

## Internal Model Control (IMC) - Neural Network (NN) Gain Scheduling untuk Pengendalian Kolom Distilasi

Totok R. Biyanto

Jurusan Teknik Fisika, Fakultas Teknologi Industri – ITS Surabaya  
Kampus ITS Keputih Sukolilo Surabaya 60111  
Email : totokrb@ep.its.ac.id

### Abstrak

Pada penelitian ini dikembangkan suatu alternatif sistem pengendalian dengan algoritma *Internal Model Control – Neural Network Gain Scheduling* (IMC-NNGS) untuk mengendalikan fraksi mol metanol dan air pada kolom distilasi tunggal sistem biner metanol-air dengan struktur L-V. Pada struktur L-V Fraksi distilat ( $X_d$ ) dipasangkan dengan laju aliran refluks ( $L$ ) sedangkan fraksi bawah dipasangkan dengan laju panas pada reboiler ( $Q_r$ ). Karakteristik pengendali IMC hanya tergantung pada harga *tuning*  $\lambda$  atau *time* konstan filter yang diberikan kepadanya. Dengan memanipulasi harga *tuning*  $\lambda$  maka pengendali IMC akan menjadi pengendali nonlinier, dimana pada IMC-NNGS harga  $\lambda$  yang di-update dari *output* NN yang telah dilatih dengan input berupa *error*, proses variabel (PV), *manipulated* variabel (MV) dan *setpoint* dari *plant*. Kinerja NN dalam melakukan *gain scheduling* terhadap IMC dapat meningkatkan kualitas sistem pengendalian dan kualitas produk yang ditunjukkan secara kuantitatif dengan *Integral Absolute Error* (IAE). Perubahan IAE terbaik antara IMC dan IMC-NNGS tercapai pada pengujian penambahan fraksi input ( $X_f$ ), diperoleh IAE sebesar 0,234799 untuk IMC dan IAE sebesar 0,00042 untuk IMC-NNGS atau 559 kali lebih baik. Selain itu IMC-NNGS memiliki respons sistem lebih cepat, tidak memiliki offset, serta bersifat kokoh terhadap perubahan *setpoint* dan kehadiran gangguan yang mempengaruhi proses.

**Kata kunci:** Neural Network (NN), Internal Model Control (IMC) Gain Scheduling, kolom distilasi.

### Abstract

*This research is develop the alternative control algorithm using Internal Model Control – Neural Network Gain Scheduling (IMC-NNGS) to control mole fraction of methanol-water distillation column. Distillation column with L-V control strategy has pairing  $X_d-L$  and  $X_b-Q_r$ . IMC performances depend on only  $\lambda$  tuning value or filter time constant. With  $\lambda$  tuning value manipulating IMC could be nonlinear control, where  $\lambda$  tuning value is outputs of NN that had been trained by using error variable, process variable, manipulated variable, and set point variable from plant. Gain scheduling using NN could be increase control system performance and product quality. The best IAE changing value shown at mole fraction feed increase. There are IAE equal with 0,234799 for IMC and IAE equal with 0, 00042 for IMC-NNGS. In other word IMCGS has IAE 559 times better than IMC. Beside that IMC-NNGS has faster response, offset free and robust to overcome set-point and disturbance changes.*

**Keywords:** Neural Network (NN), Internal Model Control (IMC) Gain Scheduling, Distillation Column.

### Pendahuluan

IMC telah banyak diulas pada beberapa buku ajar [4], dan beberapa peneliti telah mengaplikasikan metode pengendalian IMC menggunakan pemodelan matematis. Dalam penelitian tersebut membandingkan respon pengendalian antara PID dengan IMC, dan didapatkan bahwa untuk proses yang kompleks, IMC menampilkan respon yang lebih baik dan *robust* dibandingkan dengan PID (konvensional kontrol). Namun karakteristik IMC pada penelitian diatas tidak berbeda dengan PID yaitu pengendali yang linier. Sementara karakteristik umum dari proses di industri merupakan proses yang nonlinier,

kompleks, multivariabel serta dipengaruhi oleh gangguan-gangguan yang merugikan proses tersebut. Salah satu alternatif yang dapat digunakan untuk meningkatkan kualitas dan unjuk kerja sistem pengendalian di industri adalah mengembangkan strategi sistem pengendalian nonlinier.

