

## **PENDEKATAN NEURAL NETWORK TERHADAP SIFAT MEKANIK MATERIAL PADA TINGKAT BEBAN BERBEDA**

**Mike Susmikanti<sup>1)</sup>, Ghofir<sup>2)</sup>**

<sup>1,2)</sup>Pusat Pengembangan Informatika Nuklir

Badan Tenaga Nuklir Nasional

Kawasan PUSPIPTEK Gd. 71, Tangerang Selatan Telp (021)-7560905

e-mail : [mike@batan.go.id](mailto:mike@batan.go.id)

### **Abstrak**

*Dalam bidang industri khususnya dalam pembangunan PLTN merupakan hal penting untuk mengetahui kondisi material yang digunakan. Berkaitan dengan penggunaan material, dilakukan pemodelan sifat mekanik material khususnya terhadap jenis stainless steel AISI-416. Material tipe AISI-416 merupakan salah satu material dengan komposisi yang tahan terhadap korosi. Pemodelan dilakukan pada beberapa tingkat pembebanan yang berbeda menggunakan neural network. Data pembelajaran menggunakan data hasil eksperimen. Dalam simulasi pelatihan dipilih metoda backpropagation dengan optimisasi menggunakan Levenberg-Marquardt. Diperoleh pemodelan alur stress terhadap jenis stainless steel AISI-416 pada simulasi beberapa tingkat beban yang berbeda.*

**Kata Kunci :** *Neural Network, Backpropagation, Levenberg-Marquardt, Stainless Steel, Stress, Strain*

### **1. PENDAHULUAN**

Dalam beberapa tahun, jenis stainless steel martensitic banyak digunakan dalam bidang industri dikarenakan tingginya kekuatan material, mempunyai kemudahan dalam pengerjaan dan biaya murah. Stainless steel termasuk *martensitic steel* tipe AISI-416 mempunyai ketahanan yang cukup terhadap korosi. Mempunyai sifat yang tahan dalam pengerjaan dan perlakuan panas, bahkan pada reaktor fusi. Dalam perkembangannya, jenis ini cukup kompetitif secara ekonomis. Disisi lain, *martensitic steel* menjadi lebih berperan dalam penerapannya ditinjau dari strukturnya. Terdapat beberapa macam perubahan dari bahan yang digunakan diantaranya akibat umur, temperatur serta efek radiasi yang dikenakan. Pemodelan dan simulasi merupakan salah satu cara membantu mendukung suatu pendapat dan keputusan untuk mengetahui bagaimanakah sifat mekanik bahan. Sifat mekanik bahan dapat dinyatakan diantaranya dengan melihat trend alur stress dengan tingkatan beban yang berbeda.

Metoda *Backpropagation* merupakan salah satu pembelajaran dengan pengawasan pada sistem jaringan syaraf yang sangat sesuai dalam banyak kasus. Diperlukan suatu rancangan dalam neural network dengan sejumlah spesifikasi untuk identifikasi yang terdiri dari sejumlah input dan neuron. Sejumlah neuron digunakan untuk membedakan klasifikasi pada pengenalan trend alur stress dengan tingkatan beban yang berbeda. Algoritma *Levenberg-Marquardt* dirancang untuk mendekati kecepatan pelatihan seperti pelatihan pada jaringan *feedforward*.

Dalam hal ini diambil beberapa tingkatan beban terhadap bahan stainless steel tipe AISI-416 sebagai data pembelajaran terhadap model alur stress. Beberapa data pembelajaran ini diambil dari data hasil eksperimen. Dalam pelatihan diambil beberapa data contoh, kemudian dilakukan beberapa simulasi. Untuk identifikasi dalam sistim jaringan syaraf digunakan metoda *Backpropagation*. Dalam efisiensi pelatihan dipilih algoritma *Levenberg-Marquardt*. Keseluruhan pembelajaran, pelatihan dan simulasi identifikasi pemodelan alur stress menggunakan MATLAB.

