



Prediksi Produktivitas Tanaman Padi di Kabupaten Karawang Menggunakan *Bayesian Networks*

Betha Nurina Sari¹, Hendi Permana², Kardo Trihandoko³, Asep Jamaludin⁴, Yuyun Umidah⁵
^{1,2,3,4,5}Program Studi Teknik Informatika, Fakultas Ilmu Komputer Universitas Singaperbangsa Karawang
^{1,2,3,4,5}Jl. H.S. Ronggowaluyo Telukjambe Timur, Karawang, Indonesia 41361
Email korespondensi : betha.nurina@staff.unsika.ac.id

Dikirim 12 November 2017, Direvisi 26 November 2017, Diterima 30 November 2017

Abstrak – Penelitian ini ditujukan untuk membangun sebuah model prediksi tingkat produktivitas padi di kabupaten Karawang. Prediksi menggunakan *Bayesian Networks* dilakukan dengan tiga tahap, yaitu tahap pra-pemrosesan data, tahap implementasi, dan tahap evaluasi. Tahap pra-pemrosesan dilakukan dengan transformasi data numerik menjadi data nominal dengan menggunakan dua skenario, yaitu *threshold mean* dan teknik diskretisasi. Tahap implementasi adalah menerapkan algoritma *Bayesian Networks*, yaitu melalui proses pembelajaran struktur dan pembelajaran parameter. Proses pembelajaran struktur dan parameter pada *Bayesian Networks* menggunakan *software* CaMML 1.41. Evaluasi performa *Bayesian Networks* dalam memprediksi produktivitas padi dengan *confusion matrix*, yaitu menghitung akurasi prediksi dan *log loss*. Hasil eksperimen menunjukkan hasil yang memuaskan, akurasi di atas 90%. Model terbaik dihasilkan dari tahap pra-pemrosesan menggunakan diskretisasi dan *training data* selama 5 tahun dan *testing data* selama 1 tahun. Hal ini menunjukkan pemilihan teknik pra-pemrosesan, teknik pembagian *training data*, dan *testing data* mempengaruhi hasil evaluasi performa struktur *Bayesian Networks*.

Kata kunci – *Bayesian Networks*, CaMML, prediksi, produktivitas padi

Abstract - This research is aimed to build a model for predicting rice productivity level in Karawang district. The prediction using Bayesian Networks allowed three stages, pre-processing of data, implementation, and evaluation stages. Pre-processing is transformation of numerical data into nominal data by using two scenarios, using threshold mean and discretization. Implementation stage is to apply Bayesian Networks algorithm, that is through structure learning process and parameter learning. The learning process of structures and parameters on Bayesian Networks using CaMML 1.41 software. Evaluation of Bayesian Networks performance in predicting rice productivity with confusion matrix, i.e. calculating prediction accuracy and log loss. The experiment results show the satisfactory results, the accuracy above 90%. The best model generated from pre-processing using the data discretization and 5-years training and 1-year testing data. This explain that the selection techniques of pre-processing, dividing of the training data, and testing the data affect the results of the performance evaluation of the structure of Bayesian Networks.

Keywords - Bayesian Networks, CaMML, prediction, rice productivity

I. PENDAHULUAN

Kabupaten Karawang dikenal dengan sebutan lumbung padi nasional, kota yang diandalkan untuk dapat memenuhi kebutuhan pangan provinsi juga nasional. Pada tahun 2015, Karawang merupakan penghasil padi terbanyak dengan penghasilan padi mencapai 1.070.505 ton GKP (Gabah Kering Panen) atau setara dengan beras 647.655 ton, yakni sekitar 71,85% dari target produksi 1.489.781 ton GKP.

Berdasarkan data dari Dinas Pertanian padmenunjukan bahwa luas panen paling besar di tahun 2007 seluas 197.377 Ha, tetapi produksi padi sebanyak 1.223.900 ton GKP, sehingga produktivitas sebesar 62,16 (Kw/Ha). Bila dilihat selama 10 tahun (2006-2015), tingkat produktivitas ton pada tahun 2007 merupakan yang terendah. Berbeda dengan data pada tahun 2015, dimana luas panen 190.725 Ha, produksi padi sebanyak 1.524.842,55 ton GKP, sehingga produktivitasnya mencapai 79,99 Kw/Ha. Tingkat

produktivitas padi tertinggi selama 10 tahun (2006-2015) adalah pada tahun 2015. Selain itu, setiap tahun terjadi perubahan luas panen, banyak produksi sehingga tingkat produktivitas padi juga mengalami perubahan (Dinas Pertanian Kehutanan dan Peternakan Kabupaten Karawang). Perkembangan luas panen, produksi, dan produktivitas padi sawah selama 10 tahun (2006-2015) dapat dilihat pada Tabel 1.

