

PENGEMBANGAN HIDDEN MARKOV MODEL UNTUK FONEM BERBAHASA INDONESIA PADA TRANSKRIPSI SINYAL SUARA

Agus buono¹ dan Sri Danuarita²

^{1,2}Departemen Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam
 Institut Pertanian Bogor
¹pudesha@yahoo.co.id

Abstrak

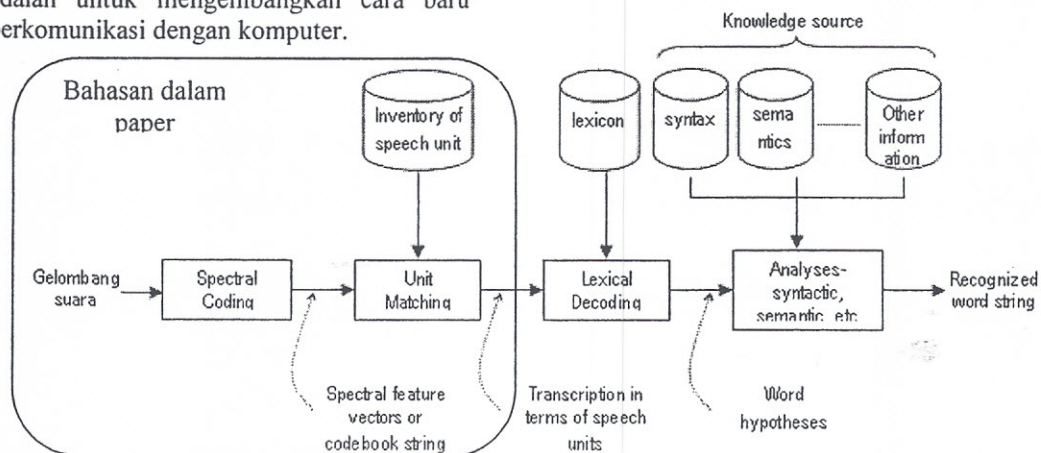
Pada paper ini disajikan suatu percobaan untuk transkripsi sinyal suara ke barisan fonem, yang mana hal ini merupakan bagian awal dari sistem konversi suara ke teks. Pendekatan yang dilakukan adalah dengan memodelkan fonem dengan HMM dan untuk meningkatkan kualitas hasil transkripsi dilakukan postprocessing menggunakan length common sequence (LCS), pencocokan string atau gabungan keduanya. Dengan mengambil kasus pada 10 fonem yang diperoleh dari 5 kata dengan sample masing-masing sebanyak 50 pengucapan diperoleh akurasi tertinggi adalah 82%. Kelemahan dari sistem yang ada adalah belum dikembangkannya HMM untuk fonem transisi dan belum mengakomodasi variasi durasi state. Oleh karena itu, ada harapan untuk meningkatkan akurasi sistem.

Kata kunci : *Mel-Frequency cepstrum coefficients (MFCC), Hidden Markov Model (HMM), speech to text transcription, phoneme, Baum Welch algorithm, Longest common sequence (LCS).*

1. Pendahuluan

Konversi suara ke teks merupakan proses melakukan transformasi dari sinyal suara sebagai input ke bentuk teks dalam suatu bahasa tertentu. Proses ini mempunyai kegunaan yang amat luas, salah satunya adalah untuk mengembangkan cara baru berkomunikasi dengan komputer.

Namun demikian, secara teknis masih banyak ditemui permasalahan, terutama karena sifat sinyal suara yang secara alami sangat bervariasi dengan kesehatan, waktu, emosi, dan alat transmisi, [1], disamping masalah lain terkait sifat ketatabahasaannya.



Gambar 1. Blok diagram konversi suara ke teks dan fokus bahasa dalam paper

Paper ini menyajikan pemodelan Hidden Markov Model (HMM) untuk fonem, yang merupakan unit bunyi terkecil dari sebuah bahasa, untuk transkripsi suara ke teks dengan ekstraksi ciri menggunakan teknik mel-frequency cepstrum coefficients (MFCC). Untuk menilai kesesuaian hasil transkripsi sinyal suara yang diinputkan dipergunakan teknik longest common sequence (LCS). Proses ini merupakan bagian awal dari sebuah sistem konversi suara ke teks secara utuh. Pada sistem yang lengkap telah memasukkan sifat ketatabahasaan dari domain bahasa yang dikaji, seperti diperlihatkan pada Gambar 1, [2].

Paper ini disajikan dengan susunan sebagai berikut : Bagian 2 mengenai teknik MFCC dan HMM. Metodologi disajikan pada Bagian 3 yang meliputi data, tahapan percobaan. Hasil pembahasan disajikan pada Bagian 4. Sebagai penutup adalah kesimpulan dan saran untuk penelitian selanjutnya yang disajikan pada bagian 5.

2. Teknik MFCC dan HMM

2.1 Teknik MFCC

Input dari analisis fitur suara adalah sinyal suara analog dan sebagai outputnya adalah *feature vector* untuk setiap *frame* (*time slice*), [3]. Tahap pertama adalah melakukan digitasi terhadap sinyal suara analog (disebut sebagai *analog-to-digital conversion*). Proses ini terdiri dari *sampling* dan kuantisasi, [1].

Sampling artinya mengukur amplitudo sinyal pada suatu indeks waktu tertentu. Dalam hal ini dikenal istilah *sampling rate*, yaitu banyaknya *sampling* yang dilakukan setiap detik. *Sampling rate* biasanya berkisar 8000 hingga 20000 *sample* per detik. Berikutnya adalah kuantisasi, yaitu menyimpan nilai amplitudo ke dalam nilai integer, yang dalam hal ini memakai representasi 8 bit atau 16 bit.

Setelah sinyal didigitasi, berikutnya adalah menyekatnya ke dalam *frame* dan menkonversikannya menjadi *feature vector* yang selanjutnya menjadi masukan bagi tahap berikutnya.

Fitur yang dipakai dalam penelitian ini adalah *Mel Frequency Cepstral Coefficients* (MFCC). MFCC merupakan fitur yang

populer saat ini. MFCC didasarkan pada variasi dari frekuensi kritis telinga manusia. Filter diletakkan secara linear pada frekuensi rendah dan logaritmik pada frekuensi tinggi untuk mendapatkan karakteristik suara yang penting. Diagram blok yang merepresentasikan struktur MFCC dapat dilihat pada Gambar 2, [4].

Dari Gambar 2 terlihat empat tahapan dalam ekstraksi ciri menggunakan MFCC, yaitu :

Frame blocking: sinyal suara dibaca per blok (*frame*) yang terdiri dari *N* sample. Antara dua *frame* yang bersisihan terdapat overlap *N-M* sample, dengan *M* adalah banyaknya pergeseran antar *frame* ($M < N$).