IMC sebagai pengendali berbasis model, maka usaha membuat pengendali IMC nonlinier dapat dilakukan dengan membuat model yang nonlinier seperti yang telah dilakukan oleh [2] menggunakan model dan pengendali NN dan [3] model dan pengendali dengan Neurofuzzy. Namun cara ini mempunyai kendala untuk mendapatkan data *openloop plant* yang bervariasi pada seluruh *range* pengendalian [1], sehingga perlu dipikirkan metode lain untuk mendapatkan pengendali yang nonlinier.

**Catatan:** Diskusi untuk makalah ini diterima sebelum tanggal 1 Desember 2005. Diskusi yang layak muat akan diterbitkan pada Jurnal Teknik Elektro volume 6, nomor 1, Maret 2006.

Alternatif lain adalah dengan memanfaatkan NN [6] sebagai *Gain Scheduling tuning* IMC, dengan mengatur harga  $\lambda$  sesuai kebutuhan *plant*.

NN mempunyai kemampuan dalam memodelkan sistem yang kompleks dan bekerja pada daerah yang non linier, sehingga dapat dimanfaatkan untuk mengoptimasi kontroler IMC dengan mengkombinasikan keduanya [3]. Fungsi NN disini adalah sebagai *Gain Scheduling* IMC yang merubah – ubah parameter  $\lambda$  sesuai kebutuhan *plant*.

Dalam penelitian ini IMC-NN *Gain Scheduling* akan diterapkan secara simulasi menggunakan Matlab untuk mengendalikan fraksi mol distilat dan faksi mol produk bawah pada kolom distilasi metanol air. Proses didalam kolom distilasi metanol-air. melibatkan beberapa variabel yaitu tekanan *top tray*, temperatur di tiap tray, *flow feed*, konsentrasi produk  $X_d$  dan  $X_b$  serta level kondensor dan *bottom* yang saling berinteraksi satu sama lain, sehingga proses yang berjalan didalamnya menjadi kompleks dan non linier. Produk distilat ( $X_d$ ) dan produk bawah ( $X_b$ ) dipengaruhi juga oleh laju umpan/*feed* dan fraksi mol *feed* ( $X_f$ ). [1]

Permasalahannya adalah bagaimana performansi pengendali IMC yang *tuning* dengan NN untuk mengendalikan komposisi fraksi distilat ( $X_d$ ) dan fraksi bawah ( $X_b$ ) pada kolom distilasi metanol – air?

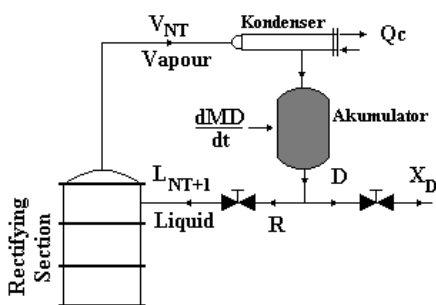
Penelitian ini bertujuan untuk mensimulasikan dan menganalisa kinerja performansi pengendali IMC *Gain Scheduling* NN pada kolom distilasi metanol air dan dibandingkan dengan kontroler IMC konvensional.

**Tinjauan Pustaka**

**Kolom Distilasi Biner**

Kolom distilasi biner mempunyai kesetimbangan massa [4] dan energi [1] yang dapat diterangkan sebagai berikut:

Kesetimbangan massa dan panas pada kondensor dan reflux drum



Gambar 1. Kesetimbangan massa pada kondensor dan reflux drum

Neraca massa total:

$$\frac{dM_D}{dt} = V_{NT} - L_{NT+1} - D \tag{1}$$

Neraca massa komponen :

$$\frac{d(M_D X_D)}{dt} = V_{NT} Y_{NT} - (L_{NT+1} + D) X_D \tag{2}$$

Neraca panas:

$$\frac{d(M_D h_D)}{dt} = V_{NT} H_{NT} - L_{NT+1} h_{NT+1} - D h_D - Q_c \tag{3}$$

Kesetimbangan massa dan panas pada tiap tray

Neraca massa total:


$$\frac{dM_n}{dt} = L_{n+1} - L_n + V_{n-1} - V_n \tag{4}$$

Neraca massa komponen :

$$\frac{d(M_n X_n)}{dt} = L_{n+1} X_{n+1} - L_n X_n + V_{n-1} Y_{n-1} - V_n Y_n \tag{5}$$


Neraca massa panas :

$$\frac{d(M_n h_n)}{dt} = L_{n+1} h_{n+1} - L_n h_n + V_{n-1} H_{n-1} - V_n H_n \tag{6}$$