### **2. TINJAUAN PUSTAKA**

Sumantra Mandal (2009), telah melakukan penelitian dan penulisan pemodelan artificial neural network untuk mengevaluasi dan memprediksi sifat deformasi dari stainless steel tipe AISI 304L selama torsi dengan temperatur tinggi. Penulisan penelitian tentang prediksi alur kurva dari logam *A-Mg* diatas kondisi temperatur kamar pada beberapa tingkat strain dengan artificial neural network telah dilakukan oleh Serkan Toros (2011). Sedangkan Ajay K. (2012) telah melakukan penelitian dan menulis mengenai sifat kompresif atau mekanik dari stainless steel AISI-416 pada tingkatan loading yang berbeda dalam eksperimen.

Dalam simulasi dan pemodelan ini, penulis akan melakukan pendekatan pemodelan menggunakan artificial neural network terhadap sifat mekanik suatu material pada tingkat beban berbeda khususnya stainless steel sejenis AISI-416. Diharapkan pendekatan pemodelan ini dapat digunakan untuk mengetahui apakah suatu

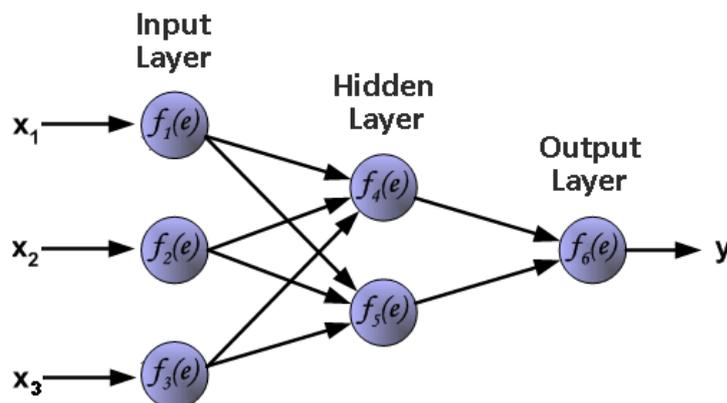
komposisi material stainless steel yang sejenis dengan type *AISI-416* mempunyai sifat mekanik bahan yang serupa atau tidak sama dikarenakan adanya perlakuan beberapa tingkatan beban.

### 2.1. Artificial neural network

Pemodelan berbasis jaringan syaraf tiruan merupakan pembelajaran dan adaptasi suatu obyek. Terdapat beberapa metode dalam pembelajaran dengan pengawasan pada jaringan syaraf tiruan diantaranya metode *back propagation*. Metode pembelajaran *backpropagation* diperoleh dengan melakukan taksiran kuadrat terkecil (*Least Mean Square*) pada jaringan lapisan ganda. Jaringan neuron menggunakan metode *backpropagation* dengan *multi-layer* dinyatakan pada Gambar 1.

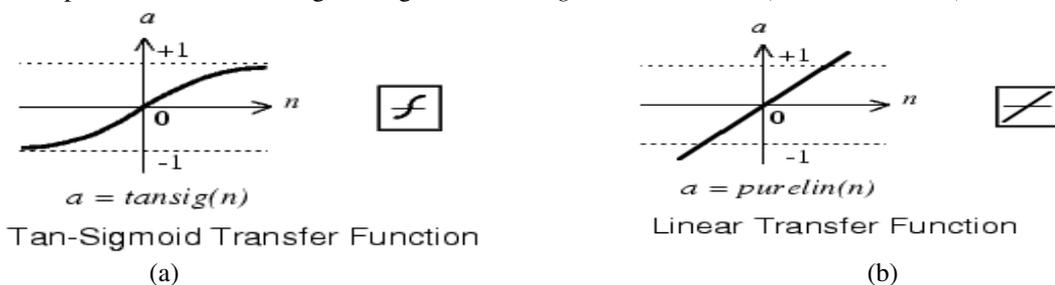
Dalam proses *backpropagation*, unit vektor input ( $X$ ) menerima sinyal atau tanda dan menyebarkan sinyal ke unit lapisan tersembunyi (*hidden layer*) yang menentukan sinyal aktivasi  $f(e)$  sebagai respon dari unit lapisan masukan (input) sebagai faktor bobot. Selanjutnya, unit lapisan tersembunyi akan menyebarkan sinyal respon tersebut ke unit lapisan keluaran (output). Unit lapisan output juga menentukan sinyal aktivasi sebagai respon terhadap sinyal yang berasal dari unit lapisan tersembunyi untuk pendekatan yang diberikan (Zilouchian, 2001).