Membangun sebuah model untuk prediksi produktivitas padi sangat dibutuhkan untuk mengetahui faktor-faktor apa saja yang berpengaruh dominan dan dijadikan sasaran fokus perhatian di bidang pertanian di kabupaten Karawang. Hal ini terkait dengan peran Karawang dalam pemenuhan kebutuhan padi baik tingkat provinsi maupun nasional. Penelitian ini ditujukan untuk membangun sebuah model prediksi tingkat produktivitas padi di kabupaten Karawang menggunakan *Bayesian Networks*.

Tabel 1. Perkembangan Luas Panen, Produksi dan Produktivitas Padi Sawah

Tahun	Luas Panen (ha)	Produksi (Ton GKP)	Produktivitas (Kw/Ha)
2006	186.606	1.200.810	64,35
2007	197.377	1.223.900	62,16
2008	191.261	1.244.070	65,05
2009	192.502	1.352.396	70,25
2010	194.850	1.364.924	70,05
2011	197.005	1.459.406	74,08
2012	193.458	1.438.775	74,80
2013	195.929	1.481.466	75,61
2014	195.285	1.485.298	76,05
2015	190.725	1.524.842,55	79,99

Bayesian Networks dapat menghasilkan visualisasi berupa struktur graf hasil dari distribusi probabilitas, sehingga dapat digunakan untuk pemodelan suatu sistem dan prediksi. Graf yang terbentuk disebut *Directed Acyclic Graph* (DAG), dimana setiap *node* mewakili variabel dan terdapat *link* yang menghubungkan antar *node* [1]. Model berupa graf *Bayesian Networks* merepresentasikan *joint probability distribution* pada situasi yang tetap dan statis [2].

Metode yang digunakan dalam penelitian ini adalah algoritma *Bayesian Networks*. Metode ini dapat menghasilkan gambaran model berupa graf yang dapat memudahkan dalam memahami keterkaitan antara satu variabel dengan variabel yang lain. Selain itu, metode ini dapat mengintegrasikan pengetahuan pakar dengan data empirik [3].

Bayesian Networks telah diterapkan untuk pemodelan di bidang lingkungan, sumber daya air, agrikultur, geologi, kelautan, kehutanan, perikanan, dan bidang lingkungan yang lain [4]. Penelitian tersebut menunjukkan model terbaik dihasilkan dari skenario *training data* dan *learning data* daripada

skenario *uniform* dan *random*. CPT (*Conditional Probability Table*) yang terbentuk dapat merepresentasikan hubungan keterkaitan antar variabel dan dapat digunakan untuk prediksi penggunaan lahan dan perubahan penggunaan lahan. Pada tahun 2010, Carmel A.Pollino dan Christian Henderson di Australia menerapkan *Bayesian Networks* untuk memodelkan manajemen lingkungan, lalu ditulis dalam *Technical Report* [5]. Penulis menyebutkan bahwa kelebihan *Bayesian Networks* dapat memenuhi kebutuhan dalam hal mengintegrasikan tipe data dan informasi yang kualitatif, menentukan prioritas, fleksibilitas, dan dapat diperbarui apabila ada pengetahuan yang baru, dan dari sisi komunikasi karena hasilnya berbasis graf yang dapat memberikan dokumentasi dari asumsi secara eksplisit. Ana Passuello, dkk menerapkan *Bayesian Networks* untuk pemodelan klasifikasi kesesuaian lahan dalam 4 kriteria (*poor, marginally, moderately, highly suitable*) [6]. Model yang dihasilkan bermanfaat untuk mendukung pengambilan keputusan terkait ketidakpastian dan masalah yang kompleks untuk menggunakan biosolid sebagai *organic amendment*.

II. METODE PENELITIAN

Data yang digunakan pada penelitian ini mulai dari tahun 2010 sampai 2015, terdiri dari data luas sawah, luas baku sawah, luas tanam, luas panen, produksi, curah hujan, hari hujan, organisme pengganggu tanaman (penggerek batang, tikus, wereng batang cokelat, blasit, siput murbai, bakteri hawar daun, hama putih palsu), dan tingkat produktivitas yang ada di Dinas Pertanian Kabupaten Karawang.

