

FAULT DIAGNOSIS DINAMIK UNTUK INSTALASI NUKLIR MENGGUNAKAN PENDEKATAN PROBABILISTIK

Djoko Hari Nugroho, Deswandri, Ahmad Abtokhi, Darlis

ABSTRAK

FAULT DIAGNOSIS DINAMIK UNTUK INSTALASI NUKLIR MENGGUNAKAN PENDEKATAN PROBABILISTIK. Pada penelitian ini dikembangkan metode *fault diagnosis* secara probabilistik untuk merunut kemungkinan penyebab awal insiden berdasarkan *Bayesian Networks* sebagai dasar pembuatan perangkat lunak untuk *trouble shooting* instalasi. Pengembangan dilakukan dengan cara memasukkan data *on-line* dari sensor dan data reliabilitas sistem/komponen pada *node cause* sehingga diharapkan tingkat kepercayaan hasil menjadi lebih baik.

Kata kunci : *fault diagnosis* dinamik, probabilistik

ABSTRACT

DYNAMIC FAULT DIAGNOSIS FOR NUCLEAR INSTALLATION USING PROBABILISTIC APPROACH. Probabilistic based *fault diagnosis* which represent the relationship between cause and consequence of the events for *trouble shooting* is developed in this research based on *Bayesian Networks*. Contribution of *on-line* data comes from sensors and system/component reliability in *node cause* is expected increasing the belief level of *Bayesian Networks*.

Key words : dynamic *fault diagnosis*, probabilistic

PENDAHULUAN

Ketersediaan dan keandalan operasi suatu instalasi ditentukan oleh seberapa jauh instalasi tersebut dapat memberikan pelayanan pada saat diperlukan. Artinya kemungkinan terjadinya kerusakan dalam instalasi harus dijauhkan atau kalaupun ada harus dikelola sebaik mungkin. Amat beralasan bila instalasi nuklir dan instalasi kritis yang lain sebagai sistem yang mengutamakan keselamatan menempatkan program pengelolaan kerusakan sebagai prioritas utama untuk diteliti, dikembangkan dan diaplikasikan. Pengelolaan kerusakan sangat ditekankan dalam program pengelolaan siklus hidup (*life cycle management*) suatu instalasi.

Telah banyak dikembangkan metode tentang *fault diagnosis*. Banyak penelitian menganalisis instalasi yang dianggap sebagai sistem deterministik, sedangkan penelitian ini bertujuan untuk mengembangkan suatu metoda *diagnosis* kerusakan yang meninjau instalasi

sebagai sistem yang stokastik agar *diagnosis* dapat dilakukan dalam suatu *range* waktu panjang tertentu dalam lingkungan yang dinamik dan ketidak pastian (*uncertainty*). Salah satu metode yang banyak dipergunakan untuk maksud tersebut adalah *Bayesian Networks*. *Bayesian networks* adalah suatu metoda penting untuk merepresentasikan ketidak pastian (*uncertainty*) dan penalaran (*reasoning*) dalam bidang kecerdasan buatan (*artificial intelligence*). Sampai saat ini belum tampak adanya perangkat lunak komersial berdasarkan *Bayesian Networks*.

Saat ini banyak keraguan terhadap hasil analisis berdasarkan *Bayesian Networks*, karena adanya keraguan terhadap data sebelumnya (*prior*). Jika tingkat kepercayaan data *prior* rendah, maka hasil yang diperoleh dari *Bayesian network* juga memiliki tingkat kepercayaan yang rendah. Penelitian ini bertujuan untuk melakukan pengembangan *Bayesian networks* untuk meningkatkan tingkat

kepercayaan yang nantinya akan dibuat dalam bentuk perangkat lunak bagi keperluan *trouble shooting* instalasi.