Selama pelatihan, setiap unit membandingkan nilai aktivasi dengan nilai target untuk mendapatkan nilai error yang berhubungan dengan pendekatan yang diberikan. Hal ini dilakukan dengan menggunakan prinsip minimisasi fungsi error. Berdasarkan nilai error ini, faktor selisih  $\Delta k$  dihitung. Nilai  $\Delta k$  akan digunakan untuk memodifikasi fungsi bobot antara unit hidden layer dan unit output. Digunakan pendekatan *Levenberg-Marquardt* untuk kecepatan pelatihan ketika fungsi kinerja dengan bentuk nilai jumlah kuadrat dilakukan optimisasi, seperti pelatihan dalam jaringan *feedforward*.



Gambar 1. Jaringan neuron dengan metode backpropagation

Fungsi aktivasi yang dapat digunakan pada setiap unit antara lain *Tan-Sigmoid* dan *Linear*. Kedua fungsi aktivasi dinyatakan pada Gambar 2, masing-masing untuk *Tan-Sigmoid* dan *Linear* (Zilouchian, 2001).



Gambar 2. Fungsi aktivasi (a) Tan-Sigmoid dan (b) Linear

### 2.2. Alur Stress Material

Pengujian *stress* (tegangan) dilakukan terhadap penampang lintang ( $A$ ) spesimen material apabila dikenakan suatu gaya atau beban. Sedangkan pengujian *strain* (regangan) dilakukan terhadap material dengan panjang awal tertentu sehingga diperoleh perubahan panjang material tersebut. Dalam eksperimen, berdasarkan pada teori

perambatan gelombang, engineering stress ( $\sigma_s$ ), engineering strain ( $\varepsilon_s$ ) dan tingkat strain ( $\varepsilon_z$ ) dari spesimen dinyatakan masing-masing dalam persamaan (1), (2) dan (3) (Ajay K. dkk, 2012),

$$\sigma_s = E \frac{A}{A_z} \varepsilon_t \quad (1)$$

$$\varepsilon_s = \frac{-2C_0}{L} \int_0^t \varepsilon_t dt \quad (2)$$

$$\varepsilon_z = \frac{-2C_0 A}{L} \varepsilon_t \quad (3)$$

$E$  = Modulus elastisitas material,  $A$  = luas penampang lintang material,  $A_z$  = luas penampang lintang spesimen,  $C_0$  adalah panjang kecepatan gelombang stress dalam tekanan pada material,  $L$  = tebal spesimen. Setelah diperoleh engineering stress dan engineering strain diperoleh hubungan stress dan strain sesungguhnya (*True Stress* dan *True Strain*) yang dinyatakan pada persamaan (4) dan (5) (Donald. dkk, 2006),

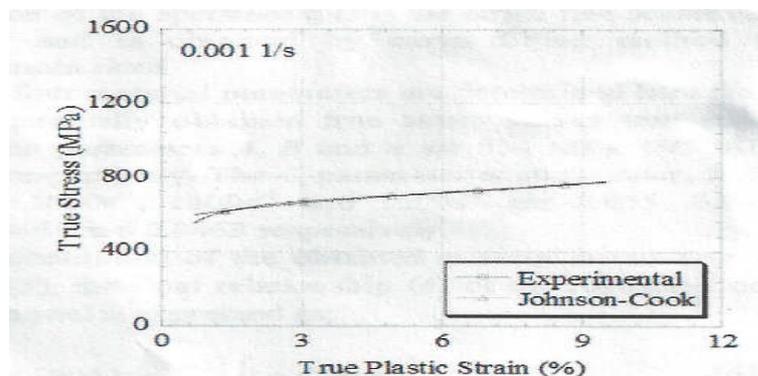
$$\sigma_t = \sigma_s (1 + \varepsilon_s) \quad (4)$$