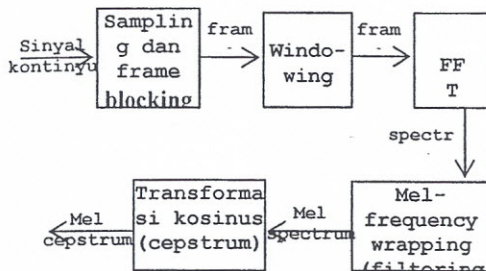
Windowing: proses *windowing* dilakukan pada setiap *frame* dengan tujuan untuk meminimumkan diskontinuitas antar *frame*, khususnya pada bagian awal dan akhir.

FFT (Fast-Fourier Transform): Pada tahap ini setiap *frame* yang terdiri dari *N* samples dikonversi dari domain waktu ke domain frekuensi. Output dari proses ini disebut dengan nama spektrum atau periodogram.

Mel-Frequency wrapping: tahap ini merupakan proses pengfilteran dari spektrum setiap *frame* yang diperoleh dari tahapan sebelumnya. Filter tersebut berupa *M* filter segitiga sama tinggi dengan tinggi satu. Filter ini dibuat dengan mengikuti persepsi telinga manusia dalam menerima suara. Persepsi ini dinyatakan dalam skala 'mel' (berasal dari **Melody**) yang mempunyai hubungan tidak linear dengan frekuensi suara, [4]. Dalam hal ini skala mel-frequency adalah linear untuk frekuensi kurang dari 1000 Hz dan logaritmik untuk frekuensi di atas 1000 Hz. Satu relasi antara frekuensi bunyi (dalam Hz) dengan skala mel adalah, [4], [5] :

$$\hat{f}_{mel} = 2595 * \log_{10} \left(1 + \frac{f}{700} \right) \dots \dots \dots (1)$$

Penjelasan detail mengenai teknik MFCC dapat dijumpai pada [4] dan [5].



Gambar 2. Block Diagram Teknik MFCC

Cepstrum: Pada tahap ini dilakukan konversi dari koefisien spektrum mel kembali ke domain waktu menggunakan transformasi kosinus sesuai rumus 2.

$$C_j = \sum_{i=1}^M X_i * \cos\left(\frac{j * (i - 0.5) * \pi}{20}\right) \dots\dots (2)$$

Dengan $j=1,2,3,\dots,K$; K adalah banyaknya koefisien; M adalah banyaknya filter segitiga; X_i adalah koefisien spektrum mel yang diperoleh dengan formula (1). Dalam hal ini C_j disebut sebagai mel frequency cepstrum coefficients (MFCC) koefisien ke j .

2.2 Hidden Markov Model

Hidden Markov Model (HMM), atau model Markov tersembunyi, ialah suatu model peluang temporal yang menggambarkan keterkaitan antar peubah *state* (*state variable*) dari waktu ke waktu, serta antara peubah *state* dengan peubah teramati (*observable variable*). Secara visual, model ini dapat digambarkan menggunakan suatu *finite state automata* dengan banyaknya *state* adalah sesuai dengan banyaknya kemungkinan kombinasi nilai variabel dalam model. Dalam hal ini, setiap *state* merupakan suatu kombinasi variabel tersebut. Sebagai contoh, jika terdapat suatu model temporal dengan tiga variabel biner maka banyaknya *state* adalah $2^3 = 8$ buah. Di dalam HMM, peubah *state* adalah peubah yang tak teramati (*hidden variable*), dan peubah yang teramati (*observable variable*).

Berikut adalah notasi yang digunakan dalam HMM, [6] :

N : Banyaknya *hidden state* (*state* ke 1, 2, 3, ..., n). Sedangkan q_t menotasikan *state* ke- q pada indeks waktu t .

M : Banyaknya kemungkinan kemunculan peubah teramati. Sedangkan v_k , untuk $k=1, 2, 3, \dots, M$, adalah nilai-nilai peubah teramati.

Π : adalah $\{\pi_i\}$, dengan $\pi_i = P(q_1=i)$, yaitu peluang pada tahap awal berada pada *state* i . Dalam hal ini $\sum_{i=1}^N \pi_i = 1$

A : adalah $\{a_{ij}\}$ dengan $a_{ij} = P(q_{t+1}=j|q_t=i)$, yaitu peluang berada di *state* j pada waktu $t+1$ jika pada waktu t berada di *state* i . Dalam hal ini diasumsikan a_{ij} bebas dari waktu.

B : adalah $\{b_j(k)\}$, dengan $b_j(k) = P(v_k \text{ pada waktu } t | q_t=j)$, yaitu peluang peubah teramati yang muncul adalah simbol v_k .

O_t : adalah notasi untuk nilai teramati pada waktu t , sehingga barisan nilai teramati (*observable symbol*) adalah $O = O_1, O_2, O_3, \dots, O_T$. Dengan T adalah panjang observasi yang dilakukan.

Dengan notasi-notasi seperti di atas, maka suatu HMM dilambangkan dengan :

$$\lambda = (A, B, \Pi)$$

Secara umum ada tiga masalah dasar yang terdapat dalam HMM, [6], yaitu : (1) Evaluasi untuk menduga peluang munculnya barisan $O = O_1, O_2, O_3, \dots, O_T$ dari sebuah HMM; (2) Decoding untuk memilih barisan *state* $Q = q_1, q_2, \dots, q_T$ yang 'optimal', yaitu yang paling besar kemungkinannya menghasilkan O yang diketahui; dan (3) Pembelajaran parameter HMM, yaitu melakukan pendugaan terhadap parameter-parameter model HMM, $\lambda = (A, B, \Pi)$, sehingga $P(O|\lambda)$ atau $P(O, Q|\lambda)$ maksimum. Secara detail, ketiga algoritma tersebut dapat dijumpai di [6] dan [7].

3. Metodologi

3.1 Data dan Praproses


Data yang dipergunakan berasal dari pengucapan satu orang pembicara yang mengucapkan beberapa 5 kata (Tabel 1) sebanyak 50 kali, sehingga diperoleh 250 data sinyal suara.

Tabel 1 Kata yang digunakan untuk membentuk model

Kata	Fonem	
	Fonem asli	Fonem transisi
Alam	/a/,/l/,/m/	/al/,/la/,/am/
Aman	/a/,/m/,/n/	/am/,/ma/,/an/
Malam	/a/,/l/,/m/	/ma/,/al/,/la/,/am/
Mana	/a/,/m/,/n/	/ma/,/an/,/na/
Nama	/a/,/m/,/n/	/na/,/am/,/ma/

Selanjutnya sinyal suara tersebut disampling dengan smapling rate 11 kHz dengan durasi 1 detik. Dari 10 kata tersebut, diperoleh 10 fonem seperti terlihat pada Tabel 1.

