

## PENGEMBANGAN TEKNIK VALIDASI SINYAL

Kristedjo Kurnianto

Pusat Teknologi Reaktor dan Keselamatan Nuklir

### ABSTRAK

**PENGEMBANGAN TEKNIK VALIDASI SINYAL.** Metoda perawatan periodik tidak mampu mendeteksi penurunan unjuk kerja sebuah sensor yang pada umumnya terjadi bersamaan dengan operasi reaktor. 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. Secara khusus sinyal-sinyal dari sensor yang memiliki korelasi tinggi dan sinyal dari sensor redundan dapat digunakan untuk membuat sebuah model dengan menggunakan *Artificial Neural Network* (ANN). ANN 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*). Sistem validasi sinyal yang telah dikembangkan di uji pada sistem instrumentasi RSG\_GAS pada kanal-kanal Fluks Neutron, Radiasi N-16, Flowrate sistem Primer dan Suhu Masukan Teras. Selain itu validasi sinyal di aplikasikan pada data off-line dari Feedwater Flow PLTN PWR Florida Power Corporation's Crystal River USA. Pengujian pada RSG-GAS tidak menunjukkan adanya anomali, sedangkan pengujian pada feedwater flow dapat mendeteksi adanya ventury fouling sesuai dengan penelitian lain yang telah dilakukan oleh Hines dkk. Penggunaan pendeteksi kegagalan SPRT memberikan hasil alarm yang lebih dapat diandalkan karena didasarkan pada pertimbangan-pertimbangan statistik.

Kata kunci: Validasi Sinyal, Sensor, neural network.

### ABSTRACT

**DEVELOPMENT OF SIGNAL VALIDATION TECHNIQUES.** Performance deterioration of sensor usually could not be detected by conventional periodic maintenance, since it is occur when the reactor in operation. This paper will be focused on the introduction of predictive maintenance methods using sensor signal validation. This method provides an on-line early warning system which appear when sensor degradation or sensor faulty happened. Specifically this research dealt with highly correlated signals which usually comes from redundant sensors. This condition is sensitive with ill condition so the modeling using Artificial Neural Network (ANN) needs special treatment to deal with this ill condition. As a predictive models, ANN's, were trained using data from various operation conditions. This training procedure provides a predictive model which produce similar input and output signal under normal condition. The signal difference between input and output is called deviation signal. The deviation signals are sent to Sequential Probability Ratio Test (SPRT) module, to generate alarm. This signal validation techniques has been applied in RSG-GAS sensors (Neutron flux, N-16, primary coolant flow rate and inlet temperature) and feed water flow PWR Florida NPP. RSG-GAS system did not indicated any anomaly or performance degradation, however PWR feed water flow indication a flaw. This result is confirmed with previous research developed by Hines at al. The application of SPRT provides a more reliable alarm system since it is analyzed based on statistical consideration.

Key words: signal validation, Sensor, neural network.

### PENDAHULUAN

Pengoperasian sistem yang besar dan kompleks seperti Reaktor Nuklir menjadikan system 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 tidak memfokuskan pada pembuatan model dengan menggunakan jaringan saraf tiruan atau biasa disingkat ANN (*Artificial Neural Network*) sebagai model, namun pada penggunaan *Sequential Probability Test* (SPRT) dalam memvalidasi sinyal. Dengan modul ini akan ditentukan apakah sinyal hasil pengukuran dikategorikan menimbulkan alarm atau tidak untuk sebuah kejadian penurunan kinerja yang telah ditentukan sebelumnya.

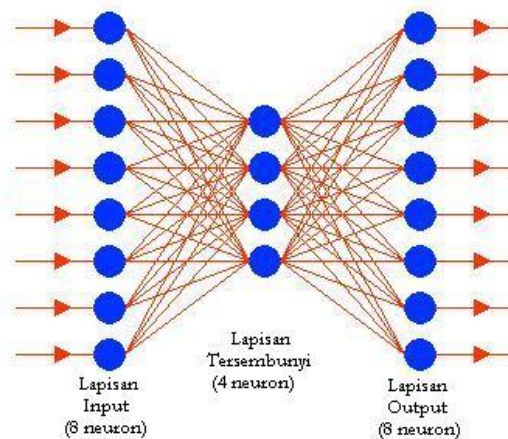
Validasi sinyal sensor pada tulisan ini dilakukan dengan cara melakukan pemilihan parameter-parameter pengukuran sistem instrumentasi RSG-GAS dan Feedwater Flow PLTN PWR Florida Power Corporation's Crystal River USA. Data yang telah dikumpulkan kemudian digunakan untuk pelatihan dan pengujian beberapa model ANN. Kemudian, dicari AANN yang paling optimal yang dapat menghasilkan sinyal prediksi dan dapat menggantikan sinyal sensor yang mengalami kegagalan (*signal recovery*). Selisih sinyal prediksi dan sinyal hasil pengukuran kemudian dianalisis dengan menggunakan modul yang dikembangkan dalam penelitian ini yaitu *Sequential Probability Test* (SPRT). Akhirnya, sistem validasi 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.