FAULT DIAGNOSIS

Ulerich mendefinisikan diagnosis kerusakan (*fault diagnosis*) sebagai proses dimana problem-problem operasional dideteksi menggunakan sensor, alat pengukur serta alarm dan kemudian keputusan dibuat berdasar bagaimana cara memperbaikinya pada saat instalasi beroperasi. Isermann mendefinisikan diagnosis kerusakan sebagai suatu prosedur yang bertujuan untuk menentukan jenis kerusakan, lokasi kerusakan, ukuran kerusakan, dan penyebab kerusakan. Chessa mendefinisikan bahwa diagnosis kerusakan berkaitan dengan lokasi komponen yang rusak dalam sistem, yang akan diganti atau diperbaiki agar dapat kembali ke kondisi normal. Secara singkat, diagnosis kerusakan dapat didefinisikan sebagai suatu proses untuk mendeteksi abnormalitas yang muncul dalam sistem dan menentukan lokasi kerusakan.

Menurut Kokawa ada 2 jenis teknik untuk menentukan lokasi kerusakan antara lain :

- (a) *cause and consequence tree approach* (CCT) adalah suatu pohon logika yang menghubungkan antara penyebab awal dengan konsekuensi yang teramati.
- (b) *signed digraph* (SD) *approach* adalah suatu model matematika yang merepresentasikan pengaruh antar elemen-elemen sistem.

Kokawa menganalisis bahwa pendekatan CCT mengekspresikan perambatan kerusakan pada suatu perangkat sebagai kerusakan. Walaupun SD menggunakan struktur instalasi

untuk mencari lokasi kerusakan berdasarkan pendekatan *graph*, namun metoda ini tidak memperhatikan probabilitas penjarangan kerusakan.

Kondisi real menunjukkan bahwa jumlah kerusakan tidaklah selalu satu dalam sistem, oleh karena itu problematika diagnosis kerusakan menjadi kompleks.

Ulerich menekankan analisis diagnosis kerusakan dalam model *graph*. Chessa mengembangkan algoritma D-FAULTS yang mendiagnosis sistem bila paling tidak ada dua node sumber kerusakan dalam satu waktu.

BAYESIAN NETWORKS

Telah diperoleh banyak definisi berkaitan dengan *fault diagnosis* yang berkembang sampai saat ini. Namun pada umumnya ruang lingkup pembahasan bertitik tolak pada pengelolaan masalah *fault detection* dan *fault localization*. Masalah *fault detection* telah banyak dibahas dan dikembangkan, yang prinsip kerjanya berkaitan dengan metode untuk membedakan adanya parameter yang abnormal bila diketahui status normalnya, dan kemudian membangkitkan sinyal pemberitahuan ke manajer sistem. *Fault localization* terkait dengan metode untuk menentukan lokasi komponen atau sistem yang gagal. Sedangkan metode *fault diagnosis* lebih menekankan penyusunan struktur pohon pada *cause and consequence tree approach* untuk mengetahui hubungan antara kejadian dan penyebabnya sehingga dapat dirunut kemungkinan penyebab awal kalau terjadi insiden.

Ada ketidak pastian (*uncertainty*) pada *model of environment* dan lokasi penyebab

kegagalan dalam sistem yang akan dirunut berdasarkan pada *data evidence* yang bersifat ambiguous ataupun berdasarkan perkiraan penganalisis. Analisis data yang bersifat tidak pasti dapat direpresentasi dalam penalaran probabilistik menggunakan pendekatan *Bayesian*, Dempster-Shafer, ataupun *fuzzy logic*.

Salah satu metoda *fault diagnosis* menggunakan pendekatan statistik adalah pendekatan *Bayesian networks*. *Bayesian networks* adalah suatu metoda penting untuk merepresentasikan ketidak pastian (*uncertainty*) dan penalaran (*reasoning*) dalam bidang kecerdasan buatan (*artificial intelligence*). Menurut Kadie dari perusahaan Microsoft ⁽¹⁾, *Bayesian network* adalah :


- sekumpulan variabel-variabel,
- sebuah struktur grafis yang menghubungkan antar variabel,
- sekumpulan distribusi kondisional.

$$P(X_1, X_2, X_3, X_4, \dots, X_n) = P(X_1 | X_2, X_3, X_4, \dots, X_n) * P(X_2 | X_3, X_4, \dots, X_n) * P(X_3 | X_4, \dots, X_n) * \dots * P(X_n)$$

atau

$$P(X_1, \dots, X_n) = \prod_i P(X_i | pa_i)$$

Contoh sederhana Bayesian network adalah hubungan antara musim (X_1), hujan (X_2), semprotan air nyala (X_3), halaman basah (X_4) dan halaman licin (X_5).



