDICTION OF COOLING PROCESS FOR MATERIAL AT NUCLEAR POWER PLANTS USING NEURAL NETWORK AND GENETIC ALGORITHM. *A prediction of the cooling process material is the main factor to determine the mechanical properties of the materials used in nuclear power plants. This is to prevent corrosion and cracks. Cooling process affects the mechanical properties of materials such as creep and fatigue. The purpose of this study is to develop a model of the cooling process of the materials used in nuclear power plants using genetic algorithms and artificial neural networks. Modeling with neural network in this case is done to obtain the properties of the materials used. Neural network is a system of learning and training for non-linear models. In terms of optimization to determine the mechanical properties of the material used genetic algorithms. The data used of the experimental results for learning and training. Retrieved the optimal true stress and modeling to predict the cooling process of the materials used in nuclear power plants.*

Keywords: Material, cold work, corrosion, neural network, genetic algorithm.

PENDAHULUAN

Faktor yang mempengaruhi kekuatan umur bahan yaitu proses pendinginan, konsentrasi tegangan, sifat mekanik material, struktur makro dan struktur mikro. Proses pendinginan merupakan salah satu faktor penting yang berpengaruh pada umur kelelahan bahan dibandingkan faktor lain. Proses pendinginan merupakan kompresi dalam bahan tanpa adanya beban eksternal dan struktur yang disebabkan tidak sesuainya regangan dari dalam. Keretakan yang diakibatkan tegangan

biasanya terjadi bilamana lingkungan terkorosi. Hasil proses pendinginan dapat diukur dengan teknik uji tidak merusak dan uji merusak setempat. Teknik uji tidak merusak termasuk X-ray, metode difraksi neutron, metoda magnetik dan teknik ultrasonik. Dalam hal untuk memprediksi akibat proses pendinginan secara komputasi numerik dapat dilakukan dengan metoda elemen hingga. Teknik kecerdasan buatan, seperti sistem jaringan syaraf tiruan dan sistem fuzzy, saat ini mulai digunakan sebagai alat yang handal dalam

bidang teknik nuklir^[1]. Pelatihan sistem jaringan syaraf dapat mengadopsi fenomena pendekatan fungsi non linier^[2]. Dalam simulasi umur kelelahan bahan, algoritma genetika digunakan untuk mengoptimalkan beban untuk mendapatkan nilai tegangan dan regangan^[3]. Data eksperimen ini digunakan untuk input pembelajaran dari jaringan syaraf tiruan.

Tujuan dari penelitian ini adalah memprediksi hasil proses pendinginan bahan yang digunakan di PLTN menggunakan algoritma genetika dan jaringan syaraf.

METODE

Jenis tegangan yang terjadi pada bahan tergantung pada beban atau gaya yang diterapkan. Ada banyak jenis tegangan, tetapi umumnya diklasifikasikan dalam salah satu dari beberapa kategori yaitu tegangan sisa, tekanan struktural, tekanan aliran, tegangan termal dan tekanan kelelahan^[4]. Pada umumnya regangan dikarenakan proses fabrikasi yang salah satu diantaranya adalah proses pendinginan. Tegangan (stress) dan regangan (strain) pada proses pendinginan dinyatakan dalam Persamaan (1)^[5],

$$\sigma_i = K\varepsilon_i^n \tag{1}$$


Melakukan perhitungan deformasi, berarti melakukan perhitungan pengerasan regangan. Secara umum mengukur nilai deformasi adalah mendefinisikan *prosentase* dari proses pendinginan yang dinyatakan dalam Persamaan (2) atau (3),

$$\%CW = \left[\frac{A_0 - A_f}{A_0} \right] \times 100 \tag{2}$$

atau


$$\%CW = \left[\frac{t_0 - t_f}{t_0} \right] \times 100 \tag{3}$$

Diagram pengaruh proses pendinginan pada sifat mekanik tembaga ditampilkan pada Gambar 1 [Donald et al, 2006],



Gambar 1. Diagram efek proses pendinginan untuk tembaga

Pemodelan berbasis jaringan merupakan pembelajaran dan adaptasi suatu obyek. Terdapat beberapa metode dalam pembelajaran dengan pengawasan pada jaringan syaraf tiruan diantaranya dengan metode *Widrow-Hoff Weight*. Metode pembelajaran diperoleh dengan melakukan taksiran kuadrat terkecil (*Least Mean Square*) pada jaringan lapisan ganda. Jaringan syaraf dengan *multi-layer perceptron* ditampilkan pada Gambar 2.