Tingkat produktivitas didapatkan dari data produksi dan luas panen, yaitu dengan perhitungan pada persamaan (1).

$$\text{Produktivitas} = \frac{\text{Produksi}}{\text{Luas Panen}} \quad (1)$$

Kategori tingkat produktivitas padi [7] menggunakan ketentuan sebagai berikut,

- a) Tinggi: Produktivitas > 5.808
- b) Sedang: $5.727 \leq \text{Produktivitas} \leq 5.808$
- c) Rendah : Produktivitas < 5.727

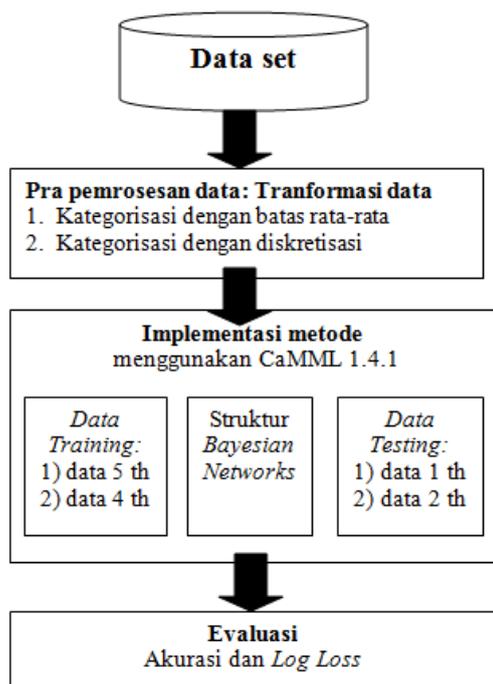
Metode penelitian dapat dilihat pada Gambar 1, dimana alur penelitian dimulai dari pengelolaan data set, tahap pra pemrosesan data, tahap implementasi metode, dan tahap evaluasi. Tahap pra pemrosesan data dilakukan untuk menjamin data yang digunakan sesuai untuk diterapkan. Data yang digunakan sebagian besar berupa numerik kontinu sehingga perlu dilakukan proses transformasi menjadi data kategori numerik. Peneliti menggunakan dua skenario untuk transformasi data yaitu,

- a) Skenario 1 : rata-rata sebagai batas, apabila nilai kurang dari rata-rata (*mean*) akan diberi angka 1 dan yang lebih dari rata-rata diberi angka 2 [8].

- b) Skenario 2 : diskretisasi, mereduksi sekumpulan nilai atribut kontinyu dengan membagi range dari atribut ke dalam interval [9].

Setelah tahap pra-pemrosesan selesai, maka dilanjutkan tahap implementasi, yaitu menerapkan algoritma *Bayesian Networks*, yaitu melalui proses pembelajaran struktur dan pembelajaran parameter. Proses pembelajaran struktur dan parameter pada *Bayesian Networks* menggunakan *software* CaMML 1.4.1. Pada tahap implementasi dibagi menjadi dua skenario, yaitu,

- a) Skenario 1 (data 5 tahun untuk data latih, data 1 tahun untuk data uji).
- b) Skenario 2 (data 4 tahun untuk data latih, data 2 tahun untuk data uji untuk diprediksi).



Gambar 1. Metode Penelitian

Evaluasi implementasi metode dalam penelitian ini menggunakan Netica-J API yang berbasis Java. Menampilkan model *Bayesian Networks* dapat menggunakan fungsi “Process Cases” pada Netica, seperti yang diterapkan John T. Mc Closkey dkk [10]. Evaluasi akan dilakukan dengan cara mengukur nilai akurasi, yaitu dengan membentuk matriks konvusi seperti yang ditunjukkan pada Gambar 2 dan menghitung *logarithmic loss* untuk menunjukkan besarnya *error* prediksi hasil.

		Prediksi	
		Negatif	Positif
Data Real	Negatif	A	B
	Positif	C	D

Gambar 2. Matriks Konvusi

$$Akurasi (\%) = \frac{A+D}{A+B+C+D} \times 100\% \quad (2)$$

$$Logloss = - \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M y_{i,j} \log(p_{i,j}) \quad (3)$$

Keterangan:

N = jumlah dari sampel atau data

M = jumlah dari kemungkinan label

y_{ij} = indikator biner (salah dan benar) pada j untuk pada setiap data i

p_{ij} = probabilitas pada label j pada setiap data i

III. HASIL PENELITIAN

Ekperimen dilakukan sebanyak empat kali, yaitu kombinasi tahap pre-pemrosesan data, skenario *training data* dan *testing data*. Daftar variabel dan kategori dapat dilihat pada Tabel 2.

