
PENGEMBANGAN METODA VALIDASI SENSOR DENGAN MENGUNAKAN AUTOASSOCIATIVE NEURAL NETWORK

Kristedjo Kurnianto

Pusat Pengembangan Teknologi Reaktor Riset - BATAN

ABSTRAK

PENGEMBANGAN METODA VALIDASI SENSOR DENGAN MENGGUNAKAN AUTOASSOCIATIVE NEURAL NETWORK. Penurunan unjuk kerja sebuah sensor umumnya terjadi bersamaan dengan operasi reaktor sehingga metoda perawatan periodik tidak mampu mendeteksinya. Penelitian ini menitikberatkan pada metode perawatan prediktif yaitu validasi sinyal sensor yang dapat memberikan peringatan dini adanya penurunan unjuk kerja dan kegagalan pada sensor secara *on-line* tanpa mengganggu operasi reaktor. Dengan menggunakan sinyal-sinyal dari sensor yang memiliki korelasi tinggi dibuat sebuah model dengan menggunakan *Auto Associative Neural Network* (AANN) yang memiliki jumlah input dan output yang sama banyaknya. AANN dilatih dengan menggunakan data pada berbagai kondisi operasi sehingga menghasilkan sinyal output yang sama dengan input pada keadaan normal. Adanya gangguan anomali pada salah satu input akan diindikasikan pada perbedaan sinyal output dan input pada kanal yang bersangkutan (sinyal deviasi). Sinyal deviasi yang dihasilkan selanjutnya dianalisis dengan penganalisis sinyal deviasi jenis SPRT (*Sequential Probability Ratio Test*). Pengujian model AANN dilakukan dengan menggunakan data *off-line* dari RSG-GAS dan PWR Borssele untuk memperoleh topologi AANN yang optimal dan teknik pelatihan yang optimal. Selanjutnya dilakukan penerapan metoda validasi ini pada reaktor sebenarnya yaitu dengan cara mengintegrasikan sistem validasi sensor pada Sistem Monitoring Reaktor (SIMOR) RSG-GAS. Pengujian pada sistem SIMOR dilakukan dengan menggunakan sinyal-sinyal yang memiliki korelasi tinggi dengan daya reaktor. Berdasarkan pengamatan awal, sistem validasi sensor ini dapat berfungsi dengan baik dan hingga saat ini belum menemukan adanya penurunan unjuk kerja sensor ataupun kegagalan sensor.

ABSTRACT

DEVELOPMENT OF SENSOR VALIDATION METHOD USING AUTOASSOCIATIVE NEURAL NETWORK. Performace deterioration of a sensor plays a significant role in a nuclear reactor safety and operation. The periodical maintenance method usually has some problems especially when dealing with sensor performance deterioration since the degradation or failure usually occur when the reactor in operation.. This research is focused on predictive maintenance method ie. sensor signal validation which provides a sensor degradation or sensor failure early warning system. Using sensor signals, which are considered high correlated, an AANN was trained to produce similar input and output signal on various normal mode operations. The difference between input and output (deviation signal) can be used to determine anomaly occurrence. The deviation signals are then be analyzed using SPRT (Sequential Probability Ratio Test) deviation signal analyzer. To get an optimum and appropriate learning method of AANN, the model was trained using off-line dataset from RSG-GAS and Borssele PWR plant. Finally, the sensor validation system was integrated into RSG-GAS reactor monitoring system (SIMOR). The on-line system test showed that the neural network successfully monitored the sensor signals status by the using of power correlated signals. Based on the preliminary observation, the sensor degradation and or sensor failure are not detected.

Kata kunci: Validasi Sensor, neural network, deteksi drift.

PENDAHULUAN

Reaktor Nuklir dalam operasinya selalu melibatkan sistem yang besar dan kompleks. Sistem kompleks tersebut menjadi sarat dengan instrumentasi dan menjadi sangat peka terhadap kegagalan sensor dan sistem elektroniknya. Pengoperasian reaktor nuklir dengan aman dan ekonomis membutuhkan verifikasi status sistem instrumentasi pengukuran parameter kritis. Sebagai contoh, sinyal-sinyal yang berhubungan dengan daya reaktor adalah salah satu sinyal yang sangat menentukan kinerja sebuah reaktor nuklir.