Gambar 2. Jaringan Syaraf Multilayer Perceptron

Pada proses *Widrow-Hoff*, unit vektor input (X) menerima sinyal aktivasi dan menyebarkan sinyal ke unit lapisan tersembunyi (*hidden layer*) serta menentukan sinyal sebagai respon dari unit lapisan masukan (*input*) dengan faktor bobot. Selanjutnya, unit lapisan tersembunyi akan menyebarkan sinyal respon ke unit lapisan keluaran (*output*). Unit lapisan output juga menentukan sinyal aktivasi sebagai respon terhadap sinyal yang berasal dari unit lapisan tersembunyi^[2]

Algoritma genetika merupakan salah satu pendekatan pencarian optimasi yang

didasarkan mekanisme evolusi biologis. Teknik pencarian dilakukan terhadap sejumlah solusi yang mungkin yang disebut populasi. Individu dalam populasi disebut kromosom. Populasi awal dibangun secara acak, sedangkan populasi berikutnya merupakan hasil evolusi kromosom melalui iterasi yang disebut generasi. Pada tiap generasi, kromosom melalui proses evaluasi dengan fungsi kesesuaian (*fitness*). Generasi berikutnya terbentuk dari proses penyilangan (*crossover*) dan proses mutasi. Populasi generasi baru dibentuk dengan cara seleksi nilai *fitness* kromosom induk dan anak, serta menolak kromosom lain yang tidak memenuhi syarat, sehingga ukuran populasi (jumlah kromosom dalam suatu populasi) konstan. Setelah melalui beberapa generasi, maka algoritma ini akan konvergen kekromosom terbaik^[6].

Algoritma genetika disederhanakan menjadi berikut ini, Misalkan P (generasi) adalah populasi dari satu generasi, maka secara sederhana algoritma genetika terdiri dari langkah-langkah :

1. Generasi = 0 (generasi awal)
2. Inisialisasi Populasi Awal, P(generasi), secara acak
3. Evaluasi nilai fitness pada setiap individu dalam P(generasi)
4. Kerjakan langkah-langkah berikut hingga generasi mencapai maksimum generasi :
 - a. generasi = generasi + 1 (tambah generasi)
 - b. Seleksi populasi tersebut untuk mendapatkan kandidat induk, P'(generasi)
 - c. Crossover pada P'(generasi)
 - d. Mutasi pada P'(generasi)
 - e. Evaluasi fitness setiap individu pada P'(generasi)
 - f. Bentuk populasi baru: P(generasi) = {P(generasi-1) yang survive, P'(generasi)}

HASIL DAN PEMBAHASAN

Dilakukan pembuatan program dalam pemodelan dan optimisasi menggunakan MATLAB. Sebelum pemodelan untuk proses pendinginan dilakukan optimisasi menggunakan algoritma genetika. Logam tembaga (Cu), campuran tembaga (Cu30%Zn) dan titanium (Ti) mempunyai parameter derajat ketahanan *n* masing masing sebesar 0,54; 0,50 dan 0,05. Konstanta koefisien ketahanan *K*

untuk tembaga, campuran tembaga dan titanium masing masing sebesar sebesar 46000, 130000 dan 175000 psi. Parameter regangan berada dalam interval dari 0 sampai 1.5 [Donald et al, 2006]. Penentuan parameter kontrol dalam algoritma genetika meliputi ukuran populasi (*popsiz*e) sebesar 30, peluang *crossover* (*pc*) sebesar 0,25 dan peluang mutasi (*pm*) sebesar 0,01.

Dilakukan simulasi untuk mencapai fungsi tujuan tegangan terhadap regangan yang telah dihitung sesuai dengan batasan yang diberikan [Mark et al, 2000]. Simulasi dilakukan pengulangan sampai mencapai generasi ke-50. Regangan diperoleh ketika fungsi tujuan mencapai nilai optimal yang didefinisikan sebagai nilai dari fungsi kecocokan (*fitness*). Dari simulasi, nilai tegangan dan regangan yang optimal dari tembaga, campuran tembaga dan diberikan pada Tabel 1 dan titanium pada Tabel 2.