Setelah menghapuskan bagian *unvoice*, selanjutnya melakukan proses MFCC dengan lebar frame 30 ms dan overlap 50%. Dari sekuen vektor MFCC yang terdiri 13 koefisien ini, dilakukan segmentasi manual untuk mendapatkan sekuen setiap fonem dari setiap sinyal dalam data training (Gambar 3). Berdasar sekuen setiap fonem ini dikembangkan model HMM ergodic dengan beberapa jumlah hidden state (yaitu 2, 3, 4, dan 5).



Gambar 3 Ilustrasi sekuen fonem hasil segmentasi

3.2 Tahapan Percobaan

Tahapan detail dari percobaan yang dilakukan adalah seperti disajikan pada Gambar 4.

4. Hasil dan Pembahasan

Berdasar data pelatihan, dilakukan pendugaan parameter model HMM dengan iterasi sebanyak 5, 10, dan 15 dengan jumlah hidden state 2, 3, dan 4, menggunakan algoritme Baum-Welch. Berdasar model ini dilakukan transkripsi terhadap data uji, dan selanjutnya dilakukan tahapan *postprocessing* untuk mendapatkan label kata.

Hasil *postprocessing*

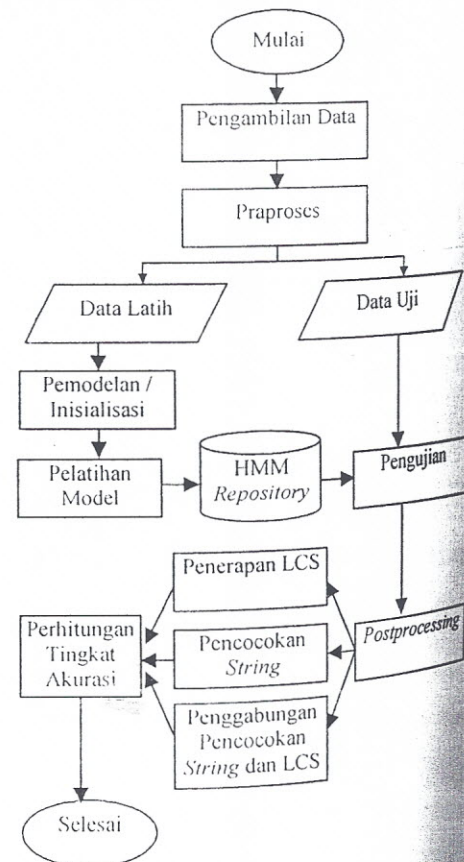
Tiga proses *postprocessing* yang dipergunakan untuk menetapkan kata yang

diinputkan adalah LCS, pencocokan *string*, dan kombinasi penggabungan pencocokan *string* dan LCS. Hal ini dilakukan untuk meningkatkan akurasi sistem. Hasil proses *postprocessing* merupakan barisan fonem yang belum sesuai dengan kata yang sebenarnya. Tabel 2 menunjukkan variasi hasil *postprocessing* pada masing-masing kata.

Tabel 2 Hasil *postprocessing*

Kata				
Alam	Aman	Malam	Mana	Nama
ALAM	AMAN	MNMALAM	MANA	NAMAN
ALAMN	AMANL	MALALAMN	MAN	NAMAMN
ALALAM	AMAMAN	MALAMALA	MANAN	NAMNMAN
ALALMN	AMALAN	MAMALALAM	MANLAN	NALAMAM
ALALAMN	AMAMLAN	MAMLAMALA	MAMANAN	NANAMNMA


Dari tabel tersebut terlihat bahwa hasil *postprocessing* memperbaiki hasil transkripsi, sehingga lebih mudah dikenali pada tahap selanjutnya yang mempertimbangkan aspek ketatabahasaan (tidak dibahas dalam paper ini).



Gambar 4. Tahapan proses percobaan

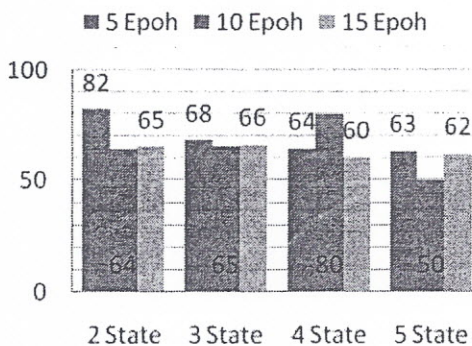
Hasil Pengujian Model HMM

Rata-rata hasil akurasi dengan semua kombinasi jumlah iterasi pelatihan HMM dan jumlah hidden state, terlihat bahwa postprocessing dengan gabungan LCS dan pencocokan *string* memberikan akurasi tertinggi, yaitu 69% (Gambar 5).



Gambar 5 Grafik akurasi LCS dan pencocokan *string*.

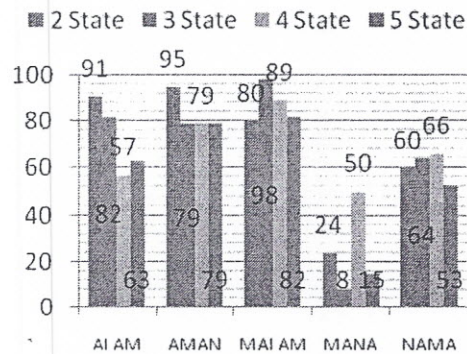
Akurasi yang dihasilkan HMM untuk setiap *state* dapat dilihat pada Gambar 6. Akurasi yang dihasilkan oleh HMM 2 *state* dengan 5 epoh merupakan akurasi tertinggi yaitu sebesar 82%, sedangkan akurasi terendah yaitu 50% dihasilkan oleh HMM 5 *state* dengan 10 epoh. Dari Gambar 6 dapat diketahui bahwa HMM dengan jumlah hidden state 2 memberikan akurasi yang tinggi (82%).



Gambar 6 Grafik akurasi HMM setiap *state*.

Hasil Pengujian Kata

Secara umum, kata yang paling mudah dikenali adalah kata MALAM dengan akurasi rata-rata sebesar 87%, sedangkan kata MANA memiliki akurasi rata-rata terendah yaitu 25%.



Gambar 7 Grafik akurasi setiap kata untuk setiap *state*.

Gambar 7 menunjukkan akurasi setiap kata melalui pengujian HMM setiap *state*, sedangkan Tabel 3 menunjukkan akurasi terendah dan tertinggi untuk masing-masing kata.