Gambar 2 Kesetimbangan massa pada tiap tray

Kesetimbangan massa dan panas pada tray umpan (n = N\_F)



Gambar 3 Kesetimbangan massa pada tray umpan

Neraca massa total:

$$\frac{dM_{NF}}{dt} = L_{NF+1} - L_{NF} + F + V_{NF-1} - V_{NF} \tag{7}$$

Neraca massa komponen :

$$\frac{d(M_{NF} X_{NF})}{dt} = L_{NF+1} X_{NF+1} - L_{NF} X_{NF} + V_{NF-1} Y_{NF-1} - V_{NF} Y_{NF} + F X_F \tag{8}$$

Neraca panas:

$$\frac{d(M_{NF}h_{NF})}{dt} = L_{NF+1}h_{NF+1} - L_{NF}h_{NF} + V_{NF-1}H_{NF-1} - V_{NF}H_{NF} + Fh_F \quad (9)$$

Neraca panas :

$$\frac{d(M_n h_n)}{dt} = L_{n+1}h_{n+1} - L_n h_n + V_{n-1}H_{n-1} - V_n H_n \quad (10)$$

Kesetimbangan massa dan panas pada reboiler dan base kolom

Neraca massa total:


$$\frac{dM_n}{dt} = L_1 - V_{RB} - B \quad (11)$$

Neraca massa komponen:

$$\frac{d(M_B X_B)}{dt} = L_1 X_1 - V_{RB} Y_B - B X_B \quad (12)$$

Neraca panas :

$$\frac{d(M_B h_B)}{dt} = L_1 h_1 - V_{RB} H_B - B h_B + Q_R \quad (13)$$

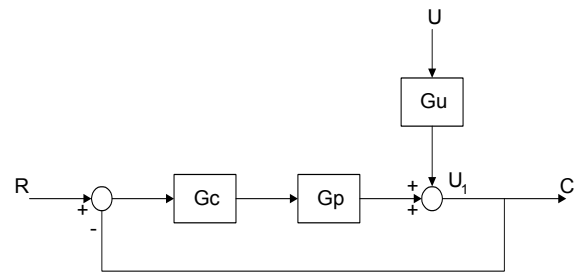


Gambar 4. Kesetimbangan massa pada Reboiler dan base kolom

**IMC (Internal Model Control)**

Internal Model Control (IMC) adalah metode pengendalian yang berdasarkan pada ketepatan suatu model dari suatu proses, yang menjadi pedoman untuk mendesain sistem pengendalian yang *stabil* dan *robust*. Dimana, suatu sistem pengendalian yang *robust* adalah sistem pengendalian yang aman pada perubahan proses dinamik [5]

Blok diagram untuk *feedback controller* dan Struktur pengendali IMC pada gambar 5 sampai gambar 8. Dimana Gp adalah fungsi transfer *plant*, Gc adalah fungsi transfer pengendali, Gu adalah fungsi transfer *disturbance*, Gi adalah fungsi transfer *inverse model*, Gm adalah fungsi transfer *forward model*, R adalah *setpoint*, U adalah *disturbance*, U1 adalah output *plant* yang disebabkan perubahan *disturbance* dan C adalah *control variable*



Gambar 5. Feedback controller

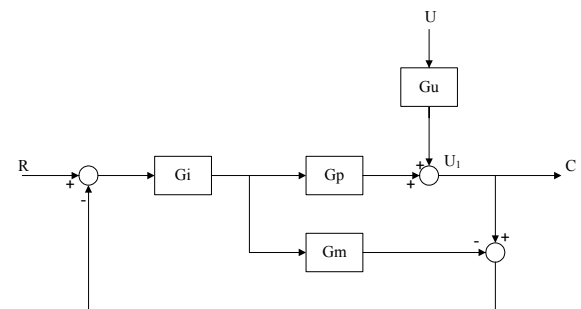
Hubungan antara Gc dan Gi ditunjukkan pada persamaan:

$$G_c = G_i / (1 - G_i G_m) \quad (14)$$


Untuk struktur yang ditunjukkan pada gambar 8, menunjukkan bahwa :

$$C = U_1 + \frac{G G_i}{1 + G_i (G - G_m)} [R - U_1] \quad (15)$$


Jika model tepat sama dengan proses (Gm = Gp), maka hanya sinyal U1 yang masuk ke dalam komparator 1 pada gambar 6. Ketika U1 tidak menghasilkan proses apapun oleh fungsi transfer pada loop forward, U1 bukan merupakan sinyal *feedback* tetapi sinyal bebas yang *equivalent* dengan R dan menghasilkan keluaran C. Pada kenyataannya, tidak ada *feedback* ketika Gp = Gm dan gambar 6 akan menghasilkan sistem open-loop seperti ditunjukkan pada gambar 9.