Tabel 1. Nilai optimal tegangan dan regangan untuk tembaga (Cu) dan campuran tembaga (Cu30%Zn)

No. gen.	ε_t	σ_t	ε_t	σ_t
	fitness Cu	fitness Cu	fitness Cu30% Zn	fitness Cu30% Zn
1	0,977	39622	0,977	107585
2	0,977	38735	0,977	105176
3	0,973	38580	0,973	104757
4	0,984	39043	0,984	106014
5	0,977	38735	0,977	105176
6	0,977	38735	0,977	105176.
7	0,961	38117	0,961	103500
8	0,977	38735	0,977	103500
9	0,977	38735	0,977	105176
10	0,977	38735	0,977	105176
:				:
41	0,969	38426	0,969	104338
42	0,977	38735	0,977	105176
43	0,977	38735	0,977	105176
44	0,977	38735	0,977	105700
45	0,977	38735	0,977	105176
46	0,977	38735	0,977	105176
47	0,977	38735	0,977	105176
48	0,977	38735	0,977	104757
49	0,977	38735	0,977	105176
50	0,977	38735	0,977	105176

Variabel regangan ϵ_t untuk tembaga, campuran tembaga dan titanium menunjukkan konvergen atau optimal pada nilai 0.977 dan nilai tegangan σ_t optimal masing masing pada nilai 38735, 105176 dan 90277 psi.

Melakukan perhitungan deformasi, berarti melakukan perhitungan pengerasan regangan. Secara umum mengukur nilai deformasi adalah dengan mendefinisikan *prosentase* dari proses pendinginan (*cold work*) yang dinyatakan dalam Persamaan (3).

Tabel 2. Nilai optimal tegangan dan regangan untuk Titanium

Nomer generasi	ϵ_t Fitness Titanium	σ_t Fitness Titanium
1	0,977	92345
2	0,977	90277
3	0,973	89918
4	0,984	90977
5	0,977	90277
6	0,977	90277
7	0,961	88839
8	0,977	90277
9	0,977	90277
10	0,977	90277
:	:	:
41	0,969	89588
42	0,977	90277
43	0,977	90277
44	0,977	90727
45	0,977	90277
46	0,977	90277
47	0,977	90277
48	0,977	89918
49	0,977	90277
50	0,977	90277

Jika dilakukan proses pendinginan misalnya terhadap pelat tembaga dengan ketebalan 1 cm menjadi 0,5 cm dan kemudian selanjutnya menjadi 0,16 cm, maka prosentase total proses pendinginan dan kekuatan tarik dari pelat tembaga 0,16 cm,

$$\%CW = \left[\frac{1,0cm - 0,16cm}{1,0cm} \right] \times 100 = 84\%$$

Dari acuan^[5] diperoleh kekuatan tarik adalah 82000 psi. Untuk merancang proses fabrikasi

yang menghasilkan ketebalan tembaga 0,1 cm adalah mempunyai sekurang-kurangnya 65000 psi kekuatan tarik, 60000 yield strength dan 5% elongasi. Dari acuan^[5] diperoleh sekurang-kurangnya 35% proses pendinginan untuk menghasilkan kekuatan tarik (*tensile strength*) 65000 psi dan 40% proses pendinginan untuk menghasilkan yield strength dari 60000 psi, tetapi diperlukan kurang dari 45% proses pendinginan untuk memperoleh 5% elongasi. Proses pendinginan dilakukan diantara 40% dan 45% menghasilkan ketebalan minimum t_{min} dan maksimum t_{max} .


$$\%CW_{min} = \left[\frac{t_{min}cm - 0,1cm}{t_{min}cm} \right] \times 100 = 40\%$$

maka $t_{min} = 0,167$ cm, dan

$$\%CW_{max} = \left[\frac{t_{max}cm - 0,1cm}{t_{max}cm} \right] \times 100 = 45\%$$