Dasar dari *Bayesian network* adalah probabilitas kondisional berantai dari *Bayesian* yang dipergunakan dalam jaringan yang berdasarkan pendekatan *graph*. Pada *Bayesian Network*, direpresentasikan keadaan nyata dan bukan proses penalaran Probabilitas peristiwa gabungan (*joint events*) antara dua events X_1 dan X_2 dimana probabilitas $P(X_1) > 0$ ditentukan oleh formulasi probabilitas kondisional dalam Bayesian sebagai berikut ^(2,3) :

$$P(X_2 | X_1) = \frac{P(X_1, X_2)}{P(X_1)}$$

atau dapat juga dinyatakan sebagai:

$$P(X_1, X_2) = P(X_1)P(X_2 | X_1)$$

dimana :

$P(X_1)$ = probabilitas *a priori*

$P(X_2 | X_1)$ = fungsi *likelihood*

Formulasi umum untuk hukum berantai (*chain rule*) adalah sebagai berikut :

Pada *Bayesian Network*, direpresentasikan keadaan nyata dan bukan proses penalaran. Tanda panah di atas menunjukkan hubungan sebab-akibat dan bukan aliran informasi dalam penalaran. Bila semprotan air nyala, maka halaman akan basah. Jika seseorang terpeleset di halaman, artinya halaman juga basah. Pada contoh kita di atas, formulasi umum untuk hukum berantai (*chain rule*) adalah :

$$P(X_1, X_2, X_3, X_4, X_5) = P(X_1) P(X_2|X_1) P(X_3|X_1) \\ P(X_4|X_2, X_3) P(X_5|X_4).$$

BAYESIAN NETWORKS SEBAGAI TROUBLESHOOTER

Probabilitas asli yang terdapat pada model diagram disebut sebagai probabilitas *prior*, karena dimasukkan sebelum kondisi saat ini (*evidence*) diketahui. Probabilitas setelah *evidence* diketahui disebut probabilitas *posterior*, karena angka tersebut merefleksikan tingkat probabilitas pada saat terdapat *evidence* yang baru. Penggunaan inferensi mengakibatkan manipulasi *evidence* pada model sehingga menghasilkan perubahan probabilitas posterior akibat berubahnya *evidence*.

Dalam skenario peristiwa, simpul (*node*) yang memiliki nilai informasi penting dalam model dapat berupa simpul hipotetik ataupun simpul informatik. Simpul hipotetik menunjukkan bahwa simpul tersebut merupakan variabel tersembunyi yang tidak dapat diobservasi secara langsung, sedangkan simpul informatik adalah variabel yang dapat diobservasi langsung dan mempengaruhi simpul hipotetik dalam model. Simpul hipotetik merupakan target atau tujuan dari diagnosis secara keseluruhan.

Untuk keperluan *fault diagnosis*, Bayesian Network bekerja sebagai *trouble shooter*. Bayesian Network yang murni hanya berdasarkan probabilitas, namun karena *troubleshooting* menggunakan probabilistik banyak memberikan hasil, maka dihitung tingkat kegagalan atau keberhasilan masing-masing node sesuai *constraints* yang sudah ditentukan.

Diagnosis menggunakan informasi bersama untuk menghitung bobot *evidence* yang terkandung dalam *state* setiap simpul informasi yang akan mengarah ke variabel hipotetik. Ranking hasil dari simpul informasi yang tidak pasti tersebut dipergunakan pada proses diagnosis. Untuk melakukan diagnosis suatu model diperlukan adanya :

- paling tidak satu simpul dapat diidentifikasi sebagai simpul hipotetik
- paling tidak dua simpul dapat diidentifikasi sebagai simpul informatik

Lokasi komponen yang rusak dalam sistem dapat diketahui dengan menggunakan *back-tracking* dalam jaringan untuk memeriksa simpul hipotetik.

