



# Pendeskripsian Kontur Dan Image Suatu Kawasan Eksplorasi Menggunakan Monte Carlo Markov Chain

Jose Rizal, Ulfasari Rafflesia

Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Bengkulu, Indonesia

Diterima 3 Oktober 2007; Disetujui 18 Desember 2007

**Abstrak** – Artikel ini membahas salah satu dari simulasi bersyarat (*conditional simulation*) yaitu Monte Carlo Markov Chain (MCMC) dalam pendeskripsian kontur dan image. Simulasi ini mengkombinasikan antara simulasi Monte Carlo (mengeneret state awal) dan Markov Chain (pengujian perubahan state). Dalam aplikasi MCMC pada suatu kawasan eksplorasi, terdapat proses pembentukan dan perubahan state untuk setiap iterasinya. Algoritma Metropolis-Hasting digunakan sebagai kriteria pengujian diterima atau tidaknya perubahan state. Sebagai studi kasus, diberikan contoh permasalahan dalam pendeskripsian image dan kontur pada kawasan eksplorasi di lapangan X.

**Kata kunci** : Simulasi Bersyarat, Monte Carlo Markov Chain, Algoritma Metropolis-Hasting

## 1. Pendahuluan

Dengan meningkatnya jumlah pertumbuhan manusia untuk setiap tahunnya, akan berdampak pada ketersediaan energi-energi yang digunakan manusia dalam seluruh kegiatan aktivitas kehidupan. Dengan keterbatasan cadangan energi dalam suatu kawasan eksplorasi, perlu adanya suatu perencanaan dalam memperluas kawasan eksplorasi atau mencari kawasan eksplorasi yang baru. Dalam pengembangan dan pemilihan kawasan eksplorasi, ahli-ahli pertambangan membutuhkan suatu metoda simulasi stokastik yang dapat memberikan suatu gambaran awal mengenai karakteristik reservoir berupa kontur dan image seakurat mungkin dengan data yang terbatas. Dengan harapan pada lokasi yang telah ditentukan dapat menghasilkan hasil tambang yang optimal.

## 2. Metode Penelitian

Masalah yang berkaitan dengan proses stokastik muncul dari keinginan peneliti-peneliti untuk membangun dan mengembangkan model-model matematika yang terjadi pada fenomena alam. Proses stokastik sendiri [3] adalah koleksi peubah acak  $\{S(t), t \in T\}$  yang diberi indeks dengan urutan oleh parameter  $t$ , dimana  $t$  berubah-ubah sesuai dengan himpunan indeks  $T$ .

Definisi [3] Suatu proses stokastik dengan indeks parameter kontinu  $\{S(t), t \in T\}$ , dikatakan proses Markov jika terdapat himpunan  $n$  titik waktu  $t_1 < t_2 < \dots < t_n$ , maka distribusi bersyarat  $S(t_n)$  diberikan  $S(t_1), S(t_2), \dots, S(t_{n-1})$  hanya bergantung pada  $S(t_{n-1})$  atau secara notasi:

$$\begin{aligned} P(S(t_n) \leq s_n | S(t_1) = s_1, S(t_2) = s_2, \dots, S(t_{n-1}) = s_{n-1}) \\ = P(S(t_n) \leq s_n | S(t_{n-1}) = s_{n-1}) \end{aligned} \quad (1)$$

Proses Stokastik  $\{S_t, t \in T\}$  dikatakan rantai Markov jika distribusi bersyarat keadaan yang akan datang  $S_{n+1}$  diberikan keadan sekarang  $S_n$  dan keadaan sebelumnya  $S_0, S_1, S_2, \dots, S_{n-1}$ , hanya bergantung dari keadaan sekarang dan bebas dari keadaan sebelumnya. Atau secara formal, proses stokastik  $\{S_t, t \in T\}$  dikatakan rantai markov jika memenuhi sifat:

$$\begin{aligned} \Pr(S_{n+1} \in A | S_n = s, S_{n-1} \in A_{n-1}, S_{n-2} \in A_{n-2}, \dots, S_0 \in A_0) = \\ \Pr(S_{n+1} \in A | S_n = s) \end{aligned} \quad (2)$$

untuk semua  $A_0, A_1, \dots, A_{n-1}, A \subset S$  dan  $s \in S$ .