Tabel 2. Daftar Variabel dan Kategori

No	Variabel	Kategori
1	Luas sawah	Rendah (1)
		Tinggi (2)
2	Luas baku sawah	Rendah (1)
		Tinggi (2)
3	Luas panen	Rendah (1)
		Tinggi (2)
4	Luas tanam	Rendah (1)
		Tinggi (2)
5	Produksi	Rendah (1)
		Tinggi (2)
6	Curah hujan	Rendah (1)
		Tinggi (2)
7	Hari hujan	Rendah (1)
		Tinggi (2)
8	Penggerek batang	Rendah (1)
		Tinggi (2)
9	Tikus	Rendah (1)
		Tinggi (2)
10	Wereng batang cokelat	Rendah (1)
		Tinggi (2)
11	Blasit	Rendah (1)
		Tinggi (2)
12	Siput murbai	Rendah (1)
		Tinggi (2)
13	Bakteri hawar daun	Rendah (1)
		Tinggi (2)
14	Hama putih palsu	Rendah (1)
		Tinggi (2)
15	Tingkat produktivitas	Rendah
		Sedang
		Tinggi

Implementasi pembelajaran struktur dan parameter pada *Bayesian Networks* dilakukan pada *software* CaMML 1.4.1. Aturan parameter *Bayesian Networks* menggunakan tipe MML: CPT (*Minimal M Length: Condition Probability Table*) dengan *Metropolis Algorithm Search* tipe generator *Java RNG-Random Seed* dan *prior arc probabily* sebesar 0.5. Masing-

masing skenario menghasilkan model yang berbeda, yaitu dengan rincian pada Tabel 3.

Tabel 3. Hasil Skenario Implementasi Metode

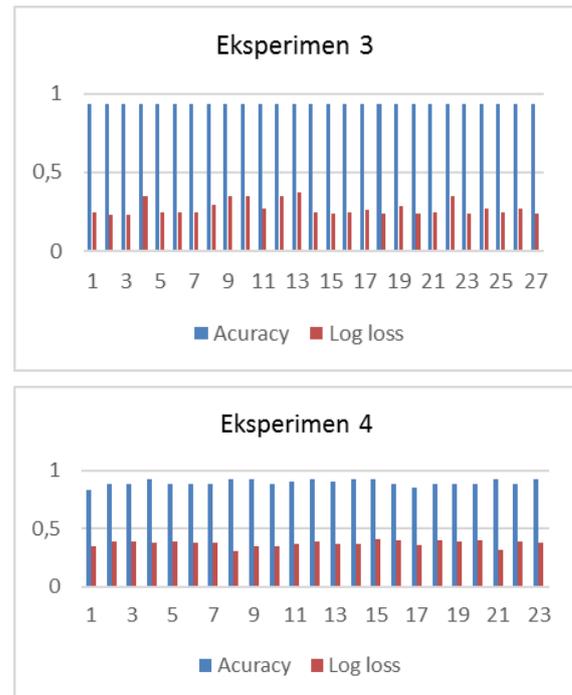
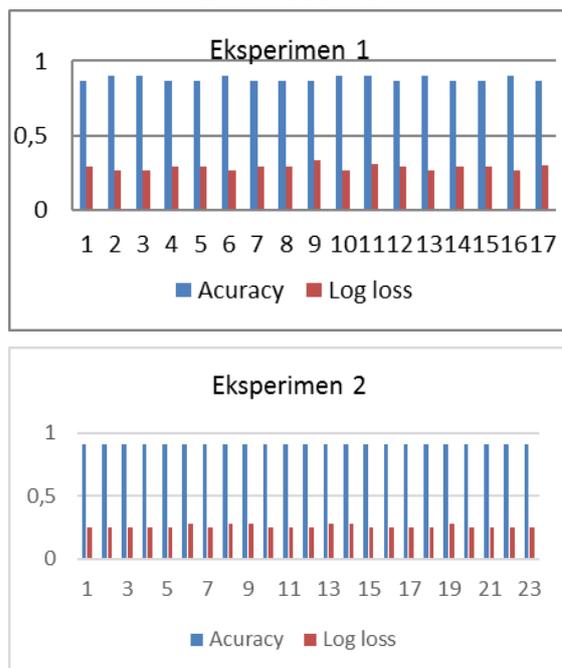
Skenario	Banyak Model
1	17 model
2	23 model
3	27 model
4	23 model

Setelah mendapatkan model struktur *Bayesian Networks* dari setiap skenario, maka dilakukan evaluasi performa untuk menyeleksi mana model terbaik. Dari Tabel 3 dapat dilihat, skenario 3 menghasilkan model terbanyak, sebanyak 27 model. Hal ini menunjukkan bahwa dilakukan sebanyak 27 kali evaluasi, karena masing-masing model diukur performanya dalam memprediksi kelas target, yaitu tingkat produktivitas.