Metode konvensional untuk validasi sensor adalah mengoperasikan sensor redundan dan melakukan kalibrasi berkala untuk memastikan sensor beroperasi dengan baik dan benar. Metode kalibrasi berkala biasanya membutuhkan proses dalam keadaan *shut-down* dan sensor diambil atau dilepaskan dari sistem untuk dikalibrasi. Hal tersebut berakibat pada meningkatnya kemungkinan kerusakan sensor pada saat kalibrasi karena kalibrasi dilakukan pada lingkungan yang berbeda dari sistem pengukuran yang sesungguhnya.

Perawatan berbasis kondisi saat ini menjadi lebih diminati dari perawatan berkala. Perubahan metoda perawatan ini berdampak pada perlunya dikembangkan metode-metode perawatan berbasis kondisi yang biasanya dilakukan bersamaan dengan operasi sistem yang diamati. Proses monitoring dilakukan tanpa mengganggu operasi sistem yang diamati.

Dunia et al. [1] mendefinisikan validasi sensor sebagai deteksi kegagalan sensor yang diikuti dengan identifikasi dan rekonstruksi sensor terkait dengan sebuah model. Tulisan ini akan lebih memfokuskan pada deteksi kegagalan dan recovery sinyal sensor pada sistem kompleks seperti reaktor nuklir dengan menggunakan jaringan saraf tiruan atau biasa disingkat ANN (*Artificial Neural Network*) sebagai model.

Secara teoritis penunjukkan besaran dari sebuah sensor dapat digantikan oleh sensor-sensor lain yang memiliki korelasi tinggi [2]. Sebagai contoh indikator suhu sebuah bejana tertutup, secara tidak langsung dapat diukur dengan memperhatikan tekanan dan volumenya. Masalah utama yang muncul adalah bagaimana membuat model yang dapat merepresentasikan karakteristik dari sistem yang diamati. ANN menjadi salah satu pilihan dalam pemodelan sistem yang cukup baik karena ANN mampu belajar dari data operasi yang ada dan dapat mensimulasikan sistem yang memiliki hubungan non-linear dan kompleks.

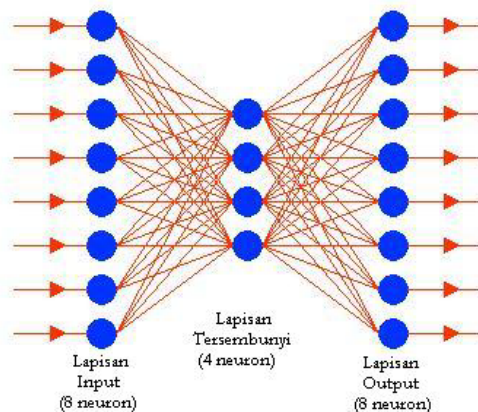
Validasi sensor pada tulisan ini dilakukan dengan cara melakukan pemilihan parameter-parameter pengukuran sistem instrumentasi RSG-GAS dan PWR Borssele yang memiliki korelasi tinggi. Parameter-parameter tersebut kemudian diamati pada berbagai mode operasi seperti start-up, steady-state dan shutdown. Data yang telah dikumpulkan kemudian digunakan untuk pelatihan dan pengujian beberapa model ANN. Kemudian, dengan menggunakan berbagai jenis topologi dan metode pelatihan, dicari AANN yang paling optimal yang dapat menghasilkan sinyal prediksi dan dapat menggantikan sinyal sensor yang mengalami kegagalan (*signal recovery*). Akhirnya, model yang telah dilatih dan memberikan hasil yang memuaskan untuk data *off-line*, dipasang pada sistem instrumentasi reaktor secara *on-line* untuk memonitor jika ada penurunan unjuk kerja atau kegagalan sensor.