maka $t_{max} = 0,182$ cm,

Jadi untuk memproduksi 0,1 cm pelat tembaga, dimulai dengan kondisi antara 0,167 cm dan 0,182 cm serta proses pendinginan dilakukan antara 40% dan 45% untuk mencapai ketebalan 0,1 cm. Berikutnya dilakukan pemodelan dengan neural network untuk mengidentifikasi kurva proses pendinginan. Sejumlah neuron diidentifikasi untuk data pembelajaran dan pelatihan. Dalam simulasi ini digunakan beberapa neuron sebagai input dan satu lapisan tersembunyi sebagai fungsi bobot^[8]. Nilai *prosentase* proses pendinginan masing masing untuk tembaga, campuran tembaga dan titanium diberikan berturut turut: 0, 10, 20, 30, 40, 50, 60, 70, 80 dan 90 (%). Nilai kekuatan tarik (*tensile-strength*) untuk tembaga berturut turut adalah 46000, 50000, 56000, 62000, 68000, 72000, 74000, 80000, 83000 dan 85000 psi^[5]. Untuk campuran tembaga 130000, 134000, 140000, 146000, 152000, 156000, 158000, 164000, 167000 dan 169000 psi dan untuk titanium 175000, 179000, 185000, 191000, 197000, 199000, 203000, 209000, 212000 dan 214000 psi^[4]. Sebelumnya data dijadikan standard normal baku. Pembelajaran dalam *neural network* menggunakan metoda *feedforward*. Pengamatan proses pendinginan untuk tembaga, ditampilkan pada Gambar 3. Kurva prediksi kekuatan tarik (*tensile-strength*) untuk tembaga dengan tingkat pendinginan dari 0 sampai 100% diberikan pada Gambar 4.



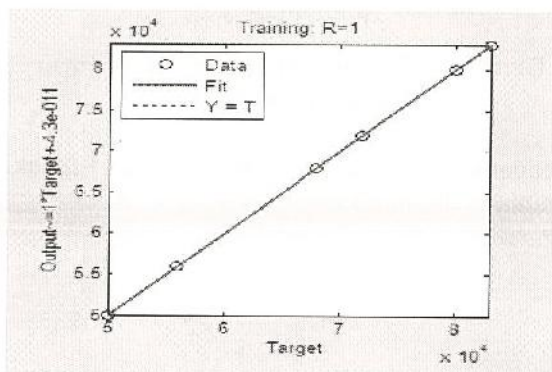
Gambar 3. Pengamatan proses pendinginan tembaga

Prediksi proses pendinginan tembaga ditampilkan pada Gambar 4.



Gambar 4. Kurva prediksi proses pendinginan tembaga

Gambar 5 menunjukkan koefisien kesuaian (R) dari proses pembelajaran.

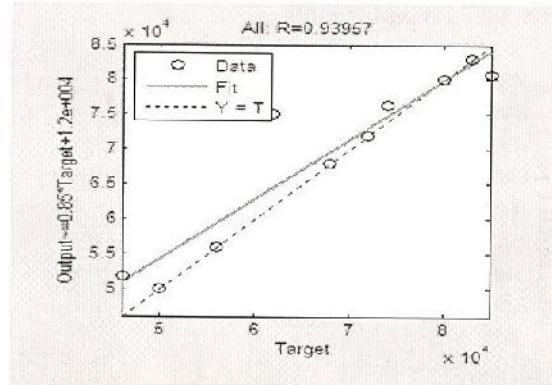


Gambar 5. Kurva pendugaan pembelajaran untuk data eksperimen

Koefisien kesuaian dari hasil pembelajaran dinyatakan dalam parameter R yaitu sama dengan satu ($R = 1$). Hal ini berarti jika R

sama dengan satu menunjukkan bahwa hasil pembelajaran adalah tepat berada pada nilai sebenarnya.

Gambar 6 menunjukkan koefisien kesuaian dari hasil pelatihan.



Gambar 6. Koefisien kesuaian dari hasil pelatihan

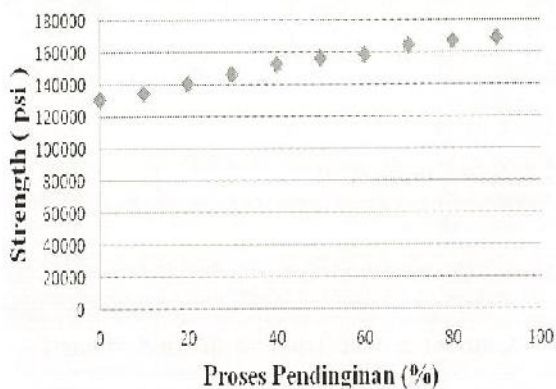
Diperoleh hasil pelatihan dengan nilai R adalah 0.93957. Dikarenakan nilai R mendekati satu, maka data hasil pelatihan sesuai dengan yang diharapkan dan mendekati nilai sebenarnya dalam proses pendinginan.