$$\varepsilon_t = \ln(1 + \varepsilon_s) \quad (5)$$

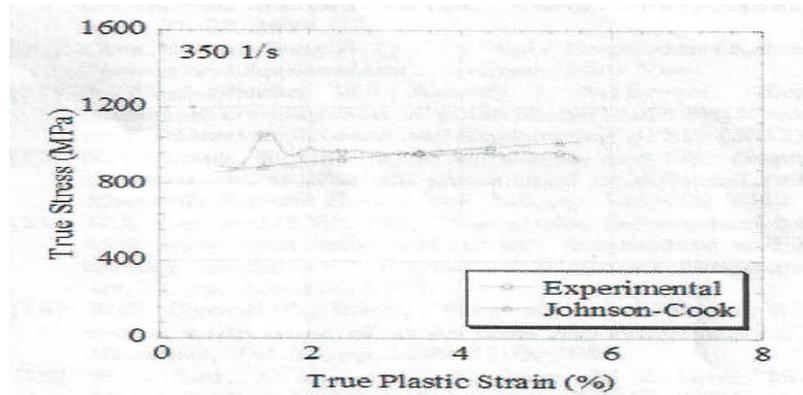
### 3. METODE PENELITIAN

Sifat mekanik spesimen *stainless steel AISI-416* dibawah *quasi-static* (keadaan keseimbangan) dan tekanan beban dinamik akan dianalisis dalam hal ini. *Stainless steel* tipe *AISI -416* yang digunakan dalam penelitian ini mengandung komposisi kimia dalam presentase masing-masing sebesar, C : 0,142, Si : 0,4025, Mn : 0,862, Cr : 13,03, Ni : 0,155, Mo : 0,1756, Cu : 0,0523, Al : 0,0145, V : 0,0449, S : 0,359, P : 0,0134, Co : 0,0184, Fe : 84,72. Dalam data eksperimen, dipilih spesimen silinder dengan ketebalan 12 mm dan diameter 8 mm yang dipilih pada variasi ketebalan dan diameter spesimen silinder kurang dari  $\pm 1\%$ . (Ajay K. dkk, 2012)

Dilakukan pendugaan pemodelan terhadap analisis perbandingan kurva stress-strain tekanan pada beberapa tingkatan beban menggunakan *neural network*. *Yield stress* dalam kurva eksperimen diukur pada *0,2% offset strain* sampai *10%*. Sehingga batasan *engineering strain* 0,2% sampai 10%. Diketahui bahwa konstanta *true yield stress (true stress)* dan *engineering yield stress* dibawah kondisi *quasi-static* ( $0,001 s^{-1}$ ) adalah 550 MPa. Dari data eksperimen, diambil sampel trend alur stress dibawah kondisi *quasi-static* ditunjukkan pada Gambar 3(a) dan nilai *engineering yield stress* pada tingkat strain  $350s^{-1}$  pada Gambar 3(b). Demikian pula untuk nilai-nilai  $750s^{-1}$ ,  $1050s^{-1}$ ,  $1300s^{-1}$  dan  $1500s^{-1}$  dimulai pada 882 MPa, 1033 MPa, 884 MPa, 857 Mpa, 857 Mpa untuk nilai true stress lainnya. Sedangkan nilai tingkat strain sebagai variabel bebas dapat diambil pada nilai-nilai misalnya 0,2; 0,3; 0,6; 1,0; 2,0; 2,5; 3,0; 4,0; 6,0 dan 9,0 % (*True plastic strain*)