TEORI

Auto Associative Neural Network

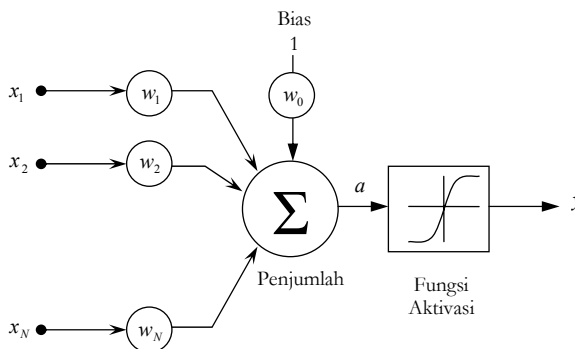
Autoassociative Neural Network (AANN) adalah sebuah *feedforward Neural Network* yang dilatih untuk menghasilkan mapping identitas (*mapping identity*) antara input dan output dan menggunakan propagasi balik (*back propagation*) untuk pelatihannya. Kramer [3] dalam tulisannya menjelaskan bahwa fitur utama sebuah AANN adalah memiliki input dan output yang sama dan biasanya memiliki topologi *bottleneck* (jumlah neuron pada hidden layer lebih sedikit dari input dan output layer) sebagai representasi dari kompresi informasi akibat kuatnya korelasi antar input.

Seperti *Feedforward Neural Network* pada umumnya, AANN memiliki sebuah lapisan input dan output dan satu atau lebih lapisan tersembunyi (*hidden layer*). Setiap lapisan terdiri dari beberapa neuron dimana setiap neuron terhubung ke seluruh neuron pada lapisan berikutnya (*fully connected*). Semua sinyal neural menyebar dalam arah maju (*feed forward*) melalui setiap lapisan network dari lapisan input ke output. Perambatan balik dimungkinkan hanya pada saat pelatihan untuk mengkoreksi nilai bobot sebuah neuron berdasarkan nilai error (selisih antara target dan output dari neuron) neuron bersangkutan. Gambar 1 mengilustrasikan sebuah AANN dengan topologi 8-4-8.



Gambar 1. AANN dengan topologi 8-4-8

Seperti neuron pada jaringan syaraf manusia, artifisial neuron pada setiap lapisan berfungsi menghitung hasil fungsi aktivasi dari jumlahan terbobot input-inputnya. Fungsi aktivasi dapat dipilih seperti fungsi sigmoid, fungsi linear, fungsi step atau radial basis. Jenis fungsi aktivasi tergantung jenis sistem yang dimodelkan. Untuk topologi AANN dalam tulisan ini menggunakan fungsi aktivasi logistik sigmoid pada lapisan tersembunyi dan fungsi aktivasi linear pada lapisan input dan output. Gambar 2 menunjukkan skema sebuah artifisial neuron.



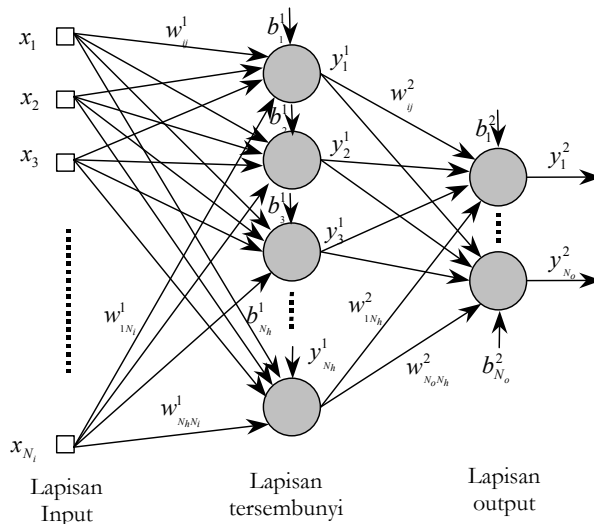
Gambar 2. Blok diagram sebuah artifisial neuron

Hubungan matematis sebuah neuron artifisial dapat dinyatakan dalam persamaan (1), dimana fungsi aktivasi sigmoid ditunjukkan pada persamaan (2).

$$y = f(a) = f\left(\sum_{i=1}^n w_i x_i + w_0\right) \quad (1)$$

$$f(x) = \frac{1}{1 - e^{-x}} \quad (2)$$

ANN biasanya terdiri atas beberapa lapisan atau sering disebut sebagai *multi layer perceptron* (MLP). MLP dengan lapisan tersembunyi tunggal didefinisikan dengan jumlah neuron input (N_i), jumlah neuron pada lapisan tersembunyi (N_h) dan jumlah neuron pada lapisan output (N_o). Topologi ini ditulis dalam bentuk $N_i - N_h - N_o$, sehingga topologi 4-2-1 berarti sebuah ANN dengan 4 input, 2 unit neuron lapisan tersembunyi dan satu unit neuron output.