Gambar 6. Struktur IMC



Gambar 7. Alternatif struktur IMC



Gambar 8. Struktur IMC *equivalent* dengan kontrol konvensional



Gambar 9. Struktur IMC ketika model sesuai dengan proses ( $G_m = G_p$ )

Pada gambar stabilitas dari sistem pengendalian bergantung hanya pada  $G_f$  dan  $G_m$ . Jika  $G_f$  dan  $G_m$  stabil, maka sistem pengendalian stabil.

Idealnya, jika hanya terjadi perubahan *set point* ( $U_1 = 0$ ) dapat dilihat dari gambar 9 atau persamaan 10 bahwa  $G_f G_m = 1$  ( $G_p = G_m$ ), maka:

$$G_f G_m = 1 \tag{16}$$

$$G_f = 1 / G_m \tag{17}$$

Untuk kasus perubahan gangguan *load*  $U_1$ , dimana  $R = 0$  dan harga keluaran  $C$  stabil, maka akan juga menghasilkan persamaan yang sama dengan persamaan (11) dan (12).

IMC hanya membutuhkan satu parameter pengendali  $\lambda$ . sebagai filter (persamaan 18), agar dapat menjadi pengendali yang cukup *robust* untuk gangguan *load* dan *set point* karena harga fungsi transfer pada model *plant* dan *inversenya* sesuai dengan persamaan (16) dan (17).

$$f(s) = \frac{1}{(\lambda s + 1)} \tag{18}$$

### Neural Network (NN) Dengan Algoritma Belajar Levenbeg Marquard

Algoritma Levenberg Marquardt dapat didiringskas sebagai berikut: [6]

1. Pilih vector bobot awal  $w^{(0)}$  dan harga awal  $\lambda^{(0)}$ . Dimana  $w$  adalah bobot dan  $\lambda$  diberikan harga awal.

2. Tentukan arah pencarian.

$$[R(w^{(i)} + \lambda^{(i)} I)] f^{(i)} = -G(w^{(i)}) \tag{19}$$

maka diperoleh  $f$  dan dimasukkan ke:

$$w = \arg \min_w V_N(w, Z^N)$$

jika  $V_N(w^{(i)} + f^{(i)}, Z^N) < V_N(w^{(i)}, Z^N)$  sehingga memenuhi  $w^{(i+1)} = w^{(i)} + f^{(i)}$  sebagai iterasi baru, maka  $\lambda^{(i+1)} = \lambda^{(i)}$ . Jika tidak maka mencari harga baru dari  $r$

$$r^{(i)} = \frac{V_N(w^{(i)}, Z^N) - V_N(w^{(i)} + f^{(i)}, Z^N)}{V_N(w^{(i)}, Z^N) - L^{(i)}(w^{(i)} + f^{(i)})} \tag{20}$$

jika  $r^{(i)} > 0,75$  maka  $\lambda^{(i)} = \lambda^{(i)}/2$

jika  $r^{(i)} < 0,25$  maka  $\lambda^{(i)} = 2\lambda^{(i)}$

3. Jika kriteria tercapai, maka perhitungan berhenti. Jika kriteria belum tercapai maka mengulangi langkah nomer 2.

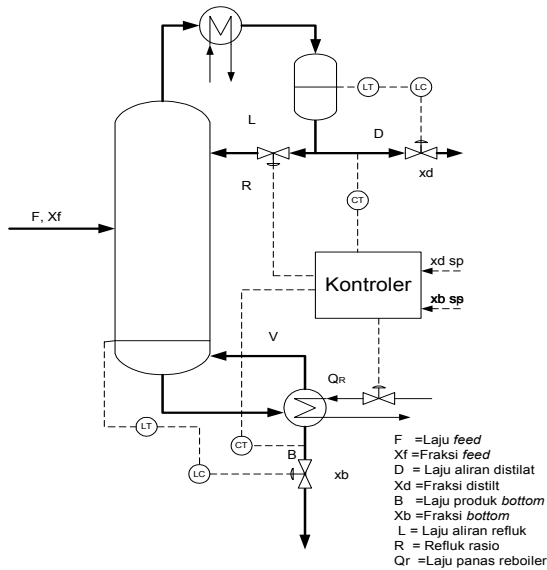
### Sistem Yang Diteliti

Penelitian ini menggunakan model pemisahan sistem methanol-air dalam kolom distilasi tunggal dengan menggunakan struktur pengendalian L-V. Spesifikasi perancangan sistem ditunjukkan pada Tabel 1 [1,3].

