

	Jurnal Arjuna : Aplikasi Riset Jaringan dan Komputer Volume 1, Number 1, November 2023 (Halaman 1 - 6) DOI : https://doi.org/10.5281/zenodo.11077557	e-ISSN : 3032-7229
---	--	--------------------

IMPLEMENTASI ALGORITMA C4.5 UNTUK DETEKSI DINI PENYAKIT DIABETES MELLITUS PADA MANUSIA

Oleh :
Chandra✉

Program Studi Teknik Informatika, STMIK TIME Medan
email: chandra.wiejaya@gmail.com

Abstrak

Diabetes tergolong sebagai salah satu penyakit kronis yang mengancam jiwa dengan pertumbuhan tercepat yang telah mempengaruhi 422 juta orang di seluruh dunia menurut laporan *World Health Organization* (WHO), pada tahun 2018. Oleh sebab itu, sangat penting melakukan deteksi dini terhadap penyakit DM karena apabila penyakit tersebut dibiarkan terlalu lama tanpa adanya pengobatan maka dapat berakibat pada komplikasi yang berbahaya seperti gagal ginjal, kerusakan fungsi organ lainnya hingga serangan jantung. Pada penelitian ini akan dibangun sebuah sistem informasi dengan menerapkan algoritma *data mining* C4.5 untuk deteksi dini penyakit *Diabetes Mellitus* pada manusia. *Dataset* pada penelitian ini diambil dari *Kaggle Diabetes Dataset*. Hasil penelitian menunjukkan bahwa sistem informasi yang dibangun dapat membantu dunia medis dalam melakukan deteksi dini penyakit *Diabetes Mellitus* pada manusia melalui fitur prediksi yang mengimplementasikan algoritma C4.5. Selain itu, hasil pengujian algoritma C4.5 menunjukkan bahwa algoritma tersebut tergolong akurat dalam melakukan prediksi deteksi dini penyakit *Diabetes Mellitus* apabila mengikuti *rule* pohon keputusan yang terbentuk.

Kata Kunci : Sistem Prediksi, *Diabetes Mellitus*, Pohon Keputusan, C4.5

1. PENDAHULUAN

Diabetes Mellitus (DM), menurut definisi *World Health Organization* (WHO), adalah penyakit degeneratif kronis yang disebabkan oleh produksi insulin yang tidak mencukupi di pankreas atau oleh ketidakmampuan tubuh untuk secara efektif menggunakan insulin yang diproduksi, mengambil *hyperglycemia* (peningkatan glukosa darah) sebagai indikator utama [1]. Diabetes tergolong sebagai salah satu penyakit kronis yang mengancam jiwa dengan pertumbuhan tercepat yang telah mempengaruhi 422 juta orang di seluruh dunia menurut laporan Organisasi Kesehatan Dunia (WHO), pada tahun 2018. Diabetes dianggap sebagai salah satu penyakit paling mematikan dan kronis yang menyebabkan peningkatan gula darah. Banyak komplikasi yang dapat terjadi jika diabetes tetap tidak diobati dan tidak teridentifikasi sejak awal [2].

Secara umum, penyakit DM memiliki gejala yang hampir mirip dengan kondisi sakit biasa sehingga banyak orang yang tidak menyadari bahwa mereka mengidap penyakit tersebut dan bahkan sudah mengarah pada komplikasi. Oleh sebab itu, sangat penting melakukan deteksi dini terhadap penyakit

DM karena apabila penyakit tersebut dibiarkan terlalu lama tanpa adanya pengobatan maka dapat berakibat pada komplikasi yang berbahaya seperti gagal ginjal, kerusakan fungsi organ lainnya hingga serangan jantung. Banyak cara yang dapat dilakukan dalam mendeteksi dini seseorang mengalami penyakit DM atau tidak. Jika dari sisi medis, diagnosa penyakit DM dapat dilakukan melalui pengecekan darah. Namun terkadang dari sisi medis, proses pengecekan darah hanya melihat dari satu parameter saja yaitu kadar gula darah pasien. Faktanya, terkadang kadar gula darah pasien rendah, namun pasien tersebut merupakan pasien DM sehingga perlu melibatkan parameter-parameter lain dari pasien agar menghasilkan hasil deteksi dini yang lebih akurat [3].