Gambar 3. Topologi umum MLP

Persamaan matematis MLP dalam format matriks dapat ditulis sebagai persamaan (3).

$$\mathbf{y}^2 = f_o(\mathbf{W}^2 \mathbf{y}^1 + \mathbf{b}^2) = f_o(\mathbf{W}^2 f_h(\mathbf{W}^1 \mathbf{x} + \mathbf{b}^1) + \mathbf{b}^2) \quad (3)$$

Dimana \mathbf{W}^1 adalah matriks pembobot input (ukuran $N_h \times N_i$ dan elemen matrik w_{ij}^1), \mathbf{W}^2 adalah matriks pembobot output (ukuran $N_o \times N_h$ dan elemen matrik w_{ij}^2), \mathbf{x} adalah vektor data, \mathbf{b}^1 adalah vektor bias pada lapisan tersembunyi, \mathbf{b}^2 adalah vektor bias lapisan output dan $f_o(\cdot), f_h(\cdot)$ adalah fungsi aktifasi output dan tersembunyi. Notasi persamaan (3) dapat disederhanakan dengan menganggap bias sebagai sebuah input konstan (biasanya +1 atau -1), sehingga panjang \mathbf{x} menjadi $N_i + 1$, ukuran \mathbf{W}^1 menjadi $N_h \times N_i + 1$ dan ukuran \mathbf{W}^2 menjadi $N_o \times N_h + 1$. Bentuk sederhana persamaan (3) menjadi

$$\mathbf{y} = \psi(x, w) = f_o(\mathbf{W}^2 f_h(\mathbf{W}^1 \mathbf{x})) \quad (4)$$

Algoritma propagasi balik untuk pelatihan

Pelatihan ANN pada dasarnya adalah masalah optimasi *cost-function*, dimana nilai bobot diatur sedemikian rupa sehingga output ANN (\mathbf{y}) mendekati atau sama dengan target (\mathbf{t}) berdasarkan sebuah *cost-function* seperti kesalahan rata-rata kuadrat (Mean Squared Error). Pelatihan propagasi balik dilakukan dengan cara meminimalkan fungsi kesalahan dengan merubah nilai pembobot. Algoritma pelatihan propagasi balik didasarkan pada algoritma *gradient descent*, pertamakali dikenalkan oleh Rumelhart [4], yang menghitung nilai gradient \mathbf{g}_k pada tiap *epoch* dan memperbaharui nilai bobot dengan menggunakan persamaan,

$$\begin{aligned}\mathbf{w}_{k+1} &= \mathbf{w}_k + \Delta\mathbf{w}_k \\ \Delta\mathbf{w}_k &= -\eta\mathbf{g}_k = -\eta \frac{\partial E_k}{\partial \mathbf{w}_k}\end{aligned}\quad (5)$$

dimana η (*learning rate*) adalah konstanta positif kecil (biasanya bernilai antara 0–1). Gradient \mathbf{g}_k pada persamaan (5) dihitung melalui dua fase.

Output network dihitung dengan perambatan maju dari lapisan input ke lapisan output, dari lapisan $l = 1$ ke $l = L$. Kemudian kesalahan E_p dihitung merambat mundur dari lapisan output ke lapisan input. Pada proses ini gradient \mathbf{g}_p dihitung menggunakan persamaan (6) dari lapisan $l = L$ ke $l = 1$.

$$\frac{\partial E_p}{\partial w_{ij}^{lm}} = -\delta_{i,p}^l y_{j,p}^{l-1} \quad (6)$$

dimana nilai δ diberikan oleh persamaan 7.

$$\begin{aligned}\delta_{i,p}^L &= (t_{i,p} - y_{i,p}^{L-1}) f'(a_{i,p}^L) \\ \delta_{j,p}^m &= f'(a_{j,p}^m) \sum \delta_{i,p}^l w_{ij}^{lm}, \quad m < L\end{aligned}\quad (7)$$

Jika fungsi aktivasi adalah logistik sigmoid, maka fungsi turunan menjadi sederhana

$$f'(a) = y(1 - y) \quad (8)$$

Proses ini berulang untuk epoch berikutnya sampai diperoleh nilai kesalahan (MSE) minimal.