Sebagai model secara umum untuk data *fitting* digunakan fungsi pangkat (tidak linier). Pendugaan parameter μ dari sebaran data tembaga, campuran tembaga dan titanium adalah 45. Interval kepercayaan untuk taksiran parameter dalam suatu sebaran data tembaga dalam fungsi pangkat adalah (26,073;93,8402). Dalam Tabel 3 diberikan nilai residual antara hasil pengamatan dalam proses pendinginan dan pendugaan nilai strength untuk tembaga.

Tabel 3. Residual antara pengamatan dan pendugaan nilai strength tembaga

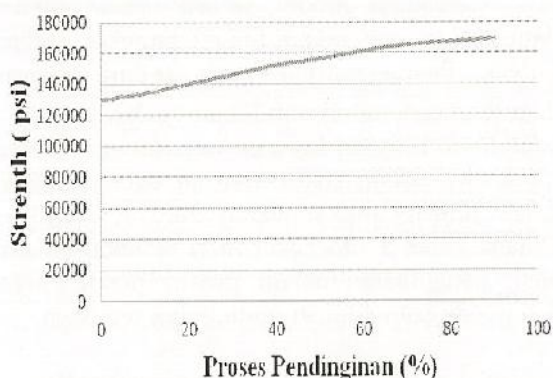
Prosentase Proses Pendinginan (%)	Y	Y fitness	Residual
0	46000	45000	1000
10	50000	51073	-1073
20	56000	56075,2	-752
30	62000	62036	-36
40	68000	67092,7	1073
50	72000	71042,4	576
60	74000	75052,7	-1527
70	80000	79236	764
80	83000	82552	448
90	85000	85473	-473

Simpangan baku untuk pendugaan diantara data pengamatan dan prediksi campuran tembaga diperoleh 952,1 yang berarti uji kecocokan pemodelan yang diperoleh mempunyai kesalahan yang kecil. Pengamatan proses pendinginan untuk campuran tembaga ditampilkan pada Gambar 7.



Gambar 7. Pengamatan proses pendinginan campuran tembaga

Prediksi proses pendinginan campuran tembaga ditampilkan pada Gambar 8.



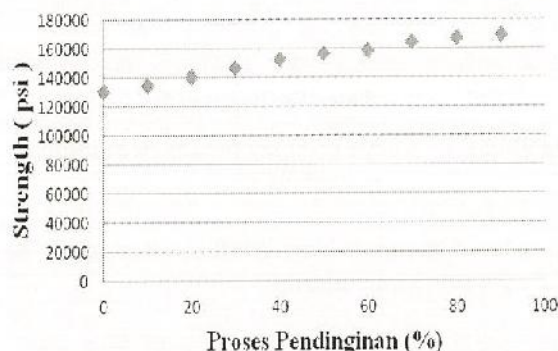
Gambar 8. Kurva prediksi proses pendinginan campuran tembaga

Dalam Tabel 4 diberikan nilai residual antara hasil pengamatan dalam proses pendinginan dan pendugaan nilai strength untuk campuran tembaga.

Tabel 4. Residual antara pengamatan dan pendugaan nilai strength campuran tembaga

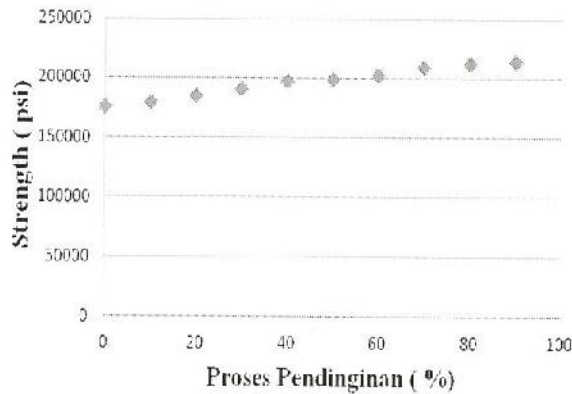
Prosentase Proses Pendinginan (%)	Y	Y fitness	Residual
0	130000	129000	1000
10	135000	135070	-70
20	139000	140750	-1750
30	147000	146040	960
40	152000	150930	2070
50	156000	155420	580
60	159000	159530	53
70	165000	163240	1760
80	166000	166550	-550
90	169000	169470	70

Simpangan baku untuk pendugaan diantara data pengamatan dan prediksi campuran tembaga diperoleh 1054,1 berarti uji kecocokan untuk pemodelan yang diperoleh untuk campuran tembaga mempunyai kesalahan yang kecil. Pengamatan proses pendinginan untuk titanium, ditampilkan pada Gambar 9.