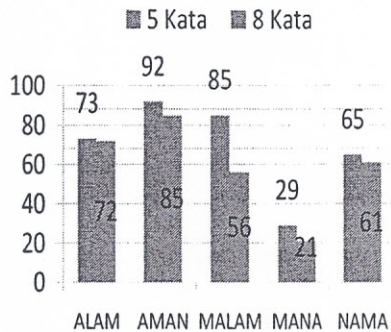
Tabel 3 Akurasi maximum dan minimum setiap kata

Fonem	Akurasi Min & Max	Model HMM	
		ΣState	ΣEpoh
ALAM	40%	4	5
	92%	2	5,10
AMAN	56%	4	15
	98%	4	5
MALAM	76%	4	5
	100%	3	15
MANA	6%	3	5,10
	62%	4	10
NAMA	54%	2	10
	90%	3	15

Penggunaan Kata Lain Pada LCS

Kata yang digunakan dalam LCS pada percobaan di atas adalah kata yang terdapat dalam kamus, yaitu ALAM, AMAN, MALAM, MANA, dan MALAM. Untuk mengetahui kestabilan kinerja sistem, penerapan LCS tidak hanya menggunakan kelima kata tersebut, tetapi juga melibatkan kata lain namun mengandung fonem yang sama yaitu AMAL, LAMA, dan MAMA. Gambar 8 menunjukkan perbandingan akurasi penerapan LCS menggunakan kata lain dan tanpa kata lain pada HMM dengan 5 epoh. Berdasarkan Gambar 8 dapat diketahui bahwa penambahan kata lain pada LCS dapat menurunkan tingkat akurasi sistem. Hal ini logis, dikarenakan ada

pilihan yang lebih banyak dalam kamus-kata.



Gambar 6 Grafik akurasi penerapan LCS dengan 5 kata dan 8 kata

Penurunan akurasi yang paling signifikan terjadi pada kata MALAM. Hal ini dikarenakan hasil penerapan gabungan pencocokan string dan LCS untuk kata MALAM sebagian besar mengandung karakter awal 'mama' misalnya, 'mamalam', sehingga banyak yang diidentifikasi sebagai kata MAMA.

5. Kesimpulan

Berdasar percobaan yang telah dilakukan, terlihat bahwa HMM dapat diterapkan untuk memodelkan fonem dan dipergunakan dalam konversi sinyal suara ke teks. Tahap postprocessing untuk memperbaiki hasil transkripsi adalah gabungan pencocokan *string* dan LCS. Akurasi tertinggi yang dihasilkan adalah 82% dengan HMM 2 state dan 5 kali pelatihan. Sedangkan kata yang paling baik dikenali model adalah kata MALAM dengan akurasi sebesar 87%. Model terbaik mampu mengenali beberapa kata lain yang mengandung fonem yang sama namun akurasi yang dihasilkan masih rendah.

Beberapa kelemahan yang ada diantaranya adalah minimnya jumlah data

pelatihan sehingga dirasa kurang mampu mengakomodasi semua variasi yang ada dari sebuah fonem. Juga perlu dikembangkan model tersendiri untuk fonem transisi. Dari aspek HMM sendiri, perlu diakomodasi variasi durasi dari setiap state.

Daftar Rujukan

- [1] Jurafsky, D. dan J H. Martin. 2000. *Speech and Language Processing : An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition*. Prentice Hall. New Jersey
- [2] Pelton, G.E. 1993. *Voice Processing*. McGraw-Hill, International Edition, Singapore.....
- [3] Buono, A., Y. Mandrasari dan S.N. Neyman. 2010. Pengembangan Model Markov tersembunyi untuk Pengenalan Kata Berbahasa Indonesia. Prosiding Pada Munas APTIKOM 2010 "Competitive Advantage in ICT", November 2010, ISSN 2087-1562
- [4] Cornaz, C. dan U. Hunkeler. An Automatic Speaker Recognition System. Mini-Project. http://www.ifp.uiuc.edu/~minhdo/teaching/speaker_recognition, access : August, 15, 2005.
- [5] Todor D. Ganchev. 2005. *Speaker Recognition*. PhD Dissertation, Wire Communications Laboratory, Department of Computer and Electrical Engineering, University of Patras Greece.
- [6] Dugad R, Desai UB. 1996. *A Tutorial on Hidden Markov Models*. Technical Report, Department of Electrical Engineering, Indian Institute of Technology – Bombay, India
- [7] L.R. Rabiner. 1989. *A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition*, Proceeding IEEE, Vol 77 No. 2, pp 257-289.

PENGEMBANGAN MODEL DECISION NETWORK DAN IMPLEMENASINYA PADA SISTEM KALENDER TANAM PERTANIAN KABUPATEN PACITAN

Agus buono¹, Rizaldi Boer², Suciantini³, dan Arief Ramadhan⁴

¹ Departemen Ilmu Komputer, FMIPA - Institut Pertanian Bogor

^{2,4} CCROMSEAP - Institut Pertanian Bogor

³ Balai Penelitian Klimatologi, Balitbang - Deptan

¹ pudsha@yahoo.co.id, ² rizaldiboer@gmail.com

Abstrak

Pada paper ini disajikan suatu pengembangan model decision network yang merupakan pengembangan dari bayesian network guna menentukan pilihan alternatif pola tanam yang meminimumkan risiko kekeringan pada pertanaman kedua. Empat peubah dalam bayesian network adalah fase SOI, curah hujan, sisa dasarian musim hujan dan bencana kekeringan. Sedangkan alternatif keputusan yang bisa dipilih ada 4 yang semuanya adalah pola tanam padi-padi. Perbedaan utamanya adalah pada awal penanaman pertama. Sesuai dengan kategori peubah dalam bayesian network, maka ada 42 parameter dalam model bayesian network yang diduga dengan menggunakan teknik kemungkinan maksimum. Model yang dikembangkan telah berhasil diimplementasikan sebagai modul dari prototipe sistem kalender pertanian untuk Kabupaten Pacitan. Pada sistem yang dengan unit kecamatan ini, Pengguna secara dinamis dapat melakukan update data, struktur bayesian network dan fungsi risiko, serta melakukan prediksi harapan kerugian untuk sembarang kemunculan kondisi iklim.

Kata kunci : Metode kemungkinan maksimum (*maximum likelihood estimation, MLE*), *Bayesian Network (BN)*, *Decision Network (DN)*, dan kalender tanam pertanian (*Cropping calendar*).

1. Pendahuluan

Kalender Tanaman merupakan penjadwalan waktu tanam berbagai komoditi pertanian yang disusun dalam satu pola tanam di suatu daerah, [1]. Pola tanam yang tidak sesuai dengan prakiraan musim akan berisiko terkena bencana iklim seperti banjir dan kekeringan. Pengalaman menunjukkan bahwa tingkat variasi iklim di Indonesia sangat tinggi dan hasil pertanian secara nyata sangat tergantung dari kondisi iklim. Pemahaman informasi iklim sangat bermanfaat dalam melakukan adaptasi guna menghindari risiko yang lebih besar.