Dari sisi sains komputer, proses deteksi dini penyakit DM pada manusia dapat dilakukan melalui sistem informasi dengan menerapkan teknik *data mining*. *Data mining* merupakan suatu rangkaian atau tindakan untuk menemukan hubungan yang memiliki arti melalui pola dan kecenderungan dalam himpunan besar data yang tersimpan dengan menggunakan metode ataupun algoritma [4]. Kelebihan dari pemanfaatan sistem informasi dan teknik *data mining* adalah dapat melakukan deteksi dini penyakit DM

pada manusia secara cepat. Selain itu, dengan data mining, maka dapat dilakukan prediksi dengan melibatkan parameter-parameter yang lebih banyak tidak hanya berdasarkan satu parameter saja namun juga melibatkan parameter-parameter lain seperti usia, berat badan, tekanan darah, dan parameter-parameter lainnya sehingga hasil deteksi lebih akurat [5]. Salah satu algoritma data mining yang memiliki akurasi yang cukup baik dalam deteksi dini penyakit adalah algoritma C4.5. Berdasarkan penelitian terdahulu dilakukan perbandingan algoritma C4.5 dan Naïve Bayes dalam memprediksi penyakit Cerebrovascular. Hasil penelitian yang dilakukan menyimpulkan bahwa algoritma C4.5 memperoleh tingkat akurasi yang lebih tinggi yaitu 95% sedangkan algoritma Naive Bayes memperoleh tingkat akurasi 91% [6].

Berdasarkan uraian yang telah dipaparkan, maka akan dibangun sebuah sistem informasi dengan menerapkan algoritma data mining C4.5 untuk deteksi dini penyakit *Diabetes Mellitus* pada manusia.

2. METODE PENELITIAN

Metode Pengumpulan Data

Metode pengumpulan data yang digunakan pada penelitian ini antara lain sebagai berikut:

a. Metode Observasi

Melakukan survei ke beberapa klinik untuk mengumpulkan data-data yang akan diolah pada penelitian yaitu data pasien penderita penyakit *Diabetes Mellitus*.

b. Metode Studi Pustaka

Mengumpulkan data-data teori melalui jurnal, media cetak, ataupun sumber-sumber referensi dari internet.

Analisis Sistem

Analisis sistem pada penelitian ini terbagi menjadi 3 tahapan proses yaitu:

- Analisis sistem berjalan yaitu melakukan analisis sistem berjalan yang digunakan saat ini khususnya sistem berjalan yang digunakan dalam melakukan deteksi dini penyakit *Diabetes Mellitus*.
- Analisis algoritma yang digunakan yaitu algoritma *Decision Tree* C4.5 dengan memaparkan contoh kasus sederhana implementasi algoritma tersebut dalam membentuk pohon keputusan yang digunakan untuk deteksi dini penyakit *Diabetes Mellitus*. Pada tahap ini akan diuraikan secara lengkap cara kerja dari algoritma *Decision Tree* C4.5 dalam bentuk contoh kasus sederhana berupa 10 data *training* dan 1 data *testing* serta menunjukkan hasil deteksi yang didapatkan.

Penelitian ini mengimplementasikan algoritma C4.5 untuk deteksi dini penyakit *Diabetes Mellitus* pada manusia. Berikut ini Tabel 3.1 menunjukkan contoh 10 *dataset* yang digunakan diambil dari <https://www.kaggle.com/datasets/mathchi/diabetes-data-set>.