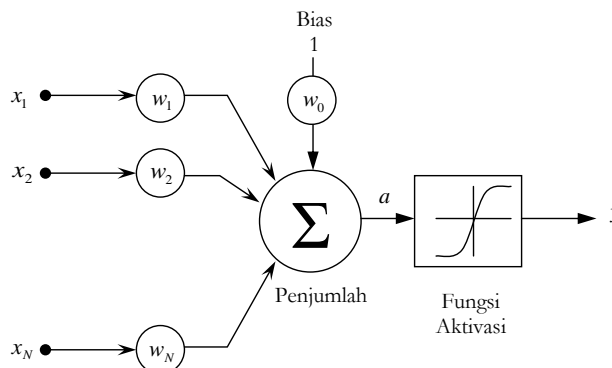
Seperti *Feedforward Neural Network* pada umumnya, AANN memiliki sebuah lapisan input dan output dan satu atau lebih lapisan tersembunyi (*hidden layer*). Setiap lapisan terdiri dari beberapa neuron dimana setiap neuron terhubung ke seluruh neuron pada lapisan berikutnya (*fully connected*). Semua sinyal 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).

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

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

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).

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

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,

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

dimana  $\eta$  (*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  $l = 1$ .

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

dimana nilai  $\delta$  diberikan oleh persamaan 7.

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

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

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

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*  $\alpha$  (bernilai 0 – 1) ditambahkan untuk mempercepat proses pembelajaran. Dengan  $\alpha = 0.9$  dapat meningkatkan kecepatan pembelajaran 10 kali dari algoritma perambatan balik standar.

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

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.

**Sequential Probability Ratio Test (SPRT)**

SPRT pada awalnya dikembangkan oleh Wald [7], dilanjutkan oleh Chien et. al. [8] dan akhirnya oleh Glocker [9] untuk deteksi kontinyu. Pada dasarnya metode ini adalah pengujian hipotesis ( $H_a$ ) alternatif terhadap hipotesis null ( $H_0$ ), yang biasanya digunakan sebagai acuan kondisi normal.

Misalkan data sinyal yang diamati adalah  $\mathbf{r} = (r_1, r_2, \dots, r_n)$ . Metode SPRT menggunakan logaritma perbandingan likelihood seperti dirumuskan pada persamaan 10.

$$\lambda(t) = \ln \frac{F_t(\mathbf{r}|H_1)}{F_t(\mathbf{r}|H_0)} \dots\dots\dots(10)$$

dimana  $F_t(\mathbf{r}|H)$  adalah fungsi distribusi sampel data  $\mathbf{r}$  dengan asumsi bahwa hipotesis benar adalah  $H$  and  $\lambda(t)$  dalam SPRT disebut sebagai parameter keputusan.. SPRT biasanya diterapkan dengan asumsi bahwa data memiliki distribusi normal dan mutally independent. Jika asumsi tersebut dipenuhi  $F_t(\mathbf{r}|H)$  dapat ditulis sebagai  $\prod_{i=1}^n F_1(r_i|H)$ .

Kombinasi perkalian ini dengan persamaan 10 akan memberikan parameter keputusan  $\lambda(t)$  dalam bentuk rekursif berikut ini

$$\lambda(t) = \lambda(t-1) + \ln \frac{F_1(r_t|H_1)}{F_1(r_t|H_0)} \dots\dots\dots(11)$$

**Deteksi Kegagalan Berupa Drift Sinyal dengan SPRT**

Jika null hipotesis adalah keadaan dimana tidak ada drift, dan sampel memiliki distribusi normal, maka hipotesis untuk deteksi drift data ditulis

$$F_1(\mathbf{r}|H_i) = F_1(\mathbf{r}; \theta_i) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(\mathbf{r} - \theta_i)^2}{2\sigma^2}\right) \quad \text{dimana } i = 0,1 \dots\dots\dots(12)$$