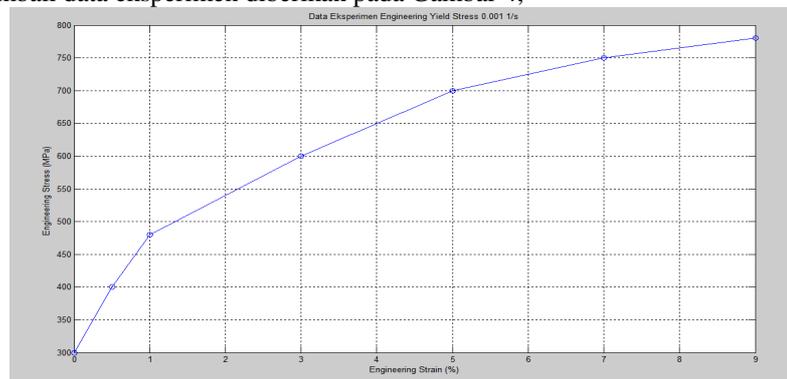


Gambar 3(a). Data eksperimen  $0,001s^{-1}$  kondisi static (Ajay K. Behera, 2012)



**Gambar 3(b).** Data eksperimen pada  $350 \text{ s}^{-1}$  (Ajay K. Behera, 2012)

Adapun plotting kembali data eksperimen diberikan pada Gambar 4,



**Gambar 4.** Ploting data eksperimen

Pertama dilakukan pembentukan pemodelan untuk input pembelajaran terdiri dari *yield stress* dibawah kondisi keseimbangan dengan *engineering strain* 0,2% sampai 10% terhadap *engineering stress* yang diperoleh dari hasil eksperimen dengan nilai-nilai berikut;

$$\begin{aligned}
 p &= [0.001 \ 0.001 \ 0.001 \ 0.001 \ 0.001 \ 0.001 \ 0.001 \ 0.001 \ 0.001 \ 0.001]; \\
 &\quad 0.2 \ 0.3 \ 0.6 \ 1.0 \ 2.0 \ 2.5 \ 3.0 \ 4.0 \ 6.0 \ 9.0]; \\
 &\quad \% \text{ Strain } (\%) \\
 t &= [350 \ 410 \ 450 \ 550 \ 600 \ 650 \ 680 \ 720 \ 750 \ 780]; \\
 &\quad \% \text{ Engineering stress (Mpa)}
 \end{aligned}$$

Dilakukan normalisasi data terlebih dahulu atau preprocessing. Selanjutnya membangun jaringan syaraf *feedforward* dan dilakukan pembelajaran berikut ini, (Serkan Toros dkk, 2011)

```

[pn,minp,maxp,tn,mint,maxt] = premmx(p,t);
net = newff(minmax(pn),[6 1],{'tansig' 'purelin'},'trainlm');
net=train(net,pn,tn);
    
```

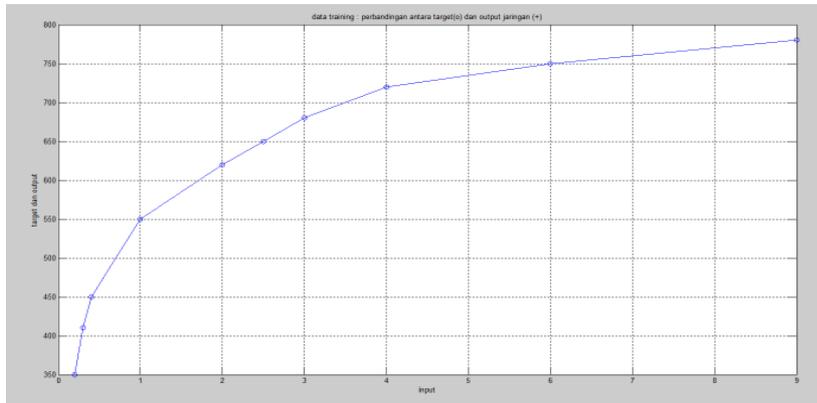
Pelatihan serta simulasi yang dilakukan (Sumantra Mandal dkk, 2009), salah satunya diberikan dengan pernyataan-pernyataan berikut,

```

net1 = newff(R,TR,20);
[net,tr] = train(net1,R,TR);
out = sim(net,R);
    
```