Tahap pemilihan model terbaik dari setiap skenario eksperimen didapatkan dari evaluasi performa struktur *Bayesian Networks* berupa nilai akurasi dan *Log loss*. Masing-masing hasil evaluasi performa model *bayesian networks* dapat dilihat melalui gambar grafik dari empat eksperimen pada Gambar 3.

Selanjutnya didapatkan performa struktur model *Bayesian Networks* terbaik dari setiap skenario dalam memprediksi produktivitas padi, yaitu dapat dilihat pada Tabel 4. Hasil eksperimen menunjukkan hasil yang memuaskan, model terbaik setiap skenario eksperimen akurasinya di atas 90%.

Evaluasi Model

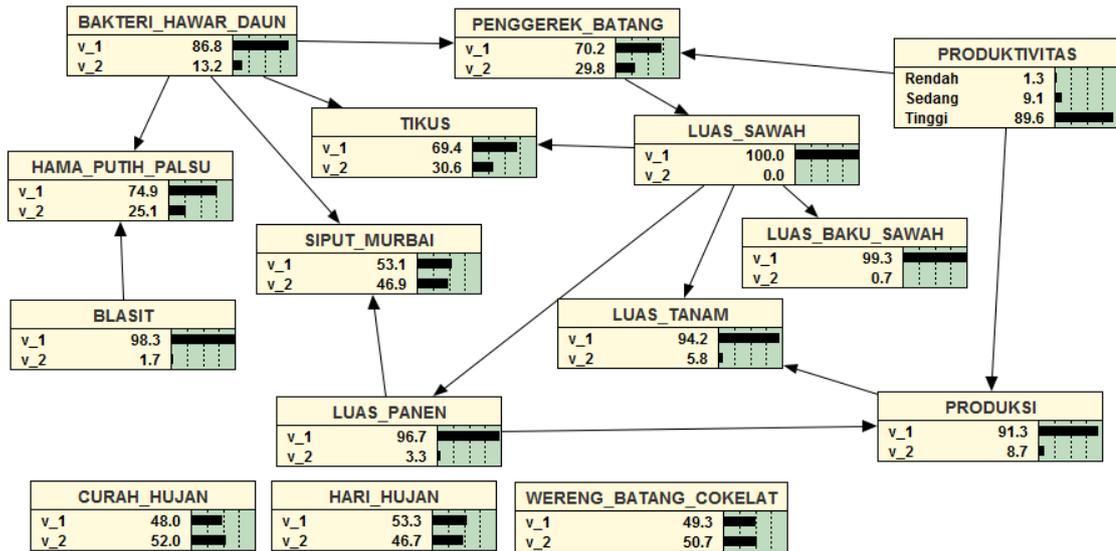
Gambar 3. Evaluasi Model *Bayesian Networks*Tabel 4. Evaluasi Performa *Bayesian Networks*

Skenario	Akurasi	Logarithmic Loss
1	0.90	0,2646
2	0.9090	0,2450
3	0.9333	0,2298
4	0.9268	0,3038

Skenario dengan *training data* dengan data 5 tahun dan 1 tahun untuk *testing data* menunjukkan performa yang lebih baik daripada skenario kedua. Hal ini menunjukkan jumlah data latih yang dipelajari juga mempengaruhi tingkat pembelajaran struktur model *Bayesian Networks*. Selain itu, skenario tahap pemrosesan data juga mempengaruhi hasil evaluasi performa, transformasi data menggunakan teknik diskretisasi lebih baik daripada teknik *threshold* mean (rata-rata). Hasil evaluasi skenario 3 dan 4 lebih tinggi daripada skenario 1 dan 2. Perlakuan pada tahap kategorisasi terhadap data numerik menjadi data nominal merupakan tahap yang penting dalam pemodelan dengan *Bayesian Networks*.

IV. PEMBAHASAN

Hasil pembelajaran *Bayesian Networks* untuk prediksi produktivitas padi menghasilkan model struktur dengan hasil evaluasi performa yang baik. Struktur bayesian yang direkomendasikan adalah hasil eksperimen ke-3, yaitu dapat dilihat pada Gambar 4.