Paper ini menyajikan pemodelan Decision Network (DN) sebagai alat untuk memproses informasi iklim guna memberikan alternatif pola pertanaman padi yang meminimalisasi risiko akibat variasi iklim. Dengan teknik seperti ini, maka informasi pola tanam dapat dikembangkan secara dinamis mengikuti pola iklim yang ada. Dengan demikian, informasi yang

diberikan akan lebih baik dibandingkan dengan informasi pola tanam sebelumnya yang bersifat statis. Bencana iklim yang menjadi bahasan pada paper ini difokuskan pada kekeringan yang terjadi pada pertanaman kedua dari pola tanam padi-padi.

Paper ini disajikan dengan susunan sebagai berikut : Bagian 2 mengenai rumusan masalah kalender tanam dengan model decision network. Teori ringkas mengenai Bayesian Network disajikan pada bagian 3. Bagian 4 menyajikan teori ringkas mengenai decision network. Hasil dan pembahasan disajikan pada bagian 5. Sebagai penutup adalah kesimpulan dan saran untuk penelitian selanjutnya yang disajikan pada bagian 6.

2. Perumusan Masalah

Bencana kekeringan seringkali terjadi pada pertanaman kedua, yang disebabkan oleh munculnya kejadian El-Nino yang


ditengarai dengan anomali suhu muka laut di kawasan Pacific atau Indeks Osilasi Selatan (SOI). Indek Osilasi Selatan merupakan indek yang menggambarkan perbedaan tekanan udara dekat permukaan laut di kawasan Tahiti (P_{Tahiti}) dan Darwin (P_{Darwin}), yang dirumuskan sebagai :

$$SOI = \frac{(P_{Tahiti} - P_{Darwin})}{Stdev(P_{Tahiti} - P_{Darwin})} \times 10 \quad (1)$$

Selanjutnya nilai SOI dikelompokkan menjadi 5 fase yaitu (Stone *et al.*, 1996, dalam [1]):

1. Fase 1: konstan negatif
2. Fase 2: konstan positive
3. Fase 3: menurun cepat
4. Fase 4: meningkat cepat
5. Fase 5: mendekati nol

Fase 1 dan 3 dikenal dengan fenomena El-Nino, 2 dan 4 La-Nina dan fase 5 dikenal dengan normal. Kejadian El-Nino akan menyebabkan musim tanam mundur. Sementara itu pada kondisi La-Nina, musim tanam akan maju, seperti terlihat pada Gambar 1, [1].




Gambar 1. Rata-rata luas tambah tanam bulanan padi di Jawa Barat (1971-2001) pada tahun normal, El-Nino dan La-Nina

Bencana kekeringan kemungkinan akan terjadi saat kondisi El-Nino, khususnya pada pertanaman kedua. Hal ini dikarenakan pada pertanaman kedua, musim hujan sudah berhenti. Namun demikian, jika curah hujan pada tanam kedua masim tinggi (di atas normal) dan musim hujan masih berlangsung maka bencana kekeringan (K) tidak terjadi. Kedua hal tersebut dinyatakan sebagai sifat hujan, CH, (yaitu di bawah normal, normal dan di atas normal) dan

panjang musim hujan dinyatakan sebagai sisa dasarian musim hujan (SDMH), yang keduanya sangat tergantung dari fase SOI atau fase ENSO.

Dari bahasan di atas, model keterkaitan ke empat peubah dapat digambarkan dalam bentuk directed acyclic graph (DAG) seperti Gambar 2.



Gambar 2. Keterkaitan ENSO, CH, SDMH, dan K

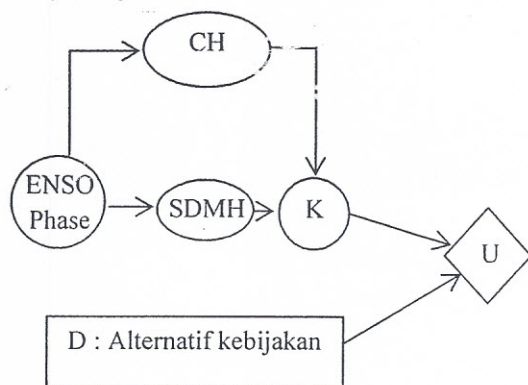
Dalam hal ini ENSO fase berpengaruh langsung pada CH dan SDMH. Sedangkan CH dan SDMH berpengaruh langsung pada K (Kekeringan). Pemilihan nilai-nilai untuk 4 peubah tersebut adalah seperti disajikan pada Tabel 1.

Tabel 1. Nilai peubah Pengkelasan

No	Variabel	Nilai	Arti
1	E-Phase : ENSO Phase Bln Agustus	1	Near Zero (SOI 5)
		2	Consistent Negative (SOI 1/3)
		3	Consistent Positive (SOI 2/4)
2	CH : Curah Hujan	1	$CH < (0.85 * \text{Rataan tahunan})$
		2	$(0.85 * \text{Rataan tahunan}) < CH < 1.15 * \text{Rataan Tahunan}$
		3	$CH > (1.15 * \text{Rataan Tahunan})$
3	SDMH : Sisa Dasarian Musim Hujan	1	Sisa MH < 10 dasarian
		2	Sisa MH : 10, 11, 12, dan 13 dasarian
		3	Sisa MH > 13 dasarian
4	K : Kekeringan	1	Tidak ada lahan kekeringan

gan	2	Kekeringan ringan
	3	Kekeringan besar
	4	Kekeringan sangat besar

Pemilihan nilai untuk fase SOI adalah mengikuti fenomena Normal, El-Nino, dan La-Nina. Untuk curah hujan adalah mengikuti ketetapan dari BMKG. Nilai SDMH berdasar fakta bahwa masa tanam padi adalah sekitar 4 bulan (12 dasarian), maka jika kurang dari 10 dinilai sangat kurang, 10-13 cukup, dan untuk SDMH > 13 maka berlebih. Sedangkan untuk tingkat kekeringan dikelompokkan menjadi 4, yang nilai batas-batasnya sangat tergantung dari wilayah kajian.



Gambar 3. Keterkaitan Peubah Iklim, Bencana, Alternatif Kebijakan dan Risiko

Selanjutnya, model keterkaitan peubah tersebut digabungkan dengan sebuah node yang mencerminkan alternatif kebijakan. Setiap kemunculan kejadian peubah dan kebijakan yang dipilih akan berimplikasi pada risiko tertentu. Dengan dasar pemikiran tersebut, maka diagram Gambar 2 dikembangkan menjadi diagram gambar 3. Nilai informasi peubah pada Gambar 2 dikuantifikasi secara probabilistik yang nilainya diduga berdasar data. Dengan menambahkan nilai peluang bersyarat (conditional probability) pada setiap peubah dalam Gambar 2, maka DAG tersebut dikenal dengan Bayesian Network (BN). Sedangkan diagram Gambar 3 dikenal dengan Decision Network (DN).