Persamaan 2 berubah menjadi

$$\lambda(t) = \lambda(t-1) + \frac{\theta_0^2 - \theta_1^2}{2\sigma^2} + \frac{\theta_0 - \theta_1}{\sigma^2} e_t \dots\dots\dots(13)$$

Batas ambang  $A$  dan  $B$  didefinisikan untuk menguji  $H_0$  terhadap  $H_1$ . Batasan  $A$

biasanya adalah konstanta negatif dan  $B$  adalah konstanta positif. Jika  $\lambda(t) \geq B$ , maka hipotesis  $H_1$  dapat diterima. Sebaliknya,  $H_0$  dapat diterima bila  $\lambda(t) \leq A$ .


Batasan keputusan  $A$  dan  $B$  didefinisikan sebagai *False Alarm Probability* (FAP) dan *Alarm False Probability* (AFP). FAP adalah probabilitas indikasi gagal dimana sesungguhnya tidak terjadi kegagalan, sedangkan AFP adalah probabilitas bahwa tidak ada indikasi kegagalan sementara sesungguhnya kegagalan telah terjadi. Batasan  $A$  dan  $B$  dirumuskan sebagai,

$$A = \ln \frac{AFP}{(1 - FAP)} \quad \text{dan} \quad B = \ln \frac{(1 - AFP)}{FAP} \dots\dots\dots(14)$$

Secara umum langkah-langkah pengambilan keputusan dalam SPRT dejelaskan sebagai berikut

1. Parameter keputusan  $\lambda(1)$  diinisialisasi sama dengan nol dan status Hipotesis  $H_0$  (normal) diinisiasi “diterima”.
2. Untuk data berikutnya,  $\lambda(t)$  dihitung dengan menggunakan persamaan 13. Jika nilai  $\lambda(t)$  dalam interval  $[A, B]$ , hipotesis tidak berubah dan tidak ada perubahan keputusan (tetap menggunakan keputusan sebelumnya) dan kembali ke langkah ke-2.
3. Jika  $\lambda(t)$  melewati batas ambang  $B$ , hipotesis  $H_1$  (keadaan gagal) diterima dan keputusan yang diambil adalah adanya indikasi kondisi kegagalan. Sebaliknya, jika  $\lambda(t)$  melewati batas ambang  $A$ , hipotesis  $H_0$  (keadaan normal) diterima dan keputusan yang diambil adalah kondisi normal. Ketika  $\lambda(t)$  memotong batas ambang dan keputusan dibuat, nilainya diinisialisasi kembali ke nilai 0 dan proses kembali ke langkah ke-2





Gambar 4. Contoh perilaku parameter  $\lambda(t)$  dan indikator kegagalan pada SPRT

## 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 Feedwater Flow PLTN PWR Florida Power Corporation's Crystal River USA. 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 PWR Florida Power Corporation's Cristal River USA memiliki identifikasi sinyal seperti tampak ada Tabel 2. Data diambil dari sinyal-sinyal yang memiliki korelasi tinggi dengan feedwater flow. Data terdiri atas 9601 sampel yang dicuplik setiap 30 menit selama enam bulan operasi. Data diperoleh pada awal siklus sampai dengan sekitar enam

bulan operasi. Setelah operasi selama enam bulan, biasanya fenomena venturi fouling terjadi, dimana terjadinya sedimentasi pada pipa venturi akan menyebabkan terjadinya drift pada hasil pengukuran feedwater flow.

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

Data pelatihan diambil dari 600 data pertama, sedangkan 400 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.

Tabel 2. Tabel Identifikasi sinyal dan kanal untuk data PWR Cristal River

No	Nama Sinyal	Range	Unit
1	FWP A Speed	0-7500	rpm
2	'A' OTSG EFIC HIGH LEVEL	0-100	%
3	FEEDWATER PUMP A SPEED	0-7500	rpm
4	LINEAR POWER CH NI-6	0-125	%
5	HEATER 3A INLET COND TEMP	40-300	°F
6	HEATER 3B OUTLET COND TEMP.	40-350	°F
7	DEARATOR INLET COND TEMP	40-350	°F
8	HEATER 6A INLET FW TEMP	40-500	°F
9	FWP A DISCHARGE TEMP	40-500	°F
10	FWP A SUCTION TEMP	40-500	°F