Gambar 4. Struktur Graf Bayesian Networks

Dari Gambar 4 dapat dilihat keterkaitan antar 15 variabel, ada yang terhubung dan tidak terhubung. Ada 3 variabel yang tidak terhubung pada graf, yaitu curah hujan, hari hujan, dan hama warang batang coklat. Hal ini mengidentifikasi hubungan ketiga variabel tersebut independen terhadap variabel produktivitas padi. Sedangkan 12 variabel yang lain memiliki hubungan langsung dan hubungan tidak langsung terhadap produktivitas padi. Struktur *Bayesian Networks* menerapkan sifat Markov dimana dapat secara eksplisit menunjukkan hubungan independen bersyarat dalam distribusi probabilitas [11].

Besar probabilitas dari hubungan antar luas panen, produksi dan produktivitas padi dapat dilihat melalui *Conditional Probability Table* (CPT) pada Tabel 5.

Tabel 5. *Conditional Probability Table* (CPT) Variabel Luas Panen, Produktivitas Dan Produksi

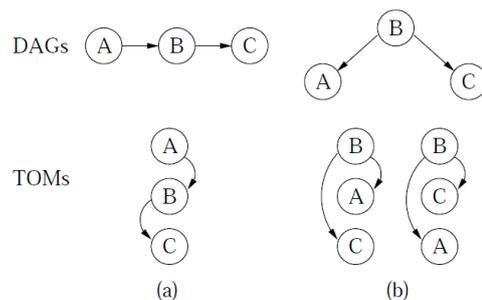
parents	node	probability
[LUAS_PANEN, PRODUKTIVITAS]	PRODUKSI	
1, Rendah	1	0,5
	2	0,5
1, Sedang	1	0,94
	2	0,06
1, Tinggi	1	0,95
	2	0,05
2, Rendah	1	0,17
	2	0,83
2, Sedang	1	0,5
	2	0,5
2, Tinggi	1	0,01
	2	0,99

Keterangan:
luas panen : 1 (kategori rendah), 2 (kategori tinggi)
produktivitas: rendah, sedang, tinggi

produksi : 1 (kategori rendah), 2 (kategori tinggi)

Keterkaitan ketiga variabel dapat ditunjukkan dari Tabel 5, dimana saat luas panen kategori tinggi dan produksi tinggi maka 99% produktivitas padi kategori tinggi. Selain itu luas panen kategori rendah, produksi kategori rendah, maka 94% kategori produktivitas sedang. Probabilitas sebesar 95% untuk luas panen kategori rendah, produksi rendah maka produktivitas masuk kategori tinggi. Hal ini menunjukkan ketiga variabel ini memiliki keterkaitan yang tinggi.

Konsep penting dalam pembelajaran kausal dalam CaMML adalah *Statistical Equivalence Class* (SEC). Dua DAG di dalam kelas ekuivalensi yang sama dapat diparameterisasi untuk memberikan identitas dari *joint probability distribution*. Dua DAG tersebut dapat dibedakan dan dipisahkan dengan variabel yang diberikan dari data observasi dan data eksperimental. Selain itu, konsep yang penting lainnya adalah *Totally Ordered Model* (TOM) terdiri dari sekumpulan koneksi dan *total ordering* atau permutasi dari semua variabel. Ada beberapa DAG yang berada pada satu SEC, dan ada beberapa TOM terbentuk dari satu DAG tunggal.



Gambar 5. DAG di dalam SEC yang sama, tetapi mempunyai TOM yang berbeda: (a) 1 TOM dengan urutan ABC, (b) 2 TOM dengan urutan BAC, BCA.

Gambar 5 menunjukkan bahwa dua DAG yang termasuk dalam SEC yang sama. Gambar DAG bagian

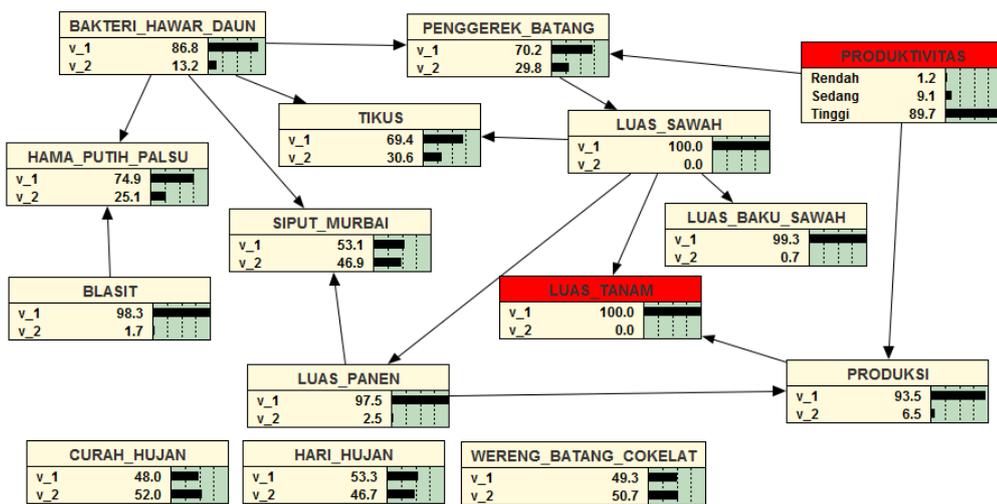
(a) merepresentasikan TOM tunggal dengan urutan ABC, sedangkan pada gambar DAG bagian (b) mempunyai dua TOM dengan urutan ABC dan ACB. Sesuai dengan *default prior* pada CaMML, DAG pada gambar bagian (b) mempunyai dua TOM yang mencerminkan besar jumlah cara DAG direalisasikan.