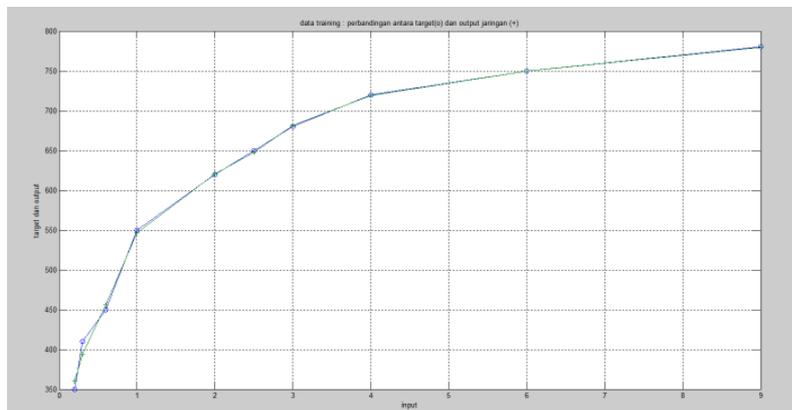
#### 4. HASIL DAN PEMBAHASAN

Hasil pembelajaran data eksperimen diperoleh sebagai berikut pada Gambar 5,



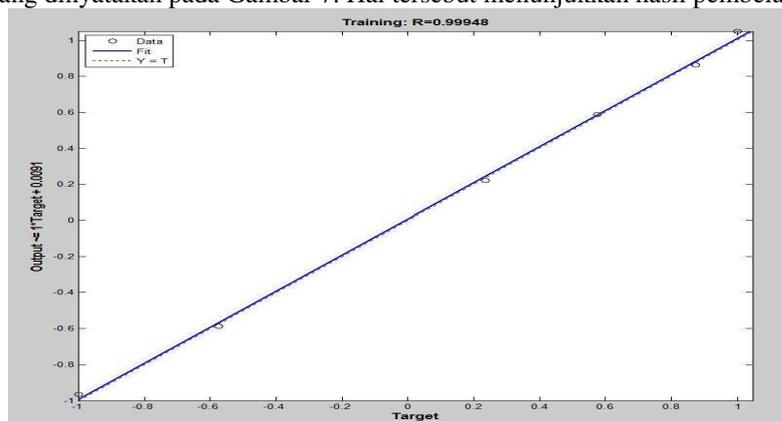
**Gambar 5.** Hasil pembelajaran data eksperimen

Diperoleh plot masukan dan output atau target dari hasil pembelajaran berikut pada Gambar 6,



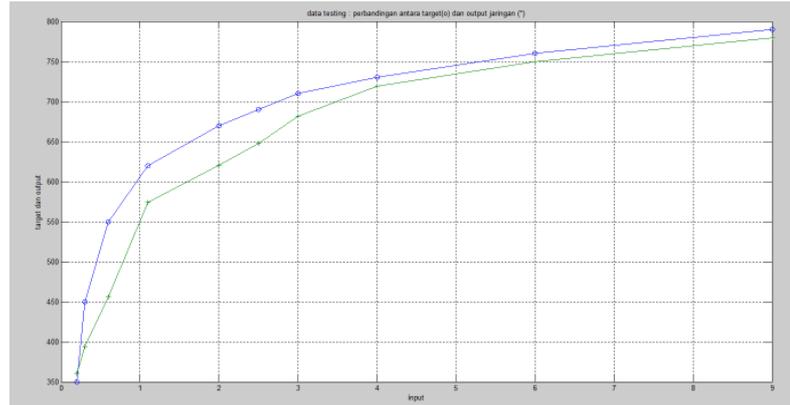
**Gambar 6.** Kurva taksiran pembelajaran data hasil eksperimen

Koefisien kesuaian hasil pembelajaran yang dinyatakan dengan parameter  $R$ , menunjukkan  $R = 0.99948$  yang mendekati nilai 1 yang dinyatakan pada Gambar 7. Hal tersebut menunjukkan hasil pembelajaran yang baik.