Tabel 1. Contoh *Dataset* Penelitian

<i>Pregnancies</i>	<i>Glucose</i>	<i>BloodPressure</i>	<i>SkinThickness</i>	<i>Insulin</i>	<i>BMI</i>	<i>DiabetesPedigreeFunction</i>	<i>Age</i>	<i>Outcome</i>
6	148	72	35	0	33.6	0.627	50	1
1	85	66	29	0	26.6	0.351	31	0
8	183	64	0	0	23.3	0.672	32	1
1	89	66	23	94	28.1	0.167	21	0
0	137	40	35	168	43.1	2.288	33	1
5	116	74	0	0	25.6	0.201	30	0
3	78	50	32	88	31.0	0.248	26	1
10	115	0	0	0	0.0	0.261	30	0
2	197	70	45	543	30.5	0.158	53	1
8	125	96	0	0	0.0	0.232	54	1

Langkah-langkah dalam membuat model C4.5 adalah sebagai berikut:

a. Menghitung *entropy* dari label (*Outcome*) di seluruh *dataset*.

Jumlah total sampel = 10

Jumlah sampel dengan *Outcome* 0 = 5 Jumlah

sampel dengan *Outcome* 1 = 5

Entropy untuk seluruh *dataset* dapat dihitung dengan menggunakan rumus berikut:

$Entropy = - (p_1 * \log_2(p_1)) - (p_2 * \log_2(p_2))$
dengan p_1 dan p_2 masing-masing merupakan proporsi sampel dengan *Outcome* 0 dan *Outcome* 1.

$$p_1 = 5 / 10 = 0.5$$

$$p_2 = 5 / 10 = 0.5$$

$$Entropy = - (0.5 * \log_2(0.5)) - (0.5 * \log_2(0.5)) = 1.0$$

Jadi, entropi dari label (*Outcome*) di seluruh dataset adalah 1.0.

- b. Membagi dataset menjadi subset yang lebih kecil, berdasarkan nilai dari setiap atribut. Pada langkah ini, akan diperiksa setiap atribut dan membagi dataset menjadi subset yang lebih kecil berdasarkan nilai dari atribut tersebut. Selanjutnya akan dipilih atribut dengan *gain* informasi tertinggi sebagai atribut pemisah pada *node* (akar).

1) Atribut *Pregnancies*

- a) Subset 1: Sampel dengan *Pregnancies* ≤ 1

Jumlah total sampel = 2

Jumlah sampel dengan *Outcome* 0 = 1

Jumlah sampel dengan *Outcome* 1 = 1

- b) Subset 2: Sampel dengan *Pregnancies* > 1

Jumlah total sampel = 8

Jumlah sampel dengan *Outcome* 0 = 4

Jumlah sampel dengan *Outcome* 1 = 4

2) Atribut *Glucoses*

- a) Subset 1: Sampel dengan *Glucoses* ≤ 137

Jumlah total sampel = 4

Jumlah sampel dengan *Outcome* 0 = 1

Jumlah sampel dengan *Outcome* 1 = 3

- b) Subset 2: Sampel dengan *Glucoses* > 137

Jumlah total sampel = 6

Jumlah sampel dengan *Outcome* 0 = 4

Jumlah sampel dengan *Outcome* 1 = 2

3) Atribut *BloodPressure*

- a) Subset 1: Sampel dengan *BloodPressure* ≤ 70

Jumlah total sampel = 3

Jumlah sampel dengan *Outcome* 0 = 1

Jumlah sampel dengan *Outcome* 1 = 2

- b) Subset 2: Sampel dengan *BloodPressure* > 70

Jumlah total sampel = 7

Jumlah sampel dengan *Outcome* 0 = 4

Jumlah sampel dengan *Outcome* 1 = 3

4) Atribut *SkinThickness*

- a) Subset 1: Sampel dengan *SkinThickness* ≤ 23

Jumlah total sampel = 5

Jumlah sampel dengan *Outcome* 0 = 3

Jumlah sampel dengan *Outcome* 1 = 2

- b) Subset 2: Sampel dengan *SkinThickness* > 23

Jumlah total sampel = 5

Jumlah sampel dengan *Outcome* 0 = 2

Jumlah sampel dengan *Outcome* 1 = 3

5) Dan seterusnya

- c. Menghitung *gain* informasi dari setiap atribut dan memilih atribut dengan *gain* informasi tertinggi sebagai atribut pemisah pada *node* (akar). *Gain* informasi untuk setiap atribut dapat dihitung dengan menggunakan rumus berikut:

$$Gain = Entropy \text{ sebelumnya} - \left(\frac{total_sampel_subset1}{total_sampel} * Entropy_subset1 \right) - \left(\frac{total_sampel_subset2}{total_sampel} * Entropy_subset2 \right)$$

1) Atribut *Pregnancies*

$$Gain = 1.0 - \left(\frac{2}{10} * - (0.5 * \log_2(0.5)) - (0.5 * \log_2(0.5)) \right) - \left(\frac{8}{10} * - (0.5 * \log_2(0.5)) - (0.5 * \log_2(0.5)) \right) = 0.0$$

2) Atribut *Glucose*

$$Gain = 1.0 - \left(\frac{4}{10} * - (0.25 * \log_2(0.25)) - (0.75 * \log_2(0.75)) \right) - \left(\frac{6}{10} * - (0.67 * \log_2(0.67)) - (0.33 * \log_2(0.33)) \right) = 0.066$$

3) Atribut *BloodPressure*

$$Gain = 1.0 - \left(\frac{3}{10} * - (0.33 * \log_2(0.33)) - (0.67 * \log_2(0.67)) \right) - \left(\frac{7}{10} * - (0.43 * \log_2(0.43)) - (0.57 * \log_2(0.57)) \right) = 0.002$$

4) Atribut *SkinThickness*

$$Gain = 1.0 - \left(\frac{5}{10} * - (0.4 * \log_2(0.4)) - (0.6 * \log_2(0.6)) \right) - \left(\frac{5}{10} * - (0.4 * \log_2(0.4)) - (0.6 * \log_2(0.6)) \right) = 0.0$$

5) Atribut *Insulin*

$$Gain = 1.0 - \left(\frac{3}{10} * - (1/3 * \log_2(1/3)) - (2/3 * \log_2(2/3)) \right) - \left(\frac{7}{10} * - (0.57 * \log_2(0.57)) - (0.43 * \log_2(0.43)) \right) = 0.089$$

6) Dan seterusnya

Atribut dengan *gain* informasi tertinggi adalah *Glucose* dengan *gain* sebesar 0.066.

- d. Membuat *node* baru dengan atribut pemisah *Glucose*.


- e. Membuat cabang-cabang baru pada *node Glucose* berdasarkan nilai-nilai yang dimilikinya, yaitu ≤ 112 dan > 112 .

- f. Mengulangi proses untuk setiap subset yang terbentuk pada cabang-cabang baru sampai

mencapai kondisi terminasi.

Pada contoh ini, terdapat 6 sampel pada subset *Glucose* ≤ 112 dan 4 sampel pada subset *Glucose* > 112 . Karena setiap subset telah mencapai kondisi terminasi (semua sampel pada subset memiliki nilai *Outcome* yang sama), maka proses pembentukan cabang-cabang baru dihentikan dan *Decision Tree* selesai dibentuk.

Decision Tree yang dihasilkan memiliki struktur sebagai berikut.



Keterangan: *Decision Tree* hanya memiliki satu node (akar) dan dua daun. Nilai 3 pada daun kiri mengindikasikan bahwa terdapat 3 sampel pada subset *Glucose* ≤ 112 yang memiliki nilai *Outcome* = 0 (tidak terdiagnosis *Diabetes Mellitus*), sedangkan nilai 1 pada daun kanan mengindikasikan bahwa terdapat 1 sampel pada subset *Glucose* > 112 yang memiliki nilai *Outcome* = 1 (terdiagnosis *Diabetes Mellitus*).