Pada kasus ruang indeks  $S = \{x_1, x_2, \dots\}$  diskrit, matriks transisi  $P$  terdiri dari komponen baris ke- $i$  dan kolom ke- $j$  dinotasikan sebagai berikut  $P(x_i, x_j)$ , yang menyatakan peluang proses transisi ketika pada

keadaan  $x_i$  kemudian akan berpindah pada  $x_j$ .

Berikut ini Bila  $S$  hanya terdiri dari  $r+1$  komponen, maka matriks transisi  $P$  adalah:

$$P = \begin{pmatrix} P(x_0, x_0) & P(x_0, x_1) & \cdots & P(x_0, x_r) \\ P(x_1, x_0) & P(x_1, x_1) & \cdots & P(x_1, x_r) \\ \vdots & \vdots & \ddots & \vdots \\ P(x_r, x_0) & P(x_r, x_1) & \cdots & P(x_r, x_r) \end{pmatrix} \quad (3)$$

dimana :

$$P(x_i, x_j) \geq 0, \forall x_i, x_j \in S$$

dan

$$\sum_{x_j \in S} P(x_i, x_j) = 1 \forall x_i \in S$$

$P^n(x_i, x_j)$  didefinisikan sebagai peluang bahwa proses dari keadaan  $x_i$  akan berpindah ke keadaan  $x_j$  dalam tepat  $n$  langkah. Dapat dituliskan untuk suatu  $k \geq 0$  berlaku:

$$P^n(x_i, x_j) = \Pr(X_{k+n} = x_j | X_k = x_i), n \geq 0, x_i, x_j \in S \quad (4)$$

dan peluang bahwa proses dari keadaan  $x_i$  akan berpindah ke keadaan  $x_j$  dalam tepat  $n+m$  langkah dapat dihitung dengan menggunakan persamaan Chapman-Kolmogorov yang didefinisikan sebagai berikut:

$$P^{n+m}(x_i, x_j) = \sum_{l=0}^r P^n(x_i, x_l) P^m(x_l, x_j) \forall n, m \geq 0, \text{ dan } \forall x_i, x_j \in S \quad (5)$$

Distribusi marginal tingkat ke- $n$  didefinisikan sebagai vektor baris  $\pi^{(n)}$  dengan komponen-komponennya  $\pi^{(n)} = (\pi^{(n)}(x_0), \dots, \pi^{(n)}(x_r))$  untuk semua  $x_i \in S$ , dan  $\pi^{(0)}$  disebut distribusi awal dari Rantai Markov.

Perhatikan bahwa untuk sebarang  $x_i \in S$ , berlaku:

1.  $\pi(x_i) = \sum_{j=0}^r \pi(x_j) P(x_j, x_i)$
2.  $\sum_{i=0}^r \pi(x_i) = 1$
3.  $\pi^{(n)}(x_i) = \sum_{j=0}^r P^n(x_j, x_i) \pi^{(0)}(x_j)$

Persamaan di atas (3) dapat ditulis dalam bentuk perkalian matriks sebagai berikut:

$$\pi^{(n)} = \pi^{(0)} P^n = \pi^{(n-1)} P \quad (6)$$

Untuk kasus dimana  $n \rightarrow \infty$  maka  $\pi^{(n)}$  akan mendekati  $\pi$  (distribusi stasioner) dan tidak tergantung dari distribusi awal dengan syarat distribusi stasioner  $\pi$  ada dan  $\lim_{n \rightarrow \infty} P^n(x_i, x_j) = \pi(x_j)$ .

**a. Monte Carlo Markov Chain (MCMC)**

Metode Markov Chain Monte Carlo (MCMC) [2] adalah suatu teknik simulasi yang menggunakan kombinasi antara Simulasi Monte Carlo dan Rantai Markov yang berusaha memecahkan masalah model stokastik yang kompleks dengan cara mensimulasi sebuah barisan bilangan random yang berkorelasi dan membuat suatu kriteria penerimaan atau penolakan dari suatu state (keadaan) menggunakan *Algoritma Metropolis-Hasting*.