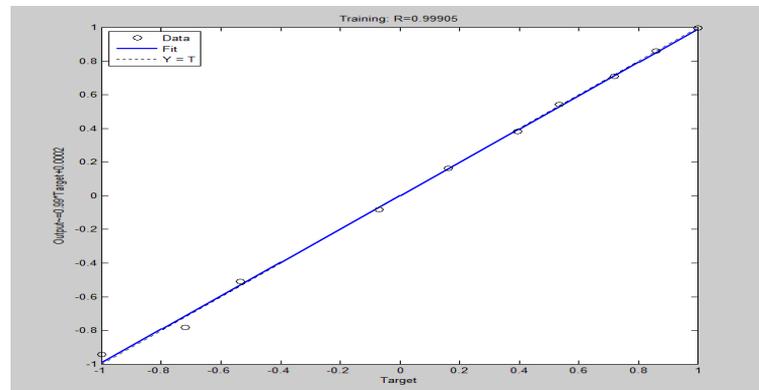
**Gambar 7.** Kurva taksiran pembelajaran data hasil eksperimen

Diperoleh plot masukan dan output dari hasil pelatihan berikut pada Gambar 8,



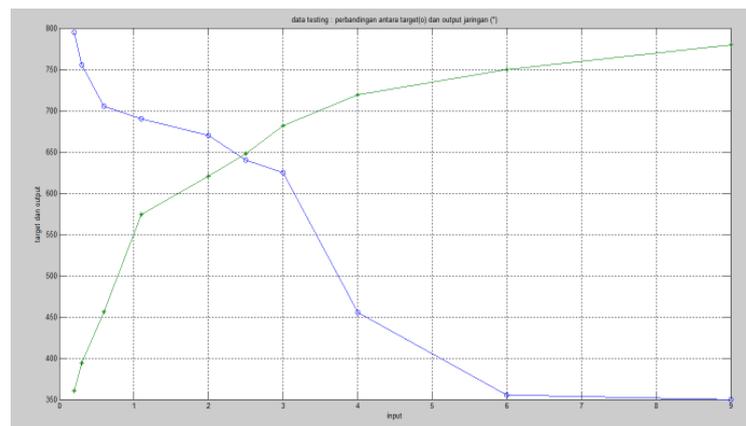
**Gambar 8.** Data masukan dan pelatihan

Koefisien kesuaian hasil pelatihan menunjukkan  $R = 0.99905$  yang mendekati nilai 1 yang dinyatakan pada Gambar 9. Hal tersebut menunjukkan hasil pelatihan yang baik untuk data pelatihan yang diberikan.



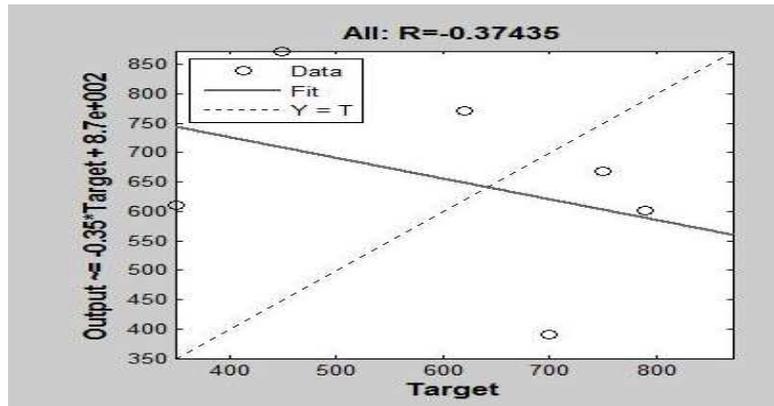
**Gambar 9.** Kurva hasil taksiran pada pelatihan