Decision Tree yang dihasilkan dapat digunakan untuk melakukan klasifikasi pada data baru. Misalnya, untuk seorang pasien dengan nilai *Glucose* sebesar 100, *Decision Tree* akan menentukan bahwa pasien tersebut tidak terdiagnosis *Diabetes Mellitus* (*Outcome* = 0) karena nilai *Glucose* ≤ 112 . Sedangkan untuk seorang pasien dengan nilai *Glucose* sebesar 120, *Decision Tree* akan menentukan bahwa pasien tersebut terdiagnosis *Diabetes Mellitus* (*Outcome* = 1) karena nilai *Glucose* > 112 .

Misalkan contoh terdapat sebuah data pasien yang akan diprediksi sebagai berikut:

Pregnancies: 8

Glucose: 125

Blood Pressure: 96

Skin Thickness: 0

Insulin: 0

BMI: 23,5

Diabetes Pedigree Function: 0.234

Age : 54

Maka berdasarkan pohon keputusan dimana akar utama dimulai dari *Glucose* sehingga untuk memprediksi data pasien dengan melihat nilai *Glucose* pasien tersebut yaitu sebesar 125. Berdasarkan pohon keputusan, *Glucose* > 112 adalah diprediksi sebagai pasien terdiagnosis

Diabetes Mellitus (*Outcome* = 1) sehingga pasien tersebut diprediksi pasien terdiagnosis *Diabetes Mellitus*.


Perancangan Sistem

Perancangan sistem pada penelitian ini terbagi menjadi 2 tahapan yaitu:

- Perancangan *prototype* tampilan dengan menggunakan *software* Balsamiq Mockup 3.
- Perancangan basis data yang menunjukkan relasi antar tabel dari setiap basis data yang dimodelkan dengan menggunakan *tools* *Entity Relationship Diagram* (ERD).

3. HASIL DAN PEMBAHASAN

Hasil penelitian berupa dibangunnya sebuah sistem deteksi dini penyakit *Diabetes Mellitus* pada manusia dengan mengimplementasikan algoritma C4.5. Berikut ini akan disajikan keseluruhan hasil tampilan dari sistem usulan yang akan dibangun. Tampilan paling awal adalah berupa tampilan untuk




melakukan proses instalasi sistem. Setiap pelayanan medis yang hendak menggunakan sistem harus melakukan instalasi awal seperti yang ditunjukkan pada Gambar 1.

Gambar 1. Tampilan Instalasi Sistem

Untuk melakukan instalasi awal sistem cukup mengisikan informasi yang tersedia pada *form*. Jika semua *form* telah terisi, maka pengguna cukup menekan tombol mulai untuk memproses *form* yang diisikan dan mendaftarkan informasi ke dalam basis data sistem.

Setelah proses instalasi selesai dilakukan, maka



untuk menderita penyakit *Diabetes Mellitus*. Selanjutnya atribut pendukung berikutnya adalah jumlah pasien melahirkan juga menjadi pertimbangan serta *Skin Thickness*. Terdapat atribut-atribut yang tidak masuk dalam pohon keputusan berdasarkan data *training* yang digunakan yakni *Insulin*, *BMI*, dan *Diabetes Pedigree Function*.

Berdasarkan hasil pengujian algoritma C4.5 tergolong akurat dalam melakukan prediksi deteksi dini penyakit *Diabetes Mellitus* apabila mengikuti *rule* pohon keputusan yang terbentuk.