Untuk mempercepat proses pembelajaran dan menghindari algoritma terjebak pada *local minima* (nilai minimum yang palsu), persamaan (5) dimodifikasi menjadi persamaan (9) dimana sebuah parameter *momentum* α (bernilai 0 – 1) ditambahkan

untuk mempercepat proses pembelajaran. Dengan $\alpha = 0.9$ dapat meningkatkan kecepatan pembelajaran 10 kali dari algoritma perambatan balik standar.

$$\Delta \mathbf{w}_k = -\eta \mathbf{g}_k + \alpha \Delta \mathbf{w}_{k-1} \quad (9)$$

Isu penting lain dalam proses pembelajaran ANN adalah inisialisasi bobot pada awal tahap pembelajaran. Pada umumnya nilai bobot diberi nilai awal dengan bilangan random yang kecil, namun beberapa peneliti mengajukan beberapa metode inisialisasi bobot awal dengan bilangan random uniform (i.i.d) [5] atau dengan inisialisasi bilangan random dengan rata-rata nol dan standar deviasi satu [6], $\sigma_w = m^{-1/2}$, dimana m adalah jumlah unit input.

EKSPERIMEN

Eksperimen pada penelitian ini dibagi menjadi dua bagian. Pertama, pelatihan AANN dengan menggunakan data secara *off-line* yang bertujuan untuk mendapatkan topologi AANN serta metode pelatihan yang optimal. Kedua, pengujian sistem validasi sensor pada sistem instrumentasi reaktor yang sebenarnya.

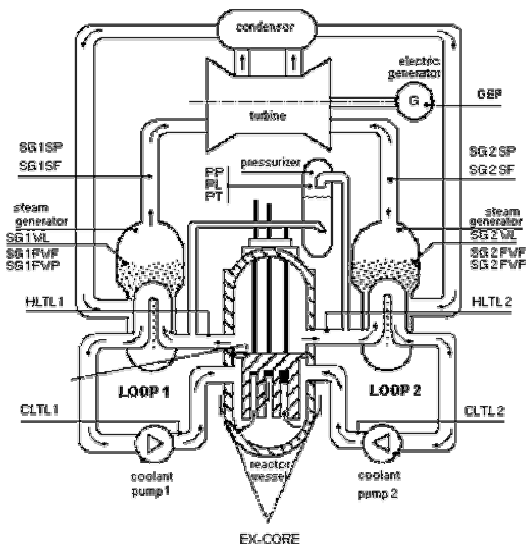
Data pelatihan yang digunakan pada eksperimen ini adalah data dari pengukuran sistem instrumentasi RSG-GAS dan PWR Borselle Belanda. Data pengukuran dari RSG-GAS diambil dari Sistem Monitoring Reaktor (SIMOR) dengan identifikasi sinyal seperti pada Tabel 1. Data diperoleh dengan waktu cuplik 2 detik dan data dikirim oleh komputer akuisisi SIMOR melalui jaringan dengan menggunakan protokol TCP/IP. Sedangkan data pelatihan untuk kasus reaktor Borselle diperoleh dari data SMORN-VII Benchmark. Identifikasi sinyal reaktor Borselle tampak ada Tabel 2. Data diperoleh dengan waktu cuplik 1 menit. Adapun gambar lokasi sensor yang diamati pada PWR Borselle ini dapat dilihat pada Gambar 4.

Tabel 1. Tabel Identifikasi sinyal dan kanal untuk data RSG-GAS

No	Nama Sinyal	Nama Kanal	Unit
1	Fluks Neutron	JKT03 CX811	%
2	Fluks Neutron	JKT03 CX821	%
3	Fluks Neutron	JKT03 CX831	%
4	Fluks Neutron	JKT03 CX841	%
5	Radiasi N-16	JAC01 CR811	%
6	Radiasi N-16	JAC01 CR811	%
7	Radiasi N-16	JAC01 CR811	%
8	Temperatur Inlet Teras	JE-01 CT811	°C
9	Temperatur Inlet Teras	JE-01 CT811	°C
10	Temperatur Inlet Teras	JE-01 CT811	°C