Plot masukan dan target dari hasil simulasi dinyatakan berikut pada Gambar 10,



**Gambar 10.** Kurva hasil simulasi pelatihan

Koefisien kesuaian hasil pembelajaran yang dinyatakan dengan parameter  $R$ , menunjukkan  $R = 0.37435$  dinyatakan pada Gambar 11. Hal tersebut menunjukkan hasil masukan simulasi, yang diduga “tidak mengikuti” alur stress, ternyata benar teridentifikasi “tidak mengikuti” alur stress untuk jenis stainless steel tipe AISI-416.



Gambar 11. Kurva hasil simulasi

Hasil pelatihan dan simulasi dengan mengambil data sampel masing masing sebanyak 10 untuk masing-masing tingkat strain  $350s^{-1}$ ,  $750s^{-1}$ ,  $1050s^{-1}$ ,  $1300s^{-1}$  dan  $1500s^{-1}$  diberikan pada Tabel 1 berikut, Diperoleh pemodelan alur stress terhadap stainless steel jenis *AISI-416* dengan simulasi beberapa tingkat beban yang berbeda yaitu  $0,001s^{-1}$ ,  $350s^{-1}$ ,  $750s^{-1}$ ,  $1050s^{-1}$ ,  $1300s^{-1}$  dan  $1500s^{-1}$ . Engineering yield stress dibawah kondisi quasi-static ( $0,001s^{-1}$ ) dan Engineering yield stress pada beberapa tingkat strain dimulai pada 882 MPa, 1033 MPa, 884 MPa, 857 MPa dan 857 MPa. Sedangkan true yield stress adalah pada 890 MPa, 1048 MPa, 852 MPa, 865 MPa dan 866 MPa.

Tabel 1. Hasil Identifikasi simulasi untuk masukan alur stress

Tingkat Strain ( $s^{-1}$ )	Kesesuaian		
	Pembelajaran	Pelatihan	Simulasi
0,001	100%	100%	100%
350	100%	100%	90%
750	100%	90%	90%
1050	100%	90%	90%
1300	100%	90%	80%
1500	100%	80%	80%

## 5. KESIMPULAN

Dilakukan pemodelan sifat mekanik bahan stainless steel untuk beban kompresif menggunakan pendekatan neural network. Pemodelan dilakukan terhadap salah satu jenis stainless steel tipe *AISI-416* pada beberapa tingkat beban yang berbeda. Dengan menggunakan data hasil eksperimen sebagai data pembelajaran menggunakan metoda backpropagation diperoleh pemodelan aliran stress dari stainless steel *AISI-416* dalam simulasi untuk beberapa tingkat beban yang berbeda.

## DAFTAR PUSTAKA

- Ajay K. Behera, Nilamber K. Singh, Maloy K Singha, 2012 “Compressive Behavior of AISI-416 Stainless Steel at Different Rates of Loading”, Proceedings of the World Congress on Engineering Vol III London UK
- Donald R. Askeland, Phule, P. Pradeep 2006, *The Science and Engineering Of materials*, Nelson, a division of Thomson Canada
- Serkan Toros, Fahrettin Ozturk, 2011, “Flow curve prediction of A-Mg alloys under warm forming conditions at various strain rates by ANN”, Journal Applied Soft Computing 11 homepage : [www.elsevier.com/locate/asoc](http://www.elsevier.com/locate/asoc)
- Sumantra Mandal, P.V. Sivaprasa, S. Venugopal, K.P.N. Murthy, 2009, “Artificial neural network modeling to evaluate and predict the deformation behavior of stainless steel type AISI 304L during hot torsion”, Journal Applied Soft Computing 9 homepage : [www.elsevier.com/locate/asoc](http://www.elsevier.com/locate/asoc)
- Zilouchian, Ali, *Fundamentals of Neural Network*, 2001. CRC Press LLC