Gambar 9. Pengamatan proses pendinginan campuran tembaga

Pengamatan proses pendinginan untuk titanium, ditampilkan pada Gambar 10.



Gambar 10. Pengamatan proses pendinginan titanium

Prediksi proses pendinginan titanium ditampilkan pada Gambar 11.



Gambar 11. Kurva prediksi proses pendinginan titanium

Untuk titanium dengan derajat ketahanan n yang cukup kecil akan menghasilkan kurva proses pendinginan yang lebih landai^[5].

Dengan cara yang sama koefisien kesuaian dari hasil pembelajaran dan pelatihan yang dinyatakan dalam parameter R untuk pemodelan proses pendinginan campuran tembaga dan titanium juga diselidiki. Jika R mendekati satu hal ini berarti diperoleh hasil pembelajaran dan pelatihan dalam proses pendinginan sesuai dengan yang diharapkan dan mendekati nilai sebenarnya.

Dalam Tabel 5 diberikan nilai residual antara hasil pengamatan dalam proses pendinginan dan pendugaan nilai strength untuk titanium.

Tabel 5. Residual antara pengamatan dan pendugaan nilai strength titanium

Prosentase Proses Pendinginan (%)	Y	Y fitness	Residual
0	175000	174220	780
10	180000	180040	-40
20	184000	185220	-1520
30	190000	190670	670
40	198000	195490	2510
50	198500	199980	-1980
60	203000	204130	-1130
70	208000	207950	50
80	212000	211430	570
90	214000	214580	-580

Simpangan baku untuk pendugaan antara pengamatan dan prediksi titanium diperoleh 1295,9 berarti uji kecocokan untuk pemodelan mempunyai kesalahan yang kecil.

KESIMPULAN

Diperoleh hasil optimasi nilai tegangan dan regangan untuk tembaga, tembaga campuran dan titanium yang mempengaruhi sifat mekanik bahan menggunakan algoritma genetika. Dalam hal ini diperoleh pemodelan untuk memprediksi proses pendinginan tembaga, tembaga campuran dan titanium menggunakan jaringan syaraf.

ARTI SIMBOL

- σ_t : True Stress (psi)
- ϵ_t : True Strain
- K : Koefisien kekuatan (psi)
- n : Derajat kekuatan/ Tingkat Ketahanan
- F : Beban (lb)
- A_0 : Luas penampang lintang awal dari spesimen bahan sebelum dimulainya pengujian (in^2).
- A_j : Penampang lintang sesudah deformasi (cm^2)
- t_0 : Tebal spesimen bahan sebelum pengujian (cm)
- t_j : Tebal sesudah deformasi (cm).
- CW : Prosentase Proses Pendinginan (%)

DAFTAR PUSTAKA

1. Na M.G., Kim J.W., dan Lim D. H. Prediction of Residual Stree for Dissimilar Metals Welding at Nuclear Power Plants

- using Fuzzy Neural Network Models, *Nuclear Engineering and Technology*, Vol 29 No 4 August, Korea, p. 337-347. , (2007)
2. Ali Z., *Fundamentals of Neural Network*, CRC Press LLC. (2001)
 3. Bassir D. H., Tang X. G., and Zhang W. H., Material Optimization with Mixed Variables Based on Genetic Algorithm: in International Conference on Engineering Optimizations, Rio de Janeiro, Brazil. (2008)
 4. Kaufman J.G, *Properties of Aluminium Alloys, Tensile, Creep and Fatigue Data at High and Low Temperatures*, ASM International. (2008)
 5. Donald R. A., and Phule P. P., Properties versus Percent Cold Work: *The Science and Engineering Of materials*, Nelson, a division of Thomson, Canada, p. 269, 273. (2006)
 6. Kusumadewi S., *Artificial Intelligence (Teknik dan Aplikasinya)*, Penerbit Graha Ilmu, Yogyakarta. (2003)
 7. Mark J. J., Chapman, Colin, and Duda J., Continuum structural topology design with genetics algorithms, *Computing Methods Appl. Mechanical. Energy*, 186, ELSEVIER, USA, p 339-356. (2000)
 8. Serkan T., and Fahrettin O., Flow curve prediction of A-Mg alloys under warm forming conditions at various strain rates by ANN, *Journal Applied Soft Computing* 11, Elsevier. (2011)