Tabel 1. Data *steady state* kolom distilasi metanol – air [1,3]

Diskripsi Variabel	Nilai
Laju umpan (F), mol/meni	45.000
Laju distilat (D), mol/menit	22.500
Laju produk bawah (B), mol/menit	22.500
Komposisi umpan (Xf), fraksi mol methanol	1
Komposisi distilat (XD), fraksi mol methanol	1
Komposisi produk bawah (XB), fraksi mol methanol	0
Perbandingan refluks	1
Jumlah plate	30
Letak plate umpan	5
Tekanan operasi (atm)	1
Beban condensor, 104 kcal/menit	35
Beban reboiler, 104 kcal/menit	35

Kolom tunggal dirancang dengan basis perbandingan *refluks* sebesar 1,1 kali perbandingan *refluks* minimum. Sistem yang digunakan adalah methanol-air pada tekanan 1 atm. Kemurnian produk adalah 99% fraksi mol metanol pada distilat dan 1% fraksi mol metanol pada produk bawah. Konsumsi energi panas untuk *reboiler* adalah sebesar  $35,1 \times 10^4$  kcal/menit.



Gambar 10. Struktur kolom distilasi dengan struktur L-V [3]


Pada penelitian ini, variabel yang dikendalikan adalah fraksi mol methanol pada produk bawah,  $X_B$ , dan fraksi mol methanol pada distilat,  $X_D$ . Sedangkan variabel yang dimanipulasi adalah laju *refluk* ( $L$ ) dan laju panas pada *reboiler* ( $Q_r$ ) dengan gangguan laju *Feed* ( $F$ ) dan fraksi *Feed* ( $X_F$ ). Sistem proses yang digunakan ditunjukkan pada gambar 10. [3]

## Perancangan

### Amplitudo PseudoRandom Binary Signal (APRBS)

Sinyal APRBS (*Amplitudo Pseudo Random Binary Signal*) [5] merupakan pembangkit sinyal yang terbaik untuk mendapatkan karakteristik kompleks dari proses yang diteliti dengan mengatur lebar pulsa sinyal dan amplitudo. Dalam penelitian ini APRBS digunakan untuk  $\lambda_1$  dan  $\lambda_2$  serta *setpoint*  $X_d$  dan *setpoint*  $X_b$ .


Setelah parameter APRBS (lebar dan tinggi pulsa) ditentukan, maka random data dapat dimasukkan sebagai pemacu data *plant*. Gambar 11 adalah salah satu contoh sinyal APRBS



Gambar 11 Salah satu hasil APRBS yaitu  $\lambda_1$

## Simulasi Pengambilan Data Input Output Training

Data input output untuk training NN diperoleh dari simulasi pada Matlab dengan cara memberikan input sinyal APRBS  $\lambda_1$  dan  $\lambda_2$  serta *setpoint*  $X_d$  dan *setpoint*  $X_b$  kepada sistem pengendalian kolom distilasi menggunakan IMC dan mencatat output sistem pengendalian yang berupa data dinamik *error* ( $e$ ), variabel termanipulasi (MV) dan proses variabel (PV). Seperti pada gambar 12.



Gambar 12 Proses variabel fraksi  $X_d$

## Arsitektur dan Training NN

Arsitektur dari NN pada penelitian ini menggunakan NN - MLP (Multi Layer Perceptron) dengan struktur NNARX (*Neural Network Auto Regressive, eXternal input*) dimana variabel *input* NN mengandung *input* ( $U$ ) dan *output* ( $Y$ ) masa sekarang dan lampau [1]. Persamaan *output* model  $\hat{Y}$  dapat ditulis sebagai berikut:

$$\hat{Y} = f(Y_1, Y_2, U_1, U_2) \quad (21)$$

dimana :

$$\hat{Y} = [\hat{y}_1(k+1) \ \hat{y}_2(k+1)]^T$$

$$Y_1 = [y_1(k), y_1(k-1), \dots, y_1(k-n_{y1})]$$

$$Y_2 = [y_2(k), y_2(k-1), \dots, y_2(k-n_{y2})]$$

$$U_1 = [u_1(k), u_1(k-1), \dots, u_1(k-n_{u1})]$$


$$U_2 = [u_2(k), u_2(k-1), \dots, u_2(k-n_{u2})]$$

dimana  $n_y$  dan  $n_u$  adalah *history length* untuk *output* dan *input* proses.