Pada paper ini, ada 4 kebijakan pola tanam yang dilakukan (mengikuti kebiasaan petani), yang semuanya adalah pertanaman padi-padi. Perbedaannya adalah pada awal penanaman.

D1: penanaman pertama di awal musim hujan

D2: penanaman pertama mundur 1 bulan

D3: penanaman pertama mundur 2 bulan

D4: penanaman pertama mundur 3 bulan

Sedangkan node U adalah risiko yang nilainya sebagai fungsi dari kebijakan pola tanam yang diambil dan kejadian iklim bencana yang muncul, yaitu :

$$U = f(D, K)$$

Nilai risiko ini sangat tergantung dari wilayah kajian.

3. Bayesian Network

Bayesian Network (BN) merupakan sebuah directed acyclic graph dengan setiap node yang ada dilengkapi dengan distribusi bersyarat, [2]. Dalam hal ini setiap node merepresentasikan sebuah variabel dan link dari node A ke node B (A sebagai parent dari B) menunjukkan bahwa kemunculan nilai peubah A akan berpengaruh langsung pada kemunculan node B. Pada paper ini setiap node merepresentasikan peubah diskret, sehingga distribusi peluang pada setiap node dapat disajikan dalam bentuk tabel dan disebut sebagai tabel peluang bersyarat (conditional probability table, CPT).

Secara umum, peubah-peubah (node-node) pada BN dikelompokkan menjadi 3 jenis, yaitu peubah query (Q), peubah evidence (E) dan peubah hidden (Y), [3], sehingga berlaku :

$$X = Q \cup E \cup Y$$

X adalah himpunan semua peubah yang ada dalam BN. Dalam hal ini peubah query adalah peubah yang ingin dihitung distribusinya kalau diketahui kemunculan beberapa peubah lain yang disebut sebagai peubah evidence. Selain peubah query dan peubah hidden, maka dikelompokkan dalam peubah hidden. Ada 3 permasalahan dalam pemodelan BN, yaitu pembuatan struktur, inferensi, dan pendugaan parameter model. Dalam pembuatan struktur, peran pakar bidang ilmu yang menjadi kajian lebih dominan. Seperti halnya pada paper ini, struktur Bn ditentukan berdasar analisis bidang kajian, yaitu permasalahan iklim.

3.1 Inferensi

Inferensi merupakan pendugaan distribusi peubah query (Q) kalau diketahui adanya beberapa eviden (E), yaitu P(Q|E). Sesuai dengan kaidah bayes, maka P(Q|E) dirumuskan sebagai :

$$P(Q|e) = \frac{P(Q,e)}{P(e)} = \alpha P(Q,e) \quad (2)$$

Dalam hal ini nilai α hanya merupakan normalisasi, mengingat total nilai peluang adalah 1. Nilai $P(Q,e)$ dirumuskan sebagai :

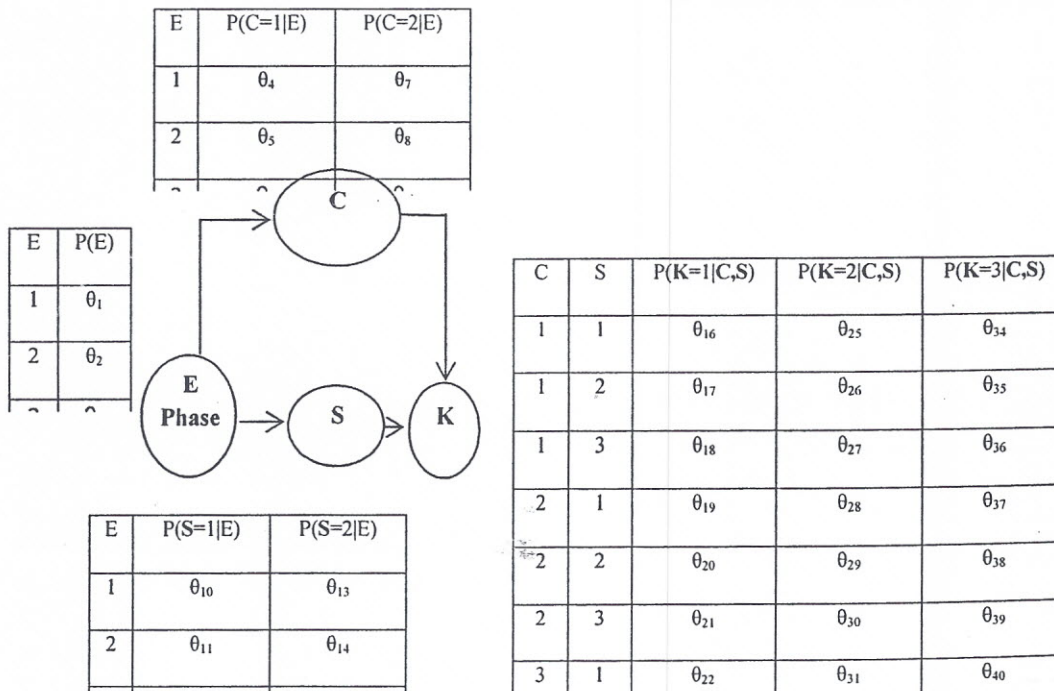
$$P(Q,e) = \sum_{\forall y \in Y} P(Q,e,y) \quad (3)$$

Sesuai dengan prinsip dasar teori peluang dan keterkaitan antar peubah dalam BN, maka nilai $P(Q,e,y)$ dirumuskan sebagai berikut :

$$\left[P(Q,e,Y) = \prod_{\forall X_i \in X} P(X_i | X_i's \text{ Parents}) \right] \quad (4)$$

Oleh karena itu, distribusi peubah query yang ingin dihitung adalah dirumuskan mengikuti formula berikut :

$$P(Q|e) = \alpha \sum_{\forall y \in Y} \prod_{\forall X_i \in X} P(X_i | X_i's \text{ parents}) \quad (5)$$



Gambar 4. Model BN dengan 4 peubah dan mempunyai 42 parameter

3.2 Pendugaan Parameter BN dengan Metode Kemungkinan Maksimum

Metode kemungkinan maksimum merupakan teknik pendugaan parameter yang memaksimalkan fungsi kemungkinan. Fungsi kemungkinan merupakan fungsi dari parameter kalau diketahui beberapa sample, [4]. Dari sebuah struktur BN dengan parameter Θ dan data M sample, yaitu $d_1, d_2, d_3, \dots, d_M$, maka fungsi kemungkinan dari Θ adalah, [2] :

$$P(\Theta | d) = P(d | \Theta) = \prod_{j=1}^M P(d_j | \Theta) \quad (6)$$

Oleh karena itu, tahapan teknis dari metode kemungkinan maksimum untuk menduga parameter sebuah BN tertentu adalah sebagai berikut :

1. tuliskan formula fungsi kemungkinan sesuai dengan persamaan di atas dan struktur BN
2. turunkan fungsi kemungkinan tersebut terhadap setiap parameter
3. hitung nilai parameter sedemikian sehingga nilai turunannya nol

Misalkan struktur BN adalah seperti Gambar 2, maka parameter dari model BN adalah seperti ditunjukkan pada Gambar 4. Terlihat ada 42 parameter dalam model tersebut.