4. REFERENSI

- [1] A. Viloriaa, Y. H. Beltranb, B. Cabrera and O. B. Pineda, "Diabetes Diagnostic Prediction Using Vector Support Machines," *Procedia Computer Science*, pp. 376-381, 2020.
- [2] W. Apriliah, I. Kurniawan, M. Baydhowi and T. Haryati, "Prediksi Kemungkinan Diabetes pada Tahap Awal Menggunakan Algoritma Klasifikasi Random Forest," *Jurnal Sistem Informasi (SISTEMASI)*, vol. X, no. 1, pp. 163-171, 2021.
- [3] W. Yusnaeni and Widiarina, "Penerapan Algoritma C4.5 Dalam Prediksi Resiko Diabetes Tahap Awal (Early Stage Diabetes)," *Jurnal Teknik Komputer AMIK BSI*, vol. VIII, no. 1, pp. 56-60, 2022.
- [4] A. Muzakir and R. A. Wulandari, "Model Data Mining sebagai Prediksi Penyakit Hipertensi Kehamilan dengan Teknik Decision Tree," *Scientific Journal of Informatics*, vol. III, no. 1, pp. 19-26, 2016.
- [5] I. M. S. Ramayu, F. Susanto and G. S. Mahendra, "Penerapan Data Mining Dengan Algoritma C4.5 Dalam Pemesanan Obat Guna Meningkatkan Keuntungan Apotek," in *Prosiding Seminar Nasional Manajemen, Desain & Aplikasi Bisnis Teknologi (SENADA)*, Bali, 2022.
- [6] K. L. Kohsasih and Z. Situmorang, "Analisis Perbandingan Algoritma C4.5 Dan Naïve Bayes Dalam Memprediksi Penyakit Cerebrovascular," *Jurnal Informatika*, vol. IX, no. 1, pp. 13-17, 2022.
- [7] M. Dewi, Yellyanda and D. Ulfa, "Edukasi Penatalaksanaan Diabetes Terhadap Manajemen Perawatan Diri Pasien Diabetes Mellitus Tipe II," *Jurnal Keperawatan Silampari*, vol. V, no. 2, pp. 981-990, 2022.
- [8] I. P. P. Iswara, F. Farhan, W. Kumara and A. A. Supianto, "Rekomendasi Pengambilan Mata Kuliah Pilihan Untuk Mahasiswa Sistem Informasi Menggunakan Algoritma Decision Tree," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 6, no. 3, pp. 341-348, 2019.
- [9] C. Armayani, A. Fauzi and H. Sembiring, "Implementasi Data Mining Dalam Pengelompokan Jumlah Data Produktivitas Ubinan Tanaman Pangan Berdasarkan Jenis Ubinan Dengan Metode Clustering Dikab Langkat (Studi Kasus: Badan Pusat Statistik Langkat)," *Jurnal Informatika Kaputama (JIK)*, vol. V, no. 1, pp. 185-196, 2021.
- [10] N. Anwar, F. Adikara, R. Setiyati, R. Satria and A. Satriawan, "Data Mining Menggunakan Metode Algoritma Apriori Pada Vending Machine Product Display," *Journal of Business and Audit Information Systems*, vol. IV, no. 2, pp. 23-31, 2021.
- [11] E. Elisa, "Analisa dan Penerapan Algoritma C4.5 Dalam Data Mining Untuk Mengidentifikasi Faktor-Faktor Penyebab Kecelakaan Kerja Kontruksi PT.Arupadhatu Adisesanti," *JOIN*, vol. II, no. 1, pp. 36-41, 2017.
- [12] R. A. Sukanto and M. Shalahuddin, *Rekayasa Perangkat Lunak Terstruktur dan Berorientasi Objek*, Bandung: Informatika, 2018.
- [13] J. Enterprise, *Mengenal PHP Menggunakan Framework Laravel*, Jakarta: Elex Media Komputindo, 2016.
- [14] Y. Yudhanto and H. A. Prasetyo, *Panduan Mudah Belajar Framework Laravel*, Jakarta: Elex Media Komputindo, 2018. Y. Supardi and Sulaeman, *Semua Bisa Menjadi Programmer Laravel Basic*, Jakarta: Elex Media Komputindo, 2019.

 Jurnal Arjuna	Jurnal Arjuna : Aplikasi Riset Jaringan dan Komputer Volume 1, Number 1, November 2023 (Halaman 1 - 6) DOI : https://doi.org/10.5281/zenodo.11077557	e-ISSN : 3032-7229
--	---	---------------------------