Inkorporasi Data Dinamik

Diasumsikan bahwa sampel acak D dihasilkan dari model *causal* $M = \langle G, \theta_G \rangle$. Probabilitas posterior untuk diagram *causal* G dimana terdapat satuan data D adalah ⁽⁴⁾ :

$$P(G|D, \xi) = \frac{P(D|G, \xi)P(G|\xi)}{P(D|\xi)}$$

Marginal likelihood dari data G dapat dihitung sebagai :

$$P(D|G, \xi) = \int P(D|\theta_G, G, \xi)P(\theta_G|G, \xi)d\theta_G$$

dimana $P(D|\theta_G, G, \xi)$ adalah probabilitas data, $P(\theta_G|G, \xi)$ adalah distribusi prior untuk parameter probabilitas, dan $P(G|\xi)$ adalah diagram *causal*.

Bila diasumsikan terdapat dua dataset D dan D' yang diperoleh dari diagram kausal G dengan parameter yang berlainan Θ_G dan Θ'_G ,

$$P(D, D'|G, \xi) = \int P(D, D'|\Theta_G, \Theta'_G, G, \xi) P(\Theta_G, \Theta'_G|G, \xi) d\Theta_G d\Theta'_G$$

Untuk dua diagram *causal* G_1 dan G_2 yang saling tak tergantung, setiap distribusi yang kompatibel dengan G_1 juga kompatibel dengan G_2 . Sehingga dapat dinyatakan adanya ekivalensi

$$P(D|G_1, \xi) = P(D|G_2, \xi).$$

Bila data diperoleh secara berurutan dari berbagai sumber, $D = \{D^0, D^1, \dots, D^k\}$ adalah sekelompok data berurutan yang diperoleh dari diagram *causal* G dengan parameter $\Theta_G^0, \dots, \Theta_G^k$, dan $\Xi_G = \bigcup_{i=0}^k \Theta_G^i$, maka *marginal likelihood* dapat dihitung sebagai ⁽⁴⁾:

$$P(D|G, \xi) = \int P(D|\Xi_G, G, \xi) P(\Xi_G|G, \xi) d\Xi_G$$

PEMBAHASAN

Permasalahan yang muncul berkenaan dengan penggunaan *Bayesian Networks* terletak pada kualitas kepercayaan pada data sebelumnya. Jika tingkat kepercayaan data *prior* rendah, maka hasil yang diperoleh dari *Bayesian network* juga memiliki tingkat kepercayaan yang rendah. Data ekspektasi *prior* yang terlampau optimistik maupun pesimistik juga akan menurunkan tingkat kepercayaan hasil *Bayesian Networks*. Berkenaan dengan hal tersebut diperlukan distribusi statistik pada pemodelan data.

Alternatif berikutnya berkenaan dengan ketidakpastian (*uncertainty*) data dapat diatasi

maka *marginal likelihood* dapat dinyatakan sebagai.⁽⁴⁾

dengan memastikannya. Dalam arah ini pengembangan dilakukan dengan memperhatikan parameter-parameter *constraint* pada *node cause*. Pada aplikasi *trouble shooting* dapat dinyatakan bahwa data masukan yang diperoleh dari sensor berupa digit (gagal/berhasil, atau 0/1). Penggunaan masukan data on-line dan dipadukan dengan data reliabilitas komponen/sistem diharapkan tingkat kepercayaan hasil menjadi lebih baik.

Originalitas yang dikembangkan dalam *Bayesian Network* adalah dengan memasukkan *constraints* dalam bentuk berbagai parameter pembentuk yang menentukan tingkat keberhasilan atau kegagalan untuk masing-masing *node cause* pada diagram *cost and consequence*. Artinya, kalau program *fault diagnosis* ini dijalankan secara *on-line*, maka parameter pembentuk *node* adalah informasi keberhasilan/kegagalan bekerjanya komponen *node* beserta *delay time* dan sifat-sifat jaringan instrumentasi yang lain. Sedangkan bila program *fault diagnosis* dilakukan secara *off-line*, maka parameter pembentuk adalah parameter-parameter yang menjadi komponen untuk mengestimasi probabilitas kegagalan/keberhasilan *node*.

Berdasarkan diagram *cost and consequence* sistem yang menunjukkan kemungkinan solusi, maka dapat dibuat ranking

berdasarkan *likelihood* keberhasilan, dan node yang memiliki harga terbesar menunjukkan probabilitas terbesar mengalami kerusakan.