Algoritma Metropolis-Hasting merupakan suatu algoritma yang membangkitkan sebuah Rantai Markov dengan distribusi kesetimbangan  $\pi$ . Langkah-langkah dalam Algoritma Metropolis-Hasting adalah sebagai berikut: Misalkan  $X_n = i$  menyatakan image ke- $i$  dalam proses algoritma Metropolis-Hasting, langkah selanjutnya dalam proses simulasi tersebut adalah menerima image ke- $i$  sebagai hasil akhir atau menolak dan melanjutkan proses simulasi untuk mendapatkan image baru. Jadi akan ditentukan image dari  $X_{n+1}$  dengan tahapan sebagai berikut [2]:

1. Langkah awal
  - Membangkitkan sebuah kandidat keadaan  $j$  dari keadaan  $i$  dengan distribusi  $g(j|i)$  dengan  $i, j = 1, 2, \dots, m$ . Dimana  $g(j|i)$  merupakan suatu distribusi yang tetap dan memiliki sifat-sifat:
    - Jika  $g(j|i) = 0$  maka  $g(i|j) = 0$
    - $g(j|i)$  adalah suatu matriks transisi dari Rantai Markov *irreducible*
2. Langkah Keputusan (menerima atau menolak)
  - Misalkan peluang  $\alpha(j|i) \equiv \min\left\{1, \frac{\pi_j g(i|j)}{\pi_i g(j|i)}\right\}$ , dimana  $\alpha(j|i) = P(X_{n+1} = j | X_n = i)$
  - $X_{n+1} = j$  dengan peluang  $\alpha(j|i)$  dan  $X_n = i$  dengan peluang  $1 - \alpha(j|i)$


### 3. Hasil dan Pembahasan

Studi kasus diambil pada lapangan eksplorasi tambang batu bara di lapangan X. Misalkan terdapat lima titik lokasi lapangan batu bara X dengan informasi lokasi titik dan besarnya produksi batu bara yang dihasilkan pada titik tersebut, Lokasi 1 (100,200) produksi 80 ton/hari, Lokasi 2 (150,400) produksi 110 ton/hari, Lokasi 3 (300,400) produksi 95 ton/hari, Lokasi 4 (500,300) produksi 100 ton/hari, dan Lokasi 5 (500,100) produksi 90 ton/hari

Sebagai gambaran awal, kelima data tersebut diplot dalam bidang kartesius untuk mengetahui letak penyebaran data. Berikut ini plot dari kelima data tersebut (Gambar 1),



Gambar 1. Lokasi produksi batu bara



Gambar 2. Konfigurasi sistem


Langkah selanjutnya adalah membuat sistem konfigurasi (Gambar 2) dalam grid-grid yang dikehendaki. Sebagai contoh misalkan sistem konfigurasi tersebut dibagi dalam 25 grid. Setelah konfigurasi sistem dibentuk, langkah selanjutnya memberikan setiap nilai untuk masing-masing grid yang tidak ada nilai produksinya. Seperti tampak pada gambar 2, terdapat dua titik lokasi sumur yang berimpit dengan sistem grid yang dibuat. Yakni koordinat

(500,100) dan (300,400). Nilai produksi ini dikondisikan sesuai dengan nilai produksi sesungguhnya yakni 90 ton/jam dan 95 ton/jam. Ini merupakan image awal dari proses Monte Carlo Markov Chain, sebelum dilakukan penukaran pada setiap gridnya.