Tabel 2. Tabel Identifikasi sinyal dan kanal untuk data PWR Borselle

Kanal	Identifikasi Sinyal	Nama Kanal	Unit
1	Detektor Neutron Excore (D82) Pos. 50°	EXCORE	mV
2	Tekanan Feedwater Steam Generator 1	SG1FWP	kgf/cm ²
3	Tekanan Feedwater Steam Generator 2	SG2FWP	kgf/cm ²
4	Beda Suhu Kalang 1 (HLTL1 - CLTL1)	DTL1	Derajat(°C)
5	Beda Suhu Kalang 2 (HLTL2 - CLTL2)	DTL2	Derajat(°C)
6	Laju Alir Feedwater Steam Generator 1	SG1FWF	T/h
7	Laju Alir Feedwater Steam Generator 2	SG1FWF	T/h
8	Tekanan uap Steam Generator 1	SG1SP	kgf/cm ²
9	Tekanan uap Steam Generator 2	SG2SP	kgf/cm ²
10	Laju Alir Uap Steam Generator 1	SG1SF	T/h
11	Laju Alir Uap Steam Generator 2	SG2SF	T/h
12	Tenaga Listrik Dibangkitkan	GEP	MW-elec.



Gambar 4. Peta lokasi sensor yang diamati pada reaktor PWR Borselle

Data pelatihan diambil dari 600 data pertama, sedangkan 100 data berikutnya digunakan sebagai data validasi. Data validasi digunakan untuk mencegah pelatihan AANN mengalami *overfitting*. Sisa data lainnya digunakan untuk data tes. Pengujian kegagalan sensor dilakukan pada data tes sehingga menjamin evaluasi unjuk kerja AANN karena selama proses pelatihan data ini tidak pernah diberikan.

Pelatihan AANN dilakukan dengan menggunakan perangkat lunak TRAJAN. Program ini dapat membuat dan melatih ANN pada berbagai topologi, sekaligus menyimpan hasilnya dan kemudian dapat dipanggil oleh program lain dengan WinAPI


(*Windows Application Program Interface*). Dengan fasilitas WinAPI ini, penulis membuat program dengan LabVIEW untuk melakukan pengujian pada kondisi normal maupun simulasi kegagalan.

HASIL DAN PEMBAHASAN

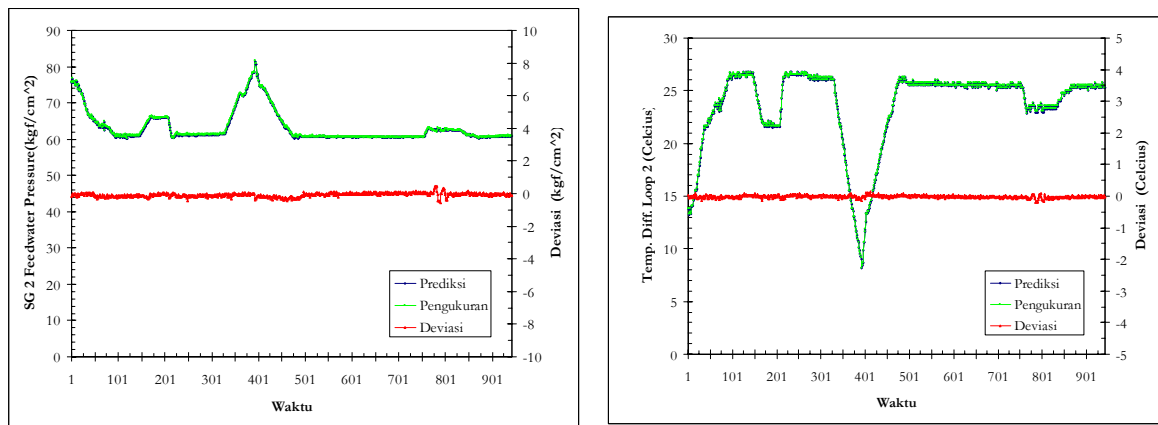
Pada kasus RSG-GAS, hasil pelatihan dengan menggunakan AANN 10-12-10 dapat dilihat pada gambar 5. Sinyal prediksi adalah sinyal yang dihasilkan oleh AANN, sinyal pengukuran merupakan hasil pengukuran dari sensor sedangkan sinyal deviasi adalah perbedaan antara prediksi dan pengukuran. Sinyal deviasi inilah yang kemudian digunakan sebagai bahan analisis untuk menentukan kondisi sebuah sensor.

Pada kasus PWR Borselle, hasil pelatihan dengan menggunakan AANN 12-8-12 dapat dilihat pada gambar 6.