Pemilihan jumlah *layer* adalah tiga yaitu *layer input*, *layer hidden* dan *layer output* dengan fungsi aktivasi *hyperbolic tangent* pada *hidden neuron* dan fungsi aktivasi *linear* pada *output neuron*, sudah mampu memodelkan sistem dinamik dengan baik. Hal ini sudah dibuktikan untuk memodelkan kolom distilasi menggunakan Matlab dan divalidasi dengan Hysys Software [1,3]

Gambar 13 adalah NN MLP dengan struktur input NNARX dengan jumlah *layer* dan fungsi aktivasi dimana pada saat awal pelatihan dengan bobot model diambil secara acak, maka  $Y$  dan  $Y_{hat}$  akan


menunjukkan harga yang berbeda pada keseluruhan data set pelatihan atau masih ada *error* (e). *Error* ini adalah fungsi tujuan yang akan diminimisasi pada setiap iterasi atau *epoch* selama pelatihan menggunakan algoritma Levenberg Marquard dengan mengubah bobot W1 dan W2 pada NN.



Gambar 13 Struktur NN hasil rancangan

Validasi model yang telah dibuat terhadap *plant* dilakukan dengan memberikan *input* yang belum pernah dilatihkan kepada NN dan mencatat *Root Mean Squared Error* (RMSE) yang terjadi sepanjang N sample validasi. Hasil validasi seperti gambar 14, terlihat bahwa output model dan output proses sangat berimpit, sehingga terlihat seperti satu garis. Sedangkan *Root Mean Squared Error* (RMSE) dapat ditulis sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}}$$

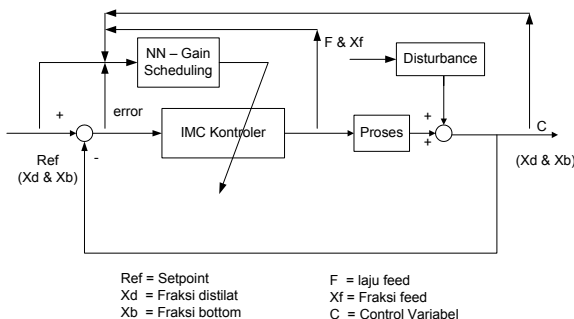


Gambar 14. Validasi output model NN dan output proses  $\lambda$ 1

**Pengujian dan Analisa**

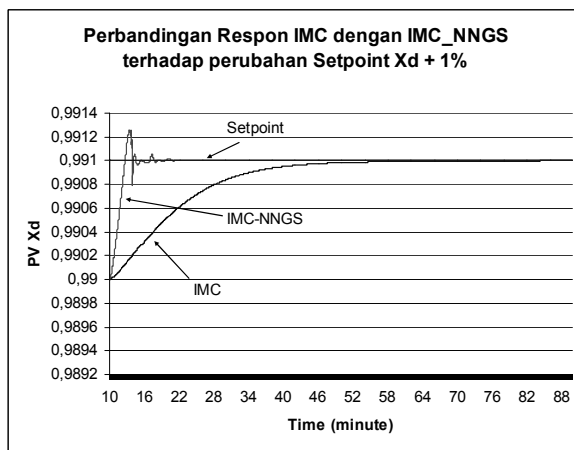
Setelah training dilakukan, hasilnya NN dibandingkan dengan IMC kontroler. Untuk melihat efektifitas kinerja NN, maka diberikan perubahan *set point* Xd dan Xb, dan *disturbance* berupa perubahan fraksi *feed* dan laju *feed* yang besarnya  $\pm 1\%$ .

Gambar 15 adalah struktur IMC-NNGS yang akan diuji performansinya dimana NN gain scheduling akan mengeluarkan *output* untuk meng-*update* nilai  $\lambda$  berdasarkan beberapa *input* yaitu *error*, proses variabel, *setpoint*, dan *manipulated* variabel.