Algoritma pencarian *Markov Chain Monte Carlo* (MCMC) yang diterapkan pada CaMML menggunakan distribusi posterior atas *Directed Acyclic Graph* (DAG) dan *Statistical Equivalence Class* (SEC) dengan sampling ruang *Totally Ordered Model* (TOM).

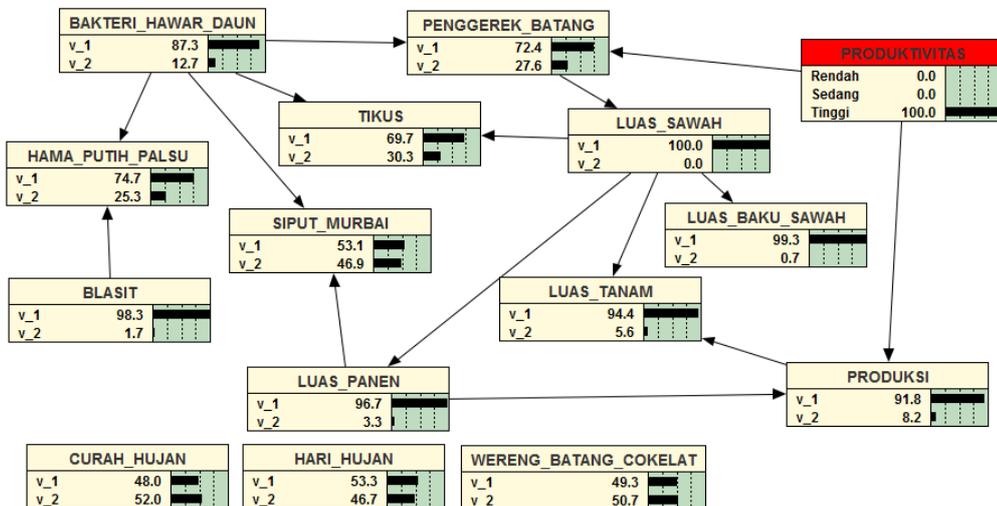
Hasil pemodelan struktur graf *Bayesian Networks* yang sudah terbangun maka siap digunakan untuk inferensi, yaitu dengan komputasi nilai probabilitas dari setiap variabel yang terdapat pada graf. Apabila ditemukan *evidence* atau fakta hasil observasi yang diketahui dari suatu variabel, maka probabilitas

posterior akan dikomputasi [12]. Misalnya diketahui luas tanam masuk dalam kategori rendah, maka akan tampil nilai probabilitas dari 11 variabel yang terhubung. Nilai probabilitas pada variabel luas panen 97,5% kategori rendah, produksi kategori rendah 93,5% dan tingkat produktivitas bernilai tinggi sebesar 89,7%. Hasil simulasi tersebut dapat dilihat pada Gambar 6.

Selain itu simulasi prediksi dapat juga dilakukan untuk kelas target, yaitu pada variabel produktivitas. Misalnya diharapkan tingkat produktivitasnya tinggi, maka dapat dilihat variabel-variabel yang lain yang dapat mempengaruhinya dengan nilai probabilitasnya. Hal ini dapat dilihat pada Gambar 7. Pada saat menentukan target tingkat produktivitas tinggi, ada beberapa faktor yang berkaitan, yaitu produksi kategori rendah 91,8 %, luas tanam kategori rendah 94,4%, luas sawah kategori rendah 100%, penggerek batang sedikit 72,4 %.