Tabel 1. Nilai produksi X pada awal iterasi

No	Lokasi		Produksi X (ton/jam)
	X	Y	
1	100	100	110 00
2	200	100	99 91
3	300	100	103 92
4	400	100	80 00
5	500	100	90 00
6	100	175	94 47
7	200	175	102 01
8	300	175	96 31
9	400	175	98 60
10	500	175	92 00
11	100	250	86 67
12	200	250	104 30
13	300	250	99 60
14	400	250	80 00
15	500	250	80 00
16	100	325	90 01
17	200	325	102 77
18	300	325	94 40
19	400	325	93 71
20	500	325	95 80
21	100	400	107 90
22	200	400	99 89
23	300	400	95 00
24	400	400	83 68
25	500	400	98 94

Sesuai dengan tahapan yang dijelaskan, hasil output dari iterasi MCMC berikutnya adalah updating image dan bentuk kontur,



Gambar 3. Image awal iterasi MCMC




Gambar 4. Kontur awal iterasi MCMC




Gambar 7. Image iterasi MCMC ketiga

Proses selanjutnya, melakukan penukaran pada tiap grid sampai dihasilkan suatu konfigurasi sistem yang stasioner. Berikut ini merupakan hasil iterasi kedua dari proses MCMC.




Gambar 5. Image iterasi MCMC kedua




Gambar 8. Kontur iterasi MCMC ketiga

Berikut ini merupakan iterasi keempat dari proses MCMC dimana terjadi penukaran sebanyak 27875 kali. Dan beberapa out put pada iterasi keempat.




Gambar 6. Kontur iterasi MCMC kedua



Gambar 9. Image iterasi MCMC keempat

Karena kriteria berhenti (stasioner) simulasi belum terpenuhi, proses MCMC dilakukan pada iterasi ketiga dimana terjadi penukaran sebanyak 3850 kali. Berikut ini beberapa out put pada iterasi ketiga.



Gambar 10. Kontur iterasi MCMC keempat

Tabel 5. Nilai produksi X pada iterasi keempat

No	Lokasi		Produksi X (ton/jam)
	X	Y	
1	100	100	92.00
2	200	100	99.60
3	300	100	86.67
4	400	100	90.01
5	500	100	90.00
6	100	175	98.38
7	200	175	99.91
8	300	175	107.90
9	400	175	98.94
10	500	175	102.01
11	100	250	94.47
12	200	250	110.00
13	300	250	80.00
14	400	250	80.00
15	500	250	104.30
16	100	325	91.19
17	200	325	102.77
18	300	325	80.00
19	400	325	83.68
20	500	325	93.71
21	100	400	95.80
22	200	400	103.92
23	300	400	95.00
24	400	400	99.89
25	500	400	96.31

Setelah iterasi keempat, hasil simulasi MCMC untuk iterasi selanjutnya memberikan suatu hasil (kontur dan image) yang identik dengan iterasi keempat. Hal ini menandakan konfigurasi sistem pada iterasi keempat sudah stasioner. Jadi konfigurasi pada iterasi keempat merupakan hasil akhir dari proses simulasi MCMC pada kawasan eksplorasi tersebut.

#### 4. Kesimpulan dan Saran

Algoritma Metropolis-Hasting mampu diaplikasikan dalam menghasilkan sebuah deskripsi suatu kawasan eksplorasi berupa image dan kontur suatu parameter kawasan eksplorasi. Tentu saja hasil ini dapat digunakan sebagai bahan pertimbangan dalam pengembangan suatu kawasan eksplorasi tambang.

Salah satu keunggulan yang dimiliki oleh Simulasi bersyarat (Algoritma Metropolis-Hasting) adalah

mampu mengatasi keterbatasan data dalam melakukan simulasi guna menghasilkan image dan kontur.

Perlu kajian ilmiah yang lebih dalam guna melihat validitas hasil simulasi bersyarat khususnya Algoritma Metropolis-Hasting pada simulasi Monte Carlo Markov Chain dalam pendeskripsian parameter reservoir kawasan eksplorasi.

#### Daftar Pustaka

- [1] Basuki, A, Budi, S.T, dan Huda, M., 2004, *Modeling dan Simulasi*, Edisi pertama IPTAQ Mulia Media Jakarta
- [2] Ross, S.M., 1997, *Simulation 2 Ed.*, HP Harcourt Academic Press, San Diego California.
- [3] Ross, S.M., 1996, *Stochastic Process 2 Ed.*, John Wiley & Sons, Inc. New York