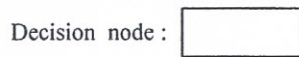
4. Decision Network

Decision Network (DN) atau sering disebut juga sebagai Influenced Network merupakan pengembangan dari Bayesian Network (BN). Pada dasarnya BN merupakan model visual menggunakan graph dari distribusi bersama sejumlah peubah. Oleh karena itu, pada BN bisa mengetahui peluang dari suatu peubah tertentu (peubah query) kalau diketahui nilai peubah lain (peubah evidence). Jadi output dari BN adalah distribusi peubah query. Sedangkan pada DN, ingin mengetahui bagaimana kaitan dari tiga hal, yaitu keputusan yang diambil, resiko yang terjadi, serta ketakpastian dari peubah-peubah dalam BN. DN merupakan BN yang dikembangkan dengan dua hal, yaitu keputusan yang bisa diambil dan resiko yang mungkin terjadi, sehingga DN terdiri dari tiga jenis node, yaitu :


- a. chance node : node yang merepresentasikan peubah-peubah dalam BN. Node ini dilambangkan dengan simbol



- b. Decision node : node yang merepresentasikan peubah keputusan, sehingga nilai dari node ini adalah semua kemungkinan keputusan yang bisa diambil. Decision node dilambangkan dengan



- c. Utility node : node yang merepresentasikan nilai resiko yang mungkin terjadi. Oleh karena itu, nilai dari node ini adalah semua kemungkinan resiko yang bisa terjadi akibat dari keputusan yang diambil dan ketakpastian yang ada pada BN. Utility node dilambangkan dengan :



Pilihan alternatif kebijakan didasarkan pada pilihan yang memaksimalkan harapan utility atau meminimumkan resiko, tergantung sifat fungsi U, yang dirumuskan sebagai :

$$EU(D|E) = \sum_{vi} P(O_i | E)U(O_i, D) \quad (7)$$

Setelah semua alternatif kebijakan, D, dihitung nilai harapan utilitynya, maka pilihan didasarkan pada D yang memaksimalkan utility atau meminimumkan risikonya.

Fungsi utilitas pada paper ini adalah fungsi risiko, sehingga kriteria pemilihan kebijakan adalah yang meminimumkan harapan risiko kekeringan. Oleh karena peubah bencana (K) mempunyai 4 kemungkinan nilai dan ada 4 alternatif pola tanam (D), maka ada 4x4=16 kemungkinan nilai utilitas (U). Nilai f(D,K) adalah luas lahan (Ha) penanaman padi kedua yang terkena bencana kekeringan untuk setiap pasangan (D,K), dan ditentukan dengan tahapan sebagai berikut :

Tahap 1 : pencarian tahun terjadinya kekeringan penanaman padi kedua. Untuk setiap tahun terjadi kekeringan, lakukan tahap 2 dan tahap 3.

Tahap 2 : menghitung proporsi luas tambah tanam (LT) padi kedua untuk pola D1, D2, D3, dan D4.

Tahap 3 : menduga luas lahan padi penanaman kedua yang terkena bencana untuk setiap pola tanam (D1, D2, D3, dan D4). Jikalau setelah tahap 3 ini masih ada kombinasi (D,K) yang belum bisa ditentukan dikarekan keterbatasan data, lakukan tahap 4.

Tahap 4 : menduga nilai luas lahan penanaman padi kedua yang terkena bencana, dari hasil tahap 3, dan selesai.

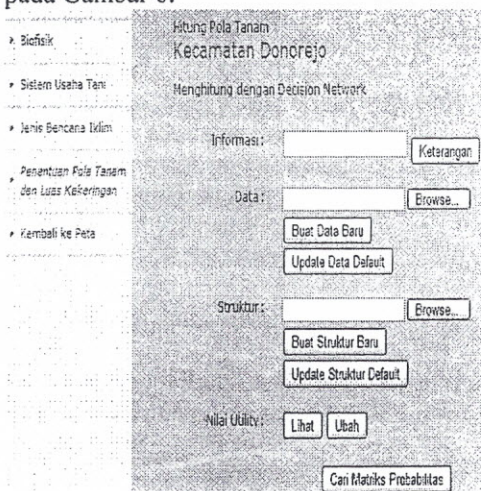
5. Hasil dan Pembahasan

Model komputasi yang telah dideskripsikan di atas telah berhasil dijadikan sebagai salah satu modul pada prototipe sistem kalender pertanian, yang diberi nama SIPOTAN. Tampilan utama dari SIPOTAN adalah seperti pada Gambar 5.



Gambar 5. Tampilan prototipe SIPOTAN

Dengan memilih salah satu kecamatan, misalnya pilih kecamatan Donorejo, maka akan muncul tampilan menu SIPOTAN untuk Kecamatan Donorejo, seperti terlihat pada Gambar 6.



Gambar 6. Tampilan menu SIPOTAN untuk Kecamatan Donorejo

Terlihat ada 5 fitur, salah satunya adalah fitur "Penentuan Pola Tanam dan Luas Kekeringan". Jika fitur ini dipilih, maka sistem menampilkan seperti terlihat pada sebelah kanannya. Terlihat bahwa Pengguna secara dinamis dapat melakukan penghitungan harapan kerugian sesuai kondisi iklim yang ada dengan memilih isian "Informasi", "Data", "Struktur" dan "Nilai Utility". Semua pilihan tersebut bersifat optional, yang artinya, jika Pengguna tidak mengisi, maka sistem akan dijalankan dengan menggunakan nilai default.

Pilihan "Informasi" dipergunakan untuk mengisi nilai iklim yang real.


Misalnya fase ENSO (Peubah 1) adalah sedang berlangsung El-Nino (nilai 2), dan Curah Hujan (peubah 2) adalah di atas normal (nilai 3), maka format datanya adalah 1,2;2,3.

Pilihan "Data" untuk menentukan data yang dipergunakan guna menduga parameter model bayesian network. Dalam hal ini Pengguna dapat memilih file data baru, membuat data baru ataupun mengupdate file default yang ada. Format penulisannya adalah untuk kolom 1, 2, 3, dan 4 berturut-turut nilai peubah 1 (Fase ENSO bulan Agustus tahun sebelumnya), peubah 2 (Curah hujan), peubah 3 (Sisa Dasarian Musim Hujan), dan peubah 4 (Kekeringan). Sedangkan baris adalah record data.