Bila probabilitas hukum berantai (*chain rule probability*) adalah :

$$p(x_1, \dots, x_R | \xi) = \prod_{i=1}^R p(x_i | x_1, \dots, x_{i-1}, \xi)$$

dimana ξ adalah status informasi saat ini.

Karena x_i dan $\{x_1, \dots, x_{i-1}\}$ tidak tergantung secara kondisional, maka :

$$p(x_i | x_1, \dots, x_{i-1}, \xi) = p(x_i | \prod_{i=1}^i \xi)$$

dimana $x_i = f(\alpha, \beta)$, dan α = data on-line, β = data reliabilitas komponen/sistem

Algoritma untuk pemograman dapat disusun sebagai berikut :

1. Susun database reliabilitas sistem/komponen terkait (0 sampai 1)
2. Susun sistem on-line/real-time untuk memperoleh status sistem/komponen terkait (0 atau 1)
3. Masukkan data reliabilitas dan status sistem ke dalam simpul pada model *Bayesian Networks* instalasi
4. Bila ada fault message muncul di tampilan utama, maka akan dapat diprediksi kemungkinan area lokasi kegagalan sistem/komponen
5. Menggunakan *back-tracking* probabilitas kegagalan simpul untuk memprediksi

lokasi kegagalan melalui pemeriksaan pada simpul informatik dan hipotetik

KESIMPULAN

Dalam penelitian ini telah dilakukan pengembangan *Bayesian Networks* untuk nantinya akan dibuat dalam bentuk perangkat lunak bagi keperluan *trouble shooting* instalasi. Pengembangan dilakukan dengan cara memasukkan data *on-line* dari sensor dan data reliabilitas komponen pada *node cause* sehingga diharapkan tingkat kepercayaan hasil menjadi lebih baik.

DAFTAR PUSTAKA

1. KADIE, C. M., HOVEL, D., HORVITZ, E. "MSBNx: A Component-Centric Toolkit for Modeling and Inference with Bayesian Networks". Technical Report MSR-TR-2001-67. Microsoft Research, Microsoft Corporation, 2001.
2. PEARL, J., RUSSELL, S. "Bayesian Networks". Computer Science Department, University of California, Berkeley. 2000.
3. PEARL, J. "Bayesian Networks, Causal Inference and Knowledge Discovery". Computer Science Department, University of California, Berkeley. 2001.
4. TIAN, J., PEARL, J. "Causal Discovery from Changes: a Bayesian Approach". Computer Science Department, University of California, Berkeley. 2001.

DISKUSI

Pertanyaan : Sigit Asmara Santa

1. Bagaimana tingkat “*autonomos*” diserahkan secara subyektif pada fault diagnostic supaya memberikan nilai yang bersifat general obyektif?
2. Bagaimana penyelesaian paling mungkin (*like hood*) dalam *Bayesian Network*, dari data-data riil informasi di *plant field level* dan *guesing condition* (nilai dugaan) untuk mendapatkan *fault diagnosis* yang benar ?

Jawaban : Djoko Hari Nugroho

1. *Fault diagnosis* “*autonomos*” sebagai sistem yang mampu mengatur sendiri, melakukan sesuatu tanpa dikendalikan dari luar diri memerlukan obyektivitas data prior dan dijauhkan dari penilaian subyektif (dugaan) operator/manusia. Kontribusi penelitian dalam pengembangan metode dilakukan dengan memberikan data prior sebagai fungsi dari (a) data reliabilitas komponen/sistem dan (b) data on-line dari instalasi.
2. Bila $D = \{D^0, D^1, \dots, D^k\}$ adalah sekelompok data berurutan yang diperoleh dari diagram kausal G dengan parameter $\Theta^0, \dots, \Theta^k$ dan $\Xi_G = U^k_{i=0} \Theta^i$, maka *likelihood* : $P(D|G, \xi) = \int P(D|\Xi_G, G, \xi) P(\Xi_G | G, \xi) d\Xi_G$ dimana data -data informasi di plant $D_p \in D$ dan data reliabilitas $D_R \in D$.