Gambar 15. Blok diagram IMC-NNGS yang akan diuji performansinya

Sebagai contoh pada pengujian perubahan *setpoint* Xd plus 1% diperoleh harga IAE sebesar 0,095585 untuk kontroler IMC NN *Gain Scheduling* dan IAE 0,603510 untuk IMC konvensional. Sedangkan untuk perubahan *setpoint* Xb diperoleh harga IAE sebesar 0,813987 untuk kontroler IMC NN *Gain Scheduling* dan IAE 0,840295 untuk IMC konvensional, seperti terlihat pada Gambar 16. Data IAE pengujian selengkapnya dapat dilihat pada Tabel 2.



Gambar 16. Perubahan set point Xd +1% dengan kontroler IMC dan kontroler IMC-NN Gain Scheduling

Gambar 16 menunjukkan bahwa IMC konvensional yang telah dituning dengan harga  $\lambda$  terbaik yaitu 0,1 memiliki respon yang *sluggish* disebabkan harga  $\lambda$  yang tetap. Apabila harga  $\lambda$  dirubah menjadi lebih kecil atau gain pengendali menjadi lebih besar maka akan menyebabkan *overshoot* dan IAE yang besar. Sedangkan untuk IMC-NNGS harga  $\lambda$  berharga kecil sekali pada saat error besar dan membesar saat error semakin kecil, sehingga diperoleh respon yang cepat

tgh

tgh

tgh

namun memiliki overshoot yang kecil dan harga IAE yang kecil juga.

Tabel 2. Perbandingan performansi IAE untuk IMC dan IMC-NNGS

Perubahan	IAE IMC (%)		IAE IMC-NNGS (%)	
	Xd	Xb	Xd	Xb
Xd + 1 %	0,603510	0,840295	0,095585	0,813987
Xd - 1 %	0,539230	0,741740	0,034428	0,002195
Xb + 1%	0,048320	0,166444	0,001751	0,016990
Xb - 1%	0,050580	0,170174	0,001635	0,009636
Xf + 1 %	0,062958	0,234799	0,000561	0,000420
Xf - 1 %	0,062959	0,234786	0,000561	0,000420
F + 1 %	0,362867	0,362767	0,003706	0,002808
F - 1 %	0,363074	1,278669	0,003705	0,002808

### Kesimpulan

Telah dirancang IMC-NNGS untuk mengendalikan kualitas produk kolom distilasi methanol-air dan menunjukkan bahwa efektifitas NN dalam *update* harga *tuning*  $\lambda$  pada kontroler IMC membuat performansi sistem pengendalian IMC-NNGS lebih baik jika dibandingkan dengan IMC konvensional, ditinjau dari nilai IAE yang kecil, IAE yang kecil pada pengendalian kualitas kolom distilasi menunjukkan bahwa produk distilat (methanol) yang tidak sesuai spesifikasi dari kualitas yang ditentukan semakin sedikit dan produk bawah (air) semakin ramah lingkungan, penghematan energi pada reboiler dan kondenser dan secara keseluruhan performansi sistim menjadi lebih baik.

### Daftar Pustaka

- [1] Biyanto, TR., Santosa, HH, "Modeling of methanol-water binary distillation column using a Neural Network", *Journal Instrumentasi Vol 28 No1, Instrumentation Society of Indonesia*, Jakarta, January – June 2004
- [2] Biyanto, TR., Hendarwanto, D, "Internal Model Control Based Neuro-Fuzzy – (NF-IMC) for Controlling Reactor Temperature", *National Seminar XII – FTI - ITS 2005*, Surabaya, 29-30 March 2005
- [3] Biyanto, TR., Handogo, R., Suhartanto, T, *Controlling of a binary distillation column using Neural Network - Internal Model Control (NN-IMC)*, Post Graduate Seminar IV, Sepuluh Nopember Institute of Technology Surabaya, Surabaya, 24-25 August 2004
- [4] Luyben, W. L. Bjorn D. Tyreus, Michael L. Luyben, *Plant wide Process Control*, Mc Graw-Hill, New York, 1998
- [5] Nelles O, Isermann R., *Basis Function Networks for Interpolation of Local Linear Models*, Proc.of 35<sup>th</sup> Conference on Decision and Control, Kobe, Japan, December, 1996.
- [6] Norgaard, M., Ravn, O., Poulsen, N.K., and Hansen L.K., *Neural Network for Modelling and Control of Dynamic Systems*, Springer London. Nopember 2000.