Pilihan Struktur dipergunakan untuk menentukan struktur bayesian network. Dalam hal ini dinyatakan dalam bentuk matrik evidensi, yang berisi 1 (ada link) dan 0 (tidak ada link), yang dibaca sebagai baris adalah parent dari kolom. Misalkan peubah 1 sebagai parent dari peubah 2 dan 3, peubah 2 dan peubah 3 sebagai parent dari peubah 4, maka matrik yang diinputkan adalah sebagai berikut :

0;1;1;0
0;0;0;1
0;0;0;1
0;0;0;0

Ini berarti peubah 1 sebagai parent dari peubah 2 dan 3, peubah 2 dan peubah 3 sebagai parent dari peubah 4. Struktur bayesian network yang sesuai untuk matriks di atas adalah seperti gambar berikut :

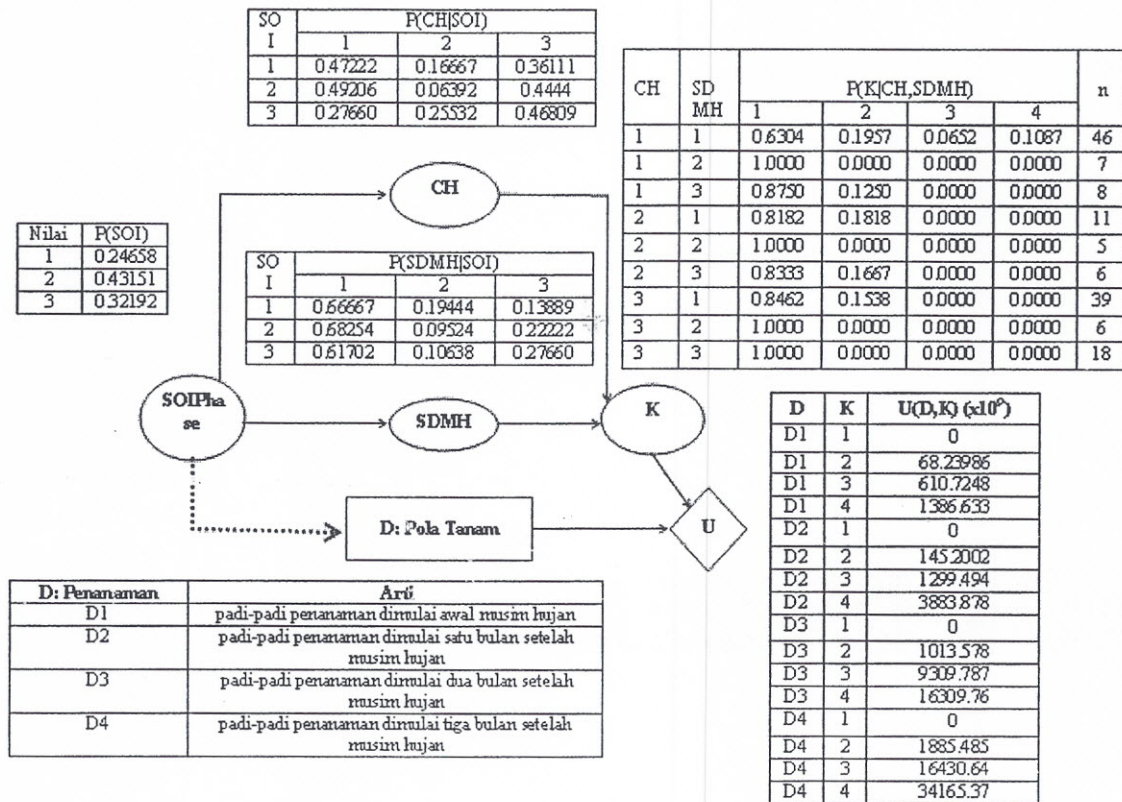


Untuk memperbaiki fungsi utilitas, Pengguna dapat memilih "Nilai Utility". Nilai utility ini ditentukan mengikuti tahapan seperti dideskripsikan pada bagian 4.

Berdasar data dari tahun 1989 hingga 2001 untuk salah satu kecamatan, dan menggunakan metode kemungkinan maksimum untuk menduga parameter

model, maka diperoleh bayesian network secara lengkap seperti diperlihatkan pada

Gambar 7.



Gambar 7. Model decision network untuk Indramayu berdasar data periode tahun 1989-2001

6. Kesimpulan

Telah berhasil dikembangkan model decision network yang terdiri dari empat peubah penyusun bayesian network (fase Enso, Curah Hujan, Sisa Dasarian Musim Hujan, dan Kekeringan), dan empat alternatif kebijakan pola tanam padi-padi. Perbedaan antar pola tanam adalah awal penanaman pertama, yaitu awal musim hujan, mundur 1, 2, dan 3 bulan. Oleh karena nilai risiko akibat memilih satu alternatif dikaitkan dengan kejadian iklim dipergunakan sebagai fungsi utilitas, maka kriteria pemilihan pola tanam adalah yang meminimumkan harapan fungsi utilitas.

Modul yang dikembangkan dengan metode kemungkinan maksimum untuk menduga parameter ini bersifat dinamis, sehingga Pengguna secara realtime dapat memprediksi risiko kekeringan pertanian kedua satu tahun ke depan yang didasarkan

informasi fase SOI bulan Agustus pada tahun ini.

Beberapa kelemahan yang ada diantaranya adalah minimnya jumlah data kekeringan dan data iklim lainnya yang tersedia untuk pelatihan sehingga dirasa kurang mampu mengakomodasi semua variasi yang ada. Dalam sistem belum disertakan model penduga peubah terkait curah hujan. Untuk penelitian selanjutnya akan integrasikan teknik downscaling untuk menduga sifat hujan, panjang musim dan awal musim hujan, sehingga informasi dalam menduga tingkat kekeringan lebih akurat.

Daftar Rujukan

- [1] Boer, R., et.al. 2008. Penyusunan Kalender Tanaman. Laporan Penelitian, CCROMSEAP LPM IPB kerjasama dengan BMKG dan Deptan. Bogor.
- [2] Neapolitan, R.E. 2004. Learning Bayesian Networks. Prentice Hall, New Jersey
- [3] Russell, S. dan Peter N. 2003. Artificial Intelligence A Modern Approach, Second Edition. Prentice Hall Series, New Jersey.
- [4] Buono, A. 2000. Sistem Pendeteksian Wajah 3D dalam Ruang Eigen dengan Metode Kemungkinan Maksimum Menggunakan Algoritma EM. Tesis Program Master Ilmu Komputer, Fasilkom UI.