Gambar 6. Graf Bayesian Networks Dengan Nilai Probabilitas Setiap Variabel



Gambar 7. Graf Bayesian Networks Dengan Harapan Tingkat Produktivitas Tinggi

V. PENUTUP

A. Kesimpulan

Adapun kesimpulan dari penelitian ini adalah sebagai berikut, prediksi produktivitas padi di kabupaten Karawang menggunakan *Bayesian Networks* dilakukan dengan tiga tahap, yaitu tahap pra-pemrosesan data, tahap implementasi dan tahap evaluasi. Tahap implementasi menggunakan *software* CaMML 1.41 untuk fase pembelajaran struktur dan parameter. Tahap evaluasi performa menggunakan *package* Netica J-API. Hasil model berupa graf Bayesian Network dapat digunakan untuk simulasi prediksi tingkat produktivitas padi.

Evaluasi performa *Bayesian Networks* dalam memprediksi produktivitas padi di kabupaten Karawang dengan mengevaluasi struktur sesuai empat skenario implementasi dengan menghitung akurasi prediksi dan *logarithmic loss*. Pemilihan teknik pra-pemrosesan dan teknik pembagian *training data* dan *testing data* mempengaruhi hasil evaluasi performa struktur *Bayesian Networks*.

B. Saran

Saran untuk penelitian selanjutnya adalah penelitian dapat dilanjutkan dengan pemetaan pada lahan pertanian di kabupaten Karawang dengan menerapkan model terbaik dari *Bayesian Networks*. Penelitian ini dapat dikembangkan dengan metode lain atau penggabungan beberapa metode dalam prediksi produktivitas padi. Penelitian terkait prediksi produktivitas padi dapat diperluas cakupan obyek penelitiannya, misalnya meliputi data per bulan, penambahan variabel atau parameter pada data sehingga dapat memperkaya bagian analisis dan pengetahuan.

UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) Universitas Singaperbangsa Karawang yang telah mendukung penuh dan memberikan dana pendukung untuk menyelesaikan penelitian ini.

DAFTAR PUSTAKA

- [1] M. Aminian, D. Couvin, A. Shabbeer, K. Hadley, S. Vandenberg, N. Rastogi, and K. P. Bennett, "Predicting Mycobacterium tuberculosis Complex Clades Using Knowledge-Based *Bayesian Networks*", *BioMed Research International*, 2014.
- [2] M. Sandri, P. Berchialla, I. Baldi, D. Gregori, R. Alberto, and D. Blasi, "Dynamic *Bayesian Networks* to predict sequences of organ failures in patients admitted to ICU", *J. Biomed. Inform.*, 2014, vol.48, pp. 106–113.
- [3] P. Larrañaga, H. Karshenas, C. Bielza, and R. Santana, "A review on evolutionary algorithms in Bayesian network learning and inference tasks," *Information Sciences*, 2013, vol. 233, pp. 109–125.
- [4] P. A. Aguilera, A. Fernández, R. Fernández, R. Rumí, and A. Salmerón, "Environmental Modelling & Software *Bayesian Networks* in environmental modelling," *Environmental Modelling Software*, 2011, vol. 26, no. 12, pp. 1376–1388.
- [5] C. A. P. and C. Henderson, "*Bayesian Networks*: A guide for their application in natural resource management and policy", *Technical Report Landscape Logic*, 2010.
- [6] A. Passuello, O. Cadiach, V. Kumar, and M. Schuhmacher, "Application of *Bayesian Networks* for agricultural land suitability classification: a case study of biosolids amendment," *International Congress on Environmental Modelling and Software*, 2012.
- [7] B. Irawan, "Dinamika Produktivitas dan Kualitas Budi Daya Padi Sawah", 2016, pp. 179–199.
- [8] B. N. Sari, "Identifikasi Keterkaitan Variabel dan Prediksi Indeks Pembangunan Manusia (IPM) Provinsi Jawa Barat Menggunakan Dynamic *Bayesian Networks*," *Jurnal Infotel*, 2016, Vol.8 No.2, pp. 150–155.
- [9] H. Junaedi, H. Budianto, and I. Maryati, "Data transformation pada data mining", *Prosiding Konferensi Nasional Inovasi dalam Desain dan Teknologi-IDEaTech*, 2011, pp. 93–99.
- [10] J. T. McCloskey, R. J. Lilieholm, and C. Cronan, "Landscape and Urban Planning Using Bayesian belief networks to identify potential compatibilities and conflicts between development and landscape conservation," *Landsc. Urban Plan.*, vol. 101, no. 2, pp. 190–203, 2011.
- [11] K. B. Korb and A. E. Nicholson, *Bayesian Artificial Intelligence*, Second edi. CRC Press, 2011.
- [12] E. Millán, T. Loboda, and J. L. Pérez-de-la-cruz, "Computers & Education *Bayesian Networks* for student model engineering," *Computers & Education*, vol. 55, 2010, pp. 1663–1683.