Bersambung


Tabel 2. Sambungan

No	Nama Sinyal	Range	Unit
11	HEATER 5B OUTLET FW TEMP	40-500	°F
12	STEAM GEN B INLET FW TEMP	40-600	°F
13	HEATER 6B OUTLET FW TEMP	40-600	°F
14	STEAM GEN A LEVEL (OP)	0-100	%
15	STEAM GEN A LEVEL (FULL)	40-640	inches
16	STEAM GEN A LEVEL (START UP)	0-250	inches
17	STEAM GEN B INLET FW TEMP	0-500	°F
18	STEAM GEN B LEVEL (START UP)	0-250	inches
19	STEAM GEN A INLET FW TEMP	40-600	°F
20	STEAM GEN B INLET FW TEMP	40-600	°F
21	REHEATER A COLD REHEAT PRESS.	0-200	psig
22	REHEATER D COLD REHEAT PRESS.	0-200	psig
23	REHEATER C COLD REHEAT PRESS.	0-200	psig
24	NO. 2A EXTR LP TURB PRESSURE	0-20	psia


### 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 SPRT untuk menentukan apakah fluktuasi sinyal sudah dapat dikategorikan terjadinya kegagalan sensor. Pada kasus PWR Cristal River, hasil pelatihan dengan menggunakan AANN 24-3-1 dapat dilihat pada gambar 6.

Dari 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 feedwater flow PWR Cristal River.

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 ANN 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*.

Untuk kasus feedwater flow PWR Cristal River, digunakan beberapa metoda pelatihan antara lain dengan metoda Levenberg-Marquardt (LM), Gradient Descent (GD), Gradiend Descent dengan teknik Bagging (GDBAG) dan Gradient Descent dengan teknik boosting. Hasil pengujian dengan berbagai metode pelatihan tidak memberikan perbedaan yang berarti terhadap hasil prediksi, namun pada pengujian kestabilan metode terhadap kondisi 'ill-condition', metode boosting memberikan keunggulan kesatabilan yang cukup berarti.

Setelah hasil pegujian dengan menggunakan data off-line menunjukkan hasil yang memuaskan. Sistem validasi sensor diintegrasikan pada sistem monitoring reaktor

(SIMOR). Komputer akuisisi 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. Sedangkan pada kasus feedwater flow PWR ditemukan bahwa indikasi permulaan drift sudah terjadi pada data ke 1200 (sekitar hari ke 25 dari awal siklus). Gambar 7 menunjukkan sinyal deviasi, nilai  $\lambda(t)$  dan indikator alarm drift, pada kasus feedwater flow.



Gambar 7. Indikasi drift dan nilai parameter  $\lambda(t)$  SPRT pada kasus feedwater flow

## KESIMPULAN

Validasi sensor dengan menggunakan ANN telah dilakukan. Hasil eksperimen dengan menggunakan data off-line dari Sistem monitoring reaktor (SIMOR) RSG-GAS dan PWR Cristal River menunjukkan ANN dan SPRT dapat memprediksi sinyal hasil pengukuran dengan baik dan memberikan alarm jika terjadi drift. 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 ANN, akan diperoleh arsitektur ANN yang sesuai dengan sistem yang dimodelkan.

Hasil ujicoba *online* pada sistem instrumentasi RSG-GAS menunjukkan bahwa model ANN 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, modul SPRT tidak menemukan adanya indikasi penurunan unjuk kerja pada sensor-sensor yang diamati yaitu kanal flux neutron, radiasi N-16 dan temperatur inlet teras. Sedangkan pada kasus feedwater flow PWR ditemukan bahwa indikasi permulaan drift sudah terjadi pada data ke 1200 (sekitar hari ke 25 dari awal siklus).

#### 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.
7. Wald, A., *Sequential analysis*, Wiley mathematical statistics series, new York: Wiley. 212p, 1947.
8. Chien, T. and M.B. Adams, *A Sequential Failure Detection Technique and its Application*. IEEE transactions on automatic control, **21**: p. 750, 1976.

9. Glöcker, O. *Fault Detectin via Sequential Probability Ratio Test of Multivariate Autoregressive Modelling-Based Residual Time Series*. in *Proceedings of SMORN-VI, A Symposium on Nuclear Reactor Surveillance and Diagnostic*. Galtinburg, Tennese, USA, 1991.