Dari ke-dua belas hasil pengujian tampak bahwa prediksi dan pengukuran hampir berhimpit dan deviasi yang diperoleh relatif kecil. Hal ini menunjukkan AANN yang dikembangkan telah mampu memodelkan sistem berdasar data pelatihan dan mampu menghasilkan sinyal prediksi yang baik untuk data yang sebelumnya belum pernah diajarkan.



Gambar 5. Hasil pengujian data off-line kanal JKT03 CX811 dan kanal JE-01 CR811



Gambar 6. Hasil Pengujian data off-line kanal SG2FWP dan kanal DTL2 .

Hasil eksperimen dengan topologi dengan menggunakan 3 hidden layer memberikan hasil prediksi dan deviasi yang tidak jauh berbeda. Hal ini menunjukkan non-linearitas sistem yang diamati tidak begitu besar, sehingga pemodelan dengan lapisan tersembunyi tunggal sudah mampu memberikan unjuk kerja yang baik. Peningkatan kompleksitas AANN tidak memberikan sumbangan yang signifikan terhadap pemodelan sistem yang tingkat non-linearitasnya tidak begitu tinggi. Perlu dicatat pula bahwa proses pelatihan dengan topologi yang kompleks ini memakan waktu pelatihan yang lebih dan mudah terjebak pada *local minima*.

Setelah hasil pegujian dengan menggunakan data off-line menunjukkan hasil yang memuaskan. Sistem validasi sensor diintegrasikan pada sistem monitoring reaktor (SIMOR). Komputer akusisi data SIMOR, mengirim data setiap 2 detik ke komputer pemroses validasi sensor dengan menggunakan protokol TCP/IP. Komputer system validasi sensor kemudian akan menghasilkan sinyal deviasi yaitu selisih antara sinyal hasil prediksi AANN dan hasil pengukuran aktual (*on-line*). Dari hasil pengamatan awal, sistem mengindikasikan seluruh sensor yang diamati dalam keadaan normal.

KESIMPULAN

Validasi sensor dengan menggunakan AANN telah dilakukan. Hasil eksperimen dengan menggunakan data off-line dari Sistem monitoring reaktor (SIMOR) RSG-GAS dan PWR Borssele menunjukkan AANN dapat memprediksi sinyal hasil pengukuran dengan baik. Sinyal-sinyal prediksi ini dapat digunakan untuk mendeteksi adanya kegagalan atau penurunan unjuk kerja sensor dan juga dapat digunakan untuk

menyediakan sinyal pengganti dari sensor yang mengalami gangguan. Dengan melakukan pemilihan sinyal dan eksplorasi berbagai jenis arsitektur AANN, akan diperoleh arsitektur AANN yang sesuai dengan sistem yang dimodelkan.

Hasil ujicoba *online* pada sistem instrumentasi RSG-GAS menunjukkan bahwa model AANN yang telah dilatih dapat menghasilkan sinyal prediksi dengan baik dan memberikan sinyal deviasi yang kemudian digunakan untuk mendeteksi adanya penurunan unjuk kerja atau kegagalan sensor. Dari hasil pengamatan awal, belum ditemukan adanya indikasi penurunan unjuk kerja pada sensor-sensor yang diamati yaitu kanal flux neutron, radiasi N-16 dan temperatur inlet teras.

DAFTAR PUSTAKA

1. Dunia, R., et al., *Identification of faulty sensors using principal component analysis*. Aiche Journal, 1996. **42**(10): p. 2797-2812.
2. Black, C.L., R.E. Uhrig, and J.W. Hines. *Inferential Neural Networks for Nuclear Power Plant Sensor Channel Drift Monitoring*. in *The 1996 American Nuclear Society International Topical Meeting on Nuclear Plant Instrumentation, Control and Human Machine Interface Technologies*. 1996. University Park, PA: University Park, PA.
3. Kramer, M.A., *Autoassociative neural networks*. Comput Chem Eng, 1992. **16**(4): p. 313-328.
4. Rumelhart, D.E., J.L. McClelland, and University of California San Diego. PDP Research Group., *Parallel distributed processing : explorations in the microstructure of cognition*. Computational models of cognition and perception. 1986, Cambridge, Mass.: MIT Press. 2 v.
5. Youngjik, L., O. Sang Hoon, and K. Myung Won. *An analysis of premature saturation in back propagation learning*. 1993.
6. LeCun, Y., et al., *Efficient BackProp*, in *Neural networks : tips and tricks of the trade*. 1998, Springer: New York. p. 9-50.